

COMO A COVID-19 AFETOU O SETOR DE TRANSPORTES NO BRASIL? - UMA ABORDAGEM BASEADA EM ANÁLISE ENVOLTÓRIA DE DADOS (DEA)

PAULO NOCERA ALVES JUNIOR
UNIVERSIDADE DE SÃO PAULO (USP)

ISOTILIA COSTA MELO
ESCOLA DE ENGENHARIA DE SÃO CARLOS - EESC

FERNANDO VINÍCIUS DA ROCHA
UNIVERSIDADE DE SÃO PAULO (USP)

RODRIGO DE MORAES SANTOS
ESCOLA DE ENGENHARIA DE SÃO CARLOS - EESC

JOSÉ VICENTE CAIXETA FILHO
UNIVERSIDADE DE SÃO PAULO (USP)

Agradecimento à órgão de fomento:

Os autores gostariam de agradecer à Fundação de Amparo à Pesquisa do Estado de São Paulo - FAPESP, processos nº 2017/50420-7 e 2018/20436-1, e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES (001), pelo apoio.

COMO A COVID-19 AFETOU O SETOR DE TRANSPORTES NO BRASIL? – UMA ABORDAGEM BASEADA EM ANÁLISE ENVOLTÓRIA DE DADOS (DEA)

INTRODUÇÃO

Acontecimento recente, a COVID-19 tem recebido atenção internacional pelo potencial de danos socioeconômicos que pode gerar nas mais diversas localidades. Com origem em território chinês, a doença assumiu o *status* de pandemia dado pela Organização Mundial da Saúde (OMS) e atingiu uma série de países, os quais tiveram que readaptar a rotina de suas sociedades. O Brasil é um dos países com maior número de casos confirmados da COVID-19 no mundo, tendo as suas operações logísticas de alguma forma afetadas pelo novo conjunto de restrições, que foi imposto como forma de minimizar os efeitos negativos causados. A queda repentina na demanda pelo serviço de transporte e eventuais dificuldades operacionais impostas ao uso dos ativos logísticos impôs, entre outras coisas, o comprometimento financeiro de uma série de operadores logísticos que atuam no mercado brasileiro. Além disso, a incerteza da retomada gradual da economia também aumenta as irresoluções das empresas e profissionais da área logística, mesmo sendo parte das operações consideradas como serviços essenciais.

Inserido nesse contexto, o presente artigo discute os impactos da COVID-19 no cenário logístico brasileiro, traçando um comparativo entre diferentes operadores logísticos a partir de um conjunto de dados obtidos junto à Confederação Nacional dos Transportes (CNT). Os dados fazem parte de uma pesquisa realizada pela instituição com o objetivo de identificar os impactos da doença sob a ótica de diferentes *players* que atuam no mercado de transporte brasileiro. O comparativo é feito a partir da aplicação do modelo *Slack-Based Measure* (SBM) de Análise Envoltória de Dados (DEA), que traça a eficiência relativa dos casos analisados.

Dessa forma, pelo comparativo entre os agentes atuantes em 11 subsetores de transporte no Brasil, este artigo teve por objetivo responder às seguintes questões: (i) quais os setores se mostraram mais eficientes com relação à gestão dos impactos da pandemia da COVID-19?; e (ii) quais setores foram menos eficientes em relação às respostas para a crise ocasionada pela COVID-19? (iii) sob a perspectiva da comparação entre subsetores, pode-se sugerir alguma política pública para melhorar a eficiência?

CONTEXTO INVESTIGADO

No início de janeiro de 2020, a OMS reconheceu o vírus causador da COVID-19 como um novo agente patológico, que teve os seus primeiros casos registrados na cidade Chinesa de Wuhan em meados de dezembro de 2019 (TOIT, 2020). Esse novo vírus pode causar, em seres humanos, doenças respiratórias leves ou severas de resfriado a uma pneumonia severa, sendo facilmente transmissível entre as pessoas (MINISTÉRIO DA SAÚDE, 2020).

Segundo Guo et al (2019), no início de março de 2020, o vírus havia se espalhado por mais de 85 países além da China. De acordo com dados disponibilizados pelo Worldometers (2020), foram registrados aproximadamente 9,23 milhões de casos de pacientes infectados com a COVID-19 em 215 países até o final do mês de junho, desde o primeiro caso registrado na China. Dentre esses países, o Brasil se configurava como o segundo país com o maior número de casos, com aproximadamente 1,11 milhões de indivíduos contaminados, ficando atrás apenas dos Estados Unidos, com 2,34 milhões de infectados.

A OMS (2020) estima que cerca de 20% dos infectados com a COVID-19 podem necessitar de tratamento hospitalar em função das dificuldades respiratórias. Devido à inexistência de tratamentos confirmados ou vacinas, Barreto et al (2020) apontam que as medidas de isolamento social são fundamentais para conter o avanço da doença enquanto são buscadas maneiras de ampliar a capacidade dos sistemas de saúde e tratamentos e vacinas que possam combater o vírus.

No Brasil, o primeiro caso de coronavírus foi registrado no dia 25 de fevereiro de 2020, segundo o Ministério da Saúde (2020). Com o avanço da doença no país, ao final do mês de março, o governo do estado de São Paulo passou a adotar medidas de isolamento social para conter o avanço da doença, para evitar um colapso do sistema de saúde, e, na sequência, os demais estados adotaram medidas semelhantes de acordo com o avanço da doença nas suas respectivas populações.

Conforme afirmam Porsse et al (2020), uma consequência das medidas de isolamento social é a redução da atividade econômica. Essa redução ocorre em escalas diferentes conforme o setor da economia, com destaque para as atividades de comércio, transportes, alimentação, alojamento, atividades artísticas e serviços pessoais.

Levando em consideração a grande extensão territorial brasileira, os impactos econômicos devem ser sentidos de maneiras distintas de acordo com a distribuição dos níveis de atividades essenciais e atividades não-essenciais em cada estado, com destaque para aqueles que há maior predominância de atividades agrícolas, como, por exemplo, aqueles localizados na região Centro-Oeste (PORSSE et al, 2020). Entretanto, mesmo que o impacto seja maior nas atividades não essenciais, atividades essenciais também devem sofrer prejuízos econômicos indiretamente.

DIAGNÓSTICO DA SITUAÇÃO-PROBLEMA

Impactos do coronavírus no setor de transporte

Não diferente dos demais setores da economia, o setor de transportes no Brasil também sofreu impactos econômicos decorrente do aumento da COVID-19 no território brasileiro. De acordo com informações obtidas junto a CNT (2020), nos dois primeiros meses de 2020 os agentes do setor de transportes no Brasil esperavam um aumento do PIB nacional e do setor. Com o avanço da pandemia da COVID-19 no país e a redução da atividade econômica com as medidas de isolamento, os agentes do setor de transportes deixaram essa visão mais otimista e passaram para uma visão mais negativa, com a grande maioria deles esperando um comprometimento das suas atividades, principalmente em empresas responsáveis pelo transporte de passageiros e as pequenas e médias transportadoras de carga.

No mês de maio de 2020, cerca de 80,6% de 619 empresas transportadoras de vários subsetores (isto é, diferentes tipos de modais) de transporte, entrevistadas pela CNT, registraram uma redução da demanda pelos serviços de transporte (CNT, 2020). Além disso, 64,6% observaram uma redução do seu faturamento em relação do mês de abril de 2020, e 75,3% dos agentes esperavam maiores quedas na receita no mês de junho de 2020. A expectativa da maioria dos agentes é de que esses impactos negativos perdurem por quatro ou mais meses a partir de junho.

Dentre os agentes entrevistados, o principal impacto da pandemia foi a queda no faturamento, exceto para os agentes do transporte ferroviário, que sentiram uma maior redução na sua produtividade (CNT, 2020). Dentre os principais problemas enfrentados no setor de transportes, de maneira geral, destacam-se: dificuldade para encontrar serviços de apoio ao transporte, barreiras de entrada em municípios e dificuldade de operação por restrições de movimentação. Já em relação ao tempo estimado de impacto, a grande maioria dos agentes espera sentir os efeitos da pandemia por mais 4 a 8 meses, com exceção dos agentes do transporte aéreo de passageiros e os operadores logísticos, que estimam que os impactos devem perdurar por mais 9 a 12 meses.

Análise Envoltória de Dados (DEA): aplicações nas áreas de logística e transportes

A Análise Envoltória de Dados (DEA) é uma técnica não-paramétrica de análise de eficiência relativa, utilizada para se obter o desempenho das Unidades Tomadoras de Decisão

(DMUs) e compará-las entre si. Esses DMUs podem representar firmas, países, pessoas, projetos, dentre outras, sendo a DEA utilizada para mensuração relativa da eficiência, por meio da construção de uma fronteira. Trata-se de uma técnica baseada em programação linear, que pode utilizar múltiplas variáveis de entrada (*input*) e de saída (*output*), caracterizando cada DMU (Ray, 2004).

Inputs são variáveis cuja a minimização beneficia a eficiência e *outputs* são variáveis cuja maximização beneficia a eficiência. A DEA permite analisar a contribuição relativa de cada *input* e *output* para o grau de eficiência dos casos analisados e trazer considerações sobre potenciais melhorias (Ray, 2004), apoiando decisões de seleção de fornecedores e seleção de investimentos, por exemplo.

Conforme apresentado por Ray (2004) e Cooper, Seiford e Tone (2007), a DEA foi introduzida como técnica de análise em Charnes, Cooper e Rhodes (1978). O modelo apresentado foi denominado de CCR e é caracterizado por considerar retornos constantes de escala. Banker, Charnes e Cooper (1984) aprimoraram esse modelo inicial ao considerarem condições tecnológicas de retornos variáveis de escala - modelo BCC (Cooper et al., 2007). A partir desses, variações foram sendo desenvolvidas e incorporadas na literatura acadêmica, tal como o modelo baseado em folgas, que foi o utilizado neste artigo e será detalhado na intervenção proposta.

A DEA é uma ferramenta que pode ser utilizada em diferentes contextos e para diferentes propósitos. Dentre as vantagens de aplicação dessa técnica de análise, Cooper, Seiford e Tone (2007) destacam: (i) a possibilidade de serem identificadas as fontes (e quantidades) das ineficiências dos *inputs* e *outputs* para cada unidade; e (ii) a possibilidade de serem identificadas as DMUs localizadas na fronteira de eficiência e realizar comparativos entre os casos analisados. Ramanathan (2003) afirma que a DEA é caracterizada pela objetividade da análise, pelo fato de atribuir pesos baseados em dados numéricos - informações não subjetivas. Por outro lado, uma limitação do seu uso é associada ao fato de essa técnica ser não paramétrica, dificultando a generalizações dos resultados (Ramanathan, 2003).

As aplicações da DEA percorrem diversas áreas do conhecimento, incluindo as áreas de transporte e infraestruturas logísticas portuárias, aeroportuárias, ferroviárias e rodoviárias. Chen, Shen, Zhang, Li e Ren (2019), por exemplo, utilizam a DEA para avaliação da eficiência de utilização de infraestruturas urbanas construídas em localidades chinesas. Aplicações dessa mesma temática são verificadas em Cheng e Lu (2017), que analisam a eficiência dos investimentos em infraestrutura urbana; e Kyriacou, Muinelo-Gallo e Roca-Sagalés (2019) para analisarem a eficiência dos investimentos em infraestrutura de transporte em 34 países entre os anos de 1996 e 2010.

No caso específico do transporte aeroviário, uma análise da eficiência relativa de 85 aeroportos regionais europeus é apresentada em Adler, Ülku e Yazhensky (2013). Yoshida e Fujimoto (2004) utilizam essa mesma técnica para efetuar um comparativo entre aeroportos japoneses, ao passo que Amoroso, Castelluccio e Maritano (2015) avaliam a eficiência de um conjunto de pequenos aeroportos e de heliportos na Itália, fazendo uma comparação entre os dois tipos de infraestrutura. Na mesma temática, Carlucci, Cirà e Coccorese (2018) analisam, para o período entre 2006 e 2016, a eficiência de aeroportos regionais italianos e Barros e Peypoch (2009) analisaram o desempenho operacional de companhias aéreas da Europa.

Doomernik (2015) adentra na análise do desempenho de sistemas ferroviários de alta velocidade. Como aplicação para a realidade brasileira, Marchetti e Wanke (2017) analisam a performance de operadores ferroviários, considerando dados de 2010 a 2014. A análise de eficiência de empresas ferroviárias é também verificada em Merkert, Smith e Nash (2010), que têm como objeto de estudo 43 instituições da Suécia, Alemanha e Inglaterra; e em Vasco Correa (2012), que fazem um comparativo da eficiência de empresas de transporte ferroviário e rodoviário na Colômbia.

Fancello, Uccheddu e Fadda (2014) analisaram a performance de diferentes sistemas de transporte rodoviário urbano. Outros trabalhos relacionados ao modal de transporte rodoviário utilizaram a DEA para avaliação da eficiência das manutenções em pontes (Ozbek, de la Garza e Triantis, 2010) e da eficiência de rodovias em relação à segurança (Shah e Ahmad, 2019).

Pina e Torres (2001) fazem um comparativo da eficiência do oferecimento do serviço de transporte urbano, sob a gestão de empresas públicas e de empresas privadas. A análise foi aplicada para diferentes localidades da Espanha e mostra um grau maior de eficiência para as localidades em que o transporte público é gerido por agentes públicos. Em temática similar, Swami e Parida (2015) utilizam a DEA para obterem medidas de eficiência e de performance das estações de metrô do transporte público em Deli (Índia).

Infraestrutura portuária é o objeto de análise de Díaz-Hernández, Martínez-Budría e Salazar-González (2014). O trabalho analisa a eficiência de 27 agentes de administração portuária da Espanha entre os anos de 2000 e de 2007. Castellano et al. (2019), por sua vez, analisam a eficiência portuária sob a ótica de investimentos em tecnologia de informação e comunicação. Cullinane, Wang, Song e Ji (2006) analisam o setor portuário, medindo a eficiência de terminais de contêineres. A medição da performance de portos marítimos também é objeto de análise de Guimarães, Leal Junior e Garcia (2014), Jiang e Li (2009), Bray, Caggiani e Ottomanelli (2015), Kutin, Nguyen e Vallée (2017) e Simões e Marques (2010).

Do ponto de vista metodológico, Costa Melo et al (2018) utilizaram o modelo DEA baseado em folgas chamado SBM (*Slack-Based Measure*) para comparar o desempenho das rotas agrícolas exportadoras dos Brasil e dos EUA, considerando diversos modais. Baseados nessa metodologia, Garcia et al (2019) aplicaram o modelo SBM de escala variável para rotas brasileiras, demonstrando o impacto da construção da hidrovía Tapajós-Teles Pires na eficiência da navegação interna. O modelo SBM resulta diretamente em um *rank* de eficiência com valores entre 0 a 1, onde 0 representa que a DMU foi totalmente ineficiente e 1 representa 100% de eficiência.

Rentizelas et al. (2019) utilizam uma técnica chamada de *Benefit-of-Doubt* (BoD) associada ao SBM para investigar alternativas internacionais para transporte de biomassa. O BoD representa uma das formas de utilização de DEA, em que se utiliza apenas *inputs* e o *output* é unitário, ou se utiliza apenas *outputs* e o *input* é unitário. Ou seja, o BoD é utilizado quando a eficiência do problema de interesse envolve apenas um tipo de variável (*input* ou *output*) e o outro tipo assume valores unitários. Por exemplo, modelo BoD orientado ao *input*, com *output* unitário e igual a 1, ou modelo BoD orientado ao *output*, com *input* unitário e igual a 1 (Alves Junior, Mariano, e Rebelatto, 2016). Essa aplicação de BoD-DEA foi proposta por Melyn e Moesen (1991) e revisada por Cherchye et al. (2007).

INTERVENÇÃO PROPOSTA

A intervenção proposta se deu em cinco etapas: (1) coleta dos dados, (2) configuração do modelo (DMUs e suas variáveis), (3) aplicação do modelo BoD, DEA-SBM, orientado aos *inputs*, (4) desempate (técnica do índice composto), (5) validação dos resultados (análises de *cluster*).

Coleta de dados

Os dados utilizados nesse estudo foram coletados no “Painel: Pesquisa de Impacto no Transporte – Covid-19”, uma pesquisa realizada com gentes de 11 ramos do setor de transportes, entre 1 e 3 de abril de 2020, pela Confederação Nacional dos Transportes (CNT, 2020). A pesquisa completa da CNT envolveu 776 empresas dos seguintes ramos: rodoviário de cargas, rodoviário de passageiros (regular), rodoviário de passageiros (fretamento), urbano de passageiros por ônibus, ferroviário, navegação interior, metroferroviário, aéreo de

passageiros, portuário, operadores logísticos, e agentes marítimos. Os dados foram compilados em uma planilha em Excel.

Seleção de variáveis e Configuração do modelo

Como alguns dados repetiam virtualmente a mesma informação, então foi feita uma pré-seleção de dados. Por exemplo, “Percentual de redução do faturamento do transporte” foi excluída e usado o “Impacto do faturamento do transporte”, pois as duas variáveis se referiam à mesma informação, mas a escala do impacto estava mais condizente com o das outras variáveis qualitativas categóricas e não percentuais. E foi aplicada uma Análise de Componentes Principais nas demais variáveis para determinar quais perguntas eram mais relevantes e consistentes para o estudo. Foram consideradas as seguintes perguntas (todas as escalas computadas em um sentido de “quanto maior, pior”, ou seja, quanto a pergunta for positiva, a escala é invertida):

- P1: Impacto da pandemia Covid-19 nas empresas de transporte;
- P2: Queda da demanda dos serviços de transporte em março de 2020;
- P3: Impacto do faturamento do transporte nos próximos 30 dias (mercado interno);
- P4: Impacto do faturamento do transporte nos próximos 60 dias (mercado interno);
- P5: Situação financeira e capacidade de cumprimento das obrigações (folha de pagamento, financiamento, tributos, fornecedores, concessionárias, aluguel, etc.);
- P6: Tempo que as transportadoras conseguem operar sem apoio financeiro;
- P7: Acesso ao crédito para capital de giro durante a pandemia Covid-19;
- P8: Tempo estimado de impacto da pandemia de Covid-19 nas transportadoras.

Aplicação do modelo DEA

Foi aplicado o modelo SBM-DEA, conforme proposto por Tone (2001), programado em Matlab. Foi adotado o retorno de escala variável (VRS), uma vez que a relação entre as respostas e o impacto é assumida como não linear. Todas as respostas foram inseridas como *inputs*, o *output* é unitário e a orientação é para a minimização dos *inputs*. O modelo de SBM (Tone, 2001) é apresentado nas Equações 1 a 6:

$$\text{Minimizar } \tau = t - (1/m) \sum_{i=1}^m S_i^- / x_{i0} \quad (1)$$

Sujeito a:

$$t + (1/s) \sum_{r=1}^s S_r^+ / y_{r0} = 1 \quad (2)$$

$$\sum_{k=1}^z \Lambda_k x_{ik} + S_i^- - t x_{i0} = 0 \quad i=1,2, \dots, m \quad (3)$$

$$\sum_{k=1}^z \Lambda_k y_{rk} - S_r^+ - t y_{r0} = 0 \quad r=1,2, \dots, s \quad (4)$$

$$\sum_{k=1}^z \Lambda_k - t = 0 \quad (5)$$

$$\Lambda_k \geq 0, S_i^- \geq 0, S_r^+ \geq 0 \text{ e } t > 0 \quad (6)$$

Onde τ é a eficiência, t é a variável de linearização do modelo, is the model linearization variable, S_i^- é a folga do i -ésimo *input*, S_r^+ é a folga do r -ésimo *output*, Λ_k é a contribuição da k -ésima DMU para a DMU em análise, x_{i0} é o i -ésimo *input* da DMU em análise, y_{r0} é o r -ésimo *output* da DMU em análise, x_{ik} é o i -ésimo *input* da k -ésima DMU, y_{rk} é o r -ésimo *output* da k -ésima DMU, s é o número de *outputs*, m é o número de *inputs* e z é o número de DMUs.

Desempate

Assim como Costa Melo et al (2018) e Rentizelas et al (2019), foi aplicada a técnica de desempate do Índice Composto (CI) proposta por Leta et al (2005) (Equação 7). Ele representa uma média aritmética entre as eficiências padrão e invertida padronizada pelo índice composto máximo observado na amostra. A eficiência invertida é o resultado do modelo DEA quando os *inputs* são inseridos como *outputs* e vice-versa. No caso, a eficiência invertida é calculada usando o mesmo modelo, com a mesma orientação, mas quando todas as respostas são inseridas como *outputs* e o *input* passa a ser unitário e igual a 1.

$$E_k^{composite} = \frac{[E_k^{standard} + (1 - E_k^{inverted})]/2}{\max \{[E_k^{standard} + (1 - E_k^{inverted})]/2\}} \quad k=1,2,3,\dots,z \quad (7)$$

Onde $E_k^{standard}$ é a eficiência padrão resultante da aplicação do modelo DEA para a k -ésima DMU, $E_k^{inverted}$ é a eficiência invertida da k -ésima DMU.

Validação

De acordo com Johnson e Wichern (2002), os índices de Componentes Principais (PC_i) podem ser obtidos a partir das variáveis originais conforme Equação 8.

$$PC_i = e_{i1}X_1 + e_{i2}X_2 + \dots + e_{ip}X_p \quad , i = 1,2, \dots, p \quad (8)$$

Onde PC_i são as components principais, e_{ip} são os autovetores (*eigenvectors*) da i -ésima PC e j -ésima variável, X_j são as variáveis originais, e p é o número de variáveis.

As variáveis originais da Equação 8 podem ser substituídas por variáveis padronizadas ou matriz de correlações quando a covariância das variáveis originais não possui escalas similares. O software R foi usado para computar os resultados da PCA. E a análise de agrupamentos foi feita utilizando o *package* de Maechler et al. (2019).

A validação foi feita em termos de agrupamentos das DMUs em relação às suas eficiências nas duas fronteiras e comparados ao resultado do PCA. Dividindo as DMUs em quatro grupos, conforme Tabela 1:

Tabela 1 Critérios para grupos DEA e PCA.

Grupo	$E_k^{standard}$	$E_k^{inverted}$	PC_1	PC_2
1	=1	<1	<-1	>-1
2	=1	=1	-1 < PC_1 < 1	<-1
3	<1	<1	-1 < PC_1 < 1	>-1
4	<1	=1	>1	>-1

Seguindo os critérios da Tabela 1, tanto usando PCA, quanto as informações de eficiência e fronteiras em DEA, e comparando esses grupos com os agrupamentos por *Ward's*

Clustering e K-means, apenas a DMU navegação interior recebeu uma classificação diferente (sendo classificada como grupo 4 pela eficiência ao em vez de grupo 3).

RESULTADOS OBTIDOS

A **Tabela 2** mostra os dados coletados e inseridos no modelo SBM-DEA como *inputs*.

Tabela 2 Dados colocados no modelo SBM-DEA como *inputs*.

Questão	DMU1	DMU2	DMU3	DMU4	DMU5	DMU6
1	9,1120	23,9820	31,4720	29,2900	31,3160	25,9360
2	3,2680	42,0800	76,1300	74,8800	71,3900	57,2900
3	2,6000	3,3490	3,2740	3,6530	3,7800	3,8700
4	2,5530	3,2850	3,2870	3,6100	3,7170	4,0000
5	2,0150	2,0480	3,0390	3,1310	3,5620	2,1610
6	0,4830	0,7382	0,7843	0,7613	0,9433	0,4552
7	1,7770	2,0230	2,0010	2,4050	2,6830	2,8570
8	2,1880	7,1460	7,2570	81,9450	12,3030	6,5400
Questão	DMU7	DMU8	DMU9	DMU10	DMU11	DMU12
1	27,5600	22,8640	30,4800	23,2000	26,2880	17,9240
2	68,7500	28,0000	75,0000	16,6600	48,3700	24,5700
3	3,3340	4,0000	3,4280	2,6000	3,4280	3,2970
4	2,8900	3,1420	3,6200	2,8000	3,4280	2,8530
5	2,4420	1,5710	2,5730	1,1000	1,8560	1,3700
6	0,4869	1,7482	0,4158	0,2000	0,3598	0,2079
7	2,2500	1,0000	2,1660	0,8330	2,2880	1,2500
8	4,4016	6,8640	10,0905	8,5500	8,1510	5,3835

A **Tabela 3** apresenta os resultados do modelo, a coluna da eficiência padrão (Ef) apresenta quatro DMUs eficientes empatadas (Geral, Portuário, Agente marítimo e Ferroviário). Para o cálculo do índice de desempate (CI) foi necessário calcular a eficiência invertida (InvEf), a translação desse valor (1- InvEf), a média e a normalizar o índice composto. Houve seis DMUs com valor igual a um para a eficiência invertida. Entre elas, de forma geral, os ramos de passageiros (i.e. aéreo de passageiros, rodo passageiros regular, rodo passageiros fretamento e urbano passageiros por ônibus) foram os mais impactados por causa do Covid-19 e ficaram nas últimas 4 posições do *ranking*, seguidos por navegação interior. Já o ramo ferroviário fez parte das duas fronteiras, ou seja, teve um grande impacto em alguma de suas variáveis (como o tempo que conseguiria operar sem apoio financeiro), mas ao mesmo tempo também apresentou características que foram pouco afetadas (como acesso a crédito para capital de giro durante a pandemia). No *rank* final (*Rank_CI*), essas DMUs (exceto o ramo ferroviário) ocuparam as últimas posições, refletindo a sua eficiência invertida. A técnica de desempate mostrou a DMU Geral como a mais eficiente, seguida da portuária e da agente marítimo. Por outro lado, a DMU operador logístico ocupou posições intermediárias em ambas as fronteiras, mas após o cálculo do CI, ultrapassou a ferroviário por 0,0041, devido ao resultado ruim da InvEf da segunda. Além da DMU operador logístico, outras duas DMUs ocuparam posições intermediárias tanto antes quanto depois da técnica de desempate: metroferroviário e rodocarga, porém estas ficaram em um *ranking* inferior ao ferroviário.

Tabela 3 Resultados do modelo SBM-DEA.

DMU	Ramo	Ef	InvEf	1-InvEf	Média	CI	Rank_CI
DMU1	Geral	1,0000	0,2049	0,7951	0,8975	1,0000	1
DMU10	Portuário	1,0000	0,3803	0,6196	0,8098	0,9022	2
DMU12	Agente marítimo	1,0000	0,4284	0,5715	0,7857	0,8754	3
DMU11	Operador logístico	0,6706	0,6624	0,3375	0,5041	0,5616	4
DMU8	Ferroviário	1,0000	1,0000	0,0000	0,5000	0,5570	5
DMU7	Metroferroviário	0,6431	0,6678	0,3321	0,4876	0,5433	6
DMU2	RodoCarga	0,6042	0,7062	0,2937	0,4490	0,5002	7
DMU6	Navegação interior	0,5882	1,0000	0,0000	0,2941	0,3276	8
DMU9	Aéreo de passageiros	0,5819	1,0000	0,0000	0,2909	0,3241	9
DMU3	Rodo passageiros regular	0,5464	1,0000	0,0000	0,2732	0,3044	10
DMU4	Rodo passageiros fretamento	0,5072	1,0000	0,0000	0,2536	0,2825	11
DMU5	Urbano passageiros por ônibus	0,4536	1,0000	0,0000	0,2268	0,2527	12

Comparando as **Tabelas 2** e 3, observa-se que a DMU1 (Geral) possui 5 dos menores valores da amostra, seguida da DMU10 (Portuário) possui 3 dos menores valores. Isso impactou no *ranking* da eficiência, pois a DMU1 ocupa a primeira posição, seguida pela DMU10. Já os maiores valores estão distribuídos entre as DMUs. Três delas têm dois dos maiores valores (DMUs 5, 6 e 8) e duas têm um valor máximo (DMUs 3 e 4).

Entre essas cinco DMUs, o subsetor ferroviário (DMU8) é a mais bem posicionado, apesar de ter os dois maiores valores da amostra para as perguntas 3 e 6 (impacto do faturamento em 30 dias e tempo que consegue operar sem apoio financeiro). Por outro lado, o setor ferroviário possui valores abaixo da média da amostra para todas as demais perguntas, isso contribuiu para uma melhor eficiência.

Como já foi enunciado no tópico *Impactos do coronavírus no setor de transporte*, enquanto a maioria dos setores declararam problemas com a queda de faturamento, o ferroviário declarou que seu maior impacto foi a queda de produtividade. Os agentes desse subsetor também disseram que suas maiores dificuldades eram: dificuldade de operação por restrições de movimentação e redução da frota em operação.

O setor da navegação interior (DMU6) possui os maiores valores para P4 e P7 (impacto do faturamento em 60 dias e acesso ao crédito para capital de giro). Além disso, o setor também apresentou respostas acima da média para as perguntas de 1 a 3 (impacto geral, queda de demanda e faturamento em 30 dias).

O setor rodo passageiros regular (DMU3) possui o maior valor da amostra para a P2 (queda de demanda). Além disso, possui valores acima da média para P1 e P4-7, só apresentando resultados abaixo da média para P3 e P8 (impacto do faturamento em 30 dias e tempo estimado de impacto), sugerindo tratar-se de um setor muito impactado, porém, mais otimista para os cenários de recuperação.

O setor rodo passageiros fretamento (DMU4) possui o maior valor da amostra para a P8 (81,945). Para essa pergunta, a média da amostra é 13,406 e o desvio padrão é 21,741. Ou seja, o setor acredita que os impactos da pandemia durarão muito mais tempo do que para os demais, dificultando na recuperação. Além disso, o setor esteve acima da média para todas as perguntas, evidenciando um maior pessimismo.

O setor urbano passageiros por ônibus (DMU5), a unidade pior *rankeada*, possui os maiores valores para as perguntas P1 e P5 (impacto geral e capacidade de cumprimento das obrigações), além disso, se manteve acima da média para todas as perguntas, exceto a P8. Isso reflete que o setor prevê maior impacto para o cumprimento das obrigações, porém acredita em

uma menor duração dos impactos da pandemia do que no setor de passageiros fretamento, talvez devido aos contratos institucionais.

As perguntas 5, 6 e 7 refletem critérios onde a atuação governamental pode atuar direta ou indiretamente, promovendo políticas junto a bancos públicos e privados, para ampliação do acesso a crédito dos agentes. Os subsetores que mais afirmaram sua dificuldade com relação ao financiamento do capital de giro foram, em ordem decrescente, navegação interior (DMU6), urbano passageiro por ônibus (DMU5), rodo passageiro fretamento (DMU4), operador logístico (DMU11), metroferroviário (DMU7), aéreo passageiro (DMU9), rodocarga (DMU2) e rodo passageiros regular (DMU3). Todos eles ocupam posições inferiores ou intermediárias no *rank* de eficiência. Os setores melhor posicionados alegaram menor dificuldade ao acesso a crédito para financiar o capital de giro.

O número de PCs adotados foi baseado no critério Latent Root Criterion (que também é conhecido como a regra Kaiser rule) para escolher PCs com autovalor maior do que um (*eigenvalue*>1) (Johnson e Wichern 2002; Kaiser 1960). Então, foram selecionadas as duas primeiras PCs. A % cumulativa de variância explicada foi de 75,87%, então também alcançou-se o critério de porcentagem de variância explicada acima de 60%, baseado em Hair et al. (2016).

A **Figura 1** apresenta o agrupamento por PCA. Observa-se a formação de quatro *clusters*. Considerando a PCA1 (eixo horizontal), pode-se entender que quanto mais a direita, pior. O *cluster* das DMUs 3,4,5,6 e 9 coincide com o *rank* das menos eficientes. É interessante notar a entrada o setor aéreo de passageiros (DMU9), que apresentou valores acima da média para todas as perguntas, exceto P6 e P8. A maior resposta do setor foi para a P2, queda de demanda, reflexo de várias medidas, entre elas, o fechamento de fronteiras. Também, como já foi enunciado no tópico *Impactos do coronavírus no setor de transporte*, enquanto a grande maioria dos agentes espera sentir os efeitos da pandemia por mais 4 a 8 meses, os agentes do transporte aéreo de passageiros e os operadores logísticos, que estimam que os impactos devem perdurar por mais 9 a 12 meses.

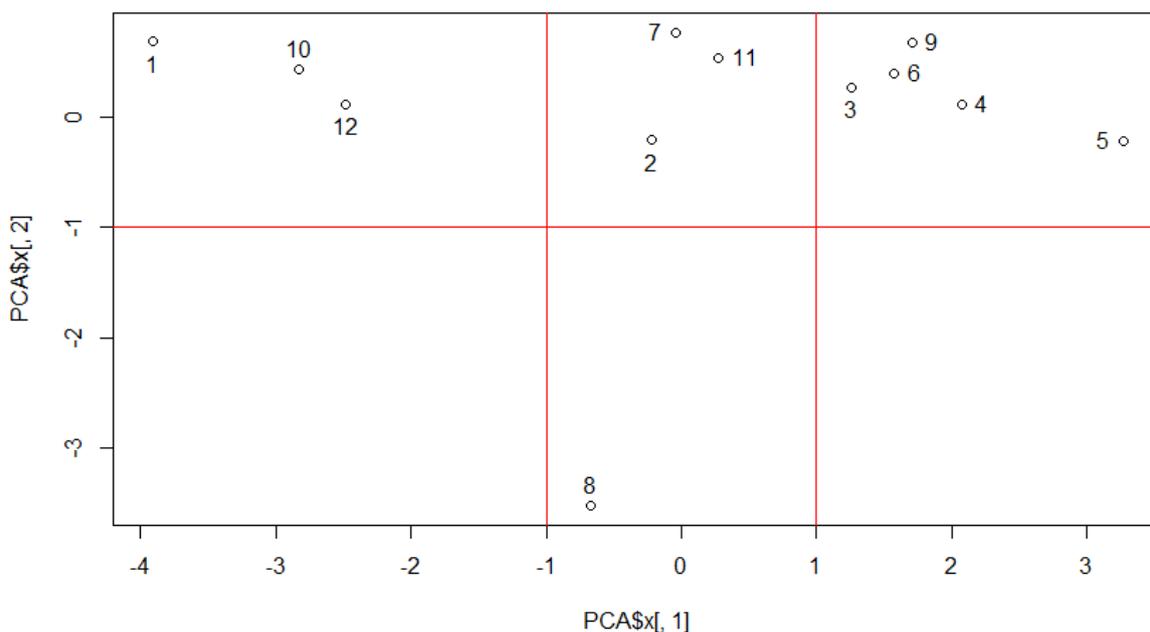


Figura 1 Resultado do PCA para as DMUs analisadas.

O *cluster* das DMUs 1, 10 e 12 corresponde aos subsetores mais eficientes no modelo DEA, a unidade geral, o portuário e o marítimo. Esses subsetores são mais relacionados às exportações. O portuário apresentou três perguntas com menor valor e todas as demais abaixo da média, enquanto o marítimo (DMU12) se manteve abaixo ou próximo da média para todas as perguntas, o que se reflete em uma posição levemente abaixo e ligeiramente à direita em relação ao portuário (DMU10).

A DMU8 (Ferroviário) apresenta um comportamento isolado, distinto de todas as demais, que se reflete na PCA2 (eixo vertical). Ocupando a posição intermediária (acima no segundo quadrante do eixo vertical), há um *cluster* com as DMUs 2, 11 e 7 (RodoCarga, Operador Logístico e Metroferroviários). Essas DMUs também ocupam posições intermediárias no *rank* do SBM-DEA.

Além do agrupamento por PCA, foram aplicados os métodos *Ward's Clustering* e *K-means*, os quais apresentaram resultados iguais. Para melhor utilização do espaço deste artigo, a **Figura 2** apresenta apenas o dendrograma do método *Ward*. Observa-se que o ferroviário (DMU8) permanece com um comportamento único e destoante dos demais. A única diferença com relação ao resultado do PCA é a alocação da DMU6 (navegação interior) para outro *cluster* (junto aos setores metroferroviário, rodocarga e operador logístico). Isso se deve ao caráter híbrido deste subsetor, que atua tanto no transporte de passageiros quanto no de cargas.

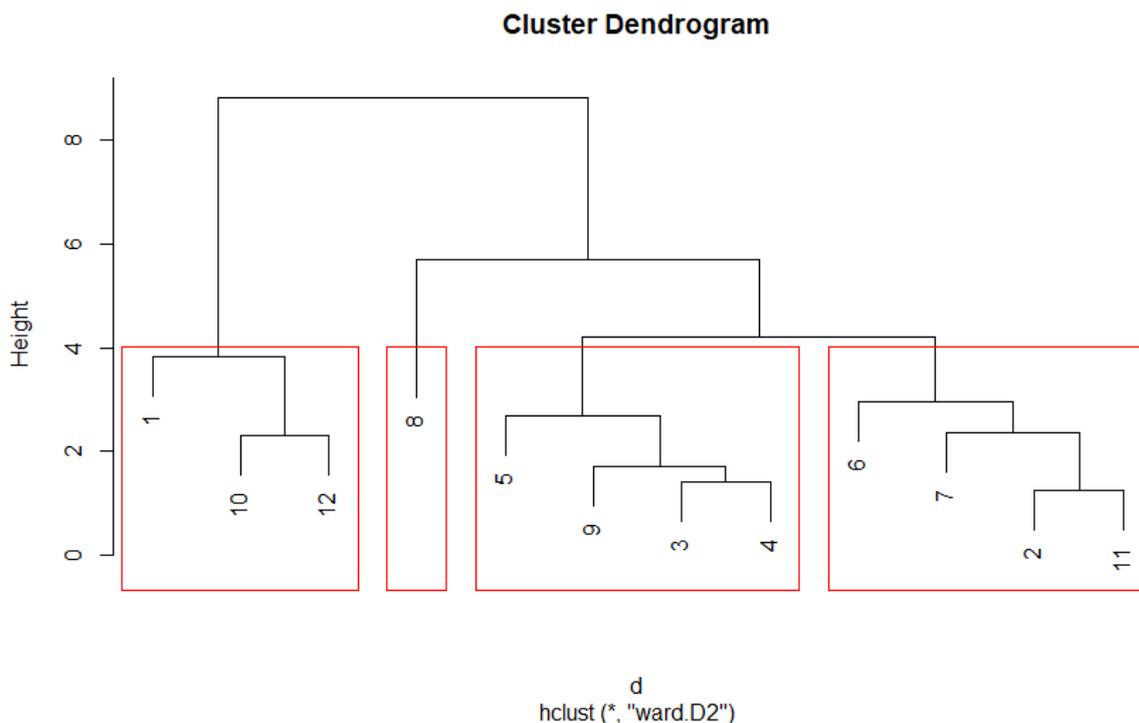


Figura 2 Dendrograma de *clusters*, elaborado pela técnica *Ward*.

Um resumo dos grupos, de acordo com as técnicas usadas, pode ser visto na **Tabela 4**.

Tabela 4 Grupos DEA, PCA, *Ward* e *K-means*.

DMU	Ramo	Grupos DEA	Grupos PCA	Grupos Ward	Grupos K-means
DMU1	Geral	1	1	1	1
DMU10	Portuário	1	1	1	1
DMU12	Agente marítimo	1	1	1	1

<i>DMU11</i>	Operador logístico	3	3	3	3
<i>DMU8</i>	Ferroviário	2	2	2	2
<i>DMU7</i>	Metroferroviário	3	3	3	3
<i>DMU2</i>	RodoCarga	3	3	3	3
<i>DMU6</i>	Navegação interior	4	4	3	3
<i>DMU9</i>	Aéreo de passageiros	4	4	4	4
<i>DMU3</i>	Rodo passageiros regular	4	4	4	4
<i>DMU4</i>	Rodo passageiros fretamento	4	4	4	4
<i>DMU5</i>	Urbano passageiros por ônibus	4	4	4	4

CONTRIBUIÇÃO TECNOLÓGICA-SOCIAL

Os subsetores menos atingidos pela pandemia, portanto mais eficientes, foram o portuário e o marítimo. Os mais afetados e menos eficientes foram os de transporte terrestre de passageiros (regular, fretamento e por ônibus), seguido o aéreo de passageiros e da navegação de interior. Percebe-se que os subsetores relacionados ao transporte humano foram mais afetados, enquanto aqueles relacionados a operações de exportação, menos. O ferroviário apresentou um comportamento ímpar, com desempenhos simultaneamente positivo para a maioria dos quesitos, porém extremamente negativo para dois deles (impacto do faturamento em 30 dias e tempo que consegue operar sem apoio financeiro). Além do ferroviário, ocuparam posições intermediárias com relação à pandemia, os setores rodocarga, operador logístico e metroferroviários. Os dois primeiros atendem também às exportações, além das atividades econômicas internas. O setor metroferroviários é mais limitado geograficamente e costuma ser operado por contratos institucionais, o que lhe traz maior robustez.

Os subsetores que alegaram maior acesso a crédito para financiar o capital de giro (agente marítimo, portuário e ferroviário) também ficaram melhor posicionados no *rank* de eficiência. Isso indica que políticas públicas voltadas para o financiamento do capital de giro dos subsetores pior posicionados (navegação interior, urbano passageiro por ônibus e rodo passageiro fretamento) podem resultar em melhorias significativas.

Para trabalhos futuros, recomenda-se mensurar quantitativamente quanto foi esse impacto efetivamente (e não apenas o esperado qualitativamente), em termos de variáveis socioeconômicas, principalmente nos setores mais impactados (transporte de passageiros). Com esse impacto, pode-se estimar um tempo de recuperação e elencar melhores medidas e incentivos governamentais para acelerar a retomada desses setores.

Também sugere-se estudar um ramo que apresentou diferentes resultados dentro do próprio setor, por produto e agente, como é o caso do rodocarga, que parece ter havido um maior impacto em um tipo de carga, enquanto outras cargas, como as cargas agrícolas a granel, bateram recordes de exportações (GR, 2020).

REFERÊNCIAS

- ADLER, N.; ÜLKÜ, T.; YAZHEMSKY, E. Small regional airport sustainability: Lessons from benchmarking. *Journal of Air Transport Management*, v. 33, p. 22–31, 2013.
- Alves Junior, P. N.; Mariano, E. B.; Rebelatto, D. A. N. Using Data Envelopment Analysis to Construct Human Development Index. Chapter 13. In: *Emerging Trends in the Development and Application of Composite Indicators* (pp. 298–323). IGI Global, 2016.
- AMOROSO, S.; CASTELLUCCIO, F.; MARITANO, L. A DEA-based transport heliports' efficiencies evaluation. *Aircraft Engineering and Aerospace Technology*, v. 87, n. 2, p. 131–138, 2 mar. 2015.

Banker, R. D., Charnes, A., & Cooper, W. W. (1984). Some models for estimating technical and scale inefficiencies in data envelopment analysis. *Management science*, 30(9), 1078-1092.

BARRETO, M. L. et al. O que é urgente e necessário para subsidiar as políticas de enfrentamento da pandemia de COVID-19 no Brasil?. *Revista Brasileira de Epidemiologia*, v. 23, 2020.

BARROS, C. P.; PEYPOCH, N. An evaluation of European airlines' operational performance. *International Journal of Production Economics*, v. 122, n. 2, p. 525–533, 1 dez. 2009. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0925527309001339?via%3Dihub>>. Acesso em: 9 mar. 2019.

BRAY, S.; CAGGIANI, L.; OTTOMANELLI, M. Measuring transport systems efficiency under uncertainty by fuzzy sets theory based data envelopment analysis: Theoretical and practical comparison with traditional DEA model. In: *Transportation Research Procedia*, Anais...Elsevier, 2015.

CARLUCCI, F.; CIRÀ, A.; COCCORESE, P. Measuring and explaining airport efficiency and sustainability: Evidence from Italy. *Sustainability (Switzerland)*, v. 10, n. 2, 4 fev. 2018.

CASTELLANO, R. et al. Do Digital and Communication Technologies Improve Smart Ports? A Fuzzy DEA Approach. *IEEE Transactions on Industrial Informatics*, v. 15, n. 10, p. 5674–5681, 1 out. 2019.

Charnes, A., Cooper, W. W., & Rhodes, E. (1978). Measuring the efficiency of decision making units. *European journal of operational research*, 2(6), 429-444.

CHENG, M.; LU, Y. Investment efficiency of urban infrastructure systems: Empirical measurement and implications for China. *Habitat International*, v. 70, p. 91–102, 1 dez. 2017.

Cherchye, L.; Moesen, W.; Rogge, N.; Puyenbroeck, T. V. An Introduction to 'Benefit of the Doubt' Composite indicators. *Social Indicators Research*, 82(1), 111–145. 2007. CNT. Painel Pesquisa de Impacto Covid-19. 2020. Disponível em: <<https://www.cnt.org.br/painel-impacto-covid19>>. Acesso em 23 jun. 2020.

COOPER, W. W.; SEIFORD, L. M.; TONE, K. *Data envelopment analysis: A comprehensive text with models, applications, references and DEA-solver software: Second edition*. [s.l.] Springer US, 2007.

COSTA MELO, I. C.; ALVES JUNIOR, P. N.; PERICO, A. E., GUZMAN, M. G. S.; REBELATTO, D. A. N. Benchmarking freight transportation corridors and routes with data envelopment analysis (DEA). *Benchmarking: An International Journal*, v. 25, n. 2, p.713–742, jul. 2018.

CULLINANE, K. et al. The technical efficiency of container ports: Comparing data envelopment analysis and stochastic frontier analysis. *Transportation Research Part A: Policy and Practice*, v. 40, n. 4, p. 354–374, 1 maio 2006. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0965856405001072?via%3Dihub>>. Acesso em: 9 mar. 2019.

DÍAZ-HERNÁNDEZ, J. J.; MARTÍNEZ-BUDRÍA, E.; SALAZAR-GONZÁLEZ, J. J. Measuring cost efficiency in the presence of quasi-fixed *inputs* using dynamic data envelopment analysis: The case of port infrastructure. *Maritime Economics and Logistics*, v. 16, n. 2, p. 111–126, 2014.

DOOMERNIK, J. E. Performance and efficiency of high-speed rail systems. In: *Transportation Research Procedia*, Anais...Elsevier, 2015.

FANCELLO, G.; UCCHEDDU, B.; FADDA, P. Data Envelopment Analysis (D.E.A.) for Urban Road System Performance Assessment. *Procedia - Social and Behavioral Sciences*, v. 111, p. 780–789, fev. 2014.

GARCIA, B. T. G.; LOPES, D. M. M.; LEAL JUNIOR, I. C.; AMORIM, J. C. C.; DA SILVA, M. A. V.; GUIMARAES, V. A.. Analysis of the Performance of Transporting Soybeans from

Mato Grosso for Export: A Case Study of the Tapajós-Teles Pires Waterway. *Sustainability*, v. 11, n. 21, p.1-16, out. 2019.

GR – GLOBORURAL. Apesar da pandemia, Brasil bate recorde na exportação de soja, carnes e algodão em abril. 2020. Disponível em <<https://revistagloborural.globo.com/Noticias/Economia/noticia/2020/05/apesar-da-pandemia-brasil-bate-recorde-na-exportacao-de-soja-carnes-e-algodao-em-abril.html>>. Acesso em 20/07/2020.

GUIMARÃES, V. de A.; JUNIOR, I. C. L.; GARCIA, P. A. de A. Environmental Performance of Brazilian Container Terminals: A Data Envelopment Analysis Approach. *Procedia - Social and Behavioral Sciences*, v. 160, p. 178–187, dez. 2014.

GUO, Y. et al. The origin, transmission and clinical therapies on coronavirus disease 2019 (COVID-19) outbreak—an update on the status. *Military Medical Research*, v. 7, n. 1, p. 1-10, 2020.

HAIR, J. F.; ANDERSON, R. E.; TATHAM, R. L.; AND BLACK, W. C. *Multivariate Data Analysis*. 5th ed. New Jersey: Prentice Hall. 2016.

JIANG, B.; LI, J. DEA-based performance measurement of seaports in northeast Asia: Radial and non-radial approach. *Asian Journal of Shipping and Logistics*, v. 25, n. 2, p. 219–236, 2009.

Johnson, R. A., and D. W. Wichern. *Applied Multivariate Statistical Analysis*. Prentice Hall. 2002.

Kaiser, Henry F. The Application of Electronic Computers to Factor Analysis. *Educational and Psychological Measurement* 20(1): 141–51. 1960.

KUTIN, N.; NGUYEN, T. T.; VALLÉE, T. Relative Efficiencies of ASEAN Container Ports based on Data Envelopment Analysis. *Asian Journal of Shipping and Logistics*, v. 33, n. 2, p. 67–77, 1 jul. 2017.

KYRIACOU, A. P.; MUINELO-GALLO, L.; ROCA-SAGALÉS, O. The efficiency of transport infrastructure investment and the role of government quality: An empirical analysis. *Transport Policy*, v. 74, p. 93–102, 1 fev. 2019.

LETA, F. R.; MELLO, J. C. C. B. S.; GOMES, E. G.; MEZA, L. A.. Métodos de melhora de ordenação em DEA aplicados à avaliação estática de tornos mecânicos. *Investigação Operacional*, v. 25, n. 2, p. 229–242, 2005.

Maechler, M.; Rousseeuw, P.; Struyf, A.; Hubert, M.; Hornik, K. Package ‘cluster’: Cluster Analysis Basics and Extensions. R package version 2.1.0. 2019.

Melyn, W.; Moesen, W. Towards a synthetic indicator of macroeconomic performance: Unequal weighting when limited information is available. *Public Economics Research Papers*, 17(1), 1–24. 1991.

MERKERT, R.; SMITH, A. S. J.; NASH, C. A. Benchmarking of train operating firms - A transaction cost efficiency analysis. *Transportation Planning and Technology*, v. 33, n. 1, p. 35–53, fev. 2010.

Ministério da Saúde. Sobre a doença. 2020. Disponível em: <<https://coronavirus.saude.gov.br/sobre-a-doenca#transmissao>>. Acesso em 22 jun. 2020.

OZBEK, M. E.; DE LA GARZA, J. M.; TRIANTIS, K. Data and modeling issues faced during the efficiency measurement of road maintenance using data envelopment analysis. *Journal of Infrastructure Systems*, v. 16, n. 1, p. 21–30, mar. 2010.

PINA, V.; TORRES, L. Analysis of the efficiency of local government services delivery. An application to urban public transport. *Transportation Research Part A: Policy and Practice*, v. 35, n. 10, p. 929–944, 1 dez. 2001. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0965856400000331?via%3Dihub>>. Acesso em: 9 mar. 2019.

PORSSE, A. A. et al. Impactos Econômicos do COVID-19 no Brasil. 2020. Nota Técnica NEDUR-UFPR No 01-2020.

RAMANATHAN, R. An introduction to data envelopment analysis: a tool for performance measurement. [s.l.] Sage Publications, 2003.

RAY, S. C. Data envelopment analysis: Theory and techniques for economics and operations research. [s.l.] Cambridge University Press, 2004.

RENTIZELAS, A.; MELO, I. C.; ALVES JUNIOR, P. N.; CAMPOLI, J. S.; REBELATTO, D. A. N. Multi-criteria efficiency assessment of international biomass supply chain pathways using Data Envelopment Analysis. *Journal of Cleaner Production*, v. 237, nov. 2019.

SHAH, S. A. R. et al. Relationship between road traffic features and accidents: An application of two-stage decision-making approach for transportation engineers. *Journal of Safety Research*, v. 69, p. 201–215, 1 jun. 2019.

SIMÕES, P.; MARQUES, R. C. Influence of congestion efficiency on the european seaports performance: Does it matter? *Transport Reviews*, v. 30, n. 4, p. 517–539, jul. 2010.

SWAMI, M.; PARIDA, M. Comparative appraisal of metro stations in Delhi using data envelopment analysis in a multimodal context. *Journal of Public Transportation*, v. 18, n. 3, p. 29–51, 9 set. 2015.

TOIT, A. Outbreak of a novel coronavirus. *Nature Reviews Microbiology*, v. 18, n. 3, p. 123–123, 2020.

TONE, K. A slacks-based measure of efficiency in data envelopment analysis. *European Journal of Operational Research*, v.130, n.3, p. 498–509, 2001.

VASCO CORREA, C. A. Economic evaluation of current conditions of competition and efficiency of automotive and rail systems in Colombia. *Energy Policy*, v. 46, p. 78–87, jul. 2012.

World Health Organization. WHO Coronavirus Disease (COVID-19) Dashboard. 2020. Disponível em: <<https://covid19.who.int/>>. Acesso em 23 jun. 2020.

Worldometers. Coronavirus Cases. 2020. Disponível em: <<https://www.worldometers.info/coronavirus/>>, Acesso em 23 jun. 2020.

YOSHIDA, Y.; FUJIMOTO, H. Japanese-airport benchmarking with the DEA and endogenous-weight TFP methods: testing the criticism of overinvestment in Japanese regional airports. *Transportation Research Part E: Logistics and Transportation Review*, v. 40, n. 6, p. 533–546, 1 nov. 2004. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1366554504000547?via%3Dihub>>. Acesso em: 9 mar. 2019.