

Título do capítulo	CAPÍTULO 7 EFICIÊNCIA NAS MACRORREGIÕES DE SAÚDE NO SISTEMA ÚNICO DE SAÚDE: UMA ABORDAGEM COMPARATIVA – 2008-2017
Autores (as)	Alexandre Marinho Maria Angelica Borges dos Santos Simone Souza Cardoso Rodrigo Pucci de Sá e Benevides
DOI	

Título do livro	SUS: AVALIAÇÃO DA EFICIÊNCIA DO GASTO PÚBLICO EM SAÚDE
Organizadores (as)	Carlos Octávio Ocké-Reis
Volume	
Série	
Cidade	
Editora	Instituto de Pesquisa Econômica Aplicada (Ipea)
Ano	2023
Edição	1ª
ISBN	
DOI	

© Instituto de Pesquisa Econômica Aplicada – **ipea** 2023

As publicações do Ipea estão disponíveis para *download* gratuito nos formatos PDF (todas) e EPUB (livros e periódicos). Acesse: <http://repositorio.ipea.gov.br>

As opiniões emitidas nesta publicação são de exclusiva e inteira responsabilidade dos autores, não exprimindo, necessariamente, o ponto de vista do Instituto de Pesquisa Econômica Aplicada ou do Ministério do Planejamento, Desenvolvimento e Gestão.

É permitida a reprodução deste texto e dos dados nele contidos, desde que citada a fonte. Reproduções para fins comerciais são proibidas.

Eficiência nas macrorregiões de saúde no Sistema Único de Saúde: uma abordagem comparativa – 2008-2017

Alexandre Marinho

Maria Angelica Borges dos Santos

Simone Souza Cardoso

Rodrigo Pucci de Sá e Benevides

Introdução

Este capítulo tem por objetivo principal aplicar os conceitos de eficiência discutidos nos capítulos precedentes aos dados das macrorregiões de saúde do SUS disponíveis em bases de dados públicas. Eficiência, como já explicitado em detalhes neste livro, será uma relação matemática entre valores observados e valores ótimos de produção de resultados a partir do consumo de insumos. Os valores ótimos são calculados a partir dos dados observados na amostra, o que faz da eficiência uma medida relativa, gerada a partir da comparação de desempenhos das unidades comparáveis em sua produção e estrutura produtiva.

As análises de eficiência em saúde, em geral, têm como foco o desempenho das DMU¹. Na saúde, têm sido representadas por hospitais²⁻⁶; níveis de atenção à saúde⁷; entes subnacionais como estados e municípios⁸; transplantes de órgãos⁹; e, finalmente sistemas de saúde¹⁰⁻¹⁴.

O primeiro trabalho nacional de avaliação de eficiência técnica no Brasil, aplicado a hospitais, com metodologia no estado da arte e publicado em periódico científico, foi o trabalho de Marinho (1998), citado por Silva et al.¹⁵. Esse estudo explorou um estudo apresentado por Zucchi (1998) que, por sua vez, usava indicadores mais tradicionais de desempenho (os quocientes resultantes da divisão de quantidades de funcionários por quantidades de leitos).

Eficiência é naturalmente um conceito que ganha espaço em situações em que os recursos ficam mais escassos e aumentam a pressão por “fazer mais com menos.” Entende-se, portanto, o motivo pelo qual um dos trabalhos sobre eficiência em saúde com grande repercussão na mídia nacional tenha sido o relatório do Banco Mundial de 2017¹⁶. O relatório apresentava uma análise de eficiência abrangente do sistema de saúde brasileiro, que destacava altos níveis de ineficiência, ainda que, com menos ênfase, reconhecesse uma suposta influência decisiva sobre esses resultados dos prestadores privados, que conforme Perelman et al. (2016), citado pelo Banco Mundial¹⁶, “gastam grandes quantias com uma parcela pequena da população”. Os resultados desse estudo, no qual foi aplicada a metodologia da DEA orientada a insumos – que não analisa apenas o SUS, mas todo o sistema de saúde brasileiro –, são citados tanto no relatório do Banco Mundial¹⁶ quanto em estudo realizado no âmbito do Fundo Monetário Internacional¹⁷.

Igualmente, estudos sobre o SUS reportados nesse mesmo relatório analisaram, de forma independente, a atenção primária e os atendimentos secundários e terciários. A partir de dados de 2013, foram descritos altos níveis de ineficiência na atenção primária, mas que ficavam concentrados em pequenos municípios, ou seja, “ineficiência aplicada a uma pequena parcela das despesas”¹⁶. Nos serviços hospitalares, em que é notória a grande participação de pequenos hospitais públicos⁶ e prestadores privados no SUS¹⁸, a maior parte dos municípios apresentava baixa produtividade e alta ineficiência¹. Nesse caso, não foram realizadas análises que permitissem delimitar a origem das ineficiências – se em um, outro ou ambos os segmentos – e onde elas teriam mais impacto.

A maioria das análises sobre sistemas de saúde aponta a limitação de abordar apenas componentes isolados do sistema de saúde. A operação dos sistemas de saúde pressupõe interrelações recíprocas entre unidades assistenciais e níveis de atenção, que se estabelecem no decorrer do atendimento à população. Sistemas de saúde são sistemas, reconhecidamente, complexos¹⁹, especialmente quando a integralidade é um princípio fundamental na organização das práticas assistenciais²⁰. Constatação semelhante já havia anteriormente motivado um estudo sobre eficiência da prestação à saúde nas capitais brasileiras, que buscou modelar e captar as interrelações entre os níveis de atenção²¹.

Eficiências e/ou ineficiências dos distintos níveis de atenção reverberam não apenas no mesmo nível, mas em outros níveis de atenção, criando realimentações (*loops*) de ineficiência. No SUS, esse fenômeno também é amplamente reconhecido²² no ‘gargalo’ da

I No relatório do Banco Mundial¹⁶, foi dado destaque aos pequenos hospitais como causa da ineficiência, mas inserimos aqui como explicação potencial válida para a baixa eficiência a elevada participação de prestadores privados com e sem fins lucrativos (filantrópicos). A ineficiência do setor privado é admitida como causa da ineficiência global do sistema de saúde brasileiro no próprio relatório.

média complexidade no SUS²³, mas é pouco investigado e insuficientemente considerado em estudos que avaliam eficiência.

Corroborando essa visão, Hone et al.⁷ detectaram reduções substanciais da mortalidade evitável com o fortalecimento da atenção básica, mas destacaram a necessidade de considerar relacionamentos mais amplos (incluindo atenção secundária e cuidados comunitários), além de arranjos de governança^{II}. Os efeitos mais débeis da Atenção Primária à Saúde (APS) sobre doenças não transmissíveis comparativamente a doenças transmissíveis sugerem que melhoras em outros níveis do sistema sejam necessárias para otimizar desfechos e bom funcionamento.

Nesse sentido, uma opção é tentar empreender análises de eficiência que considerem simultaneamente distintos níveis de cuidados e um conjunto heterogêneo e abrangente de variáveis de infraestrutura contemplados nas DMU a serem comparadas, a exemplo do que se espera em uma macrorregião. As macrorregiões de saúde integram a trajetória de sistemas de saúde universais para promover um uso mais eficiente dos recursos no território²⁴ e foram definidas como eixo estruturante da descentralização do SUS no Pacto pela Saúde²⁵. As políticas de regionalização têm progressivamente sido direcionadas para que as macrorregiões passem a se comportar como unidades tomadoras de decisão (DMU) no SUS.

Análises de eficiência usando macrorregiões como DMU ainda são incipientes. A macrorregião conforma a Rede de Atenção à Saúde (RAS), que inclui desde a APS até a atenção terciária, considerando questões de escala e governança²⁶. Com o intuito de simplificar o desenho de DMU que representem a rede de atenção e, ainda assim, preservar a possibilidade de analisar as contribuições individualizadas dos níveis de atenção para a eficiência das macrorregiões, podemos utilizar o modelo de Homa et al.²⁷, que divide os sistemas de saúde em dois níveis de atenção (a atenção primária e a atenção especializada). As DMU macrorregionais passariam a contemplar, simultaneamente, variáveis de infraestrutura, de financiamento e de níveis de atenção.

Os dois níveis de atenção teriam impactos preferenciais sobre distintas categorias de problemas de saúde, rebatidas em desfechos específicos. Indicadores de mortalidade evitável constituem um bom ponto de partida para avaliar a eficiência e a efetividade dos

II O autor definiu governança como “combinação entre fatores institucionais, sociais, políticos e econômicos que afeta o comportamento das organizações e indivíduos e influenciam seu desempenho”, incluindo “funções de elaboração de regras e definição de rumos”. No estudo, utilizaram como proxies as 18 dimensões-chave de governança definidas pela OMS, pesquisadas em um inquérito sobre Perfil dos Municípios Brasileiros realizado pelo Instituto Brasileiro de Geografia e Estatística em 2001-2002 e transformadas em escores.

sistemas de saúde. Mortalidade evitável é entendida como capacidade de evitar mortes prematuras na presença de cuidados temporâneos e efetivos de saúde²⁸.

A mortalidade evitável (*avoidable mortality*) divide-se em mortalidade prevenível (*preventable mortality*) – aquela provocada por causas que poderiam ser evitadas por intervenções preventivas e de saúde pública (atenção básica) – e mortalidade tratável (*treatable mortality*) – correspondente àquela que poderia ser evitada por cuidados de saúde oportunos e efetivos (atenção especializada hospitalar)²⁸. Algumas causas recaem nas duas categorias, como, por exemplo, doenças isquêmicas cardíacas e câncer colorretal, consideradas evitáveis por atenção básica, e tratáveis por cuidados especializados.

O objetivo deste capítulo é realizar avaliações comparativas de eficiência para as 117 macrorregiões do SUS, segundo aportes de recursos para atenção básica e média/alta complexidade para os anos de 2008 a 2017. Nesse sentido, pode-se supor que haveria proporções e quantitativos ótimos de alocação de recursos aos distintos níveis de atenção, que gerem maior eficiência e otimização de desfechos no sistema de saúde.

De antemão, já citamos possíveis objeções a esse desenho, que poderiam ser consideradas limitações. Do ponto de vista da gestão do SUS, em termos do desenho das DMU, pode-se argumentar que a opção pelas macrorregiões delimitou agregados geográficos que ainda não atuavam em sua plenitude no período compreendido entre 2008 e 2017. Com relação aos insumos dos modelos, a ausência de dados relacionada com os profissionais de saúde, inclusive na atenção primária, notadamente o pessoal da saúde empregado nas equipes da Estratégia Saúde da Família (ESF), é um limitador. Entretanto, há um obstáculo caso se queira utilizar essas informações: a ausência de horas efetivamente trabalhadas por profissionais que, em geral, têm múltiplas ocupações, inclusive no setor privado, o que ocasionaria duplas contagens e erros de diversos tipos se a força de trabalho for computada pelo seu quantitativo nominal. Cabe destacar que essa lacuna, praticamente impossível de suprimir, é reduzida, em parte, pela correlação positiva existente entre as despesas na atenção primária, as atividades das equipes de ESF, os leitos e os equipamentos.

Igualmente, existem críticas à opção pela mortalidade evitável como indicador de efetividade, ou seja, o desenho, o aprimoramento e a consecução de objetivos do sistema de saúde, dando legitimidade à busca da eficiência²⁹. A mortalidade evitável, segundo esses críticos, não refletiria a efetividade dos sistemas de saúde, compondo um indicador estatisticamente pobre em termos de confiabilidade e sensibilidade. Ademais, não captaria os determinantes sociais, problema que tentamos contornar pela introdução de variáveis não discricionárias como o Produto Interno Bruto (PIB) per capita e a

proporção de população coberta por planos de saúde. No entanto, a literatura já admite e sustenta o uso da mortalidade evitável como desfecho de desempenho³⁰. Pode haver instabilidade desse indicador quando aplicado em pequenas regiões, mas ele é confiável e sensível quando aplicado a sistemas de saúde regionais, como são as macrorregiões, e, principalmente, quando são usados dados de vários anos, como é o nosso caso.

Em relação aos dados utilizados no modelo, todos oriundos de registros administrativos, eles apresentam intrinsicamente as limitações e as falhas desse tipo de registro e de seu uso como dados secundários³¹. O Sistema de Informação sobre Mortalidade (SIM) alimenta-se de registros de mortalidade que são obrigatórios no Brasil, mas cuja completude tem variado substancialmente entre os estados nas últimas três décadas³². O Cadastro Nacional de Estabelecimentos de Saúde (CNES), usado para coletar informações para os insumos, também apresenta imprecisões conhecidas nos registros, o que não invalida o uso de suas informações³³. No caso dos dados mais críticos de financiamento, oriundo do Sistema de Informações sobre Orçamentos Públicos em Saúde (SIOPS), tentamos ajustar falhas e fazer adaptações ao uso pretendido de captar o financiamento das três esferas nas macrorregiões (Apêndice 1).

Apesar dessas questões, a avaliação presente neste capítulo é *sui generis* na literatura brasileira, seja devido ao tamanho da série histórica (dez anos), seja em razão da adoção de metodologias estatísticas especificamente desenvolvidas para a correção dos problemas de caráter estatístico^{III} dos modelos tradicionais de DEA apontados por Simar e Wilson³⁴, que detalharemos mais adiante. Afinal, os modelos tradicionais de DEA, quando aplicados aos dados do SUS, são afetados de forma ainda pouco clara por esses problemas que, aliás, não foram corretamente tratados no difundido estudo do Banco Mundial⁸. Finalmente, outro aspecto inédito foi a correção dos dados relacionados com as despesas do SUS, inclusive das transferências para os municípios, sem os quais os resultados estariam comprometidos.

Estudos futuros que contemplem a adoção de modelos e métodos complementares de avaliação de eficiência, notadamente a SFA, bem como a imputação correta da carga horária de trabalho efetivo dos profissionais do SUS, em suas diversas categorias, poderão fornecer uma gama maior de informação sobre a evolução do desempenho das macrorregiões.

Os dados descritivos gerais, expressos por um conjunto de indicadores descritos na Seção Métodos, retratam as macrorregiões em estudo (tabela 1). Permitem perceber

III Resumidamente, o processo produtivo que gera *outputs* a partir dos *inputs* tem propriedades estatísticas que não são corretamente tratados nos modelos iniciais de DEA.

de antemão a enorme diversidade de realidades contempladas por elas, desde as socio-demográficas até as sanitárias e financeiras^{IV}.

Tabela 1. Estatística descritiva dos indicadores pertencentes às macrorregiões de saúde do SUS, 2017

Variáveis	Média	Desvio-padrão	Min.	1ºQ	2ºQ	3ºQ	Máx.
Taxa de mortalidade por causas evitáveis (100.000 hab.) ^{1,2}	129,48	19,54	70,93	117,81	129,26	140,87	173,19
Taxa de mortalidade por causas tratáveis (100.000 hab.) ^{1,2}	64,31	11,19	43,46	57,50	62,60	70,33	108,35
Taxa de mortalidade por causas evitáveis/tratáveis (100.000 hab.) ^{1,2}	92,31	19,51	43,47	79,33	91,90	105,67	143,22
Despesas per capita em atenção básica e vigilância ^{2,3}	352,30	116,30	164,38	261,29	323,56	413,49	681,89
Despesas per capita em atenção especializada e Suporte profilático terapêutico ^{2,3}	663,57	246,55	181,16	468,99	636,76	817,26	1.375,14
Leitos de internações/hab. (x100.000) ^{2,4}	157,69	41,65	55,13	129,08	152,11	184,42	291,04
Leitos complementares/hab. (x100.000) ^{2,4}	12,78	5,41	0,40	9,09	12,95	16,45	27,82
Equipamentos respiradores e ventiladores SUS/hab. (x100.000) ^{2,4}	2,99	1,03	1,05	2,27	2,86	3,66	5,83
População (em mil hab.) ²	1.705,97	1.811,60	129,21	771,15	1.179,21	1.881,07	12.852,25
Área (km ²) ²	72.630,79	116.857,93	553,75	15.809,84	34.942,60	79.439,17	772.873,34
Densidade demográfica (hab./km ²) ²	210,07	822,89	1,14	13,23	34,99	90,45	7.634,50
Idosos % ²	9,59	2,10	4,22	8,22	9,59	11,03	15,03
PIB per capita ²	29,08	15,41	9,03	16,40	28,77	38,33	85,48
Usuários de planos de saúde % ⁵	16,99	11,56	0,69	7,09	15,91	23,63	48,67

Fonte: elaboração própria com base em: 1. Sistema de Informação sobre Mortalidade (SIM); 2. Instituto Brasileiro de Geografia e Estatística (IBGE); 3. SIOPS (Sistema de Informações sobre Orçamentos Públicos em Saúde) e FNS (Fundo Nacional de Saúde); 4. Cadastro Nacional de Estabelecimentos de Saúde (CNES); 5. Agência Nacional de Saúde Suplementar (ANS).

IV Mais adiante, na tabela 2, serão exibidos os dados médios no período 2008-2017.

A próxima seção apresenta os principais aspectos metodológicos dos modelos empíricos utilizados. A seguir, apresentamos e discutimos as variáveis e os dados utilizados. A grande variedade de resultados obtidos, nos diferentes modelos, é discutida na sequência. As Considerações Finais e os Apêndices fecham o capítulo.

Metodologia

Analisamos nesta seção a eficiência comparativa de agrupamentos de municípios, desenhados segundo as definições para a regionalização contidas na Resolução da Comissão Intergestores Tripartite (CIT) nº 37, de 22 de março de 2018³⁵, que trata do Planejamento Regional Integrado (PRI) e da organização de macrorregiões de saúde (listadas nas Tabelas 2 a 6 do Cap. 8). Seguindo as perspectivas de análise consagradas em avaliações econômicas que reforçam a necessidade da explicitação da perspectiva do estudo³⁶, o enfoque utilizado é a do SUS pagador de serviços de saúde.

A inclusão dos aspectos essenciais da modelagem foi verificada utilizando-se as diretrizes definidas por Bennett e Manuel³⁷. São examinados os desempenhos agregados dos municípios, que compõem essas macrorregiões, desde sua definição como eixo estruturante da descentralização no Pacto pela Saúde²⁵ até a Resolução da CIT³⁵. O horizonte temporal de dez anos é suficiente para permitir detectar variações de eficiência e de tecnologia, que são também componentes da variação de produtividade no longo prazo.

Os pressupostos que fundamentam nosso modelo admitem que aportes de financiamento para cada nível de atenção e região são proporcionais à capacidade instalada desses níveis e que exista uma relação entre aporte de recursos e desfechos³⁸. Variações em aportes de financiamento para diferentes níveis de complexidade dos sistemas de saúde (Atenção Básica – AB, representada por serviços básicos e atividades de prevenção e promoção da saúde; e Média/Alta Complexidade – MAC, representada pelo financiamento MAC) impactariam na eficiência das macrorregiões, mediada pelos desfechos de morte evitável. Essa abordagem, que considera os níveis de atenção em conjunto, porém desagrega *inputs* e *outputs* correspondentes sob a perspectiva das macrorregiões, em âmbito nacional, seria inédita na literatura. Permite, inclusive, análises futuras visando quantificar o peso de variáveis de *input* relacionadas com os níveis de atenção para um espectro de desfechos de saúde.

O método principal de análise escolhido foi a DEA, desenvolvida em Charnes, Cooper e Rhodes¹, que é um modelo de programação matemática em que, a partir de múltiplos insumos consumidos por várias DMU, é avaliada a produção de múltiplos

resultados dessas mesmas DMU. O método permite a construção de uma fronteira de eficiência e foi escolhido, entre outras opções, dado o desconhecimento da verdadeira função de produção que conecta recursos e resultados nas macrorregiões de saúde. Além disso, o método acomoda facilmente a produção múltipla orientada para a maximização da produção em casos em que há dificuldades de acesso e formação de filas como no SUS. Um método alternativo bastante utilizado também é a SFA, que apresenta dificuldades em tais contextos¹³⁻¹⁴. As fronteiras estocásticas foram desenvolvidas, de modo simultâneo, em Aigner et al.³⁹, Battese e Corra⁴⁰ e Meeusen e Van den Broeck⁴¹.

Definidas as macrorregiões de saúde como DMU, passou-se à escolha dos insumos (*inputs*) e resultados (*outcomes*), conforme explicitado acima na tabela 1, que é uma etapa fundamental da DEA, pois os escores de eficiência são diretamente influenciados por essas variáveis. Em todos os casos, procuramos seguir o princípio da parcimônia^{36,42}, utilizando um número reduzido de variáveis.

Na perspectiva do modelo selecionado, para definir os resultados do sistema de saúde, consideramos que sua função crucial é evitar mortes evitáveis. Os impactos específicos da atuação da atenção primária são captados pelas mortes preveníveis, e os impactos específicos da atenção de média e alta complexidade seriam traduzidos nas mortes tratáveis. Por sua vez, o conjunto dos dois desfechos comporia as mortes evitáveis. As causas de mortalidade prevenível e tratável foram definidas segundo a Eurostat²⁸. A listagem completa, inclusive a codificação disponível no SIM, é apresentada no Apêndice 2.

Como a mortalidade é um resultado indesejável, as taxas de mortalidade disponíveis no SUS foram transformadas em taxas de sobrevivência por razões analíticas, conforme veremos mais adiante. Assim, foram definidos três resultados: i) taxa de sobrevivência por causas preveníveis; ii) taxa de sobrevivência para causas tratáveis; e iii) taxas de sobrevivência para causas híbridas. Dessa forma, evitamos o problema bastante comum na literatura, mesmo em trabalhos recentes sofisticados tecnicamente, decorrente da utilização exclusiva de variáveis representativas de produção de unidades de saúde (*outputs*), como as internações, consultas, exames, que não estão necessariamente conectadas com os efetivos resultados na saúde das pessoas. Botega et al.⁶, por exemplo, utilizam apenas internações como *outputs*. Os *outputs* podem ser objeto de manipulações estratégicas por motivações financeiras ou gerenciais, ou ainda, afetadas por maus comportamentos de agentes como o

moral hazard, e agenciamento^V, ou frutos de tratamentos malfeitos geradores de reinternações e retrabalho.

Os insumos que utilizamos incluíram variáveis de financiamento, segundo nível de atenção e variáveis de estrutura. As variáveis de financiamento foram inicialmente divididas em: a) despesas executadas em nível municipal em nível estadual para APS, compostas por despesas liquidadas com as subfunções Atenção Básica; Vigilância Epidemiológica e Sanitária; e Alimentação e Nutrição; e b) despesas executadas em nível municipal e em nível estadual para MAC (compreendendo despesas liquidadas com as subfunções Atenção Ambulatorial e Hospitalar e Suporte Profilático e Terapêutico).

Para cada um dos níveis de atenção, os recursos advindos de União, estados e municípios, que correspondem, na prática, aos recursos executados por estados e municípios, foram somados baseados no pressuposto de que o impacto na eficiência está mais ligado à destinação dos recursos do que a sua origem (todavia, não existe consenso sobre essa premissa e há poucos estudos dedicados a análises da relação entre fontes de financiamento e resultados na Administração Pública⁴³)^{VI}. As variáveis de estrutura foram representadas por leitos de internação, leitos complementares e equipamentos de alta complexidade (respiradores), todos eles indicativos de presença de estrutura para média e alta complexidade hospitalar. Foram também incluídas variáveis explicativas exógenas (variáveis não discricionárias), que são variáveis fora do controle dos gestores locais do SUS, mas que podem ser importantes para determinar a eficiência nas macrorregiões de saúde. As seguintes variáveis não discricionárias foram usadas: densidade demográfica; porcentagem de idosos (entre 60 e 74 anos de idade) na população; PIB per capita; e porcentagem da população que é usuária de planos privados de saúde.

A mão de obra é um insumo importante em saúde, mas nem sempre pode ser utilizada em avaliações de eficiência setorial, basicamente, pelas seguintes razões: idealmente, deveria ser usada a carga horária de trabalho – que representa o esforço humano exercido – das diferentes profissões, e não o quantitativo de profissionais de cada uma delas, porém não existem tais dados nas macrorregiões. Adicionalmente, existem muitos trabalhadores do SUS com dupla e até tripla ocupação, o que torna

V No *moral hazard*, ou dano moral, o agente utiliza os serviços sem necessidade, apenas porque estão disponíveis, ou porque se expôs em demasia aos riscos de adoecimento por saber que está coberto. No agenciamento, os profissionais de saúde induzem as pessoas ao uso por motivações financeiras ou excesso de precaução (conforme discutimos no capítulo 6).

VI Ressaltamos que a exploração do impacto dessa variável sobre a eficiência poderá ser objeto de estudos futuros.

muito difícil evitar a dupla contagem. Como a mão de obra efetivamente utilizada é muito correlacionada com leitos e equipamentos utilizados, e considerando as atividades das equipes de ESF, a ausência dessa variável seria aceitável, como ocorreu em outros textos da literatura⁴⁴.

Os dados e as variáveis utilizadas

A partir de *sites* públicos, as variáveis foram coletadas no nível municipal entre 2008 e 2017, e depois agregadas conforme as macrorregiões de saúde e os códigos definidos no DATASUS. Esses dados foram objeto de transformações e ajustes para tentar contornar fragilidades e inadequação das informações às análises realizadas (isso será mais detalhado nas seções seguintes e nos apêndices deste capítulo).

Apresentaremos algumas variáveis que permitirão a avaliação de eficiência nas macrorregiões do SUS:

Recursos (*inputs*)

Partimos da premissa de que sistemas de saúde são sistemas complexos, em que eficiências e/ou ineficiências dos distintos níveis de atenção repercutem não somente no mesmo nível, mas também em outros níveis, criando *loops* de ineficiência (‘portas giratórias’). Nesse sentido, pode-se supor que haveria proporções ótimas de alocação de recursos aos distintos níveis de atenção, que gerem maior eficiência e otimização de desfechos no sistema de saúde. Um levantamento de informações sobre gastos públicos em saúde foi feito para compor o modelo. Foram propostos dois indicadores: despesas em atenção básica e despesas em atenção especializada, que foram utilizadas em separado ou como total de ambas as despesas.

Os dados financeiros fornecidos para a construção dos indicadores de despesas referentes à atenção ambulatorial e hospitalar de média e alta complexidade foram construídos com base nos dados do SIOPS, do Fundo Nacional de Saúde (FNS) e do Ministério da Saúde (MS).

Obtivemos dois tipos de variáveis de despesas: uma refere-se às despesas per capita, incluindo recursos estaduais, municipais e transferências federais para despesas representativas da Atenção Básica e Vigilância em Saúde (variável “DABV”) e de Média e Alta Complexidade (variável “DMAC”), cuja composição e construção são mais bem detalhadas no Apêndice 1. Outras variáveis foram incluídas como insumos, quais sejam: número de leitos internação; número de leitos complementares; número de equipamen-

tos respiradores e ventiladores disponíveis SUS (essa última variável é importante, pois serve como *proxy* de infraestrutura dos hospitais públicos de alta complexidade). Essas variáveis citadas foram obtidas pelo CNES e calculadas da seguinte forma:

$$\text{Média anual de leitos de internação/habitante} = \frac{\text{Média anual de leitos de internação}}{\text{população residente 0 a 74 anos}} \times 100.000$$

$$\text{Média anual de leitos complementares/habitante} = \frac{\text{Média anual de leitos complementares}}{\text{população residente 0 a 74 anos}} \times 100.000$$

$$\text{Equipamento ou ventilador (SUS)} = \frac{\text{Média anual de equipamentos disponíveis SUS}}{\text{população residente 0 a 74 anos}} \times 100.000$$

Foram ainda coletados, no DATASUS, as estimativas da população residente na faixa etária de 0 a 74 anos e na faixa de 60 anos a 74 anos (idosos), no período entre 2008 e 2017, por macrorregiões de saúde.

Produtos (*outcomes*)

Com relação aos dados de mortalidade, um bom ponto de partida para avaliar a eficiência e/ou efetividade dos sistemas de saúde, está na capacidade de evitar mortes prematuras²⁸.

Uma das referências para o levantamento das informações e indicadores de óbitos é a lista de mortes evitáveis categorizadas em causas preveníveis e tratáveis, contida no relatório da Eurostat²⁸, que define a mortalidade prevenível como mortes que podem ser evitadas por meio de intervenções de prevenção primária (isto é, antes do aparecimento de doenças ou lesões, para reduzir a incidência). A mortalidade por causa tratável se define como causa de morte que pode ser evitada, principalmente, por meio de intervenções de saúde oportunas e eficazes, incluindo a prevenção secundária e o tratamento (ou seja, após o aparecimento de doenças, para reduzir a letalidade). Algumas causas recaem nas duas categorias como, por exemplo, doenças isquêmicas cardíacas e câncer colorretal, consideradas como preveníveis por atenção básica e tratável por cuidados especializados; e, portanto, nesses casos, podemos denominar essas categorias como mortalidade por causa prevenível e tratável.

As listas de mortalidade evitável se concentraram em mortes, logo, envolvem a definição de um limite de idade para definir mortes prematuras. O limite de idade que

tem sido tradicionalmente usado em listas de mortalidade evitáveis nos países desenvolvidos está abaixo de 75 anos. Esse limite de idade ainda reflete as menores expectativas de vida ao nascer dentre os países da Organização para a Cooperação e Desenvolvimento Econômico (OCDE) e da União Europeia (UE). O limite de idade de 75 anos é arbitrário e apenas reflete uma definição atual de mortalidade prematura que será revista no futuro, à luz dos ganhos futuros na expectativa de vida (ou perdas, devidas à pandemia do novo coronavírus). Sendo assim, neste trabalho, usaremos o limite de idade de 0 a 74 anos, conforme é utilizado na OCDE e na UE.

A partir dessa percepção, apenas três resultados finais de saúde (*outcomes*) foram coletados para as 117 macrorregiões: óbitos por residência, segundo as causas preveníveis, tratáveis e causas preveníveis/tratáveis, na faixa etária de 0 a 74 anos, todos compreendidos na categoria da décima revisão da Classificação Internacional de Doenças e Problemas Relacionados à Saúde (CID-10). Todos os dados foram obtidos pelo SIM^{VII}.

Para fins comparativos entre as macrorregiões, foram criados três indicadores que correspondem às taxas de mortalidade (TXM) (prevenível, tratável e prevenível/tratável). Em função dos óbitos citados acima, as taxas foram calculadas da seguinte forma:

$$TXM = \frac{\text{óbitos por causa}}{\text{população residente 0 a 74 anos}} \times 100.000$$

Como os óbitos são resultados indesejados, a taxa de mortalidade é um resultado que desejamos minimizar ao invés de maximizar. Dessa forma, a solução foi transformar o indicador em *output* desejável como taxa de sobrevivência (TS), apresentado na seguinte forma:

$$TS = \frac{100.000 - TM}{TM}$$

Em que TM é a taxa de mortalidade estimada.

Variáveis ambientais (não discricionárias)

Devido ao grau de heterogeneidade entre as macrorregiões de saúde, seja em relação aos indicadores de saúde utilizados, seja no que se refere às características físicas e

VII Ver <https://datasus.saude.gov.br/mortalidade-desde-1996-pela-cid-10>.

populacionais, tornou-se necessário incluir, na análise de eficiência, variáveis não controláveis pelos gestores do SUS, mas que, de alguma forma, poderiam impactar no desempenho das macrorregiões. Esse é um procedimento bastante frequente na análise da eficiência em saúde^{5,45} e em outros setores⁴⁶. Assim, nos modelos, foram incluídas as variáveis denominadas como não discricionárias ou ambientais, a fim de captar essas desigualdades. As variáveis coletadas foram as seguintes: população, área geográfica, densidade demográfica, percentual de idosos (60 anos a 74 anos), PIB e número de usuários de planos de saúde. A escolha de insumos e resultados discricionários não é trivial. Em alguns casos, determinados elementos em nossos modelos podem aumentar a produção e a eficiência mesmo não controlados pelos gestores, e devem ser tratados com insumos, como é o caso do PIB e, talvez, da proporção de pessoas usuárias de planos de saúde. A renda costuma ter correlação positiva com a posse de planos de saúde. Já para os resultados, a escolha pode não ser tão simples. Um critério é pensar o seguinte: suponha que uma variável afeta a produção de saúde, mas não pode ser transformada em saúde, ou seja, não é um insumo para produção de saúde. Presuma que a maior presença dessa variável, combinada às demais do modelo, reduz a produção de saúde. Se essa variável for colocada como *input* no modelo, quanto maior o seu nível, maior seria a ineficiência, e a DMU seria ‘punida’ pelo modelo. Então, para compensar uma DMU exposta a essa variável, ela deve ser colocada como *output* no modelo. O oposto ocorreria com variáveis que beneficiam as DMU e que devem ser tratadas como *inputs*⁴⁷. Então, em nosso modelo, a densidade demográfica e a proporção de idosos foram tratadas como resultados; e o PIB per capita e a porcentagem de posse de planos de saúde foram tratadas como insumos, nos modelos que incorporam diretamente as variáveis não discricionárias na DEA. Nos modelos de dois estágios, em que essas variáveis ambientais são regressores que explicam a eficiência, essa escolha não é necessária, pois elas não fazem parte do problema de otimização condicionada.

Na prática, os modelos de DEA acomodam esses problemas de duas maneiras, que serão, ambas, implementadas neste capítulo. A primeira abordagem inclui essas variáveis não discricionárias no conjunto de restrições dos modelos, mas não as insere na função objetivo a ser maximizada ou minimizada, conforme tenhamos um modelo de maximização de resultados ou de minimização de insumos respectivamente (para mais informações técnicas, ver Banker e Morey⁴⁸ e Marinho et al.^{49,50}). A segunda alternativa, geralmente mais adotada, por exemplo, em Marinho⁴⁵, Araujo et al.⁵ e Marinho, Cardoso e Almeida¹⁴, consiste no método de dois estágios. Nessa abordagem, as variáveis não discricionárias são utilizadas como variáveis explicativas (independentes), em modelos de regressão nos quais os escores de eficiên-

cia calculados pela DEA são as variáveis dependentes. Assim, consegue-se inferir os impactos de tais variáveis sobre os escores de eficiência das DMU sob análise. Essa abordagem é problematizada por Simar e Wilson^{47,51} e por Banker et al.⁵², que discutem as propriedades dos estimadores dos parâmetros das regressões, pois os estimadores dos escores de eficiência da DEA não são serialmente independentes, são viesados, e são concentrados em torno da unidade, violando princípios básicos de modelos de regressão.

Podemos conjecturar, dadas as limitações das variáveis disponíveis, que maiores populações podem gerar maiores problemas de gestão e de controle dos sistemas locais de saúde; apresentam maiores dificuldades para acompanhamento de indivíduos doentes; estão sujeitas à maiores possibilidades de contágios de doenças transmissíveis; exibem maiores incidências de violências relacionadas com grandes aglomerações e grandes centros urbanos; suscitam maiores possibilidades de presença de desigualdades sociais; e costumam exibir grande diversidade de doenças e de agravos à saúde. Além disso, as prováveis diversidades étnicas, religiosas, culturais e políticas, geralmente presentes em grandes contingentes populacionais, não devem, em tese, favorecer a gestão dos sistemas de saúde. Assim, macrorregiões com grandes populações podem ter a sua avaliação prejudicada em arcações metodológicas que não contemplem compensações para essa característica específica. O oposto poderia ocorrer com macrorregiões com populações relativamente pequenas. Problemas de gestão similares aos encontrados em grandes contingentes populacionais poderiam ocorrer em macrorregiões com territórios (áreas geográficas) muito grandes. Nesse caso, as grandes distâncias e os prováveis obstáculos naturais (acidentes geográficos) podem servir, no mínimo, de elementos multiplicadores de custos; de deseconomias de escala (diante das eventuais necessidades de dispersão dos serviços); e das dificuldades de acesso das populações aos serviços de saúde com base fixa. Adicionalmente, possíveis discrepâncias político-administrativas entre os municípios componentes de uma macrorregião poderiam ser elementos complicadores da gestão de sistemas de saúde.

Para tentar reduzir as influências da população e do território, vamos utilizar a densidade demográfica nos modelos de análise de eficiência, conforme Marinho, Cardoso e Almeida¹⁴ e Marinho et al.^{49,50} ao compararem os sistemas de saúde do Brasil com os países da América Latina, Caribe e OCDE. Obviamente, tal síntese não elimina todo o conjunto de óbices e de disparidades já mencionadas, mas é um primeiro passo nesta direção. Dever⁵³ qualifica a análise estática da população como um dos elementos fundamentais da epidemiologia descritiva e arrola, entre os seus

principais conceitos descritivos, a densidade e o tamanho da população. Rouquayrol e Almeida Filho⁵⁴ também discorrem sobre tal problemática de um ponto de vista epidemiológico. Dadas todas essas complexidades, não há como prever a influência da densidade demográfica sobre a eficiência. Aparentemente, trata-se de um problema cuja solução será empírica, sem uma magnitude ou sentido definidos *ex ante*.

No DATASUS, foram coletados os dados da população na faixa etária de 0 a 74 anos e de 60 a 74 anos (idosos), assim como o número de usuários de planos de saúde, também na faixa etária de 0 a 74 anos.

O percentual de idosos foi calculado da seguinte maneira:

$$\text{Percentual de idosos} = \frac{\text{População com 60 anos a 74 anos}}{\text{população residente com 0 a 74 anos}} \times 100$$

Os usuários de planos de saúde foram, também, considerados em termos percentuais sobre a população de 0 a 74 anos, como:

$$\text{Percentual de usuários} = \frac{\text{Número de usuários de planos de saúde com 0 a 74 anos}}{\text{população residente com 0 a 74 anos}} \times 100$$

O PIB a preços correntes (R\$ mil) e a área demográfica (km²) foram coletados no Instituto Brasileiro de Geografia e Estatística (IBGE). Por sua vez, o PIB per capita foi calculado da seguinte forma:

$$\text{PIB per capita} = \frac{\text{PIB}}{\text{população residente com 0 a 74 anos}} \times 100$$

O cálculo da densidade demográfica segue com a seguinte fórmula:

$$\text{Densidade demográfica} = \frac{\text{população residente com 0 a 74 anos}}{\text{área demográfica (km}^2\text{)}}$$

Logo abaixo, no quadro 1, apresentamos o resumo dos indicadores que foram selecionados e utilizados para os cálculos dos escores de eficiência:

Quadro 1. Indicadores de produtos e recursos para a avaliação da eficiência

Indicadores
Resultados
Taxa de Sobrevivência por causas preveníveis
Taxa de Sobrevivência por causas tratáveis
Taxa de Sobrevivência por causas preveníveis e tratáveis
Insumos
Despesas per capita em Atenção Básica; com Vigilância Sanitária; e com Vigilância Epidemiológica, e com Alimentação e Nutrição
Despesas per capita para Média e Alta Complexidade; e Suporte Profilático Terapêutico
Média anual de leitos internação por habitante (x 100.000)
Média anual de leitos complementares por habitante (x 100.000)
Média anual de equipamento respirador e ventilador (SUS) por habitante (x 100.000)
Variáveis não discricionárias (variáveis explicativas exógenas)
Resultados não discricionários
<ul style="list-style-type: none"> • Densidade demográfica • Percentual de idosos
Insumos não discricionários
<ul style="list-style-type: none"> • PIB per capita • Percentual de usuários de planos de saúde

Fonte: elaboração própria

Avaliação da eficiência nas macrorregiões

Os escores nas macrorregiões de saúde: visão geral

Os dados disponíveis para os anos compreendidos entre 2008 e 2017 permitiram calcular, para as 117 macrorregiões do SUS, as eficiências e seus determinantes em modelos de DEA para cada ano da série histórica. Abaixo, na tabela 2, seguem as estatísticas descritivas das variáveis utilizadas:

Tabela 2. Estatística descritiva dos indicadores pertencentes às macrorregiões de saúde do Brasil – 2008-2017

Variáveis	Média	Desvio-Padrão	Min.	1ºQ	2ºQ	3ºQ	Máx.
Taxa de mortalidade por causas preveníveis (100.000 hab.)	126,38	21,77	53,19	113,56	125,11	140,14	184,55
Taxa de mortalidade por causas tratáveis (100.000 hab.)	60,94	10,41	34,88	53,59	59,32	66,93	108,35
Taxa de mortalidade por causas preveníveis /tratáveis (100.000 hab.)	89,15	21,27	22,68	75,01	89,50	103,14	147,05
Despesas per capita em atenção básica e vigilância	278,67	112,65	55,90	201,29	256,07	339,46	1.199,75
Despesas per capita em atenção especializada e Suporte profilático terapêutico	487,86	243,17	92,48	307,49	430,41	621,52	1.766,84
Leitos de internações/hab.(x100.000)	171,62	47,29	55,13	139,40	166,77	199,59	324,55
Leitos complementares/hab.(x100.000)	11,18	5,23	0,40	7,13	11,23	14,49	27,82
Equipamentos respiradores e ventiladores SUS/hab.(x100.000)	2,59	1,00	0,59	1,85	2,45	3,26	5,83
Densidade demográfica (Hab./km ²)	202,88	797,44	1,05	12,94	33,96	88,42	7.634,50
Idosos %	8,46	1,93	3,66	7,27	8,48	9,62	15,03
PIB per capita	22,19	13,76	3,27	11,69	19,15	29,89	85,48
Usuários de planos de saúde %	16,95	12,33	0,54	6,75	14,77	24,17	55,39

Fonte: elaboração própria

Como existe demanda reprimida e necessidades de saúde não atendidas, com a formação de filas no SUS em todos os níveis de atenção, optamos por modelos que privilegiem a expansão da produção, dados os insumos disponíveis (modelos *output oriented*). A DEA permite diferentes formas de orientação (*input oriented*, direcional, hiperbólica, entre outras), mas essa opção nos parece mais adequada (o leitor interessado pode ver mais detalhes no capítulo 6 deste livro). Também optamos por modelos em que as variações nos resultados não são proporcionalmente iguais às variações nos insumos. Esses modelos são chamados de modelos com retornos variáveis de escala. Se as variações proporcionais nos insumos e nos resultados fossem

iguais, teríamos retornos constantes de escala (retornos de escala foram descritos de modo pormenorizado no capítulo 6 deste livro).

A opção por modelos corrigidos pelo *bootstrap*³⁴ se deu porque não conhecemos a tecnologia de produção em cada macrorregião, e há grande heterogeneidade estrutural entre elas. Simar e Wilson³⁴ apontam uma série de problemas com os modelos originais da DEA. Os escores de eficiência são viesados, dado que a fronteira de eficiência estimada é, por construção, superposta ou inferior à fronteira teórica, que não pode ser observada. Além disso, os escores de eficiência, por serem relativos, são, serialmente, correlacionados. Como o processo de geração de dados (DGP) é desconhecido, a distribuição de probabilidade dos escores também é desconhecida, o que impede a construção de intervalos de confiança e a realização de testes de hipóteses.

A partir dessa crítica foram desenvolvidos aqui novos modelos corrigidos. Esses problemas são particularmente importantes, quando a qualidade dos dados é questionável, como ocorre com os dados do SUS em nível municipal, principalmente os registros relacionados com as despesas (para mais detalhes, ver o Apêndice 1). O trabalho de Marinho e Araújo⁹, aplicado em transplantes de órgãos no Brasil, é uma referência para essa correção dos modelos de DEA aplicados em saúde. É importante assinalar que estudos muito citados de avaliação do SUS não tomaram essas precauções metodológicas^{4,8,43}.

Em primeiro exame, embora o método não vede categoricamente, não seria interessante a presença de correlações positivas muito fortes entre insumos ou entre resultados, porque insumos muito correlacionados carregam a mesma informação. Se isso ocorrer, pode ser aconselhável, por razões de parcimônia, retirar algumas dessas variáveis correlacionadas de modo muito positivo. Por outro lado, também não seria muito recomendável a presença de correlações negativas entre insumos e resultados. Embora correlação não signifique causalidade, insumos e resultados deveriam, em princípio, correlacionar-se positivamente, ou seja, as quantidades produzidas dos resultados deveriam aumentar, ou, ao menos, não diminuir, quando um *input* tem sua quantidade aumentada. Obviamente que, em uma amostra grande, que cobre um período largo de observação com muitas variáveis, como é o caso em tela, podem surgir relações diversas entre as variáveis. Como se pode ver na tabela 3, a única correlação realmente elevada (0,73) ocorre entre a variável que representa a porcentagem da população usuária de planos de saúde e o PIB per capita, mas essas são variáveis não discricionárias, fora do controle dos gestores das macrorregiões de saúde e, portanto, a situação não é problemática.

Tabela 3. Matriz de correlação entre as variáveis – 2008-2017

Cód.	Variáveis	1	2	3	4	5	6	7	8	9	10	11	12
1	Despesas per capita em atenção básica e vigilância	1,00	0,44	0,13	0,27	0,51	0,40	0,13	0,24	0,20	0,16	-0,06	0,51
2	Despesas per capita em atenção especializada e Suporte profilático terapêutico	0,44	1,00	0,05*	0,58	0,33	0,54	0,37	0,16	0,34	0,15	0,16	0,29
3	Leitos de internações/hab. (x100.000)	0,13	0,05*	1,00	0,18	0,33	-0,21	-0,25	0,14	-0,01*	0,26	-0,22	0,32
4	Leitos complementares/hab. (x100.000)	0,27	0,58	0,18	1,00	0,38	0,45	0,50	0,31	0,37	0,26	0,20	0,35
5	Equipamentos respiradores e ventiladores SUS/hab. (x100.000)	0,51	0,33	0,33	0,38	1,00	0,34	0,20	0,42	0,26	0,31	-0,11	0,56
6	PIB per capita	0,40	0,54	-0,21	0,45	0,34	1,00	0,73	0,26	0,41	0,24	0,36	0,33
7	Usuários de planos de saúde %	0,13	0,37	-0,25	0,50	0,20	0,73	1,00	0,20	0,53	0,34	0,49	0,32
8	Taxa de mortalidade por causas evitáveis (100.000 hab.)	0,24	0,16	0,14	0,31	0,42	0,26	0,20	1,00	0,21	0,49	-0,09	0,35
9	Taxa de mortalidade por causas tratáveis (100.000 hab.)	0,20	0,34	-0,01*	0,37	0,26	0,41	0,53	0,21	1,00	0,62	0,29	0,46
10	Taxa de mortalidade por causas evitáveis/tratáveis (100.000 hab.)	0,16	0,15	0,26	0,26	0,31	0,24	0,34	0,49	0,62	1,00	0,14	0,55
11	Densidade demográfica (hab./km ²)	-0,06	0,16	-0,22	0,20	-0,11	0,36	0,49	-0,09	0,29	0,14	1,00	0,05*
12	Idosos %	0,51	0,29	0,32	0,35	0,56	0,33	0,32	0,35	0,46	0,55	0,05*	1,00

Fonte: elaboração própria

* Correlações não significativas no nível de 5%

As estimativas dos escores de eficiência e o impacto das variáveis não discricionárias nos resultados

A seguir, discutiremos os resultados dos modelos de cálculo dos escores de eficiência das macrorregiões do SUS no período entre os anos de 2008 e 2017. A amostra utilizada apresenta um grau de heterogeneidade elevado, seja com relação aos indicadores de saúde utilizados, seja no que se refere às características socioeconômicas, físicas e populacionais das macrorregiões de saúde. Então, tornou-se necessário incluir, na análise de eficiência, como já assinalamos, variáveis não controláveis pelos gestores locais do SUS, mas que, em certa medida, poderiam impactar no seu desempenho com relação à provisão dos cuidados à saúde das populações,

previamente discutidas quando analisamos as variáveis do nosso modelo. Então, a nossa análise de eficiência das macrorregiões de saúde inclui, de modo explícito, as chamadas variáveis não discricionárias, ou ambientais, a fim de captar estas desigualdades. As variáveis não discricionárias utilizadas no presente trabalho foram, para cada macrorregião: densidade demográfica; porcentagem de idosos entre 60 e 74 anos na população; porcentagem de usuários de planos de saúde; e PIB per capita.

Conforme veremos a seguir, a introdução das variáveis não discricionárias diretamente nos modelos de DEA eleva, entre os anos de 2008 e 2017, a média geral nacional dos escores de eficiência de 67,5% na tabela 4 para 91,2% na tabela 5 (aumento de 23,7 pontos percentuais) e reduz a dispersão dos mesmos escores de 14% na tabela 4 para 6,5% (praticamente a metade) na tabela 5. A comparação entre os dois modelos está em perspectiva no gráfico 3.

A elevação da média dos escores que ocorre quando as variáveis não discricionárias são introduzidas nos modelos pode ser explicada de dois modos não necessariamente excludentes: seria um artefato dos modelos, dado que a DEA perde capacidade discriminatória quando a quantidade de variáveis (insumos e resultados) aumenta em uma amostra fixa não muito grande (em nosso caso, são 117 macrorregiões de saúde), o que ocorre quando introduzimos as quatro variáveis não discricionárias em nosso modelo. Isso acontece porque cada variável é, de fato, um critério de julgamento da DMU. Com muitos critérios, aumentam as probabilidades de uma dada DMU ser eficiente. Outra explicação seria que a performance das macrorregiões é realmente muito afetada pelas variáveis não discricionárias. Essa hipótese será testada quando discutirmos os modelos de dois estágios. Aparentemente, essa não seria uma hipótese descartável nas macrorregiões do SUS, de acordo com os nossos modelos, inclusive na análise dos modelos dinâmicos da próxima seção, pois, como veremos, os parâmetros dessas variáveis são estatisticamente significativos nos modelos de regressão em que elas explicam os escores de eficiência obtidos na DEA.

Um ponto importante que devemos assinalar é que os modelos de DEA, que são modelos de programação matemática, são sensíveis às observações atípicas (*outliers*). *Outliers* podem ser gerados por erros na coleta ou registro dos dados, ou pela ocorrência de dados pouco prováveis. No caso de dados errados, as observações devem ser retiradas da amostra. Para detectar a presença de *outliers*, usamos, no *software* FEAR, o método proposto por Wilson⁵⁵. Foram detectados dois *outliers*: a macrorregião Oeste e a região Leste, ambas no estado do Amazonas. São macrorregiões com baixíssima densidade demográfica e, por isso, foram detectadas. Então,

como não se trata de erro, não foram retiradas da amostra, até porque, como assinala Wilson⁵⁵, *outliers* podem ser a parte mais interessante dos dados^{VIII}.


Tabela 4. Estatísticas descritivas dos escores de eficiência, nas macrorregiões de saúde do SUS, no modelo corrigido pelo *bootstrap* sem variáveis não discricionárias – 2008-2017 (%)

Ano	Média	Máximo	Mínimo	Mediana	Desvio-Padrão	Moda	CV
2008	66,8	90,8	48,4	65,8	10,2	79%	15,3
2009	69,8	89,0	49,4	69,6	8,2	80%	11,8
2010	61,2	80,8	39,8	60,8	9,3	62%	15,2
2011	67,1	90,1	47,3	66,8	9,3	78%	13,9
2012	64,3	86,5	46,0	63,0	9,8	77%	15,2
2013	70,2	90,7	49,9	70,0	9,1	80%	13,0
2014	72,8	95,6	51,4	73,4	10,1	73% e 82%	13,8
2015	66,0	85,1	43,8	64,5	9,2	60 e 63%	13,9
2016	65,9	90,4	44,4	64,9	9,3	59% e 65%	14,1
2017	70,4	94,9	46,5	70,3	9,7	66%	13,8
Média	67,5	89,4	46,7	66,9	9,4	-	14,0

Fonte: elaboração própria.

VIII Em tom algo anedótico, pode-se pensar que as pernas do saudoso jogador Garrincha eram, certamente, *outliers* comparadas com as pernas dos demais jogadores de futebol. Entretanto, ninguém ousaria excluir o magnífico craque de uma avaliação ou de uma descrição do desempenho histórico das seleções brasileiras de futebol.

Gráfico 1. Evolução das estatísticas anuais dos escores de eficiência, nas macrorregiões de saúde do SUS, no modelo corrigido pelo *bootstrap* sem variáveis não discricionárias – 2008-2017 (%)




Fonte: elaboração própria.

Tabela 5. Estatísticas descritivas dos escores de eficiência nas macrorregiões de saúde do SUS, no modelo corrigido pelo *bootstrap*, considerando as variáveis não discricionárias – 2008-2017 (%)

Ano	Média	Máximo	Mínimo	Mediana	Desvio-Padrão	Moda	CV
2008	88,6	97,5	66,7	92,1	7,4	92,0	8,4
2009	89,6	98,2	72,9	92,2	6,2	93,0	6,9
2010	88,9	98,0	68,9	92,4	7,0	92,0	7,9
2011	90,8	98,2	73,6	93,8	6,2	93,0	6,8
2012	91,1	97,8	72,9	94,0	6,4	94,0	7,0
2013	92,2	98,0	79,1	94,7	5,1	94,0	5,5
2014	92,5	98,7	78,4	95,0	5,4	95,0	5,8
2015	92,0	98,1	76,8	94,7	5,4	94,0	5,9
2016	92,5	98,1	75,5	95,0	5,4	95,0	5,8
2017	93,4	98,5	77,7	95,7	4,8	95,0	5,1
Média	91,2	98,1	74,3	94,0	5,9	93,7	6,5


Fonte: elaboração própria.

Gráfico 2. Evolução das estatísticas anuais dos escores de eficiência, nas macrorregiões de saúde do SUS, no modelo corrigido pelo *bootstrap* considerando as variáveis não discricionárias – 2008-2017 (%)



Fonte: elaboração própria.

Gráfico 3. Comparativo entre os modelos DEA-*bootstrap* relativo às médias anuais de eficiência das macrorregiões de saúde, no período 2008-2017



Fonte: elaboração própria.

O nível de eficiência nas macrorregiões de saúde

Em termos médios, o nível de eficiência nas macrorregiões não seria ruim. No modelo com as variáveis não discricionárias, atinge 91,2% e é, portanto, elevado. No modelo sem essas variáveis, é 67,5%, apenas mediano. Por outro lado, conforme vimos nos gráficos 1, 2 e 3, a eficiência varia pouco, sempre em torno da média, ao longo dos anos. Não há tendência definida no modelo sem variáveis não discricionárias. Há uma leve tendência de crescimento da média no modelo com variáveis não discricionárias, com crescimento constante a partir de 2010. O mais interessante é que esse movimento, nesse modelo, é puxado pelo crescimento da eficiência mínima estimada, ou seja, ocorreu uma tendência para o desaparecimento de níveis de muito baixos de eficiência nas macrorregiões.

As dispersões, em ambos os modelos, não são grandes, quando medidas pelo coeficiente de variação (desvio-padrão/média). No modelo com variáveis não discricionárias, corresponde a 6,5% (na tabela 5), e no modelo sem variáveis não discricionárias, é de 14,0% (na tabela 4). Dispersões muito elevadas não seriam razoáveis em um SUS, de caráter nacional. Um fenômeno importante é que a dispersão da eficiência vem caindo em ambos os modelos: a eficiência vinha se tornando mais uniforme entre as macrorregiões do SUS ao longo do tempo, notadamente a partir do ano de 2012. Esse movimento é particularmente visível dada a convergência das linhas no gráfico 2 ao longo do tempo.

Modelos de dois estágios: os determinantes da eficiência nas macrorregiões de saúde

Uma perspectiva alternativa para considerar as variáveis não discricionárias nos modelos de eficiência consiste em usar essas variáveis como independentes (regressores), em modelos de regressão em que os escores de eficiência são as variáveis dependentes. Assim, busca-se explicar os impactos que as variáveis fora do controle dos gestores do SUS nas macrorregiões exercem sobre a eficiência da prestação de serviços do SUS. Trata-se de abordagem muito utilizada, em diversos contextos como análise de eficiência na prestação de serviços de saúde por municípios⁴⁵, hospitais⁵ ou de sistemas nacionais de saúde^{56,57}, inclusive em métodos de cálculo de eficiência diferentes da DEA como o método das fronteiras estocásticas, aplicados em sistemas de saúde em Marinho et al⁴⁹ e em Marinho, Cardoso e Almeida¹⁴.

Há controvérsias na literatura sobre a especificação econométrica dos modelos em segundo estágio^{46,51,52}. O debate ocorre devido à existência de correlação serial entre os estimadores dos escores de eficiência, que são medidas relativas. Os escores de eficiência reais não são observados, o processo de geração dos dados é desconhecido, e os

escores são truncados entre zero e a unidade. Além disso, os estimadores dos escores de eficiência são viesados, pois são, por construção, maiores ou iguais aos escores reais, e ficam concentrados em torno da unidade. Esses problemas vão contra os pressupostos dos modelos usuais de regressão.

Para dirimir dúvidas, executamos regressões com as correções propostas via *bootstrap* por Simar e Wilson⁵¹, e modelos de mínimos quadrados ordinários (*Ordinary Least Squares* – OLS) propostas por Banker et al.⁵² e, ainda, regressões truncadas (*Tobit*) muito usadas na literatura com resultados bastante semelhantes^{IX}. Isso significa que o arcabouço da análise econométrica é razoavelmente estável e pouco sensível às mudanças de especificação previstas na literatura. Os resultados que apresentaremos no quadro 2^X não diferem qualitativamente dos obtidos nas alternativas. Precauções semelhantes foram observadas na análise dinâmica da próxima seção, na qual regredimos essas mesmas variáveis não discricionárias contra os componentes do Índice de Malmquist (IM), com a mesma estabilidade de resultados.

Cabe ressaltar que, nos modelos de regressão executados por característica do *software* utilizado, a variável dependente é o inverso dos escores de eficiência (função distância). Então, de fato, nas análises que se seguem, as variáveis dependentes estão determinando a ineficiência das macrorregiões.

A densidade demográfica tem coeficiente negativo e estatisticamente significativo em todos os anos. Então, quanto maior a densidade demográfica, menor a ineficiência, ou seja, maior será a eficiência das macrorregiões do SUS.

A porcentagem de idosos na população tem parâmetro de regressão com sinal positivo e sempre estatisticamente significativo. Então, altos níveis de ineficiência estão associados com elevada presença de idosos. Como idosos são pacientes relativamente dispendiosos, e cujas condições de saúde respondem de forma menos efetiva aos tratamentos, esse achado se repete em todos os anos; e os coeficientes das regressões são os maiores entre todas as demais variáveis explicativas.

Na regressão, o PIB per capita tem parâmetro sempre estatisticamente significativo, mas apresenta sinal ora positivo, ora negativo, sem qualquer padrão aparente. Vale

IX Os resultados de todos esses diferentes procedimentos praticamente não mudam em termos qualitativos, e não serão comentados para evitar repetições enfadonhas ao leitor, mas estão disponíveis com os autores. Não existem, ainda, métodos consolidados para regressão de eficiência em painel (cross sections combinadas com séries temporais) de modo que optamos por fazer as regressões ano a ano. A alternativa disponível para utilizar a sequência de dados anuais em conjunto com regressões é o IM, que será explorado subsequentemente.

X Esses resultados foram obtidos no *software Robust Data Envelopment Analysis (DEA) for R* (rDEA, 1.2-4, 2016).

dizer: as correlações negativas entre o PIB e a eficiência em sistemas de saúde podem ser explicadas pelo fato de que fica cada vez mais difícil obter melhoria da situação em saúde para cada unidade monetária adicional empregada, quando o nível de renda é elevado. Por sua vez, a renda elevada costuma estar associada com elevados níveis de saúde. Isto é, a presença de alta renda na amostra costuma estar associada com boas condições de saúde, e isso torna relativamente difícil melhorar a saúde de quem já é saudável (a esse respeito, ver Marinho, Cardoso e Almeida¹⁴ e Marinho et al.^{49,50}). Entretanto, como existem cinco anos com parâmetros com sinais positivos, não há como chegar a conclusões definitivas.

A porcentagem de usuários de planos de saúde na população tem coeficiente sempre positivo e estatisticamente significativo. Então, a ineficiência medida nas macrorregiões do SUS e a posse de planos de saúde estão positivamente correlacionadas. Dito de modo mais específico, percentuais mais elevados de usuários de planos de saúde estão, na amostra, associados com baixos escores de eficiência técnica nas macrorregiões de saúde. Podemos interpretar esse fenômeno da seguinte forma: os planos de saúde, no afã de reduzir dispêndios e investimentos e aumentar os seus lucros, impactam negativamente o desempenho do SUS, via mecanismos de interações complexos, e nada triviais, mas fartamente relatados na imprensa e na literatura (exclusão de pacientes idosos via elevação de preços, seleção de riscos (*cream skinning*), negativa de atendimentos etc.). Esse comportamento dos planos de saúde, ao fim e ao cabo, termina por gerar atendimentos tardios e em piores condições no SUS daqueles que não foram corretamente tratados no setor privado. Aqui cabe uma ressalva: se a mortalidade evitável é aumentada por maus procedimentos dos planos de saúde, os impactos em nosso modelo são atribuídos ao SUS. É impossível evitar esse artefato, por falta de dados adequados.

Por outro lado, vale ressaltar que este livro não contempla os gastos das famílias, das empresas (em planos empresariais) e do governo (renúncia fiscal) com planos de saúde nem com atendimentos pagos diretamente pelas famílias (*out-of-pocket*). Esses dados, que não são disponíveis para as macrorregiões, se acrescidos aos dispêndios do SUS, poderiam modificar substancialmente os resultados aqui obtidos, rebaixando ainda mais a eficiência em saúde que, nesse caso, nem seria mais a eficiência do SUS em um sentido estrito. A influência dos planos de saúde, e de outros modelos organizacionais privados de atenção à saúde, sobre o desempenho do SUS é um tema controverso, ainda em aberto, que mereceria investigações e pesquisa que iriam além do escopo deste livro.

Quadro 2. Estimativas dos parâmetros das variáveis ambientais e desvios-padrão da regressão truncada sobre a função distância na DEA – 2008-2017

Ano	Variáveis	coef.	Coef. robust	IC 95% (robust)	
				Inf.	Sup.
2008	(Intercept)	0,339	0,448	0,001	0,917
	Log (densidade)	-0,041	-0,050	-0,085	-0,015
	Log (idosos %)	0,389	0,428	0,220	0,634
	Log (PIB per capita)	0,088	0,002	-0,135	0,143
	Log (Beneficiários %)	0,099	0,183	0,078	0,285
	<i>Sigma</i>	<i>0,211</i>	<i>0,222</i>	<i>0,193</i>	<i>0,257</i>
2009	(Intercept)	0,379	0,589	0,269	0,915
	Log (densidade)	-0,046	-0,035	-0,059	-0,010
	Log (idosos %)	0,429	0,387	0,238	0,529
	Log (PIB per capita)	0,013	-0,036	-0,138	0,069
	Log (Beneficiários %)	0,107	0,131	0,055	0,205
	<i>Sigma</i>	<i>0,160</i>	<i>0,159</i>	<i>0,140</i>	<i>0,183</i>
2010	(Intercept)	0,112	0,400	-0,041	0,856
	Log (densidade)	-0,032	-0,039	-0,072	-0,006
	Log (idosos %)	0,577	0,548	0,348	0,744
	Log (PIB per capita)	0,025	-0,082	-0,220	0,058
	Log (Beneficiários %)	0,121	0,210	0,107	0,310
	<i>Sigma</i>	<i>0,203</i>	<i>0,215</i>	<i>0,189</i>	<i>0,248</i>
2011	(Intercept)	0,150	0,363	0,012	0,731
	Log (densidade)	-0,060	-0,049	-0,075	-0,022
	Log (idosos %)	0,600	0,544	0,380	0,701
	Log (PIB per capita)	-0,070	-0,109	-0,216	-0,003
	Log (Beneficiários %)	0,175	0,198	0,118	0,280
	<i>Sigma</i>	<i>0,166</i>	<i>0,172</i>	<i>0,151</i>	<i>0,199</i>
2012	(Intercept)	-0,130	-0,084	-0,485	0,336
	Log (densidade)	-0,083	-0,085	-0,114	-0,055
	Log (idosos %)	0,697	0,757	0,570	0,936
	Log (PIB per capita)	0,007	-0,039	-0,155	0,082
	Log (Beneficiários %)	0,167	0,200	0,108	0,288
	<i>Sigma</i>	<i>0,181</i>	<i>0,189</i>	<i>0,167</i>	<i>0,218</i>

Ano	Variáveis	coef.	Coef. robust	IC 95% (robust)	
				Inf.	Sup.
2013	(Intercept)	-0,082	0,027	-0,336	0,399
	Log (densidade)	-0,045	-0,045	-0,069	-0,020
	Log (idosos %)	0,620	0,625	0,460	0,783
	Log (PIB per capita)	0,016	-0,017	-0,115	0,083
	Log (Beneficiários %)	0,091	0,110	0,034	0,184
	<i>Sigma</i>	0,154	0,159	0,139	0,184
2014	(Intercept)	-0,231	-0,015	-0,473	0,467
	Log (densidade)	-0,046	-0,041	-0,070	-0,011
	Log (idosos %)	0,631	0,593	0,386	0,790
	Log (PIB per capita)	-0,016	-0,050	-0,171	0,075
	Log (Beneficiários %)	0,145	0,149	0,053	0,240
	<i>Sigma</i>	0,175	0,181	0,156	0,213
2015	(Intercept)	0,236	0,289	-0,142	0,740
	Log (densidade)	-0,039	-0,044	-0,073	-0,014
	Log (idosos %)	0,600	0,631	0,435	0,823
	Log (PIB per capita)	-0,087	-0,106	-0,233	0,028
	Log (Beneficiários %)	0,110	0,138	0,046	0,227
	<i>Sigma</i>	0,186	0,193	0,170	0,224
2016	(Intercept)	0,298	0,288	-0,144	0,744
	Log (densidade)	-0,056	-0,068	-0,097	-0,038
	Log (idosos %)	0,661	0,747	0,555	0,926
	Log (PIB per capita)	-0,132	-0,147	-0,272	-0,015
	Log (Beneficiários %)	0,112	0,125	0,036	0,213
	<i>Sigma</i>	0,177	0,188	0,165	0,217
2017	(Intercept)	0,128	0,177	-0,253	0,629
	Log (densidade)	-0,047	-0,043	-0,070	-0,016
	Log (idosos %)	0,729	0,726	0,534	0,913
	Log (PIB per capita)	-0,201	-0,202	-0,319	-0,077
	Log (Beneficiários %)	0,152	0,160	0,073	0,241
	<i>Sigma</i>	0,162	0,168	0,146	0,195

Fonte: elaboração própria.

Análise da eficiência nas regiões geográficas

O Brasil é marcado por desigualdades socioeconômicas e sanitárias. Em nível macro, normalmente, as regiões Sul e Sudeste, e em menor medida, a região Centro-Oeste, apresentam indicadores de desenvolvimento superiores aos indicadores da região Norte e da região Nordeste. Faremos uma breve avaliação da eficiência nas regiões geográficas, pois essa é uma maneira de agregar melhor os resultados que obtivemos nas macrorregiões. Inclusive, veremos os efeitos da consideração, ou não, das variáveis não discricionárias (densidade demográfica; porcentagem de idosos na população; porcentagem de pessoas com planos de saúde; PIB per capita), em cada região.


No modelo que não considera as variáveis não discricionárias, os resultados vistos na tabela 6 e no gráfico 4 indicam menores eficiências e maiores dispersões (medido pelo coeficiente de variação) nas regiões mais desenvolvidas do país (Sul, Sudeste e Centro-Oeste). A menor eficiência em regiões mais desenvolvidas, fenômeno que já discutimos anteriormente, é um resultado que ocorre com frequência: esse fenômeno deve-se, basicamente, às maiores dificuldades de obtenção de resultados causados por gastos em saúde, em situações em que a população é relativamente mais saudável, do que em regiões mais pobres e menos desenvolvidas. Entretanto, esse resultado deve ser relativizado, como veremos com a introdução das variáveis não discricionárias no modelo.

Tabela 6. Médias e desvios-padrão das eficiências sem as variáveis não discricionárias e corrigidas pelo *bootstrap*, nas regiões do Brasil, 2008-2017 (%)

Regiões	Média	Desvio-Padrão	CV
Centro-Oeste	67,21	8,24	12,26
Norte	74,78	4,64	6,20
Nordeste	69,70	5,21	7,47
Sul	65,72	8,63	13,13
Sudeste	63,63	8,18	12,85
Total Geral	68,21	6,98	10,23

Fonte: elaboração própria.

Gráfico 4. Eficiências médias sem as variáveis não discricionárias e corrigidas pelo *bootstrap*, segundo as regiões do Brasil – 2008-2017



Fonte: elaboração própria.


No modelo de análise que considera, explicitamente, as variáveis não discricionárias como restrições aos modelos com base na DEA, os resultados se invertem em relação ao observado anteriormente. Agora, as regiões mais desenvolvidas (Centro-Oeste, Sudeste e Sul) têm desempenhos superiores, em termos de escores de eficiência do que as regiões menos desenvolvidas do país (Nordeste e Norte). Esse achado não corrobora, em parte, o que verificamos na seção anterior, em que os modelos de regressão indicavam que a posse de planos de saúde e a porcentagem de presença de idosos, que costumam indicar maior desenvolvimento econômico, reduzem, em média, a eficiência nas macrorregiões do SUS. A variabilidade dos escores de eficiência, medidas pelo coeficiente de variação, é bem menor nesse modelo (média 5,14), ou seja, é praticamente a metade do modelo sem as variáveis não discricionárias (média 10,23). Talvez, o mais importante desse fenômeno seja a constatação de que avaliações da eficiência do SUS não devem desconsiderar situações socioeconômicas distintas, como as que ocorrem no território brasileiro. Mais ainda, os resultados obtidos pelo SUS não dependem apenas dele. Dependem, também, das condições gerais de vida da população. O SUS é condição necessária, mas não suficiente, para que a população brasileira goze de boa saúde.

Tabela 7. Médias e desvios-padrão das eficiências nas regiões do Brasil, corrigidas pelo *bootstrap*, considerando as variáveis não discricionárias – 2008-2017 (%)

Regiões	Média	Desvio-Padrão	CV
Centro-Oeste	85,94	5,46	6,35
Norte	86,50	6,04	6,98
Nordeste	91,72	4,75	5,18
Sul	93,31	3,66	3,93
Sudeste	93,52	3,26	3,48
Total Geral	90,20	4,63	5,14

Fonte: elaboração própria.

Gráfico 5. Eficiências médias, corrigidas pelo *bootstrap*, considerando as variáveis não discricionárias, segundo as regiões do Brasil – 2008-2017



Fonte: elaboração própria.

As variações na produtividade, eficiência e tecnologia: o índice de Malmquist

Nesta seção, utilizamos o IM, baseado na DEA e descrito no Apêndice 4, para analisar as variações da produtividade, da eficiência e da tecnologia entre os anos 2008 e 2017 (nos moldes dos modelos anteriores da DEA). O *software* utilizado para o cálculo é o *Frontier Efficiency Analysis with R*, 1.15 (FEAR)⁵⁸, que calcula o IM com as correções feitas pelo bootstrap⁵⁹. Embora tenhamos realizado estudos com o modelo tradicional, esses não serão comentados, dado que os indicadores são qualitativamente semelhantes, no entanto, menos confiáveis por serem determinísticos, sem intervalos de confiança e viesados.

As variáveis básicas estão apresentadas a seguir no quadro 3:

Quadro 3. Indicadores de produtos e recursos para a avaliação da eficiência

Indicadores
Resultados
Taxa de Sobrevivência por causas preveníveis
Taxa de Sobrevivência por causas tratáveis
Taxa de Sobrevivência por causas preveníveis/tratáveis
Insumos
Despesas em Atenção Básica; com Vigilância Sanitária; com Vigilância Epidemiológica; e com Alimentação e Nutrição
Despesas para Média e Alta Complexidade; com Suporte Profilático e Terapêutico; e com Assistência Farmacêutica
Média de leitos internação por habitante
Média de leitos complementares por habitante
Equipamento Respirador e Ventilador no SUS(%)

Fonte: elaboração própria

O quadro geral do IM

A média da produtividade das macrorregiões de saúde, aparentemente, aumentou no período analisado (2008 e 2017). Quando a produtividade aumenta, o IM é maior do que a unidade; quando a produtividade diminui, o valor do índice é menor do que a unidade; a produtividade fica constante quando o índice é igual à unidade. Conforme a tabela 8 abaixo, O IM médio foi 1,351, com máximo igual a 7,179 e mínimo igual a 0,07.

A variabilidade do IM é relativamente grande na amostra, pois o coeficiente de variação (quociente entre o desvio-padrão e a média amostral) é igual a 77,54%.

Como na DEA, o IM em nosso estudo está orientado para maximização de resultados. No IM, a variação da produtividade se divide em dois componentes: a variação da eficiência técnica e a mudança da tecnologia. Diz-se que há aumentos nesses componentes quando o parâmetro estimado de cada um deles é maior do que a unidade (1,000). Parâmetros menores do que a unidade apontam para redução nos indicadores. Um parâmetro igual à unidade indica que não houve aumento nem redução da respectiva variável.

Todos os indicadores que estimamos com o método corrigido estão dentro dos respectivos intervalos de confiança. Na tabela 8, observamos que a variação da produtividade, medida pelo IM, teve média igual a 1,351 e mediana igual a 1,182 no período entre os anos de 2008 e 2017. A rigor, em termos estatísticos, se o intervalo de confiança gerado pelo método corrigido pelo *bootstrap* contém a unidade (1,000), nada pode ser dito a respeito da variação do IM e de seus componentes^{XI}. Um critério para avaliar o comportamento dos parâmetros calculados é observar a média de um dado parâmetro e o intervalo de confiança médio desse parâmetro. Com essa hipótese de trabalho, teria ocorrido crescimento da produtividade média da amostra medida pelo IM, pois o intervalo de confiança médio (1,05; 155) é superior à unidade com IM igual a 1,35, o que significaria um crescimento da produtividade do SUS no período igual a aproximadamente 35%. Entretanto, paradoxalmente, não teria ocorrido crescimento estatisticamente significativo de seus componentes, pois a variação da eficiência técnica e a variação tecnológica têm, ambas, intervalos de confiança médios que contêm a unidade. Um critério alternativo é avaliar apenas as macrorregiões nas quais todos os parâmetros apresentam intervalos de confiança que não contenham a unidade. Nesse caso, ocorre uma redução dramática do tamanho da amostra (cujo tamanho caiu de 117 macrorregiões de saúde para apenas 27 macrorregiões). Como alguns intervalos de confiança estão à esquerda e outros à direita da unidade, ocorreu que, mesmo nesse caso, os intervalos de confiança médios dos parâmetros contêm a unidade, e nada se pode afirmar sobre crescimento ou redução da produtividade. No entanto, é possível afirmar que ocorreu aumento de produtividade estatisticamente significativo em 11 macrorregiões de saúde, e decréscimo de produtividade em 16 macrorregiões. Por sua vez, ocorreu aumento de eficiência técnica em 11 macrorregiões de saúde e decréscimo em 16 macrorregiões.

Qualquer que seja o critério de análise, a variação de tecnologia foi inferior, ou muito próxima da unidade, não impulsionando, ou até impactando negativamente a

XI Esse cálculo e a exclusão de casos descrita a seguir foram realizados nas tabelas desagregadas, e não constam neste livro, por serem extensos e enfadonhos.

produtividade do SUS. É importante ressaltar que tecnologia não se refere apenas aos processos técnicos inovadores ocorridos por meio da incorporação de máquinas, instalações ou equipamentos nem apenas às tecnologias médicas ou das demais profissões e atividades em saúde. Tecnologia, em sentido estrito, refere-se ao que é possível produzir, dados os insumos e o modo de transformação de insumos em produtos. Sendo assim, a ‘tecnologia’ pode também admitir e abranger os arranjos organizacionais e políticos, bem como os processos decisórios que afetam a produção de bens e serviços de saúde. Igualmente, é importante assinalar que o IM não permite dizer se a tecnologia é boa ou ruim, tampouco se a produtividade ou a eficiência são baixas ou elevadas. Esse índice mede tão somente ‘variações’ da produtividade, da eficiência e da tecnologia.

Por outro lado, em ambos os critérios descritos acima, com ou sem a amostra completa, há indicação de ganhos de eficiência no SUS no período 2008-2017 visto que a mudança de eficiência técnica sempre foi superior à unidade. Então, o ganho de produtividade no SUS, seja na amostra completa (35%) ou na amostra reduzida (5%), teria ocorrido devido aos ganhos de eficiência no sistema.

Tabela 8. Estatísticas dos índices de produtividade de Malmquist e de seus componentes – 2008-2017

Estatísticas	Mudança de produtividade total	Mudança de eficiência	Mudança tecnológica
Média	1,351	1,248	1,048
Máximo	7,179	6,046	3,029
Mínimo	0,070	0,096	0,373
Desvio Padrão	1,052	0,819	0,365
Mediana	1,182	1,066	0,965
Coefficiente de variação (CV) %	77,873	65,636	34,861

Fonte: elaboração própria.

Nos mapas abaixo relacionados, conforme estimado pelo IM, pode-se notar que a produtividade variou de modo bastante errático pelo país, se considerarmos válidos todos os resultados gerados pelos modelos, a despeito dos intervalos de confiança. O mesmo fenômeno ocorreu com os componentes da variação de produtividade, a saber: a mudança na eficiência técnica e a mudança na tecnologia. Aparentemente, nossos resultados indicam que não houve redução de produtividade, de eficiência nem retrocesso tecnológico no SUS entre os anos de 2008 e 2017.

Figura 1. Índice de Produtividade de Malmquist orientado para a maximização de resultados, distribuídos segundo as macrorregiões de saúde – 2008-2017




Figura 2. Componente mudança de eficiência, distribuídos segundo as macrorregiões de saúde – 2008-2017





Figura 3. Componente mudança tecnológica, distribuídos segundo as macrorregiões de saúde – 2008-2017



Esses resultados não podem ser tirados do contexto geral, que inclui, como vimos, variáveis fora do controle dos gestores do SUS. Ademais, políticas estruturantes do SUS, entre elas, a ESF, que é muito intensiva em mão de obra de baixa ou média escolaridade, como no caso dos Agentes Comunitários de Saúde (ACS), podem não ser indutoras de aumentos imediatos de produtividade. Essas políticas aumentam instantaneamente as despesas na atenção primária, mas seus resultados – além daqueles de curto prazo como a redução da mortalidade materna e infantil – somente serão captados em longo prazo, por exemplo, a maior longevidade combinada com a redução da morbimortalidade de doenças crônicas e degenerativas. Para além da determinação social do processo saúde/doença, a ESF busca aumentar o tempo médio do médico e/ou do profissional de saúde com o paciente, na perspectiva de melhorar a eficácia e a efetividade do cuidado, o que pode ter impacto positivo na qualidade das condições de saúde do indivíduo em seu ciclo de vida.

Os determinantes das variações da produtividade, da eficiência e da tecnologia

Utilizamos modelos de regressão, que nos permitiram fazer inferências a respeito das causas das variações da produtividade, da eficiência e da tecnologia nas macrorregiões de saúde, para além do controle dos gestores do SUS. É importante assinalar que, agora, avaliaremos o impacto das variáveis não discricionárias

sobre as variações da produtividade e seus componentes (mudança tecnológica e mudança de eficiência técnica), e não sobre o nível dessas variáveis, como fizemos nas regressões que explicam a eficiência técnica. É uma diferença sutil, mas, como veremos, os resultados podem ser distintos nas duas análises. As variáveis testadas como determinantes (regressores) foram: densidade demográfica; porcentagem de idosos (entre 60 e 74 anos de idade) na população; PIB per capita; e porcentagem da população que é usuária de planos de saúde. Cada uma das tabelas a seguir mostra os resultados, para a variação da produtividade, da eficiência e da tecnologia. Para melhorar as regressões, todas as variáveis estão em logaritmos naturais. O IM calculou as variações de eficiência e de tecnologia entre os anos de 2008 e 2017. Os dados dos determinantes foram a média dos resultados encontrados entre 2008 e 2017. Também foram testados, separadamente, modelos com os dados dos regressores observados em 2008 e em 2017, e a média apenas desses dois anos e, ainda, com a diferença entre os dados desses dois anos. Além disso, conforme Simar e Wilson^{51,60} e Banker et al.⁵², diversas especificações econométricas recomendadas na literatura (regressões OLS, *bootstrap* e truncada) foram testadas, com resultados muito semelhantes. Entretanto, por concisão, apresentaremos apenas a regressão truncada e a de mínimos quadrados ordinários (OLS). Todos os parâmetros, em todos os modelos, são estatisticamente significativos em nível de teste de 5%.

Determinantes da variação da produtividade

Dada a correlação negativa, a tabela 9 indica que maior densidade demográfica implica redução da variação da produtividade, calculada pelo IM, entre os anos de 2008 e 2017. Esse resultado não é de explicação trivial, conforme já expusemos ao discutir os efeitos da densidade demográfica sobre os sistemas de saúde. A porcentagem de idosos caminha em sentido oposto ao da variação da produtividade. Esse seria um resultado esperado, uma vez que idosos exigem maiores cuidados e gastos, em geral, para a manutenção e recuperação da saúde. Desse modo, a produtividade em saúde diminui quando a porcentagem de idosos aumenta. Por sua vez, os modelos apontam uma correlação negativa entre a variação da produtividade e o PIB. Macrorregiões de saúde com PIB elevado experimentaram, em média, redução de produtividade no período, o que talvez seja resultado das dificuldades em melhorar o desempenho de sistemas de saúde em sociedades mais afluentes, conforme já discutimos.

Paralelamente, a porcentagem de usuários de planos de saúde e a variação da produtividade caminham no mesmo sentido, dada a correlação positiva entre as variáveis. Esse resultado pode, por hipótese que não temos como testar no âmbito deste livro, advir

de um comportamento estratégico dos planos que, ao longo do tempo, posicionam-se em regiões com menores problemas de saúde ou mesmo de uma limitação dos nossos modelos, que não contemplam os gastos privados com os planos de saúde. Se incluídos, esses gastos reduziriam a eficiência de uma forma impossível de prever, dado que elevariam o uso dos *inputs* em montantes que desconhecemos. Ademais, a compra de planos de saúde é um indicador correlacionado com a renda, a educação e a disponibilidade de profissionais e de redes de atenção à saúde. Desse modo, para obter um resultado mais apurado, entre outras medidas de avaliação, o gasto total (público e privado) deveria ser incluído. De nenhum modo, portanto, caberia recomendar a substituição do SUS pelo mercado de planos de saúde com base nesses resultados, até mesmo pela limitação de acesso aos planos imposta pela renda disponível e pelo aumento continuado de seus preços acima da inflação.

Tabela 9. Estimativas dos parâmetros das variáveis ambientais, erros-padrão, estatísticas T e intervalos de confiança da regressão truncada e OLS sobre os índices de produtividade de Malmquist bootstrap – 2008-2017

	Log IM	Coef.	Erro-Padrão	T	[95% Int. conf.]	
					Bootstrap	
Regressão truncada*	Log (densidade)	-0,007	0,102	-0,068	-0,250	0,156
	Log (idosos %)	-0,079	0,403	-0,197	-1,195	0,404
	Log (PIB per capita)	-0,284	0,350	-0,811	-0,956	0,438
	Log (Beneficiários %)	0,128	0,224	0,573	-0,227	0,673
	(Intercepto)	5,659	0,828	6,833	4,459	7,685
OLS	Log (densidade)	-0,112	0,072	-1,552	-0,281	0,009
	Log (idosos %)	-0,731	0,281	-2,599	-1,303	-0,191
	Log (PIB per capita)	-0,401	0,231	-1,731	-0,889	0,013
	Log (Beneficiários %)	0,455	0,171	2,661	0,139	0,813
	(Intercepto)	6,676	0,620	10,772	5,511	7,975

Fonte: elaboração própria

* Limit: lower = 0; upper = +inf

Replications = 10.000

Number of obs = 117

Determinantes da variação da eficiência técnica

Na tabela 10, a densidade demográfica e a variação de eficiência têm correlação positiva, em contraponto ao efeito positivo dessa variável sobre variação da produtividade. Como veremos adiante, a variação da tecnologia é negativamente impactada pela densidade demográfica. Então, esse efeito negativo da densidade demográfica sobre a mudança tecnológica predomina sobre o efeito positivo sobre a eficiência técnica, dado que o efeito final da densidade demográfica sobre a produtividade é negativo. Porcentagem de idosos e o PIB per capita variam em sentidos opostos na regressão truncada e na OLS; assim, dada essa divergência, não faremos maiores comentários nesses casos.

Vale dizer: a porcentagem de usuários de planos de saúde e a variação na eficiência técnica variam no mesmo sentido, haja vista o sinal positivo do respectivo parâmetro nas regressões. Aqui, cabe a mesma linha de argumentação que apresentamos para a correlação positiva entre a posse de planos de saúde e produtividade (posicionamento estratégico dos planos em regiões desenvolvidas, correlação positiva da posse de planos de saúde e renda etc.).

Tabela 10. Estimativas dos parâmetros das variáveis ambientais, erros-padrão, estatísticas T e intervalos de confiança da regressão truncada e OLS sobre os escores de mudança de eficiência *bootstrap* – 2008-2017

	Log EC	Coef.	Erro-Padrão	T	[95% Int. conf.]	
					<i>Bootstrap</i>	
Regressão truncada*	Log (densidade)	-0,083	0,078	-1,068	-0,226	0,083
	Log (idosos %)	0,165	0,323	0,513	-0,596	0,706
	Log (PIB per capita)	0,116	0,279	0,414	-0,582	0,516
	Log (Beneficiários %)	0,120	0,177	0,674	-0,119	0,578
	(Intercepto)	4,206	0,743	5,661	3,094	6,047
OLS	Log (densidade)	-0,094	0,060	-1,574	-0,242	0,001
	Log (idosos %)	-0,276	0,215	-1,286	-0,697	0,143
	Log (PIB per capita)	-0,233	0,174	-1,339	-0,632	0,059
	Log (Beneficiários %)	0,271	0,126	2,148	0,046	0,546
	(Intercepto)	5,604	0,479	11,687	4,744	6,645

Fonte: elaboração própria

* Limit: lower = 0; pper = +inf; Replications = 10.000; Number of obs = 117

Determinantes da mudança tecnológica

Na tabela 11 abaixo, vemos que a densidade demográfica está negativamente correlacionada com a variação da tecnologia. Esse resultado poderia parecer surpreendente, em princípio, em virtude de avanços tecnológicos de produtos, em saúde, estarem associados aos grandes centros urbanos, onde a densidade demográfica é maior do que em áreas rurais ou pouco populosas. Entretanto, já comentamos que políticas estruturantes do SUS, entre elas, a ESF, que é uma inovação de processo produtivo, é muito intensiva em mão de obra de baixa ou média escolaridade, como no caso dos ACS. Essas inovações no processo de produção de saúde no SUS foram muito mais intensivamente implementadas em áreas rurais do que nos grandes centros urbanos. A porcentagem de idosos na população também está negativamente associada com a variação da tecnologia nas macrorregiões de saúde. Aqui, podemos conjecturar que, talvez, ocorra um efeito relacionado com a atividade econômica: muitos idosos significam baixa dinâmica econômica, concomitantemente com a adoção de processos sanitários paliativos, que demandam poucas inovações no campo da saúde pública. O PIB per capita também está negativamente associado com a variação tecnológica nos modelos de regressão, o que não faz muito sentido e demandaria esforços adicionais de pesquisa para além das limitações deste livro. Existe, na amostra, uma associação positiva entre a mudança tecnológica e a porcentagem de usuários de planos de saúde na população. Essa relação demanda maiores investigações, mas, em princípio, pode estar associada ao dinamismo do mercado de trabalho, pois os planos de saúde, no Brasil, são bastante associados ao mercado de trabalho formal (os ditos planos de saúde empresariais) e às populações mais jovens. Esses dois fatores, entre outros, induziriam a adoção de novas tecnologias no SUS.

Tabela 11. Estimativas dos parâmetros das variáveis ambientais, erros-padrão, estatísticas T e intervalos de confiança da regressão truncada e OLS sobre os escores de mudança tecnológica *bootstrap*, 2008-2017

	Log TC	Coef.	Erro-Padrão	T	[95% Int. conf.]	
					<i>Bootstrap</i>	
Regressão truncada*	Log (densidade)	-0,034	0,056	-0,617	-0,112	0,104
	Log (idosos %)	-0,367	0,182	-2,024	-0,766	-0,073
	Log (PIB per capita)	-0,128	0,147	-0,869	-0,388	0,164
	Log (Beneficiários %)	0,142	0,125	1,138	-0,118	0,347
	(Intercepto)	5,578	0,422	13,221	4,803	6,425

	Log TC	Coef.	Erro-Padrão	T	[95% Int. conf.]	
					Bootstrap	
OLS	Log (densidade)	-0,018	0,026	-0,710	-0,067	0,033
	Log (idosos %)	-0,455	0,147	-3,091	-0,784	-0,191
	Log (PIB per capita)	-0,168	0,098	-1,710	-0,351	0,031
	Log (Beneficiários %)	0,184	0,076	2,418	0,036	0,334
	(Intercepto)	5,677	0,340	16,714	5,096	6,469

Fonte: elaboração própria

Em resumo, as análises anteriores mostram que a variação da produtividade, da eficiência e da tecnologia do SUS não estão dissociadas de variáveis socioeconômicas importantes, que não são controladas pelos gestores do sistema. Esse é um aspecto muito relevante, pois nos remete para as discussões sobre os determinantes socioeconômicos da saúde em uma sociedade com elevados índices de desigualdades sociais, econômicas e sanitárias. O bom funcionamento do SUS é condição absolutamente necessária para proteção, preservação e recuperação da saúde da população brasileira, mas não seria uma condição suficiente.

Análise do IM por regiões geográficas

É importante observar agora, na tabela 12 e no gráfico 6, os resultados dos modelos de variação de produtividade, eficiência e tecnologia a partir de um recorte regional. Esses resultados têm limitações, pois são obtidos a partir da agregação dos resultados individualizados das macrorregiões. A alternativa de agregar os indicadores individuais e fazer a análise regional *a posteriori* também seria limitada, pois algumas variáveis usadas nos modelos das macrorregiões não estão disponíveis no nível regional de agregação. Então, como não foi possível construir intervalos de confiança regionais, as análises do desempenho da variação da produtividade e de seus dois componentes (a mudança de eficiência e a mudança tecnológica) abrange a totalidade da amostra, e não apenas os casos em que o intervalo de confiança está totalmente à esquerda da unidade (indicando retrocesso) ou totalmente à direita da unidade (indicando melhoria). Ainda assim, a análise se beneficia da correção feita pelo *bootstrap*, sendo livre do viés dos modelos de DEA não corrigidos. Podem existir diferenças substanciais entre modelos corrigidos pelo *bootstrap* e modelos sem essa correção, como exposto em Simar e Wilson³⁴ e exemplificado em Marinho e Araújo⁹ que apresentam resultados de diversos modelos aplicados aos transplantes de órgãos no Brasil.


As regiões Centro-Oeste (IM=2,003) e Sudeste (IM=1,417), nessa ordem, têm o melhor desempenho em termos relativos. A região Sul, que é uma das mais desenvolvidas do país, não apresenta bom desempenho, sendo a única com IM menor do que a unidade (IM=0,891), o que significaria retrocesso tecnológico, enquanto as demais regiões têm indicadores maiores do que a unidade. No que se refere à mudança de eficiência, novamente, apenas a região Sul teve retrocesso, embora pequeno (EC=0,944). Teria ocorrido progresso tecnológico nas regiões Centro-Oeste (TC=1,214), Sudeste (TC=1,064) e Norte (TC=1,129), e retrocesso nas regiões Nordeste (TC=0,982) e Sul (TC=0,931), por razões que desconhecemos no momento. A dispersão, medida pelo coeficiente de variação, sempre na casa de dois dígitos, é relativamente elevada na amostra. Então, há muita desigualdade nas produtividades estimadas para as macrorregiões do SUS tanto entre as macrorregiões de saúde quanto entre as regiões geográficas. A região Sul apareceria como aquela de pior desempenho, mas, reiteramos, não é possível fazer afirmativas muito categóricas devido à ausência de intervalos de confiança regionais para as variações de produtividade, de eficiência e de tecnologia. Por último, nesse aspecto, vemos que o desempenho da região Sul pode ser atribuído, de modo bastante equitativo, aos desempenhos na variação da eficiência técnica (EC=0,944) e a variação tecnológica (TC=0,931). Nas demais regiões, o desempenho é majoritariamente determinado pela variação da eficiência técnica (EC=1,351), com a variação tecnológica ficando em segundo plano (TC=1,048). Na análise regional, não seria possível fazer modelos de regressão, dado o pequeno tamanho da amostra, que conta com apenas cinco regiões.

Tabela 12. Estatísticas dos índices de Malmquist e de seus componentes, segundo as regiões do Brasil nos anos 2008-2017

Regiões	Índice de Malmquist			Mudança de eficiência			Mudança tecnológica		
	Média	Desvio-Padrão	CV%	Média	Desvio-Padrão	CV%	Média	Desvio-Padrão	CV%
Centro-Oeste	2,003	1,487	74,234	1,693	1,117	65,981	1,214	0,638	52,570
Sudeste	1,417	1,191	84,105	1,261	0,746	59,184	1,064	0,301	28,319
Norte	1,367	0,605	44,272	1,187	0,355	29,885	1,129	0,327	28,991
Nordeste	1,225	0,921	75,206	1,223	0,982	80,287	0,982	0,350	35,654
Sul	0,891	0,457	51,235	0,944	0,427	45,268	0,931	0,127	13,606
Total Geral	1,351	1,052	77,873	1,248	0,819	65,636	1,048	0,365	34,861

Fonte: elaboração própria.

Gráfico 6. Médias dos Índices de Malmquist e de seus componentes, segundo as regiões do Brasil – 2008-2017



Considerações finais

Aparentemente, houve ganhos medianos de produtividade e de eficiência nas macrorregiões do SUS estudadas neste livro. O desempenho dessas macrorregiões de saúde foi, pelo que avaliamos, obstada, em parte, pelo fraco desenvolvimento tecnológico detectado no IM. Com cautelas, esse fenômeno nos permitiria afirmar que nossos modelos de análise não foram capazes de identificar efeitos positivos de investimentos significativos no parque tecnológico do SUS nos anos analisados (2008-2017). Resultado semelhante já havia sido indicado em estudo sobre as capitais brasileiras, cobrindo os anos de 2008 a 2013²¹. A manutenção dessa situação – que corrobora a existência de uma situação de estagnação ou sucateamento provavelmente vinculada ao subfinanciamento crônico –, certamente fragiliza as perspectivas de aumento da produtividade e eficiência nas macrorregiões.

A despeito de constatararmos enormes disparidades entre as macrorregiões, o contraste entre seus respectivos desempenhos diminuiu entre 2008 e 2017 (gráfico 2). De modo positivo, essa convergência vai ao encontro de redução de desigualdades de acesso, pois os valores mínimos de eficiência se elevaram consistentemente. Assim, a produtividade e a eficiência, que refletem a capacidade de transformar recursos em resultados adequados com as melhores práticas disponíveis, vinham se tornando mais uniformes no país, com redução das disparidades entre as regiões do Brasil. Entretanto, a limitação da capacidade de obtenção de resultados em saúde para a população brasileira está

mais restrita pela escassez de recursos do que pelas possibilidades de transformação. Essa constatação reforça o acerto da luta pela busca de maior alocação de recursos no sistema, pois a hipótese da perenidade de grandes desperdícios em razão de elevadas ineficiências resta, aparentemente, afastada.

Os modestos ganhos de eficiência, com poucas mudanças na produtividade, reforçam a relativa desvinculação entre a produção de mais procedimentos e melhores resultados. Tendo isso em mente, há um desempenho insatisfatório a partir do eixo ‘mudança tecnológica’. Considerando que o período foi pródigo na introdução de novos modelos de gestão⁶¹ e que a mudança tecnológica inclui tecnologias de gestão, os resultados lançam dúvidas sobre os impactos positivos da introdução disseminada desses novos modelos. Ainda assim, tais modelos tendem a ser iniciativas com alto grau de fragmentação do ponto de vista macrorregional, o que difere de uma atuação política e gerencial mais integrada esperada para uma macrorregião. Como reconhecemos que a qualidade da administração dos serviços de saúde é uma variável relevante, que pode impactar positivamente seu desempenho⁷, é possível que a consolidação das macrorregiões enquanto unidades de gestão possa contribuir para melhorar sua eficiência.

Cabe destacar que o período analisado coincidiu com a vigência de regras de vinculação de recursos que ainda forneciam garantias de manutenção de níveis mínimos de financiamento ao SUS. É possível que as regras do novo regime fiscal trazidas pelas Emenda Constitucional (EC) nº 95⁶² revertam a tendência de desaparecimento de níveis de muito baixos de eficiência nas macrorregiões, mais ainda em um cenário de estagnação tecnológica que até agora vinha sendo de alguma forma contraposta por esforços macrorregionais.

A inclusão de variáveis fora do controle dos gestores do SUS, tais como a porcentagem de idosos na população, o PIB per capita, a densidade demográfica e a cobertura de planos de saúde, possibilitou demonstrar, empiricamente, que a produtividade e a eficiência do SUS dependem das condições socioeconômicas da população. Essa é uma hipótese muito aventada na literatura, mas, de forma original, neste livro, foi feito um esforço teórico e empírico sistemático para deslindar e para demonstrar essa proposição. Cabe repetir o que já afirmamos: o SUS é condição ‘necessária’, mas não suficiente para que população brasileira desfrute das melhores condições de saúde possíveis, dados os recursos que o Estado se dispõe a investir no setor.

Além de correções e imputações que fizemos, é imprescindível que se adotem métodos de avaliação que acomodem eventuais erros de medidas e evitem que eles sejam

lançados na conta do desempenho efetivo (contra ou a favor) das unidades de análise (as –DMU). Os modelos corrigidos pelo *bootstrap*^{34,51,59} adotados aqui permitem mitigar esse problema. De fato, os estimadores da DEA tradicionais, gerados no modelo CCR^{1,64}, são ‘estimativas’ sujeitas a problemas de caráter estatístico, dado que a produtividade e a fronteira real de eficiência não são observáveis.

Tratar a DEA como um método determinístico é um erro elementar. Fazer inferências e projeções com esse pressuposto, e não admitir as possibilidades de existência de erros de medidas, é um problema adicional. Fazer diagnósticos categóricos e recomendações de políticas de saúde baseadas em tais erros não seria recomendável em termos científicos.

Outra novidade deste capítulo foi ter considerado a contribuição de recursos executados tanto por estados como por municípios nas macrorregiões de saúde. Essa contribuição tripartite para o financiamento é desconsiderada ou mal-informada em estudos sobre a eficiência do SUS. Frequentemente, as investigações utilizam apenas a execução de recursos municipais quando analisam municípios ou capitais, desconsiderando os recursos estaduais ali alocados. Pior, muitos estudos não nos permitem avaliar criteriosamente a origem dos dados. Diante da sensibilidade das análises de eficiência à qualidade dos dados, isso pode gerar distorções consideráveis não reconhecidas nos resultados^{8,21,63}. Os dados do SUS, principalmente, aqueles referentes às suas despesas, são muito sujeitos a erros de medidas e de lançamentos, omissões e outras imperfeições. Transferências entre a União, estados, Distrito Federal, e municípios são particularmente problemáticas, conforme demonstrado neste livro e detalhado no Apêndice Metodológico.

Referências

1. Charnes, Cooper e Rhodes, 1978. Measuring the Efficiency of Decision-Making Units European Journal of Operational Research 1978; 2(6):429-444
2. Marinho A. Estudo de eficiência em hospitais públicos e privados com a geração de rankings. Rev Adm Publica. 1998;32(6):145-58.
3. Marinho A, Façanha LO. Hospitais universitários: Mecanismos de coordenação e avaliação comparativa de eficiência técnica. Ensaio. 1998;6(19):201-35.
4. La Forgia GM, Couttolenc BF. Desempenho hospitalar no Brasil: em busca da excelência. São Paulo: Singular; 2009.

5. Araujo CAS, Barros CP, Wanke P. Efficiency determinants and capacity issues in Brazilian for-profit hospitals. *Health Care Manag Sci.* 2014;17(2):126-38.
6. Botega LA, Andrade MV, Guedes GR. Brazilian hospitals' performance: an assessment of the unified health system (SUS). *Health Care Manag Sci.* 2020;23(3):443-52.
7. Hone T, Rasella D, Barreto ML, Atun R, Majeed A, Millett C. Large reductions in amenable mortality associated with Brazil's primary care expansion and strong health governance. *Health Aff.* 2017;36(1):149-58.
8. Banco Mundial. Saúde: Alternativas para Oferecer Mais e Melhores Serviços. In: Um ajuste justo – Análise da eficiência e equidade do gasto público no Brasil. Brasília: Grupo Banco Mundial; 2017 a. p. 109-18.
9. Marinho A, Araújo CAS. Using data envelopment analysis and the bootstrap method to evaluate organ transplantation efficiency in Brazil. *Health Care Manag Sci.* 2021;(24):569-81.
10. World Health Organization. World Health Report 2000—Health Systems: Improving Performance. Geneva: WHO; 2000.
11. Berenguer G, Iyer AV, Yadava P. Disentangling the efficiency drivers in country-level global health programs: An empirical study. *J Oper Manag.* 2016;45(1):30-43
12. Evans DB, Tandon A, Murray CJL, Lauer JA. The comparative efficiency of national health systems in producing health: An analysis of 191 countries. *BMJ.* 2001;323(7308):307-10.
13. Marinho, A, Cardoso, SS, Almeida VV. Brasil e OCDE: avaliação da eficiência em sistemas de saúde. Texto para Discussão, 2009.
14. Marinho A, Cardoso SS, Almeida VV. Avaliação comparativa dos sistemas de saúde do Brasil e de países da América Latina, do Caribe, e da OECD, com o uso de fronteiras estocásticas. *Econ Aplic.* 2020;24(2):195-214.
15. Silva BN, Costa NAS, Abbas K, Galdamez EVC. Eficiência, hospitalar das regiões brasileiras: um estudo por meio da análise envoltória de dados. *Rev Gest Sist Saúde.* 2017;6(1):76-91.
16. Banco Mundial. Um Ajuste Justo – Análise da Eficiência e Equidade do Gasto Público no Brasil [Internet]. Brasília: Grupo Banco Mundial; 2017 b [citado 2021 mar 13]. Disponível em: <https://bit.ly/2SUTtfF>

17. Flamini VS, Mauricio. Doing More with Less: How Can Brazil Foster Development while Pursuing Fiscal Consolidation? IMF Working Paper. 2019;19(326).
18. Santos IS, Santos MAB, Borges DCL. Mix público-privado no sistema de saúde brasileiro: realidade e futuro do SUS. In: Fundação Oswaldo Cruz. A saúde no Brasil em 2030 – prospecção estratégica do sistema de saúde brasileiro: estrutura do financiamento e do gasto setorial. Rio de Janeiro: Fiocruz/Ipea/Ministério da Saúde; 2013. v. 4. p. 73-131.
19. Tenbensen T. Complexity in health and health care systems. Soc Sci Med. 2013;93:181-4.
20. Pinheiro R. Integralidade em saúde. Ciênc Saúde Coletiva. 2007;12(3):553-65.
21. Castro Lobo MS, Araujo EC. Efficiency Analysis of Public Health Spending in Brazilian Capitals Using Network Data Envelopment Analysis (DEA). Cent Eur Review Econom Manag. 2017;1(4):147-74.
22. Conselho Nacional de Secretários de Saúde. Assistência de média e alta complexidade no SUS. Brasília: CONASS; 2007. Coleção Para Entender a Gestão do SUS, v. 4.
23. Spedo SM, Pinto NRS, Tanaka OY. O difícil acesso a serviços de média complexidade no SUS. Physis. 2010;20(3):953-72.
24. Kuschnir R, Chorny AH. Redes de atenção à saúde: contextualizando o debate. Ciênc Saúde Coletiva. 2010;15(5):2307-16.
25. Brasil. Ministério da Saúde. Gabinete do Ministro. Portaria nº 399, de 22 de fevereiro de 2006. Divulga o Pacto pela Saúde 2006 – Consolidação do SUS e aprova as diretrizes do referido Pacto. Diário Oficial da União. 2006 fev 23;143(39 seção 1):43-51.
26. Magalhães Junior HM. Redes de Atenção à Saúde: rumo à integralidade. Divulg Saúde Debate. 2014;(52):15-37.
27. Homa L, Rose J, Hovmand PS, Cherg ST, Riolo RL, Kraus A, et al. A participatory model of the paradox of primary care. Ann Fam Med. 2015;13(5):456-65.
28. Eurostat. Directorate F: Social statistics. Avoidable mortality: OECD/Eurostat lists of preventable and treatable causes of death. Luxembourg: Eurostat; 2019.
29. Lavergne MR, McGrrail K. What, if anything, does amenable mortality tell us about regional health system performance? Healthc Policy. 2013;8(3):79-90.

30. Allin S, Grignon M. Examining the role of amenable mortality as an indicator of health system effectiveness. *Health Policy*. 2014;9(3):12-9.
31. França EB, Passos VMA, Malta DC, Duncan BB, Ribeiro ALP, Guimarães MDC, et al. Cause-specific mortality for 249 causes in Brazil and states during 1990–2015: a systematic analysis for the global burden of disease study 2015. *Popul Health Metr*. 2017;15(1):39.
32. Lima EEC, Queiroz BL. Evolution of the deaths registry system in Brazil: associations with changes in the mortality profile, under-registration of death counts, and ill-defined causes of death. *Cad Saúde Pública*. 2014;30(8):1721-30.
33. Rocha TAH., Silva NC, Barbosa ACQ, Amaral PV, Thumé E, Rocha JV, et al. Cadastro Nacional de Estabelecimentos de Saúde: evidências sobre a confiabilidade dos dados. *Ciênc Saúde Coletiva*. 2018;23(1):229-40.
34. Simar L, Wilson PW. Sensitivity analysis of efficiency scores: How to bootstrap in non-parametric frontier models. *Manag Sci*. 1998;44(1):49-61.
35. Brasil. Ministério da Saúde. Gabinete do Ministro. Resolução nº 37, de 22 de março de 2018. *Diário Oficial da União*. 2018 mar 26;155(58 seção 1):135.
36. Garrison JR LP, Neumann PJ, Willke RJ, Basu A, Danzon PM, Doshi JA, et al. A health economics approach to US value assessment frameworks—summary and recommendations of the ISPOR Special Task Force Report [7]. *Value Health*. 2018;21(2):161-65.
37. Bennett C, Manuel DG. Reporting guidelines for modelling studies. *BMC Med Res Methodol*. 2012;12:168. doi:10.1186/1471-2288-12-168
38. Heijink R, Koolman X, Westert GP. Spending more money, saving more lives? The relationship between avoidable mortality and healthcare spending in 14 countries. *Eur J Health Econ*. 2013;14(3):527-38.
39. Aigner D, Lovell CAK, Schmidt PS. Formulation and estimation of stochastic frontier models. *J Econom*. 1977;6(1):21-37.
40. Battese GE, Corra GS. Estimation of a production frontier model: With application to the Pastoral Zone of Eastern Australia. *Aust J Agric Econ*. 1977;21:169-79.
41. Meeusen W, Van Den Broeck J. Efficiency estimation from Cobb-Douglas production functions with composed error. *Int Econ Rev*. 1977;18:435-44.

42. Saltelli A, Bammer G, Bruno I, Charters E, Di Fiore M, Didier E, et al. Five ways to ensure that models serve society: a manifesto. *Nature*. 2020;582(7813):482-4.
43. Rocha F, Duarte J, Oliveira PP, Pereira LFDV, Gadelha SRB. Are more resources always the answer? A supply and demand analysis for public health services in Brazilian municipalities. *Economia*. 2017;18(1):98-116.
44. Marinho A. Avaliação da eficiência técnica nos serviços de saúde nos municípios do Rio de Janeiro. *Revista Brasileira de Economia*. 2003; v. 57, n. 3, p. 515-534, jul./set.
45. Matos PRF. Alternative funding sources' impact on efficiency and productivity of subnational entities in Brazil after the Fiscal Responsibility Law. *Rev Adm Pública*. 2017;51(4):482-508.
46. Marinho A, Resende M. Service quality in electricity distribution in Brazil a Malmquist approach. *Ann Public Coop Econ*. 2019;90:687-712.
47. Simar L, Wilson PW. Statistical approaches for nonparametric frontier models: a guided tour. *Int Stat Rev*. 2015;83(1):77-110.
48. Banker R.; Morey, R. C. Efficiency analysis for exogenously fixed inputs and outputs. *Operations Research*. 1986; v. 34, n. 4, p. 513-521, July/Aug.
49. Marinho A, Cardoso SS, Almeida VV. Avaliação comparativa de sistemas de saúde com a utilização de fronteiras estocásticas: Brasil e OCDE. *Rev Bras Econ*. 2012;66(1):3-19.
50. Marinho A, Cardoso SS, Almeida VV. Avaliação de eficiência em sistemas de saúde: Brasil, América Latina, Caribe e OCDE. Rio de Janeiro: IPEA; 2012. Texto para Discussão 1784.
51. Simar L, Wilson PW. Estimation and inference in two-stage, semiparametric models of production processes. *J Econom*. 2007;136(1):31-64.
52. Banker RD, Natarajan R, Zhang D. Two-stage estimation of the impact of contextual variables in stochastic frontier production function models using Data Envelopment Analysis: Second stage OLS versus bootstrap approaches. *Eur J Oper Res*. 2019;278(2):368-84.
53. Dever GEA. A epidemiologia na administração dos serviços de saúde. São Paulo: Pioneira; 1998.

54. Rouquayrol MZ, Almeida Filho N. *Epidemiologia e saúde*. 5. ed. Rio de Janeiro: Editora Médica e Científica Ltda; 2001.
55. Wilson PW. Detecting outliers in deterministic nonparametric frontier models with multiple results. *J Bus Econ Stat*. 1993;11(3):319-23.
56. Cetin VR, Bahce S. Measuring the efficiency of health systems of OECD countries by data envelopment analysis. *Appl Econ*. 2016;48(37):3497-507.
57. Moreno-Enguix MDR, Gómez-Gallego JC, Gómez Gallego M. Analysis and determination the efficiency of the European health systems. *Int J Health Plann Manag*. 2018;33(1):136-54.
58. Wilson PW. (2008). Fear 1.0: A Software Package for Frontier Efficiency Analysis with R. *Socio-Econ Plan Sci*. 2008;42:247-54.
59. Simar L, Wilson PW. Estimating and bootstrapping Malmquist indices. *Eur J Oper Res*. 1999;115(3):459-471.
60. SIMAR, L. WILSON, P. Two-stage DEA: caveat emptor. *Journal of Productivity Analysis*. 2011; 36: 205-218.
61. Santos MAB, Servo LMS. A provisão dos serviços e ações do SUS: participação de agentes públicos e privados e formas de produção/remuneração dos serviços. In: Marques RM, Piola SF, Roa AC, organizadores. *Sistema de Saúde no Brasil: organização e financiamento*. Rio de Janeiro: ABrES; Brasília, DF: Ministério da Saúde, OPAS; 2016. p. 205-46.
62. Vieira FS, Benevides RPS. Os impactos do Novo Regime Fiscal para o financiamento do Sistema Único de Saúde e para a efetivação do direito à saúde no Brasil. Brasília: Ipea; 2016. (Nota Técnica, n. 28).
63. Rocha F, Duarte J, Gadelha SRB, de Oliveira PP, Pereira LFN. Mais recursos ou mais eficiência? Uma análise de oferta e de demanda por serviços de saúde no Brasil. Brasília: STN, 2012. Texto para Discussão do Tesouro Nacional, n. 10. 2012
64. Banker RD, Charnes A, Cooper WW. Some models for estimating technical and scale inefficiencies in data envelopment analysis. *Manag Sci*. 1984;30(9):1078-92.

Tratamento dos dados usados para informar as variáveis de input para o financiamento das Ações e Serviços Públicos em Saúde (ASPS) de estados e municípios

Introdução

As variáveis de *input* (insumos) usadas em nosso estudos para tratar do financiamento do SUS por subfunção contemplam estimativas das despesas per capita nas subfunções Atenção Básica (301), Vigilância Sanitária (304), Vigilância Epidemiológica (305) e Alimentação e Nutrição (306), bem como estimativas de despesas per capita para as subfunções Assistência Hospitalar e Ambulatorial (302) e Suporte Profilático Terapêutico (303), cada uma delas denotando, respectivamente, agregações representativas de Despesas da Atenção Básica e Vigilância em Saúde (variável “DABV”) e de Despesas com Atenção de Média e Alta Complexidade (variável “DMAC”).

Essas despesas representam os recursos financeiros oriundos das três esferas de governo (recursos próprios de estados, recursos próprios de municípios e recursos transferidos fundo a fundo da União para estados e municípios) executados pelos governos estaduais e municipais em cada uma das 117 macrorregiões de saúde que integram o estudo. Não foram contabilizados os recursos federais da modalidade

aplicação direta em função da dificuldade em definir o local para onde foram direcionados. Esses recursos totalizam anualmente cerca de um terço do total dos recursos federais alocados no SUS e 15% dos recursos totais aplicados no SUS¹.

Os dados são informados por estados e municípios no SIOPS, obtidos como microdados diretamente do gestor do sistema, o Departamento de Economia da Saúde, Investimentos e Desenvolvimento do Ministério da Saúde (DESID/MS). Para os anos estudados, cada ente federativo (estados e municípios) informa a totalidade dos recursos executados em seu âmbito, independentemente de sua origem ser de recursos próprios ou transferências entre entes federados. A informação utilizada corresponde às despesas liquidadas segundo a classificação funcional (subfunção).

A classificação funcional agrupa despesas com mesma finalidade. O primeiro nível de consolidação da informação da despesa com saúde por subfunção do SIOPS divide as despesas entre subfunções vinculadas à saúde e não vinculadas à saúde (administrativas e complementares), aplicável a todos os níveis de governo. O segundo nível de consolidação detalha as despesas de cada um desses grupos segundo um maior detalhamento das subfunções. Entretanto, diversos fatores podem prejudicar a qualidade dos registros em um sistema autodeclaratório, inclusive a clareza sobre os critérios de classificação das despesas.

Implicações de uso dos dados brutos do SIOPS

É importante ressaltar que o uso de dados brutos do SIOPS pode levar a análises e propostas equivocadas de políticas públicas quando se utiliza modelos para avaliar eficiência e os dados não são ajustados. Em 2017, o Banco Mundial publicou um relatório² no qual se propôs a analisar “a eficiência e equidade do gasto público no Brasil”, dedicando 11 páginas à saúde, com 16 recomendações, sendo a maior parte delas baseadas em estudo de DEA. Tal modelo utiliza como *input* as despesas municipais com saúde, mas o relatório não cita a fonte, informando que os dados provêm de “Cálculos da equipe do Banco Mundial”. A apresentação em Power-Point^{XII} referente ao estudo informa que o “Modelo DEA Atenção Primária, VRS-O (ND, SBM)” tem como insumo a variável “Gasto público Total na Atenção primária (subfunção 301)”, indicando como fonte de dados o SIOPS; já o “Modelo DEA Média e Alta Complexidade, VRS-O (ND, SBM)” tem como insumo a variável “Gasto total atenção secundária e terciária (subfunção 302)”, indicando também como fonte de dados o SIOPS.

XII Disponível em <https://bit.ly/3bh4FMv>.

As diferentes formas de classificação das despesas por subfunção por parte dos municípios tornam os dados brutos informados não comparáveis *a priori*. O principal problema reside na classificação da despesa com pessoal, que representa grande parte das despesas dos municípios, e é registrada em muitos casos em subfunções administrativas, ao invés da subfunção referente ao nível de atenção à saúde em questão. Ao utilizar apenas as informações das subfunções 301 – Atenção Básica – e 302 – Assistência Hospitalar e Ambulatorial –, o modelo ignora as despesas desses níveis de atenção classificadas em subfunções administrativas. Como resultado, o modelo DEA para a atenção básica, por exemplo, *ceteris paribus*, tende a considerar mais eficiente o município que classificar as despesas com pessoal da atenção básica, em subfunção administrativa, e que, portanto, informar ao SIOPS uma despesa (*input*) menor na subfunção 301 – Atenção Básica –, e esse município “mais eficiente” servirá como parâmetro de eficiência para os outros municípios (DMU) do modelo. O grau de eficiência das DMU do modelo dependeria do critério utilizado pela contabilidade do município na classificação da despesa com pessoal.

Para ilustrar essa distorção, a tabela 1 apresenta as informações do ano de 2017 declaradas por dois municípios de porte populacional e níveis de receitas e despesas comparáveis. O município de Joinville-SC declara ter R\$ 449,1 milhões de despesas na subfunção 122 – Administração Geral (67% da despesa total) –, e apenas R\$ 18,8 milhões na subfunção 301 – Atenção Básica (3% do total), valor inferior ao repassado no ano pelo FNS, de R\$ 31,9 milhões. Já o município de Londrina registrou R\$ 133,4 milhões de despesa na subfunção 301 – Atenção Básica (23% do total), uma vez que a despesa com pessoal que trabalha na assistência à saúde é corretamente classificada na respectiva subfunção, conforme o nível de atenção.

Tabela 1. Comparações entre as despesas com ASPS por subfunção de Londrina-PR e Joinville-SC, 2017

Subfunção	Despesa em R\$ milhões	% do total	Despesa por Habitante	Despesa em R\$ milhões	% do total	Despesa por Habitante
Município	Londrina-PR			Joinville-SC		
População	558.439			577.077		
Despesa Total em ASPS	580,19	100%	1.039	672,68	100%	1.166
Subfunções da Saúde	554,01	95%	992	203,26	30%	352
301 - Atenção Básica	133,42	23%	239	18,79	3%	33
302 - Assist. Hospitalar e Ambulat.	401,46	69%	719	173,62	26%	301

Subfunção	Despesa em R\$ milhões	% do total	Despesa por Habitante	Despesa em R\$ milhões	% do total	Despesa por Habitante
Município			Londrina-PR			Joinville-SC
303 - Suporte Profilático e Terap.	0,00	0%	0	8,15	1%	14
304 - Vigilância Sanitária	6,76	1%	12	2,67	0%	5
305 - Vigilância Epidemiológica	12,37	2%	22	0,03	0%	0
306 - Alimentação e Nutrição	0,00	0%	0	0,00	0%	0
Subfunções administrativas	23,76	4%	43	449,08	67%	778
121 - Planejamento e Orçamento	0,00	0%	0	0,00	0%	0
122 - Administração Geral	23,76	4%	43	448,73	67%	778
123 - Administração Financeira	0,00	0%	0	0,00	0%	0
124 - Controle Interno	0,00	0%	0	0,00	0%	0
126 - Tecnologia da Informação	0,00	0%	0	0,01	0%	0
128 - Formação de Rec. Humanos	0,00	0%	0	0,04	0%	0
131 - Comunicação Social	0,00	0%	0	0,30	0%	1
Subfunções complementares	2,41	0%	4	20,34	3%	35

Fonte: SIOPS/MS. Dados disponíveis em <https://bit.ly/3q6S3dT>, acesso em 07/05/2020.

No exemplo da tabela 1, demonstra-se que, ao se utilizar no modelo apenas as despesas informadas nas subfunções 301 e 302, considerar-se-ia mais eficiente, *ceteris paribus*, o município de Joinville-SC, por informar as despesas com pessoal em subfunção administrativa, desconsiderada no modelo. É possível que um município seja considerado mais eficiente, portanto, por uma decisão contábil.

As tabelas 2 e 3 apresentam os efeitos dessas mesmas decisões de classificação para o conjunto de municípios e dos estados em 2017. O resultado agregado dos municípios é de 18,4% da despesa ASPS informada em subfunções administrativas e complementares em 2017 (tabela 2), enquanto para os estados esse percentual é de 28,2% (tabela 3). As tabelas apresentam também o número de Unidades Federadas (UF) que preencheram valor diferente de zero em cada uma das subfunções, conforme constam do SIOPS.

Tabela 2. Despesa ASPS, declarada pelos governos municipais, segundo a subfunção – 2017^{XIII}

Subfunção	Despesas com ASPS R\$ bilhões	Despesas com ASPS em % total	Nº de municípios que informou na subfunção	% dos municípios que informou na subfunção
Despesa Total (1+2+3)	142,71	100,0%	5.568	100,0%
2 - Subfunções da Saúde	116,47	81,6%	5.504	98,9%
301 - Atenção Básica	52,11	36,5%	5.440	97,7%
302 - Assistência Hospitalar e Ambulatorial	57,96	40,6%	4.513	81,1%
303 - Suporte Profilático e Terapêutico	2,76	1,9%	2.482	44,6%
304 - Vigilância Sanitária	2,29	1,6%	3.925	70,5%
305 - Vigilância Epidemiológica	1,29	0,9%	3.950	70,9%
306 - Alimentação e Nutrição	0,07	0,0%	308	5,5%
Subfunções Administr. e Complem. (1+3)	26,24	18,4%	3.321	59,6%
1 - Subfunções Administrativas	23,85	16,7%	2.961	53,2%
121 - Planejamento e Orçamento	0,31	0,2%	51	0,9%
122 - Administração Geral	22,96	16,1%	2.868	51,5%
123 - Administração Financeira	0,04	0,0%	40	0,7%
124 - Controle Interno	0,00	0,0%	21	0,4%
126 - Tecnologia da Informação	0,20	0,1%	45	0,8%
128 - Formação de Recursos Humanos	0,14	0,1%	138	2,5%
131 - Comunicação Social	0,20	0,1%	48	0,9%
3 - Informações Complementares	2,39	1,7%	1.102	19,8%
271 - Previdência Básica	0,43	0,3%	139	2,5%
272 - Previdência do Regime Estatutário	0,42	0,3%	310	5,6%
273 - Previdência Complementar	0,00	0,0%	2	0,0%
571 - Desenvolvimento Científico	0,03	0,0%	1	0,0%

XIII Até o ano de 2017, os dados municipais estão disponíveis em <http://siops.datasus.gov.br/consvaloresmunicipio.php>, e os estaduais, em <http://siops.datasus.gov.br/consvaloresuf.php>. A partir do ano base 2018, as bases dos dados estaduais e municipais estão disponíveis em <http://siops.datasus.gov.br/valoresinformados.php>, acesso em 07/05/2020.

Subfunção	Despesas com ASPS R\$ bilhões	Despesas com ASPS em % total	Nº de municípios que informou na subfunção	% dos municípios que informou na subfunção
572 - Desenvolv. Tecnológico e Engenharia	0,00	0,0%	1	0,0%
573 - Difusão do Conhec. Científ e Tecnológ.	0,00	0,0%	1	0,0%
841 - Refinanciamento da Dívida Interna	0,00	0,0%	2	0,0%
842 - Refinanciamento da Dívida Externa	0,00	0,0%		0,0%
843 - Serviço da Dívida Interna	0,01	0,0%	37	0,7%
844 - Serviço da Dívida Externa	0,00	0,0%	3	0,1%
xxx - Outras	1,50	1,1%	739	13,3%

Fonte: SIOPS/MS. Dados disponíveis em <https://bit.ly/3q6S3dT>, acesso em 07/05/2020.

As subfunções administrativas desdobram-se em várias subfunções, entre elas, a de número 122 (Administração Geral), usada pelos entes da federação para classificar a maior parte das despesas administrativas; as quais deveriam captar exclusivamente gastos com a administração dos serviços de saúde, inclusive pessoal envolvido nessa tarefa. Em 2017, 23,6% e 16,1% das despesas de estados e municípios com saúde, respectivamente, foram informadas como despesas administrativas na Subfunção 122. Em países da OCDE, despesas administrativas em sistemas públicos variam de 1% a 5% do total dos gastos; e em sistemas fortemente privados, chegam a 7% do total^{3,4}, o que aponta para uma expressiva distorção nos dados brasileiros.

Tabela 3. Despesa ASPS, declarada por governos estaduais, segundo a subfunção – 2017

Subfunção	Despesas com ASPS R\$ bilhões	Despesas com ASPS em % total	Nº de estados que informaram na subfunção	% dos estados que informaram na subfunção
Despesa Total (1+2+3)	87,41	100,0%	27	100,0%
2 - Subfunções da Saúde	62,79	71,8%	27	100,0%
301 - Atenção Básica	2,30	2,6%	25	92,6%
302 - Assistência Hospitalar e Ambulatorial	54,94	62,9%	27	100,0%
303 - Suporte Profilático e Terapêutico	4,43	5,1%	25	92,6%
304 - Vigilância Sanitária	0,13	0,1%	25	92,6%

Subfunção	Despesas com ASPS R\$ bilhões	Despesas com ASPS em % total	Nº de estados que informaram na subfunção	% dos estados que informaram na subfunção
305 - Vigilância Epidemiológica	0,64	0,7%	26	96,3%
306 - Alimentação e Nutrição	0,36	0,4%	7	25,9%
Subfunções Administr. e Complem. (1+3)	24,62	28,2%	26	96,3%
1 - Subfunções Administrativas	22,27	25,5%	26	96,3%
121 - Planejamento e Orçamento	0,50	0,6%	14	51,9%
122 - Administração Geral	20,59	23,6%	24	88,9%
124 - Controle Interno	0,65	0,7%	5	18,5%
126 - Tecnologia da Informação	0,12	0,1%	13	48,1%
128 - Formação de Recursos Humanos	0,37	0,4%	21	77,8%
131 - Comunicação Social	0,04	0,0%	9	33,3%
3 - Informações Complementares	2,35	2,7%	23	85,2%
271 - Previdência Básica	0,00	0,0%	1	3,7%
272 - Previdência do Regime Estatutário	0,18	0,2%	3	11,1%
273 - Previdência Complementar	0,00	0,0%	1	3,7%
571 - Desenvolvimento Científico	0,03	0,0%	7	25,9%
572 - Desenvolvimento. Tecnológico e Engenharia	0,01	0,0%	2	7,4%
573 - Difusão do Conhec. Científico. E Tecnológico.	0,00	0,0%	3	11,1%
843 - Serviço da Dívida Interna	0,15	0,2%	6	22,2%
844 - Serviço da Dívida Externa	0,01	0,0%	1	3,7%
xxx - Outras	1,98	2,3%	20	74,1%

Fonte: SIOPS/MS. Dados disponíveis em <https://bit.ly/3q653dT>, acesso em 07/05/2020.

A possível explicação seria que um número expressivo de entes federados remunera seus funcionários via Secretaria de Administração municipal ou estadual,

conforme demonstrado para os dois municípios apresentados na tabela 1, Londrina-PR e Joinville-SC. Isso acaba levando-os a lançar na rubrica 122 – Administração Geral, de forma equivocada, despesas com pessoal ativo lotado em serviços de saúde que deveriam ser contabilizadas nas subfunções vinculadas à função saúde, notadamente 301 – Atenção Básica; 302 – Assistência Hospitalar e Ambulatorial; 304 – Vigilância Sanitária; e 305 – Vigilância Epidemiológica. Essa distorção pode gerar um subdimensionamento das despesas assistenciais em detrimento das administrativas, e merece atenção e retificação.

Estratégias para ajuste nas distorções dos dados do SIOPS

A classificação por subfunção vinculada à Saúde define que despesas orçamentárias relacionadas com os programas e ações da APS devem ser registradas na subfunção 301 (Atenção Básica), as despesas em programas e ações de atenção ambulatorial e hospitalar na subfunção 302 (Assistência Hospitalar e Ambulatorial), e assim por diante. No que tange a declarações nessas subfunções, as evidências de distorções declaratórias provêm da comparação com as informações do FNS, que registram repasses do governo federal a estados e municípios por blocos de financiamento, que correspondem às subfunções. Evidentemente, o total de despesas declaradas pelos entes federados em cada uma delas precisa contemplar, no mínimo, o valor desses repasses federais recebidos, e esse nem sempre é o caso.

Pode-se reduzir essas distorções com o auxílio desses parâmetros auxiliares de correção. Por esses motivos, os dados do SIOPS usados em nosso estudo para estimar a despesa por macrorregião foram objeto de ajustes. O passo a passo utilizado incluiu (quadro 1): 1) agregação das despesas representativas de Atenção Básica e Média e Alta Complexidade, que correspondem aos agregados empregados em nossas análises (etapa 1); 2) correção das distorções na informação autodeclarada das despesas agregadas representativas de Atenção Básica e Média e Alta Complexidade (subfunções vinculadas à saúde) (etapa 2); 3) correção das distorções da distribuição informada entre funções não vinculadas à saúde e vinculadas à saúde (etapa 3); 4) estimação da alocação total de recursos estaduais nos territórios municipais (etapas 4).

Quadro 1. Tratamento de dados do SIOPS para estimar DABV e DMAC

Etapa	Justificativa	Método de ajuste
1. Agregação das despesas representativas de Atenção Básica e Média e Alta Complexidade	Para definir despesas em Atenção Básica e em Média e Alta Complexidade, devem-se agregar os valores de subfunções que representem esses níveis de atenção. Com isso, passamos também a trabalhar com um número menor de variáveis, o que facilita os ajustes necessários.	O primeiro bloco de despesas (variável de <i>input</i> DABV) comporta recursos que financiam ações e serviços de saúde relevantes para as ações da Atenção Básica (subfunções 301 – Atenção Básica, 304 – Vigilância Sanitária, 305 – Vigilância Epidemiológica e 306 – Alimentação e Nutrição). O segundo bloco (variável de <i>input</i> DMAC) corresponde à soma dos recursos ajustados destinados a Atenção Especializada (subfunções 302 – Assistência Hospitalar e Ambulatorial e 303 – Suporte profilático terapêutico).
2. Ajustes das despesas em subfunções vinculadas à saúde	Parte das UF informam nas subfunções despesas inferiores aos recursos transferidos pelo governo federal por meio do FNS. As UF precisam aplicar pelo menos os valores da transferência federal nos blocos de financiamento que correspondem às subfunções.	Para UF que informam valores liquidados nas subfunções inferiores aos transferidos pelo governo federal (base Transferências Fundo a Fundo via FNS – https://bit.ly/3HSe1dN), corrige-se o valor para o da transferência federal na subfunção correspondente. Os valores correspondentes são subtraídos prioritariamente das despesas não vinculadas, e depois em ordem de prioridade, DMAC e DABV.
3. Ajustes entre subfunções vinculadas e não vinculadas à saúde	Despesas em subfunções administrativas e complementares são superestimadas para alguns estados e municípios no SIOPS (entre 2008 e 2017, o valor médio foi de 32% para os estados e de 20% para os municípios) comparativamente às das contas de saúde usando metodologia System of Health Accounts (SHA) desenvolvida pela OCDE (5,1% para estados e 6,6% para municípios) ³ .	Para UF (estados ou municípios) onde as despesas em subfunções não vinculadas à saúde representam menos de 10% das despesas, os dados foram mantidos, e nas UF onde representam mais de 10% das despesas, ajusta-se o montante para 10% das despesas totais. O eventual saldo de recursos obtido (o que excede 10% da despesa) é considerado como despesa que deveria ser classificada nas subfunções vinculadas à função saúde. Esse saldo é, portanto, reservado para ser rateado proporcionalmente por essas subfunções após a primeira etapa de ajustes (comparação com os valores recebidos do FNS).
4. Rateio de alocação de recursos DABV e DMAC dos estados entre seus municípios	As informações do SIOPS fornecidas pelos estados não contemplam a distribuição de recursos por macrorregiões ou municípios	O rateio anual dos recursos estaduais DABV pelos respectivos municípios é proporcional à produção apresentada para o grupo de procedimentos 1 – Ações de Prevenção e Promoção em Saúde no Sistema de Informações Ambulatoriais do SUS (SIA/SUS) pelos municípios da UF. O rateio para recursos DMAC é proporcional aos valores apresentados de produção de serviços por estabelecimentos sob gestão estadual em cada município.
5. Recomposição da despesa estimada por macrorregiões	A variável usada no estudo corresponde à soma da despesa estimada para estados e municípios segundo o nível de Atenção (DABV e DMAC).	O financiamento estadual e municipal em DABV e DMAC são alocados em cada município, agregados segundo macrorregião e divididos pela população da macrorregião, para gerar valores de financiamento per capita.

Fonte: elaboração própria.

De forma resumida, as despesas executadas por estados e municípios são ajustadas e estimadas independentemente, distribuídas pelos municípios que compõem cada macrorregião e posteriormente agregadas nas variáveis DABV e DMAC, bem como divididas pela população de cada macrorregião para gerar os valores per capita, como discriminado no passo a passo apresentado acima (quadro 1). Essa agregação em DABV e DMAC (quadro 2) pressupõe uma afinidade entre subfunções do SIOPS que compõem esses dois grupos que pode levar a falhas declaratórias (informar em uma subfunção valores que podem ser referentes a outra subfunção). Adicionalmente, a agregação reduz o número de variáveis ajustadas, facilitando a eventual redistribuição de recurso, quando necessária.

Quadro 2. Agregação utilizada para estimar a desagregação da Despesa Total com Saúde (DTS) nas despesas por subfunção com dados do SIOPS e do FNS

Despesas estimadas	Subfunções SIOPS	Transferências de custeio do FNS
DMAC = Despesas com Média e Alta Complexidade e Suporte Profilático Terapêutico	302 – Assistência Ambulatorial e Hospitalar 303 – Suporte Profilático e Terapêutico	FNS_MAC_AF = Blocos financeiros de Média e Alta Complexidade (MAC) + Assistência Farmacêutica (AF)
DABV = Despesas com Atenção Básica, Vigilância Sanitária, Vigilância Epidemiológica e Alimentação e Nutrição (DABV)	301 – Atenção Básica 304 – Vigilância Sanitária 305 – Vigilância Epidemiológica 306 – Alimentação e Nutrição	FNS_AB_VS = Blocos financeiros de Atenção Básica (AB) + Vigilância em Saúde (VS)
Outras despesas	Subfunções Administrativas; Subfunções Complementares	

Fonte: elaboração própria.

O primeiro bloco de despesas – traduzido na variável de *input* DABV – comporta recursos que financiam ações e serviços de saúde relevantes para as ações de Atenção

Básica e Vigilância em Saúde (subfunções 301 – Atenção Básica + 304 – Vigilância Sanitária + 305 – Vigilância Epidemiológica + 306 – Alimentação e Nutrição) e seus desfechos estariam primordialmente relacionados com os óbitos preveníveis ou mistos. O segundo bloco abrange recursos destinados à atenção especializada hospitalar e ambulatorial de média e alta complexidade (subfunções 302 – Assistência Hospitalar e Ambulatorial + 303 – Suporte Profilático e Terapêutico), traduzidos na variável de *input* DMAC, cujos desfechos estão mais relacionados com a mortalidade por causas tratáveis. O terceiro bloco indica outras despesas, abrangendo as despesas que devem ser registradas em outras subfunções, “administrativas” e “complementares”.

Há informações detalhadas sobre as transferências para cada bloco de financiamento até 2017, que, grosso modo, correspondem às subfunções nas bases de dados de repasses financeiros do FNS. Com base nas informações sobre as transferências do FNS, seria esperado que as despesas declaradas no SIOPS nas subfunções por estados e municípios fossem pelo menos iguais e, idealmente, superiores aos repasses, o que indicaria aporte de recursos próprios no financiamento dessas atividades.

Desse modo, a distribuição de recursos por subfunção é ajustada usando como espelho as transferências federais: sempre que os valores declarados na subfunção são inferiores aos valores transferidos no regime ‘fundo a fundo’, presume-se que ocorreu um erro de declaração, e o valor é corrigido para corresponder, na primeira etapa do ajuste, ao valor transferido pelo governo federal para aquele bloco/subfunção. Os ajustes iniciais são realizados entre os dois blocos de subfunções da saúde criados (DABV e DMAC). Em alguns casos, não é possível realizar o ajuste dessa forma. Isso ocorre quando o valor informado em subfunções administrativas e complementares é igual a zero ou inferior à diferença entre DABV informada e as transferências FNS AB+VS, ou inferior à diferença entre DMAC e as transferências FNS MAC+SPT, conforme o caso, uma vez que não há sobra de valores nessas subfunções (administrativas ou complementares) que possam ser alocados nas subfunções da saúde (neste estudo agregadas nos blocos DABV e DMAC) que registram valores inferiores às transferências do FNS. Como exemplo para essa situação, apresentam-se a seguir os dados informados pelo município de Acrelândia-AC (tabela 4). As subfunções 302 e 303 (DMAC) registram valor zero, mas o município recebeu R\$ 101.676,48 do FNS em 2017 nos blocos de financiamento correspondentes a essas subfunções (tabela 5). Só é possível ajustar DMAC para esse valor retirando-se de DABV, uma vez que toda a despesa foi declarada nas subfunções 301 e 304. Nesse caso, DABV é ajustada de R\$ 5.275.391,56 para R\$ 5.173.715,08.

Tabela 4. Despesa ASPS informada ao SIOPS segundo a subfunção, Acrelândia-AC, 2017

Subfunção	Despesa em R\$
Despesa Total em ASPS	5.275.391,56
<i>Subfunções da Saúde</i>	<i>5.275.391,56</i>
301 - Atenção Básica	5.211.480,35
302 - Assistência Hospitalar e Ambulatorial	0,00
303 - Suporte Profilático e Terapêutico	0,00
304 - Vigilância Sanitária	63.911,21
305 - Vigilância Epidemiológica	0,00
306 - Alimentação e Nutrição	0,00
<i>Subfunções administrativas</i>	<i>0,00</i>
121 - Planejamento e Orçamento	0,00
122 - Administração Geral	0,00
123 - Administração Financeira	0,00
124 - Controle Interno	0,00
126 - Tecnologia da Informação	0,00
128 - Formação de Recursos Humanos	0,00
131 - Comunicação Social	0,00
<i>Subfunções complementares</i>	<i>0,00</i>

Fonte: SIOPS/MS. Dados disponíveis em <https://bit.ly/3q6S3dT>, acesso em 07/05/2020.

Tabela 5. Transferências do FNS para o município de Acrelândia-AC, valor líquido, 2017

Bloco Financeiro	Valor Transferido em 2017 (R\$)
Total	3.998.963,50
<i>FNS AB + VS</i>	<i>3.384.787,02</i>
Atenção Básica	3.213.956,00
Vigilância em Saúde	170.831,02

Bloco Financeiro	Valor Transferido em 2017 (R\$)
<i>FNS MAC + AF</i>	101.676,48
MAC	31.964,64
Assistência Farmacêutica	69.711,84
<i>Investimento</i>	512.500,00

Fonte: FNS. Dados disponíveis em <https://bit.ly/3bh4FMv>, acesso em 04/05/2020.

A terceira etapa de ajuste visa corrigir o excesso de despesas informadas em subfunções não vinculadas à saúde, a maior parte na subfunção 122 – Administração Geral. Conforme já indicado anteriormente, muitos governos estaduais e municipais reportam uma parcela de gasto com pessoal ativo lotado em serviços de atenção à saúde em subfunções não vinculadas, possivelmente devido à centralização do pagamento de pessoal por algum órgão nos entes federados, como em secretarias de administração, fazenda ou finanças. Durante o período analisado neste capítulo (2008-2017), os estados reportaram ao SIOPS, em média, 32% das despesas com saúde alocadas nas subfunções não vinculadas à saúde, consideradas despesas com gestão do sistema de saúde, enquanto os municípios registraram média de 20%.

Como parâmetro, os gastos com gestão reportados na Contas SHA do SUS³, baseados em metodologias recomendadas pela OCDE⁴, apontaram, no período compreendido entre 2010 e 2014, percentuais de despesa com gestão/despesas correntes segundo esfera administrativa, da ordem de 6,6% das despesas com saúde na esfera municipal e de 5,1% na esfera estadual.

Buscando corrigir essa distorção e alocar às subfunções vinculadas à saúde o ‘excesso’ de despesas alocadas às subfunções não vinculadas, na terceira etapa desse ajuste, parte-se dos valores estimados na segunda etapa para ratear de forma proporcional os valores considerados nesse momento como “Outras Despesas”. Para as UF (estados ou municípios) onde “Outras Despesas” (DTS – DMAC – DABV) é menor ou igual a 10% das despesas, os dados são mantidos. Nas UF (estados ou municípios) onde o item “Outras Despesas” representa mais de 10% da DTS, ajusta-se para 10% das despesas totais, e o saldo de recursos é reservado para ser rateado, proporcionalmente, pelas subfunções vinculadas à saúde (DABV e DMAC).

Procedido esse ajuste, de limitação de despesas em subfunções não vinculadas à saúde a 10%, obtivemos em média despesas com funções não vinculadas de 6,2% no período 2008-2017 (6,5% em 2017) para a esfera municipal e de 9% em média

(9,6% em 2017) para a esfera estadual, sendo que, neste último caso, consideram-se nesse percentual também as transferências intergovernamentais para a saúde nos municípios^{XIV}. Esses percentuais são compatíveis com as despesas em gestão identificadas pela metodologia OCDE³.

Concluída as três etapas de ajuste da informação, é preciso distribuir os recursos estaduais entre os municípios de cada estado antes de agregar os municípios componentes de cada macrorregião, visto que tal informação não consta do SIOPS (quadro 2). Para esse fim, aplica-se exclusivamente nos estados um rateio, que propicia uma distribuição *pro rata* dos recursos pelos municípios de cada estado.

Para o rateio das despesas estaduais com atenção básica e vigilância (DABV), utilizou-se a produção ambulatorial (número atendimentos/procedimentos), por local de atendimento e por município, apresentada no SIA/SUS. Esse rateio foi realizado de forma proporcional à quantidade apresentada de procedimentos do Grupo 01 – Ações de Promoção e Prevenção em Saúde, em estabelecimentos da “Esfera Administrativa” estadual.

Por sua vez, no caso dos recursos DMAC, aplicou-se um rateio proporcional aos valores apresentados por local e ano de atendimento, somados no SIA e no Sistema de Informações Hospitalares do SUS (SIH/SUS). No SIH, foram consideradas as formas de financiamento: “04 Fundo de Ações Estratégicas e Compensações (FAEC)”; “05 Incentivo – MAC”; “06 Média e Alta Complexidade (MAC)”; e a gestão “Estadual” e “Estadual plena”. Já no SIA/SUS, foi considerado o total de grupos de procedimentos^{XV}, exceto o “01 Ações de Promoção e Prevenção em Saúde”, naqueles estabelecimentos enquadrados nos tipos de gestão “Estado Pleno” e “Estado Convencional”.

Cada macrorregião compreende a agregação dos financiamentos executados por estado e municípios, segundo a composição de municípios por macrorregião de saúde, conforme disposto na Resolução CIT nº 37/2018⁵. Foi utilizada a composição das 117 macrorregiões de saúde do país, vigente em dezembro de 2019, disponível na Sala de Apoio à Gestão Estratégica (SAGE)⁶ do Ministério da Saúde^{XVI} e na página eletrônica do DataSUS^{XVII}.

XIV No SIOPS, somente a partir do ano base de 2018, passa a ser possível separar essas transferências por subfunção.

XV 02 - Procedimentos com finalidade diagnóstica; 03 - Procedimentos clínicos; 04 - Procedimentos cirúrgicos; 05 - Transplantes de órgãos, tecidos e células; 06 Medicamentos; 07 - Órteses, próteses e materiais especiais; 08 - Ações complementares da atenção à saúde.

XVI Disponível em <https://sage.saude.gov.br/#> na aba “Gestão/Financiamento”, selecionando “Regionalização” e “Macrorregiões”. Mais informações em <https://www.conass.org.br/guiainformacao/planejamento-regional-integrado/>.

XVII Disponível em <http://www2.datasus.gov.br/DATASUS/index.php?area=0901&item=1&acao=33>.

Referências

1. Piola SF, Benevides RPS, Vieira FS. Consolidação do gasto com ações e serviços públicos de saúde: trajetória e percalços no período de 2003 a 2017. Texto para Discussão 2439 [Internet]. Brasília, IPEA; 2018 [citado 2021 mar 13]. Disponível em: <http://bit.ly/2GUG39Z>
2. Banco Mundial. Um Ajuste Justo – Análise da Eficiência e Equidade do Gasto Público no Brasil [Internet]. Brasília: Grupo Banco Mundial; 2017 [citado 2021 mar 13]. Disponível em: <https://bit.ly/2SUTtfF>
3. Brasil. Ministério da Saúde. Fundação Oswaldo Cruz. Contas do SUS na perspectiva da contabilidade internacional: Brasil, 2010-2014 [Internet]. Brasília: Ministério da Saúde; 2018 [citado 2021 mar 13]. Disponível em: <https://bit.ly/3q1q6V5>
4. Organisation for Economic Co-operation and Development. Guidelines to improve estimates of expenditure on health administration and health insurance, Health Division, Directorate for Employment, Labour and Social Affairs. Paris: OECD; Dec 2013 Version.
5. Brasil. Ministério da Saúde. Gabinete do Ministro. Resolução nº 37, de 22 de março de 2018. Diário Oficial da União [Internet]. 2018 mar 26 [citado 2021 mar 13];155(58 seção 1):135. Disponível em: http://bvsms.saude.gov.br/bvs/saudelegis/cit/2018/res0037_26_03_2018.html
6. Brasil. Ministério da Saúde. Departamento de Monitoramento e Avaliação do SUS. Sala de Apoio à Gestão Estratégica (SAGE) do Ministério da Saúde [Internet]. Brasília: Ministério da Saúde; 2021 [acesso 2021 mar 13]. Disponível em: <https://sage.saude.gov.br/#>

Tabela 1. Conjunto de causas de mortalidade preveníveis e tratáveis com a lista OECD/Eurostat (versão 2019)

Grupo	Causas de mortes	Código CID-10	Mortalidade	Lista OECD/Eurostat (Versão 2019)
			Prevenível/tratável	
Doenças infecciosas	Doenças infecciosas intestinais	A00 - A09	Prevenível	
	Tuberculose	A15 - A19, B90	50% prevenível; outros 50% tratável	
	Tétano, Difteria, Poliomielite aguda	A35, A36, A80	Prevenível	
	Coqueluche	A37	Prevenível	
	Escarlatina	A38	Tratável	
	Infecção meningocócica	A39	Prevenível	
	Septicemia	A40, A41	Tratável	Exceto A40.3, A41.3 (relacionados às doenças preveníveis)
	Erisipela, Celulite	A46, L03	Tratável	
	Outr. doença bacter. NCOP	A48	Tratável	A48.1
	Infecç. bacter. de localiz. NE	A49	Tratável	A49.1, (A49.2 relacionado às doenças preveníveis)
	Infecções com transmissão predominantemente sexual	A50-A60, A63, A64	Prevenível	
	Varicela	B01	Prevenível	
	Sarampo	B05	Prevenível	
	Rubéola	B06	Prevenível	
	Hepatite viral	B15-B19	Prevenível	
	Doença por vírus da imunodeficiência humana (HIV)	B20-B24	Prevenível	
Malária	B50-B54	Prevenível		

Grupo	Causas de mortes	Código CID-10	Mortalidade	Lista OECD/Eurostat (Versão 2019)
			Prevenível/tratável	
Doenças infecciosas	Meningite	G00, G03	Tratável	G00.2, G00.3, G00.8, G00.9; G03 (G00.0, G001 relacionados às doenças preveníveis)
	Pneumoconiose assoc. c/tuberc.	J65	50% prevenível; outros 50% tratável	
Neoplasias	Neoplasia maligna do lábio, da cavidade oral e da faringe	C00-C14	Prevenível	
	Neoplasia maligna do esôfago	C15	Prevenível	
	Neoplasia maligna do estômago	C16	Prevenível	
	Neoplasia maligna do cólon, do reto e do ânus	C18-C21	Tratável	
	Neopl. maligna fígado vias biliares intra-hepática	C22	Prevenível	
	Neoplasia maligna da traqueia, dos brônquios e dos pulmões	C33-C34	Prevenível	
	Melanoma maligno da pele	C43	Prevenível	
	Mesotelioma	C45	Prevenível	
	Neoplasia maligna da mama	C50	Tratável	
	Neoplasia maligna do colo do útero	C53	50% prevenível; outros 50% tratável	
	Neoplasia maligna do corpo e de partes não especificadas do útero	C54, C55	Tratável	
	Neoplasia maligna dos testículos	C62	Tratável	
	Neoplasia maligna da bexiga	C67	Prevenível	
	Neoplasia maligna da glândula tireoide	C73	Tratável	
	Doença de Hodgkin	C81	Tratável	
	Leucemia linfóide	C91	Tratável	C91.0, C91.1
Neoplasias benignas	D10 - D36	Tratável		

Grupo	Causas de mortes	Código CID-10	Mortalidade	Lista OECD/Eurostat (Versão 2019)
			Prevenível/tratável	
Doenças endócrinas nutricionais e metabólicas	Deficiência nutricional anemias	D50 - D53	Prevenível	
	Transtornos da tireoide	E00 - E07	Tratável	
	Diabetes mellitus	E10 - E14	50% prevenível; outros 50% tratável	
	Síndrome de Cushing	E24	Tratável	Exceto E24.4 alocado para álcool relacionado às doenças preveníveis
	Transtornos adrenogenitais	E25	Tratável	
	Outros transtornos da glândula suprarrenal	E27	Tratável	
Doenças do sistema nervoso	Outras doenças degenerativas do sistema nervoso NCOP	G31	Prevenível	G31.2 alocado para álcool
	Epilepsia	G40, G41	Tratável	
	Outras polineuropatias	G62	Prevenível	G62.1 alocado para álcool
Doenças do aparelho circulatório	Febre reumática aguda e doenças reumáticas crônicas do coração	I01, I02, I05-I09	Tratável	
	Doenças hipertensivas	I10-I13, I15	50% prevenível; outros 50% tratável	
	Doenças isquêmicas do coração	I20-I25	50% prevenível; outros 50% tratável	
	Embolia pulmonar	I26	Tratável	
	Cardiomiopatias	I42	Prevenível	I42.6 alocado para álcool
	Doenças cerebrovasculares	I60-I69	50% prevenível; outros 50% tratável	
	Aterosclerose	I70	50% prevenível; outros 50% tratável	
	Aneurisma e dissecação da aorta	I71	50% prevenível; outros 50% tratável	
	Outras doenças vasculares periféricas	I73	50% prevenível; outros 50% tratável	I73.9
	Flebite e tromboflebite	I80	Tratável	

Grupo	Causas de mortes	Código CID-10	Mortalidade	Lista OECD/Eurostat (Versão 2019)
			Prevenível/tratável	
Doenças do aparelho circulatório	Outras embolias e trombose venosas	I82	Tratável	
Doenças do aparelho respiratório	Infecções respiratórias superiores	J00-J06, J30-J39	Tratável	
	Influenza (gripe)	J09-J11	Prevenível	
	Pneumonia viral NCOP	J12	Tratável	
	Pneumonia devidas a <i>Streptococcus pneumoniae</i>	J13	Tratável	
	Pneumonia devidas a <i>Haemophilus influenzae</i>	J14	Prevenível	
	Pneumonia bacter. NCOP	J15	Tratável	
	Pneumonia devida a outros micro-org Infecç. espec. NCOP	J16	Tratável	
	Pneumonia em doenças COP	J17	Tratável	
	Pneumonia por micro-organismos NE	J18	Tratável	
	Outras infecções agudas das vias aéreas inferiores	J20-J22	Tratável	
	Doenças crônicas das vias aéreas inferiores	J40-J44	Prevenível	
	Asma e Bronquiectasia	J45-J47	Tratável	
	Doenças pulmonares, devida a agentes externos	J60 - J64, J66 -J70, J82, J92	Prevenível	
	Síndrome do desconforto respiratório do adulto	J80	Tratável	
	Edema pulmonar NE de outras form.	J81	Tratável	
	Abcesso do pulmão e mediastino piotórax	J85, J86	Tratável	
Outros distúrbios pleurais	J90, J93, J94	Tratável		

Grupo	Causas de mortes	Código CID-10	Mortalidade	Lista OECD/Eurostat (Versão 2019)
			Prevenível/tratável	
Doenças do aparelho digestivo	Úlcera gástrica, duodenal e péptica	K25-K28	Tratável	
	Gastrite e duodenite	K29	Prevenível	K29.2 alocado para álcool
	Apendicite	K35 - K38	Tratável	
	Hérnia abdominal	K40 - K46	Tratável	
	Doença alcoólica do fígado	K70	Prevenível	Alocado para álcool
	Hepatite crônica NCOP	K73	Prevenível	Alocado para álcool
	Fibrose e cirrose hepáticas	K74	Prevenível	K74.0-K74.2, K74.6-K74.9 alocados para álcool
	Colelitíase e Colecistite	K80, K81	Tratável	
	Outras doenças da vesícula biliar ou trato	K82, K83	Tratável	
	Pancreatite aguda	K85	Tratável	K85.0,1,3,8,9 (K85.2 alocado para álcool e relacionado às doenças preveníveis)
Outras doenças do pâncreas	K86	Tratável	K86.1,2,3,8,9 (K86.0 alocado para álcool e relacionado às doenças preveníveis)	
Doenças do aparelho geniturinário	Nefrite e nefrose	N00 - N07	Tratável	
	Insuficiência renal	N17 - N19	Tratável	
	Uropatia obstrutiva	N13, N20 -N21, N35	Tratável	
	Cólica nefrética NE	N23	Tratável	
	Transtornos resultantes de função renal tubular alterada	N25	Tratável	
	Rim contraído NE e Hipoplasia renal de causa desconhecida	N26, N27	Tratável	
	Doenças inflamatórias do aparelho geniturinário	N34, N70 - N73, N75, N76	Tratável	N34.1, N70-N73, N75.0, N75.1, N76.4, N76.6
	Hiperplasia da próstata	N40	Tratável	

Grupo	Causas de mortes	Código CID-10	Mortalidade	Lista OECD/Eurostat (Versão 2019)
			Prevenível/tratável	
Gravidez parto e puerpério	Gravidez, parto e puerpério	O00-O99	Tratável	
Algumas afec. originadas no período perinatal	Tétano neonatal	A33	Prevenível	
	Tétano obstétrico	A34	Prevenível	
	Algumas afecções originadas no período perinatal	P00-P96	Tratável	
Malformações congênitas deformidades e anomalias cromossômicas	Espinha bífida	Q05	Prevenível	Q00, Q01, Q05
	Malformações congênitas do aparelho circulatório	Q20-Q28	Tratável	
Causas externas de morbidade e mortalidade	Acidentes de transporte	V01-V99	Prevenível	
	Quedas	W00-W19	Prevenível	
	Outras causas externas de lesões acidentais	W20-W64	Prevenível	
	Afogamentos	W65-W74	Prevenível	
	Exposição à fumaça, ao fogo e às chamas	X00-X09	Prevenível	
	Envenenamento acidental e exposição a substâncias nocivas	X40-X49	Prevenível	X45 alocado para álcool
	Esforço excessivo, viagens e privação	X50-X59	Prevenível	
	Lesões autoprovocadas voluntariamente	X60-X84	Prevenível	X65 alocado para álcool
	Agressões	X85-Y09	Prevenível	
	Eventos [fatos] cuja intenção é indeterminada	Y10-Y34	Prevenível	Y15 alocado para álcool
	Efeitos adversos de drogas, medicamentos e substâncias biológicas em uso terapêutico	Y40-Y59	Tratável	
	Acidentes ocorridos em pacientes durante a prestação de cuidados médicos e cirúrgicos	Y60-Y66, Y69	Tratável	

Grupo	Causas de mortes	Código CID-10	Mortalidade	Lista OECD/Eurostat (Versão 2019)
			Prevenível/tratável	
Causas externas de morbidade e mortalidade	Incidentes adversos durante atos diagnósticos ou terapêuticos associados ao uso de dispositivos (aparelhos) médicos	Y70-Y82	Tratável	
	Procedimentos médicos, cirúrgicos e outros como a causa de reação anormal	Y83, Y84	Tratável	
	Sequelas de lesões autoprovocadas intencionalmente	Y87	Prevenível	Y87.0, Y87.1
Transtornos por uso de drogas e álcool	Transtornos mentais e comportamentais devidos ao uso de substância psicoativa	F10-F16, F18-F19	Prevenível	

Apresentação formal da Análise Envoltória de Dados (*Data Envelopment Analysis – DEA*)

A Análise Envoltória de Dados (DEA) é um modelo de avaliação de eficiência econômica desenvolvido por Charnes, Cooper e Rhodes¹, com a aplicação de elementos de programação matemática ao problema de maximização de produção condicionada pela disponibilidade de recursos da firma desenhado por Farrell², a partir do conceito de eficiência de Pareto-Koopmans³.

As Unidades Tomadoras de Decisão (DMU) são os elementos básicos das análises de eficiência. Elas devem ser homogêneas, utilizar os mesmos insumos e resultados, que podem, cada um deles, ter unidades de medidas diferentes (por exemplo: toneladas, metros), mas essas unidades de medida devem ser as mesmas em todas as DMU. Estas devem, efetivamente, ser capazes de tomar decisões no problema tratado (por exemplo: não é razoável, em princípio, avaliar a eficiência da realização de transplantes de órgãos em municípios, dado que eles não têm autonomia nesses procedimentos).

A eficiência de cada DMU é medida pela otimização da soma ponderada das quantidades dos produtos ('resultados') dividida pela soma ponderada das quantidades dos insumos ('insumos'), ou seja, pela combinação entre 'resultado ponderado e insumo ponderado', de modo a maximizar o quociente $h = \frac{\text{resultado ponderado}}{\text{insumo ponderado}}$, ou, de maneira equivalente, minimizar o quociente $1/h = \frac{\text{insumo ponderado}}{\text{resultado ponderado}}$. Por definição, não é possível apresentar o 'insumo ponderado' maior do que o 'resultado' ponderado, e, portanto, o 'resultado ponderado' deve ser menor ou igual ao 'insumo' ponderado. Então, uma DMU plenamente 'eficiente' é aquela que consegue transformar todo o 'insumo' em *output* ponderado, e fazer o quociente $h = \frac{\text{insumo ponderado}}{\text{resultado ponderado}} = 1$.

Os modelos de DEA admitem diferentes naturezas de retornos de escala. Os modelos mais conhecidos e utilizados são: i) o modelo CCR (Charnes, Cooper e Rhodes¹) impõe

retornos constantes de escala; e ii) o modelo BCC (Banker, Charnes e Cooper⁴) admite retornos variáveis de escala. Existem também modelos com retornos decrescentes ou não crescentes de escala^{XVIII}.

É possível também escolher a orientação do modelo de DEA. Um modelo orientado para resultados maximiza as quantidades produzidas dos ‘resultados’ mantendo inalteradas as quantidades produzidas dos ‘insumos’, enquanto um modelo orientado para insumos minimiza os insumos mantendo os ‘resultados’ inalterados. Um modelo hiperbólico privilegia ambas as direções simultaneamente. Um modelo direcional escolhe direções específicas de otimização. Existem também modelos sem orientação.

São dois os modelos clássicos da DEA, o primeiro, já citado, que surgiu no artigo seminal de Charnes, Cooper e Rhodes¹, conhecido como CCR ou *Constant Returns to Scale* (CRS), que considera retornos constantes de escala. O segundo, desenvolvido posteriormente por Banker, Charnes e Cooper⁴, chamado de modelo BCC ou *Variable Returns to Scale* (VRS), que considera retornos variáveis de escala.

Os retornos de escala examinam a variação na quantidade produzida, quando os fatores de produção variam. Quando há uma variação da produção na mesma proporção dos fatores, caracteriza-se como retornos constantes de escala; se a variação da produção for proporcionalmente maior (menor) que dos fatores, têm-se retornos crescentes de escala (decrescentes).

A determinação dos escores de eficiência é feita a partir de um problema de programação linear, resolvido para cada DMU analisada. A partir dessa análise conjunta, temos a formação de uma fronteira determinada pelas DMU eficientes. A seguir, serão apresentados os problemas de otimização referentes aos modelos supracitados para a melhor compreensão:

Sabendo-se que:

X é uma matriz de n insumos e k DMUs com x_i colunas;

Y é uma matriz de m resultados e k DMUs e y_i colunas;

x_i é o vetor de insumos e y_i é o vetor de resultados de cada uma das DMU avaliadas;

θ é a medida de expansão radial dos resultados ou insumos;

XVIII Para mais detalhes sobre retornos de escala, ver o nosso capítulo 6.

λ é um vetor de pesos para as combinações convexas;

s^- e s^+ são vetores relacionados aos *slacks* (excessos e folgas, de insumos e resultados respectivamente);

ε representa uma constante positiva infinitesimal;

v e u são vetores de parâmetros de cada DMU e representam os pesos dos insumos e os pesos dos resultados, respectivamente.

Modelo CCR *Output* Orientado:

(Forma da Envoltória)

$$\text{Max } Z_j = \theta + \varepsilon \vec{1}s^+ + \varepsilon \vec{1}s^-$$

s.a

$$X\lambda - x_j + s^- = 0$$

$$\lambda, s^+, s^- \geq 0$$

Dual (Forma dos Multiplicadores)

$$\text{Min } Q_j = v^t x_j$$


$$\text{s.a. } u^t y_j = 1$$

$$v^t X - u^t Y \geq 0$$

$$u^t \geq \varepsilon \vec{1}; v^t \geq \varepsilon \vec{1}$$

Uma DMU será considerada eficiente se, e somente se, não for possível expandir os resultados (ou reduzir os insumos) e quando todas as folgas e excessos forem simultaneamente nulos, o que significa $\theta = 1$, e s^+ e s^- nulos. A seguir, vemos um gráfico representando um modelo com retornos constantes de escala.

Gráfico 1. Fronteira de eficiência de um modelo CCR



Fonte: elaboração própria.

Para um modelo CCR, a fronteira de eficiência é uma reta partindo da origem, sendo o ponto C, sobre a fronteira, o único eficiente, enquanto os demais pontos, abaixo da reta, são ditos ineficientes.

Modelo BCC:

Em um modelo BCC, que admite retornos variáveis de escala, é imposta no problema primal a restrição de convexidade, tal que $\sum \lambda = 1$. No modelo dual, essa mudança representada pela introdução do parâmetro adicional w_j , que não necessariamente é zero, como ocorre sempre no modelo CCR, o que fará com que a fronteira, diferentemente do modelo CCR, não passe necessariamente pela origem.

Modelo BCC *output* orientado:

Primal (Forma de Envoltória)

$$\text{Max } Z_j = \theta + \varepsilon \vec{1}s^+ + \varepsilon \vec{1}s^-$$

$$\text{s.a. } \theta y_j - Y\lambda + s^+ = 0$$

$$X\lambda - x_j + s^- = 0$$

$$\vec{1}\lambda = 1$$

$$\lambda, s^+, s^- \geq 0$$

Modelo Dual (Forma dos Multiplicadores):

$$\text{Min } Q_j = v^t x_j + w_j$$

$$\text{s.a. } u^t y_j = 1$$


$$v^t X - u^t Y + w_j \vec{1} \geq 0$$

$$u^t \geq \varepsilon \vec{1}; v^t \geq \varepsilon \vec{1}$$

w_j é livre

A seguir, apresentamos um gráfico representando uma fronteira hipotética para um modelo com retornos variáveis de escala. Para um modelo BCC, conclui-se que a fronteira de eficiência é côncava em relação à origem. No gráfico 8 a seguir, temos como eficientes as DMU representadas pelo ponto A, C, e D, sendo B a única não eficiente desse modelo. O problema de envoltória com que nos defrontamos é o de selecionar, para cada DMU, o ponto de fronteira que maximize seus resultados, dados os insumos disponíveis.

Gráfico 2. Fronteira de eficiência de um modelo BCC



Fonte: elaboração própria.

A DEA apresenta as seguintes características básicas:

1. Não faz julgamentos, *a priori*, sobre os valores das ponderações de ‘insumos’ e ‘resultados’ que levariam as DMU ao melhor nível de eficiência possível;
2. Dispensa (mas não rejeita), sistemas de preços ou pré-especificações da função de produção;
3. As DMU, com eficiência igual a 100%, teriam o valor $\theta = 1$ com todas as variáveis

representativas de folgas (s^+) e excessos (s^-) iguais a zero;

4. As DMU ineficientes teriam (no modelo *output*-orientado) valores de θ maiores do que a unidade, e folgas e excesso (*slacks*) positivos. Quanto maiores os valores de θ maior a ineficiência da respectiva DMU;
5. As DMU ineficientes teriam (no modelo *input*-orientado) valores de θ menores do que a unidade, e folgas e excesso (*slacks*) positivos. Quanto menores os valores de θ , maior a ineficiência da respectiva DMU.

As variáveis não discricionárias

Em princípio, espera-se que uma DMU controle todas as variáveis (insumos e resultados), que fazem parte do seu processo produtivo. Entretanto, nem sempre isso é possível. Variáveis importantes, mas não controláveis pelas DMU, são chamadas de variáveis ambientais ou exógenas, ou ainda, não discricionárias. As variáveis não discricionárias não fazem parte da função objetivo dos modelos de DEA, pois não podem ser maximizadas nem minimizadas pelas DMU. Entretanto, elas fazem parte das restrições dos modelos. Entre os exemplos mais frequentes dessas variáveis no setor saúde, podemos citar o PIB, a renda das populações e das pessoas atendidas, o nível de desenvolvimento de países ou de estados e municípios. Em nosso caso, utilizamos como variáveis ambientais a porcentagem de idosos na população, a cobertura de planos de saúde, o PIB per capita e a densidade demográfica.

Formalmente, um modelo com resultados discricionários e resultados não discricionários tem a seguinte forma:

OD-Resultados discricionários.

OND-Resultados não discricionários.

Max θ , λ , s^+ , s^- ($+\epsilon.1s^++\epsilon.1s^-$); $s^+\epsilon OD$ e $s^-\epsilon OD$

Sujeito a:

$X\lambda + s^- = x_0$

$y_0 + s^+ = Y\lambda$, $Y\epsilon OD$

$y_0 + s^+ = Y\lambda$, $Y\epsilon ND$

λ , s^+ , $s^- \geq 0$.

O fator de contração radial θ somente é aplicado no conjunto dos resultados (insumos) controláveis em um modelo orientado para insumos (resultados) e somente as folgas controláveis estão na função objetivo. Outra forma de incorporar as

variáveis não discricionárias na análise de eficiência usando DEA é utilizar modelos de regressões, em que essas variáveis são utilizadas como variáveis explicativas dos escores.

O *smoothed-bootstrap* e a DEA

Para corrigir os problemas dos modelos tradicionais de DEA (correlação serial; estimador viesado e com muitos escores próximos da unidade; desconhecimento da distribuição de probabilidades dos escores de eficiência), é utilizado o método do *bootstrap* (reamostragem) devido a Efron e Tibshirani⁵ e adaptado para a DEA por Simar e Wilson⁶.

Entretanto, o *bootstrap* usual não se aplica diretamente à DEA. Não é recomendado reamostrar diretamente o conjunto de escores da DEA, pois, dessa maneira, seria admitido que os escores são independentes e identicamente distribuídos, o que iria contra a suposição de que eles dependem da relação entre ‘insumos’ e ‘resultados’.

Também não é aconselhável reamostrar simplesmente os ‘insumos’ (ou ‘resultados’) para estimar a tecnologia e a eficiência de determinada DMU, uma vez que existe a possibilidade de encontrar escores maiores do que a unidade, ou seja, poderiam surgir vetores (combinações de quantidades de insumos e de resultados), que não pertencem à tecnologia estimada apesar de estarem na amostra. Tal ocorrência é mais provável em DMU mais próximas à fronteira original.

Os escores do DEA apresentam, igualmente, o problema de serem bastante concentrados em torno do valor unitário. Para enfrentar essa dificuldade, Simar e Wilson⁶ propõem os métodos de alisamento da distribuição e de reflexão, bem como a correção do viés (*smoothed-bootstrap*). Por sua vez, para a aplicação do *smoothed-bootstrap* na DEA, estima-se a DEA na amostra original e obtêm-se os escores de eficiência estimados para cada uma das K DMUs (onde $k=1, 2, \dots, K$). Em seguida, são realizadas B réplicas para obter os escores via *bootstrap*. Os escores são corrigidos pelo viés, alisados e refletidos da seguinte forma:

1. Realizam-se amostras *bootstrap* \widehat{E}_k para cada uma das DMUs $(\beta_1, \beta_2, \dots, \beta_k)$;
2. Simulam-se variáveis aleatórias independentes com distribuição normal-padrão $\epsilon_1, \epsilon_2, \dots, \epsilon_k$;
3. Estabelecem-se o alisamento e a reflexão por meio do cálculo abaixo:

$$\widetilde{E}_k = \beta_k + h\epsilon_k \text{ se } \beta_k + h\epsilon_k \leq 1,$$

ou $\widetilde{E}_k = 2 - \beta k - h\epsilon_k$: caso $\beta k + h\epsilon_k > 1$.

O método de reflexão é utilizado para corrigir eventuais problemas com valores próximos da unidade (1,0), uma vez que a DEA exige que a eficiência tenha valores entre [0,1];

4. Ajusta-se \widetilde{E}_k para obter os parâmetros com a correta variância assintótica. Em seguida, estima-se a variância $\widehat{\sigma}^2 = \frac{1}{n} \sum_{k=1}^K (\widetilde{E}_k - \bar{E}_k)^2$;
5. Agora é possível calcular $E_k^* = \bar{\beta} + \frac{1}{\sqrt{1 + \frac{h^2}{\sigma^2}}} (\widetilde{E}_k - \bar{\beta})$ onde $\bar{\beta} = \frac{1}{n} \sum_{k=1}^K \beta_k$.

O processo de *bootstrap* é repetido e obtêm-se para cada DMU K , B pseudoamostras de interesse $(x_k^b, y_k) = \left(\frac{E_k^*}{E_k} x_k, y_k \right)$. Estas serão aplicadas na DEA para permitir o cálculo dos estimadores $E_1^b, E_2^b, \dots, E_k^b$ onde $b=1, 2, \dots, B$.

Ao final, $(E_k^b - \widehat{E}_k) | \widehat{P} \sim (\widehat{E}_k - E_k) | P$, em que P e \widehat{P} correspondem ao processo de geração de dados estimado e original, respectivamente, ou seja, $(E_k^b - \widehat{E}_k)$ e $(\widehat{E}_k - E_k)$, têm distribuição de probabilidades similares. Assim, a despeito de o processo gerador de dados original não ser conhecido, a diferença entre a eficiência estimada pelo *bootstrap* e a eficiência estimada pelo método convencional é próxima da diferença entre a eficiência estimada pelo método convencional e a eficiência real. Como a eficiência estimada pelo método convencional e a estimada pelo *bootstrap* são conhecidas, pode-se inferir a eficiência real.

Referências

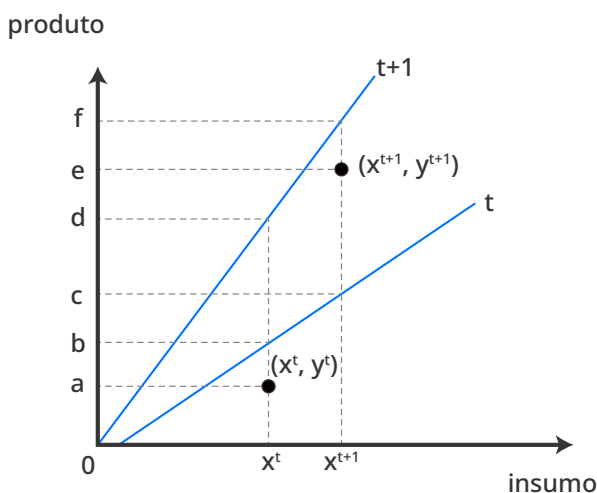
1. Charnes, Cooper e Rhodes. Measuring the Efficiency of Decision Making Units European Journal of Operational Research 2 6: 429-444
2. Farrell MJ. The Measurement of Productive Efficiency. J R Stat Soc. Ser. A. 1957;120(111):253-90.

3. Koopmans T. Activity analysis of production and allocation. New York: John Wiley & Sons; 1951.
4. Banker RD, Charnes A, Cooper WW. Some models for estimating technical and scale inefficiencies in data envelopment analysis. *Manag Sci.* 1984;30(9):1078-92.
5. Efron B, Tibshirani R. An Introduction to the Bootstrap. London: Chapman & Hall; 1993.
6. Simar L, Wilson PW. Sensitivity analysis of efficiency scores: How to bootstrap in non-parametric frontier models. *Manag Sci.* 1998;44(1):49-61.

O Índice de Malmquist

Desenvolvido por Malmquist¹, aplicado pela primeira vez por Caves et al.², o IM calcula variações de produtividade, eficiência e tecnologia entre períodos distintos. A fronteira de eficiência é construída a partir do vetor insumo-produto de cada DMU sob análise. Esse vetor insumo-produto, por sua vez, varia conforme o tempo e a orientação desejada. Cada período possui uma fronteira de eficiência diferente. O gráfico 1 apresenta duas fronteiras tecnológicas, uma formada no período t e outra no período $t+1$, ambas, com orientação voltada para o *output*. Para a sua concepção, deve-se considerar uma tecnologia de produção S_t convexa, fechada, e não vazia, com insumos $[x^t = (x^1, x^2, \dots, x^n)]$ e produtos $[y^t = (y^1, y^2, \dots, y^m)]$ disponíveis para cada período $t=1, 2, \dots, T$.

Gráfico 1. Mudanças dinâmicas de performance e tecnologia



Fonte: elaboração própria.

Uma DMU de referência DMU_0 apresenta um vetor insumo-produto (x^t, y^t) em uma tecnologia válida no instante t , e um vetor insumo-produto (x^{t+1}, y^{t+1}) em uma tecnologia válida em $t+1$. Observe-se que o vetor insumo-produto (x^t, y^t) é uma combinação possível tanto com a tecnologia vigente em t quanto em $t+1$. Entretanto, o vetor insumo-produto (x^{t+1}, y^{t+1}) só pode ser alcançado com a tecnologia disponível em $t+1$. A razão entre a distância da origem até o vetor insumo-produto e a distância da origem até a fronteira tecnológica da DMU sob análise é chamada de função-distância. Portanto, a função-distância (afastamento da fronteira) da DMU_0 em t corresponde a $\frac{\vec{0a}}{0b}$. Como não há razão teórica para escolha do período de referência, que tanto pode ser o instante t como o instante $t+1$, a fórmula que define o IM corresponde à média geométrica entre dois índices gerados por funções distâncias medidas em t e em $t+1$ e está apresentada a seguir:

$$M_0(x^{t+1}, y^{t+1}, x^t, y^t) = \left[\frac{D_0^t(x^{t+1}, y^{t+1})}{D_0^t(x^t, y^t)} \times \frac{D_0^{t+1}(x^{t+1}, y^{t+1})}{D_0^{t+1}(x^t, y^t)} \right]^{\frac{1}{2}}$$

Em que:

- $D_0^t(x^{t+1}, y^{t+1})$ corresponde à função-distância da DMU_0 considerando o vetor insumo-produto em $t+1$ e a tecnologia em t ;
- $D_0^t(x^t, y^t)$ corresponde à função-distância da DMU_0 considerando o vetor insumo-produto em t e a tecnologia em t ;
- $D_0^{t+1}(x^{t+1}, y^{t+1})$ corresponde à função-distância da DMU_0 considerando o vetor insumo-produto em $t+1$ e a tecnologia em $t+1$;
- $D_0^{t+1}(x^t, y^t)$ corresponde à função-distância da DMU_0 considerando o vetor insumo-produto em t e a tecnologia em $t+1$;

A média geométrica é utilizada para que não seja necessário escolher uma das fronteiras de produção para servir de referência no cálculo do índice. Em um modelo orientado para resultados, a produtividade aumentou (diminuiu) se o índice for maior (menor) do que a unidade. O oposto ocorre com orientação para os insumos. Se o IM for

igual a unidade não houve mudança na produtividade. Conforme abaixo relacionado, o IM pode ser decomposto em dois componentes:

$$M_0(x^{t+1}, y^{t+1}, x^t, y^t) = \frac{D_0^{t+1}(x^{t+1}, y^{t+1})}{D_0^t(x^t, y^t)} \left[\frac{D_0^t(x^{t+1}, y^{t+1})}{D_0^{t+1}(x^{t+1}, y^{t+1})} \times \frac{D_0^t(x^t, y^t)}{D_0^{t+1}(x^t, y^t)} \right]^{\frac{1}{2}}$$

O primeiro componente é $\frac{D_0^{t+1}(x^{t+1}, y^{t+1})}{D_0^t(x^t, y^t)}$ e corresponde ao efeito conhecido como emparelhamento (*catch-up effect*), que identifica alterações no nível de eficiência ao longo do tempo, para transformar insumos em produtos (eficiência técnica). Em um modelo orientado para os resultados, se existir uma elevação de eficiência técnica, o valor da expressão será maior do que a unidade e ocorrerá o posto em um modelo orientado para insumos. Se houver redução, o indicador será menor do que a unidade, com o oposto ocorrendo em um modelo orientado para insumos e, se não houver variação, o indicador será igual a unidade.

O segundo componente é $\left[\frac{D_0^t(x^{t+1}, y^{t+1})}{D_0^{t+1}(x^{t+1}, y^{t+1})} \times \frac{D_0^t(x^t, y^t)}{D_0^{t+1}(x^t, y^t)} \right]^{\frac{1}{2}}$, que capta alterações no nível de eficiência geradas pela adequação da unidade tomadora de decisão, em relação a tecnologia disponível no momento (mudança tecnológica). Se essa expressão for maior do que a unidade, em um modelo orientado para produtos, significa que houve avanço tecnológico, e vice-versa, em um modelo orientado para insumos. Se for igual à unidade, significa que há não há variação. Se for menor do que a unidade, houve retrocesso tecnológico em um modelo orientado para resultados ocorrendo o oposto, em um modelo orientado para insumos.

No modelo corrigido pelo bootstrap³, após o cálculo do intervalo de confiança, verifica-se se cada índice é significativamente diferente da unidade. Se o intervalo de confiança de uma DMU contém a unidade, não há evidências estatísticas da ocorrência de alterações significativas de produtividade. Por outro lado, se os limites superior e inferior do intervalo de confiança de uma DMU forem, ambos, inferiores (ou superiores)

à unidade, ou seja, se a unidade está fora do intervalo, existe evidência estatística de perda (ou ganho) estatisticamente significativa de produtividade. Esse raciocínio também é válido para a variação de eficiência e para a variação tecnológica.

Referências

1. Malmquist S. (1953). Index numbers and indifference surfaces. *Trabajos de Estadística*. 1953;4(2):209-242.
2. Caves DW, Chistensen LR, Diewert WE. The economic theory of index numbers and the measurement of inputs, outcomes and productivity. *Econometrica*. 1982;50(6):1393-1414.
3. Simar L, Wilson PW. Estimating and bootstrapping Malmquist indices. *Eur J Oper Res*. 1999;115(3):459-471.