

Econometria a Serviço da Saúde: Big Data e Avaliação de Políticas de Saúde no Brasil

Rudi Rocha
FGV & IEPS

Ciência e Inovação Digital em Saúde – eScience Fapesp
02.10.2019

- Motivação geral: como dados e a ciência de dados podem nos fazer mais saudáveis?

- Motivação geral: como dados e a ciência de dados podem nos fazer mais saudáveis? Ou melhor, uma sociedade melhor?

- Motivação geral: como dados e a ciência de dados podem nos fazer mais saudáveis? Ou melhor, uma sociedade melhor?
- Roteiro desta apresentação:
 - ① Pano de fundo em economia da saúde:

- Motivação geral: como dados e a ciência de dados podem nos fazer mais saudáveis? Ou melhor, uma sociedade melhor?
- Roteiro desta apresentação:
 - 1 Pano de fundo em economia da saúde: problemas

- Motivação geral: como dados e a ciência de dados podem nos fazer mais saudáveis? Ou melhor, uma sociedade melhor?
- Roteiro desta apresentação:
 - ① Pano de fundo em economia da saúde: problemas tsunâmicos!

- Motivação geral: como dados e a ciência de dados podem nos fazer mais saudáveis? Ou melhor, uma sociedade melhor?
- Roteiro desta apresentação:
 - ❶ Pano de fundo em economia da saúde: problemas tsunâmicos! Dados poderiam ajudar na solução?

- Motivação geral: como dados e a ciência de dados podem nos fazer mais saudáveis? Ou melhor, uma sociedade melhor?
- Roteiro desta apresentação:
 - ❶ Pano de fundo em economia da saúde: problemas tsunâmicos! Dados poderiam ajudar na solução?
 - ❷ Dados e ciência de dados em mais detalhes: potencial para modelos de caracterização, previsão e causalidade.

Introdução

- Motivação geral: como dados e a ciência de dados podem nos fazer mais saudáveis? Ou melhor, uma sociedade melhor?
- Roteiro desta apresentação:
 - ❶ Pano de fundo em economia da saúde: problemas tsunâmicos! Dados poderiam ajudar na solução?
 - ❷ Dados e ciência de dados em mais detalhes: potencial para modelos de caracterização, previsão e causalidade.
 - ❸ Causalidade em mais detalhes: a econometria a serviço da saúde.

- Motivação geral: como dados e a ciência de dados podem nos fazer mais saudáveis? Ou melhor, uma sociedade melhor?
- Roteiro desta apresentação:
 - ❶ Pano de fundo em economia da saúde: problemas tsunâmicos! Dados poderiam ajudar na solução?
 - ❷ Dados e ciência de dados em mais detalhes: potencial para modelos de caracterização, previsão e causalidade.
 - ❸ Causalidade em mais detalhes: a econometria a serviço da saúde.
 - ❹ Exemplos de aplicações: avaliações de políticas públicas.

- Motivação geral: como dados e a ciência de dados podem nos fazer mais saudáveis? Ou melhor, uma sociedade melhor?
- Roteiro desta apresentação:
 - ❶ Pano de fundo em economia da saúde: problemas tsunâmicos! Dados poderiam ajudar na solução?
 - ❷ Dados e ciência de dados em mais detalhes: potencial para modelos de caracterização, previsão e causalidade.
 - ❸ Causalidade em mais detalhes: a econometria a serviço da saúde.
 - ❹ Exemplos de aplicações: avaliações de políticas públicas.
- Por fim, mas não menos importante: desigualdade.

Pano de Fundo em Economia da Saúde: Complexidade

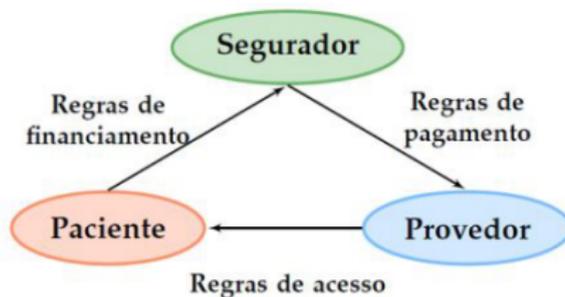


Table 15.1 Public and Private Mix in Health Care

	Public Funding	Private Funding
Public provision	National Health Service	
Private provision	Social insurance	(Regulated) private insurance

Future and potential spending on health 2015–40: development assistance for health, and government, prepaid private, and out-of-pocket health spending in 184 countries

Global Burden of Disease Health Financing Collaborator Network*

Abstract

Background The amount of resources, particularly prepaid resources, available for health can affect access to health care and health outcomes. Although health spending tends to increase with economic development, tremendous variation exists among health financing systems. Estimates of future spending can be beneficial for policy makers and planners, and can identify financing gaps. In this study, we estimate future gross domestic product (GDP), all-sector government spending, and health spending disaggregated by source, and we compare expected future spending to potential future spending.

Methods We extracted GDP, government spending in 184 countries from 1980–2015, and health spend data from 1995–2014. We used a series of ensemble models to estimate future GDP, all-sector government spending, development assistance for health, and government, out-of-pocket, and prepaid private health spending through 2040. We used frontier analyses to identify patterns exhibited by the countries that dedicate the most funding to health, and used these frontiers to estimate potential health spending for each low-income or middle-income country. All estimates are inflation and purchasing power adjusted.

Findings We estimated that global spending on health will increase from US\$9.21 trillion in 2014 to \$24.24 trillion (uncertainty interval [UI] 20.47–29.72) in 2040. We expect per capita health spending to increase fastest in upper-middle-income countries, at 5.3% (UI 4.1–6.8) per year. This growth is driven by continued growth in GDP, government spending, and government health spending. Lower-middle income countries are expected to grow at 4.2% (3.8–4.9). High-income countries are expected to grow at 2.1% (UI 1.8–2.4) and low-income countries are expected to grow at 1.8% (1.0–2.8). Despite this growth, health spending per capita in low-income countries is expected to remain low, at \$154 (UI 133–181) per capita in 2030 and \$195 (157–258) per capita in 2040. Increases in national health spending to reach the level of the countries who spend the most on health, relative to their level of economic development, would mean \$321 (157–258) per capita was available for health in 2040 in low-income countries.

Interpretation Health spending is associated with economic development but past trends and relationships suggest that spending will remain variable, and low in some low-resource settings. Policy change could lead to increased health spending, although for the poorest countries external support might remain essential.

Funding Bill & Melinda Gates Foundation.

Copyright © The Author(s). Published by Elsevier Ltd. This is an Open Access article under the CC BY 4.0 license.



Lancet 2017; 389: 2005–30

Published Online

April 19, 2017

[http://dx.doi.org/10.1016/S0140-6736\(17\)30873-5](http://dx.doi.org/10.1016/S0140-6736(17)30873-5)

50140-6736(17)30873-5

This online publication has been corrected. The corrected version first appeared at thelancet.com on May 18, 2017

See [Comment](#) page 1955

*Collaborators listed at the end of the Article

Correspondence to:
Dr Joseph L Dieleman,
2301 5th Avenue, Suite 600,
Seattle, WA 98121, USA
dieleman@uw.edu

- Sistemas de saúde são extremamente complexos... e estão sob pressão crescente.
 - Sistemas ao redor do mundo estão experimentando com reformas, sem um benchmark ideal... necessariamente se transformarão.
 - Quais serão as consequências? Quais os riscos e oportunidades?
- Em particular, dados e ciência de dados têm sido apontados como fonte de soluções.
 - Via inovações não apenas em bens e serviços de saúde, mas via mitigação de falhas informacionais e no apoio à gestão de sistemas.
 - Benefícios estão cada vez mais claros. Mas riscos também.

- Mas como utilizar massa crescente de dados e de informação a serviço da saúde?

- Mas como utilizar massa crescente de dados e de informação a serviço da saúde?
- Podemos destacar pelo menos três formas de uso bastante relevantes e que têm sido frequentemente empregadas em aplicações:
 - ❶ Para caracterização de fenômenos: através de um dashboard de saúde ou via diagnóstico por imagens...
 - ❷ Para previsão de fenômenos: difusão de infecciosas ou prevenção de crônicas...
 - ❸ Para identificação de relações causais... afinal, em que medida isso e aquilo funcionam?

- Mas como utilizar massa crescente de dados e de informação a serviço da saúde?
- Podemos destacar pelo menos três formas de uso bastante relevantes e que têm sido frequentemente empregadas em aplicações:
 - ❶ Para caracterização de fenômenos: através de um dashboard de saúde ou via diagnóstico por imagens...
 - ❷ Para previsão de fenômenos: difusão de infecciosas ou prevenção de crônicas...
 - ❸ Para identificação de relações causais... afinal, em que medida isso e aquilo funcionam?
- Quando falamos sobre big data e ML, em geral nos referimos a caracterizações (em tempo real) e modelos preditivos.
 - Muito por conta disso, me concentro a partir de agora em causalidade: não menos importante e mais artesanal.

Causalidade a Serviço da Saúde

- Muito frequentemente queremos identificar e quantificar uma relação de causalidade entre duas variáveis:
 - Uma determinado medicamento causou melhoria na saúde dos pacientes?
 - Uma determinada política causou uma queda na mortalidade infantil?

Causalidade a Serviço da Saúde

- Muito frequentemente queremos identificar e quantificar uma relação de causalidade entre duas variáveis:
 - Uma determinado medicamento causou melhoria na saúde dos pacientes?
 - Uma determinada política causou uma queda na mortalidade infantil?
- Em que medida?

Causalidade a Serviço da Saúde

- Muito frequentemente queremos identificar e quantificar uma relação de causalidade entre duas variáveis:
 - Uma determinado medicamento causou melhoria na saúde dos pacientes?
 - Uma determinada política causou uma queda na mortalidade infantil?
- Em que medida? A econometria mede relações; e às vezes é capaz de qualificar esta mensuração como causal.

Causalidade a Serviço da Saúde

- Muito frequentemente queremos identificar e quantificar uma relação de causalidade entre duas variáveis:
 - Uma determinado medicamento causou melhoria na saúde dos pacientes?
 - Uma determinada política causou uma queda na mortalidade infantil?
- Em que medida? A econometria mede relações; e às vezes é capaz de qualificar esta mensuração como causal.
- Com disponibilidade cada vez maior de dados, com técnicas econométricas apropriadas, tem sido possível responder perguntas relevantes.

Causalidade a Serviço da Saúde

- Muito frequentemente queremos identificar e quantificar uma relação de causalidade entre duas variáveis:
 - Uma determinado medicamento causou melhoria na saúde dos pacientes?
 - Uma determinada política causou uma queda na mortalidade infantil?
- Em que medida? A econometria mede relações; e às vezes é capaz de qualificar esta mensuração como causal.
- Com disponibilidade cada vez maior de dados, com técnicas econométricas apropriadas, tem sido possível responder perguntas relevantes.
- Um pouco sobre técnicas e dados, para além do laboratório:
 - Técnicas: RCTs, DiD, IV, RDD, PSM...
 - Um pouco sobre dados no Brasil...

Principais Bases Públicas de Dados em Saúde

- Datasus: padroniza, centraliza e dissemina informações em saúde. Principais sistemas de informação (dentre +600):
 - SIM (óbitos) e SINASC (nascimentos): censitários, $\sim 10 \times$ milhões obs, desde 1996.
 - SIH (hospitalizações): internações no SUS (publico e privado conveniado), $\sim 100 \times$ milhões obs, desde 1996.
 - SIA (ambulatorial): contem todos os procedimentos ambulatoriais do SUS (idem), \sim bilhões obs, desde 1996.
 - CNES: informação censitária de todos os estabelecimentos de saúde no Brasil, $\sim 300k$ geocoded obs/mês, desde 2006.
- Todos os microdados disponíveis publicamente; dependendo do que se deseja: dados de qualidade, país em desenvolvimento e muito heterogêneo.
- Acesso a dados identificados é limitado (mas identificação existe). Linkage com outras bases administrativas (RAIS/MEC/MDS etc) e Georef.

- Algumas aplicações em andamento:

① ATFP

② UPA 24hs

③ Regionalização

Figure 1: ATFP Expansion, 2006-2015

(a) Total Number of ATFP Pharmacies and Municipality Coverage

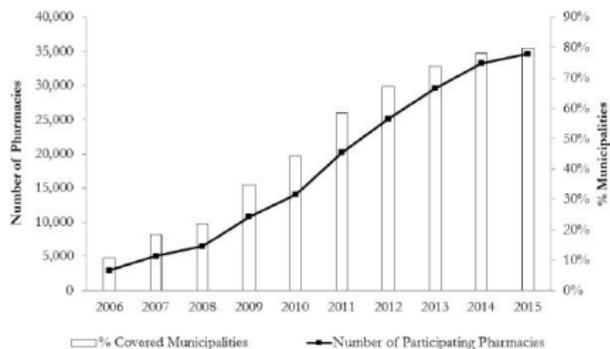


Table 5: ATFP Effects by Diabetes Type

	Effects by Diabetes Type		
	OLS	2SLS	RF
Panel A - Type I Diabetes (Insulin-Dependent)			
Mortality	0.022 (0.009)**	0.019 (0.056)	0.057 (0.165)
Hospitalization	-0.498 (0.157)***	-1.931 (0.774)**	-5.645 (2.285)**
Panel B - Type II Diabetes (Non Insulin-Dependent)			
Mortality	0.016 (0.055)	-0.644 (0.334)*	-1.884 (0.944)**
Hospitalization	-0.528 (0.226)**	-6.286 (1.487)***	-18.381 (3.989)***
Observations	71,591	71,591	71,591
Number of Municipalities	5,507	5,507	5,507

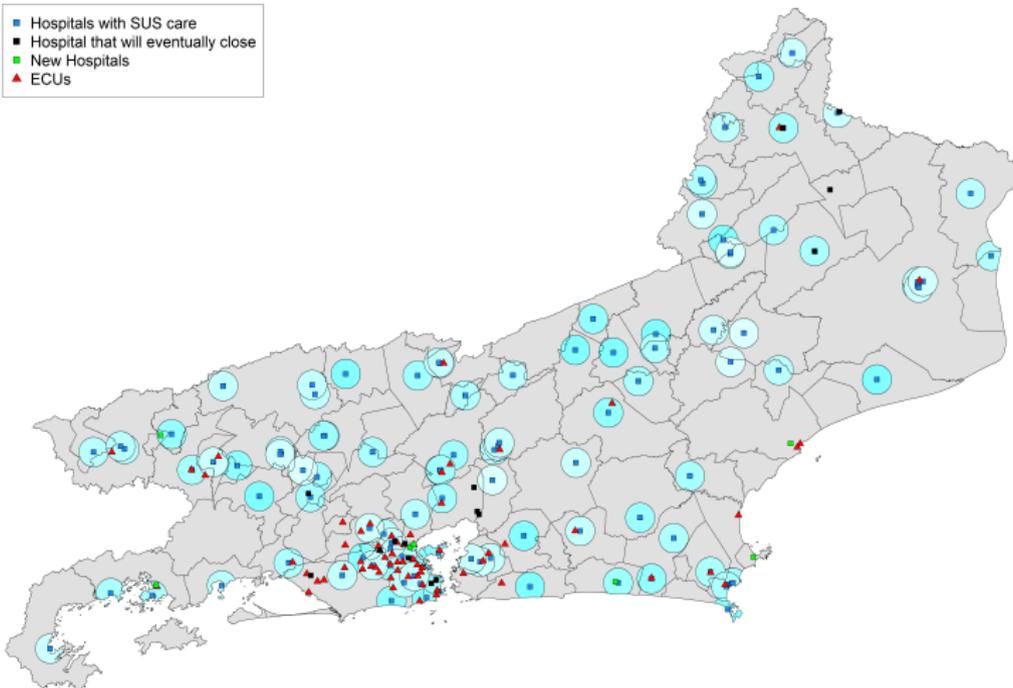
Notes: Each cell presents the results (point estimate and standard error) from a different regression. The first two columns show coefficients from OLS and 2SLS specifications, respectively, while the third column reports reduced-form estimates. Mortality/Hospitalization rows refer to estimates for effects on mortality and hospitalization rates, respectively. In the upper panel, outcomes are computed for type 1 diabetes only. The bottom panel refers to outcomes for type II diabetes. All regressions include municipality and year fixed effects, socioeconomic controls (the logarithm of GDP per capita, population density and the share of population within each 5-year age bracket), controls for the presence of hospitals, hospital beds per capita, PSF and PACS coverage (in %), and the number of private pharmacies per capita. Robust standard errors allowing for clustering at the municipality level in parentheses; regressions weighted by population. * significant at 10%; ** significant at 5%; *** significant at 1%.

Table 7: ATFP Effects on Hospitalization by SES
 Poor Zipcodes vs Non-Poor Zipcodes

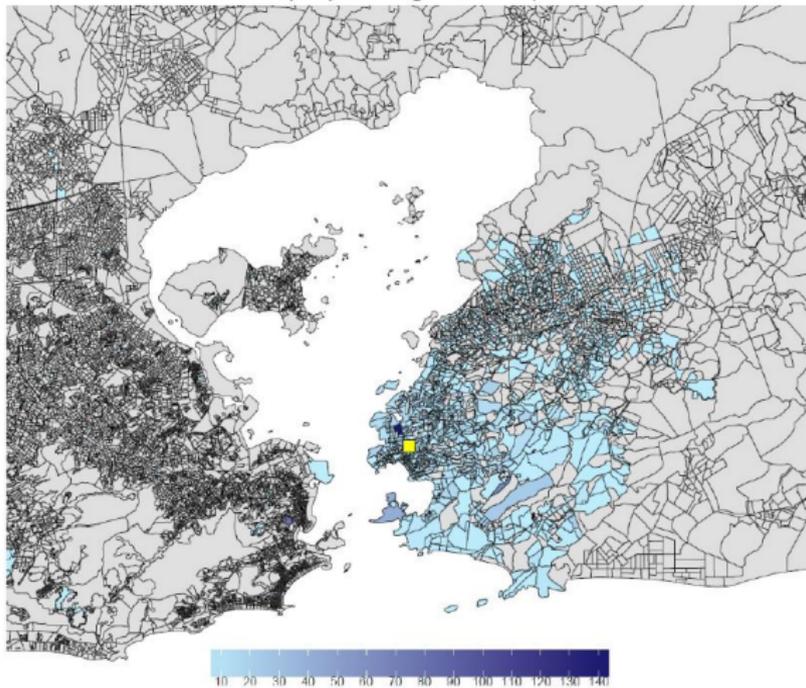
	Diabetes Hospitalization Rates		
	OLS	2SLS	RF
Poor Zipcodes	-0.003 (0.004)	-0.061 (0.019)***	-0.177 (0.056)***
Non-Poor Zipcodes	0.001 (0.002)	-0.028 (0.012)**	-0.081 (0.035)**
Observations	71,591	71,591	71,591
Number of Municipalities	5,507	5,507	5,507

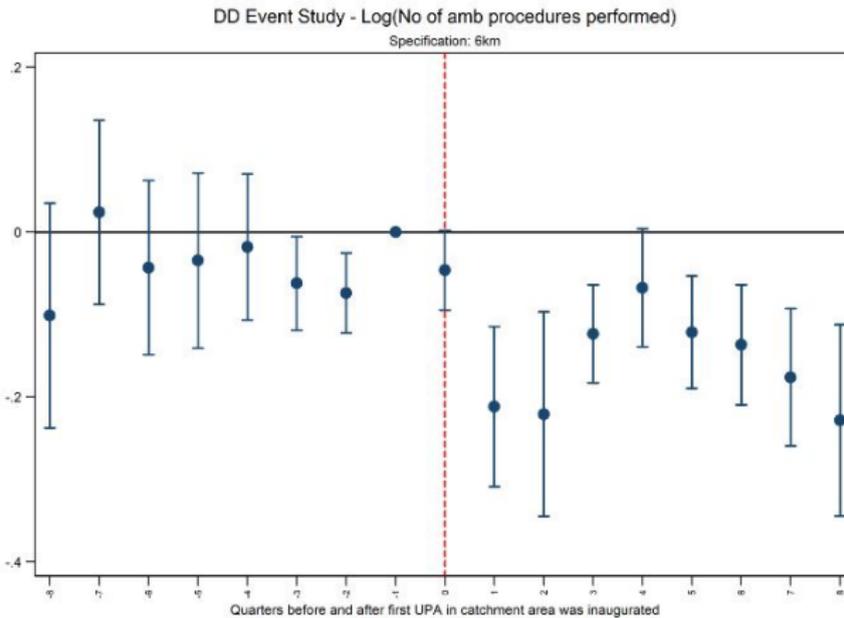
Notes: Each cell presents the results (point estimate and standard error) from a different regression. In all specifications the dependent variable is the hyperbolic sine-transformation of the number of hospital admissions for diabetes. The first two columns show coefficients from OLS and 2SLS specifications, respectively, while the third column reports reduced-form estimates. Poor/non-poor zipcodes refer to zipcodes with average income below/above the median household income per capita. All regressions include municipality and year fixed effects, socioeconomic controls (the logarithm of GDP per capita, population density and the share of population within each 5-year age bracket), controls for the presence of hospitals, hospital beds per capita, PSF and PACS coverage (in %), and the number of private pharmacies per capita. Robust standard errors allowing for clustering at the municipality level in parentheses; regressions weighted by population. * significant at 10%; ** significant at 5%; *** significant at 1%.

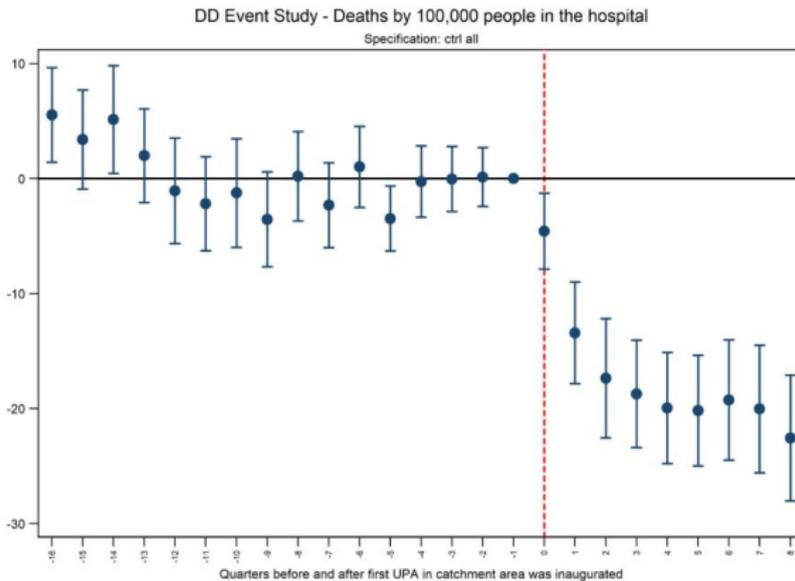
- Hospitals with SUS care
- Hospital that will eventually close
- New Hospitals
- ▲ ECUs



Number of people that goes to hospital 12513

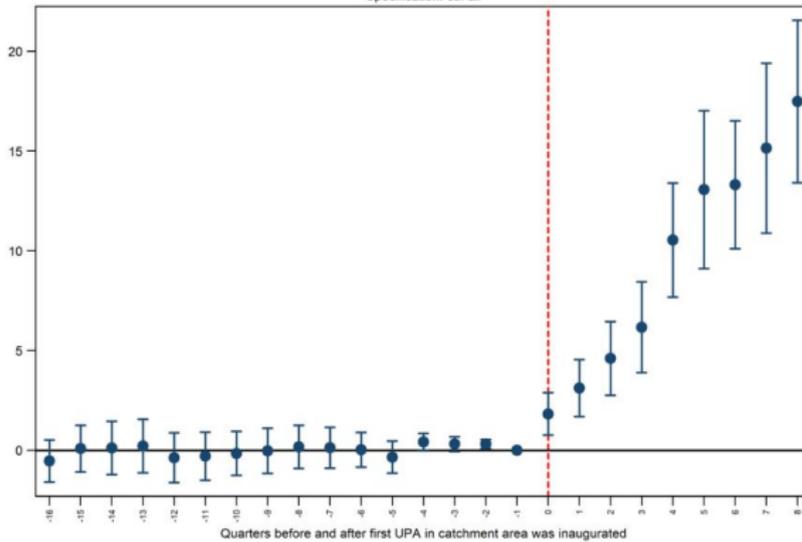






DD Event Study - Deaths in the UPA by 100,000 people

Specification: ctri all



Regionalização



- Saúde: muitos problemas (desafios) à frente.
- Para quem está na área, momento é extraordinariamente interessante:
 - Pesquisadores
 - Gestores
 - Empreendedores
- Inovações podem seguramente induzir ganhos de saúde e ganhos de eficiência. Mas:
 - Não necessariamente resolvem problemas de gastos, muito pelo contrário.
 - Não podemos descuidar da equidade...

