


ipea DATA lab


Ago/2024

Integração de Registros Administrativos

Motivação




Use of Pre-Existing Survey Data in Publications in Leading Journals, 1980-2010



Note: "Pre-existing survey" datasets refer to micro surveys such as the CPS or SIPP and do not include surveys designed by researchers for their study. Sample excludes studies whose primary data source is from developing countries.

Use of Administrative Data in Publications in Leading Journals, 1980-2010



Note: "Administrative" datasets refer to any dataset that was collected without directly surveying individuals (e.g., scanner data, stock prices, school district records, social security records). Sample excludes studies whose primary data source is from developing countries.

Motivação


- Silos de dados
- Integração para
 - Melhorar a avaliação de políticas públicas
 - Melhorar a provisão de serviços públicos



Interoperabilidade

- Iniciativa de interoperabilidade
 - Ministério do Planejamento: Secretaria Executiva, Seplan, STI
 - IPEA
 - Serpro
 - Dataprev
- Obtenção de bases de dados
- Cruzamentos de dados
- Apoio ao CMAP

Interoperabilidade



Iniciativas

Iniciativas de integração de registros administrativos

ipeaDATA lab

SERPRO

cidacs
Centro de Integração de Dados
e Conhecimentos para a Saúde

TCU
LabContas

CGU

OBSERVATÓRIO
da Despesa Pública

DATAPREV

GOVDATA

ipea DATA lab

Objetivo

- Obter, organizar e integrar registros administrativos do Governo Federal
- BMAPP: Base para Monitoramento e Avaliação de Políticas Públicas
 - Acompanhar cidadãos e empresas, do nascimento à morte, nas diversas esferas da vida
 - Benefícios sociais recebidos
 - Saúde
 - Educação
 - Renda
 - Produtividade
 - Reconstruir Vínculos Familiares
- Usar a BMAPP para subsidiar as avaliações do Ipea, especialmente CMAPP

Objetivo

- Avaliação de impacto

$$y_{i, t} = \alpha + \beta * P_{i, t}$$

- Onde:
 - i: indivíduo/empresa
 - t: período



Política
pública

Objetivo

- Avaliação de impacto

$$y_{i,t} = \alpha + \beta * P_{i,t} + \delta * X_{i,t}$$

- Onde:
 - i: indivíduo/empresa
 - t: período

Controles
indivíduo

Política
pública

Objetivo

- Avaliação de impacto

$$y_{i,f,t} = \alpha + \beta * P_{i,f,t} + \delta * X_{i,t} + \gamma * H_{f,t}$$

- Onde:

- i: indivíduo/empresa
- t: período
- f: família/grupo

Controles
indivíduo

Política
pública

Controles
família

Objetivo

- Avaliação de impacto

Educação
Saúde
Emprego
...

$$y_{i,f,t} = \alpha + \beta * P_{i,f,t} + \delta * X_{i,t} + \gamma * H_{f,t}$$


- Onde:
 - i: indivíduo/empresa
 - t: período
 - f: família/grupo

Controles
indivíduo


Política
pública

Controles
família

Objetivo




Objetivo



Princípios

- Segurança, privacidade
- Simplicidade, documentação
- Default: baseado em R (software livre)
- Desenvolvimento ágil
 - Controle de versão (git, gitlab)
 - Gerenciamento por issues (git, gitlab)
 - Prototipagem rápida



Equipe

- Equipe multidisciplinar, 12 pessoas
 - Economistas
 - Cientistas sociais
 - Cientistas da computação
 - Estatísticos



Segurança



Nível 1:

Pastas restritas

Nível 2

Servidor Restrito

Nível 3:

Sala do Sigilo

Termo de responsabilidade



Entrada e saída controlada e rastreável



Acesso remoto em máquinas controladas



Isolamento lógico



Isolamento físico



Controle biométrico de acesso




Monitoramento: presencial e por vídeo



Comitê de avaliação dos pedidos de liberação




Ex1: Família-BPC vs Família-CadÚnico



Fonte: [Mation e Moares \(2015\)](#)

Ex1: Família-BPC vs Família-CadÚnico




Fonte: [Mation e Moares \(2015\)](#)

Ex1: Família-BPC vs Família-CadÚnico

Merge	Número de observações
Só GRUFAM	4.668.301
Matched	2.289.602
Só CadÚnico Reclassificado	1.485.713
Total	8.443.616

Nota: Resultado após retirada das duplicatas nas chaves


Reclassificações	N. de pessoas	(%)
Correta	2.279.966	99,6%
Errada	9.639	0,4%
Total	2.289.605	100,0%



Fonte: [Mation e Moares \(2015\)](#)

Ex2: Geocode

- Harmonização de endereços
 - Separação de campos (tipo, logradouro, N, complemento)
 - Harmonização por campo (ex: cs, casa, c.)
 - Correção de *typos*
- Geocode
 - Base proprietária
 - + CNEFE
- Aplicações:
 - Afetados enchentes RS



Limitações dos Registros Adm. Brasileiros

- Historicamente: Mundo PIS (Dataprev) vs Mundo CPF (Serpro)
- Falta de vínculos familiares explícitos

RAs: riscos e oportunidades

- Conhecimento substantivo de cada registro administrativo
 - Conhecer do significado das variáveis, motivação para coleta do dado
- Manutenção do acesso
 - Consolidar jurisprudência/entendimento da LGPD
- Multiplicidades de salas do sigilo

Fronteiras de pesquisa

- Registros Administrativos + pesquisas domiciliares
 - US Census, Statistics Canada, Norway, etc ...
 - Mais relevante no Brasil. INFORMALIDADE
 - Valida informações da pesquisa
 - Mostra limites do registro administrativo
- Pareamento com arquivos históricos, genealógicos
 - Dados educacionais

Softwares Desenvolvidos

- [microdadosBrasil](#)
 - Facilita a leitura de microdados públicos brasileiros
 - branch [microdadosBrasil](#)-RA : facilita a leitura de registros administrativos
- [validaRA](#)
 - Facilita validação de dados de registros administrativos brasileiros
 - doc2integer64 : converte documentos para numérico retirando “-”, “.”, etc
 - valida_doc : verifica dígito verificador de CPF, PIS, CNPJ, CNS, etc...
 - relatorioDOC : gera relatório descrevendo a qualidade dos dados
 - missings, duplicidades de identificadores, histogramas
- [geobr](#)