



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE MATEMÁTICA
DEPARTAMENTO DE ESTATÍSTICA



Efeito do Plano Amostral Complexo na Análise de Índices de Utilidade

Autor: Juliana Feliciati Hoffmann
Orientador: Professora Dra. Suzi Alves Camey

Porto Alegre, 1º de Dezembro de 2010

Universidade Federal do Rio Grande do Sul
Instituto de Matemática
Departamento de Estatística

Efeito do Plano Amostral Complexo na Análise de Índices de Utilidade

Autor: Juliana Feliciati Hoffmann

Monografia apresentada para obtenção
do grau de Bacharel em Estatística.

Banca Examinadora:
Professora Dra. Suzi Alves Camey
Professor Dr. Álvaro Vigo

Porto Alegre, 1º de Dezembro de 2010

Agradecimentos

Aos meus pais amados, Ana Maria e José, pelo exemplo de vida. Por sempre me disponibilizarem as melhores condições de educação e por me ensinarem a importância do estudo.

Aos meus queridos irmãos, Cris e Márcio, pela amizade incondicional.

À Suzi, por todos seus ensinamentos, pelas horas de dedicação a esse trabalho e pela paciência. Pela orientação em mais um trabalho e também na vida profissional.

À Luciane Cruz, pela oportunidade de trabalhar com os dados de sua tese de doutorado. Pela disponibilidade para esclarecimento de dúvidas, pelas contribuições a esse trabalho e pelo convívio e coleguismo desde o início do Projeto Quali.

Ao professor Álvaro Vigo, por compor a banca examinadora e contribuir para o aperfeiçoamento deste trabalho.

A todos os professores do curso de graduação em estatística, pelos seus ensinamentos ao longo do curso.

Aos colegas, que se tornaram também grandes amigos, em especial a Marina, Maria Cláudia, Fernanda, Cristiane, Silvana e Marcel, pelo convívio, pela amizade e pelo apoio em todos os momentos. Sem a ajuda de vocês a caminhada teria sido ainda mais difícil.

Este artigo será submetido à "REVISTA HCPA".

Efeito do Plano Amostral Complexo na Análise de Índices de Utilidade

Complex Survey Effect in analysis of utility index

Título abreviado: Efeito do Plano Amostral Complexo

Juliana Feliciati Hoffmann¹

Luciane Nascimento Cruz³

Suzi Alves Camey^{1,2}

1. Departamento de Estatística, Instituto de Matemática, Universidade Federal do Rio Grande do Sul (UFRGS). 2. Grupo de Pesquisa e Pós-Graduação, HCPA. 3. Programa de Pós-graduação em Epidemiologia, UFRGS.

O trabalho foi realizado no Departamento de Estatística, Instituto de Matemática, Universidade Federal do Rio Grande do Sul (UFRGS).

Contato: Juliana Feliciati Hoffmann, e-mail: julianafhoffmann@gmail.com (Porto Alegre, RS, Brasil).

Monografia apresentada para obtenção do grau de Bacharel em Estatística, em 13 de dezembro de 2010.

Resumo

Introdução: Os índices de utilidade são medidas de desfecho atualmente preconizadas para uso em análises econômicas e que geram a unidade denominada QALY (Quality Adjusted Life Years) que agrega qualidade de vida e sobrevida em uma única medida. Muitos estudos utilizam planos amostrais complexos (PAC) nas adaptações culturais deste tipo de instrumento, mas não incorporam essa característica na análise dos dados. Em estudos de QV e utilidade não se sabe o efeito do PAC nos modelos finais.

Objetivo: Avaliar o efeito do plano amostral em um estudo de para adaptação cultural do instrumento SF-6D.

Métodos: Estudo transversal de base populacional (n=469) realizado em Porto Alegre, usando amostragem por conglomerados. Foram aplicados o instrumento SF-6D e o *Standard gamble*. Para estimar utilidade foram ajustados 4 modelos diferentes, sendo 2 OLS (Ordinary Least Square) e 2 modelos multinível. Calculou-se o efeito do plano amostral (EPA) para avaliar o efeito da amostragem por conglomerados e o coeficiente de correlação intraclasse (CCI) para avaliar a necessidade de modelagem multinível.

Resultados: Para os modelos OLS a maioria dos valores de EPA foi menor que 1. Os valores de CCI indicam que a modelagem multinível é adequada nesse estudo. Os modelos multinível tiveram menores erros padrões que os modelos OLS.

Discussão: Os modelos multinível foram melhores que os modelos OLS, mesmo quando o modelo OLS inclui o efeito de setor censitário, indicando a importância da inclusão de efeitos aleatórios. Entre os modelos multinível, a incorporação do efeito aleatório do setor censitário melhorou a qualidade do modelo.

Conclusões: Recomenda-se a incorporação da amostragem por conglomerados na análise de dados de utilidade, utilizando modelos multinível.

Descritores: Amostragem por Conglomerados, Análise Multinível, Qualidade de Vida

Abstract

Introduction: Utility values are outcome measures recommended nowadays for use in economic analysis. They generate an unit called QALY (Quality Adjusted Life Years) which aggregates quality of life and survival in one measure. Many studies use complex survey sample (CSS) in the cultural adaptations of this kind of instrument, but do not consider it when analyzing data. In QOL and utility studies the effect of CSS in the final models is unknown.

Objective: Evaluate the effect of sampling plan in a study for cultural adaptation of the instrument SF-6D..

Methods: Cross-sectional population-based study (n=469) made in Porto Alegre, through cluster sampling. SF-6D and Standard gamble have been applied. In order to estimate utility, 4 different models were adjusted, 2 Ordinary Lest Square (OLS) and 2 multi-level models. Design effect (*deff*) was calculated to evaluate the effect of cluster sampling and intraclass correlation coefficient (ICC) to evaluate the need of multi-level modeling.

Results: For OLS models most of *deff* values were smaller then 1. ICC values indicate multi-level modeling is adequate in this study. Multi-level models had smaller standard errors then OLS models.

Discussion: Multi-level modeling was better then OLS models, even when OLS models included the effect of cluster, showing how important is the inclusion of random effects. Among multi-level models, incorporating random effect of cluster improved model quality.

Conclusions: It's recommended incorporating cluster sampling in analysis of utility data, through multi-level modeling

Keywords: Cluster Sampling, Multilevel Analysis, Quality of Life

Introdução

As medidas de utilidade são um tipo de medida de qualidade de vida (QV) que pode ser utilizada em análises econômicas em saúde, como uma medida de desfecho para avaliar as diferentes intervenções e programas (1). Recentemente também tem sido incorporadas em avaliações de tecnologia em saúde e nos processos de tomada de decisão em políticas públicas de saúde (1).

No cenário brasileiro, a pesquisa em QV vem crescendo, e instrumentos genéricos de uso disseminado no mundo todo, como o *Medical Outcomes Study Short-Form 36 (SF-36)* (2), já estão traduzidos e validados para a população brasileira. Porém, estes instrumentos não são adequados como uma medida de efetividade em estudos de custo-efetividade, pois não incorporam em seu constructo as preferências dos indivíduos por determinados estados de saúde. Estes métodos baseados em preferências geram um índice denominado índice de utilidade, que podem dar origem aos QALYs (Quality Adjusted Life Years), que são as medidas de desfecho recomendadas para uso em estudos de custo-efetividade e agregam, em uma única medida, qualidade de vida e sobrevida (1).

O desenvolvimento das medidas baseadas em preferências compõe-se de 3 estágios principais: 1) composição de um sistema descritivo que poderá gerar diferentes estados de saúde em várias dimensões; 2) seleção de uma amostra de estados de saúde para quantificação das preferências de um grupo de indivíduos através de técnicas padronizadas; 3) construção de um algoritmo através de modelos de regressão utilizando os valores obtidos na etapa 2. Esta equação tem como objetivo estimar os valores de preferências para todos os outros estados de saúde gerados pelo instrumento (1). Para a fase 2 deste processo, geralmente, são realizados estudos de base populacional que envolvem planos amostrais complexos (PAC), os quais podem ter uma ou mais das seguintes características: conglomerados, estratificação ou probabilidades desiguais de seleção (3). O uso de regressão convencional para dados em conglomerados resulta em subestimação dos erros padrões, pois esse modelo não considera a similaridade das respostas entre observações do mesmo *cluster* (4). Erros padrões (EP) menores afetam as estatísticas de teste, as quais serão mais facilmente significativas estatisticamente (4).

Um dos métodos que pode ser utilizado para análise de dados amostrais complexos é a modelagem multinível, que permite estudar o efeito das variáveis ao nível de conglomerados sobre a variável dependente do nível individual (5). Cada estágio de amostragem corresponde a um nível na modelagem multinível, sendo que a unidade final de amostragem corresponde ao nível 1 e os conglomerados de cada estágio de amostragem constituem os demais níveis (6). Os modelos multinível resolvem o problema da subestimação dos EPs, pois incluem componentes aleatórios de efeitos do conglomerado no modelo, possibilitando a estimação dos verdadeiros EPs. Além disso, nesses modelos é possível decompor a variância total da variável dependente em 2 partes (entre e dentro dos conglomerados) e a variabilidade dos efeitos aleatórios através dos conglomerados também pode ser avaliada (4).

Muitos estudos utilizam PAC na coleta dos dados, mas não incorporam essa característica na análise dos mesmos (3). Em estudos que utilizam medidas de QV e utilidade não se sabe o efeito do PAC nos modelos finais. Um estudo utilizou o instrumento EQ-5D para medir QV, incorporando as características do plano amostral, mas não comparou os resultados do PAC versus amostragem aleatória simples (AAS) (7). O presente trabalho tem como objetivo avaliar o efeito do plano amostral em um estudo de QV e utilidade.

Métodos

Amostragem

Este foi um estudo transversal de base populacional (n=469) realizado na cidade de Porto Alegre. Utilizou-se amostragem por conglomerados (setores censitários (SC) definidos pelo Instituto Brasileiro de Geografia e Estatística) (8), selecionando-se aleatoriamente 118 SC de um total de 2157. Dentro de cada SC, sete domicílios foram selecionados sistematicamente, e em cada residência foram convidados a participar todos os moradores que preenchessem os seguintes critérios de inclusão: ter entre 20 e 64 anos de idade, ser alfabetizado e não ser portador de nenhuma doença física ou mental que impossibilitasse o preenchimento dos instrumentos.

Índice de Utilidade

Para obtenção dos índices de utilidade, que daqui em diante chamaremos apenas de utilidade, foi aplicado o instrumento *SF-6D* (9) e o *Standard gamble* (10) para medir as preferências da população pelos estados de saúde gerados pelo instrumento SF-6D. O *SF-6D* é um sistema descritivo derivado do instrumento psicométrico SF-36, gerando 18000 possíveis estados de saúde. Os estados de saúde resultam da combinação de um nível de cada um dos 6 domínios que compõem o instrumento ($6 \times 4 \times 5 \times 6 \times 5 \times 5$), conforme apresentado na figura complementar 1, em anexo. Para este estudo foi utilizada uma amostra aleatória de 247 estados intermediários para serem avaliados, além do melhor e do pior estado. Cada participante avaliou 5 estados de saúde, além do pior estado de saúde.

A técnica do *standard gamble* inicia apresentando ao entrevistado uma descrição de um dos estados de saúde gerados pelo SF-6D. Após, o entrevistado é orientado a imaginar a situação hipotética na qual ele é confrontado com uma escolha. As opções são continuar a viver no estado descrito ou optar por um *gamble* (“aposta”). Esta “aposta”, representada pela hipótese de realizar um tratamento, tem 2 possíveis desfechos. O melhor desfecho seria o tratamento ter sucesso e ocorrer recuperação imediata da saúde perfeita, com uma probabilidade “p”. O pior desfecho seria falha no tratamento levando ao pior estado de saúde do SF-6D, com probabilidade “1-p”. Estas probabilidades variam de forma sistemática, até que o entrevistado seja indiferente entre manter-se no mesmo estado intermediário ou aceitar a “aposta” (1).

Variáveis

As seguintes variáveis sócio-demográficas foram coletadas com a aplicação de um questionário: sexo, idade, raça, estado civil, religião, escolaridade, ocupação. Através do *standard gamble* foram obtidas as utilidades dos estados de saúde avaliados.

Análises estatísticas

Foram excluídos 58 casos que não fizeram avaliação do pior estado, dado que essa variável era necessária para calcular a utilidade ajustada, utilizada nos modelos (9).

A fim de estimar utilidade para os 18.000 estados de saúde foram ajustados diferentes modelos, com o objetivo de encontrar aquele com melhor desempenho. Todos os modelos restringem o intercepto à unidade, visando garantir que o estado de saúde 111111, que representa saúde plena, tenha utilidade “1”. Assim, a variável dependente a ser estimada é “1 – utilidade”. Considerando esse desfecho, é intuitivo pensar que os valores dos coeficientes estimados das variáveis indicadoras representando cada nível do SF-6D, dentro de cada domínio, deveriam aumentar em valor absoluto conforme os níveis vão aumentando (indicando uma piora no estado de saúde avaliado). Quando isso não ocorreu (modelos com inconsistências) os níveis dos domínios foram agrupados, até a obtenção de coeficientes consistentes (modelos sem inconsistências).

Modelos

Diversos modelos podem ser ajustados para prever os valores de utilidade gerados pelo *standard gamble*, sendo que o modelo geral é definido como:

$$y_{ij} = \beta_{\lambda\delta} x_{ij} + \varepsilon_{ij}, i = 1, 2, \dots, 247; j = 1, 2, \dots, n. \quad (1)$$

Onde i é o índice para os estados de saúde e j é o índice para os respondentes. A variável dependente y_{ij} , conforme citado anteriormente, é “1 – utilidade” do estado de saúde i avaliado pelo respondente j . x_{ij} é um vetor de variáveis indicadoras para cada domínio e nível do estado de saúde i , ou seja, $x_{ij} = (x_{ij\lambda 1}, x_{ij\lambda 2}, \dots, x_{ij\lambda 6})$ onde:

$$x_{ij\lambda\delta} = \begin{cases} 1, & \text{se para o estado de saúde } i \text{ o domínio } \delta \text{ está no nível } \lambda \\ 0, & \text{se para o estado de saúde } i \text{ o domínio } \delta \text{ não está no nível } \lambda \end{cases}$$

Assim, x_{ij32} denota que no estado de saúde i o domínio $\delta = 3$ (aspectos sociais) está no nível $\lambda = 2$ (a saúde limita atividades sociais em uma pequena parte do tempo).

Foram ajustados 4 modelos. Os modelos 1 e 2 são modelos de mínimos quadrados ordinários (Ordinary Least Square – OLS), considerando uma função de ligação linear. Para esses modelos serão apresentados apenas os resultados com inconsistências. No modelo 1 considerou-se apenas o efeito dos níveis de cada estado de saúde sobre o desfecho. Para ajuste desse modelo no R (11) foi utilizada a função de modelos lineares generalizados `glm`, sem especificação da família de ligação, uma vez que trata-se de regressão linear. O modelo 2

diferencia-se do modelo 1 na medida em que incorpora, além do efeito dos níveis de cada estado de saúde, o efeito do SC. Para o ajuste desse modelo foi utilizada a função `svyglm` do pacote `survey` (12) do R. O modelo geral apresentado em (I) aplica-se em ambos os casos, sendo ε_{ij} o erro fixo do modelo.

Os modelos 3 e 4 são modelos multinível com efeitos aleatórios. Para esses modelos serão apresentados os resultados com e sem inconsistências. O modelo 3 incorpora o efeito aleatório do sujeito e do sujeito dentro do setor, enquanto o modelo 4 considera apenas o efeito aleatório do sujeito. Para os modelos 3 e 4 foi utilizada a função `lme` do R, que se refere a modelos lineares de efeitos mistos. Podemos usar o modelo geral (I) para explicitar o modelo 4, considerando, nesse caso, que ε_{ij} é um termo de erro aleatório para sujeito. Para descrição do modelo 3 com base em (I), é necessário decompor ε_{ij} em dois erros aleatórios:

$$\varepsilon_{ij} = \mu_{0j} + e_{0ij},$$

Onde μ_{0j} é o erro aleatório para SC e e_{0ij} é o termo de erro aleatório para sujeito.

Medidas de ajuste dos modelos

Os modelos foram avaliados de acordo com critérios bem difundidos na área econômica, na qual as medidas de utilidade estão inseridas: (1): a) erro médio absoluto (mean absolute error - MAE), e proporção de predições com erro acima de 0,05 (% AE > 0,05) e de 0,10 (% AE > 0,10); b) as predições foram testadas em termos de viés através de teste t, para checar se a média dos resíduos era igual a zero; c) normalidade dos resíduos foi verificada através do teste Jarque-Bera – JB; d) A presença de autocorrelação dos resíduos foi analisada através da estatística de Ljung-Box-LB.

Avaliação do efeito do plano amostral

Para avaliar o efeito do PAC sobre a variância do estimador foi calculado o valor do Efeito do Plano Amostral (EPA) nos modelos OLS: (13)

$$EPA(\hat{\theta}) = \frac{V_{verd}(\hat{\theta})}{V_{AAS}(\hat{\theta})},$$

Onde V_{verd} é a variância do estimador considerando o PAC (verdadeiro) e V_{AAS} é a variância do estimador considerando plano de AAS.

Nos modelos mistos foi calculado o valor do Coeficiente de Correlação Intraclasse (CCI) para os modelos nulos (sem covariáveis) e para os modelos completos (considerando os estados de saúde como covariáveis). O CCI pode ser definido como:

$$CCI = \frac{\sigma_{\mu_0}^2}{\sigma_{\mu_0}^2 + \sigma_{e_0}^2},$$

Onde, para o modelo 3: (3)

$\sigma_{\mu_0}^2$ é a variância do nível 2 (setor)

$\sigma_{e_0}^2$ é a variância do nível 1 (sujeito)

E para o modelo 4: (14)

$\sigma_{\mu_0}^2$ é a variância do intercepto

$\sigma_{e_0}^2$ é a variância residual

Usaremos a mesma notação para as variâncias dos dois modelos.

Resultados

A tabela 1 apresenta as características sócio-demográficas da amostra estudada. A idade média foi de 41,4 anos (DP=12,7), sendo que 58,6% da amostra (n=275) eram do sexo masculino.

Tabela 1. Características sócio-demográficas da amostra

Variáveis	N (Total=469)	%
Idade (média e DP)	41,4 (12,7)	
Sexo		
Masculino	194	41,4
Feminino	275	58,6
Raça		
Branco	382	81,4
Negro	45	9,6
Pardo	29	6,2
Outros	13	17,5
Religião *		
Sim	246	52,5
Não	223	47,5
Estado civil		
Casado	296	63,1
Não casado	173	36,9
Anos de estudo*		
Até 4	23	4,9
5 a 8	87	18,7
9 a 11	163	35,0
12 ou mais	193	41,4
Ocupação (%)*		
Empregado	135	29,0
Emprego informal	35	7,5
Desempregado	32	6,9
Dona de casa	73	15,7
Estudante	20	4,3
Aposentado	34	7,3
Outros	137	29,4

DP: desvio padrão; *Variáveis com dados faltantes

A tabela 2 mostra os principais resultados dos modelos 1 e 2. As estimativas dos coeficientes de ambos os modelos são iguais, como era esperado, mudando apenas os valores do EP. Os valores de EPA foram, para a maioria das variáveis, menores que 1. Apenas os níveis 3 e 5 do domínio 4 e o nível 2 do domínio 6 apresentaram valores de EPA maiores que 1. Em termos de predição dos modelos, ambos apresentaram resultados idênticos. O MAE foi de 0,1111, sendo que a proporção de erros de predição acima de 0,1 e 0,05, respectivamente, foi 72,7% e 49,0%. As predições do modelo são não-viciadas (teste-t com valor-p > 0,05) e os erros são normalmente distribuídos (teste JB). Entretanto, a estatística de Ljung-Box-LB indica presença de autocorrelação dos resíduos, como pode ser visualizado na figura 1 (a e b). Pode-se observar nessa figura que existe uma tendência de subestimar as medidas de utilidade de estados de saúde mais baixos e superestimar valores mais altos.

Tabela 2. Estimativas do coeficiente, erro padrão das estimativas e nível de significância para cada modelo ajustado

Variáveis	Modelo 1			Modelo 2			
	Estimativa	EP	Pr(> t)	Estimativa	EP	Pr(> t)	EPA
Domínio1_2	0,0993	0,0271	0,0002	0,0993	0,0226	<0,0001	0,837
Domínio1_3	0,1000	0,0266	0,0002	0,1000	0,0236	0,0001	0,888
Domínio1_4	0,1397	0,0279	<0,0001	0,1397	0,0268	<0,0001	0,960
Domínio1_5	0,0776	0,0270	0,0041	0,0776	0,0240	0,0019	0,890
Domínio1_6	0,1879	0,0275	<0,0001	0,1879	0,0255	<0,0001	0,924
Domínio2_2	0,1005	0,0216	<0,0001	0,1005	0,0196	<0,0001	0,906
Domínio2_3	0,0832	0,0227	0,0002	0,0832	0,0207	0,0001	0,911
Domínio2_4	0,0945	0,0228	<0,0001	0,0945	0,0218	<0,0001	0,955
Domínio3_2	0,0780	0,0233	0,0008	0,0780	0,0210	0,0004	0,904
Domínio3_3	0,0793	0,0242	0,0011	0,0793	0,0207	0,0003	0,855
Domínio3_4	0,1282	0,0243	<0,0001	0,1282	0,0194	<0,0001	0,799
Domínio3_5	0,1390	0,0257	<0,0001	0,1390	0,0226	<0,0001	0,877
Domínio4_2	0,1386	0,0248	<0,0001	0,1386	0,0241	<0,0001	0,971
Domínio4_3	0,1221	0,0259	<0,0001	0,1221	0,0286	0,0001	1,104
Domínio4_4	0,0787	0,0265	0,0030	0,0787	0,0245	0,0020	0,923
Domínio4_5	0,1508	0,0256	<0,0001	0,1508	0,0261	<0,0001	1,019
Domínio4_6	0,1698	0,0249	<0,0001	0,1698	0,0235	<0,0001	0,944
Domínio5_2	0,1125	0,0258	<0,0001	0,1125	0,0248	<0,0001	0,961
Domínio5_3	0,1139	0,0268	<0,0001	0,1139	0,0255	<0,0001	0,949
Domínio5_4	0,0703	0,0269	0,0091	0,0703	0,0260	0,0085	0,965
Domínio5_5	0,1456	0,0273	<0,0001	0,1456	0,0252	<0,0001	0,922
Domínio6_2	0,0872	0,0239	0,0003	0,0872	0,0250	0,0008	1,045
Domínio6_3	0,0385	0,0262	0,1415	0,0385	0,0218	0,0820	0,834
Domínio6_4	0,0657	0,0261	0,0119	0,0657	0,0225	0,0047	0,862
Domínio6_5	0,1017	0,0266	0,0001	0,1017	0,0243	0,0001	0,911
MAE	0,1111			0,1111			
N° > 0,05	72,7%			72,7%			
N° > 0,10	49,0%			49,0%			
Teste t (média=0)	0,1031			0,1031			
Normalidade	0,5626			0,5626			
Autocorrelação	0,00023			0,00023			

Modelo 1: Modelo OLS com efeito dos níveis de cada estado de saúde

Modelo 2: Modelo OLS com efeito dos níveis de cada estado de saúde e efeito do setor censitário

MAE: do inglês *mean absolute error*, que significa erro médio absoluto

A tabela 3 apresenta os resultados dos modelos 3 e 4, com inconsistências. Podemos perceber que a inclusão do efeito aleatório de setor, no modelo 3, fez com que as estimativas dos coeficientes ficassem com valores menores, ou seja, um menor desconto no valor da utilidade. Os EPs também diminuíram, com exceção dos níveis 2 e 5 do domínio 4 e do nível 2 do domínio 6, que aumentaram, e do nível 2 do domínio 1, nível 2 do domínio 2, nível 3 do domínio 3 e nível 4 do domínio 6, que permaneceram iguais. O MAE foi menor no modelo 3 e a proporção de erros de predição acima de 0,1 e 0,05 também foi menor nesse modelo. As predições dos modelos podem ser consideradas não-viciadas, uma vez que o teste-t apresentou $p > 0,05$, e a estatística de Ljung-Box-LB indica ausência de autocorrelação dos resíduos. Não podemos assumir distribuição normal dos erros em nenhum dos dois modelos, uma vez que o teste JB rejeitou a hipótese nula de normalidade. Como pode ser visualizado na figura 1 (c e d), existe uma tendência de subestimar as medidas de utilidade de estados de saúde com valores mais baixos de preferência. Podemos observar que $\sigma_{\epsilon_0}^2$ é maior que $\sigma_{\mu_0}^2$ no modelo 3, enquanto no modelo 4 ocorre o contrário. Quando incluímos o efeito do setor, no modelo 3, $\sigma_{\mu_0}^2$ fica muito próximo de zero (0,0021), indicando que se não considerarmos os estados de saúde (covariáveis do modelo completo), essa variabilidade poderia ser descartada. No modelo 3 completo a variância do setor ($\sigma_{\mu_0}^2$) aumentou em relação ao modelo nulo. Quando ajustados os modelos completos o CCI do modelo 3 continuou sendo menor (0,4047) do que o do modelo 4 (0,6880).

Tabela 3. Estimativas do coeficiente, erro padrão das estimativas e nível de significância para cada modelo ajustado, com inconsistências

Variáveis	Modelo 3			Modelo 4		
	Estimativa	EP	Pr(> t)	Estimativa	EP	Pr(> t)
Domínio1_2	0,0534	0,0173	0,0020	0,0874	0,0173	<0,0001
Domínio1_3	0,0490	0,0167	0,0034	0,0709	0,0169	<0,0001
Domínio1_4	0,0804	0,0176	<0,0001	0,1045	0,0178	<0,0001
Domínio1_5	0,0501	0,0168	0,0028	0,0644	0,0171	0,0002
Domínio1_6	0,1544	0,0173	<0,0001	0,1779	0,0175	<0,0001
Domínio2_2	0,0506	0,0138	0,0003	0,0767	0,0138	<0,0001
Domínio2_3	0,0486	0,0143	0,0007	0,0657	0,0145	<0,0001
Domínio2_4	0,0705	0,0144	<0,0001	0,0893	0,0146	<0,0001
Domínio3_2	0,0289	0,0151	0,0556	0,0638	0,0150	<0,0001
Domínio3_3	0,0416	0,0153	0,0064	0,0675	0,0153	<0,0001
Domínio3_4	0,0767	0,0156	<0,0001	0,1026	0,0157	<0,0001
Domínio3_5	0,0928	0,0161	<0,0001	0,1146	0,0163	<0,0001
Domínio4_2	0,0618	0,0164	0,0002	0,1058	0,0161	<0,0001
Domínio4_3	0,0406	0,0164	0,0133	0,0684	0,0165	<0,0001
Domínio4_4	0,0474	0,0168	0,0049	0,0755	0,0169	<0,0001
Domínio4_5	0,0750	0,0165	<0,0001	0,1100	0,0164	<0,0001
Domínio4_6	0,1184	0,0157	<0,0001	0,1409	0,0158	<0,0001
Domínio5_2	0,0663	0,0163	<0,0001	0,0913	0,0164	<0,0001
Domínio5_3	0,0641	0,0168	0,0001	0,0888	0,0170	<0,0001
Domínio5_4	0,0700	0,0169	<0,0001	0,0909	0,0171	<0,0001
Domínio5_5	0,1120	0,0171	<0,0001	0,1336	0,0174	<0,0001
Domínio6_2	0,0066	0,0157	0,6760	0,0490	0,0154	0,0015
Domínio6_3	0,0164	0,0167	0,3257	0,0431	0,0168	0,0105
Domínio6_4	0,0101	0,0166	0,5428	0,0409	0,0166	0,0139
Domínio6_5	0,0582	0,0168	0,0005	0,0838	0,0169	<0,0001
MAE	0,05543			0,06408		
N° > 0,05	45,0%			49,8%		
N° > 0,10	14,9%			21,3%		
Teste t (média=0)	0,5923			0,0938		
Normalidade	0,03			0,0005		
Autocorrelação	0,4899			0,7118		
$\sigma_{\epsilon_0}^2$ a	0,0801			0,0635		
$\sigma_{\mu_0}^2$ a	0,0021			0,0822		
CCIa	0,0260			0,5642		
$\sigma_{\epsilon_0}^2$ b	0,0826			0,0438		
$\sigma_{\mu_0}^2$ b	0,0562			0,0965		
CCIb	0,4047			0,6880		

*a=modelo nulo; *b = CCI do modelo completo; Var: variância. Modelo 3: Modelo multinível considerando efeito aleatório de sujeito e de setor. Modelo 4: Modelo multinível considerando apenas o efeito aleatório de sujeito. MAE: do inglês *mean absolute error*, que significa erro médio absoluto.

$\sigma_{\epsilon_0}^2$: Variância do sujeito/residual; $\sigma_{\mu_0}^2$: Variância do setor/intercepto

As inconsistências dos valores dos coeficientes foram retiradas para o ajuste dos modelos finais, modelos 3 e 4 sem inconsistências. Resultando no modelo 3C onde foram reunidos os seguintes níveis de cada domínio - Domínio 1: níveis 2 e 3; níveis 4 e 5; Domínio 2: níveis 2 e 3; Domínio 4: níveis 2, 3 e 4; Domínio 5: níveis 2 e 3; Domínio 6: níveis 3 e 4;

No modelo 4C os níveis agrupados foram os seguintes - Domínio 1: níveis 2, 3, 4 e 5; Domínio 2: níveis 2 e 3; Domínio 4: níveis 2, 3 e 4; Domínio 5: níveis 2, 3 e 4; Domínio 6: níveis 2, 3 e 4.

Além disso, para os modelos finais também foram excluídos os coeficientes não significativos. Assim, no modelo 3C não constam os níveis 2, 3 e 4 do domínio 6.

Conforme apresentado na tabela 4, podemos observar que os modelos 3 e 4 sem inconsistências são distintos, apresentando coeficientes diferentes no modelo final. Aqui serão apresentados apenas os valores de CCI para o modelo completo, uma vez que o CCI dos modelos nulos já foi apresentado na tabela 3. A proporção de erros de predição acima de 0,1 e 0,05 aumentou no modelo 4C e diminuiu no modelo 3C. As predições dos modelos 3C e 4C podem ser consideradas não-viciadas, uma vez que o teste-t apresentou $p > 0,05$, e a estatística de Ljung-Box-LB indica ausência de autocorrelação dos resíduos. O teste JB rejeitou a hipótese nula de normalidade em ambos os modelos sem inconsistências. Nos modelos sem inconsistência os valores de CCI foram maiores do que nos modelos com inconsistências. A variância do setor no modelo 3C aumentou em relação ao modelo 3, passando de 0,0562 para 0,0719. A figura 1 (e) e (f) mostra que a predição do modelo 3C está bem próxima dos valores observados. Assim, esse modelo foi considerado o modelo final entre todos os que foram ajustados nesse estudo.

Tabela 4. Estimativas do coeficiente, erro padrão das estimativas e nível de significância para cada modelo ajustado, sem inconsistências

Modelo 3C				Modelo 4C			
Variáveis	Estimativa	EP	Pr(> t)	Variáveis	Estimativa	EP	Pr(> t)
Domínio1_23	0,0480	0,0143	0,0008	Domínio1_2345	0,0804	0,0134	<0,0001
Domínio1_45	0,0603	0,0146	<0,0001	Domínio1_6	0,1846	0,0171	<0,0001
Domínio1_6	0,1536	0,0170	<0,0001	Domínio2_23	0,0690	0,0121	<0,0001
Domínio2_23	0,0472	0,0120	0,0001	Domínio2_4	0,0839	0,0142	<0,0001
Domínio2_4	0,0654	0,0140	<0,0001	Domínio3_2	0,0629	0,0147	<0,0001
Domínio3_3	0,0273	0,0127	0,0316	Domínio3_3	0,0643	0,0148	<0,0001
Domínio3_4	0,0592	0,0132	<0,0001	Domínio3_4	0,0990	0,0152	<0,0001
Domínio3_5	0,0758	0,0139	<0,0001	Domínio3_5	0,1107	0,0160	<0,0001
Domínio4_234	0,0466	0,0127	0,0003	Domínio4_234	0,0855	0,0125	<0,0001
Domínio4_5	0,0689	0,0159	<0,0001	Domínio4_5	0,1089	0,0159	<0,0001
Domínio4_6	0,1163	0,0154	<0,0001	Domínio4_6	0,1439	0,0155	<0,0001
Domínio5_23	0,0618	0,0139	<0,0001	Domínio5_234	0,0832	0,0136	<0,0001
Domínio5_4	0,0695	0,0158	<0,0001	Domínio5_5	0,1233	0,0167	<0,0001
Domínio5_5	0,1110	0,0161	<0,0001	Domínio6_234	0,0441	0,0132	0,0009
Domínio6_5	0,0490	0,0117	<0,0001	Domínio6_5	0,0835	0,0163	<0,0001
MAE	0,05515				0,06578		
N° > 0,05	44,6%				51,0%		
N° > 0,10	14,1%				20,5%		
t (média=0)	0,7344				0,07245		
Normalidade	0,00290				0,003469		
Autocorrelação	0,5731				0,6513		
$\sigma_{e_0}^2$ ^b	0,0828				0,0437		
$\sigma_{\mu_0}^2$ ^b	0,0719				0,0983		
CCI ^b	0,4647				0,6925		

* b = CCI do modelo completo; Var: variância

Modelo 3: Modelo multinível considerando efeito aleatório de sujeito e de setor

Modelo 4: Modelo multinível considerando apenas o efeito aleatório de sujeito

MAE: do inglês *mean absolute error*, que significa erro médio absoluto

$\sigma_{e_0}^2$: Variância do sujeito/residual; $\sigma_{\mu_0}^2$: Var. do setor/intercepto

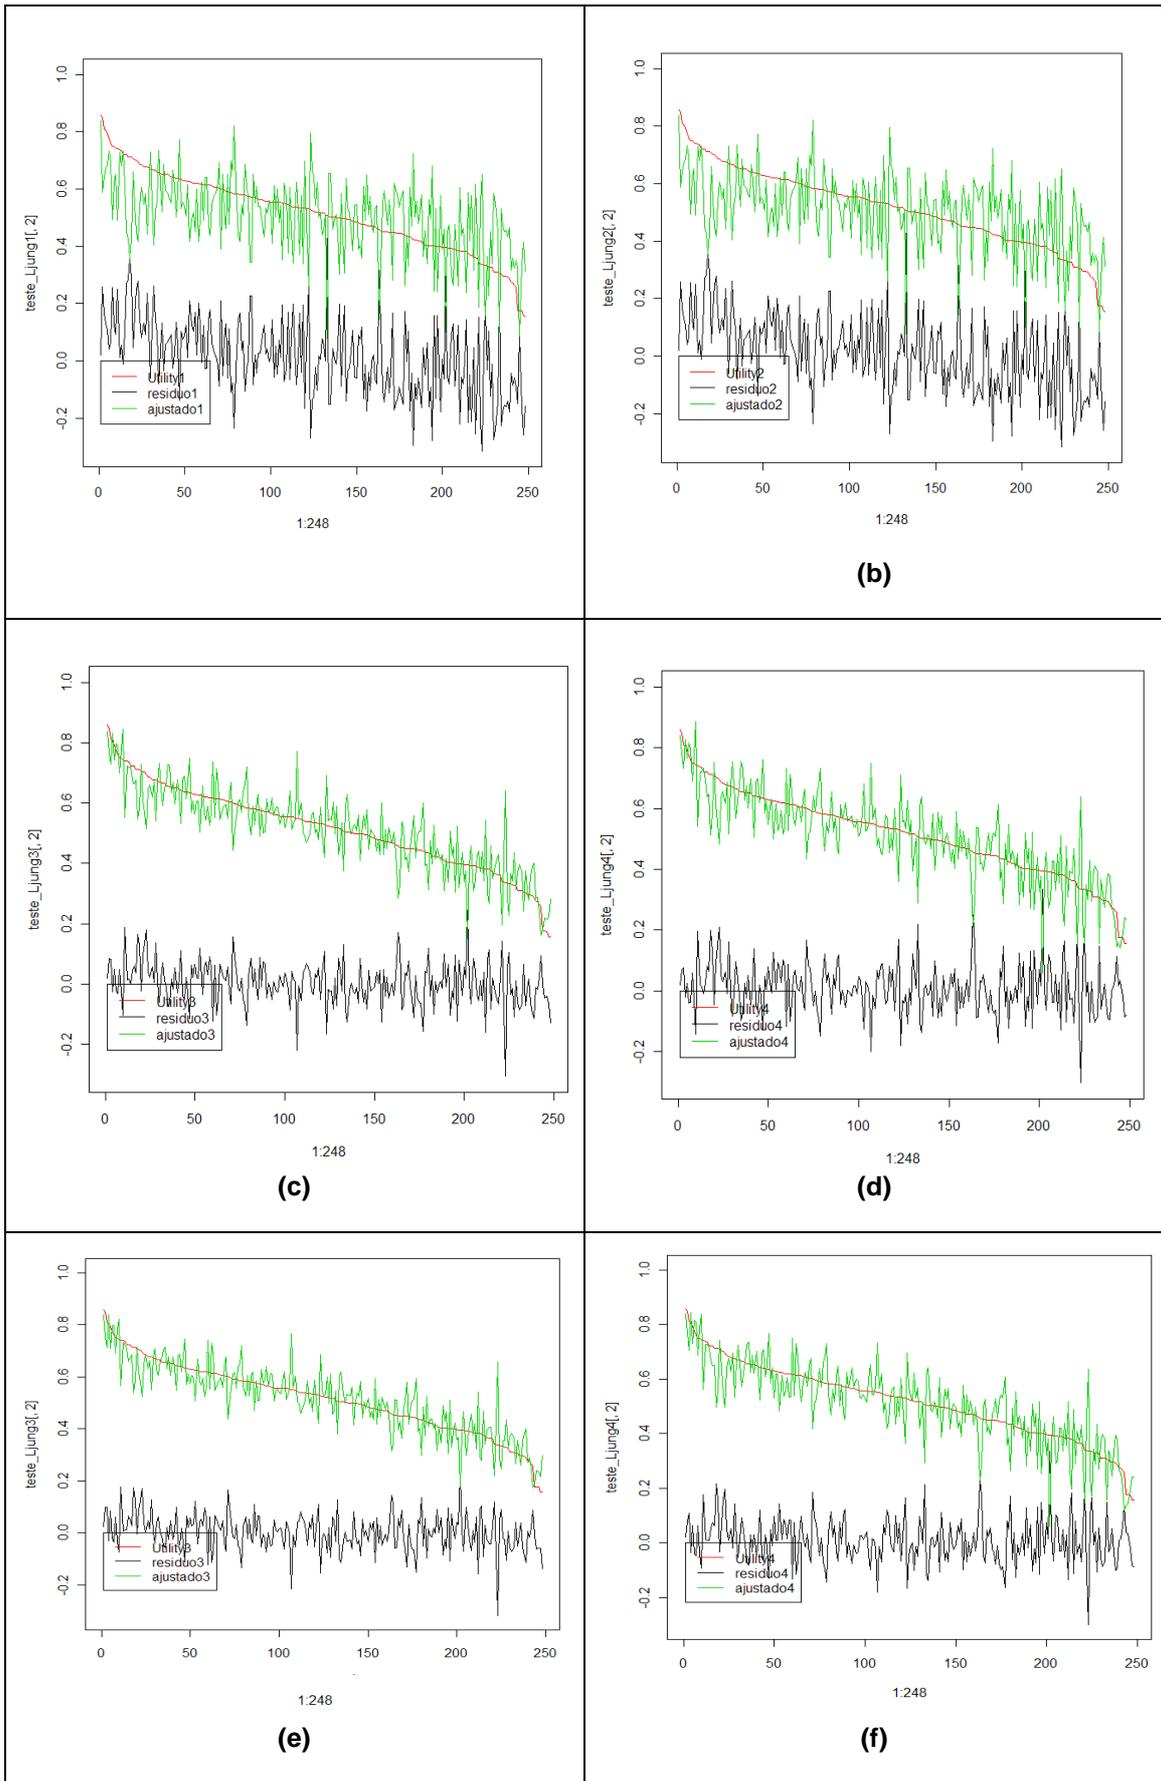


Figura 1: Valores de utilidade observados e preditos e resíduos dos modelos 1 (a), 2 (b), 3(c), 4(d), 3C(e), 4C (f).

Discussão

Muitas vezes torna-se inviável a realização de AAS, tanto por logística, como falta de uma listagem completa das unidades populacionais, quanto por custos elevados. A utilização de PAC é uma alternativa a essas dificuldades. Na amostragem por conglomerados os elementos da população são reunidos em grupos, os quais, por sua vez, são sorteados para compor a amostra. Num segundo estágio do plano amostral é possível sortear os indivíduos dentro de cada grupo. Entretanto, apesar de facilitar a seleção da amostra, ao utilizar PAC não podemos esquecer a sua influencia nos resultados finais e, portanto, deve ser considerado-lo no momento da análise, uma vez que pode levar a resultados diferentes da AAS.

Neste trabalho foram ajustados 4 modelos diferentes, sendo 2 OLS e 2 modelos multinível (2 com inconsistência e 2 sem inconsistências). Um dos modelos OLS ajustados inclui o efeito do conglomerado (modelo 2) e o outro supõe AAS. Quando fazemos ajuste para existência de conglomerado (setor censitário) a estimativa pontual não se altera, mas os EPs ficam menores, ao contrário do que é citado na literatura (4). Isso pode ser explicado pela variação pequena encontrada dentro dos SC, o que difere do que é esperado, uma vez que o ajuste para conglomerados pressupõe maior variabilidade dentro do conglomerado do que entre eles. Essa constatação nos leva a concluir que o ajuste para conglomerados não é adequado quando a variável em estudo tende a apresentar maior homogeneidade dentro dos conglomerados.

A maioria dos valores do EPA, quando comparamos os modelos 1 e 2, foi menor que 1, indicando que o estimador da variância obtido ignorando o PAC leva a superestimar a variância verdadeira do estimador (15). Quanto mais afastados de 1 estiverem os valores de EPA maior é a indicação de que ignorar o PAC na estimação da variância leva a estimativas viciadas e incorretas. Assim, podemos concluir que é importante considerar a amostragem por conglomerados na análise desses dados.

Na modelagem multinível foram ajustados inicialmente modelos com inconsistências nos coeficientes, sendo que um modelo considerava apenas o efeito do sujeito na variável dependente (modelo 4), enquanto o outro modelo considerava tanto o efeito do sujeito quanto o

efeito do setor censitário (modelo 3). Podemos perceber que nos modelos multinível mudaram também as estimativas dos coeficientes, e não apenas o EP.

Para avaliar a necessidade de modelagem multinível foram calculados os CCI para os modelos nulos e completos. O CCI avalia o grau de agrupamento ou dependência entre subgrupos de casos em dados aninhados. O CCI varia de 0, para completa independência das observações, até 1, para completa dependência. A utilização de regressão OLS assume um valor de CCI igual a zero. Segundo Perez et al (16), se dados provindos de conglomerados forem analisados como sendo AAS, as variabilidades serão subestimadas em magnitude que depende do CCI da variável que está sendo analisada. Isto é, quando a correlação é grande a variabilidade é subestimada em maior magnitude. Não há um consenso a cerca do ponto de corte do CCI, mas alguns estudos indicam que a modelagem multinível é indicada sempre que o CCI for maior que 0,05 (17) ou maior que 0,01 (18). Nesse estudo os valores de ICC para os modelos ajustados, tanto nulos quanto completos, variaram de 0,4047 a 0,6925, indicando que é adequado utilizar modelagem multinível.

Comparando os resultados obtidos, podemos observar que os modelos multinível foram muito melhores que os modelos OLS, mesmo quando o modelo OLS inclui o efeito de setor censitário, indicando a importância da inclusão de efeitos aleatórios no modelo. Os modelos multinível apresentaram menor proporção de erros de predição e resolveram o problema de autocorrelação dos resíduos. Entre os modelos multinível, a incorporação do efeito aleatório do SC melhorou ainda mais a qualidade da predição. Pela figura 1 é possível fazer uma comparação entre os modelos e é fácil visualizar que o modelo 3 apresenta menor variabilidade nos valores preditos e possui valores preditos mais próximos dos observados.

Os modelos finais sem inconsistências, 3C e 4C, são distintos, visto que foram agrupados os coeficientes inconsistentes. Até mesmo nesse aspecto o modelo 3C foi melhor, visto que o agrupamento dos níveis dos domínios foi menor que no modelo 4C, apesar dos níveis 2, 3 e 4 do domínio 6 terem sido agrupados ao nível 1 do mesmo domínio, indicando que só há perda na utilidade nesse domínio quando o estado de saúde compreende o nível.

Como limitação deste estudo, podemos citar a possível correlação entre os indivíduos do mesmo domicílio, que não foi considerada nas análises. Essa informação não foi coletada

durante as entrevistas, impossibilitando sua inclusão nas análises. Entretanto, acreditamos que esse efeito seja pequeno, pois poucas entrevistas foram realizadas no mesmo domicílio.

Conclusões

Os resultados encontrados neste trabalho são de grande importância na área de custo-efetividade em saúde. A partir dos resultados desse trabalho podemos concluir que o PAC não pode ser desconsiderado na análise de índices de utilidade. Os modelos obtidos considerando abordagem multinível apresentaram resultados distintos quando consideramos o efeito dos SC, além de possuírem melhor ajuste. Assim, recomenda-se a incorporação da estrutura do desenho amostral na análise de dados de utilidade, utilizando modelos multinível.

Referências

1. Cruz, LN. Medidas de Qualidade de Vida e Utilidade em uma amostra da população de Porto Alegre [Tese de doutorado]. Universidade Federal do Rio Grande do Sul, Programa de Pós-graduação em Epidemiologia; 2010.
2. Ware JE Jr., Sherbourne CD. The MOS 36-item short-form health survey (SF-36). I. Conceptual framework and item selection. *Med Care* 1992;30(6):473-83.
3. Battisti, IDE. Análise de dados epidemiológicos incorporando planos amostrais complexos [Tese de doutorado]. Universidade Federal do Rio Grande do Sul, Programa de Pós-graduação em Epidemiologia; 2008.
4. Sunhee P, Eileen TL. Multilevel Modeling of a Clustered Continuous Outcome: Nurses' Work Hours and Burnout. *Nurs Res*. 2005; 54(6): 406–413.
5. Asparouhov T, Muthen B. Multilevel Modeling of Complex Survey Data. Proceedings of the Joint Statistical Meeting; 2006 Aug 6-10; Seattle, United States.
6. Rabe-Hesketh S, Skrondal A. Multilevel modelling of complex survey data. *Journal of the Royal Statistical Society A* 2006, 169(4):805-27.
7. Shaw JW, Johnson JA, Coons SJ. US Valuation of the EQ-5D Health States - Development and Testing of the D1 Valuation Model. *Med Care* 2005;43: 203–220
8. Censo Populacional 2000. Instituto Brasileiro de Geografia e Estatística Available from: URL: www.ibge.gov.br. Acessado em 03.03.10
9. Brazier J, Roberts J, Deverill M. The estimation of a preference-based measure of health from the SF-36. *J Health Econ* 2002 Mar;21(2):271-92.
10. Von Neumann J, Morgenstern O. *Theory of Games and Economic Behavior*. 1st ed. Princeton: Princeton University Press; 1944.
11. R Development Core Team (2010). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0, URL <http://www.R-project.org/>.
12. Lumley T. Analysis of complex survey samples. *Journal of Statistical Software* 2004; 9(1): 1-19

13. Kish L. Survey sampling. New york: John Wiley; 1965.
14. Bliese, P. Multilevel Modeling in R (2.3) A brief Introduction to R, the multilevel package and the nlme package, 2009. Available from: URL: http://cran.r-project.org/doc/contrib/Bliese_Multilevel.pdf
15. Pessoa DGC, Silva PLN. Análise de dados amostrais complexos. São Paulo: ABE – Associação Brasileira de Estatística;1998.
16. Perez MC, Utra IB, León AA, Roche RG, Sagué KA, Rosa MC, et al. Estimaciones usadas em diseños muestrales complejos: aplicaciones em la encuesta de salud cubana Del año 2001. Rev. Panam. Salud Publica 2004; 15(3):176-84.
17. Thomas SI, Heck RH. Analysis of large-scale secondary data in higher education research. Research in higher education 2001; 42(5):517-40.
18. Hope AD, Shannon ED. A comparison of two procedures to fit multi-level data: PROC GLM versus PROC MIXED. Proceedings of the SAS users group international 30. 10-13/04/2005. Philadelphia. Pennsylvania.

Anexos

Anexo I: Figura suplementar 1: Itens do SF-6D (1)

Capacidade funcional	
1	Sua saúde <u>não</u> dificulta que você faça atividades vigorosas
2	Sua saúde dificulta <u>um pouco</u> que você faça atividades vigorosas
3	Sua saúde dificulta <u>um pouco</u> que você faça atividades moderadas
4	Sua saúde dificulta <u>muito</u> que você faça atividades moderadas
5	Sua saúde dificulta <u>um pouco</u> para você tomar banho ou vestir-se.
6	Sua saúde dificulta <u>muito</u> para você tomar banho ou vestir-se
Aspectos físicos e emocionais	
1	Você <u>não</u> teve problemas com o seu trabalho ou alguma outra atividade diária regular como consequência de sua saúde física ou algum problema emocional
2	Você esteve limitado no seu tipo de trabalho ou em outras atividades como consequência de sua saúde física
3	Você realizou menos tarefas do que você gostaria como consequência de algum problema emocional
4	Você esteve limitado no seu tipo de trabalho ou em outras atividades como consequência de sua saúde física e realizou menos tarefas do que você gostaria como consequência de algum problema emocional
Aspectos sociais	
1	Sua saúde física ou problemas emocionais <u>não</u> interferiram com as suas atividades sociais em nenhuma parte do tempo
2	Sua saúde física ou problemas emocionais interferiram com as suas atividades sociais em uma pequena parte do tempo
3	Sua saúde física ou problemas emocionais interferiram com as suas atividades sociais em alguma parte do tempo
4	Sua saúde física ou problemas emocionais interferiram com as suas atividades sociais na maior parte do tempo
5	Sua saúde física ou problemas emocionais interferiram com as suas atividades sociais todo o tempo
Dor	
1	Você <u>não</u> teve <u>nenhuma</u> dor no corpo
2	Você teve dor, mas a dor <u>não</u> interferiu <u>de maneira alguma</u> com o seu trabalho normal (incluindo tanto o trabalho fora de casa e dentro de casa)
3	Você teve dor, e a dor interferiu <u>um pouco</u> com o seu trabalho normal (incluindo tanto o trabalho fora de casa e dentro de casa)
4	Você teve dor, e a dor interferiu <u>moderadamente</u> com o seu trabalho normal (incluindo tanto o trabalho fora de casa e dentro de casa)
5	Você teve dor, e a dor interferiu <u>bastante</u> com o seu trabalho normal (incluindo tanto o trabalho fora de casa e dentro de casa)
6	Você teve dor, e a dor interferiu <u>extremamente</u> com o seu trabalho normal (incluindo tanto o trabalho fora de casa e dentro de casa)
Saúde Mental	
1	Você <u>não</u> tem se sentido uma pessoa muito nervosa ou desanimada e abatida <u>nunca</u>
2	Você tem se sentido uma pessoa muito nervosa ou desanimada e abatida <u>em uma pequena parte do tempo</u>
3	Você tem se sentido uma pessoa muito nervosa ou desanimada e abatida <u>em alguma parte do tempo</u>
4	Você tem se sentido uma pessoa muito nervosa ou desanimada e abatida <u>na maior parte do tempo</u>
5	Você tem se sentido uma pessoa muito nervosa ou desanimada e abatida <u>todo o tempo</u>
Vitalidade	
1	Você tem se sentido com muita energia <u>todo o tempo</u>
2	Você tem se sentido com muita energia <u>a maior parte do tempo</u>
3	Você tem se sentido com muita energia <u>em alguma parte do tempo</u>
4	Você tem se sentido com muita energia <u>em uma pequena parte do tempo</u>
5	Você não tem se sentido com muita energia <u>nunca</u>

Anexo II: Códigos do R

```
#bibliotecas para rodar as análises
library(survey)
library(foreign)
library(nlme)
library(lmtest)
library(tseries)
library(plm)
library(psychometric)
library(multilevel)

#####Modelos 1,2, 3 e 4

modelo1<- glm( 1 - Utility ~ 0+
domain1_2+domain1_3+domain1_4+domain1_5+domain1_6
+domain2_2+domain2_3+domain2_4

+domain3_2+domain3_3+domain3_4+domain3_5

+domain4_2+domain4_3+domain4_4+domain4_5+domain4_6

+domain5_2+domain5_3+domain5_4+domain5_5

+domain6_2+domain6_3+domain6_4+domain6_5,data=banco)

dbanco<-svydesign(ids=~Setor, data=banco)
modelo2<- svyglm(1 - Utility~ 0+
domain1_2+domain1_3+domain1_4+domain1_5+domain1_6
+domain2_2+domain2_3+domain2_4

+domain3_2+domain3_3+domain3_4+domain3_5

+domain4_2+domain4_3+domain4_4+domain4_5+domain4_6

+domain5_2+domain5_3+domain5_4+domain5_5

+domain6_2+domain6_3+domain6_4+domain6_5,design=dbanco)

modelo3<-lme(1 - Utility ~ 0+
domain1_2+domain1_3+domain1_4+domain1_5+domain1_6
+domain2_2+domain2_3+domain2_4

+domain3_2+domain3_3+domain3_4+domain3_5

+domain4_2+domain4_3+domain4_4+domain4_5+domain4_6

+domain5_2+domain5_3+domain5_4+domain5_5

+domain6_2+domain6_3+domain6_4+domain6_5,data=banco,random=~1|Setor/nu
mquest)

modelo4<- lme(1 - Utility ~
0+domain1_2+domain1_3+domain1_4+domain1_5+domain1_6
+domain2_2+domain2_3+domain2_4

+domain3_2+domain3_3+domain3_4+domain3_5

+domain4_2+domain4_3+domain4_4+domain4_5+domain4_6
```

```

+domain5_2+domain5_3+domain5_4+domain5_5

+domain6_2+domain6_3+domain6_4+domain6_5
,data=banco,random=~1|numquest)

#####Medidas de ajuste - exemplo para modelo 1

#acrescenta ao banco de dados a utilidade ajustada (estimada) pelo
modelo
banco$ajustadol<- modelol$fitted.values

##Criar a variável "1-utilidade", para comparar o ajuste com o
observado
banco$utility.unidade<-(1-banco$Utility)

#criar uma variável com a média das utilidades observados, por estado
de saúde
utility.medio.unidade<-0
eval(parse(text=paste("utility.medio.unidade[",1:248,"]<-
mean(banco[as.numeric(banco$domain)==",1:248,",53])",sep="")))
#53 é a posição da variável utility.unidade

#criar uma variável com a média das utilidades ajustadas, por estado
de saúde
ajustadol<-0

eval(parse(text=paste("ajustadol[",1:248,"]<-
mean(banco[as.numeric(banco$domain)==",1:248,",49])",sep="")))
#É a ordem das vas (ajustadol,2 e 3 ) no banco: 49, 50, 51, 52##

#calcula o resíduo
residuol<-utility.medio.unidade-ajustadol

#MAE - Mean Absolute Error (erro médio absoluto)
#É a média da diferença (valores absolutos) entre a média dos valores
observados das utilidades e os valores ajustados pelo modelo, por
estado de saúde
MAE.1<-mean(abs(utility.medio.unidade-ajustadol))
MAE.1

#Número de predições com MAE acima de 0,05
N.05.1<-sum(abs(utility.medio.unidade-ajustadol)>0.05)

#Número de predições com MAE acima de 0,10
N.10.1<-sum(abs(utility.medio.unidade-ajustadol)>0.1)

teste_Ljung1<-
t(rbind(residuol,utility.medio.unidade,ajustadol)[,order(utility.medio
.unidade,residuol,ajustadol,decreasing = T)])

#testa se o resíduo tem média 0
t.test(residuol)

#teste de Jarque- Bera => normalidade dos resíduos
jarque.bera.test (residuol)

#text de Box-Ljung => autocorrelacao dos resíduos
Box.test (teste_Ljung1[,1], lag = 1, type="Ljung")

plot(1:248,teste_Ljung1[,2], type="l",col=2,ylim=c(min(residuol),1))

```

```

lines(1:248, teste_Ljungl[,1], type="l", col=1)
lines(1:248, teste_Ljungl[,3], type="l", col=3)
legend(0, c("Utility1", "residuo1", "ajustado1"), col=c(2,1,3), lty=c(1,1,1))
)
#####Calcular ICC

#####ICC - modelo 4
##Fazer ICC para modelo nulo e para modelo completo.

#Modelo Nulo:
modelo4_nulo <- lme(1 - Utility ~
1, data=banco, random=~1|numquest, control=list(opt="optim"))
VarCorr(modelo4_nulo)
#ICC = Var(intercepto)/(Var(intercepto)+ Var(residual))
ICC_m4 = 0.08216635/(0.08216635 + 0.06347569)

#Modelo completo:
#2a) Com inconsistências
modelo4_incons <- lme(1 - Utility ~
0+domain1_2+domain1_3+domain1_4+domain1_5+domain1_6
+domain2_2+domain2_3+domain2_4

+domain3_2+domain3_3+domain3_4+domain3_5

+domain4_2+domain4_3+domain4_4+domain4_5+domain4_6

+domain5_2+domain5_3+domain5_4+domain5_5

+domain6_2+domain6_3+domain6_4+domain6_5
, data=banco, random=~1|numquest)
VarCorr(modelo4_incons)
#ICC = Var(intercepto)/(Var(intercepto)+ Var(residual))
ICC_m4_incons = 0.09648734/(0.09648734+0.04375361)

#2b) Sem inconsistências
modelo4_no_incons <- lme(1 - Utility ~ 0+domain1_2345+domain1_6
+domain2_23+domain2_4

+domain3_2+domain3_3+domain3_4+domain3_5
+domain4_234+domain4_5+domain4_6
+domain5_234+domain5_5
+domain6_234+domain6_5
, data=banco, random=~1|numquest)

VarCorr(modelo4_no_incons)
#ICC = Var(nivel 2)/(Var(nivel 2)+ Var(nivel 1)) *nivel 1: sujeito;
nivel 2: setor
ICC_m4_no_incons = 0.09831941 / (0.09831941+ 0.04365309)

#####ICC - modelo 3

#1) Modelo nulo - é o mesmo com e sem inconsistências

modelo3_nulo <- lme(1 - Utility ~
1, data=banco, random=~1|Setor/numquest, control=list(opt="optim"))
VarCorr(modelo3_nulo)
#ICC = Var(nivel 2)/(Var(nivel 2)+ Var(nivel 1)) *nivel 1: sujeito;
nivel 2: setor
ICC_m3 = 0.002140906 / (0.002140906 + 0.080117677)

```

```

#2)Modelo completo
#2a)Com inconsistencias
modelo3_incons<-lme(1 - Utility ~ 0+
domain1_2+domain1_3+domain1_4+domain1_5+domain1_6
+domain2_2+domain2_3+domain2_4

+domain3_2+domain3_3+domain3_4+domain3_5

+domain4_2+domain4_3+domain4_4+domain4_5+domain4_6

+domain5_2+domain5_3+domain5_4+domain5_5

+domain6_2+domain6_3+domain6_4+domain6_5,data=banco,random=~1|Setor/nu
mquest)
VarCorr(modelo3_incons)
#ICC = Var(nivel 2)/(Var(nivel 2)+ Var(nivel 1)) *nivel 1: sujeito;
nivel 2: setor
ICC_m3_incons=0.05616585 /(0.05616585 +0.08262201 )

#2b)Sem inconsistencias
modelo3_no_incons<-lme(1 - Utility ~ 0+
domain1_23+domain1_45+domain1_6
+domain2_23+domain2_4
+domain3_3+domain3_4+domain3_5
+domain4_234+domain4_5+domain4_6
+domain5_23+domain5_4+domain5_5

+domain6_5,data=banco,random=~1|Setor/numquest)
VarCorr(modelo3_no_incons)
#ICC = Var(nivel 2)/(Var(nivel 2)+ Var(nivel 1)) *nivel 1: sujeito;
nivel 2: setor
ICC_m3_no_incons= 0.07188419 / (0.07188419 + 0.08279771 )

```