



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE MEDICINA
PROGRAMA DE PÓS-GRADUAÇÃO EM EPIDEMIOLOGIA

DISSERTAÇÃO DE MESTRADO

Análise de classes latentes: uma aplicação visando definir pontos de corte na medida gerada na escala *Brief Measure of Emotional Preoperative Stress*

Rogério Boff Borges

Orientadora: Prof^ª Dr^ª Stela Maris de Jesus Castro

Porto Alegre, 15 de março de 2019.



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE MEDICINA
PROGRAMA DE PÓS-GRADUAÇÃO EM EPIDEMIOLOGIA

DISSERTAÇÃO DE MESTRADO

Análise de classes latentes: uma aplicação visando definir pontos de corte na medida gerada na escala *Brief Measure of Emotional Preoperative Stress*

Rogério Boff Borges

Orientadora: Prof^a Dr^a Stela Maris de Jezus Castro

A apresentação desta dissertação é exigência do Programa de Pós-graduação em Epidemiologia, Universidade Federal do Rio Grande do Sul, para obtenção do título de Mestre.

Porto Alegre, Brasil.

2019

BANCA EXAMINADORA

Prof^a. Dr^a. Luciana P. Cadore Stefani, Departamento de Cirurgia - Faculdade de Medicina da Universidade Federal do Rio Grande do Sul. Porto Alegre, RS, Brasil.

Dr. Maxciel Zortea, Programa de Pós-Graduação em Ciências Médicas da Universidade Federal do Rio Grande do Sul. Porto Alegre, RS, Brasil.

Prof. Dr. Álvaro Vigo, Programa de Pós-Graduação em Epidemiologia da Universidade Federal do Rio Grande do Sul. Porto Alegre, RS, Brasil.

DEDICATÓRIA

À Lis

AGRADECIMENTOS

Agradeço à Universidade Federal do Rio Grande do Sul e ao Programa de Pós-graduação em Epidemiologia.

A todos os professores do programa pelo conhecimento adquirido e à secretaria, pelo excelente atendimento e inúmeros esclarecimentos.

Aos membros da banca, por disponibilizarem seu valioso tempo em avaliar este trabalho e contribuir com sugestões de melhorias.

À professora Stela (minha imensa gratidão!!!) por toda orientação, amparo e estímulo na busca de metodologias para o enriquecimento deste trabalho.

Ao professor Sotero e à Andréia, pela troca de experiências, incentivo e apoio para que este trabalho fosse possível.

Aos meus familiares pelo apoio e compreensão.

Ao meu grande amigo Facundo (Facu, Dindo Facu) pelas conversas e ombro amigo em todos os momentos.

E claro, gostaria de agradecer à minha esposa Lurdiana por todo o apoio, carinho e compreensão durante os momentos mais críticos.

SUMÁRIO

ABREVIATURAS E SIGLAS	13
RESUMO	15
ABSTRACT	17
1. APRESENTAÇÃO	19
2. INTRODUÇÃO	21
3. REVISÃO DA LITERATURA.....	23
3.1. BRIEF MEASURE OF EMOTIONAL PREOPERATIVE STRESS	23
3.2. MODELO DE CLASSES LATENTES.....	25
3.2.1. DEFINIÇÃO DO MODELO.....	26
3.2.2. INDEPENDÊNCIA LOCAL.....	28
3.2.3. INVARIÂNCIA	28
3.2.4. PROBLEMAS DE ESTIMAÇÃO	30
3.3. MEDIDAS DE AJUSTE	30
3.4. HOMOGENEIDADE E INCERTEZA DE CLASSIFICAÇÃO.....	31
3.5. ENTROPIA.....	32
3.6. SELEÇÃO DO MODELO.....	33
3.7. GCPM vs LCA.....	34
3.8. DEFINIÇÃO DOS PONTOS DE CORTE.....	37
3.8.1. ÍNDICE DE YAUDEN	37
4. OBJETIVOS.....	39
5. REFERÊNCIAS BIBLIOGRÁFICAS.....	41
6. ARTIGO.....	47
7. CONCLUSÕES E CONSIDERAÇÕES FINAIS	67
8. APÊNDICES.....	69

ABREVIATURAS E SIGLAS

BIC	<i>Bayesian Information Criterion</i>
BMEPS	<i>Brief Measure of Emotional Preoperative Stress</i>
GCPM	Modelo de créditos parcial generalizado
LCA	Modelo de classes latente, sigla da língua inglesa: <i>latente class model</i>
MedPP	Média das probabilidades a posteriori
NEEPO	Nível de Estresse Emocional Pré-Operatório
p_{ic}	Probabilidade a posteriori

RESUMO

Introdução: É normal que um processo cirúrgico cause um certo grau de estresse ao indivíduo. No entanto, um alto nível de estresse no período pré-operatório implica uma maior suscetibilidade do indivíduo a reações adversas decorrentes no processo pós-operatório. O *Brief Measure Of Emotional Preoperative Stress* (BMEPS) é um instrumento que permite aferir de forma individual e pontual o Nível de Estresse Emocional Pré-Operatório (NEEPO). Contudo, do ponto de vista clínico, é interessante que existam pontos de corte para essa medida, que permitam uma classificação qualitativa, de modo a possibilitar o rastreamento dos indivíduos com alto NEEPO. O modelo de classes latentes (LCA) pode ser utilizado para identificar subgrupos de estresse emocional pré-operatório.

Objetivos: Apresentar, definir e revisar metodologias de escolha do número de classes do modelo LCA. Aplicar o modelo LCA para identificar subgrupos de nível de estresse emocional, a fim de definir os pontos de corte na medida gerada pela escala BMEPS (NEEPO), que possibilitem uma classificação qualitativa dos indivíduos quanto a esta característica.

Métodos: A revisão da literatura foi realizada em bases como a ArXiv, Scielo, Scopus, Pubmed, Google Acadêmico, periódicos Capes e bibliotecas digitais. Os indivíduos foram agrupados pelo modelo de classes latentes. Tais classes foram confrontadas com o NEEPO estimado do BMEPS calculando o índice de Youden, no intuito de definir os pontos de corte que maximizam a correta classificação dos indivíduos nas classes.

Resultados: Foram apresentados o modelo LCA em sua parametrização probabilística e referências para métodos de escolha do número de classes. Na amostra, foram observados 742 diferentes padrões de resposta aos itens do questionário. Destes, a ausência dos sintomas em todos os itens foi o padrão mais frequente, aparecendo em 51 casos. Pela análise das medidas de ajuste, interpretação e aplicação prática no contexto do estudo, optou-se por utilizar um modelo com três classes. As classes foram nomeadas, com base no padrão de resposta, em ‘Baixo estresse emocional’, ‘Médio estresse emocional’ e ‘Alto estresse emocional’, cada uma contendo 47.3%, 33.2% e 19.5% dos indivíduos, respectivamente. O índice de Youden aponta que os pontos -0.1663 e 0.7614 do NEEPO maximizam a correta classificação dos indivíduos nas respectivas classes. Com essa

configuração, os resultados apresentam uma sensibilidade de 81.7%, especificidade de 85.2% e acurácia de 76.8%.

Conclusão: A aplicação do modelo LCA identificou três subgrupos, em relação ao nível de estresse emocional, que permitem uma aplicação muito útil na prática clínica. A classificação dos indivíduos como de ‘Baixo estresse emocional’, ‘Médio estresse emocional’ ou ‘Alto estresse emocional’ através da escala BMEPS possibilita uma facilidade no rastreamento dos indivíduos com altos valores para a medida NEEPO.

Palavras-chaves: Modelo de classes latentes, Estresse Emocional, Hospitalização, Assistência ao Paciente

ABSTRACT

Introduction: It is normal for a surgical process to cause a degree of stress to the individual. However, a high level of preoperative stress implies a greater susceptibility of the individual to adverse reactions arising in the postoperative process. The Brief Measure of Emotional Preoperative Stress (BMEPS) is an instrument that allows to individually and punctually measure the Preoperative Emotional Stress Level (NEEPO). However, from the clinical point of view, it is interesting that there are cutoffs for this measure, which allow a qualitative classification so as to enable the screening of individuals with high NEEPO. The latent class model (LCA) can be used to identify subgroups of preoperative emotional stress.

Objectives: To present, define and revise methodologies for choosing the number of class of the LCA model. Apply the LCA model to identify subgroups of emotional stress level, in order to define the cutoff points in the measure generated by the BMEPS scale (NEEPO), that allow a qualitative classification of the individuals regarding this characteristic.

Methods: The literature review was carried out in databases such as ArXiv, Scielo, Scopus, Pubmed, Google Academic, Capes journals and digital libraries. The individuals were grouped by the latent class model. These class were compared with the estimated NEEP of the BMEPS calculating the Youden index, in order to define the cut-off points that maximize the correct classification of the individuals in the class.

Results: The LCA model was presented in its probabilistic parameterization and references for methods of choosing the number of class. In the sample, 742 different patterns of response to the items of the questionnaire were observed. Of these, the absence of symptoms in all items was the most frequent pattern, appearing in 51 cases. By analyzing the measures of adjustment, interpretation and practical application in the context of the study, we chose to use a model with three class. The class were named, based on the response pattern, in 'Low emotional stress', 'Medium emotional stress' and 'High emotional stress', each containing 47.3%, 33.2% and 19.5% of individuals, respectively. The Youden index points out that the -0.1663 and 0.7614 points of the NEEPO maximize the correct classification of the individuals in the respective class. With this configuration, the results have a sensitivity of 81.7%, specificity of 85.2% and accuracy of 76.8%.

Conclusion: The application of the LCA model identified three subgroups, in relation to the level of emotional stress, that allow a very useful application in clinical practice. The classification of individuals as 'Low emotional stress', 'Medium emotional stress' or 'High emotional stress' through the BMEPS scale makes it easy to track individuals with high values for NEEPO measurement.

Keywords: Latent Class Model, Emotional Stress, Hospitalization, Patient Care

1. APRESENTAÇÃO

Este trabalho consiste na dissertação de mestrado intitulada “Análise de classes latentes: uma aplicação visando definir pontos de corte na medida gerada na escala *Brief Measure of Emotional Preoperative Stress*”, apresentada ao Programa de Pós-Graduação em Epidemiologia da Universidade Federal do Rio Grande do Sul, em 15 de março de 2019. O trabalho é apresentado em três partes, na ordem que segue:

1. Introdução, Revisão da Literatura e Objetivos
2. Artigo
3. Conclusões e Considerações Finais.

Documentos de apoio estão apresentados nos apêndices.

2. INTRODUÇÃO

O estresse de maneira geral, pode ser considerado como uma resposta do corpo a alguma ameaça ou situação de incerteza (Peters, McEwen, e Friston 2017). O estresse compreende diversos aspectos: fisiológico, psicológico, biológico, emocional entre outros (Araldi-Favassa *et al.* 2005; Chrousos e Gold 1992; Margis *et al.* 2003; Reis *et al.* 2010).

Ao saber que será submetido a alguma cirurgia, é normal o indivíduo apresentar algum grau de estresse, sendo este causado pelo tipo de cirurgia, pelo local do procedimento, pela instituição de internação ou pelo tipo de tratamento que vem recebendo da equipe (Hughes 2001). Além disso, as características da condição que culminou a necessidade da cirurgia, as experiências prévias, a expectativa e a maneira como o indivíduo lida com situações estressantes, tais como uma cirurgia, influenciam diretamente nos níveis de estresse (Juan 2007; Martucci *et al.* 2004; Mavridou *et al.* 2013; Méndez *et al.* 1996).

A hospitalização exige que o indivíduo passe por um processo de adaptação a uma rotina completamente diferente do seu cotidiano. Tudo isso acaba abalando-o psicologicamente, uma vez que nem sempre o indivíduo está preparado para um processo cirúrgico (Garretson 2004; Méndez *et al.* 1996).

Indivíduos que apresentam alto estresse pré-operatório estão mais suscetíveis à reações adversas no pós-operatório se comparados a indivíduos sem essa condição (Ali *et al.* 2014; Dao *et al.* 2014; Geers *et al.* 2018; Kiecolt-Glaser *et al.* 1994; Laufenberg-Feldmann *et al.* 2016; Rosiek *et al.* 2016).

Alguns cuidados e intervenções podem ser tomados pela equipe hospitalar na tentativa de diminuir o estresse no momento que antecede a cirurgia. Bastos *et al.* 2013 fizeram uma revisão de quais cuidados e ações são importantes a serem realizados no período pré-operatório para auxiliar na promoção do bem-estar do indivíduo. Mais tarde, Sena *et al.*, 2017, construíram um instrumento identificando os cuidados considerados mais importantes pelos enfermeiros no período pré-operatório, que podem ser utilizados para identificar possíveis intervenções em diferentes situações. Entre estas, destacam-se as ações que envolvem o processo de informação e orientação do indivíduo.

Na mesma ótica, Kumar *et al.* 2018 e Zhang *et al.* 2017, constataram, em estudos com crianças, que os níveis de estresse e ansiedade no período pré-operatório são menores se são fornecidos brinquedos, videogames e terapia com palhaço no período pré-operatório.

Por se tratar de um estado de saúde latente, não é possível medir o estresse emocional diretamente, fazendo-se necessário o uso de instrumentos que permitam quantificar e classificar o indivíduo quanto ao seu nível de estresse emocional.

O *Brief Measure Of Emotional Preoperative Stress* – BMEPS, é um instrumento com a finalidade de aferir o Nível de Estresse Emocional Pré-Operatório (NEEPO) de indivíduos que serão submetidos à cirurgia (Caumo *et al.* 2016). Inicialmente foi composto por 16 itens, no entanto, após o aumento da amostra para a análise e revisão dos resultados, os autores lançaram uma nova versão utilizando apenas 12 itens. Essa nova versão, já analisada e em fase de publicação, será utilizada nesse trabalho.

O BMEPS fornece uma medida quantitativa contínua do NEEPO. Seu resultado é um valor numérico em uma escala centrada no zero, na qual quanto maior seu valor, maior é o NEEPO do indivíduo. Entretanto, para tomada de decisão clínica é fundamental ter uma classificação qualitativa do NEEPO, isto é, identificar pontos de corte na medida quantitativa que possibilitem o rastreamento de indivíduos com um alto nível de estresse emocional.

Nessa situação, em que não há um padrão de referência para a classificação qualitativa do nível de estresse emocional, o modelo de classes latentes pode ser utilizado para classificar os indivíduos (Albert e Dodd 2004; Fernandes *et al.* 2017; Sadatsafavi *et al.* 2010; Sinha, Delucchi, e Calfee 2018; van Smeden *et al.* 2014), de modo a sugerir os pontos de corte na medida quantitativa gerada a partir do BMEPS.

3. REVISÃO DA LITERATURA

3.1. BRIEF MEASURE OF EMOTIONAL PREOPERATIVE STRESS

O *Brief Measure Of Emotional Preoperative Stress* – BMEPS, é um instrumento com a finalidade de aferir o Nível de Estresse Emocional Pré-Operatório (NEEPO) de indivíduos que serão submetidos à cirurgia (Caumo *et al.* 2016).

Inicialmente foi composto por 16 itens, no entanto, após o aumento da amostra para a análise e revisão dos resultados, os autores decidiram lançar uma nova versão utilizando apenas 12 itens que versam sobre os seguintes sintomas de estresse emocional pré-operatório: nervosismo, indecisão, preocupação pontual, histórico de preocupação, confusão, agitação, desapontamento, reação aos problemas do momento, infelicidade, reação sob infelicidade, cansaço e humor.

O Quadro 1 mostra um dos itens que compõem o BMEPS, caracterizando o nervosismo. Assim como este, os demais itens também são categóricos de resposta ordinal, de modo que quanto mais alta a categoria de resposta, maior é a intensidade do sintoma aferido pelo mesmo.

Quadro 1: Exemplo de um dos itens que compõem o BMEPS.

Sigla do item	Descrição do item	Categorias de resposta
BMEPS 1	1. Estou nervoso	1 () Absolutamente não 2 () Um pouco 3 () Bastante 4 () MUITÍSSIMO

Os itens foram selecionados e/ou adaptados de instrumentos como o Inventário de Ansiedade Traço-Estado, a Escala de Sintomas Depressivos *Montgomery-Åsberg* e *Self-reporting Questionnaire* da Organização Mundial da Saúde (Caumo *et al.* 2016).

Os indivíduos foram selecionados em um processo de amostragem por conveniência, no dia antecedente à cirurgia, em pacientes do Hospital de Clínicas de Porto Alegre. Eram elegíveis indivíduos que iriam passar por um processo cirúrgico que envolvesse uma anestesia geral ou algum bloqueio neuroaxial. Foram considerados como critérios de exclusão, idade inferior a 18 anos, história clínica de danos cerebrais,

deficiência intelectual, dificuldade de compreensão dos comandos verbais, uso de um ansiolítico ou sedativo antes da aplicação do estudo e cirurgia oftalmológica ou cardíaca.

O BMEPS permite medir de forma individual o NEEPO considerando fatores físicos e emocionais. É uma medida em um momento pontual. Mesmo o indivíduo que não é estressado no dia a dia, pode vir apresentar alto NEEPO nos momentos que antecedem a cirurgia (Caumo, Segabinazi, e Stefani 2017).

O instrumento foi calibrado através do modelo de teoria de resposta ao item, denominado Modelo de Crédito Parcial Generalizado (GCPM), proposto por Muraki, 1992.

Seguindo a parametrização utilizada por Andrade e Tavares, 2000 e adaptando para o contexto desse trabalho, o NEEPO do indivíduo é denotado pela letra grega θ .

Entre os parâmetros utilizados por esse modelo, há um parâmetro relacionado ao item como um todo, conhecido como discriminação. Quanto maior o seu valor, maior é o impacto deste item na estimativa do NEEPO. Consequentemente a mudança da categoria de resposta desse item tende a acarretar uma grande variação do NEEPO estimado. Isso quer dizer que se seu valor for baixo, indivíduos com diferentes NEEPO terão aproximadamente a mesma probabilidade de apresentar o mesmo sintoma.

Considerando $P_{i,k}(\theta_j)$ como a probabilidade de um indivíduo j apresentar o sintoma de estresse emocional no nível descrito pela categoria k do item i , condicionado ao seu nível θ_j de estresse emocional no pré-operatório, o GCPM pode ser definido como

$$P_{i,k}(\theta_j) = \frac{\exp[\sum_{u=0}^k D a_i(\theta_j - b_{i,u})]}{\sum_{v=0}^{m_i} \exp[\sum_{v=0}^u D a_i(\theta_j - b_{i,v})]} \quad (1)$$

em que $b_{i,k}$ é o parâmetro do item que regula a probabilidade de o sintoma ser k ao invés da categoria adjacente ($k - 1$) no item i ; a_i é o parâmetro de inclinação (discriminação) e D é um fator de escala constante sem interpretação prática direta. A interpretação desses parâmetros será abordada na secção 3.7.

O parâmetro θ representa o NEEPO do indivíduo. Em teoria, pode assumir qualquer valor real, de modo que quanto maior for o θ maior é o NEEPO. Ademais, θ está em uma escala centrada em zero, isso quer dizer que indivíduos com uma medida de NEEPO igual a zero estão com um nível de estresse emocional médio, enquanto indivíduos com medidas positivas estão acima da média e medidas negativas estão abaixo da média. Além disso, possui o desvio padrão igual a um, o que facilita a sua interpretação. Logo, se um indivíduo apresentar $\theta = 2.5$, por exemplo, significa que este se encontra com um NEEPO 2.5 desvios padrão acima da média.

Por ser um instrumento proposto recentemente, não há outros estudos relatando seu comportamento e analisando sua distribuição para diferentes desfechos. Dessa forma não é possível definir uma classificação categórica dos indivíduos quanto ao NEEPO com base na discussão da literatura, sendo necessário utilizar alguma técnica de agrupamento baseada nos dados existentes.

3.2. MODELO DE CLASSES LATENTES

O modelo de classes latentes (LCA), proposto por Lazarsfeld e Henry, 1968, é uma família de modelos de mensuração que relacionam um conjunto de variáveis categóricas (ou qualitativas) observáveis a uma variável categórica latente, com o objetivo de captar subpopulações homogêneas não observáveis (Hagenaars e McCutcheon 2002). É uma técnica analítica que foca nas diferenças e similaridades entre as pessoas de acordo com o seu padrão de resposta (Muthñn e Muthñn 2012).

Os indivíduos são classificados em classes baseadas em seu padrão de respostas nas variáveis observadas, podendo ser utilizados tanto em estudos transversais quanto em longitudinais - na qual recebe o nome de modelo de transição latente (Rindskopf 2010).

Há diversas variações de modelo LCA com diferentes suposições e condições para análises. A mais simples pressupõe que há uma única variável latente qualitativa nominal (L) – com c subgrupos categóricos (classes) - que exerce efeito sobre as respostas aos itens. No caso do BMEPS, pressupõe-se que o único motivo para a escolha de determinada resposta a algum item do instrumento é a classe de estresse emocional na qual o indivíduo verdadeiramente se encontra.

A Figura 1 ilustra a representação do modelo LCA proposto no contexto do BMEPS. Nela é possível ver que é a classe de estresse emocional que influencia as

respostas aos itens, assim, ao ajustar um modelo LCA, não haverá associação entre as variáveis observadas dentro da mesma classe, pois toda a relação entre elas foi explicada pela variável latente. Essa suposição é conhecida como independência local e será abordada com mais detalhes na seção 3.2.2.

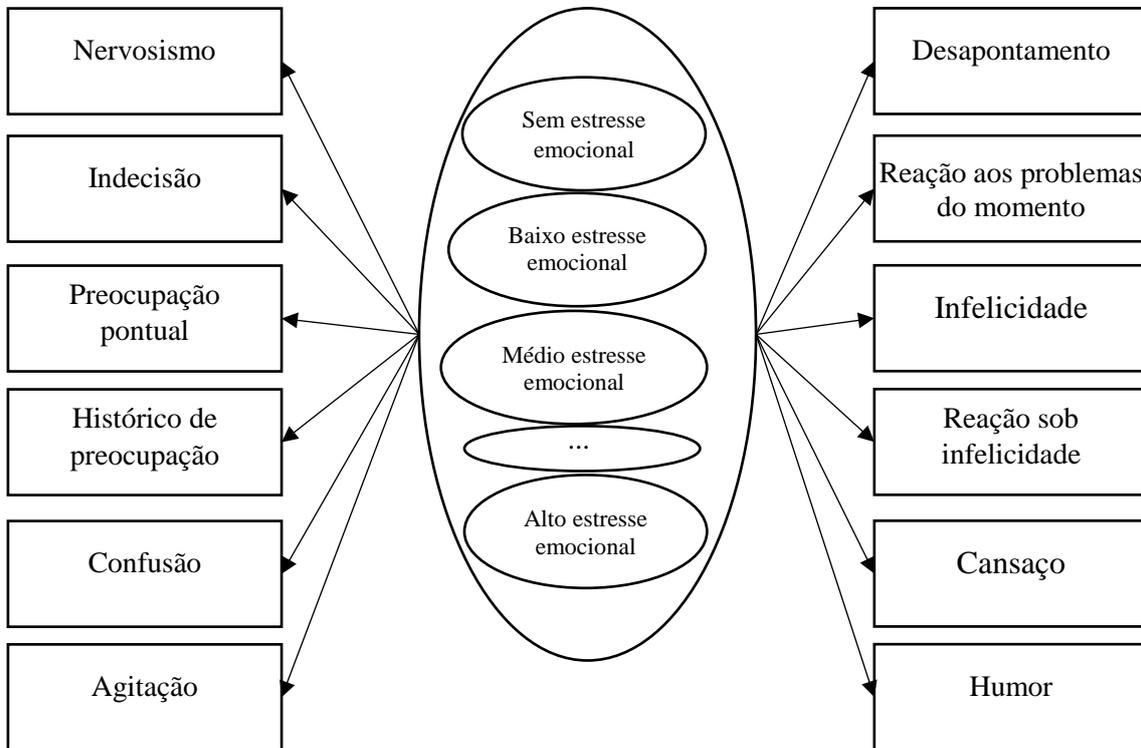


Figura 1: Diagrama da relação entre as classes latentes e as variáveis observadas do estudo BMEPS.

3.2.1. DEFINIÇÃO DO MODELO

Por tratar com variáveis categóricas, o modelo LCA trabalha em termos de probabilidades. Seja Y os possíveis perfis de resposta aos M itens; $P(Y = y)$ a probabilidade de um indivíduo apresentar um perfil de respostas y em específico, onde cada item tem r_m categorias de resposta; $I(y_m = k)$ uma função indicadora que será 1 se esse indivíduo respondeu a categoria k do item m ; e C como o número de classes da variável latente L . A relação entre os itens e as classes, na parametrização probabilística, é dada pela expressão

$$P(Y = y) = \sum_{c=1}^C \gamma_c \prod_{m=1}^M \prod_{k=1}^{r_m} \rho_{mk|c}^{I(y_m=k)}. \quad (2)$$

Nesse modelo há dois conjuntos de parâmetros:

- γ_c : é a proporção populacional de indivíduos na categoria c da variável latente L (com $c = 1, 2, \dots, C$), na qual estas categorias representam a classificação quanto ao nível de estresse pré-operatório;
- $\rho_{mk|c}$: que é a probabilidade de responder a categoria k ao m -ésimo item condicionado a classe c .

O Quadro 2, exemplifica a interpretação de algumas destas simbologias no contexto do BMEPS.

Quadro 2: Simbologia e interpretação de parâmetros e argumentos do modelo de classes latentes no contexto do BMEPS.

Símbolo	Descrição técnica	Interpretação no contexto do BMEPS
$c = 1, \dots, C$	Número de classes da variável latente L	Número de categorias de estresse emocional para classificar os indivíduos (Baixo estresse, Médio estresse...)
γ_c	Prevalência da classe latente c	Prevalência de indivíduos com a classificação de estresse emocional c
$\rho_{mk c}$	Probabilidade de resposta à k -ésima categoria do m -ésimo item condicionada à classe latente c	Dada a categoria de estresse emocional que o indivíduo se encontra, indica qual a probabilidade de responder a categoria k do m -ésimo item

Com algumas manipulações algébricas, que podem ser encontradas com detalhes no livro de Collins e Lanza 2010, é possível calcular a probabilidade a posteriori (p_{ic}),

que é a probabilidade de um indivíduo i pertencer a classe c dado o seu perfil de resposta aos 12 itens. Essa quantidade é dada pela expressão:

$$p_{ic} = \frac{\left(\prod_{m=1}^M \prod_{k=1}^{r_m} \rho_{mk|c}^{I(y_m=k)} \right) \gamma_c}{\sum_{c=1}^C \gamma_c \prod_{m=1}^M \prod_{k=1}^{r_m} \rho_{mk|c}^{I(y_m=k)}}. \quad (3)$$

Com essa equação, pode-se alocar o indivíduo na classe que apresentar maior probabilidade. Quanto maior for essa medida, menor é a incerteza de classificação.

3.2.2. INDEPENDÊNCIA LOCAL

A única suposição do modelo LCA é de que há somente uma única variável latente qualitativa nominal (L) – com c subgrupos (classes) - que tem efeito sobre as variáveis categóricas observadas (Y). Assim, ao ajustar o modelo, dada uma classe latente em específico, não haverá associação entre as variáveis observadas, pois pressupõe-se que qualquer relação entre elas foi explicada por L . Essa suposição é conhecida como independência local (Langeheine e Rost 2013; D. L. Oberski 2016; Hagenaars 1988; Little 2013).

Geralmente, essa violação ocorre quando há outras variáveis latentes, não especificadas, associadas aos itens. O não tratamento da dependência local acarreta no aumento do número necessário de classes, viés nas estimativas dos parâmetros e na classificação dos indivíduos (Vacek 1985).

Uma das formas de verificar a independência local é analisando o resíduo bivariável entre os pares de itens, no entanto, sua distribuição é desconhecida (Daniel L. Oberski, van Kollenburg, e Vermunt 2013). Nessa situação, uma alternativa é obter um p-valor através de métodos *bootstrap* (Collins e Lanza 2010; Langeheine *et al.* 1996; Oberski *et al.* 2013), mas até o momento, não foi encontrada nenhuma implementação deste método em algum software livre.

3.2.3. INVARIÂNCIA

A não invariância ocorre quando um subgrupo de indivíduos pertencentes a mesma classe latente, apresenta um comportamento diferente em algum componente da

Equação 2, seja esse componente um parâmetro ou até mesmo a própria forma funcional (Rudnev 2018).

Por exemplo, o número de classes latentes adequado é o mesmo entre indivíduos do sexo feminino e indivíduos do sexo masculino? Dado dois indivíduos, um com e outro sem histórico de câncer, pertencentes a mesma classe latente, a probabilidade de responder uma categoria de resposta a um determinado item, é a mesma entre estes dois indivíduos? Se a resposta for sim à essas questões, então podemos dizer que há invariância para a variável sexo e para a variável histórico de câncer, ou seja, os itens operam equivalentemente entre os diferentes subgrupos de indivíduos para os componentes do exemplo.

A análise da invariância pode ser realizada em duas etapas:

1. avaliar se o número de classes latentes é o mesmo entre os subgrupos;
2. verificar se a probabilidade condicional de resposta dos itens é a mesma entre os subgrupos.

Para avaliar a invariância do número de classes latentes, considera-se cada grupo como uma amostra independente e ajusta-se um modelo para cada nível do grupo. Se o número de classes latentes ideal em todos os grupos for o mesmo do modelo sem distinção de grupo (ou seja, considerando toda a amostra), pressupõe-se que há invariância desse termo.

A invariância da probabilidade condicional de resposta dos itens é avaliada a partir de dois modelos: no modelo 1 é permitido que todos os parâmetros variem entre os grupos, enquanto no modelo 2 os parâmetros são fixados entre todos grupos. Se o ajuste dos dois modelos for semelhante, então podemos assegurar que há invariância desse parâmetro.

Uma questão que deve ser considerada ao avaliar a invariância é o princípio da parcimônia e o significado prático dos resultados, pois um modelo que não considera a invariância das estimativas tem um número maior de parâmetros e é mais difícil de interpretar (Hagenaars e McCutcheon 2002; Langeheine e Rost 2013; Little 2013).

3.2.4. PROBLEMAS DE ESTIMAÇÃO

Devido à complexidade do modelo LCA, a estimação dos parâmetros é feita por maximização numérica.

Como em todos os processos de estimação, é desejável que o modelo seja identificável, em outras palavras, que o ponto de máximo global seja único e alcançado. Contudo, quanto mais complexo, maiores as chances de se ter um modelo não definido – ou seja, não há uma solução única para as estimativas ou o modelo não encontra um ponto de convergência – ou de se ter um modelo sub identificável - quando a função de verossimilhança é multimodal ou apresenta mais de um ponto de máximo local (Bauer 2007; Collins e Lanza 2010; Hoyle 1995; Tueller, Drotar, e Lubke 2011).

Para contornar o problema dos máximos locais, recomenda-se realizar o processo de estimação várias vezes utilizando diferentes pontos iniciais, elegendo aquele que apresenta maior informação. Essa prática é altamente recomendada na modelagem de classes latentes (Collins e Lanza 2010; Hagenaars e McCutcheon 2002; Langeheine e Rost 2013; Little 2013).

3.3. MEDIDAS DE AJUSTE

O teste da razão de verossimilhança pode ser utilizado para verificar se um modelo se ajusta aos dados observados e para comparar modelos aninhados (Agresti e Finlay 2012; Collins e Lanza 2010; Little 2013).

No contexto de LCA, a razão de verossimilhança (G^2) pode ser expressa em função da razão entre a contagem dos valores observados e esperados. A estatística G^2 se aproxima de uma distribuição qui-quadrado com $(w - p - 1)$ graus de liberdade, onde w é o número de possíveis perfis de respostas dado por $w = \prod_{m=1}^M r_m$ e p é o número de parâmetros do modelo. Maiores detalhes sobre o cálculo da estatística G^2 podem ser encontrados no livro de Collins e Lanza 2010.

Entretanto, a distribuição de G^2 é desconhecida quando há problemas de escassez, dificultando a interpretação do teste de ajuste do modelo.

A escassez é quando o quociente entre o número de indivíduos e o número possível de perfis de resposta é pequeno - e isso tende a virar um problema quando o modelo fica mais complexo (Collins et al. 1993). Koehler e Larntz, 1980, caracterizam a

escassez como um problema quando esse quociente é menor do que 5. Nesta situação, o uso da estatística G^2 não é recomendável, sendo preferível o uso das medidas de ajuste para comparar os modelos (Wang e Wang 2012).

As medidas de ajuste são métricas de comparação de modelos e têm vantagens de não possuir suposições quanto à sua distribuição e podem ser utilizadas para comparar modelos não aninhados (Burnham e Anderson 2003).

Em geral, para avaliar se o ajuste é mais vantajoso, essas medidas penalizam o acréscimo de parâmetros no intuito de encontrar um balanço entre o ajuste e o princípio da parcimônia. Logo, o incremento de informação na função de verossimilhança deve ser grande o suficiente para justificar a inclusão de mais parâmetros.

Um dos critérios mais conhecidos é o BIC, *Bayesian Information Criterion* (conhecido também como critério de Schwarz), proposto por Schwarz e colaboradores, em 1978. É um critério consistente e estudos apontam que ele tem um melhor desempenho (Nylund, Asparouhov, e Muthén 2007). A estatística BIC é definida por:

$$BIC = LL + p \ln(n), \quad (4)$$

em que LL é o logaritmo natural da função de verossimilhança; p é o número de parâmetros do modelo; n é o tamanho da amostra e \ln é a função do logaritmo natural.

Na comparação de modelos, valores menores dessa medida indicam um melhor ajuste aos dados.

3.4. HOMOGENEIDADE E INCERTEZA DE CLASSIFICAÇÃO

Em LCA, geralmente o indivíduo é alocado na classe que apresentar maior probabilidade de pertencê-lo, de acordo com o seu perfil de resposta. Essa probabilidade é calculada depois de ajustar o modelo, por isso é conhecida como probabilidade a posteriori (p_{ic}), definida pela equação 3.

Assim como em uma análise de agrupamentos tradicional, em LCA é esperado que as classes sejam homogêneas dentro de si. Nesse contexto, uma classe é totalmente

homogênea quando todos os indivíduos pertencentes a ela possuem o mesmo perfil de resposta, possibilitando caracterizar a classe de acordo com esse perfil.

Outro conceito interessante é o de separação, quando somente uma classe é caracterizada por um determinado perfil de resposta, ou seja, cada classe apresenta seu próprio perfil de resposta que permite caracterizá-la, e é distinta das demais classes. O baixo grau de separação entre duas classes latentes indica que elas são caracterizadas pelo mesmo perfil de respostas (Collins e Lanza 2010; Hagenars e McCutcheon 2002; Little 2013). O aumento no número observado de perfis de resposta faz com que a homogeneidade e a separação diminuam, visto que, indivíduos dentro da mesma classe podem produzir diferentes perfis de resposta.

A homogeneidade e a separação de um modelo influenciam diretamente na capacidade de classificação do indivíduo. Alta heterogeneidade e baixa separação aumentam os erros de classificação, pois fazem com que o mesmo indivíduo tenha probabilidades muito próximas de pertencer a diferentes classes (Collins e Lanza 2010).

O ideal, para facilitar a interpretação das classes, é que o modelo tenha grande homogeneidade e poder de classificação.

A média das probabilidades a posteriori (*MedPP*) de cada classe latente pode ser utilizada para avaliar a incerteza da classificação dos indivíduos. Por ser uma média de probabilidades, assume valores entre 0 e 1, sendo que quanto maior, melhor. Nagin *et al.*, 2005 apontam que com valores de *MedPP* > 0.70 é possível considerar que as classes estão bem separadas. Outra forma de se fazer essa avaliação é utilizando-se de métricas como a entropia.

Quanto à homogeneidade, valores de $\rho_{mk|c}$ maiores do que 0.70 ou menores que 0.30 são um indicativo de alta homogeneidade (Little 2013).

3.5. ENTROPIA

A entropia avalia a incerteza de classificação. É uma medida da falta de homogeneidade dos dados de entrada em relação à sua classificação, ou seja, indica o erro de classificação do modelo. Há diversas maneiras de se medir a entropia, uma delas foi proposta por Ramaswamy *et al.*, 1993, onde eles propõem uma métrica que assume valores entre 0 e 1, e que altos valores indicam melhor classificação.

A medida de entropia é definida por

$$Entropia = 1 - \frac{\sum_{i=1}^n \sum_{c=1}^C -p_{ic} \ln p_{ic}}{n \ln C}, \quad (5)$$

onde n é o tamanho da amostra; C é o número de classes do modelo; p_{ic} é a probabilidade a posteriori de classificação, definido na Equação 3, e \ln é a função do logaritmo natural.

O erro de classificação pode aumentar de acordo com o número de classes latentes, por isso à medida que aumentamos o número de classes latentes a entropia tende a ser menor (Collins e Lanza 2010).

3.6. SELEÇÃO DO MODELO

A decisão do número de classes latentes envolve fatores como a questão de pesquisa, critérios de medidas de ajuste, parcimônia e significado prático.

A escolha do modelo pode ser realizada conforme os passos a seguir, baseados nas sugestões/procedimento dos autores Collins e Lanza, 2010; Lanza *et al.*, 2007; Little, 2013; Wang e Wang, 2012:

Etapa 1: O primeiro passo, antes de definir modelos mais complexos (envolvendo variáveis de grupo), consiste em definir o número de classes do modelo base (considerando apenas os itens do instrumento, ou seja, as variáveis categóricas observáveis);

- a) são ajustados vários modelos de forma sequencial, de uma classe, em seguida com duas classes, depois com três classes, e assim sucessivamente;
- b) para contornar possíveis problemas de estimação, conforme descrito na seção 3.2.4, recomenda-se realizar a estimação de cada modelo diversas vezes alterando os pontos iniciais de cada processo iterativo, e então escolher como candidata a iteração com melhor medida de ajuste;

- c) o número de classes então é definido comparando os modelos candidatos quanto a seus valores de medida de ajuste, levando em consideração fatores como a parcimônia, questão de pesquisa e significado prático.

Etapa 2: Na sequência é necessário verificar a invariância das estimativas frente aos subgrupos observados;

- a) para avaliar a invariância do número de classes latentes, ajusta-se um modelo para cada subgrupo como se fossem amostras independentes;
 - i) se o número de classes latentes ideal em todos os subgrupos for o mesmo do modelo sem distinção de grupo (ou seja, considerando toda a amostra), pressupõe-se que essa invariância está assegurada;
- b) a invariância da probabilidade de resposta dos itens pode ser avaliada a partir da construção de dois modelos;
 - i) no modelo 1 todos esses parâmetros podem variar entre os subgrupos;
 - ii) no modelo 2 todos os parâmetros são fixados entre todos subgrupos;
 - iii) se o ajuste do modelo 2 não for inferior ao ajuste do modelo 1, então pode-se assegurar que há invariância desses parâmetros.
- c) uma questão importante sobre a invariância é que o número de parâmetros aumenta consideravelmente, o que torna mais difícil interpretar o modelo ajustado quando a mesma não está assegurada (Collins e Lanza 2010; Hagenaars e McCutcheon 2002; Langeheine e Rost 2013; Little 2013).

Com o modelo LCA selecionado, obtemos a classificação dos indivíduos da amostra nas diferentes classes latentes geradas. Este resultado pode ser confrontado com o NEEPO estimado para cada um, através da escala BMEPS, tornando possível a identificação de pontos de corte na mesma.

3.7. GCPM vs LCA

O BMEPS foi calibrado utilizando o GCPM para a obtenção da estimativa do NEEPO para cada indivíduo da amostra. O LCA é utilizado para o agrupamento dos indivíduos com base em seu padrão de resposta. Tanto o GCPM quanto o LCA utilizam de variáveis observadas para a mensuração de uma variável latente não observada.

Algumas semelhanças e diferenças entre esses modelos são apresentados no Quadro 3. As expressões dos modelos GCPM e LCA, para o entendimento da parametrização e simbologias utilizadas, estão apresentadas nas Equações 1 e 2, respectivamente.

Quadro 3: Semelhanças e diferenças entre o modelo de crédito generalizado (GCPM) e o modelo de classes latentes (LCA).

GCPM	LCA
As variáveis observadas são categóricas ordinais, ou seja, assume-se uma ordenação lógica entre as categorias.	As variáveis observadas são categóricas e tratadas como nominais, isto é, desconsidera-se (se houver) a ordenação entre as categorias dos itens.
Mensura uma única variável latente quantitativa contínua, referida como traço latente, θ . Quanto maior seu valor, maior é a intensidade latente do indivíduo.	Utilizado para mensurar uma única variável latente qualitativa nominal, L . Suas categorias são chamadas de classes, $c = 1, \dots, C$, na qual cada uma é a mais homogênea possível em relação ao padrão de resposta dos itens.
Cada item oferece uma quantidade de informação na construção do traço latente, quanto maior essa informação, maior a contribuição do item na estimativa do traço latente.	Não há um parâmetro relacionado ao item como um todo. Os itens têm o mesmo peso no cálculo de classificação do indivíduo.

Uma das principais diferenças entre os modelos, é que o GCPM trata as variáveis observadas como qualitativas ordinais para mensurar uma variável latente quantitativa contínua, gerando, naturalmente, uma ordenação dos indivíduos quanto ao traço latente. Enquanto o LCA considera as variáveis observadas como qualitativas nominais para a construção de uma variável latente também qualitativa nominal, agrupando os indivíduos quanto ao seu perfil de resposta, que não necessariamente segue uma ordenação. Também, no LCA, após a classificação dos indivíduos nas classes, eles são considerados como iguais dentro da mesma em relação à variável latente. Só são considerados diferentes indivíduos classificados em classes diferentes.

Outra diferença é que no GCPM além da escolha da categoria de resposta, o próprio item observado influencia na estimação do traço latente através de seu parâmetro de discriminação, enquanto no LCA a classificação é realizada com base na escolha da categoria de resposta condicionada a cada classe e não há uma ‘ponderação’ da variável observada como um todo, isto é, os itens têm o mesmo peso no cálculo de classificação do indivíduo.

A natureza da incerteza sobre a estimativa do valor latente também muda de um método para o outro. No GCPM a incerteza é medida em termos do erro padrão da estimativa – quanto maior o erro padrão, maior é a incerteza – e no LCA a incerteza é dada pela probabilidade de classificação entre as classes – quanto mais próximas forem as probabilidades, maior é a imprecisão de classificação. Ao se desconsiderar essas incertezas quando confrontando os resultados, assume-se que a classificação do LCA e a medição do GCPM são ‘fixas’. Assim sendo, pode-se esperar que apesar de aplicadas no mesmo conjunto de dados, os modelos podem divergir em alguns resultados quanto à classificação do estresse dos indivíduos.

Apesar do LCA, no contexto do BMEPS, possibilitar uma classificação categórica dos indivíduos quanto ao nível de estresse emocional, é de interesse dos pesquisadores responsáveis pelo BMEPS, ter uma classificação categórica dos indivíduos a partir da medida gerada pelo GCPM, uma vez que este instrumento vem sendo utilizado em novos estudos de associação para diferentes desfechos. Inclusive, na prática clínica, é interessante ao profissional da saúde ter a classificação categórica e, também a magnitude da condição do indivíduo para auxiliar na tomada de decisão. Por exemplo, um indivíduo classificado como de ‘Alto estresse emocional’ e com $\theta = 4.5$ está em uma condição muito mais vulnerável que outro indivíduo também classificado como de ‘Alto estresse emocional’ mas com um $\theta = 2.0$.

Outra vantagem da estimação e classificação do estresse emocional via GCPM, é que, conforme já citado, esse modelo possibilita que diferentes itens tenham diferentes contribuições para a medida do traço latente de acordo com a quantidade de informação fornecida pelo mesmo. Portanto, itens mais informativos terão maior contribuição (Embretson e Reise 2000). Além disso, testes envolvendo variáveis em sua forma categorizada são menos poderosos do que suas versões contínuas e, geralmente, a mesma

categorização não se aplica a diferentes estudos (Bennette e Vickers 2012; Senn 2003; Aiken, West, e Reno 1991).

3.8. DEFINIÇÃO DOS PONTOS DE CORTE

Para sugerir um ponto de corte no NEEPO obtido através do BMEPS com base nas classes do LCA, é necessário assumir a classificação dos indivíduos pelo LCA como sendo o padrão de referência. Nessas circunstâncias, podem ser utilizadas metodologias de teste de diagnóstico para a definição de pontos de corte. Entre elas está o índice de Youden, o qual maximiza a correta classificação geral dos indivíduos.

Cabe salientar que no contexto deste trabalho, o índice de Youden não tem o propósito de validação do teste. Sua funcionalidade será utilizada para identificar potenciais pontos de corte no NEEPO com base nas classes do LCA. O processo de validação não faz parte do escopo deste trabalho.

3.8.1. ÍNDICE DE YOUTEN

Proposto por Youden, 1950, para medir a performance de um teste de diagnóstico. Sua fórmula é dada por

$$J = \text{sensibilidade} + \text{especificidade} - 1. \quad (6)$$

Segundo Perkins e Schisterman, 2006, ele é recomendado quando se quer maximizar a correta classificação geral dos indivíduos, isto é, obter a menor proporção total possível de erros de classificação. É uma medida que indica a magnitude de classificações incorretas. Quanto mais próximo de 1, melhor é a performance do teste, e um valor igual a zero indica uma péssima performance (Youden 1950). Cabe notar que, em contextos onde os valores de sensibilidade e/ou especificidade são baixos, o índice de Youden pode resultar em valores negativos, podendo, em casos extremos (sensibilidade e especificidade iguais a 0), resultar até no valor -1.

A proposta de Youden, 1950, é recomendada para desfechos binários, no entanto Luo e Xiong, 2013, derivaram um indicador permitindo o uso em desfechos ordinais de até três grupos. Os mesmos autores criaram um pacote no software R para esses cálculos, chamado `DiagTest3Grp` (Luo e Xiong 2012). Atualmente não está disponível no CRAN do software, mas pode ser instalado pelo comando:

```
devtools::install_version('DiagTest3Grp', version = '1.6',  
repos = "http://cran.us.r-project.org").
```

O pacote oferece 4 métodos para estimação do índice de Youden:

- Estimação pressupondo distribuição normal do teste de diagnóstico entre os grupos;
- Aplicação de uma transformação Box-Cox para aproximar a normalidade e depois estimar sob normalidade;
- Estimação usando a função de densidade cumulativa empírica;
- Estimação usando a densidade kernel.

A suposição de normalidade pode ser verificada através do uso de testes estatísticos e análises gráficas. Para tamanhos grandes de amostra, como no caso da amostra do BMEPS, recomenda-se o uso do teste de Shapiro-Wilk, por ser mais eficiente e mais poderoso (Leotti, Coster, e Riboldi 2012; Razali e Wah 2011). Gráficos como histograma e quantil-quantil fornecem uma visualização gráfica subjetiva para a avaliação da distribuição (Bussab e Morettin 2011; Gujarati e Porter 2011).

4. OBJETIVOS

Diante da necessidade de rastrear de forma ativa e efetiva os indivíduos com alto nível de estresse emocional pré-operatório, este estudo tem por objetivos:

Objetivo Geral

Propor categorias de classificação da medida obtida pela escala BMEPS, agrupando os indivíduos por meio do modelo de classes latentes e confrontando as características de cada classe proposta quanto ao padrão de respostas dos itens e seu nível de estresse emocional pré-operatório.

Objetivos Específicos

- a) Apresentar e definir o modelo LCA;
- b) Revisar metodologias de escolha do número de classes em um modelo LCA;
- c) Identificar os pontos de corte na medida obtida pela escala BMEPS possibilitando a classificação dos indivíduos em grupos distintos quanto ao nível de estresse emocional pré-operatório.

5. REFERÊNCIAS BIBLIOGRÁFICAS

Agresti, Alan, e Barbara Finlay. 2012. *Métodos estatísticos para as ciências sociais*. Penso Editora.

Aiken, Leona S., Stephen G. West, e Raymond R. Reno. 1991. *Multiple regression: Testing and interpreting interactions*. Sage.

Albert, Paul S., e Lori E. Dodd. 2004. “A cautionary note on the robustness of latent class models for estimating diagnostic error without a gold standard”. *Biometrics* 60 (2): 427–35.

Ali, Achmet, Demet Altun, Bahadir Hakan Oguz, Mehmet Ilhan, Fatma Demircan, e Kemalettin Koltka. 2014. “The Effect of Preoperative Anxiety on Postoperative Analgesia and Anesthesia Recovery in Patients Undergoing Laparoscopic Cholecystectomy”. *Journal of Anesthesia* 28 (2): 222–27. <https://doi.org/10.1007/s00540-013-1712-7>.

Andrade, Dalton Francisco de, Heliton Ribeiro Tavares, e Raquel da Cunha Valle. 2000. “Teoria da Resposta ao Item: conceitos e aplicações”. *ABE, Sao Paulo*.

Araldi-Favassa, C.T., Armiliato, N. and Kalinine, I., 2005. “Aspectos fisiológicos e psicológicos do estresse”. *Revista de psicologia da UnC*, 2(2), pp.84-92.

Bastos, Alana Queiroz, Ramon Andrade de Souza, Flávia Menezes de Souza, e Patrícia Figueiredo Marques. 2013. “Reflexões sobre cuidados de enfermagem no pré e pós-operatório: uma revisão integrativa da literatura”. *Ciência, Cuidado & Saúde* 12 (2): 382–90.

Bauer, Daniel J. 2007. “Observations on the use of growth mixture models in psychological research”. *Multivariate Behavioral Research* 42 (4): 757–786.

Bennette, Caroline, e Andrew Vickers. 2012. “Against quantiles: categorization of continuous variables in epidemiologic research, and its discontents”. *BMC medical research methodology* 12 (1): 21.

Burnham, Kenneth P, e David R Anderson. 2003. *Model selection and multimodel inference: a practical information-theoretic approach*. Springer Science & Business Media.

Bussab, W. O., e P. A. Morettin. 2011. *Estatística Básica., 7ª edição, 1ª reimpressão*, Ed. Saraiva.

Caumo, W., M. Nazare Furtado da Cunha, S. Camey, S. Maris de Jesus Castro, I. L. S. Torres, e L. Cadore Stefani. 2016. “Development, Psychometric Evaluation and Validation of a Brief Measure of Emotional Preoperative Stress (B-MEPS) to Predict Moderate to Intense Postoperative Acute Pain”. *British Journal of Anaesthesia* 117 (5): 642–49. <https://doi.org/10.1093/bja/aew310>.

Caumo, W., J. D. Segabinazi, e L. P. C. Stefani. 2017. “Reply: allostatic load as an approach to support the theoretical assumptions of the Brief Measure of Emotional

Preoperative Stress (B-MEPS)”. *BJA: British Journal of Anaesthesia* 118 (4): 638–40. <https://doi.org/10.1093/bja/aex064>.

Chrousos, G.P. and Gold, P.W., 1992. “The concepts of stress and stress system disorders: overview of physical and behavioral homeostasis”. *Jama*, 267(9), pp.1244-1252.

Collins, Linda M, Penny L Fidler, Stuart E Wugalter, e Jeffrey D Long. 1993. “Goodness-of-fit testing for latent class models”. *Multivariate Behavioral Research* 28 (3): 375–389.

Collins, Linda M., e Stephanie T. Lanza. 2010. *Latent class and latent transition analysis: with applications in the social behavioral, and health sciences*. Wiley series in probability and statistics. Hoboken, N.J: Wiley.

Dao, Junfeng, Jincal Zhang, Guangbao Song, e Qi Xin. 2014. “Effect of preoperative anxiety level on postoperative pain sensation in patients receiving implant denture for partial edentulism”. *Nan Fang Yi Ke Da Xue Xue Bao = Journal of Southern Medical University* 34 (4): 528–31.

Embretson, Susan E., e Steven Paul Reise. 2000. *Item response theory for psychologists*. Mahwah. New Jersey: Lawrence Erlbaum Associates, Publishers.

Fernandes, Flavia F., Hugo Perazzo, Luiz E. Andrade, Alessandra Dellavance, Carlos Terra, Gustavo Pereira, João L. Pereira, Frederico Campos, Maria L. Ferraz, e Renata M. Perez. 2017. “Latent Class Analysis of Noninvasive Methods and Liver Biopsy in Chronic Hepatitis C: An Approach without a Gold Standard”. *BioMed research international* 2017.

Garretson, S., 2004. “Benefits of pre-operative information programmes”. *Nursing standard*, 18(47), pp.33-38.

Geers NC, Zegel M, Huybregts JGJ, Niessen FB. 2018. “The Influence of Preoperative Interventions on Postoperative Surgical Wound Healing in Patients Without Risk Factors: A Systematic Review”. *Aesthet Surg Journal*. 15 de outubro de 2018;38(11):1237–49.

Gujarati, Damodar N., e Dawn C. Porter. 2011. *Econometria Básica-5*. Amgh Editora.

Hagenaars, Jacques A. 1988. “Latent structure models with direct effects between indicators: local dependence models”. *Sociological Methods & Research* 16 (3): 379–405.

Hagenaars, Jacques A, e Allan L McCutcheon. 2002. *Applied latent class analysis*. Cambridge University Press.

Hoyle, Rick H. 1995. *Structural equation modeling: Concepts, issues, and applications*. Sage.

Hughes, Brian M. 2001. “Psychology, hospitalization and some thoughts on medical training”. *European Journal of Psychotherapy, Counselling & Health* 4 (1): 7–26.

Juan K de. 2007. “O impacto da cirurgia e os aspectos psicológicos do paciente: uma revisão”. *Psicologia Hospitalar*. 5(1):48–59.

Kiecolt-Glaser, J. K., Malarkey, W. B., Cacioppo, J. T., & Glaser, R. (1994). *Stressful personal relationships: Immune and endocrine function*. Handbook of human stress and immunity (pp. 321-339). Academic Press.

Koehler, Kenneth J, e Kinley Larntz. 1980. “An empirical investigation of goodness-of-fit statistics for sparse multinomials”. *Journal of the American Statistical Association* 75 (370): 336–344.

Kumar, Ashok, Sambhunath Das, Sandeep Chauhan, Usha Kiran, e Sujata Satapathy. 2018. “Perioperative Anxiety and Stress in Children Undergoing Congenital Cardiac Surgery and Their Parents: Effect of Brief Intervention—A Randomized Control Trial”. *Journal of Cardiothoracic and Vascular Anesthesia*, agosto. <https://doi.org/10.1053/j.jvca.2018.08.187>.

Langeheine, Rolf, e Jürgen Rost. 2013. *Latent trait and latent class models*. Springer Science & Business Media.

Lanza, Stephanie T, Linda M Collins, David R Lemmon, e Joseph L Schafer. 2007. “PROC LCA: A SAS procedure for latent class analysis”. *Structural Equation Modeling* 14 (4): 671–694.

Laufenberg-Feldmann, R., B. Kappis, M. Schuster, e M. Ferner. 2016. “Relevance of preoperative anxiety for postoperative outcome in urological surgery patients: A prospective observational study”. *Schmerz (Berlin, Germany)* 30 (2): 166–73. <https://doi.org/10.1007/s00482-015-0023-3>.

Lazarsfeld, P, e N Henry. 1968. “Latent Structure Analysis Houghton Mifflin”. *New York*.

Leotti, Vanessa Bielefeldt, Rodrigo Coster, e João Riboldi. 2012. “Normalidade de variáveis: métodos de verificação e comparação de alguns testes não-paramétricos por simulação”. *Revista HCPA. Porto Alegre. Vol. 32, no. 2 (2012), p. 227-234*.

Little, Todd D. 2013. *The Oxford handbook of quantitative methods, volume 1: Foundations*. Oxford University Press.

Luo, Jingqin, e Chengjie Xiong. 2012. “DiagTest3Grp: an R package for analyzing diagnostic tests with three ordinal groups”. *Journal of statistical software* 51 (3): 1.

Luo, Jingqin, e Chengjie Xiong. 2013. “Youden index and associated cut-points for three ordinal diagnostic groups”. *Communications in Statistics-Simulation and Computation* 42 (6): 1213–1234.

Margis, R., Picon, P., Cosner, A.F. and Silveira, R.D.O., 2003. “Relação entre estressores, estresse e ansiedade”. *Revista de Psiquiatria do Rio Grande do Sul*, 25(1), pp.65-74.

Martucci, C., Peron, A.P. and Vicentini, V.E.P., 2004. “Aspectos gerais do estresse”. *Arquivos do Museu Dinâmico Interdisciplinar*, 8(1), pp.58-62.

Mavridou P, Dimitriou V, Manataki A, Arnaoutoglou E, Papadopoulos G. 2013. “Patient’s anxiety and fear of anesthesia: effect of gender, age, education, and previous experience of anesthesia. A survey of 400 patients”. *Journal of anesthesia*. 27(1):104-8.

- Méndez, F.X., Ortigosa, J.M. and Pedroche, S., 1996. “Preparación a la hospitalización infantil (I): Afrontamiento del estrés”. *Psicología conductual*, 4(2), pp.193-209.
- Muraki, Eiji. 1992. “A generalized partial credit model: Application of an EM algorithm”. *ETS Research Report Series 1992* (1): i–30.
- Muthñn, LK, e BO Muthñn. 2012. “Mplus”. *Statistical Analysis With Latent Variables. User’s Guide. Seventh Edition. Los Angeles, CA: Muthñn & Muthñn.*
- Nagin, Daniel S, Daniel NAGIN, e others. 2005. *Group-based modeling of development.* Harvard University Press.
- Nylund, Karen L, Tihomir Asparouhov, e Bengt O Muthén. 2007. “Deciding on the number of classes in latent class analysis and growth mixture modeling: A Monte Carlo simulation study”. *Structural equation modeling* 14 (4): 535–569.
- Oberski, D. L. 2016. “Beyond the Number of Classes: Separating Substantive from Non-Substantive Dependence in Latent Class Analysis”. *Advances in Data Analysis and Classification* 10 (2): 171–82. <https://doi.org/10.1007/s11634-015-0211-0>.
- Oberski, Daniel L, Geert H van Kollenburg, e Jeroen K Vermunt. 2013. “A Monte Carlo evaluation of three methods to detect local dependence in binary data latent class models”. *Advances in Data Analysis and Classification* 7 (3): 267–279.
- Perkins, Neil J, e Enrique F Schisterman. 2006. “The inconsistency of ‘optimal’ cutpoints obtained using two criteria based on the receiver operating characteristic curve”. *American journal of epidemiology* 163 (7): 670–675.
- Peters, Achim, Bruce S McEwen, e Karl Friston. 2017. “Uncertainty and stress: Why it causes diseases and how it is mastered by the brain”. *Progress in neurobiology* 156: 164–188.
- Raichle, Katherine A, Travis L Osborne, Mark P Jensen, Dawn M Ehde, Douglas G Smith, e Lawrence R Robinson. 2015. “Preoperative state anxiety, acute postoperative pain, and analgesic use in persons undergoing lower limb amputation”. *The Clinical journal of pain* 31 (8): 699–706.
- Ramaswamy, Venkatram, Wayne S DeSarbo, David J Reibstein, e William T Robinson. 1993. “An empirical pooling approach for estimating marketing mix elasticities with PIMS data”. *Marketing Science* 12 (1): 103–124.
- Razali, Nornadiah Mohd, e Yap Bee Wah. 2011. “Power comparisons of shapiro-wilk, kolmogorov-smirnov, lilliefors and anderson-darling tests”. *Journal of statistical modeling and analytics* 2 (1): 21–33.
- Reis ALPP dos, Fernandes SRP, Gomes AF. 2010. “Estresse e fatores psicossociais”. *Psicologia: Ciência e profissão*. 30:712–25.
- Rosiek A, Kornatowski T, Rosiek-Kryszewska A, Leksowski Ł, Leksowski K. 2016. “Evaluation of stress intensity and anxiety level in preoperative period of cardiac patients”. *BioMed Res Int.*; 2016.

Rindskopf, David. 2010. "Latent transition analysis". *The Reviewer's Guide to Quantitative Methods in the Social Sciences*, 199.

Rudnev, Maksim. 2018. "Testing for Invariance of Latent Classes". *Cross-Cultural Analysis: Methods and Applications*, 449.

Sadatsafavi, Mohsen, Neal Shahidi, Fawziah Marra, Mark J. FitzGerald, Kevin R. Elwood, Na Guo, e Carlo A. Marra. 2010. "A statistical method was used for the meta-analysis of tests for latent TB in the absence of a gold standard, combining random-effect and latent-class methods to estimate test accuracy". *Journal of Clinical Epidemiology* 63 (3): 257–69. <https://doi.org/10.1016/j.jclinepi.2009.04.008>.

Schwarz, Gideon, e others. 1978. "Estimating the dimension of a model". *The annals of statistics* 6 (2): 461–464.

Sena, Adnairdes Cabral de, Eliane Regina Pereira do Nascimento, Ana Rosete Camargo Rodrigues Maia, José Luís Guedes dos Santos, Adnairdes Cabral de Sena, Eliane Regina Pereira do Nascimento, Ana Rosete Camargo Rodrigues Maia, e José Luís Guedes dos Santos. 2017. "Construção coletiva de um instrumento de cuidados de enfermagem a pacientes no pré-operatório imediato". *Revista Baiana de Enfermagem* 31 (1). <https://doi.org/10.18471/rbe.v31i1.20506>.

Senn, Stephen. 2003. "Disappointing Dichotomies". *Pharmaceutical Statistics* 2 (4): 239–40. <https://doi.org/10.1002/pst.90>.

Sinha, P., K. Delucchi, e C. S. Calfee. 2018. "Building a Parsimonious Model Using Biomarker and Clinical Data to Identify Subphenotypes in Acute Respiratory Distress Syndrome". In *B95. Critical care: biomarkers in ards and sepsis from genes to microbiome*, A4181–A4181. American Thoracic Society.

Smeden, Maarten van, Christiana A. Naaktgeboren, Johannes B. Reitsma, Karel G. M. Moons, e Joris A. H. de Groot. 2014. "Latent Class Models in Diagnostic Studies When There is No Reference Standard—A Systematic Review". *American Journal of Epidemiology* 179 (4): 423–31. <https://doi.org/10.1093/aje/kwt286>.

Tueller, Stephen J, Scott Drotar, e Gitta H Lubke. 2011. "Addressing the problem of switched class labels in latent variable mixture model simulation studies". *Structural Equation Modeling* 18 (1): 110–131.

Vacek, Pamela M. 1985. "The effect of conditional dependence on the evaluation of diagnostic tests". *Biometrics*, 959–968.

Wang, Jichuan, e Xiaoqian Wang. 2012. *Structural equation modeling: Applications using Mplus*. John Wiley & Sons.

Youden, William J. 1950. "Index for rating diagnostic tests". *Cancer* 3 (1): 32–35.

Zhang, Yongfu, Yuan Yang, Wing YT Lau, Samradhvi Garg, e Jianxin Lao. 2017. "Effectiveness of Pre-Operative Clown Intervention on Psychological Distress: A Systematic Review and Meta-Analysis: Meta-Analysis of Clown Intervention". *Journal of Paediatrics and Child Health* 53 (3): 237–45. <https://doi.org/10.1111/jpc.13369>.

7. CONCLUSÕES E CONSIDERAÇÕES FINAIS

A submissão a um procedimento cirúrgico, por vezes, pode provocar um aumento no nível de estresse emocional do indivíduo, tornando-o mais susceptível a complicações e a reações adversas no período pós-operatório, quando comparado a quem não apresenta tal condição.

O BMEPS é um instrumento que permite aferir o Nível de Estresse Emocional Pré-Operatório, de modo que quanto maior for essa medida, maior é o nível de estresse emocional do indivíduo. Entretanto, no âmbito clínico é fundamental, além da magnitude, ter uma classificação categórica dessa condição para auxiliar na tomada de decisão.

A aplicação do modelo LCA identificou três subgrupos, em relação ao nível de estresse emocional, que permite uma aplicação muito útil na prática clínica. A classificação dos indivíduos como de ‘Baixo estresse emocional’, ‘Médio estresse emocional’ ou ‘Alto estresse emocional’ a partir do NEEPO estimado pelo BMEPS possibilita uma facilidade no rastreio dos indivíduos com alto nível de estresse emocional.

Assim, em uma situação de gestão, em um cenário com limitações de recursos humanos, financeiros e infraestrutura, na qual há a necessidade de dar atenção somente aos mais vulneráveis, esses indivíduos podem ser facilmente detectados para que cuidados e medidas de atenção possam ser tomadas para melhorar a condição desses indivíduos.

Da mesma maneira que indivíduos classificados como de ‘Médio estresse emocional’ podem ser monitorados para detectar possíveis mudanças no nível de estresse.

Por fim, o presente estudo atendeu aos objetivos propostos, em especial aquele de propor pontos de corte na medida gerada pelo BMEPS, através do uso do modelo de classes latentes em um contexto sem um padrão de referência.

É importante que seja realizado um acompanhamento do desempenho dessa classificação, a fim de refinar os pontos com base em novos dados de seguimento dos indivíduos.

8. APÊNDICES

APÊNDICE A

Análise da distribuição do NEEPO estimado pelo BMEPS dos indivíduos, estratificada pela classe que o indivíduo pertence, de acordo com o modelo com 3 classes.

Há evidências de que a distribuição do NEEPO estimado pelo BMEPS, dentro de cada classe no modelo com 3 classes, não segue uma distribuição normal segundo o teste de Shapiro-Wilk (p -valor < 0.001 para os três casos).

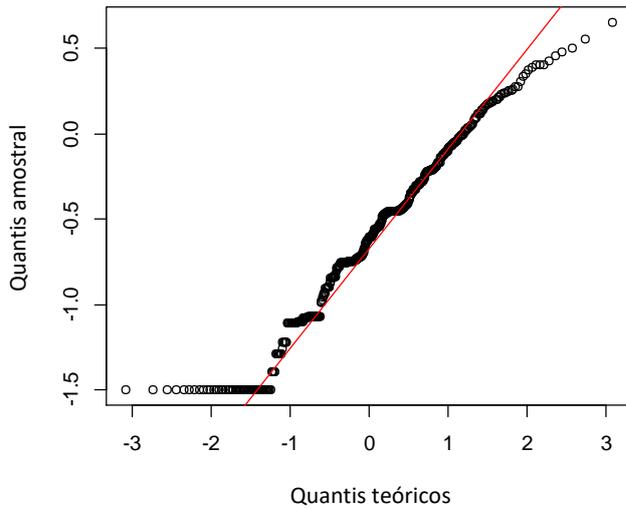


Figura 3: QQ-normal do NEEPO estimado pelo BMEPS dos indivíduos da classe 1 do modelo com 3 classes.

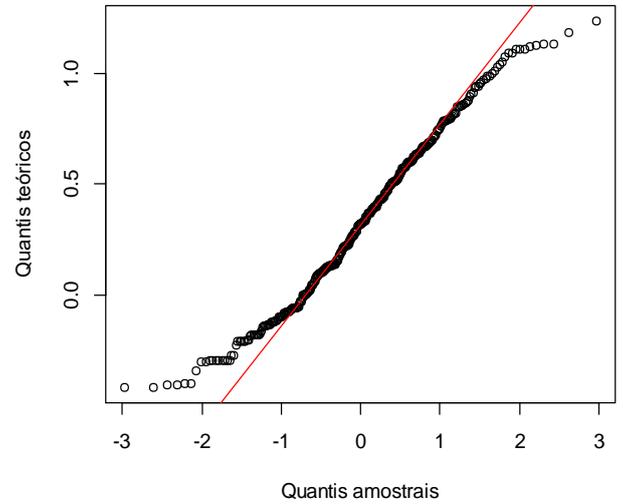


Figura 4: QQ-normal do NEEPO estimado pelo BMEPS dos indivíduos da classe 2 do modelo com 3 classes.

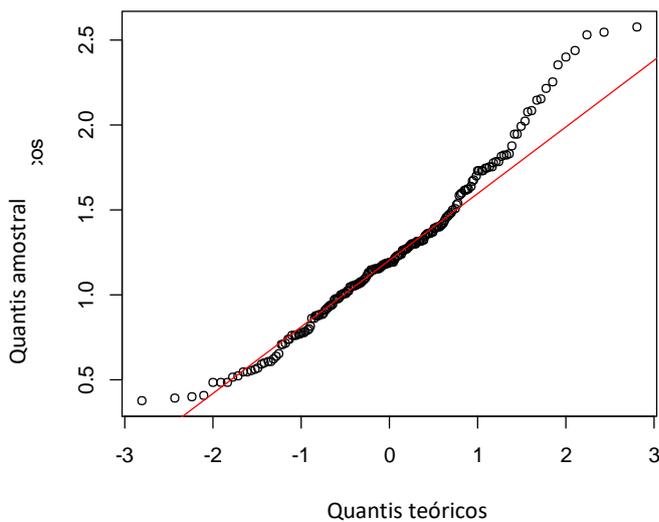


Figura 5: QQ-normal do NEEPO estimado pelo BMEPS dos indivíduos da classe 3 do modelo com 3 classes.

APÊNDICE B

Tabela 5: Distribuição das variáveis de acordo com a classificação do nível de estresse emocional pré-operatório

Variável*	Classificação qualitativa do estresse de acordo com os pontos de corte sugeridos na escala BMEPS [‡]						p [¥]
	Amostra	Baixo	IC 95%	Médio	IC 95%	Alto	
Sexo							< 0.001
Feminino	74.5	65.8	61.5-70.2	81.8	77.9-85.9	83.3	78.7-88.6
Masculino	25.5	34.2	30.0-38.7	18.2	14.3-22.4	16.7	12.2-22.1
Escolaridade							< 0.001
Nunca estudou	3.8	2.3	0.0-7.2	5.3	0.0-10.0	4.6	0.0-11.5
Até 8 anos	60.4	49.7	45.1-54.6	73.1	68.7-77.8	65.0	58.9-71.9
Mais de 8 anos	20.5	24.5	19.9-29.4	16.2	11.6-20.8	18.3	12.2-25.2
Não informado	15.3	23.5	18.9-28.4	5.4	0.1-10.0	12.1	6.1-19.1
Diagnóstico de câncer							< 0.001
Sim	26.6	26.4	22.6-30.6	25.2	20.7-30.0	29.2	23.1-35.8
Não	73.4	73.6	69.8-77.7	74.8	70.3-79.5	70.8	64.6-77.3

[‡] Se BMEPS < -0.1663: Baixo; se $-0.1663 \leq \text{BMEPS} \leq 0.7614$: Médio; se BMEPS > 0.7614: Alto.

[¥] Teste qui-quadrado de homogeneidade

* Foi desconsiderada a categoria 'Não informado' das variáveis sexo e diagnóstico de câncer, que haviam 1 e 4 indivíduos, respectivamente.

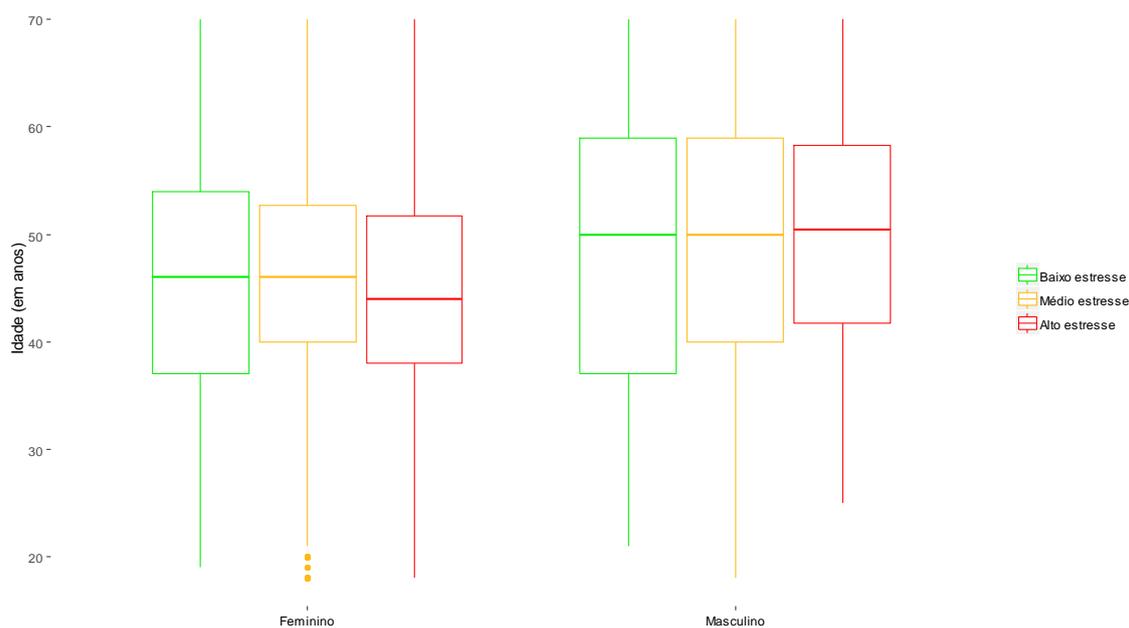


Figura 6: Distribuição da idade dos indivíduos, estratificado pelo sexo e pela classificação qualitativa do estresse de acordo com os pontos de corte sugeridos na escala BMEPS. Se BMEPS < -0.1663: Baixo estresse; se $-0.1663 \leq \text{BMEPS} \leq 0.7614$: Médio estresse; se BMEPS > 0.7614: Alto estresse.

APÊNDICE C

Exemplo de sintaxe para a análise de classes latentes e para o cálculo do índice de Youden no R.

```
# Ferramenta para facilidades no script
require(dplyr)

#-----.
#      LCA      ----
#-----.

require(poLCA)

# bd12: banco de dados contendo os itens
#n_claaases: numero de classes latentes do modelo LCA

# Ajusta o modelo
modLCA <- poLCA::poLCA(cbind(bmeps1, bmeps2, bmeps3, bmeps4,
bmeps5, bmeps6, bmeps7, bmeps8, bmeps9, bmeps10, bmeps11,
bmeps12) ~ 1, data = bd12, nclass = n_claaases, na.rm = F, nrep
= 5000)

# Medida de ajuste BIC
modLCA$bic

# probabilidade de responder a categoria k ao m-ésimo item
condicionado a classe c
modLCA

# Probabilidade a posteriori
modLCA$posterior

# Classe de alocação dos indivíduos
modLCA$predclass

#-----.
#      Índice de Youden      ----
#-----.

# Para a instalação do pacote (necessário somente 1 vez)
devtools::install_version('DiagTest3Grp', version = '1.6', repos
= "http://cran.us.r-project.org")

require(DiagTest3Grp)

# Separa Nível de Intensidade do Estresse Emocional Pré-
Operatório
# de cada em classe em vetores
```

```
# variavel tri12: Nível de Intensidade do Estresse Emocional
Pré-Operatório
# variavel classe3: classe latente na qual o individuo foi
alocado

c1 <- dplyr::filter(bd, classe3 == 1) %>%
  dplyr::select(tri12) %>% dplyr::pull()

c2 <- dplyr::filter(bd, classe3 == 2) %>%
  dplyr::select(tri12) %>% dplyr::pull()

c3 <- dplyr::filter(bd, classe3 == 3) %>%
  dplyr::select(tri12) %>% dplyr::pull()

# Índice de Youden pelo estimado pelo método 'Normal'
# para a definicao de outros métodos consulte o help da funcao
DiagTest3Grp::Youden3Grp(x = c1, y = c2, z = c3, method = 'EMP')
```