



Revista de Administração Contemporânea

ISSN: 1415-6555

ISSN: 1982-7849

Associação Nacional de Pós-Graduação e Pesquisa em Administração

Rogers, Pablo

Best Practices for Your Exploratory Factor Analysis: A Factor Tutorial
Revista de Administração Contemporânea, vol. 26, núm. 6, e210085, 2022
Associação Nacional de Pós-Graduação e Pesquisa em Administração

DOI: <https://doi.org/10.1590/1982-7849rac2022210085.en>

Disponível em: <https://www.redalyc.org/articulo.oa?id=84072128005>

- Como citar este artigo
- Número completo
- Mais informações do artigo
- Site da revista em [redalyc.org](https://www.redalyc.org)

 redalyc.org

Sistema de Informação Científica Redalyc
Rede de Revistas Científicas da América Latina e do Caribe, Espanha e Portugal
Sem fins lucrativos acadêmica projeto, desenvolvido no âmbito da iniciativa
acesso aberto

Artigo Metodológico

Melhores Práticas para sua Análise Fatorial Exploratória: Tutorial no Factor

Best Practices for Your Exploratory Factor Analysis: A Factor Tutorial



Pablo Rogers*¹

RESUMO

Contexto: a análise fatorial exploratória (AFE) é um dos métodos estatísticos mais utilizados em administração. No entanto, sua prática corrente coexiste com regras de bolso e heurísticas proferidas há meio século. **Objetivo:** o propósito deste artigo é apresentar as melhores práticas e recomendações recentes para uma AFE típica em administração através de uma solução prática acessível aos pesquisadores. **Métodos:** nesse sentido, além de serem discutidas as práticas correntes *versus* as práticas recomendadas, ilustra-se um tutorial com dados reais no Factor, um software ainda pouco conhecido na área de administração, porém *freeware*, fácil de usar (*point and click*) e poderoso. O passo a passo ilustrado no artigo, além das discussões levantadas e de um exemplo adicional, também é disponibilizado no formato de vídeos tutoriais. **Conclusão:** através da metodologia didática proposta (artigo-tutorial + vídeo-tutorial), incentivamos os pesquisadores/metodologistas que dominam alguma técnica particular a fazerem o mesmo. Especificamente sobre a AFE, esperamos que a apresentação do software Factor, como uma primeira solução, possa transcender as regras de bolso e heurísticas correntes ultrapassadas, ao tornar acessíveis as melhores práticas para os pesquisadores da administração.

Palavras-chave: análise fatorial; análise fatorial exploratória; análise de fator comum; análise de componentes principais; Factor.

ABSTRACT

Context: exploratory factor analysis (EFA) is one of the statistical methods most widely used in administration; however, its current practice coexists with rules of thumb and heuristics given half a century ago. **Objective:** the purpose of this article is to present the best practices and recent recommendations for a typical EFA in administration through a practical solution accessible to researchers. **Methods:** in this sense, in addition to discussing current practices versus recommended practices, a tutorial with real data on Factor is illustrated. The Factor software is still little known in the administration area, but is *freeware*, easy-to-use (*point and click*), and powerful. The step-by-step tutorial illustrated in the article, in addition to the discussions raised and an additional example, is also available in the format of tutorial videos. **Conclusion:** through the proposed didactic methodology (article-tutorial + video-tutorial), we encourage researchers/methodologists who have mastered a particular technique to do the same. Specifically about EFA, we hope that the presentation of the Factor software, as a first solution, can transcend the current outdated rules of thumb and heuristics, by making best practices accessible to administration researchers.

Keywords: factor analysis; exploratory factor analysis; common factor analysis; principal component analysis; Factor.

* Autor Correspondente.

1. Universidade Federal de Uberlândia, Faculdade de Gestão e Negócios, Uberlândia, MG, Brasil.

Como citar: Rogers, P. (2022). Melhores práticas para sua análise fatorial exploratória: Tutorial no Factor. Revista de Administração Contemporânea, 26(6), e210085. <https://doi.org/10.1590/1982-7849rac202210085>

Publicado em Early Access: 11 de Novembro, 2021.

Designado a essa edição: 06 de Junho, 2022.

Classificação JEL: C000.

Editores-chefes: Wesley Mendes-da-Silva (Fundação Getúlio Vargas, EAESP, Brasil) 
Marcelo de Souza Bispo (Universidade Federal da Paraíba, PPGA, Brasil) 

Editor Associado: Henrique Castro Martins (Fundação Getúlio Vargas, EAESP, Brasil) 

Pareceristas: Jorge Brantes Ferreira (Pontifícia Universidade Católica do Rio de Janeiro, IAG, Brasil) 

Um dos indivíduos revisores não autorizou a divulgação de sua identidade.

Relatório de Revisão por Pares: A disponibilização do Relatório de Revisão por Pares não foi autorizada pelos revisores.

Recebido: 15/03/2021

Última versão recebida em: 14/06/2021

Aceite em: 30/06/2021

de revisores convidados até a decisão:

	1	2	3	4	5	6	7	8	9
1ª rodada									
2ª rodada									

CONTEXTUALIZAÇÃO

A análise fatorial (AF) é uma técnica estatística de interdependência que visa determinar o número e a natureza das variáveis latentes ou fatores que explicam a variação e a covariação entre um conjunto de medidas observadas (Brown, 2015). Ela se tornou um dos procedimentos estatísticos multivariados mais amplamente utilizados em ciências sociais aplicadas, particularmente psicologia, educação, sociologia, administração, ciência política e saúde pública (Brown, 2015). Na pesquisa aplicada, a AF é comumente empregada para avaliar instrumentos de múltiplos itens, validação de construto e redução de dados (Brown, 2015; Fabrigar & Wegener, 2012). A utilização da AF nas ciências sociais aplicadas e para os fins supracitados emana do modelo de fator comum (Brown, 2015; Fabrigar & Wegener, 2012) e, por isso, é também conhecida na literatura por análise de fator comum (AFCo).

A AFCo pode ser de dois tipos: análise fatorial confirmatória (AFC) e análise fatorial exploratória (AFE). As duas têm como objetivo reproduzir as relações observadas entre um grupo de itens em um número menor de variáveis latentes. A AFC e a AFE diferem fundamentalmente pelo número e natureza das especificações a priori e restrições impostas ao modelo (Brown, 2015).

A AFE é utilizada quando o pesquisador não possui uma clara expectativa, ou quando esta é relativamente incompleta, sobre a estrutura das relações. Na AFC, o pesquisador tem uma clara predição sobre o número de fatores e as medidas específicas influenciadas pelos fatores (Fabrigar & Wegener, 2012). A AFE é uma abordagem baseada em dados, de modo que nenhuma especificação, a priori, seja feita em relação ao número de fatores e relações entre os fatores/itens (Brown, 2015). Comumente, a AFE é empregada como um primeiro passo para determinar o número apropriado de fatores e descobrir quais variáveis observadas são indicadoras das variáveis latentes (Brown, 2015).

Na AFC o pesquisador especifica o número de fatores e a estrutura das relações entre os fatores e indicadores. Nesse sentido, uma solução pré-especificada é avaliada em termos de quão bem ela reproduz a matriz de correlação amostral das variáveis observadas (Brown, 2015). Assim, ao contrário da AFE, a AFC requer uma forte base conceitual para orientar a especificação e a avaliação do modelo estimado e, por isso, é recomendada nas fases posteriores do processo de desenvolvimento de escala e validação de construto (Brown, 2015).

Duas abordagens intermediárias e complementares ganharam corpo na literatura na última década: análise fatorial confirmatória parcial (AFCP) e modelagem de equações estruturais exploratória (ESEM). A primeira emprega uma AFE convencional e faz uso das medidas de ajuste encontradas na AFC (Gignac, 2009; Hoelzle & Meyer, 2013). A segunda

utiliza o arcabouço/sistematização da modelagem de equações estruturais (SEM), na qual a AFC está incorporada, para confrontar um conjunto de modelos e grupos (Marsh et al., 2009; 2010; Marsh, Morin, Parker, & Kaur, 2014; Marsh, Guo, Dicke, Parker, & Craven, 2020). Segundo seus metodologistas, a AFC não é uma técnica estritamente confirmatória, nem a AFE é uma técnica estritamente exploratória, o que justifica um *framework* geral e integrado, com incorporação da flexibilidade da AFE e eliminação das restrições da AFC. Discutir a AFC, assim como a AFCP e a ESEM, está fora do escopo do artigo, por isso, aos leitores interessados sugerem-se algumas referências (Brown, 2015; Gignac, 2009; Kline, 2016; Marôco, 2014; Marsh et al., 2014; Marsh et al., 2009; Thompson, 2004).

A AFE é frequentemente confundida com análise de componentes principais (ACP). Esse fato se dá porque um dos métodos de extração, comum e erroneamente empregado na AFE, é o método de componentes principais (Brown, 2015; Gaskin & Happell, 2014; Hauck-Filho & Valentini, 2020). A AFE pode ser utilizada para fins de redução de dados, porém a ACP se limita a esse fim (Gaskin & Happell, 2014; Hauck-Filho & Valentini, 2020; Lloret, Ferreres, Hernández, & Tomás, 2014). Ambas têm por objetivo reduzir um conjunto de indicadores/itens em menos variáveis.

A ACP é uma técnica mais parcimoniosa, pode contribuir com informações para decisões sobre o número de fatores a serem retidos e ser o primeiro passo antes da AFE, principalmente quando se tratar de problemas complexos. No entanto, a maioria dos metodologistas recomenda que a AFE seja empregada quando o objetivo é identificar construtos latentes responsáveis por variação das variáveis observadas (Fabrigar & Wegener, 2012; Gaskin & Happell, 2014; Watkins, 2018). Alguns analistas de dados não consideram a ACP como uma técnica de AF, mas como uma técnica de sumarizar muitas variáveis em menos componentes (Hauck-Filho & Valentini, 2020; Henson & Roberts, 2006).

Na ACP os cálculos são relativamente mais simples (Brown, 2015). Ela se propagou devido à menor necessidade de poder computacional, sendo o método de extração padrão nos principais softwares comerciais (Costello & Osborne, 2005; Lloret et al., 2014). Inclusive, Baglin (2014), Costello e Osborne (2005), Izquierdo, Olea e Abad (2014), e Lloret, Ferreres, Hernández e Tomás (2014) argumentam que provavelmente isso explica a popularidade da ACP e a primeira confusão cometida quando se pretende desenvolver uma AFE.

No SPSS, por exemplo, software comercial mais utilizado na área de ciências sociais aplicadas, a ACP é desenvolvida dentro do menu *Analyze/Dimension reduction/ Factor* pela escolha padrão do método de extração *principal component* (PC). Nesse sentido, ao permanecer com o default do software, o pesquisador está realizando uma ACP em vez de uma AFE, como sugere o menu. Nesse desenrolar, muitos

pesquisadores erroneamente acreditam, ainda hoje, que ACP seja um tipo de AFE (Damásio, 2012).

Utilizar o default do SPSS quando o objetivo é reduzir os dados não está incorreto. No entanto, verifica-se que a AFE, para fins de instrumentos de múltiplos itens e validação de construto, muitas vezes é guiada pelas opções padrão dos softwares, gerando decisões incorretas sobre o número e definições dos fatores (Izquierdo, Olea, & Abad, 2014).

O leitor pode verificar esse argumento ao buscar ‘análise fatorial exploratória’ ou ‘*exploratory factor analysis*’ no YouTube. A maioria dos vídeos apresentados é de aplicações no SPSS, sendo que em muitos deles, apesar de o problema se relacionar com a obtenção de um modelo de fator comum no contexto das ciências sociais aplicadas, empregam-se opções default do software. Segundo Lloret, Ferreres, Hernández e Tomás (2017), a famosa combinação padrão do SPSS (*principal component analysis + Kaiser criterion + varimax rotation*) é provavelmente a pior maneira de desenvolver uma AFE. Infelizmente, esse procedimento é ainda muito frequente e acompanhado de diversas outras regras de bolso e heurísticas ultrapassadas (Gaskin & Happell, 2014).

Este artigo tem como objetivo secundário discutir as heurísticas tradicionais no contexto da AFE e indicar as melhores práticas baseadas nas evidências recentes, de acordo com as principais decisões que o pesquisador deve tomar ao desenvolver uma AFE: (a) tamanho da amostra; (b) matriz de correlação; (c) método de extração; (d) número de fatores; e (e) rotação fatorial.

O objetivo principal do artigo é apresentar um passo a passo para realizar uma AFE no Factor (Ferrando & Lorenzo-Seva, 2017). Lloret et al. (2017) mostram que o Factor é o software mais completo para realizar AFE, especialmente concebido para esse fim, e possui a vantagem de ser *freeware*. Segundo os autores, é o software mais flexível e incorpora as melhores práticas recentes para a AFE (Lloret, Ferreres, Hernández, & Tomás, 2017). O tutorial desenvolvido foi exemplificado a partir de dados reais de uma escala multidimensional, com características semelhantes com que pesquisadores em ciências sociais aplicadas se defrontam recorrentemente.

Adicionalmente, o artigo tem como proposta ser um recurso multimídia completo, disponibilizando aos leitores vídeos tutoriais sobre os assuntos tratados: (a) discussão acerca das principais práticas correntes e recomendações recentes para desenvolvimento de uma AFE no contexto das ciências sociais aplicadas¹, (b) tutorial para desenvolver uma AFE no Factor a partir da escala multidimensional apresentada no artigo², e (c) tutorial extra no Factor, não discutido no presente artigo, a partir de dados reais de uma escala unidimensional³.

Embora a evolução dos computadores pessoais tenha tornado a AFE mais acessível aos pesquisadores, a qualidade da prática da AFE não parece ter melhorado (Henson &

Roberts, 2006; Izquierdo et al., 2014; Lloret et al., 2017; Lloret et al., 2014; Watkins, 2018). Segundo Gaskin e Happell (2014) e Watkins (2018), um dos principais motivos é que os pesquisadores tendem a emular publicações inadequadas e confiar na padronização de softwares que indicam métodos não ideais. Uma parcela significativa das pesquisas que utiliza AFE emprega métodos equivocados, desenvolvidos na metade do século passado, principalmente porque ainda são o padrão nos principais programas estatísticos (Damásio, 2012; Gaskin & Happell, 2014; Lloret et al., 2014). Espera-se com este tutorial multimídia contribuir para mudar o referido cenário, ao divulgar o Factor, um software gratuito, fácil de usar (*point and click*) (Damásio & Dutra, 2018), poderoso (Baglin, 2014; Izquierdo et al., 2014) e com grande potencial (Lloret et al., 2017), apesar de ainda pouco utilizado na área da administração no Brasil e sem um manual didático acessível (Lloret et al., 2017). Foi somente na última versão do programa (em abril de 2021) que os autores do software colocaram menus de ajuda com algumas notas técnicas.

A revisão da literatura profissional tem, consistentemente, encontrado muitas aplicações de AFE com escolhas imprudentes de métodos e relatórios incompletos (Watkins, 2018). Nas últimas três décadas, revisões sistemáticas da literatura que abordaram a AFE (Bido, Mantovani, & Cohen, 2018; Fabrigar, Wegener, MacCallum, & Strahan, 1999; Ford, MacCallum, & Talt, 1986; Gaskin & Happell, 2014; Henson & Roberts, 2006; Howard, 2016; Izquierdo et al., 2014; Lloret et al., 2017) chegaram a conclusões similares: altas taxas de decisões incorretas ou injustificadas, normalmente com base em critérios ou padrões clássicos ou desatualizados.

Nesse sentido, também se pretende contribuir com a discussão crítica desses padrões clássicos/desatualizados e indicar recomendações de melhores práticas na condução da AFE. Infelizmente, no contexto recente da administração no Brasil, ainda se adotam e se ensinam escolhas imprudentes de métodos (Dias, Silva-Spineli, & Macedo, 2019; Hair, Gabriel, Silva, & Braga, 2019; Vidal, 2016), e não são abordadas as principais evoluções recentes em propostas de manuais dedicados à AFE (Matos & Rodrigues, 2019). Esse assunto será tratado na próxima seção, contextualizando as principais decisões da AFE. Na sequência, será discutido o exemplo utilizado como caso no Factor, a partir dos seguintes passos: (a) instalando o software; (b) inserindo a base de dados; (c) configurando a análise; e (d) interpretando o *output*. Ao final, conclui-se o tutorial *vis-a-vis* a discussão levantada nesta introdução e seção seguinte.

REGRAS DE BOLSO E MELHORES PRÁTICAS NUMA AFE TÍPICA

O presente artigo não tem pretensão de aprofundar-se nos procedimentos de cálculo na AFE, tampouco esgotar a discussão sobre cada uma das principais decisões que o

pesquisador deve enfrentar quando do ajuste de um modelo AFE. Para isso, recomendam-se algumas referências nacionais: (a) com indicação das principais diretrizes (Laros, 2012); (b) para uma abordagem matemática intermediária (Mingoti, 2005); e (c) para uma abordagem matemática mais avançada (Ferreira, 2018). Infelizmente, até a presente data, nenhum manual nacional ou traduzido para o português incorporou todas as recomendações apresentadas nesta seção. Nesse sentido, recomenda-se a leitura das referências a seguir e/ou textos mais densos, exclusivos sobre AFE (Brown, 2015; Fabrigar & Wegener, 2012; Thompson, 2004).

As orientações e recomendações na sequência levam a cabo, principalmente, uma AFE típica executada nos estudos em ciências sociais aplicadas, ou seja, aquelas que visam ao ajuste de um modelo de fator comum (AFCo) cuja escala de mensuração seja no máximo ordinal, e/ou os dados não apresentam uma distribuição de normalidade multivariada e/ou são fortemente assimétricos (assimetria fora de -1 e +1). Essas condições prevalecem em estudos de validação de construto e para avaliar instrumentos de múltiplos itens do tipo Likert com menos de cinco opções de resposta (Baglin, 2014; Lloret et al., 2014).

Concernente ao tamanho amostral, as regras de bolso de tamanho mínimo (N), número de observações (n) e quantidade de parâmetros (p) propagadas no Brasil, principalmente pelo manual de Hair, Black, Babin e Anderson (2014), carecem de validade científica. O referido manual indica um corte por baixo. No entanto, os mesmos estudos clássicos citados por ele também sugerem amostras 20 vezes maiores. Assim, sugestões de N = 50, 100, 200, 300, 400, 500 ou 1.000 e n:p = 5:1, 10:1 ou 20:1 são comuns na literatura (Costello & Osborne, 2005; Gaskin & Happell, 2014; Howard, 2016; Lloret et al., 2014) e agradam a todas as necessidades sem levar a cabo a preocupação do tamanho da amostra numa AFE.

Esse ponto ainda não é unânime na literatura. No entanto, um ponto de convergência entre os estudos de simulação recentes trata do fato de que a AFE é um procedimento de grandes amostras (Costello & Osborne, 2005; Gaskin & Happell, 2014; Lloret et al., 2014). O tamanho da amostra necessário também é determinado pela natureza dos dados: situações em que se esperam altas communalidades (> .80), baixas cargas cruzadas (< .30) e altas cargas em cada um dos fatores (> .50) necessitarão de amostras menores (Gaskin & Happell, 2014; Lloret et al., 2014). No entanto, essas condições são raras na prática. O número de itens por fator e o número de fatores também podem impactar o tamanho amostral requerido (Gaskin & Happell, 2014). Quanto mais, melhor (Costello & Osborne, 2005; Gaskin & Happell, 2014; Howard, 2016; Lloret et al., 2014). No entanto, para estudos que levam a cabo uma matriz policórica, recomenda-se um mínimo de 300 observações (Lloret et al., 2014).

Sobre a matriz dos dados que deve ser utilizada, diversos estudos de simulação demonstraram que a matriz de correlação de Pearson é enviesada em estimar (subestima) a matriz de correlação populacional quando os dados são ordinais (Baglin, 2014; Ferrando & Lorenzo-Seva, 2014; Holgado-Tello, Chacón-Moscoso, Barbero-García, & Vila-Abad 2010; Lloret et al., 2014). A matriz de correlação policórica/tetracórica é a melhor opção nesses casos. A matriz de Pearson deve ser usada apenas para dados contínuos.

No que diz respeito ao método de extração fatorial, quando se trata de variáveis ordinais os métodos baseados em mínimos quadrados [família OLS (*ordinary least squared*), tal como ULS (*unweighted LS*) e DWLS (*diagonally weighted LS*)] são os mais recomendados. Estudos de simulação indicam que eles reproduzem os melhores resultados em pequenas amostras (Gaskin & Happell, 2014; Izquierdo et al., 2014; Lloret et al., 2014). O método PC superestima as cargas fatoriais e a variância explicada pelos fatores. Além disso, ao executar uma AF por PC, não se está desenvolvendo, verdadeiramente, uma AFE típica (Hauck-Filho & Valentini, 2020). Durante décadas o método PC foi utilizado para problemas de AFE devido à facilidade computacional. No entanto, atualmente esse argumento não é válido (Gaskin & Happell, 2014; Lloret et al., 2014). O método de máxima verossimilhança (ML) não é recomendado com o uso de matriz policórica. O método DWLS (ou *WLS mean and variance adjusted* – WLSMV) é sugerido para violações da normalidade multivariada e quando as variáveis são ordinais (Izquierdo et al., 2014).

Os critérios tradicionais para retenção fatorial [critério de Kaiser (i.e., autovalor > 1), gráfico *scree* e variância explicada] têm sido, consistentemente, criticados por superestimar o número de fatores (Gaskin & Happell, 2014; Howard, 2016; Izquierdo et al., 2014; Lloret et al., 2014). Qualquer combinação deles deve ser evitada (Lloret et al., 2014). A literatura é dura e contundente sobre a utilização do critério de Kaiser (único critério clássico que é objetivo) para escolha do número de fatores. O critério de Kaiser foi proposto há meio século por questões de eficiência computacional. Estudos de simulação recentes sequer consideram o critério de Kaiser, pois partem do pressuposto de que é um método inapropriado e comprovam a melhor performance da análise paralela e método de Hull, particularmente em dados ordinais (Gaskin & Happell, 2014; Howard, 2016; Izquierdo et al., 2014; Lloret et al., 2014).

Concernente aos métodos de rotação, por padrão, as rotações oblíquas deveriam ser preferidas em detrimento das rotações ortogonais, pois em ciências sociais aplicadas é mais difícil justificar fatores não correlacionados do que correlacionados (Baglin, 2014; Costello & Osborne, 2005; Howard, 2016; Izquierdo et al., 2014; Lloret et al., 2014). Além disso, as rotações oblíquas reproduzirão uma rotação ortogonal quando os fatores não forem, de fato, correlacionados: o inverso não é verdadeiro. Entre as rotações oblíquas, a oblimin e a

promax são as mais utilizadas e recomendadas (Izquierdo et al., 2014). A promin é uma opção mais simples e flexível disponível no Factor.

E por fim, sobre o software para realização de uma AFE típica, o SPSS destaca-se como o software comercial mais utilizado em ciências sociais aplicadas. Seu default contribuiu para propagar a pior decisão que se pode tomar numa AFE (Lloret et al., 2014; 2017). Ele permite desenvolver apenas análises lineares, pois utiliza apenas a matriz de correlação de Pearson. O Factor é um software livre, fácil de usar, poderoso e que engloba todas as melhores práticas recentes (Baglin, 2014; Damásio & Dutra, 2018; Ferrando & Lorenzo-Seva, 2017; Lloret et al., 2017). Mesmo com os *plug-ins* existentes para o SPSS, ainda assim o Factor é uma opção melhor. Se o pesquisador tem familiaridade com linhas de programação, outra opção seria o pacote *psych* do R.

O EXEMPLO

A base de dados utilizada como estudo de caso consta na pesquisa de Rogers, Armada e Rogers (2020). Fez uso parcial do instrumento da pesquisa, empregando para os presentes fins apenas a escala WHOQOL-Bref (*World Health Organization Quality of Life*) da Organização Mundial da Saúde (OMS). A escala conta com 26 itens do tipo Likert de cinco pontos, dos quais se utilizam apenas 24 itens. A escala foi concebida tendo em vista quatro fatores (físico, psicológico, social e ambiental). No entanto, evidências empíricas recentes (Perera, Izadikhah, O'Connor, & McIlveen, 2018) dão suporte a uma estrutura mais parcimoniosa (um ou dois fatores) e/ou mais complexa (bifatorial ou de ordem superior). Rogers et al. (2020) utilizaram 918 observações para avaliar o bem-estar financeiro *versus* a qualidade de vida e saúde de investidores brasileiros. No entanto,

no presente estudo não aplicamos um dos filtros utilizados pelos autores, e desenvolve-se o exemplo com 1.047 observações.

TUTORIAL DO FACTOR

Por mais que sejam procedimentos simples, como instalar o software e inserir a base de dados, cabe ressaltar que alguns detalhes delineados adiante poderão ajudar na produtividade do usuário, haja vista algumas nuances do programa.

Instalando o software

O Factor é um software livre e pode ser baixado no site do Departamento de Psicologia da Universitat Rovira i Virgili, Tarragona, Espanha (Ferrando & Lorenzo-Seva, 2017). Infelizmente, até o presente momento, ele encontra-se disponível apenas para o ambiente Windows. Trata-se de um arquivo único, pequeno e sem necessidade de instalação, basta clicar no arquivo baixado (.exe) para executar o programa. Aqui fica a primeira dica: como é um arquivo que ocupa pouco espaço no computador, recomenda-se ter o arquivo executável na pasta em que se encontra a base de dados para análise. O usuário pode ter tantos arquivos executáveis do software quanto achar necessário, dependendo da quantidade de bases de dados que esteja analisando simultaneamente.

Inserindo a base de dados

Ao executar o programa, temos a tela que se apresenta na Figura 1a. Para a leitura dos dados, deve-se clicar em *Read data*. As análises são configuradas no menu *Configure analysis*, e somente depois o botão *Compute* executará os cálculos necessários e mostrará o *output* para leitura e interpretação. A Figura 1b mostra a tela onde a base de dados deve ser inserida. Neste artigo não discutiremos o menu *Multiple group analysis*.




Figura 1. Tela principal (a) e menu de inserção de dados (b) no Factor.

O software aceita apenas arquivos no formato .txt e .dat separado por tabulações. Essa estrutura de arquivo deve ser gerada (salvar como) pelo usuário em outro software, como Excel ou SPSS, pois o Factor não possui uma interface própria de edição de dados. Não inclua os rótulos das variáveis na primeira linha e salve no arquivo apenas as variáveis que serão utilizadas na análise, tal como se apresenta na Figura 2a. Essa última dica é altamente recomendada, pois o software faz leitura das variáveis de forma genérica (v1, v2, ..., vn) e uma grande base de dados pode diminuir a

produtividade e confundir o usuário. Além disso, o software gera as amostras *bootstrap* antes de configurar as análises e inclui todas as variáveis da base de dados (alguma alteração na configuração das análises, como exclusão de variáveis, pode fazer o software fechar). Opcionalmente, o usuário poderá inserir um arquivo de legenda das variáveis como na Figura 2b. Esse arquivo deverá ter o mesmo número de linhas que o número de colunas da base de dados e no máximo 40 caracteres por linha.

5	4	2	5	3	4	3	3
5	5	3	3	3	3	2	3
5	4	3	4	5	2	2	4
5	5	5	5	5	4	5	4
3	4	3	4	4	4	4	3
2	4	4	4	4	4	4	3
5	4	4	5	2	4	4	4
5	5	3	3	4	3	3	4
5	5	4	5	3	2	2	3
4	5	4	5	3	4	3	3
4	2	3	3	3	2	2	2
5	5	4	4	4	2	2	4
5	5	3	4	5	2	3	3
2	1	3	5	3	5	3	3
3	3	2	3	2	4	2	3
5	5	4	5	2	3	4	4
5	5	2	4	4	3	4	3

Q3_F
Q4_F
Q10_F
Q15_F
Q16_F
Q17_F
Q18_F
Q5_P
Q6_P
Q7_P
Q11_P
Q19_P
Q26_P
Q20_S
Q21_S
Q22_S
Q8_A

Figura 2. Formato da base de dados (a) e legenda (b) no Factor.

Se a leitura dos dados foi feita corretamente, os números em *Numbers of participants* e *Number of variables* (Figura 1b) serão destacados em verde. Confira se realmente esses números dizem respeito à sua base de dados. O usuário também poderia fazer as análises a partir de uma matriz de covariâncias (nesse caso, deve-se inserir uma matriz quadrada). Essa opção é útil quando não há os dados brutos, provindos dos resultados de um artigo, por exemplo, e deseja-se conferir, replicar ou até mesmo compilar achados para uma meta-análise. Com essa opção de tipo de dados nem todas as medidas de ajustes serão calculadas.

Caso exista expectativa sobre quantos fatores serão extraídos e o peso dos itens em cada fator, pode-se, a priori, definir uma matriz-alvo para isso (*Rotation target matrix*). Se for necessário, incentivamos o leitor a clicar no botão de interrogação ao lado para entender como configurar essa matriz. Finalmente, recomenda-se deixar as seleções padrão

marcadas na Figura 1b: (a) 500 amostras são suficientes para análises robustas em *Compute bootstrap samples*; e (b) se houver valores ausentes, inserir um código para eles na base de dados. A primeira seleção se refere ao procedimento de cálculo dos intervalos de confiança das estimativas que serão apresentadas nos resultados, via processo de re-amostragem (*bootstrapping*).

Não deixe as células vazias e cuidado para não indicar código de um valor real. Se não existir nenhum *missing* na base de dados, a seleção do menu (*Missing value code*) ou código indicado não fará diferença nas análises. Se existir alguma célula vazia, toda a linha será excluída das análises. Caso haja algum *missing* identificado pelo usuário, o software gerenciará os valores ausentes a partir da proposta de [Lorenzo-Seva e van Ginkel \(2016\)](#). Estudos recentes de simulação encontraram mínimas diferenças entre métodos alternativos de imputar valores ausentes no contexto da AFE ([Gaskin & Happell, 2014](#)).

Configurando a análise

Após inserir os dados, clique no botão *Configure analysis* no menu principal. Ele continuará aberto, mas uma tela como na Figura 3 também será aberta para selecionar todos os parâmetros da AFE. Como não selecionamos *Multiple group analysis* na tela de inserção dos dados (Figura 1b), não precisamos considerar o menu *Data configuration*, apesar de que nesse menu o usuário tem a oportunidade de visualizar os dados inseridos. Primeiro, abaixo da tela (Figura 3a), indique o nome do arquivo que conterá o *output*. Ele será salvo no formato .txt na pasta em que se encontra o arquivo executável do software. No canto superior esquerdo da tela (*Variables in the analysis*), não será preciso nenhum

procedimento caso o seu banco de dados contenha apenas as variáveis que entrarão na análise. Note que, como já comentado, o Factor codifica as variáveis de forma genérica ($v_1, v_2, \dots, v_n$) e, por isso, sugerimos utilizar um arquivo de legenda e apenas inserir as variáveis de interesse no banco de dados. A legenda somente terá efeito no *output*.

No canto superior direito (*Matrix analyzed*) deve-se tomar uma das principais decisões da AFE, muitas vezes relegada à opção padrão dos principais softwares: a matriz de correlação utilizada. Em nosso exemplo, como se trata de uma escala de verificação ordinal, com apenas cinco opções de respostas, a matriz policórica torna-se mais apropriada (Figura 3b).




Figura 3. Configurando a análise no Factor.

Nos menus *Configure smoothing* e *Configure PA* (Figura 4), geralmente mantém-se o padrão do Factor. O primeiro (Figura 4a) refere-se ao algoritmo utilizado para solucionar o problema de uma matriz não definida positivamente, o que pode acontecer, principalmente, para matrizes policóricas nos métodos *least squares*. A essência desses algoritmos consiste

em suavizar (mudar os pesos relativos) dos elementos da diagonal em relação aos elementos fora da diagonal, perdendo o mínimo de variância possível no processo. O algoritmo default do Factor (*sweet smoothing*) foca somente nas variáveis problemáticas e, por isso, é mais eficiente em não perder variância (Lorenzo-Seva & Ferrando, 2020).

O Factor conta com quatro procedimentos robustos para escolha do número de fatores: (a) BIC (*Bayesian information criterion*); (b) *minimum average partial* (MAP), caso seja selecionado o método de extração *minimum rank factor analysis* (MRFA); (c) análise paralela (Figura 4b); e (d) método de Hull. A análise paralela (PA) refere-se às soluções de Timmerman e Lorenzo-Seva (2011) e Lorenzo-Seva, Timmerman e Kiers (2011). A solução clássica de Horn requer muito recurso

computacional e, por isso, Timmerman e Lorenzo-Seva (2011) propuseram uma implementação otimizada da PA igualmente robusta, que compara os fatores gerados com a variância explicada ao invés dos autovalores. No presente exemplo optou-se pela PA otimizada (Timmerman & Lorenzo-Seva, 2011), conforme opções default apresentadas na Figura 4b, apesar de o método de Hull ser igualmente robusto (Lorenzo-Seva & Ferrando, 2019).

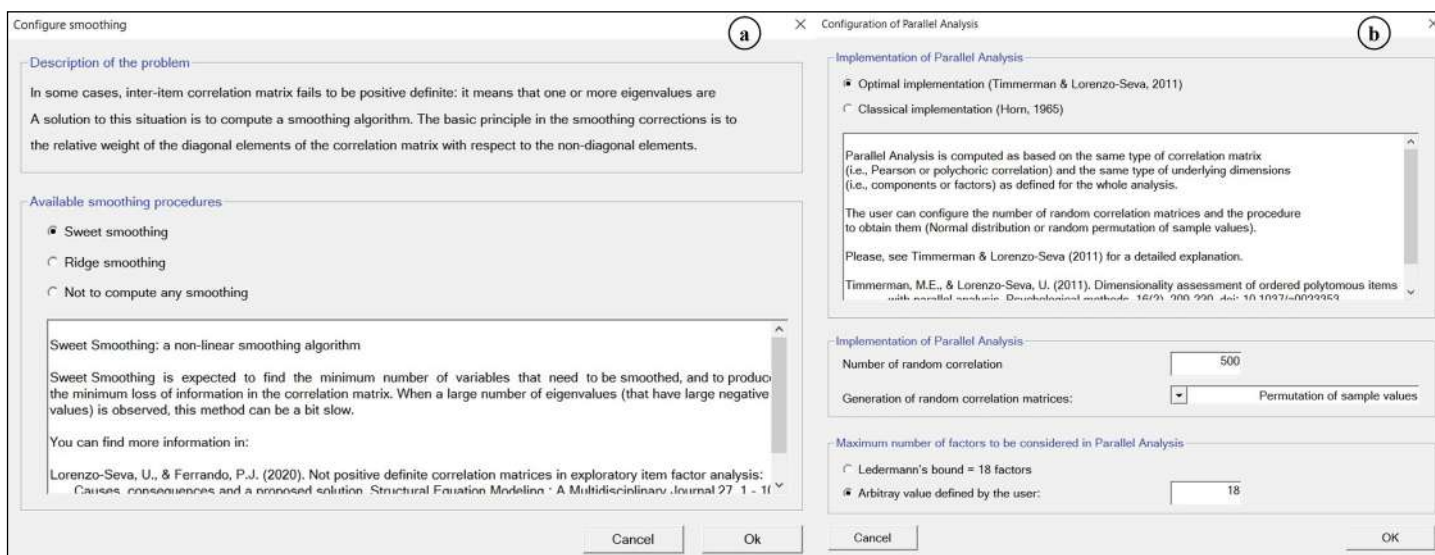


Figura 4. Smoothing (a) e análise paralela (b) no Factor.

Aumentar o número de matrizes aleatórias, a partir de simulações (*Normal distribution*) em detrimento de permutações, dependendo do número de observações e variáveis, pode incrementar demasiadamente o tempo de cálculo das análises. Adicionalmente, se selecionada a opção *Permutation of sample values*, as matrizes de correlações serão geradas a partir dos dados originais, oferecendo estimativas mais fidedignas quando a distribuição amostral observada e populacional não for normal (Damásio & Dutra, 2018; Timmerman & Lorenzo-Seva, 2011). Inclusive, na PA, não se recomenda avaliar todos os números de fatores possíveis (iguais ao número de variáveis), mas no máximo o número indicado por Ledermann (Timmerman & Lorenzo-Seva, 2011).

Em *Factor model* (Figura 3), definimos quatro fatores a serem estimados devido à expectativa a priori sobre a WHOQOL. Os dois métodos mais recomendados são ULS e DWLS, por se tratarem de variáveis ordinais com cinco graduações. O último é o mesmo WLSMV utilizado no Mplus. O ML somente estará disponível se não selecionarmos uma matriz policórica. A opção *FREE factor analysis* ainda está em desenvolvimento pelos autores do Factor e não se encontra disponível.

Inúmeras opções de rotação estão disponíveis ao usuário, como apresentado na Figura 5. Nessas condições, supondo que os fatores compartilham certo grau de relação, as rotações mais indicadas são do tipo oblíquo – especificamente, as mais utilizadas são as *direct oblimin* (Figura 5a) e *promax* (Figura 5b). Infelizmente, na maioria dos softwares o default é uma rotação do tipo ortogonal (*varimax*), que deveria ser utilizada apenas com uma boa justificativa teórica para assumir independência entre os fatores. No Factor, o default é *promin*, uma rotação oblíqua, que resulta em valores muito próximos da *oblimin*, tornando-se indicada quando o método de extração for DWLS (Watkins, 2018). Se o usuário tivesse definido uma opção de matriz de rotação (pesos alvo) no menu inicial (*Read data*), dever-se-ia selecionar a opção *Rotation target* (Figura 5c).

As telas que se abrem ao selecionar *Configure robust factor analysis* (Figura 3c) e *Other specifications of factor model* (Figura 3d) são expandidas nas Figuras 6a, 6b e 6c, respectivamente.

A primeira (Figura 6a) refere-se às configurações das estimativas dos intervalos de confiança por *bootstrap*; no presente caso, adota-se o default do Factor. O método robusto de estimação das medidas de ajuste é o mesmo utilizado no software Mplus (WLSMV), o mais completo quando se trata de SEM. Como já comentado, uma amostra $n = 500$ é considerada

suficiente para os presentes fins, e a adoção do método BCa (*bias-corrected and accelerated*) é o mais recomendado para estimar os intervalos por *bootstrap*. As seleções *Factor/Component loadings values* e *Inter-factor correlations* computarão os intervalos

bootstrap para as cargas fatoriais e a correlação entre os fatores, respectivamente. Cabe ressaltar, inclusive, que o Factor é capaz de gerar modelos baseados na teoria de resposta ao item (TRI) (Damásio & Dutra, 2018).




Figura 5. Métodos de rotação no Factor.

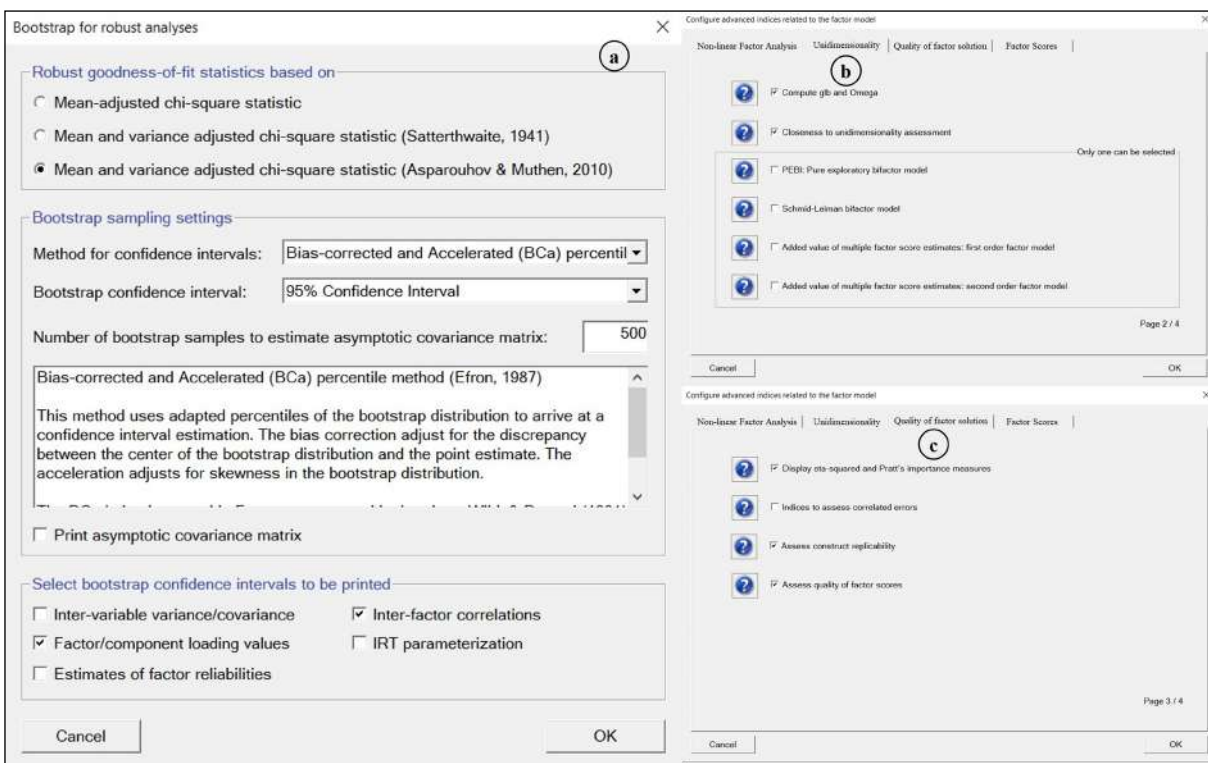


Figura 6. Configuração do *bootstrap* (a) e medidas de avaliações adicionais (b) e (c).

Nas outras especificações do modelo (Figuras 6b e 6c), selecionaremos apenas os menus *Unidimensionality* e *Quality of factor solutions*. Não serão avaliados os parâmetros (discriminação e dificuldade) estimados por um modelo TRI nem se tornam necessários os escores fatoriais estimados. Geralmente, deixamos para calcular os escores fatoriais quando do ajuste do modelo final. Assim, basta indicar o método de cálculo (um método bayesiano pode ser o mais indicado: EAP) e o nome do arquivo com o *output*, que será salvo na pasta em que se encontra o executável do software. Para além do padrão do software, cinco outras seleções são requisitadas: *Compute glb and omega* e *Closeness to unidimensionality assessment*, para serem avaliadas a confiabilidade e a unidimensionalidade da escala; e *Display eta-squared and Pratt's importance measures*, *Assess construct replicability*, e *Assess quality of factor scores*, para avaliar o tamanho do efeito dos fatores sobre os itens (interessante no exame de cargas cruzadas), a replicabilidade do constructo e a qualidade dos escores fatoriais.

Por fim, em *Configure rotation* (Figura 3), se selecionável quando da estimativa de uma escala multidimensional, geralmente não são necessárias inserções adicionais, pois trata-se de como o algoritmo de rotação vai operar. Caso haja algum problema de convergência, num primeiro momento, talvez seja o caso de aumentar o número de iterações.

Quando da finalização da configuração da AFE, clique em *Compute* (Figura 1a). O Factor começará a calcular os valores para a análise e ao término abrirá o *output*. Paciência, o Factor demora bem mais do que outros softwares do mercado, independentemente do poder computacional do computador do usuário, seja porque ele utiliza apenas um *core* do processador, seja porque suas análises são, efetivamente, mais densas. Afinal, para quase todas as medidas, calculam-se os intervalos de confiança via *bootstrap*. O exemplo em questão demorou 64 minutos em um Ryzen 5 com 16 Gb de RAM.

Interpretando os outputs

Ao final do processamento, o Factor emite um arquivo único com as análises, que será aberto automaticamente no bloco de notas ou em um software padrão para leitura de arquivos .txt definido no computador pelo usuário. Nesse caso, deve-se rolar o arquivo até o final para avaliar cada bloco de interesse. Os mais importantes, e na sequência do *output* que foi emitido, ilustraremos e comentaremos adiante.

O primeiro bloco do *output* (Figura 7a) detalha as escolhas metodológicas configuradas na etapa anterior. É recomendado conferir tais definições para avaliar se não houve nenhum deslize na etapa de configurações. Além disso, caso haja problemas no cômputo da matriz de correlações policóricas, o Factor automaticamente utilizará a matriz de Pearson. Note que para cada uma das escolhas existe uma citação de literatura, e essa lógica perdura em todo *output*, sendo que ao final as referências são apresentadas. Esse recurso torna-se muito importante para os pesquisadores que desejam referenciar suas escolhas metodológicas nos trabalhos científicos.

Na sequência, o Factor apresenta algumas estatísticas univariadas e o gráfico de barras para cada uma das variáveis observadas inseridas na análise. Esses blocos não serão comentados, ficando a cargo do leitor. Logo em seguida têm-se algumas estatísticas multivariadas (Figura 7b): (a) o teste de Mardia de normalidade multivariada, que no presente caso não foi significativo, rejeitando assim que os dados apresentam normalidade multivariada; e (b) a matriz de correlação policórica estimada. No caso do primeiro achado, o valor da curtose multivariada é muito alto para considerar os dados normalmente distribuídos, o que já era esperado, haja vista o caráter ordinal das variáveis. Sobre as correlações, muitos valores abaixo de 0,30 para uma mesma variável podem indicar falta de aderência do item em questão à estrutura fatorial proposta.




Figura 7. Detalhes das análises (a) e estatísticas multivariadas (b) no Factor.

A Figura 8a apresenta a primeira inferência que se deve fazer para avaliar a adequabilidade da AFE. O teste de Bartlett foi altamente significativo, rejeitando assim que a matriz de correlações policóricas estimada seja igual a uma matriz identidade. O KMO também se mostrou muito bom (0,923), acima dos valores recomendados para as medidas de adequabilidade da amostra (Howard, 2016). Essas duas

medidas são preliminares e não dizem muito a respeito do ajuste do modelo AFE; inclusive, o teste de Bartlett não é considerado importante para muitos autores e é relegado nos trabalhos empíricos mais recentes (Ferrando & Lorenzo-Seva, 2018), devido, quase sempre, ao fato de rejeitar a hipótese nula (Howard, 2016).




Figura 8. Adequabilidade da matriz de correlação, autovalores (a) e análise paralela (b) no Factor.

Ainda na Figura 8a, na parte de baixo, pode-se visualizar o resultado da recomendação do número de fatores pelo critério de Kaiser. Nesse caso, seriam escolhidos cinco fatores [*eigenvalue* (autovalor) > 1], o que num primeiro momento parece ser incorreto, pois o conhecimento prévio da estrutura fatorial da escala WHOQOL indica apenas quatro fatores. A técnica de retenção fatorial da PA (Figura 8b) indica a seleção de apenas um ou dois fatores, diferente dos quatro fatores, como a escala foi originalmente concebida, mas consoante às evidências empíricas mais recentes sobre esse modelo de medida (Perera et al., 2018). De acordo com os resultados da PA, em 500 matrizes aleatórias geradas a partir dos dados originais, em média, um terceiro fator explicou em torno de 7,5% da variância, abaixo dos 7% explicados pelos dados reais. Se um terceiro fator encontrado ao acaso pelos mesmos dados explica mais da variância do terceiro fator gerado pelos dados reais, não se espera, efetivamente, que exista um terceiro fator (i.e., a sugestão de um terceiro fator possivelmente se trata de um erro amostral). Por analogia, conseguimos avaliar as outras sugestões de retenção fatorial.

Uma questão importante do ponto de vista teórico, e muitas vezes relegada, é a avaliação da unidimensionalidade. Uma estrutura multifatorial poderá ser somada em um único escore geral, como muitas vezes encontramos em trabalhos empíricos; no entanto, o inverso não pode acontecer: uma estrutura essencialmente unidimensional não poderá ser particionada em subescalas. Sobre essa questão, o leitor deverá aprofundar-se na discussão de modelos *bifactor* ou *higher-order*, que nos últimos anos têm auxiliado na descoberta de novas estruturas latentes (Damásio & Dutra, 2018) e salvado muitos instrumentos de medida clássicos (Brown, 2015). O Factor apresenta três medidas para avaliar a unidimensionalidade, de acordo com a proposta de Ferrando e Lorenzo-Seva (2018): (a) *unidimensional congruence* (UniCo) > 0,95; (b) *explained common variance* (ECV) > 0,85; e (c) *mean of item residual absolute loadings* (Mireal) < 0,30. De acordo com os valores pontuais estimados para os dados do exemplo (Figura 9), pelas medidas UniCo e ECV a escala WHOQOL não pode ser tratada essencialmente como unidimensional; no entanto, a medida Mireal indica que ela pode ser tratada como unidimensional.

OVERALL ASSESSMENT				
UniCo = 0.942	BC BOOTSTRAP	95% CONFIDENCE INTERVALS = (	0.927	0.960)
ECV = 0.840	BC BOOTSTRAP	95% CONFIDENCE INTERVALS = (	0.825	0.865)
MIREAL = 0.231	BC BOOTSTRAP	95% CONFIDENCE INTERVALS = (	0.214	0.243)
A value of UniCo (Unidimensional Congruence) and I-Unico (Item Unidimensional Congruence) larger than 0.95 suggests that data can be treated as a A value of ECV (Explained Common Variance) and I-ECV (Item Explained Common Variance) larger than 0.85 suggests that data can be treated as essen A value of MIREAL (Mean of Item Residual Absolute Loadings) and I-REAL (Item Residual Absolute Loadings) lower than 0.300 suggests that data can				
ROBUST GOODNESS OF FIT STATISTICS				
Root Mean Square Error of Approximation (RMSEA) = 0.040; BC Bootstrap 95% confidence interval = (0.0366 0.0403) (between 0.010 and 0.050 : close) Estimated Non-Centrality Parameter (NCP) = 486.390 Degrees of Freedom = 186 Test of Approximate Fit H0 : RMSEA < 0.05; P = 1.000				
Minimum Fit Function Chi Square with 186 degrees of freedom = 306.156 (P = 0.000010) Robust Mean and Variance-Adjusted Chi Square with 186 degrees of freedom = 504.024 (P = 0.000010) Chi-Square for independence model with 276 degrees of freedom = 37128.454				
Non-Normed Fit Index (NNFI; Tucker & Lewis) = 0.987; BC Bootstrap 95% confidence interval = (0.987 0.991) Comparative Fit Index (CFI) = 0.991; BC Bootstrap 95% confidence interval = (0.991 0.994) (larger than 0.990 : excellent) Schwarz's Bayesian Information Criterion (BIC) = 1338.466; BC Bootstrap 95% confidence interval = (1280.844 1336.63)				
Goodness of Fit Index (GFI) = 1.000; BC Bootstrap 95% confidence interval = (1.000 1.000) Adjusted Goodness of Fit Index (AGFI) = 1.000; BC Bootstrap 95% confidence interval = (1.000 1.000) Goodness of Fit Index without diagonal values (GFI) = 1.000; BC Bootstrap 95% confidence interval = (1.000 1.000) Adjusted Goodness of Fit Index without diagonal values (AGFI) = 1.000; BC Bootstrap 95% confidence interval = (1.000 1.000)				

Figura 9. Medidas de unidimensionalidade e ajustes no Factor.

A Figura 9 apresenta diversas medidas de ajuste, que geralmente são vistas apenas na AFC. No entanto, na AFE elas também podem ser obtidas, dependendo do método de estimação dos fatores. Ao avaliarmos as medidas indicadas na Figura 9 no contexto da AFE, estamos reproduzindo uma AFCP (Hoelzle & Meyer, 2013). A avaliação da AFE pelos critérios exigidos na AFC pode ser um tanto rigorosa no primeiro momento (Hoelzle & Meyer, 2013). No entanto, uma primeira olhada nas principais medidas de ajuste de uma AFC ($1 < \chi^2/df < 3$, CFI e TLI $> 0,95$ e RMSEA $< 0,08$) pode indicar o quanto longe um modelo mais simples/restrito será alcançado. Incorporar a AFCP quando da condução da AFE acabará resultando em uma compreensão mais sofisticada e perspicaz dos resultados da AFE (Kline, 2016).

As medidas CFI (0,991) e TLI (NNFI = 0,987) visualizadas na Figura 9 indicam um excelente ajuste do modelo AFE. A medida RMSEA também foi adequada (RMSEA = 0,04; IC95% = 0,037; 0,040). A razão do qui-quadrado pelos graus de liberdade ($\chi^2/df = 486,39 / 186 = 2,615$) também passou no crivo geralmente aceito. As outras medidas não destacadas na Figura 9 (GFI e AGFI) têm sido cada vez mais relegadas pela literatura de AFC (Damásio & Dutra, 2018; Ferrando & Lorenzo-Seva, 2014; Schreiber, Stage, King, Nora, & Barlow, 2006). No entanto, quando se utiliza uma matriz policórica, com algum método de extração OLS, essas medidas podem ser interessantes, pois não dependem diretamente do teste qui-quadrado (Hancock & Mueller, 2000).

O bloco que segue refere-se, principalmente, às estimativas das matrizes de cargas fatoriais (*unrotated loading matrix, weights of robust rotation, semi-specified target loading matrix, rotated loading matrix e structure matrix*). Como essas estimativas de pesos fatoriais são outputs padrão de qualquer software que roda AFE, optou-se por apresentar na Figura 10a apenas a matriz rotacionada de cargas fatoriais ($> 0,30$) para prosseguir com o exemplo. Uma vantagem adicional do Factor é que ele emite também as cargas fatoriais e a correlação entre os fatores com seus intervalos de confiança via *bootstrap* (blocos omitidos).

A Figura 10a evidencia diversos problemas com a proposta de quatro fatores a partir dos referidos dados: (a) muitas cargas cruzadas, o que pode sugerir uma estrutura *bifactor*; (b) os itens Q17 e Q18, alocados no domínio físico, apresentaram cargas superiores a um; e (c) alguns itens com baixa carga fatorial (Q8 e Q9 do domínio ambiente, por exemplo). Há indícios de os referidos dados não se ajustarem à estrutura fatorial proposta. A medida padronizada de Pratt (Figura 10b), que mensura um ‘tipo de tamanho de efeito’, com valores próximos a um indicando que o fator tem alto efeito no item, e perto de zero no caso contrário, reafirma as cargas fatoriais cruzadas encontradas. Desejamos que apenas um fator tenha efeito alto e exclusivo num item. Inclusive, para avaliar a simplicidade de uma solução fatorial, o Factor calcula o *loading simplicity* (LS) *index* (output omitido): utilize essa medida para comparar matrizes de pesos fatoriais entre diferentes métodos de rotação – quanto mais próximo de um, melhor (Lorenzo-Seva, 2003).

ROTATED LOADING MATRIX (loadings lower than absolute 0.300 omitted)						COMMUNALITY-STANDARDIZED PRATT'S MEASURES					
Variable	F 1	F 2	F 3	F 4		Variable	F 1	F 2	F 3	F 4	
Q3_F		0.517		0.525		Q3_F	0.056	0.490	0.032	0.422	
Q4_F		0.414		0.534		Q4_F	0.004	0.386	0.098	0.512	
Q10_F		0.693				Q10_F	0.000	0.780	0.220	0.000	
Q15_F		0.397		0.301		Q15_F	0.233	0.471	0.169	0.128	
Q16_F		0.560				Q16_F	0.016	0.969	0.011	0.004	
Q17_F		1.099	-0.301			Q17_F	0.029	0.971	0.000	0.000	
Q18_F		1.088	-0.364			Q18_F	0.050	0.950	0.000	0.000	
Q5_P			0.757			Q5_P	0.000	0.092	0.864	0.044	
Q6_P		0.426	0.339			Q6_P	0.000	0.506	0.386	0.107	
Q7_P		0.624				Q7_P	0.000	0.923	0.077	0.000	
Q11_P		0.501				Q11_P	0.000	0.735	0.265	0.000	
Q19_P		0.835				Q19_P	0.000	0.930	0.005	0.065	
Q26_P		0.548				Q26_P	0.000	0.753	0.247	0.000	
Q20_S		0.487		-0.424		Q20_S	0.035	0.532	0.051	0.381	
Q21_S		0.475				Q21_S	0.024	0.813	0.000	0.162	
Q22_S		0.345		-0.358		Q22_S	0.073	0.418	0.162	0.347	
Q8_A			0.307			Q8_A	0.359	0.055	0.586	0.000	
Q9_A			0.373			Q9_A	0.398	0.036	0.565	0.000	
Q12_A			0.647			Q12_A	0.229	0.000	0.771	0.000	
Q13_A			0.520			Q13_A	0.326	0.000	0.674	0.000	
Q14_A			0.850			Q14_A	0.061	0.000	0.939	0.000	
Q23_A	0.478					Q23_A	0.668	0.000	0.257	0.075	
Q24_A	0.649					Q24_A	0.852	0.000	0.123	0.025	
Q25_A	0.672					Q25_A	0.974	0.013	0.001	0.012	

Figura 10. Matriz de carga fatorial (> 0,30) rotacionada (a) e medida padronizada de Pratt (b).

CONSTRUCT REPLICABILITY: GENERALIZED H (G-H) INDEX Ferrando & Lorenzo-Seva (2018)						ROTATED LOADING MATRIX (loadings lower than absolute 0.300 omitted)					
Factor	H-Latent	BC Bootstrap	95 %	Confidence intervals	H-Observed	BC Bootstrap	95 %	Variable	F 1	F 2	
F 1	0.762	(0.716	0.791)		0.722	(0.677	1.076)	Q3_F		0.496	
F 2	0.957	(0.950	0.964)		0.915	(0.906	0.928)	Q4_F		0.437	
F 3	0.888	(0.865	0.905)		0.856	(0.839	0.898)	Q10_F		0.810	
F 4	0.710	(0.671	0.735)		0.638	(0.589	0.665)	Q15_F		0.407	
The H index evaluates how well a set of items represents a common factor. It is bounded between 0 and 1. The magnitude of the factor loadings and/or the number of items increase. High H values (>.80) suggest which is more likely to be stable across studies, whereas low H values suggest a poorly defined latent variable to change across studies. H-Latent assesses how well the factor can be identified by the continuous latent response variables whereas H-Observed assesses how well it can be identified from the observed item scores.											
QUALITY AND EFFECTIVENESS OF FACTOR SCORE ESTIMATES Ferrando & Lorenzo-Seva (2018)											
Factor Determinacy Index (FDI)	0.873	0.978	0.942	0.843				Q16_F		0.571	
ORION marginal reliability	0.762	0.957	0.888	0.710				Q17_F		0.989	
Sensitivity ratio (SR)	1.790	4.715	2.812	1.566				Q18_F		0.951	
Expected percentage of true differences (EPTD)	87.6%	95.8%	91.9%	86.2%				Q6_P		0.613	
								Q7_P		0.680	
								Q11_P		0.588	
								Q19_P		0.870	
								Q26_P		0.669	
								Q20_S		0.534	
								Q21_S		0.466	
								Q22_S		0.406	
								Q9_A		0.471	
								Q12_A		0.642	
								Q13_A		0.621	
								Q14_A		0.584	
								Q23_A		0.626	
								Q24_A		0.750	
								Q25_A		0.650	

Figura 11. Medidas de replicabilidade e qualidade dos escores fatoriais (a) e modelo final (b).

Em consonância com os resultados da PA, o bloco que traz algumas medidas de replicabilidade e qualidade dos escores fatoriais (Figura 11a) direciona para uma boa adequação de apenas dois fatores (F2 e F3). A primeira, *H-observed*, merece destaque e indica o quanto o conjunto de itens representa o fator comum. Seu valor vai de zero a um e valores acima de 0,80 sugerem uma boa definição da variável latente, que potencialmente será mais estável em estudos futuros. Cabe ressaltar que o índice *H-latent* reflete a replicabilidade estimada quando os itens são interpretados como variáveis contínuas e o índice *H-observed* reflete a replicabilidade estimada quando os itens são interpretados como variáveis ordinais, tal como as medidas do tipo Likert (Damásio & Dutra, 2018; Ferrando & Lorenzo-Seva, 2018).

As outras medidas, dispostas abaixo na Figura 11a (FDI, EAP, SR e EPTD), dizem respeito à qualidade dos escores fatoriais – isto é, se poderão ser utilizados para avaliações individuais. Essas medidas são recentes na literatura e devem ser avaliadas com cautela (Ferrando & Lorenzo-Seva, 2018). De qualquer forma, na presente pesquisa, corroboraram o bom ajuste apenas dos fatores F2 e F3, pois: FCI > 0,90; EAP > 0,80, SR > 2 e EPTD > 90% (Ferrando & Lorenzo-Seva, 2018).

O Factor também apresenta, para a escala, a medida clássica de confiabilidade (alfa de Cronbach = 0,93), o ômega (ω) (0,93), de McDonald (0,93) e a *greatest lower bound* (GLB = 0,96). A primeira tem sido muito criticada devido à assunção de pesos equivalentes e forte influência do número de itens, e cada vez mais se recomendam as duas últimas (Damásio, 2012).

No final do arquivo dos resultados, antes das referências, o Factor ainda apresenta informações das distribuições dos resíduos, o que se torna interessante para avaliar *outliers* e *missings*, especialmente caso o modelo não apresente um bom ajuste.

Em um processo iterativo e após algumas rodadas, chegamos à proposta de estrutura fatorial indicada na Figura 11b. Perfaz um modelo de dois fatores, sem os itens Q5_P e Q8_A, com os domínios físico, psicológico e relações sociais em um fator e o domínio ambiente em outro fator. Essa proposta faz mais sentido do ponto de vista conceitual e temos evidências empíricas que a suportam (Perera et al., 2018). O leitor pode se considerar em uma posição mais exigente e querer eliminar itens com cargas fatoriais inferiores a 0,50, por exemplo, e deixar um modelo mais enxuto para ser refinado na AFC. Convidamos os leitores para assistir ao vídeo⁴ e verificar a jornada até o modelo final (Figura 11b), inclusive com a comparação desse modelo de dois fatores com um modelo *bifactor* de dois fatores. Os arquivos dos *outputs* adicionais, até ajuste do modelo final, também se encontram disponíveis em conjunto com o artigo.

CONCLUSÃO

A AFE é uma das técnicas multivariadas de interdependência mais utilizadas nas ciências sociais aplicadas. Sua implementação requer decisões cruciais que impactarão o resultado, e não deve ser empregada visando ao melhor ajuste estatístico possível aos dados, devendo partir de princípios teóricos sólidos para nortear seu desenvolvimento.

Primeiro, se o usuário é um pesquisador da administração, potencialmente seu estudo tratará de aplicar uma abordagem de fator comum (AFCo). Nesse sentido, não se trata de aplicar a ACP devido à sua simplicidade e, quase sempre, maior variância explicada. A ACP busca reter a maior parcela possível da variância total, priorizando o primeiro fator, e é concebida para modelos formativos, com a hipótese de que os itens são independentes. Os estudos que envolvem fatores latentes devem buscar a variância comum e os modelos são do tipo reflexivo, com previsão de dependência entre os itens. A AFCo e a ACP partem de princípios diferentes, e a escolha entre uma e outra não é estatística: é metodológica.

Para o usuário desenvolver uma AFCo no SPSS, por exemplo, ele não deve aceitar o método de extração default do software, pois assim ele empregará uma ACP. Infelizmente, esse é um dos primeiros erros cometidos pelos usuários. As duas opções de métodos de extração mais recomendadas no SPSS para desenvolvimento de um AFCo são ULS e *principal axis factoring*.

Segundo, se no estudo o usuário tem variáveis que são ordinais por natureza, ele não deveria empregar a matriz de correlações de Pearson. O mais indicado, principalmente se

a amplitude da escala de verificação não é alta, digamos entre um e cinco, torna-se o emprego de uma matriz policórica. A matriz de Pearson supõe que as relações são lineares e subestima a força das relações para esse tipo de variáveis. Nesse sentido, de imediato, deveria descartar-se o SPSS, pois até hoje ele utiliza apenas matriz de Pearson. Uma solução para empregar matrizes policóricas/tetracóricas seria a utilização de *syntaxes* de alguns autores desenvolvidas para o SPSS, tal como TETRA-COM (Lorenzo-Seva & Ferrando, 2012) e POLYCOR-C (Lorenzo-Seva & Ferrando, 2015) ou *plug-ins* do R no SPSS, tal como R-Factor v2.4.3 (Courtney & Gordon, 2013). No entanto, esse procedimento pode não ser familiar para o usuário comum, inclusive depende de constantes atualizações dos pacotes do software R, do próprio *plug-in* e das versões do SPSS, gerando diversas incompatibilidades.

Terceiro, caso o pesquisador utilize uma matriz policórica, o método mais indicado torna-se o DWLS. O Factor executa esse tipo de análise, inclusive com a implementação robusta do DWLS, assim como se tem no Mplus. Quarto, o usuário não deveria utilizar o critério de Kaiser para decisão sobre o número de fatores. Essa é uma das decisões mais cruciais na AFE e a literatura relatada é contundente sobre essa escolha metodológica: autovalor > 1, gráfico *scree* e porcentagem da variância explicada são escolhas péssimas para retenção fatorial, e as únicas disponíveis no SPSS. Estudos de simulação têm comprovado, consistentemente, a melhor acurácia da PA e o método de Hull. O Factor executa as duas análises.

Por fim, o pesquisador em ciências sociais aplicadas, em uma AFE típica, deveria utilizar uma rotação oblíqua como primeira opção para interpretação fatorial. Nesse sentido, o SPSS atende bem, pois tem disponíveis as principais e mais recomendadas soluções: *oblimin* e *promax*. No entanto, como a rotação ortogonal varimax é default nesse software e por décadas foi recomendada por questões de eficiência computacional, ainda é a mais utilizada na prática corrente. Em problemas de pesquisa no campo das ciências sociais aplicadas, qualquer uma das rotações ortogonais dificilmente terá respaldo conceitual.

Infelizmente, os pesquisadores tendem a utilizar regras de bolso populares em vez de recomendações baseadas em evidências na implementação de uma AFE. Muitas dessas heurísticas correntes foram apresentadas há meio século, quando o poder computacional era limitado. Hoje não mais se justificam, mas continuam a se propagar. Com o presente artigo tutorial, buscou-se contribuir com essa discussão ao criticar tais práticas, apresentando evidências de melhores opções e uma solução passo a passo para auxiliar os pesquisadores que desejam transpor a barreira do pragmatismo corrente. Esperemos que a apresentação do Factor possa ser uma solução definitiva nas pesquisas de muitos pesquisadores em ciências sociais aplicadas.

NOTAS

1. Recuperado de <https://youtu.be/ITh1w4tFerA> (Acesso em 13 de Agosto, 2021).
2. Recuperado de <https://youtu.be/9X77ARoyys0> (Acesso em 13 de Agosto, 2021).
3. Recuperado de <https://youtu.be/wFTGJG8XRRs> (Acesso em 13 de Agosto, 2021).
4. Recuperado de <https://youtu.be/9X77ARoyys0> (Acesso em 13 de Agosto, 2021).

REFERÊNCIAS

- Baglin, J. (2014). Improving your exploratory factor analysis for ordinal data: A demonstration using FACTOR. *Practical Assessment, Research & Evaluation*, 19(5), 1–15. <https://psico.fcep.urv.cat/utilitats/factor/>
- Bido, D. S., Mantovani, D. M. N., & Cohen, E. D. (2018). Destruction of measurement scale through exploratory factor analysis in production and operations research. *Gestão & Produção*, 25(2), 384–397. <https://doi.org/10.1590/0104-530X3391-16>
- Brown, T. A. (2015). *Confirmatory Factor Analysis for Applied Research* (2nd ed.). New York, NY: The Guilford Press.
- Costello, A. B., & Osborne, J. (2005). Best practices in exploratory factor analysis: Four recommendations for getting the most from your analysis. *Research, and Evaluation Practical Assessment, Research, and Evaluation*, 10, 7. <https://doi.org/10.7275/jyj1-4868>
- Courtney, M., & Gordon, R. (2013). Determining the number of factors to retain in EFA: Using the SPSS R-Menu v2.0 to make more judicious estimations. *Practical Assessment, Research and Evaluation*, 18(8), 1–14. <https://doi.org/10.7275/9cf5-2m72>
- Damásio, B. F. (2012). Uso da análise fatorial exploratória em psicologia. *Avaliação Psicológica*, 11(2), 213–228. Retrieved from http://pepsic.bvsalud.org/scielo.php?script=sci_abstract&pid=S1677-04712012000200007
- Damásio, B. F., & Dutra, D. de F. (2018). Análise fatorial exploratória: Um tutorial com o Software Factor. In B. F. Damásio & J. C. Borsa (Eds.), *Manual de Desenvolvimento de Instrumentos Psicológicos* (1ª Edição). São Paulo, SP: Vetor Editora.
- Dias, P. de S., Silva-Spineli, H. V. R., & Macedo, R. de C. (2019). Estatística multivariadas na Administração: Importância e aplicação da análise fatorial exploratória. *Revista Eletrônica de Administração e Turismo*, 13(1), 1807–1828. Retrieved from <http://www.spell.org.br/documentos/ver/53685/estatisticas-multivariadas-na-administracao--importancia-e-aplicacao-da-analise-fatorial-exploratoria>
- Fabrigar, L. R., & Wegener, D. T. (2012). *Exploratory factor analysis*. Oxford, UK: Oxford University Press.
- Fabrigar, L. R., Wegener, D. T., MacCallum, R. C., & Strahan, E. J. (1999). Evaluating the use of exploratory factor analysis in Psychological research. *Psychological Methods*, 4(3), 272–299. <https://doi.org/10.1037/1082-989X.4.3.272>
- Ferrando, P. J., & Lorenzo-Seva, U. (2014). Exploratory item factor analysis: Additional considerations. *Anales de Psicologia*, 30(3), 1170–1175. <https://doi.org/10.6018/analesps.30.3.199991>
- Ferrando, P. J., & Lorenzo-Seva, U. (2017). Program FACTOR at 10: Origins, development and future directions. *Psicothema*, 29(2), 236–241. <https://doi.org/10.7334/psicothema2016.304>
- Ferrando, P. J., & Lorenzo-Seva, U. (2018). Assessing the quality and appropriateness of factor solutions and factor score estimates in exploratory item factor analysis. *Educational and Psychological Measurement*, 78(5), 762–780. <https://doi.org/10.1177/0013164417719308>
- Ferreira, D. F. (2018). *Estatística Multivariada* (3rd ed.). Belo Horizonte, MG: UFMG.
- Ford, J. K., MacCallum, R. C., & Talt, M. (1986). The application of exploratory factor analysis in applied Psychology: A critical review and analysis. *Personnel Psychology*, 39(2), 291–314. <https://doi.org/10.1111/j.1744-6570.1986.tb00583.x>
- Gaskin, C. J., & Happell, B. (2014). On exploratory factor analysis: A review of recent evidence, an assessment of current practice, and recommendations for future use. *International Journal of Nursing Studies*, 51(3), 511–521. <https://doi.org/10.1016/j.ijnurstu.2013.10.005>
- Gignac, G. E. (2009). Partial confirmatory factor analysis: Described and illustrated on the NEO-PI-R. *Journal of Personality Assessment*, 91(1), 40–47. <https://doi.org/10.1080/00223890802484126>
- Hair, J., Black, W., Babin, B., & Anderson, R. (2014). *Multivariate Data Analysis* (7th ed.). London, UK: Pearson.
- Hair, J. F., Jr, Gabriel, M. L. D. S., Silva, D. da, & Braga, S., Junior. (2019). Development and validation of attitudes measurement scales: fundamental and practical aspects. *RAUSP Management Journal*, 54(4), 490–507. <https://doi.org/10.1108/RAUSP-05-2019-0098>

- Hancock, G. R., & Mueller, R. O. (2000). Rethinking construct reliability within latent variable systems. In D. F. S. R. Cudek, & S. H. C. DuToit (Eds.), *Structural equation modeling: Present and future* (pp. 195–216). Lincolnwood, IL: Scientific Software.
- Hauck-Filho, N., & Valentini, F. (2020). A análise de componentes principais é útil para selecionar bons itens quando a dimensionalidade dos dados é desconhecida? *Avaliação Psicológica*, 19(4), A-C. <https://doi.org/10.15689/ap.2020.1904.ed>
- Henson, R. K., & Roberts, J. K. (2006). Use of exploratory factor analysis in published research: Common errors and some comment on improved practice. *Educational and Psychological Measurement*, 66(3), 393–416. <https://doi.org/10.1177/0013164405282485>
- Hoelzle, J. B., & Meyer, G. J. (2013). Exploratory factor analysis: Basics and beyond. In *Handbook of Psychology* (2nd ed., pp. 164–188). Hoboken, NJ: John Wiley & Sons.
- Holgado-Tello, F. P., Chacón-Moscoso, S., Barbero-García, I., & Vila-Abad, E. (2010). Polychoric versus Pearson correlations in exploratory and confirmatory factor analysis of ordinal variables. *Quality and Quantity*, 44(1), 153–166. <https://doi.org/10.1007/s11135-008-9190-y>
- Howard, M. C. (2016). A review of exploratory factor analysis decisions and overview of current practices: What we are doing and how can we improve? *International Journal of Human-Computer Interaction*, 32(1), 51–62. <https://doi.org/10.1080/10447318.2015.1087664>
- Izquierdo, I., Olea, J., & Abad, F. J. (2014). El análisis factorial exploratorio en estudios de validación: Usos y recomendaciones. *Psicothema*, 26(3), 395–400. <https://doi.org/10.7334/psicothema2013.349>
- Kline, R. B. (2016). *Principles and Practice of Structural Equation Modeling* (4th ed.). New York, NY: The Guilford Press.
- Laros, J. A. (2012). O uso da análise fatorial: Algumas diretrizes para pesquisadores. In L. Pasquali (Ed.), *Análise Fatorial para pesquisadores* (pp. 141–160). LabPAM. Retrieved from https://www.researchgate.net/publication/233735561_O_Uso_da_Analise_Fatorial_Alguas_Diretrizes_para_Pesquisadores
- Lloret, S., Ferreres, A., Hernández, A., & Tomás, I. (2014). Exploratory item factor analysis: A practical guide revised and updated. *Anales de Psicología*, 30(3), 1151–1169. <https://doi.org/10.6018/analesps.30.3.199361>
- Lloret, S., Ferreres, A., Hernández, A., & Tomás, I. (2017). The exploratory factor analysis of items: Guided analysis based on empirical data and software. *Anales de Psicología*, 33(2), 417–432. <https://doi.org/10.6018/analesps.33.2.270211>
- Lorenzo-Seva, U. (2003). A factor simplicity index. *Psychometrika*, 68(1). <https://doi.org/10.1007/BF02296652>
- Lorenzo-Seva, U., & Ferrando, P. J. (2012). TETRA-COM: A comprehensive SPSS program for estimating the tetrachoric correlation. *Behavior Research Methods*, 44(4), 1191–1196. <https://doi.org/10.3758/s13428-012-0200-6>
- Lorenzo-Seva, U., & Ferrando, P. J. (2015). POLYMAT-C: a comprehensive SPSS program for computing the polychoric correlation matrix. *Behavior Research Methods*, 47(3), 884–889. <https://doi.org/10.3758/s13428-014-0511-x>
- Lorenzo-Seva, U., & Ferrando, P. J. (2019). Robust Promin: A method for diagonally weighted factor rotation. *Liberabit: Revista Peruana de Psicología*, 25(1), 99–106. <https://doi.org/10.24265/liberabit.2019.v25n1.08>
- Lorenzo-Seva, U., & Ferrando, P. J. (2020). Not Positive Definite Correlation Matrices in Exploratory Item Factor Analysis: Causes, Consequences and a Proposed Solution. *Structural Equation Modeling: A Multidisciplinary Journal*, 28(1), 1–10. <https://doi.org/10.1080/10705511.2020.1735393>
- Lorenzo-Seva, U., Timmerman, M. E., & Kiers, H. A. L. (2011). The Hull Method for Selecting the Number of Common Factors. *Multivariate Behavioral Research*, 46(2), 340–364. <https://doi.org/10.1080/00273171.2011.564527>
- Lorenzo-Seva, U., & van Ginkel, J. R. (2016). Multiple Imputation of missing values in exploratory factor analysis of multidimensional scales: estimating latent trait scores. *Anales de Psicología*, 32(2), 596. <https://doi.org/10.6018/analesps.32.2.215161>
- Marôco, J. (2014). *Análise de equações estruturais: Fundamentos teóricos, software e aplicações* (2nd ed.). Lisbon, PT: ReportNumber.
- Marsh, H., Morin, A., Parker, P., & Kaur, G. (2014). Exploratory structural equation modeling: An integration of the best features of exploratory and confirmatory factor analysis. In *Annual Review of Clinical Psychology* (Vol. 10, pp. 85–110). <https://doi.org/10.1146/annurev-clinpsy-032813-153700>
- Marsh, H. W., Muthén, B., Morin, A., Lüdtke, O., Asparouhov, T., & Trautwein, U. (2010). A new look at the big five factor structure through exploratory structural equation modeling. *Psychological Assessment*, 22(3), 471–491. <https://doi.org/10.1037/a0019227>
- Marsh, Herbert W., Guo, J., Dicke, T., Parker, P. D., & Craven, R. G. (2020). Confirmatory Factor Analysis (CFA), Exploratory Structural Equation Modeling (ESEM), and Set-ESEM: Optimal Balance Between Goodness of Fit and Parsimony. *Multivariate Behavioral Research*, 55(1), 102–119. <https://doi.org/10.1080/00273171.2019.1602503>
- Marsh, Herbert W., Muthén, B., Asparouhov, T., Lüdtke, O., Robitzsch, A., Morin, A. J. S., & Trautwein, U. (2009). Exploratory structural equation modeling, integrating CFA and EFA: Application to students' evaluations of university teaching. *Structural Equation Modeling*, 16(3), 439–476. <https://doi.org/10.1080/10705510903008220>
- Matos, S. D. A., & Rodrigues, E. C. (2019). *Análise fatorial*. Brasília, DF: Enap.
- Mingoti, S. A. (2005). *Análise de dados através de métodos de estatística multivariada: Uma abordagem aplicada*. Belo Horizonte, MG: UFMG.
- Perera, H. N., Izadikhah, Z., O'Connor, P., & McIlveen, P. (2018). Resolving Dimensionality Problems With WHOQOL-BREF Item Responses. *Assessment*, 25(8), 1014–1025. <https://doi.org/10.1177/1073191116678925>

- Rogers, D., Armada, M. J. da R., & Rogers, P. (2020). Bem-estar financeiro, saúde e qualidade de vida de um investidor. *Anais do Encontro da Associação Nacional de Pós-graduação e Pesquisa em Administração*, online, 44.
- Schreiber, J. B., Stage, F. K., King, J., Nora, A., & Barlow, E. A. (2006). Reporting structural equation modeling and confirmatory factor analysis results: A review. In *Journal of Educational Research*, 99(6), 323–338. <https://doi.org/10.3200/JOER.99.6.323-338>
- Thompson, B. (2004). *Exploratory and confirmatory factor analysis: Understanding concepts and applications*. American Psychological Association. <https://doi.org/10.1037/10694-000>
- Timmerman, M. E., & Lorenzo-Seva, U. (2011). Dimensionality assessment of ordered polytomous items with parallel analysis. *Psychological Methods*, 16(2), 209–220. <https://doi.org/10.1037/a0023353>
- Vidal, D. F. (2016). Análise fatorial em Administração: Uma aplicação prática com o software SPSS. *Revista Eletrônica Estácio Papirus*, 3(1), 54–79.
- Watkins, M. W. (2018). Exploratory Factor Analysis: A Guide to Best Practice. *Journal of Black Psychology*, 44(3), 219–246. <https://doi.org/10.1177/0095798418771807>

Autoria

Pablo Rogers

Universidade Federal de Uberlândia, Faculdade de Gestão e Negócios
Av. João Naves de Ávila, n. 2121, Santa Mônica, 38400-902, Uberlândia, MG, Brasil.

E-mail: pablorogers@ufu.br

 <https://orcid.org/0000-0002-0093-3834>

* Autor Correspondente

Financiamento

O autor relatou que não houve suporte financeiro para a pesquisa deste artigo.

Conflito de Interesses

O autor informou que não há conflito de interesses.

Verificação de Plágio

A RAC mantém a prática de submeter todos os documentos aprovados para publicação à verificação de plágio, mediante o emprego de ferramentas específicas, e.g.: iThenticate.

PMétodo de Revisão por Pares

Este conteúdo foi avaliado utilizando o processo de revisão por pares duplo-cego (*double-blind peer-review*). A divulgação das informações dos pareceristas constantes na primeira página e do Relatório de Revisão por Pares (Peer Review Report) é feita somente após a conclusão do processo avaliativo, e com o consentimento voluntário dos respectivos pareceristas e autores.

Contribuições do Autor

1º autor: conceituação (liderança); curadoria de dados (liderança); análise formal (liderança); investigação (liderança); metodologia (liderança); validação (liderança); visualização (liderança); escrita - rascunho original (liderança); escrita - revisão e edição (liderança).


Direitos Autorais

A RAC detém os direitos autorais deste conteúdo.

Disponibilidade dos Dados

A RAC informa que os vídeos e os seus conteúdos mencionados neste artigo foram uma opção do autor em oferecer material extra aos leitores. Assim, os vídeos não fizeram parte do processo de revisão por pares e não são uma publicação oficial da RAC.

Os autores afirmam que todos os dados utilizados na pesquisa foram disponibilizados publicamente, e podem ser acessados por meio da plataforma Harvard Dataverse:



Rogers, Pablo, 2021, "Replication Data for "Best Practices for Your Exploratory Factor Analysis: a Factor Tutorial" published by RAC-Revista de Administração Contemporânea", Harvard Dataverse, V1. <https://doi.org/10.7910/DVN/RCX8FF>

A RAC incentiva o compartilhamento de dados mas, por observância a ditames éticos, não demanda a divulgação de qualquer meio de identificação de sujeitos de pesquisa, preservando a privacidade dos sujeitos de pesquisa. A prática de *open data* é viabilizar a reproducibilidade de resultados, e assegurar a irrestrita transparência dos resultados da pesquisa publicada, sem que seja demandada a identidade de sujeitos de pesquisa.

A RAC é membro e subscreve os princípios do COPE - Comitê de Ética em Publicações

