

APLICAÇÃO DA ANÁLISE FATORIAL EXPLORATÓRIA NO SOFTWARE FACTOR: UM TUTORIAL METODOLÓGICO PARA PESQUISADORES DA ÁREA DE MARKETING

APPLICATION OF EXPLORATORY FACTOR ANALYSIS IN FACTOR SOFTWARE: A METHODOLOGICAL TUTORIAL FOR MARKETING RESEARCHERS

DOI: [HTTP://DX.DOI.ORG/10.13059/RACEF.V16I3.1320](http://dx.doi.org/10.13059/RACEF.V16I3.1320)

Eduardo Teixeira Magalhães
eduardomagalhaes@ufmg.br
Universidade Federal de Minas Gerais

Thaís Ligieri Zagnoli Cunha
thaispzc@gmail.com
Centro Federal de Educação Tecnológica de Minas Gerais

David Chester Carvalho Barros
davidchest@gmail.com
Centro Federal de Educação Tecnológica de Minas Gerais

Rita de Cássia Leal Campos
rita.campos.adm@gmail.com
Centro Federal de Educação Tecnológica de Minas Gerais

Data de envio do artigo: 16 de Novembro de 2024.

Data de aceite: 27 de Agosto de 2025.

Resumo: Este artigo teve como objetivo apresentar um tutorial metodológico para a realização de Análise Fatorial Exploratória (AFE) no software Factor, com foco na configuração dos parâmetros e na aplicação das melhores práticas estatísticas em pesquisas com dados de autorrelato. Como exemplo prático, utilizou-se a escala de Yi e Gong (2013), aplicada em um estudo real na área de marketing. A pesquisa reforça a segurança da utilização dessa escala em pesquisas de marketing que buscam mensurar o comportamento de cocriação, considerando as características específicas de determinado segmento de mercado e o comportamento do consumidor. Além disso, é fornecido um guia didático para a replicação da técnica e tratamento de dados em qualquer banco de dados derivado de autorrelatos, condição inerente aos questionários utilizados em pesquisas de marketing. Pesquisadores da área de marketing são incentivados a utilizar o caminho empregado. Espera-se que o software Factor seja uma ferramenta comum ao desenvolvimento de AFEs, tendo em vista a qualidade e robustez proporcionadas pela ferramenta. As práticas de análise de dados podem ser aprimoradas, gerando insights a partir de pesquisas baseadas em autorrelatos, particularmente relevantes para questões de pesquisa relacionadas a aspectos sociais e de gestão.

Palavras-chave: Análise Fatorial Exploratória; Pesquisa em Administração; Factor; Tutorial.

Abstract: *This article aimed to present a methodological tutorial for performing Exploratory Factor Analysis (EFA) in the Factor software, focusing on parameter configuration and the application of best statistical practices in research with self-report data. As a practical example, the scale by Yi and Gong (2013) was used, applied in a real study in the marketing area. The research reinforces the safety of using this scale in marketing research that seeks to measure co-creation behavior, considering the specific characteristics of a given market segment and consumer behavior. In addition,*

a didactic guide is provided for replicating the technique and data processing in any database derived from self-reports, a condition inherent to questionnaires used in marketing research. Researchers in the marketing area are encouraged to use the method employed. It is expected that the Factor software will be a common tool for developing EFAs, given the quality and robustness provided by the tool. Data analysis practices can be improved by generating insights from self-report-based surveys, particularly relevant for research questions related to social and management aspects.

Keywords: *vExploratory Factor Analysis; Management Research; Factor; Tutorial.*

1 INTRODUÇÃO

Uma das possibilidades de investigação nas Ciências Humanas e Sociais, como no campo do marketing, consiste em mensurar fenômenos não diretamente observáveis, comumente denominados variáveis latentes ou construtos. A mensuração desses construtos se dá por meio do agrupamento de variáveis observáveis e da identificação de um fator comum (Matos; Rodrigues, 2019).

Entre as técnicas aplicáveis para esse fim, destaca-se a Análise Fatorial Exploratória (AFE), inserida no escopo da Análise Fatorial de Fator Comum (AFCo) (Brown, 2015; Fabrigar; Wegener, 2012). Essa técnica multivariada visa identificar estruturas subjacentes em uma matriz de dados, determinando o número e a natureza das variáveis latentes que representam um conjunto de variáveis observadas (Brown, 2015). A AFE é particularmente indicada quando o pesquisador (1) não dispõe de uma teoria prévia, (2) carece de evidências empíricas que sustentem o agrupamento de itens, (3) deseja confirmar a estrutura original de um instrumento internacional, ou (4) não conhece a estrutura dos dados observados (Brown, 2015). Para tanto, a AFE analisa as correlações entre itens de autorrelato, presumindo correlações fortes entre itens de um mesmo fator e correlações

fracas com itens de outros fatores (Brown, 2015; Howard, 2016). Dessa forma, a técnica busca identificar construtos latentes a partir do padrão de variação das respostas dos indivíduos (Watkins, 2018; Rogers, 2021), especialmente em contextos de autorrelato específicos (Reis, 2022).

O campo do marketing, por sua vez, utiliza instrumentos de autorrelato para captar as percepções dos indivíduos e contribuir para o desenvolvimento teórico-aplicado da área (Churchill, 2017). Isso torna a AFE uma ferramenta fundamental na estruturação dos instrumentos de mensuração utilizados nessas pesquisas. No entanto, como advertido por Rogers (2021), ainda são recorrentes erros metodológicos na condução de AFEs em pesquisas sociais aplicadas. Estudos de revisão sistemática corroboram essa crítica, apontando falhas técnicas e conceituais na aplicação da AFE em diversos contextos (Gaskin; Happell, 2014; Howard, 2016; Izquierdo et al., 2014; Lloret et al., 2017).

É nesse contexto que se insere a proposta deste artigo, que teve como objetivo apresentar um tutorial metodológico para a realização de Análise Fatorial Exploratória (AFE) no software Factor, com foco na configuração dos parâmetros e na aplicação das melhores práticas estatísticas em pesquisas com dados de autorrelato. Tendo em vista a já consolidada contribuição de Rogers (2022) – especialmente no artigo “Best practices for your exploratory factor analysis: A factor tutorial” – este artigo se propõe a avançar em aspectos complementares, oferecendo um tutorial didático com foco no uso aplicado do software Factor para condução de AFE com dados de autorrelato. Diferencia-se, portanto, ao apresentar detalhadamente as configurações dos parâmetros e decisões estatísticas que otimizam a extração fatorial, com base em melhores práticas e exemplos práticos no campo do marketing.

Como ilustração prática, este trabalho utiliza uma escala de comportamento de cocriação (Yi; Gong, 2013), aplicada em um estudo real com 438 observações. Dessa forma, o trabalho contribui para suprir a lacuna apontada

por Lloret et al. (2017), relacionada à escassez de estudos metodológicos aprofundados voltados para as ciências sociais aplicadas, ao mesmo tempo em que se alinha aos esforços recentes de sistematização metodológica no contexto nacional, especialmente no campo do marketing.

2. A CONTRAPOSIÇÃO ENTRE A FACILIDADE DE USO À NECESSIDADE DE RIGOR TÉCNICO NO USO DO SPSS EM ANÁLISE FATORIAL EXPLORATÓRIA

A Análise Fatorial Exploratória (AFE) é uma técnica estatística amplamente empregada para identificar estruturas latentes em conjuntos de dados multivariados. Sua aplicação permite verificar a dimensionalidade de construtos teóricos, sendo, por isso, frequentemente utilizada em pesquisas nas áreas de psicologia, educação, administração, saúde e ciências sociais aplicadas (Hair et al., 2006; Tabachnick; Fidell, 2007).

Entre os softwares mais utilizados para a realização da AFE, destaca-se o SPSS (Statistical Package for the Social Sciences), cuja popularidade pode ser atribuída a fatores históricos, institucionais e práticos. A facilidade de uso do SPSS e sua interface gráfica amigável tornam-no acessível mesmo para pesquisadores que não possuem conhecimentos em linguagens de programação, como R ou Python (Pett, Lackey; Sullivan, 2003). Além disso, o SPSS integra um amplo conjunto de funcionalidades estatísticas em um único ambiente, o que facilita sua adoção por profissionais de diferentes áreas (Hair et al., 2009).

Outro fator que contribui para sua disseminação é a presença de licenças institucionais em universidades e centros de pesquisa, o que reduz barreiras de acesso e reforça seu uso como padrão no ambiente acadêmico. Como destacam Costello e Osborne (2005), muitas vezes a escolha do software está mais associada à tradição institucional do que à sua adequação metodológica para análises específicas, como é o caso da AFE.

Apesar da popularidade, o uso do SPSS

na execução da AFE tem sido alvo de críticas metodológicas importantes. Um dos principais pontos refere-se à escolha, como procedimento padrão, do método de extração por Componentes Principais (Principal Component Analysis – PCA), o qual considera a totalidade da variância das variáveis observadas. Tal abordagem difere da Análise Fatorial propriamente dita, que se concentra apenas na variância compartilhada, ou comum, entre as variáveis (Fabrigar et al., 1999; Dancey; Reidy, 2007). Ao aplicar a PCA em contextos em que se busca identificar fatores latentes, corre-se o risco de produzir interpretações equivocadas, confundindo objetivos de redução de dimensionalidade com o de identificação de estruturas teóricas subjacentes.

Outro procedimento amplamente difundido no SPSS, especialmente por sua simplicidade operacional, é o chamado “Little Jiffy” — combinação da extração por Componentes Principais com rotação Varimax (Kaiser, 1970). No entanto, tal estratégia é criticada por assumir, de forma rígida, que os fatores extraídos sejam ortogonais, ou seja, não correlacionados. Na prática, essa premissa nem sempre se sustenta, especialmente em pesquisas comportamentais ou sociais, onde a correlação entre dimensões latentes é comum (Costello; Osborne, 2005; Fabrigar et al., 1999).

Diante dessas limitações, recomenda-se cautela na utilização dos procedimentos padrão do SPSS. A adoção de métodos de extração que considerem apenas a variância comum — como o método de Máxima Verossimilhança (Maximum Likelihood) — e a aplicação de rotações oblíquas (por exemplo, Oblimin ou Promax) podem oferecer representações mais precisas da estrutura fatorial subjacente (Hair et al., 2006; Tabachnick; Fidell, 2007). Além disso, a verificação da adequação dos dados à AFE por meio de testes como o KMO (Kaiser-Meyer-Olkin) e o teste de Esfericidade de Bartlett é essencial para assegurar a robustez da análise (Hair et al., 2009).

Outra medida importante é considerar o uso de estimadores robustos, como o Diagonally Weighted Least Squares (DWLS), especialmente

em contextos de dados ordinais ou amostras pequenas, nos quais os pressupostos do método de Máxima Verossimilhança podem não ser atendidos (Hinkin, 1995).

Nesse contexto, é fundamental que pesquisadores desenvolvam uma postura crítica quanto ao uso do SPSS para AFE. Embora sua acessibilidade e praticidade o tornem uma ferramenta atrativa, tais características não garantem sua adequação metodológica em todas as situações analíticas (Pett, Lackey; Sullivan, 2003). Conforme argumentam Fabrigar et al. (1999), o uso incorreto da AFE compromete a validade dos instrumentos psicométricos e, por consequência, os resultados das pesquisas.

Diante disso, softwares alternativos como o R (com o pacote psych) e o Mplus têm sido recomendados por permitirem maior controle sobre os parâmetros estatísticos, possibilitando análises mais sofisticadas e aderentes aos pressupostos teóricos da AFE (Costello; Osborne, 2005). Para pesquisadores que não desejam utilizar linguagens de programação sem precisar recorrer ao SPSS e suas limitações e inadequações psicométricas, o software Factor surge como uma alternativa viável. Trata-se de uma ferramenta gratuita, com interface simples e de fácil utilização, desenvolvida especificamente para execução de análises fatoriais exploratórias. Seu uso tem se difundido em áreas como a psicologia e a educação, por oferecer um meio acessível e metodologicamente consistente de realizar a AFE (Lorenzo-Seva; Ferrando, 2006).

Assim, a escolha consciente do software e dos procedimentos estatísticos torna-se um aspecto crucial para garantir a qualidade metodológica da Análise Fatorial Exploratória e, por extensão, a validade dos constructos utilizados em pesquisas científicas.

3. FACTOR COMO UMA ALTERNATIVA EFICAZ E ACESSÍVEL PARA ANÁLISE FATORIAL EXPLORATÓRIA

O Factor é um software gratuito e acessível, desenvolvido pelo Departamento de Psicologia da Universitat Rovira i Virgili, na Espanha, com o objetivo de facilitar a realização

de Análises Fatoriais Exploratórias (AFE). Sua interface intuitiva, que adota a metodologia “point and click”, torna a ferramenta atraente especialmente para pesquisadores que não possuem experiência em programação, mas que desejam realizar análises complexas de forma eficiente (Ferrando; Lorenzo-Seva, 2018). Embora o SPSS seja amplamente utilizado no meio acadêmico, o Factor vem se destacando como uma alternativa robusta e eficiente, que segue as melhores práticas metodológicas recomendadas para a execução de AFE. Nesse contexto, o Factor surge como uma alternativa eficaz, atendendo às principais críticas direcionadas ao SPSS.

De acordo com Rogers (2022), embora o SPSS seja uma escolha consolidada, o Factor oferece vantagens significativas, pois incorpora práticas atualizadas e eficazes que não são sempre implementadas em softwares mais tradicionais. Além disso, o software permite aos pesquisadores a escolha de métodos de extração que consideram apenas a variância compartilhada entre as variáveis, uma abordagem que alinha mais diretamente com os objetivos da Análise Fatorial, ao contrário do SPSS, que utiliza o método de Componentes Principais como padrão (Hair et al., 2009). Isso contribui para a precisão e a interpretação correta dos dados na busca por estruturas subjacentes.

Outra vantagem do Factor é a opção de realizar rotações oblíquas, uma prática recomendada quando se acredita que os fatores podem ser correlacionados. A rotação oblíqua é mais alinhada com as necessidades de muitos pesquisadores nas áreas de psicologia e comportamento organizacional, onde as variáveis tendem a ser interdependentes (Tabachnick; Fidell, 2007). Isso faz com que o Factor seja uma escolha vantajosa, principalmente quando comparado com ferramentas que utilizam apenas rotação ortogonal, como o SPSS.

O software Factor já incorpora de forma prática medidas essenciais de verificação de adequação dos dados à Análise Fatorial Exploratória (AFE), oferecendo testes como

o KMO (Kaiser-Meyer-Olkin) e o teste de Esfericidade de Bartlett de forma automatizada. Esses testes são fundamentais para avaliar a adequação da amostra e garantir a robustez da análise, conforme discutido por Hair et al. (2009). Além disso, o Factor permite o uso de estimadores robustos, como o Diagonally Weighted Least Squares (DWLS), uma técnica recomendada para situações em que os dados são ordinais ou quando as amostras são pequenas, atendendo às necessidades metodológicas de contextos em que os pressupostos do método de Máxima Verossimilhança podem ser violados (Hinkin, 1995). Essas funcionalidades tornam o Factor uma ferramenta poderosa e confiável para realizar AFE de maneira adequada e precisa.

Embora o Factor tenha ganhado popularidade nos últimos anos, sua utilização ainda não é amplamente disseminada, especialmente no Brasil. Estudos recentes, como o de Nascimento, Silva e Fonseca (2022), destacam a importância de divulgar o uso do Factor, apresentando-o como uma solução prática para superar as limitações de ferramentas mais tradicionais, ao mesmo tempo em que proporciona uma abordagem mais rigorosa e moderna para análise de dados multivariados. Esses autores enfatizam que o software facilita a execução de AFE de maneira eficiente, alinhada às melhores práticas da área, e é uma opção acessível para pesquisadores que buscam resultados de alta qualidade sem a necessidade de profundos conhecimentos em programação.

Além disso, a receptividade do Factor na comunidade acadêmica tem se refletido nas publicações que adotam o software em suas metodologias. Souza, Souza e Luiz (2024), por exemplo, utilizaram o Factor em sua pesquisa sobre políticas educacionais, destacando a eficácia da ferramenta em lidar com dados complexos e a clareza proporcionada pelas análises fatoriais realizadas. Essa aceitação reforça o potencial do Factor como uma ferramenta viável e prática, especialmente para pesquisadores de áreas como educação, psicologia e ciências sociais aplicadas, onde a análise fatorial desempenha um papel crucial na identificação de fatores latentes.

Portanto, o Factor se apresenta como uma alternativa valiosa para a realização de Análises Fatoriais Exploratórias, especialmente para pesquisadores que buscam uma ferramenta acessível, mas robusta. Sua interface intuitiva e conformidade com as melhores práticas metodológicas fazem dele uma opção eficiente e relevante no cenário acadêmico atual. A não exigência de conhecimento avançado em programação, o torna uma ferramenta acessível a pesquisadores de diversas áreas, frente as barreiras relacionadas à complexidade dos softwares estatísticos tradicionais. Tais características evidenciam a adaptabilidade do Factor às necessidades metodológicas atuais, o que demonstra seu valor no avanço da pesquisa acadêmica.

4. PASSO A PASSO DA ANÁLISE FATORIAL EXPLORATÓRIA (AFE) NO SOFTWARE FACTOR

A realização da Análise Fatorial Exploratória (AFE) no software Factor exige uma abordagem metódica e fundamentada, sendo crucial para garantir a robustez e a validade dos resultados obtidos. Este processo envolve diversas etapas metodológicas, incluindo a preparação dos dados, a verificação da fatorabilidade da matriz de correlação, a extração e rotação dos fatores, bem como a avaliação da qualidade do modelo gerado. Este passo a passo detalha as metodologias e parâmetros recomendados para cada uma dessas etapas, com ênfase na obtenção de resultados sólidos e interpretáveis, especialmente no contexto das pesquisas de marketing, onde a análise de construtos latentes se torna essencial para entender as dinâmicas subjacentes dos fenômenos estudados.

4.1 Preparação dos dados

A preparação dos dados é um aspecto crítico para garantir a qualidade e a integridade dos resultados da AFE. Antes de iniciar a análise, os dados devem ser importados para o software Factor e verificados quanto à consistência e adequação para a análise fatorial. Os dados

podem ser importados em formatos compatíveis, como .csv ou .sav. Uma vez importados, deve-se realizar uma verificação cuidadosa para identificar inconsistências ou valores ausentes que possam comprometer a qualidade da análise. Quando dados ausentes são identificados, o software oferece métodos de imputação, como a imputação por média ou mediana, para preencher as lacunas, assegurando que a análise não seja prejudicada pela falta de dados. Esse cuidado com a preparação dos dados é essencial para garantir que as análises subsequentes não sejam afetadas por problemas de qualidade dos dados.

4.2 Verificação da fatorabilidade

Antes de proceder com a extração dos fatores, é essencial avaliar a fatorabilidade da matriz de correlação, ou seja, verificar se os dados são adequados para a análise fatorial. A fatorabilidade é comumente verificada por meio de dois testes principais: o índice KMO (Kaiser-Meyer-Olkin) e o teste de Esfericidade de Bartlett.

O índice KMO fornece uma medida da adequação da amostra, variando de 0 a 1, sendo que quanto mais próximo de 1, maior a adequação dos dados para a análise fatorial. Para que os dados sejam considerados adequados, o valor do KMO deve ser superior a 0,70. Valores abaixo de 0,50 indicam que os dados não são adequados para a AFE, enquanto valores entre 0,50 e 0,70 são considerados medianos. Um valor superior a 0,80 indica uma excelente adequação dos dados (Hutcheson; Sofroniou, 1999).

Já o teste de Esfericidade de Bartlett avalia a hipótese nula de que a matriz de correlação seja uma matriz identidade, ou seja, que as variáveis não estejam correlacionadas entre si. Para garantir que a AFE seja válida, o valor de significância do teste de Bartlett deve ser inferior a 0,05, indicando que as variáveis estão significativamente correlacionadas (Field et al., 2012).

Esses testes são fundamentais, pois garantem que a matriz de correlação tenha

correlações suficientes entre as variáveis para justificar a realização da AFE, sendo sua execução essencial para o sucesso da análise.

4.3 Determinação do número de fatores

Uma das etapas mais cruciais da AFE é a determinação do número adequado de fatores a serem retidos. O critério tradicional baseado no eigenvalue (valor superior a 1) é amplamente utilizado, mas pode resultar em uma superestimação ou subestimação do número de fatores. Para uma escolha mais precisa e robusta, recomenda-se o uso da Análise Paralela. Este método compara a variância explicada pelos fatores extraídos com a variância dos fatores extraídos a partir de dados aleatórios, oferecendo uma solução mais confiável ao minimizar a retenção de fatores não significativos. A Análise Paralela é considerada superior ao critério tradicional, pois oferece uma forma mais precisa e robusta de determinar o número ideal de fatores a ser retido (Timmerman; Lorenzo-Seva, 2011).

4.4 Extração dos fatores

A extração dos fatores consiste na escolha de um método adequado para identificar as dimensões latentes subjacentes aos dados. Para dados ordinais ou quando a amostra é pequena, o método recomendado é o Diagonally Weighted Robust Least Squares (DWLS). O DWLS é uma técnica robusta que fornece estimativas mais precisas na extração dos fatores, especialmente quando os dados são ordinais ou quando não atendem aos pressupostos de normalidade exigidos por outras técnicas. Este método é eficaz para lidar com amostras pequenas ou distribuições não normais, garantindo a estabilidade e a precisão dos resultados. A robustez do DWLS contribui para a qualidade da extração dos fatores, especialmente em contextos em que a normalidade dos dados pode ser questionada (Floyd; Widaman, 1995).

4.5 Rotação fatorial

Após a extração dos fatores, é fundamental realizar a rotação fatorial, que visa facilitar a interpretação dos fatores extraídos, tornando-os mais facilmente identificáveis e compreensíveis. Em dados de marketing, onde as variáveis frequentemente apresentam correlação entre si, a rotação oblíqua é mais adequada. No software Factor, a rotacionação oblíqua é preferencial, pois permite que os fatores extraídos se correlacionem entre si, o que reflete melhor as interações complexas entre as variáveis, típicas de contextos de pesquisa de marketing. O método Robust Promin, uma versão aprimorada da rotação oblíqua, é recomendado devido à sua capacidade de garantir uma interpretação mais estável e válida dos fatores extraídos, mesmo em cenários onde as interações entre variáveis são complexas (Schmitt; Sass, 2011).

4.6 Avaliação do ajuste do modelo

A avaliação do ajuste do modelo é uma etapa fundamental para verificar se a solução fatorial extraída se adequa bem aos dados observados. No software Factor, essa avaliação é realizada por meio de índices de ajuste, como RMSEA (Root Mean Square Error of Approximation), CFI (Comparative Fit Index) e TLI (Tucker-Lewis Index). O RMSEA deve ser inferior a 0,08 para indicar um bom ajuste, enquanto os valores de CFI e TLI devem ser superiores a 0,90. Esses índices são essenciais para garantir que o modelo de fatores extraídos reflita adequadamente a variabilidade dos dados observados, validando a estrutura fatorial e a adequação do modelo (Brown, 2015).

4.7 Estabilidade dos fatores e fidedignidade

A última etapa da AFE envolve a análise da estabilidade dos fatores e a avaliação da fidedignidade da solução fatorial. A estabilidade dos fatores pode ser verificada por meio do índice H, que mede a replicabilidade da estrutura fatorial. Valores superiores a 0,80 indicam que a estrutura fatorial é estável e replicável,

o que é fundamental para a confiabilidade dos resultados, especialmente em amostras diferentes ou contextos distintos (Ventura-Léon; Peña-Calero, 2021).

Para a avaliação da consistência interna da solução fatorial, recomenda-se o uso de índices de fidedignidade compostos e Fidedignidade Ômega, que são mais adequados para dados com cargas fatoriais desiguais. Esses índices são superiores ao tradicional Alfa de Cronbach, que assume a igualdade das cargas fatoriais, um pressuposto frequentemente não válido em pesquisas sociais e de marketing. A Fidedignidade Composta e a Fidedignidade Ômega oferecem uma medida mais precisa da confiabilidade do modelo, levando em consideração a variação nas cargas dos itens (Trizano-Hermosilla; Alvarado, 2016).

Diante do exposto, entende-se que a realização da AFE no software Factor requer uma abordagem metódica e fundamentada em princípios metodológicos sólidos. A aplicação criteriosa de técnicas como a Análise Paralela, a rotação oblíqua e a avaliação de fidedignidade garantem que os resultados obtidos sejam válidos, robustos e úteis para a interpretação de construtos latentes, especialmente em pesquisas que envolvem dados complexos, como as de marketing. O rigor metodológico nas etapas descritas é essencial para garantir que a solução fatorial extraída reflita adequadamente a estrutura subjacente dos dados, permitindo uma interpretação precisa dos fenômenos analisados e contribuindo para a profundidade e qualidade das conclusões da pesquisa.

5. UM EXEMPLO PRÁTICO ILUSTRATIVO DA APLICAÇÃO

Para a elaboração do tutorial, foi desenvolvido um caminho didático para a aplicação da Análise Fatorial Exploratória (AFE) no Software Factor, utilizando como referencial a escala proposta por Yi e Gong (2013) para mensuração do comportamento de cocriação. A partir de um banco de dados, (disponível em <https://drive.google.com/>

[drive/folders/1DA46PC0eaFt2NhmwB_D2ZHQGpZkL7TSC](https://drive.google.com/drive/folders/1DA46PC0eaFt2NhmwB_D2ZHQGpZkL7TSC)) composto por uma amostra de 438 observações previamente tratadas, o tutorial apresenta um exemplo prático ilustrativo da aplicação da AFE no Software Factor. São detalhadas as definições metodológicas e configurações otimizadas no software, com o objetivo de proporcionar uma análise mais robusta e precisa. Este procedimento visa assegurar a obtenção de resultados adequados e consistentes, especialmente para estudos de natureza social aplicada, nos quais a validade e a confiabilidade dos dados são de fundamental importância.

5.1 Executando a AFE no Factor

O Factor pode ser baixado no site do Departamento de Psicologia da Universitat Rovira i Virgili, Tarragona, Espanha (Ferrando; Lorenzo-Seva, 2018). O software utiliza um banco de dados no formato .dat separado por tabulações, ou seja, é preciso configurar seu banco em formato do Excel ou SPSS em (.txt), em seguida transformá-lo em (.dat). O banco de dados é executável no Factor e, como indicado na Figura 1 (próxima página), clicando em Read Data insere-se o banco de dados em Browse.

Figura 1- Executando o banco de dados

Fonte: Software Factor

Ainda na Figura 1, é possível observar em destaque verde o número de participantes e de variáveis. Mais abaixo, recomenda-se selecionar a geração de 500 amostras bootstrap para análises robustas em Compute bootstrap samples antes de configurar as análises. Caso o banco de dados tenha dados ausentes, recomenda-se clicar em Missing Values, podendo codificá-los numericamente (Lorenzo-Seva; Van Ginkel, 2016).

O procedimento de análise é configurado ao clicar em Configure Analysis. A Figura 2 indica a tela de parâmetros da AFE a serem escolhidos. No canto superior esquerdo, (vide Figura 2. a) em Variable in the Analysis, verifica-se as variáveis incluídas ou, caso necessário, excluídas da AFE, e no canto superior direito, (vide 2.b) deve-se clicar na matriz de correlação a ser utilizada.

Figura 2 – Configuração da AFE no software Factor

Fonte: Software Factor

O Padrão de matriz analisada do Factor é dado pela matriz de Pearson, que entende os dados como uma matriz escalar. Já a matriz policórica entende a matriz dos dados como ordinal. Dado que o tutorial utilizou um questionário do tipo Likert, priorizou-se a Polichoric Correlation, já que não se pode inferir em uma escala do tipo Likert que a pontuação de concordância e discordância estipulada é equivalente em termos de traço latente necessário a cada categoria.

Seguidamente, configuram-se os métodos de retenção de fatores na aba Procedure For Determing The Number Of Factors/Components (vide 2.c). O Factor conta com quatro procedimentos 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 (PA); e (d) método de Hull. Na exemplificação, escolheu-se a PA otimizada, que segue a lógica da PA clássica de Horn (1965) ao comparar eigenvalues da matriz original com matrizes aleatórias. No entanto, a PA otimizada usa a variância explicada em vez dos eigenvalues (Timmerman; Lorenzo-Seva, 2011).

A reamostragem das matrizes aleatórias, definidas em Permutation of sample values, são geradas a partir do padrão dos dados originais, oferecendo estimativas mais fidedignas quando a distribuição amostral observada não é normal (Damásio; Dutra, 2018; Timmerman; Lorenzo-Seva, 2011), característica observada em fenômenos sociais. Tais decisões são tomadas no espaço Configure (Figura 3), da aba descrita (Procedure For Determing The Number Of Factors/Components).

Figura 3- Configuração da análise paralela

Configuration of Parallel Analysis

Implementation of Parallel Analysis

☒ Optimal implementation (Timmerman & Lorenzo-Seva, 2011)

☐ Classical implementation (Horn, 1965)

Parallel Analysis is computed as based on the same type of correlation matrix (i.e., Pearson or polychoric correlation) and the same type of underlying dimensions (i.e., components or factors) as defined for the whole analysis.

The user can configure the number of random correlation matrices and the procedure to obtain them (Normal distribution or random permutation of sample values).

Please, see Timmerman & Lorenzo-Seva (2011) for a detailed explanation.

Timmerman, M.E., & Lorenzo-Seva, U. (2011). Dimensionality assessment of ordered polytomous items with parallel analysis. *Psychological methods*, 16(2), 200-220. doi: 10.1037/a0022352

Implementation of Parallel Analysis

Number of random correlation matrices:

Generation of random correlation matrices:

Maximum number of factors to be considered in Parallel Analysis

☐ Ledermann's bound = 47 factors

☒ Arbitray value defined by the user:

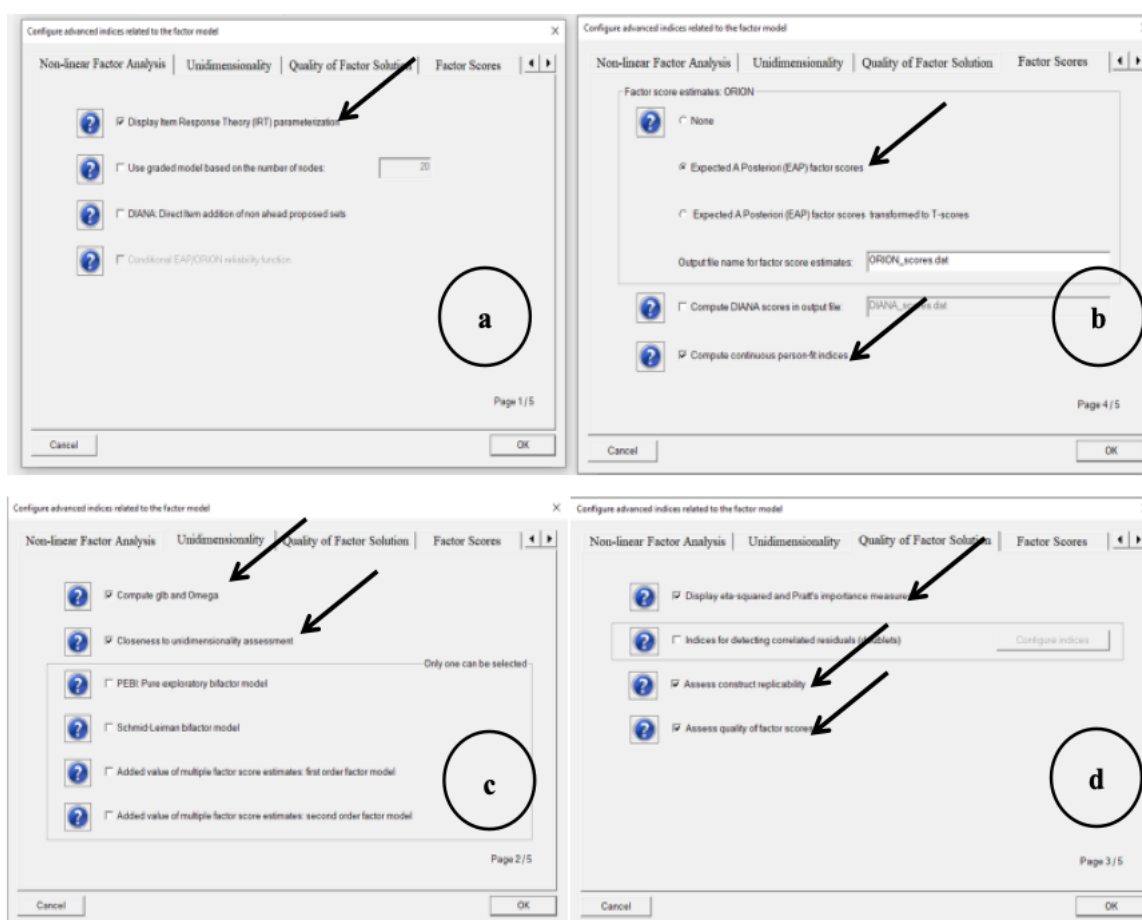
Fonte: Software Factor

Em Factor Model (vide Figura 2.d), define-se o maior número de testes a serem executados para a AFE no Factor. Primeiramente estipula-se o número de fatores que se pretende encontrar. O método de estimação utilizado para a estipulação foi o DWLS, por ser aplicável em variáveis ordinais com distribuição não normal. Para isso, clica-se em Robust Fator Analysis, de modo a realçar os

métodos robustos no Factor. Sem muito detalhamento estatístico quanto ao método, à correção robusta DWLS utiliza o mesmo algoritmo do método de estimação WLSMV (Asparouhov; Muthen, 2010), um método estaticamente robusto para a estipulação do número de fatores.

Ainda em Factor Model (vide Figura 2. d), mais especificamente em Other specifications of factors model, após o clique apresenta-se outra janela de análises a serem realizadas, como se vê na Figura 3. A interface da janela é apresenta em abas, de modo a serem escolhidos os parâmetros de análise que pretende utilizar em paridade com a natureza de seus bancos de dados. A parametrização inicial indicada em Non-linear Factor Analysis (vide Figura 2. a) e aplicada no modelo de exemplo é dado pela Teoria de Respostas ao Item (TRI). Aplicando essa parametrização, o Factor encarrega-se de relacionar, em um conjunto de itens, as variáveis observáveis e não observáveis em um traço latente. Assim, a TRI encarrega-se de identificar em um questionário os itens que possuem o traço latente, de acordo com a resposta dada pelo sujeito (Pasquali, 2020).

Figura 4 – Especificações da AFE no Factor



Fonte: Software Factor

Em Factor Scores (vide Figura 4. b), o Factor gera as pontuações fatoriais de cada um dos sujeitos do banco de dados, diante da opção dada em Expected a posteriori (EAP) factor scores. No Factor, ainda possível observar o quanto o sujeito do seu banco de dados está respondendo de forma confiável, dada à opção Compute continuous person-fit índices que indica as respostas que não apresentam um padrão de confiabilidade aceitável (não prestou atenção, respostas aleatórias de acordo com o padrão). Em seguida, na aba Unidimensionality, o Factor apresenta alguns índices de fidedignidade unidimensional, ou seja, pode-se observar, por meio de determinados índices, o quanto um fator poderia ser considerado como unidimensional (Compute glb and ômega e Closeness

to unidimensionality assessment), vide Figura 4. c. Quando se tem mais de um fator, espera-se rejeitar tais índices, de modo inverso, quando se tem um fator, espera-se aceitá-los. Em frente, na aba Quality Factor Solutions, apresentam-se os índices de qualidade da solução encontrada, de modo a verificar a força, replicabilidade e qualidade do modelo fatorial (Display eta-squared and Pratts importance measures, Assess construct replicability e Assess quality of factor scores), vide Figura 4.d.

Quanto à rotação (vide Figura 2. e), tendo como base a premissa que em pesquisas sociais aplicadas, como as pesquisas de marketing, os fatores compartilham certo grau de relação, as rotações mais indicadas são do tipo oblíquo – especificamente, Direct Oblimin e Promax. 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). Por fim, recomenda-se a nomeação do output de saída para a melhor organização de seu trabalho, de acordo com o nome da variável trada (Vide Figura 2. f). Isso feito, o processo de escolha de parâmetros para a AFE se encerra, podendo-se executar a análise na tela inicial do Factor. Esse processo foi desenvolvido com a base de dados da escala de comportamento de cocriação, em seguida, apresentam-se as soluções observadas após execução da AFE no Factor.

5.2 As principais soluções da AFE no Factor

No fator, o coeficiente de Mardia (1970) é utilizado para testar a suposição de normalidade multivariada dos dados. A normalidade dos da base dados composto pela aplicação da escala de comportamento de cocriação, em pesquisa prévia, não foi aceita (mardia $p < 0,05$), mas a técnica de estimação utilizada, ou seja, DWLS trata os dados como ordinais e corrige a não normalidade dos dados. O Kaiser-Meyer-Olkin (KMO) = 0,91904 e o Bartlett's Scouting Test = 4709,0 (df = 120; $P = 0,000010$), para a dimensão Participação e o Kaiser-Meyer-Olkin (KMO) = 0,91904 e o Bartlett Sphericity Test = 4709,0 (df = 120; $P = 0,000010$), para a dimensão Cidadania

foram adequadamente satisfatórios para seguir com a análise no Factor.

A Análise Paralela Otimizada, um método de retenção de fator usado na AFE utiliza a variância explicada real dos dados e a compara com o banco de dados gerado aleatoriamente. O número de matrizes de correlação aleatória geradas na análise foi de 500 matrizes e o método para obtenção de matrizes de correlação aleatória é a chamada Permutação Bruta de Dados (Buja; Eyuboglu, 1992). Conforme a Tabela 1, quanto à dimensão Participação, as variâncias explicadas dos itens da matriz original, comparadas aos aleatórios, concentram-se em duas dimensões. Assim, entende-se que a variância real dos dados tem poder de explicação em um primeiro fator, com percentual de 51,47%, e em segundo fator, com percentual de 14,69%, quando o percentil é 95%. Em relação à dimensão Cidadania, as variâncias explicadas dos itens da matriz original, comparadas com os aleatórios, concentram-se em uma dimensão, com percentual de 61,16%.

Tabela 1- Análise Paralela (PA) com base na Análise do Fator Mínimo – Escala Comportamento Cocriação

Itens	% de variância dos dados reais	% média de variância aleatória	95 percentis % variância aleatória
Comportamento de Participação			
1	51.4727*	12.6487	14.6751
2	14.6953*	11.5836	13.0502
3	6.8303	10.7021	11.9120
4	5.9218	9.8618	10.9303
5	4.4059	9.0255	9.9213
6	3.5739	8.2507	9.1073
7	2.6564	7.4061	8.1125
8	2.2001	6.6037	7.4367
9	2.0688	5.8364	6.6639
10	1.7290	4.9954	5.8493
11	1.3949	4.2232	5.1409
12	1.0544	3.4093	4.4158
13	1.0352	2.6533	3.6121
14	0.7230	1.8166	2.8690
15	0.2383	0.9836	1.9099
Comportamento de Cidadania			
1	61.1603*	16.9123	19.9020
2	14.3940	15.0956	17.5695
3	12.1195	13.4580	15.1828
4	3.9656	11.9128	13.2064
5	3.1740	10.4381	11.6450
6	1.5431	8.9394	10.1774
7	1.0942	7.5245	8.8495
8	0.9821	6.1628	7.5930
9	0.8268	4.6641	6.1974
10	0.5177	3.2068	4.8390
11	0.2226	1.6857	3.3061

Fonte: Software Factor

Como saída no Factor, são apresentados os índices de avaliação da unidimensionalidade para observar se a parcimoniosidade dos fatores encontrados pode ser reforçada. Para que os dados sejam tratados como essencialmente unidimensionais o valor do índice One-Dimensional Congruence e I-Unico (One-Dimensional Item Congruence) deve ser maior que 0,95, o valor do Índice ECV (Variação comum explicada) e I-ECV (variação comum explicada do item) deve ser maior que 0,85 e o valor do índice MIREAL (Cargas absolutas residuais médias do item) e I-REAL (Cargas absolutas residuais do item) deve ser menor que 0,300 (Ferrando; Lorenzo-Seva, 2018).

Após a configuração da AFE no Fator, os índices encontrados foram, respectivamente, UniCo = 0,895 (bootstrap 90% e intervalos de confiança por fator = (0,866 e 0,919)), ECV = 0,858 (bootstrap 90% e intervalos de confiança por fator = (0,843 e 0,883)) e MIREAL = 0,197 – bootstrap 90% e intervalos de confiança por fator = (0,168 e 0,207). O primeiro índice indica a não unidimensionalidade da estrutura (UniCo), o segundo apresenta unidimensionalidade limítrofe (ECV) e o terceiro apresenta unidimensionalidade (MIREAL) para a dimensão Participação. Em relação à dimensão Cidadania, os índices encontrados foram, respectivamente, UniCo = 0,935 – intervalo de confiança bootstrap 90% = (0,917 e 0,959), ECV = 0,815 – intervalo de confiança bootstrap 90% = (0,793 e 0,843) e MIREAL = 0,302 – bootstrap 90 % intervalos = (0,274 e 0,320). Os índices mostram que a dimensão cidadania se dá como unidimensional não essencial.

Os índices de unidimensionalidade não essencialmente encontrados reforça a proposta multidimensional da escala de comportamento de cocriação de Yi e Gong (2013). Contudo, a estrutura fatorial evidenciada pela Análise Paralela traz como resultado as características preponderantes da amostra que foi aplicada a escala, ou seja, características de um segmento amostral de mercado ou consumo, dado que a estrutura fatorial apresenta índices de ajuste adequados, como mostra a

Tabela 2.

Tabela 2 – Índices de Ajuste da AFE – Escala Comportamento de Cocriação

Dimension	Participação
Root Mean Square Error of Approximation (RMSEA)	0,053; Bootstrap 90% intervalo de confiança = (0.0027 0.0657).
Non-Normed Fit Index (NNFI; Tucker; Lewis)	0.973; BC Bootstrap 90% intervalo de confiança = (0.947 0.996).
Comparative Fit Index (CFI)	0.980; BC Bootstrap 90% intervalo de confiança = (0.961 0.997).
Dimensão	Cidadania
Root Mean Square Error of Approximation (RMSEA)	0.190; Bootstrap 90% intervalo de confiança = (0.1684 0.2128).
Non-Normed Fit Index (NNFI; Tucker; Lewis)	0.960; Bootstrap 90% intervalo de confiança = (0.947 0.969).
Comparative Fit Index (CFI)	0.974; BC Bootstrap 90% intervalo de confiança = (0.966 0.980).

Fonte: Software Factor

Os índices de ajuste são comumente utilizados em uma Análise Fatorial Confirmatória (AFC), no entanto, são uma possibilidade no Fator capaz de indicar o quão ajustado o modelo se encontra. Os critérios de ajuste exigidos na AFC podem ser um tanto rígidos para a AFE (Hoelzle; Meyer, 2009). No entanto, as medidas de ajuste de um CFA ($1 < \chi^2/df < 3$, CFI e TLI $> 0,95$ e RMSEA $< 0,08$) aplicadas ao AFE (Brown, 2015) contribuem para o rigor científico à pesquisa exploratória e à prática analítica (Rogers, 2021). No modelo arbitrado, os índices de ajustes comparativos CFI (0,980) e TLI (NNFI = 0,973) indicam o bom ajuste do modelo AFE, assim como o índice residual RMSEA foi adequado (RMSEA = 0,053) para a dimensão participação. A dimensão Cidadania apresenta os índices de ajustes comparativos CFI (0,974) e TLI (NNFI = 0,960) adequados, porém, o índice residual RMSEA está acima do esperado (RMSEA = 0,190). Dado o bom encontrado ajuste, considere-se a estrutura do caso na Tabela 3, ou seja, a estrutura fatorial das dimensões Participação e Cidadania, do comportamento de cocriação, omitidos os valores abaixo de 0,300 (Ferrando; Lorenzo-Seva, 2018), Dado uma consistência interna pelo coeficiente Ômega de Macdonald = 0.95, de modo a evidenciar uma consistência do instrumento quanto ao que se propõe medir.

Tabela 3 – Estrutura Fatorial – Escala Comportamento de Cocriação

Variável	Comportamento de Participação	
	F1	F2
V 1	0.544	
V 8	0.782	
V 9	0.824	
V 10	0.727	
V 11	0.628	
V 4		0.538
V 5		0.465
V 6		0.667
V 7		0.593
V 12		0.817
V 13		0.858
V 14		0.950
V 15		0.904
Variável	Comportamento de Cidadania	
	F1	F2
V 2	0.476	
V 3	0.973	
V 4	0.944	
V 5	0.840	
V 6	0.894	
V 7	0.901	
V 8	0.878	
V 9	0.868	
V 10	0.951	
V 11	0.912	
V 12	0.937	

Fonte: Software Factor

Em busca de uma AFE robusta, a estabilidade da estrutura é evidenciada pela replicabilidade do modelo por meio do índice H, que avalia o quão bem um conjunto de itens representa um fator comum. O índice limita-se a amplitude de 0 e 1 e alcança a maior unidade conforme aumenta a magnitude das cargas fatoriais e/ou o número de itens. Valores altos de H ($> 0,80$) sugerem uma variável latente bem definida, com maior probabilidade de ser estável entre os estudos, enquanto valores baixos de H sugerem uma variável latente mal definida, que provavelmente muda entre os estudos (Ferrando; Lorenzo-Seva, 2018). Nesse sentido, a Tabela 4 mostra que as variáveis Latentes Participação e Cidadania são estáveis em sua composição, de modo que a consideração do índice H pode ser dada como explicação e justificativa para a estrutura estável encontrada.

Tabela 4 – Replicabilidade dos construtos encontrados - Índice H (G-H) Generalizado

Comportamento de Participação		
	H-latente	BC Bootstrap 90% intervalo de confiança
Fator 1	0.955	(0.927 0.969)
Fator 2	0.996	(0.977 1.006)
Comportamento de Cidadania		
Fator 1	0.979	(0.975 0.982)

Fonte: Software Factor

Além disso, no que diz respeito à evidência de estrutura estável, o Factor traz a qualidade e eficácia das estimativas de pontuação fatorial por meio de índices de determinação fatorial, confiabilidade marginal, razão de sensibilidade e porcentagem esperada de diferenças verdadeiras. Se escores fatoriais forem usados para avaliação individual, valores de IDE acima de 0,90, confiabilidade marginal acima de 0,80, SR acima de 2 e EPTDs acima de 90% são recomendados (Ferrando; Lorenzo-Seva, 2018).

Tabela 5 – Qualidade e eficácia das estimativas de pontuação fatorial

Comportamento de Participação		
	Fator 1	Fator 2
Factor Determinacy Index (FDI)	0.959	0.972
ORION marginal reliability	0.919	0.944
Sensitivity ratio (SR)	3.365	4.115
Expected percentage of true differences (EPTD)	93.4%	94.9%
Comportamento de Cidadania		
Factor Determinacy Index (FDI)	0.988	
ORION marginal reliability	0.976	
Sensitivity ratio (SR)	6.355	
Expected percentage of true differences (EPTD)	97.4%	

Fonte: Software Factor

Por fim, a AFE no Factor permite avaliar a discriminação dos itens, utilizando a Teoria de Resposta ao Item para verificar a coerência dos itens em relação à probabilidade de endosso da variável latente. Isso ajuda a identificar quais itens são mais discriminatórios, contribuindo para a qualidade do instrumento e a interpretação dos resultados, com impacto teórico e prático. No exemplo didático, os resultados são apresentados na Tabela 5. Observa-se que o item V8 é o mais discriminador do Fator 1 e o item V7 é o mais discriminador do Fator 2 do comportamento Participação. No comportamento de cidadania, o item V12 foi apontado como o mais discriminador.

Tabela 6 – Padrão de discriminações de itens: modelo multidimensional de resposta graduada normal-ogiva

Comportamento de Participação			
Item	a1	a2	Mdisc
V 1	0.819	0.169	0.836
V 2	0.149	1.102	1.112
V 3	0.075	1.461	1.463
V 4	0.003	1.365	1.365
V 5	-0.006	0.987	0.987
V 6	-0.675	2.768	2.849
V 7	-0.835	3.069*	3.181
V 8	1.431*	-0.306	1.464
V 9	1.236	-0.135	1.244
V 10	0.598	0.048	0.600
V 11	1.069	0.132	1.077
V 12	0.087	0.766	0.771
V 13	0.099	0.866	0.872
V 14	-0.065	1.971	1.972
V 15	-0.104	1.437	1.441
Comportamento de Cidadania			
V1	0.306		0.348
V2	0.538		0.539
V3	1.999		2.031
V4	2.053		2.063
V5	1.420		1.423
V6	2.645		2.654
V7	2.964		2.976
V8	2.831		2.854
V9	2.304		2.316
V10	2.324		2.329
V11	2.523		2.525
V12	3.283*		3.285
a: discrimination of items in each dimension (discriminação de itens em cada dimensão)			
MDISC: multidimensional item discrimination (discriminação de itens multidimensionais)			

Fonte: Software Factor

Outra informação trazida pelo Factor em relação a TRI é os Thresholds dos itens, ou seja, no Factor é possível verificar os interceptos entre as categorias da escala, como mostra a Tabela 6. Os thresholds revela o nível de traço latente que é requerido para que você passe da categoria 1 (discordo totalmente) e passe para categoria 2 (concordo) e assim sucessivamente, de modo que quanto maior for à categoria de resposta da escala, maior for o nível de traço latente necessário para endossá-lo. No resultado, foram encontrados apenas dois padrões inesperados de resposta, contudo,

dados o número de variáveis da escala os dois padrões inesperados podem estar relacionados à escala ser desenvolvidas com muitos pontos/categorias (Reckase, 1985).

6. PANORAMA DOS RECURSOS E FUNCIONALIDADES DO FACTOR

Com uma interface intuitiva e uma ampla gama de funcionalidades estatísticas, o programa oferece suporte a diferentes técnicas de extração e métodos de análise adequados ao tratamento de variáveis ordinais e intervalares. A seguir, apresentam-se resumos com o objetivo de auxiliar os pesquisadores na escolha mais adequada conforme os objetivos e características de seus dados. O Quadro 1 sintetiza as principais ferramentas estatísticas disponíveis no Factor.

Quadro 1 – Ferramentas estatísticas no Factor

Ferramenta	Descrição Técnica	Justificativa na AFE	Base Teórica
Análise de Grupo Único (<i>Single Group</i>)	A análise é feita considerando todos os dados como pertencentes a uma única amostra/público.	Útil para investigar a estrutura fatorial geral e identificar quantos fatores latentes melhor explicam a variância comum entre os itens.	Gorsuch (1983), Fabrigar et al. (1999)
Análise de Múltiplos Grupos (<i>Multiple Groups</i>)	Permite comparar estruturas fatoriais entre dois ou mais grupos (ex: gênero, escolaridade), avaliando a invariância.	Verifica se o modelo fatorial é estável e comparável entre diferentes grupos, importante para validade externa.	Byrne (2013), Meredith (1993)
Método de Extração (ex: <i>Unweighted Least Squares – ULS, Robust ULS, ML, etc.</i>)	Técnica usada para extrair os fatores latentes a partir da matriz de correlação.	Permite a identificação estruturas subjacentes (fatores comuns), buscando reduzir a dimensionalidade dos dados	Spearman (1961), Fabrigar et al. (1999)
Determinação do Número de Fatores (ex: <i>Parallel Analysis, MAP, Eigenvalues > 1</i>)	Métodos estatísticos que ajudam a decidir quantos fatores devem ser retidos.	Evita superestimação ou subestimação de fatores, garantindo validade da estrutura.	Horn (1965), Velicer (1976)
Rotação Fatorial (ex: <i>Promin, Oblimin, Varimax</i>)	Procedimento que facilita a interpretação dos fatores, ajustando os carregamentos para maior clareza.	Promin (oblíqua) permite correlação entre fatores, mais adequado em ciências humanas.	Thurstone (1947), Jennrich; Sampson (1966)
Correlação Policórica (em vez da <i>Pearson</i>)	Correlação usada para variáveis ordinais (como escalas tipo Likert), mais apropriada para dados não contínuos.	Gera estimativas mais precisas da estrutura fatorial com dados ordinais.	Holgado–Tello et al. (2010), Flora; Curran (2004)
Índices de Ajuste (ex: <i>GFI, RMSR, CFI, RMSEA</i>)	Medidas que avaliam a adequação do modelo fatorial ajustado aos dados observados.	Valida o modelo, ajuda na decisão de modificação ou aceitação da estrutura.	Hu; Bentler (1999), Browne; Cudeck (1992)
Bootstrap / Amostras Aleatórias	Gera estimativas robustas por meio de reamostragem, útil quando o N é limitado.	Melhora a precisão das estimativas de carga fatorial e estabilidade do modelo.	Efron; Tibshirani (1993)
Invariância Fatorial (configural, métrica, escalar)	Testa se a estrutura fatorial é equivalente entre grupos em diferentes níveis (cargas, interceptos).	Necessária para comparar médias latentes entre grupos.	Vandenberg; Lance (2000), Meredith (1993)

Fonte: Elaborado pelos autores

O software se mostra particularmente eficaz para AFE com dados não normais ou de natureza ordinal — característica recorrente nos dados quantitativos utilizados nas ciências sociais. Muitos dos métodos empregados refletem abordagens mais modernas da psicometria, com destaque para o uso de correlação policórica e métodos de extração robusta. Diante disso, no Quadro 2 são apresentadas informações mais detalhadas sobre os principais métodos de extração de fatores disponíveis no Factor.

Quadro 2 – Métodos de extração no Factor

Método de Extração	Descrição Técnica	Vantagens / Quando Usar	Pressupostos	Base teórica
ULS (<i>Unweighted Least Squares</i>)	Minimiza a soma dos quadrados das diferenças entre as correlações observadas e reproduzidas, sem ponderações.	Robusto a violações da normalidade; indicado para dados ordinais e grandes amostras.	Não exige normalidade; adequado para correlação policórica.	Jöreskog; Sörbom (1979); Fabrigar et al. (1999)
RULS (<i>Robust ULS</i>)	Versão robusta do ULS, que ajusta os erros de estimação.	Ideal para dados ordinais com distorções leves; mais estável em N moderado.	Sem pressupostos rígidos.	Lloret-Segura et al. (2014); Baglin (2014)
DWLS (<i>Diagonally Weighted Least Squares</i>)	Usa apenas os elementos diagonais da matriz de peso para minimizar o impacto de erros na estimação.	Excelente para escalas tipo Likert; bom desempenho com N moderado e dados não normais.	Recomendado para correlação policórica.	Holm et al. (2019); Flora; Curran (2004)
GLS (<i>Generalized Least Squares</i>)	Estima ponderando a matriz de correlação conforme os erros padrões (matriz completa).	Mais eficiente que ULS quando os dados são normais.	Exige normalidade multivariada.	Jöreskog (1970); Lawley; Maxwell (1962)
ML (<i>Maximum Likelihood</i>)	Estima parâmetros maximizando a probabilidade de ocorrência dos dados conforme o modelo.	Permite teste de significância e ajuste do modelo; útil com dados contínuos e normais.	Pressupõe normalidade multivariada.	Jöreskog (1969); Fabrigar et al. (1999)
OSR (<i>Ordinary Scale Robust</i>)	Técnica robusta para dados ordinais; ajusta a matriz policórica para dados assimétricos.	Útil com escalas Likert e distribuições com curtose ou assimetria.	Pouca sensibilidade à violação de normalidade.	Baglin (2014)
Bayesiano (<i>Estimativas Bayes</i>)	Utiliza distribuições a priori e algoritmos de simulação para estimar os parâmetros fatoriais.	Adequado em contextos com incerteza, amostras pequenas ou modelos complexos.	Requer conhecimento prévio sobre o modelo.	Muthén; Asparouhov (2012); Lee (2007)

Fonte: Elaborado pelos autores

Nas ciências humanas e sociais, principalmente em pesquisas aplicadas em Administração, como pesquisas de marketing, é comum o uso de escalas do tipo Likert, caracterizadas por dados ordinais e não contínuos. Nesse contexto, métodos de extração como ULS (Unweighted Least

Squares), RULS (Robust ULS), DWLS (Diagonally Weighted Least Squares) e OSR (Ordinary Scale Robust) são os mais recomendados, pois são menos sensíveis à violação da normalidade e mais adequados ao tratamento de correlações policóricas.

Por outro lado, em situações em que os dados são contínuos e apresentam distribuição normal multivariada, métodos como ML (Maximum Likelihood) e GLS (Generalized Least Squares) se tornam mais apropriados por permitirem testes estatísticos mais robustos e intervalos de confiança. Dado o amplo conjunto de recursos e funcionalidades oferecidos pelo Factor, depreende-se sua notável adequação para pesquisas no campo das ciências sociais, especialmente nas áreas de Administração e Marketing. A flexibilidade nas técnicas de extração, a precisão na análise de dados ordinais e as opções para avaliação da invariância fatorial tornam o software particularmente eficaz para investigar estruturas latentes em contextos aplicados, nos quais a compreensão de constructos complexos é essencial.

7. CONSIDERAÇÕES FINAIS

A partir de uma abordagem teórico-metodológica, este estudo evidenciou como o software Factor contribui para a robustez, precisão e adequação dos procedimentos estatísticos voltados à investigação de estruturas latentes, com ênfase em dados de natureza ordinal e sem distribuição normal — condições amplamente recorrentes em áreas como Administração, Psicologia, Educação e Marketing.

Ao longo do trabalho, foram abordados os fundamentos conceituais e operacionais da AFE, com destaque para aspectos como a definição da matriz de correlação adequada (policórica), a escolha do método de extração, os critérios de retenção de fatores, as estratégias de rotação e os índices de ajuste. O artigo também avançou para uma aplicação prática com dados reais, demonstrando a operacionalização de cada etapa dentro do software, o que permitiu exemplificar a usabilidade da ferramenta, bem

como a interpretação de seus resultados.

Portanto, a principal contribuição deste estudo reside na sistematização crítica dos recursos do Factor e na demonstração de seu uso aplicado, oferecendo aos pesquisadores uma base técnica e prática para a tomada de decisões metodológicas mais fundamentadas. Essa contribuição é especialmente relevante para a construção e validação de instrumentos psicométricos, favorecendo análises mais precisas e contextualizadas nos estudos que lidam com variáveis latentes.

Ademais, os quadros-resumo apresentados — detalhando funcionalidades estatísticas e métodos de extração — representam um recurso diferencial frente a outros tutoriais já publicados, como o de Rogers (2022), qualificando o artigo como uma referência mais completa tanto para formação de pesquisadores quanto para uso em atividades de ensino em disciplinas de metodologia e estatística aplicada. O Factor se destaca, nesse contexto, por oferecer amplo suporte à análise de dados ordinais, superando limitações de programas tradicionais como o SPSS, que não oferecem suporte nativo à correlação policórica e métodos robustos como ULS, RULS ou DWLS.

Este estudo também contribui para o avanço das pesquisas nas ciências sociais aplicadas, com destaque para áreas como Administração e Marketing. Nessas disciplinas, é comum o uso de instrumentos de mensuração baseados em escalas do tipo Likert, que geram dados ordinais e frequentemente violam pressupostos de normalidade exigidos por softwares tradicionais. O Factor se sobressai justamente por oferecer soluções estatísticas robustas para esse tipo de dado, permitindo análises mais precisas e coerentes com a natureza dos fenômenos sociais estudados.

Na Administração, por exemplo, o uso da AFE é fundamental para o desenvolvimento de construtos como clima organizacional, engajamento no trabalho e satisfação do cliente — aspectos essenciais para diagnóstico e tomada de decisão organizacional. Já no Marketing, a análise de percepções, atitudes, intenções de compra e comportamentos do consumidor exige

instrumentos psicometricamente validados, cuja estrutura fatorial precisa ser adequadamente explorada. O Factor, ao permitir uma abordagem moderna e rigorosa da AFE com dados reais de pesquisas de campo, se torna uma ferramenta estratégica para pesquisadores e profissionais interessados em desenvolver escalas válidas, confiáveis e sensíveis às nuances dos dados coletados em contextos sociais e organizacionais reais.

É importante ressaltar, contudo, que os resultados encontrados refletem as particularidades da amostra e da aplicação empírica, evidenciando uma estrutura fatorial que diverge da configuração original da escala. Tal divergência não invalida a proposta do estudo, mas indica a necessidade de cautela ao extrapolar as conclusões, uma vez que a validação da estrutura fatorial exige procedimentos adicionais, como a Análise Fatorial Confirmatória (AFC) e testes de invariância. Assim, o presente estudo deve ser interpretado como um guia metodológico para condução da AFE, e não como uma validação definitiva da escala analisada.

Como limitação, ressalta-se que o escopo do artigo esteve centrado na Análise Fatorial Exploratória, sem avançar para procedimentos subsequentes, como a Análise Fatorial Confirmatória (AFC) ou a Modelagem por Equações Estruturais (MEE), que poderiam ser utilizadas para refinar ou confirmar a estrutura proposta. Além disso, embora tenha sido realizada uma aplicação empírica, o foco foi mais instrumental e ilustrativo do que analítico, não se aprofundando na discussão teórica dos resultados extraídos.

REFERÊNCIAS

- ASPAROUHOV, T.; MUTHÉN, B. Weighted least squares estimation with missing data. **Mplus Technical Appendix**, v. 2010, n. 1-10, p. 5, 2010. Disponível em: https://www.statmodel.com/download/TechAppendix_1.pdf
- BAGLIN, J. Improving your exploratory factor analysis for ordinal data: A demonstration using FACTOR. **Practical Assessment, Research & Evaluation**, v. 19, n. 5, p. n5, 2014. <https://doi.org/10.7275/dsep-4220>
- BROWN, T. **Confirmatory factor analysis for applied research**. Guilford publications, 2015.
- BROWNE, M.; CUDECK, R. Alternative ways of assessing model fit. **Sociological methods & research**, v. 21, n. 2, p. 230-258, 1992.
- BYRNE, B. **Structural equation modeling with Mplus: Basic concepts, applications, and programming**. Routledge, 2013.
- CHURCHILL, G. A paradigm for developing better measures of marketing constructs. **Journal of Marketing Research**, v. 16, n. 1, p. 64-73, 1979. <https://doi.org/10.1177/002224377901600110>
- COSTELLO, A.; OSBORNE, J. Best practices in exploratory factor analysis: Four recommendations for getting the most from your analysis. **Practical Assessment, Research & Evaluation**, v. 10, n. 1, 2005. <https://doi.org/10.7275/jyj1-4868>
- DANCEY, C.; REIDY, J. **Statistics without maths for psychology**. Pearson education, 2007.
- DISTEFANO, C.; MORGAN, G. A comparison of diagonal weighted least squares robust estimation techniques for ordinal data. **Structural Equation Modeling: a multidisciplinary journal**, v. 21, n. 3, p. 425-438, 2014. <https://doi.org/10.1080/10705511.2014.908286>
- EFRON, B.; TIBSHIRANI, R. **An introduction to the bootstrap**. 1993.
- FABRIGAR, L. et al. Evaluating the use of exploratory factor analysis in psychological research. **Psychological Methods**, v. 4, n. 3, p. 272, 1999. <https://doi.org/10.1037/1082-989X.4.3.272>
- FABRIGAR, L.; WEGENER, D. **Exploratory factor analysis**. Oxford University Press, 2012.
- FERRANDO, P.; LORENZO-SEVA, U. Program FACTOR at 10: Origins, development and future directions. **Psicothema**, v. 29, n. 2, p. 236-240, 2017. <https://doi.org/10.7334/psicothema2016.304>
- FERRANDO, P.; LORENZO-SEVA, U. Assessing the quality and appropriateness of factor solutions and factor score estimates in exploratory item factor analysis. **Educational and psychological measurement**, v. 78, n. 5, p. 762-780, 2018. <https://doi.org/10.1177/0013164417735351>
- FIELD, A.; FIELD, Z.; MILES, J. **Discovering statistics using R**. 2012.
- FLORA, D.; CURRAN, P. An empirical evaluation of alternative methods of estimation for confirmatory factor analysis with ordinal data. **Psychological Methods**, v. 9, n. 4, p. 466, 2004. <https://doi.org/10.1037/1082-989X.9.4.466>
- FLOYD, F.; WIDAMAN, K. Factor analysis in the development and refinement of clinical assessment

- instruments. **Psychological Assessment**, v. 7, n. 3, p. 286, 1995. <https://doi.org/10.1037/1040-3590.7.3.256>
- HOLM, M. et al. Psychometric evaluation of the anticipatory grief scale in a sample of family caregivers in the context of palliative care. **Health and Quality of Life Outcomes**, v. 17, p. 1-11, 2019.
- HAIR, J. et al. **Multivariate data analysis**. Uppersaddle River. 2006.
- HAIR, J. et al. **Análise multivariada de dados**. Bookman editora, 2009.
- HINKIN, T. A review of scale development practices in the study of organizations. **Journal of Management**, v. 21, n. 5, p. 967-988, 1995. <https://doi.org/10.1177/014920639502100509>
- HOELZLE, J.; MEYER, G. The invariant component structure of the Personality Assessment Inventory (PAI) full scales. **Journal of Personality Assessment**, v. 91, n. 2, p. 175-186, 2009.
- HOLGADO-TELLO, F. et al. Polychoric versus Pearson correlations in exploratory and confirmatory factor analysis of ordinal variables. **Quality & Quantity**, v. 44, p. 153-166, 2010. <https://doi.org/10.1007/s11135-008-9190-y>
- HORN, J. A rationale and test for the number of factors in factor analysis. **Psychometrika**, v. 30, n. 2, p. 179-185, 1965. <https://doi.org/10.1007/BF02289447>
- HU, L.; BENTLER, P. Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. **Structural Equation Modeling: a Multidisciplinary Journal**, v. 6, n. 1, p. 1-55, 1999. <https://doi.org/10.1080/10705519909540118>
- HUTCHESON, G.; SOFRONIOU, N. **The multivariate social scientist: Introductory statistics using generalized linear models**. 1999.
- JENNRICH, R.; SAMPSON, P. Rotation for simple loadings. **Psychometrika**, v. 31, n. 3, p. 313-323, 1966. <https://doi.org/10.1007/BF02289451>
- JÖRESKOG, K. A general approach to confirmatory maximum likelihood factor analysis. **Psychometrika**, v. 34, n. 2, p. 183-202, 1969.
- JÖRESKOG, K. A general method for estimating a linear structural equation system. **ETS Research Bulletin Series**, v. 1970, n. 2, p. i-41, 1970.
- JÖRESKOG, K.; SÖRBOM, D.; MAGIDSON, J. **Advances in factor analysis and structural equation models**, 1979.
- KAISER, H. A second generation little jiffy. **Psychometrika**, v. 35, n. 4, p. 401-415, 1970. <https://doi.org/10.1007/BF02291817>
- KLIN, Paul. Psychometrics and psychology: *The science of measurement and the meaning of mental constructs*. **Psychological Science**, 1979. <https://doi.org/10.1177/0956797615581221>
- LAWLEY, D.; MAXWELL, A. Factor analysis as a statistical method. **Journal of the Royal Statistical Society. Series D (The Statistician)**, v. 12, n. 3, p. 209-229, 1962.
- LEE, S. **Structural equation modeling: A Bayesian approach**. John Wiley & Sons, 2007.

LLORET-SEGURA, S. et al. El análisis factorial exploratorio de los ítems: una guía práctica, revisada y actualizada. **Anales de Psicología/Annals of Psychology**, v. 30, n. 3, p. 1151-1169, 2014. <https://doi.org/10.6018/analesps.30.3.199361>

LORENZO-SEVA, U.; VAN GINKEL, J. Imputación múltiple de valores perdidos en el análisis factorial exploratorio de escalas multidimensionales: Estimación de las puntuaciones de rasgos latentes. **Anales de Psicología**, v. 32, n. 2, p. 596-608, 2016. <https://doi.org/10.6018/analesps.32.2.209811>

LORENZO-SEVA, U.; TIMMERMAN, M.; KIERS, H. The Hull method for selecting the number of common factors. **Multivariate Behavioral Research**, v. 46, n. 2, p. 340-364, 2011. <https://doi.org/10.1080/00273171.2011.568924>

MALHOTRA, N. Marketing research: an applied prientation. pearson, 2020.

MARDIA, K. Measures of multivariate skewness and kurtosis with applications. **Biometrika**, v. 57, n. 3, p. 519-530, 1970. <https://doi.org/10.1093/biomet/57.3.519>

MEREDITH, W. Measurement invariance, factor analysis and factorial invariance. **Psychometrika**, v. 58, n. 4, p. 525-543, 1993. <https://doi.org/10.1007/BF02294825>

MUTHÉN, B.; ASPAROUHOV, Tihomir. Bayesian structural equation modeling: a more flexible representation of substantive theory. **Psychological Methods**, v. 17, n. 3, p. 313, 2012. <https://doi.org/10.1037/a0026802>

DO NASCIMENTO, E.; SILVA, R.; FONSECA, J. Aprimorando a aplicação da Análise Fatorial Exploratória: um exemplo didático com dados de comportamento do consumidor. **CONTRIBUCIONES A LAS CIENCIAS SOCIALES**, [S. l.], v. 17, n. 2, p. e5463, 2024. <https://doi.org/10.55905/revconv.17n.2-371>

PASQUALI, L. **TRI-Teoria de Resposta ao Item**: teoria, procedimentos e aplicações. Editora Appris, 2018.

PETT, M.; LACKEY, N.; SULLIVAN, J. **Making sense of factor analysis**: The use of factor analysis for instrument development in health care research. Sage, 2003.

ROGERS, P. Melhores práticas para sua análise fatorial exploratória: tutorial no factor. **Revista de Administração Contemporânea**, v. 26, p. e210085, 2022. <https://doi.org/10.1590/1982-7849rac2022210085.por>

SCHMITT, T.; SASS, D. Rotation criteria and hypothesis testing for exploratory factor analysis: Implications for factor pattern loadings and interfactor correlations. **Educational and Psychological Measurement**, v. 71, n. 1, p. 95-113, 2011. <https://doi.org/10.1037/a0022962>

SOUZA, J.; SOUZA, L.; LUIZ, E. Análise fatorial exploratória na avaliação das políticas educacionais em curso de pós-graduação. **E&S Engineering and Science**, v. 13, n. 1, p. 1-17, 2024. <https://doi.org/10.18607/ES20241315419>

SPEARMAN, C. **The proof and measurement of association between two things**. 1961. <https://doi.org/10.2307/1412159>

TABACHNICK, B. Using multivariate statistics. **Alyn and Bacon**, 2007.

THURSTONE, L. **Multiple-factor analysis**. University of Chicago Press, 1947.

TIMMERMAN, M.; LORENZO-SEVA, U. Dimensionality assessment of ordered polytomous items with parallel analysis. **Psychological Methods**, v. 16, n. 2, p. 209, 2011. <https://doi.org/10.1037/a0023357>

TRIZANO-HERMOSILLA, I.; ALVARADO, J. Best alternatives to Cronbach's alpha reliability in realistic conditions: congeneric and asymmetrical measurements. **Frontiers in Psychology**, v. 7, p. 769, 2016. <https://doi.org/10.3389/fpsyg.2016.00769>

VANDENBERG, R.; LANCE, C. A review and synthesis of the measurement invariance literature: Suggestions, practices, and recommendations for organizational research. **Organizational Research Methods**, v. 3, n. 1, p. 4-70, 2000. <https://doi.org/10.1177/109442810031002>

VELICER, W. Determining the number of components from the matrix of partial correlations. **Psychometrika**, v. 41, n. 3, p. 321-327, 1976. <https://doi.org/10.1007/BF02293557>

VENTURA-LEÓN, J.; PEÑA-CALERO, B. The world should not revolve around Cronbach's alpha. **Adicciones**, v. 33, n. 4, p. 369-372, 2021. <https://doi.org/10.3389/fpsyg.2020.00769>

YI, Y.; GONG, T. Customer value co-creation behavior: Scale development and validation. **Journal of Business Research**, v. 66, n. 9, p. 1279-1284, 2013. <https://doi.org/10.1016/j.jbusres.2012.07.002> disciplina de bacharelado em hotelaria. Tur., Visão e Ação, v22, n2, p277-296, Mai./Jun. 2020.