

Modelagem de Equações Estruturais com GSCA Pro: Tutorial para Pesquisadores de Administração

Structural Equation Modeling with GSCA Pro:
A Tutorial for Management Researchers

AIMÃN IBRAHIM MOURAD

FEI

aimourad@fei.edu.br

RESUMO

Este artigo apresenta um tutorial prático e didático sobre o uso do GSCA Pro, um software gratuito de modelagem de equações estruturais baseado em componentes. O objetivo é preencher uma lacuna metodológica na literatura brasileira, oferecendo um recurso acessível e sistemático que permita ampliar o uso do GSCA entre pesquisadores da área de Administração. Considerando a predominância do PLS-SEM no contexto brasileiro, o objetivo é apresentar o GSCA como uma alternativa metodológica igualmente rigorosa, porém ainda pouco explorada. O tutorial guia o leitor por todas as etapas da análise no GSCA Pro, desde a preparação dos dados até a interpretação dos resultados, utilizando dados simulados e um modelo teórico inspirado na literatura sobre intenção de compra. Procedimentos como definição do modelo, execução da análise, interpretação das métricas-chave e verificação dos critérios de qualidade são detalhados em um checklist final com as etapas fundamentais. Ao disponibilizar material gratuito e sistematizado em português, este artigo expande o repertório metodológico de docentes, discentes e pesquisadores, fomentando a adoção de práticas mais diversas e robustas em modelagem de equações estruturais.

Palavras-chave: Modelagem de Equações Estruturais; GSCA Pro; GSCA; Método Baseado em Componentes; Análise Quantitativa.

ABSTRACT

This article presents a practical and educational tutorial on the use of GSCA Pro, a free component-based structural equation modeling software. The objective is to fill a methodological gap in the Brazilian literature by offering an accessible and systematic resource that allows for expanded use of GSCA among researchers in the field of Administration. Considering the predominance of PLS-SEM in the Brazilian context, the objective is to present GSCA as an equally rigorous, yet still underexplored, methodological alternative. The tutorial guides the reader through all the stages of analysis in GSCA Pro, from data preparation to result interpretation, using simulated data and a theoretical model inspired by the literature on purchase intention. Procedures such as model definition, analysis execution, interpretation of key metrics, and verification of quality criteria are detailed in a final checklist with the fundamental steps. By providing free and systematized material in Portuguese, this article expands the methodological repertoire of faculty, students, and researchers, encouraging the adoption of more diverse and robust practices in structural equation modeling.

Keywords: Structural Equation Modeling; GSCA Pro; GSCA; Component-Based Method; Quantitative Analysis.

1. INTRODUÇÃO

A Modelagem de Equações Estruturais (*Structural Equation Modeling* – SEM) é amplamente adotada em pesquisas de Administração e áreas afins, especialmente em estudos que investigam relações entre múltiplos construtos e suas variáveis observáveis. Combinando a avaliação da qualidade das medidas e das associações estruturais em um único procedimento estatístico, a SEM se consolidou como ferramenta essencial para testar modelos teóricos complexos em pesquisas quantitativas (Hair *et al.*, 2011; Ringle, *et al.*, 2014; Sarstedt *et al.*, 2022; Hwang *et al.*, 2024).

Embora abordagens tradicionais de SEM – como modelagem baseada em covariância (CB-SEM) e modelagem por mínimos quadrados parciais (PLS-SEM) – sejam amplamente documentadas em manuais e tutoriais em português (Hair *et al.*, 2014; Malhotra *et al.*, 2014; Ringle *et al.*, 2014), observa-se uma lacuna na escassez de materiais didáticos e práticos sobre o *Generalized Structured Component Analysis* (GSCA), especialmente adaptados à realidade brasileira. Essa carência de tutoriais práticos em português dificulta a utilização e o aprimoramento da técnica por pesquisadores e estudantes de pós-graduação, restringindo a disseminação de um método com vantagens específicas para determinados modelos.

Nesse contexto, é apresentado um tutorial educativo e prático sobre o uso do GSCA Pro, *software* gratuito desenvolvido para operacionalizar o GSCA. O tutorial abrange da preparação do banco de dados até a interpretação dos resultados, oferecendo material atualizado e acessível em português. Por meio deste tutorial, pretende-se ampliar o conhecimento sobre o GSCA Pro e incentivar sua adoção no Brasil, apresentando-o como uma alternativa metodológica relevante para a pesquisa científica nacional.

2. CB-SEM, PLS-SEM E GSCA: ABORDAGENS COMPLEMENTARES PARA MODELAGEM DE EQUAÇÕES ESTRUTURAIS

A Modelagem de Equações Estruturais (SEM) consolidou-se como uma das principais técnicas em ciências sociais aplicadas, incluindo Administração, devido à sua capacidade de testar simultaneamente relações entre múltiplos construtos latentes, integrando análise confirmatória baseada em componentes e análise de regressão em um único procedimento (Hair *et al.*, 2011). Isso torna a SEM especialmente relevante em pesquisas com fenômenos multidimensionais e teoricamente complexos.

As abordagens tradicionais incluem a modelagem baseada em covariância (CB-SEM) e a modelagem por mínimos quadrados parciais (PLS-SEM). A CB-SEM visa

reproduzir a matriz de covariância, assumindo que a estrutura teórica especificada representa adequadamente a realidade empírica (Hair *et al.*, 2011). Essa abordagem é recomendada para testes confirmatórios de modelos consolidados. Ela está presente em *softwares* como AMOS, LISREL e Mplus. Entretanto, requer pressupostos estatísticos rigorosos, como normalidade multivariada, ausência de multicolinearidade grave e amostras robustas – condições nem sempre atendidas na pesquisa aplicada em Administração (Hair *et al.*, 2011).

O PLS-SEM é uma alternativa mais flexível que maximiza a variância explicada em construtos endógenos (Ringle *et al.*, 2014). É fundamental no desenvolvimento de modelos, análises exploratórias ou estudos com amostras pequenas e dados não normais (Sarstedt *et al.*, 2022). No Brasil, a popularização da SEM foi impulsionada por materiais didáticos em português (Hair *et al.*, 2014; Malhotra *et al.*, 2014; Ringle *et al.*, 2014).

Apesar do cenário consolidado para CB-SEM e PLS-SEM, uma abordagem promissora segue pouco explorada no Brasil: a *Generalized Structured Component Analysis* (GSCA-SEM), que inclui GSCA, GSCAm e IGSCA. A GSCA, assim como o PLS-SEM, é baseada em componentes; a GSCAm utiliza fatores, e a IGSCA permite modelagem híbrida com ambos no mesmo modelo. Essa flexibilidade torna o GSCA-SEM útil para lidar com construtos reflexivos (indicadores refletem um traço latente) e formativos (indicadores compõem o construto) (Hwang *et al.*, 2024). Diferente do PLS-SEM que prioriza a variância explicada, o GSCA também considera o ajuste global à matriz observada, adotando uma abordagem sistêmica próxima ao CB-SEM (Hwang *et al.*, 2024). Essa capacidade de capturar ajustes locais e globais é especialmente relevante em pesquisas em Administração, onde modelos combinam dimensões comportamentais e operacionais. O GSCA também acomoda modelos mais complexos com cargas cruzadas e relações bidirecionais. O PLS-SEM pode ser visto como um caso particular do GSCA (Hwang & Cho, 2020).

A literatura recente reforça a importância de avaliar a qualidade de modelos de mensuração baseados em componentes. Hair *et al.* (2020) propuseram a Análise Composicional Confirmatória (CCA), que verifica a consistência interna e a validade convergente e discriminante nesses modelos. Embora tenha sido proposta para o PLS-SEM, a lógica da CCA também se aplica à GSCA. Com o lançamento do GSCA Pro, sua aplicação se tornou mais acessível (Hwang *et al.*, 2024). O GSCA Pro também incorpora GSCAm para fatores comuns e IGSCA para modelagem híbrida (Hwang *et al.*, 2023).

Utilizamos a GSCA como a principal abordagem neste tutorial, visto que sua lógica de estimação está mais alinhada com o PLS-SEM baseado em componentes

(Hwang *et al.*, 2024). Assim, o GSCA Pro, em sua configuração padrão, oferece um caminho metodologicamente consistente para a aplicação da modelagem de mínimos quadrados parciais em ciências sociais aplicadas.

3. TUTORIAL PARA A MODELAGEM DE EQUAÇÕES ESTRUTURAIS UTILIZANDO A GSCA

Esta seção apresenta um tutorial sobre o uso do GSCA Pro, um software gratuito desenvolvido para operacionalizar, entre outros modelos, a PLS-SEM. O objetivo é guiar o pesquisador desde a instalação do programa até a interpretação dos resultados. São abordados os principais requisitos de dados, a construção do modelo teórico, as configurações recomendadas para pesquisa em Administração e as métricas para avaliação dos modelos. O foco é na aplicabilidade, facilitando a compreensão do processo mesmo por pesquisadores com pouca familiaridade com a lógica GSCA ou PLS-SEM. A base de dados utilizada como exemplo é a de Mourad e Quevedo (2023), na qual o PLS-SEM foi aplicado para verificar a relação entre os construtos “Percepção do Canal Físico”, “Risco Online Percebido”, “Atitude de *Webrooming*”, “Intenção de *Webrooming*” e “Comportamento de *Webrooming*”.

Passo 1 – Instalação e preparação dos dados

Para baixar o GSCA Pro, os usuários devem acessar o site oficial (www.gscapro.com) e clicar na opção “**Download GSCA Pro for Windows or Mac**” na parte inferior da página inicial. Isso os direcionará para uma nova página com informações sobre a versão mais recente do *software*, onde poderão selecionar a opção compatível com o sistema operacional do dispositivo utilizado.

Para instalar no Windows, após o download do arquivo compactado (.zip), é necessário descompactar o arquivo “**GSCA Pro 1.2.1.0.zip**” utilizando a funcionalidade padrão do sistema, clicando com o botão direito do mouse e escolhendo “**Extrair tudo**”, definindo o destino onde os arquivos serão salvos. Em seguida, localize o executável “**GSCA Pro Windows 1.2.exe**” na pasta extraída e clique duas vezes para iniciar o programa. É importante ressaltar que os arquivos não devem ser removidos ou extraídos da pasta criada, pois o GSCA Pro é executado diretamente de lá, utilizando essa estrutura como referência para seu funcionamento.

Também é importante observar que, ao abrir o GSCA Pro no Windows 10, pode aparecer uma mensagem de segurança com o aviso “**O Windows protegeu seu PC**”. Nesse caso, o usuário não deve clicar em “**Não executar**”, mas sim selecionar “**Mais informações**”, o que fará com que uma nova janela apareça, onde será possível clicar em “**Executar mesmo assim**” para

permitir que o software inicie corretamente. Além disso, é necessário ficar atento aos programas antivírus instalados, pois alguns podem bloquear a execução ou impedir o funcionamento correto do programa. Caso isso ocorra, é recomendável adicionar o GSCA Pro à lista de exceções do antivírus. Essas etapas garantem que o software funcione corretamente, mesmo com restrições impostas pelos mecanismos de segurança do Windows ou ferramentas antivírus.

A instalação em computadores com macOS requer atenção a procedimentos específicos devido às configurações de segurança. Após baixar o arquivo “**GSCA Pro Mac 1.2.1.1.zip**”, é necessário descompactá-lo usando a funcionalidade padrão do macOS, o que criará o arquivo “**GSCA Pro Mac.dmg**”. Em seguida, deve abrir o arquivo .dmg e localizar o aplicativo “**GSCAPRO**”. Para iniciar o aplicativo, clique com o botão direito do mouse no ícone do programa e selecione “**Abrir**”. Uma mensagem será exibida informando que “**GSCAPRO não pode ser aberto porque o desenvolvedor não pode ser verificado**”; neste caso, selecione “**Cancelar**”. O procedimento deve ser repetido e desta vez, uma nova mensagem informará que “**o macOS não pode verificar o desenvolvedor do aplicativo**” e será possível clicar em “**Abrir**”, permitindo que o programa seja executado. Esse processo ignora as restrições de segurança do macOS aplicadas a softwares de desenvolvedores não identificados, garantindo que o GSCA Pro inicialize corretamente e esteja pronto para uso.

O sistema operacional utilizado neste tutorial foi o Windows, e a versão do GSCA Pro adotada foi a 1.2.1.0, a mais recente disponível na escrita deste tutorial. Como mencionado, o GSCA Pro permite diferentes abordagens analíticas (GSCA, GSCAm e IGSCA), cada uma adequada a modelos e especificações distintas. No entanto, reafirmando o escopo deste tutorial, o foco será exclusivamente na análise GSCA, definida como padrão inicial na instalação do *software*. A opção “**Analysis**”, no canto superior esquerdo da interface do programa (Figura 1a), permite alterar a abordagem de acordo com o modelo.

Para executar análises no GSCA Pro, é necessário preparar um arquivo de dados com informações em nível individual, ou seja, uma linha por respondente. O software aceita arquivos .txt, .csv ou .xlsx e a primeira linha deve conter os nomes dos indicadores, separados por espaços, tabulações, vírgulas, ponto e vírgula ou, no caso do Excel, por colunas. Caso o arquivo não contenha esses nomes, o GSCA Pro atribuirá nomes genéricos como V1, V2... Vn, conforme ordem das colunas. Os dados devem iniciar na segunda linha, com valores numéricos e sem células em branco. Valores ausentes podem ser representados por um número específico (por padrão, -9999), desde que consistente em todo o banco de dados.

Para criar um modelo PLS-SEM, após a instalação, clique em **“New Project”** (Figura 1b), insira um nome para o projeto em **“Name of Project”**, carregue um arquivo com o banco de dados em formato .txt, .csv ou .xlsx em **“Raw Data File”** e escolha um diretório para salvar o projeto criado (Figura 1c). A configuração padrão dos projetos é que os nomes dos indicadores estejam na primeira linha do banco de dados. Se este for o caso,

não é necessário alterar nada, mas se este não for o caso do banco de dados utilizado, é necessário alterar, em **“Additional option”**, a configuração **“Are there variables names on the first row?”** para **“No”** (Figura 1d). Clique em **“OK”** (Figura 1e) e, após a criação do projeto, é possível verificar os dados enviados clicando em **“Data”** (Figura 1f)

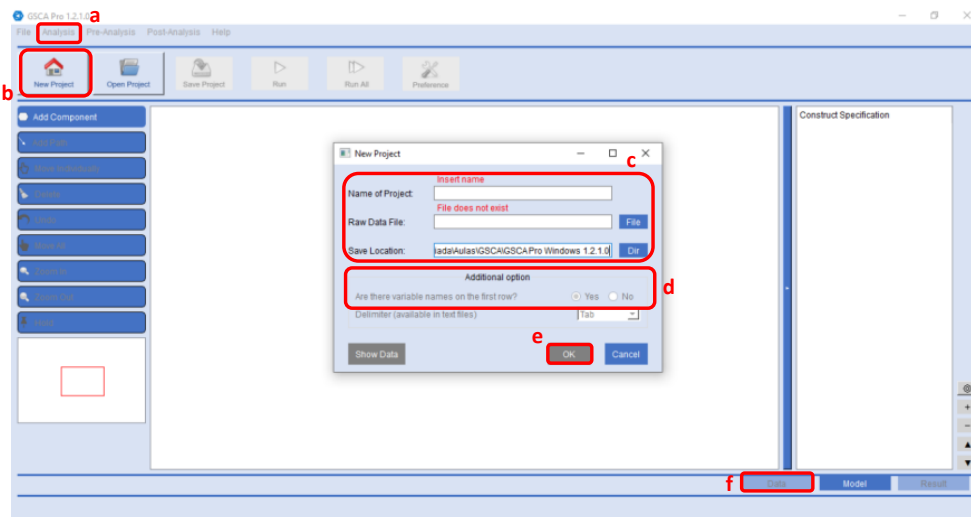


Figura 1 - Interface do GSCA Pro

Fonte: Captura de tela do GSCA Pro, elaborada pelo autor.

Na aba de verificação de dados, localizada no lado esquerdo da interface (Figura 2a), há opções para ajustar a exibição das células, permitindo aumentar ou diminuir o tamanho delas com os botões **“Zoom In”** e **“Zoom Out”**, além de verificar se há valores ausentes clicando em **“Check Missing Values”**. Ao selecionar essa opção, será exibido um menu com informações como total de observações, total incluindo valores

ausentes, total sem valores ausentes, número de valores ausentes e a configuração definida para representá-los, que, como mencionado no GSCA Pro, é -999 (Figura 2b). Também é possível visualizar o nome do projeto, o tipo de análise utilizado, que por padrão é a GSCA, e o tipo de grupo especificado, que também é, por padrão, um único grupo (Figura 2c).




Figura 2 - Verificação dos dados e valores ausentes

Fonte: Captura de tela do GSCA Pro, elaborada pelo autor.

Embora o GSCA Pro calcule estatísticas descritivas do banco de dados, essas análises não serão abordadas neste tutorial. Após retornar à aba **“Model”**, ao lado de **“Data”** (Figura 1f), o painel de ferramentas à esquerda será ativado, e é lá que o modelo deve ser especificado para realizar as análises (Figura 3a).

A especificação da Modelagem de Equações Estruturais começa com a criação de componentes, ou variáveis latentes, por meio da opção **“Add Component”**. Selecionar o botão e clicar uma vez no espaço em branco criará um componente no local indicado. Enquanto o botão estiver ativo, cada novo clique gerará um novo componente; três cliques criarão três componentes, por exemplo. No modelo deste tutorial, foram criados

cinco componentes, nomeados por padrão de **“new1”** a **“new5”** (Figura 3b).

Clique duas vezes no componente, representado por um hexágono, para atribuir indicadores aos componentes e abrir a janela **“Assign Indicators to Constructs”** (Figura 3c). Nesta janela, pode-se renomear o componente, selecionar os indicadores disponíveis à esquerda, movê-los para a direita e vinculá-los ao componente desejado. Também pode-se indicar se o componente é canônico, ou seja, formativo, o que não se aplica neste exemplo. Após esta etapa, clique em **“OK”** para confirmar e repita o processo para todos os componentes do modelo.




Figura 3 - Construção dos componentes

Fonte: Captura de tela do GSCA Pro, elaborada pelo autor.

Para criar as relações a partir das quais os coeficientes de caminho serão calculados, selecione a opção **“Add Path”** no painel de ferramentas à esquerda da tela, clique no componente que atuará como variável independente e arraste-o para o centro do componente que representará a variável dependente. Este procedimento deve ser repetido para todas as relações até que o modelo estrutural esteja completo (Figura 4a).

Uma miniatura do modelo é exibida no canto inferior esquerdo do painel (Figura 4b), enquanto as especificações de cada construto aparecem à direita da tela (Figura 4c). Após a conclusão do modelo, clique em **“Preference”** (Figura 4d) para alterar o número de amostras usadas no cálculo *bootstrap*.




Figura 4 - Especificação das relações

Fonte: Captura de tela do GSCA Pro, elaborada pelo autor.

Após alterar o valor no campo “Number of Bootstrap Samples” (Figura 5a), clique em “Apply” (Figura 5b) e, em seguida, em “Run” (Figura 5c) para que o GSCA Pro execute o modelo com as configurações desejadas. Neste tutorial, utilizamos 2.000 amostras *bootstrap*, conforme recomendado por Cho *et al.* (2019) para muitas reamostragens. Seguindo

o exemplo de Mourad e Quevedo (2023), os mesmos indicadores mencionados no artigo original foram excluídos: PF1, PF2, PF3, PF5, PF6, PF11, PF12, PF13, PF14, PF15, RP2, RP3 e RP6.

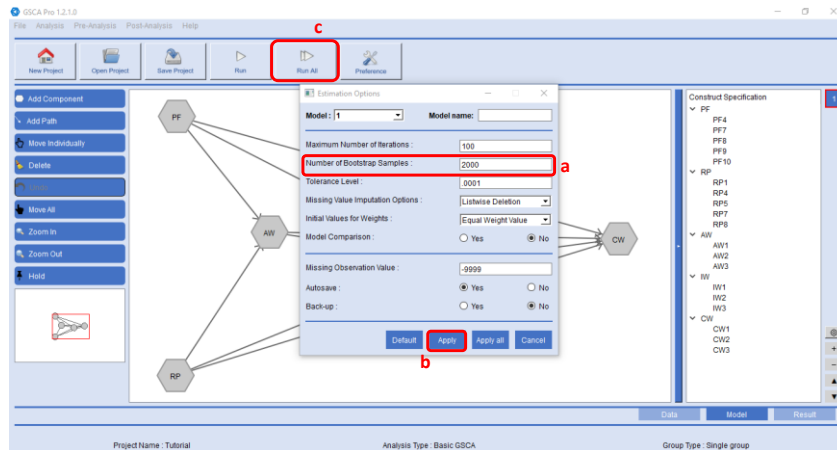


Figura 5 - Configuração de *bootstrap* e execução da análise

Fonte: Captura de tela do GSCA Pro, elaborada pelo autor.

Ao final da execução do programa, os resultados da análise básica são exibidos na aba “Result” (Figura

6a). Para facilitar a visualização, é possível clicar em “View Full Result” (Figura 6b).

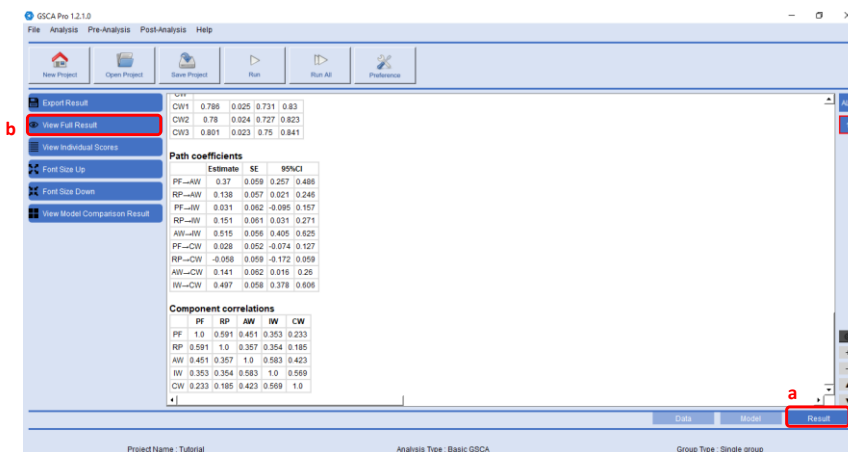


Figura 6 - Visualização dos resultados

Fonte: Captura de tela do GSCA Pro, elaborada pelo autor.

Passo 2 – Ajuste geral do modelo

No início desta aba, são exibidas informações gerais sobre a execução da análise, incluindo o número do modelo, o tipo de análise selecionado, que neste caso

é GSCA básico com um único grupo, a data e a hora da execução, o número de amostras usadas no procedimento de *bootstrap* e os tempos de processamento da amostra original, as amostras de *bootstrap* e o tempo total de execução, conforme mostrado na Figura 7.

```

=====
Model Number : 1

Analysis Type : Basic GSCA / Single group
Execution Date : Sun Apr 13 20:03:28 2025
Number of bootstrap samples : 2000

The ALS algorithm converged in 5 iterations (Convergence criterion = 0.0001)

Elapsed time for original sample: 0 minute(s) 0.01 second(s)
Average elapsed time per bootstrap sample: 0 minute(s) 0.00 second(s)
Total elapsed time: 0 minute(s) 5.06 second(s)
=====
    
```

Figura 7 - Informações gerais da análise.

Fonte: Análise no GSCA Pro, com dados simulados pelo autor.

Os critérios e valores de referência para a interpretação das medidas podem ser encontrados em Hwang *et al.* (2024). No entanto, como este tutorial não discute as métricas estatísticas em profundidade, mas fornece um guia prático para a execução da GSCA, os valores serão apenas apresentados, sem maiores interpretações. As medidas de ajuste do modelo são ilustradas na Figura 8 e apresentadas em “**Model Fit Measures**”. A **FIT** indica a variância total que o modelo explica, entre 0 e 1; **quanto maior, melhor**, e é comparável ao R² da regressão linear. A **AFIT** ajusta esse valor com base na complexidade estrutural e é usada apenas para comparar modelos concorrentes (Hwang *et al.*, 2024), assim como o R² ajustado na regressão. **FITs** e **FITm** representam, respectivamente, a variância explicada pelos componentes no modelo estrutural e

pelos indicadores no modelo de mensuração, também variando de 0 a 1.

Os índices **GFI** e **SRMR** avaliam a proximidade das covariâncias estimadas das observadas. Para amostras com até 100 casos, **GFI ≥ 0,89** e **SRMR ≤ 0,09** são considerados bons; **SRMR ≤ 0,09** pode compensar GFI mais baixo, com **GFI ≥ 0,85** ainda aceitável (Cho & Choi, 2020). Os valores recomendados para amostras acima de 100 casos são **GFI ≥ 0,93** ou **SRMR ≤ 0,08** (Cho & Choi, 2020). Os índices de **OPE**, **OPEs** e **OPEm** indicam o poder preditivo do modelo para dados fora da amostra e ajudam a comparar especificações (Cho *et al.*, 2019). Quando a análise é do tipo GSCA, o *software* apresenta um conjunto de métricas específicas para esse tipo de estrutura sem exigir testes de validade interna ou discriminante (Hwang *et al.*, 2024).

Model fit measures

FIT	AFIT	FITs	FITm	GFI	SRMR	OPE	OPEs	OPEm
0.51	0.506	0.184	0.595	0.969	0.065	0.495	0.829	0.407

Figura 8 - Medidas de ajuste do modelo

Fonte: Análise no GSCA Pro, com dados simulados pelo autor.

O OPE pode ser utilizado para comparar o desempenho preditivo de diferentes modelos em dados não observados, sendo mais preditivo aquele com menor valor de OPE. Para um único modelo, **OPE < 1** indica maior precisão preditiva em relação ao modelo nulo. De modo semelhante, o OPEm avalia o desempenho preditivo do modelo de mensuração, e valores de **OPEm < 1** sugerem menor erro de predição fora da amostra quando comparado ao modelo nulo. No modelo estrutural, o mesmo princípio se aplica ao índice **OPEs < 1**, que deve ser interpretado apenas de forma comparativa, e não como critério absoluto de ajuste (Cho *et al.*, 2019).

poder preditivo pode não ser informativo do ponto de vista prático.

Passo 3 – Avaliação do modelo de mensuração

A significância estatística dos pesos dos componentes, identificados como “**Weights**”, é avaliada por intervalos de confiança de 95%. Se o intervalo não incluir zero, o peso é considerado significativo, e quanto maior seu valor absoluto, maior a relevância do indicador na formação do componente (Hwang & Takane, 2014; Hwang *et al.*, 2023). O mesmo raciocínio se aplica às cargas dos componentes, identificadas como “**Loadings**” no GSCA Pro. Intervalos que não incluem zero indicam significância, e cargas de valor absoluto mais altas sugerem uma maior correlação com o componente correspondente (Hwang & Takane, 2014; Hwang *et al.*, 2023). Os pesos e valores de carga do exemplo utilizado neste tutorial são ilustrados na Figura 9.

Sem modelos concorrentes, como o AFIT, os índices de OPE, OPEm e OPEs têm utilidade limitada, visto que seu papel é comparativo. Nesses casos, simplesmente afirmar que o modelo supera o modelo nulo em

Weights					Loadings				
	Estimate	SE	95%CI			Estimate	SE	95%CI	
PF					PF				
PF4	0.287	0.014	0.26	0.316	PF4	0.805	0.023	0.757	0.846
PF7	0.287	0.015	0.259	0.319	PF7	0.805	0.027	0.748	0.856
PF8	0.29	0.014	0.263	0.319	PF8	0.826	0.022	0.778	0.884
PF9	0.279	0.014	0.251	0.306	PF9	0.806	0.022	0.759	0.848
PF10	0.154	0.021	0.107	0.191	PF10	0.477	0.055	0.355	0.572
RP					RP				
RP1	0.242	0.014	0.214	0.27	RP1	0.64	0.039	0.557	0.708
RP4	0.276	0.013	0.253	0.302	RP4	0.755	0.026	0.699	0.8
RP5	0.285	0.012	0.262	0.31	RP5	0.741	0.027	0.68	0.788
RP7	0.299	0.012	0.277	0.325	RP7	0.802	0.02	0.76	0.839
RP8	0.265	0.014	0.239	0.292	RP8	0.698	0.034	0.623	0.758
AW					AW				
AW1	0.312	0.022	0.27	0.357	AW1	0.853	0.017	0.816	0.883
AW2	0.353	0.024	0.304	0.397	AW2	0.854	0.023	0.803	0.891
AW3	0.466	0.019	0.451	0.523	AW3	0.891	0.015	0.88	0.918
IW					IW				
IW1	0.537	0.028	0.486	0.595	IW1	0.826	0.021	0.783	0.884
IW2	0.379	0.028	0.324	0.432	IW2	0.715	0.037	0.633	0.776
IW3	0.412	0.028	0.354	0.466	IW3	0.693	0.04	0.603	0.762
CW					CW				
CW1	0.41	0.02	0.37	0.45	CW1	0.786	0.025	0.731	0.83
CW2	0.395	0.021	0.355	0.438	CW2	0.78	0.024	0.727	0.823
CW3	0.461	0.023	0.418	0.507	CW3	0.801	0.023	0.75	0.841

Figura 9 - Pesos e cargas dos componentes

Fonte: Análise no GSCA Pro, com dados simulados pelo autor.

A qualidade dos construtos é avaliada na planilha “**Construct quality measures**”, onde dois critérios podem verificar a unidimensionalidade de cada bloco de indicadores. O primeiro é o critério de Kaiser, que considera unidimensionalidade quando apenas o primeiro autovalor é maior que 1, valor apresentado no GSCA como “**Dimensionality**” e deve ser = 1 (Kaiser, 1960). O segundo critério é a proporção da variância explicada (PVE), que indica, em média, quanto da variância total dos indicadores é explicada pelo componente correspondente. Valores de **PVE ≥ 0,70** podem indicar unidimensionalidade (Jolliffe & Cadima, 2016). No exemplo deste tutorial, embora quatro dos cinco blocos tenham apresentado PVE abaixo de 0,70, todos foram mantidos para permitir a comparação com os resultados de Mourad e Quevedo (2023).

Além da unidimensionalidade, o GSCA Pro apresenta valores de Alfa e Rho para análise de consistência interna. Alfa corresponde ao alfa de Cronbach, uma métrica tradicional baseada na suposição de tau-equivalência entre indicadores, não assumida em GSCA ou PLS-SEM (Benitez *et al.*, 2020). Rho representa a confiabilidade composta, mas deve ser calculada com cargas fatoriais, não com cargas componentes. Portanto, seu uso é inadequado em GSCA ou PLS-SEM, sendo mais adequado para modelos com fatores latentes, como em GSCAm ou IGSCA (Hwang *et al.*, 2024), que não é o foco deste tutorial. Todos esses valores são apresentados na Figura 10.

Construct quality measures

	PF	RP	AW	IW	CW
PVE	0.571	0.532	0.75	0.558	0.623
Alpha	0.804	0.778	0.838	0.606	0.698
Rho	0.866	0.85	0.9	0.79	0.832
Dimensionality	1.0	1.0	1.0	1.0	1.0

Figura 10 - Medidas de qualidade dos construtos

Fonte: Análise no GSCA Pro, com dados simulados pelo autor.

Embora o GSCA Pro apresente métricas como HTMT e o critério de Fornell-Larcker, essas abordagens são inadequadas para modelos baseados exclusivamente em componentes. O HTMT pressupõe paralelismo entre blocos de indicadores (Rönkkö & Cho, 2020), o que não é assumido no GSCA. A AVE e o critério de Fornell-Larcker, propostos por Fornell e Larcker (1981), são calculados com base em cargas fatoriais e não se aplicam ao GSCA (Benitez *et al.*, 2020). Essas métricas

são recomendadas apenas em modelos com GSCAm ou IGSCA (Hwang *et al.*, 2024).

A Figura 11 apresenta a proporção da variância de cada indicador explicada pelo componente ao qual está associado. Esses valores de R² são calculados individualmente com base na carga do indicador no componente.

R squared values of indicators in measurement model

PF4	PF7	PF8	PF9	PF10	RP1	RP4	RP5	RP7	RP8	AW1	AW2	AW3	IW1	IW2	IW3	CW1	CW2	CW3
0.648	0.648	0.683	0.65	0.228	0.41	0.569	0.548	0.644	0.488	0.728	0.729	0.794	0.682	0.512	0.48	0.618	0.609	0.642

Figura 11 - R² dos indicadores

Fonte: Análise no GSCA Pro, com dados simulados pelo autor.

Passo 4 – Avaliação do modelo estrutural

No modelo estrutural com componentes, a colinearidade entre os preditores é avaliada pelos valores de VIF. Valores de **VIF ≤ 3** são ideais; entre 3 e 5 indicam colinearidade potencial; e VIF ≥ 5, colinearidade crítica (Hair *et al.*, 2011; Hair *et al.*, 2019; Hwang *et al.*, 2023).

O GSCA Pro fornece esses valores para todos os componentes independentes e covariáveis associadas a cada componente dependente. Quando o modelo de mensuração inclui um componente canônico, o *software* calcula o VIF dos respectivos indicadores (Hwang *et al.*, 2024). Esses resultados são apresentados na Figura 12.

VIF (Structural model)

	PF	RP	AW	IW	CW
PF	0	0	1.537	1.711	1.712
RP	0	0	1.537	1.561	1.597
AW	0	0	0	1.276	1.694
IW	0	0	0	0	1.575
CW	0	0	0	0	0

Figura 12 - VIF

Fonte: Análise no GSCA Pro, com dados simulados pelo autor.

Os coeficientes de caminho, indicados na Figura 13 e identificados na saída do GSCA como “**Path coefficients**” também são considerados significativos quando seus

intervalos de confiança de 95% não incluem zero, ou seja, quando não mudam de sinal, e quanto maior o valor estimado, maior o efeito.

Path coefficients

	Estimate	SE	95%CI	
PF→AW	0.37	0.059	0.257	0.486
RP→AW	0.138	0.057	0.021	0.246
PF→IW	0.031	0.062	-0.095	0.157
RP→IW	0.151	0.061	0.031	0.271
AW→IW	0.515	0.056	0.405	0.625
PF→CW	0.028	0.052	-0.074	0.127
RP→CW	-0.058	0.059	-0.172	0.059
AW→CW	0.141	0.062	0.016	0.26
IW→CW	0.497	0.058	0.378	0.606

Figura 13 - Coeficientes de caminho

Fonte: Análise no GSCA Pro, com dados simulados pelo autor.

O tamanho do efeito é analisado com base no f^2 , com valores de **0,02**, **0,15** e **0,35** indicando efeitos **pequeno**, **médio** e **grande**, respectivamente

(Cohen, 1988; Hwang *et al.*, 2023) e podem ser encontrados no GSCA como “**F squared values**”, conforme Figura 14.

F squared values

	PF	RP	AW	IW	CW
PF			0.158	0.001	0.001
RP			0.02	0.023	0.003
AW				0.361	0.02
IW					0.327
CW					

Figura 14 - Tamanho do efeito

Fonte: Análise no GSCA Pro, com dados simulados pelo autor.

No modelo estrutural, o R^2 de cada componente indica o quanto de sua variância é explicado pelos componentes que o precedem. Os valores de R^2 , identificados como “**R squared values of components in structural model**” (Figura 15), devem ser interpretados de

acordo com o contexto teórico da pesquisa. No entanto, em construtos que medem percepções, atitudes ou intenções, R^2 igual ou superior a 0,90 pode indicar sobreajuste (Sharma *et al.*, 2019; Hwang *et al.*, 2023).

R squared values of components in structural model

PF	RP	AW	IW	CW
		0.216	0.365	0.338

Figura 15 - R^2

Fonte: Análise no GSCA Pro, com dados simulados pelo autor.

Os resultados obtidos neste tutorial, tanto nos coeficientes de caminho e suas significâncias quanto nos valores de R^2 , são compatíveis com os encontrados por Mourad e Quevedo (2023), confirmando seis das nove relações testadas. Embora a comparação entre GSCA e PLS-SEM, ou entre os *softwares* utilizados, não seja o foco deste tutorial, um exemplo previamente validado foi escolhido para oferecer um ponto de referência e demonstrar que o GSCA pode ser uma alternativa gratuita, acessível e intuitiva para pesquisadores e estudantes interessados em aplicar a Modelagem de Equações Estruturais em suas pesquisas.

Fase 5 – Informações complementares e exportação de resultados

Ao final da análise, o GSCA Pro apresenta tabelas que, embora não constituam um critério formal de avaliação do modelo, podem ser utilizadas nas análises. As tabelas com médias e variâncias dos componentes não padronizados são calculadas nas mesmas escalas dos indicadores originais (Figura 16). Essas informações são úteis para fins exploratórios e para a interpretação substantiva dos componentes, especialmente quando se busca compreender o comportamento médio e a dispersão dos valores construídos com base em dados empíricos.

Unstandardized component means

PF	RP	AW	IW	CW
3.779	3.051	3.863	3.29	3.033

Unstandardized component variances

PF	RP	AW	IW	CW
0.938	0.812	1.041	0.968	1.343

Figura 16 - Médias e variâncias componentes não padronizados

Fonte: Análise no GSCA Pro, com dados simulados pelo autor.

O GSCA Pro também apresenta uma matriz com as correlações entre todos os indicadores localizados na diagonal inferior e as diferenças entre as correlações observadas e aquelas reproduzidas pelo modelo na diagonal superior (Figura 17). Essa matriz pode ser usada para inspecionar a qualidade do ajuste local entre as variáveis.

Sample correlations (lower diagonal) & Residual correlations (upper diagonal)

	PF4	PF7	PF8	PF9	PF10	RP1	RP4	RP5	RP7	RP8	AW1	AW2	AW3	IW1	IW2	IW3	CW1	CW2	CW3
PF4	0.0	-0.057	-0.126	-0.135	-0.069	-0.019	-0.003	0.038	-0.0	-0.02	0.042	-0.024	-0.009	0.014	0.028	-0.045	0.056	-0.064	0.005
PF7	0.591	0.0	-0.125	-0.076	-0.174	-0.072	-0.01	0.012	-0.024	0.09	0.016	0.034	-0.035	0.028	-0.003	-0.034	0.012	-0.065	0.044
PF8	0.54	0.54	0.0	-0.053	-0.035	0.045	0.002	-0.022	0.014	-0.035	-0.045	-0.003	0.031	-0.005	-0.006	0.012	-0.049	0.079	-0.024
PF9	0.514	0.572	0.614	0.0	-0.14	-0.023	-0.022	-0.036	0.016	0.065	0.005	-0.017	0.009	-0.018	-0.007	0.031	-0.03	0.03	0.0
PF10	0.315	0.21	0.359	0.245	0.0	0.128	0.06	0.012	-0.008	-0.183	-0.033	0.018	0.008	-0.038	-0.013	0.069	0.02	0.036	-0.048
RP1	0.336	0.243	0.406	0.317	0.376	0.0	-0.092	-0.171	-0.136	-0.107	-0.048	-0.011	0.039	-0.013	0.002	0.015	-0.009	-0.017	0.023
RP4	0.323	0.268	0.332	0.285	0.297	0.391	0.0	-0.077	-0.068	-0.206	-0.032	0.036	-0.005	-0.041	0.013	0.04	-0.004	0.021	-0.015
RP5	0.324	0.251	0.267	0.231	0.224	0.303	0.482	0.0	-0.124	-0.109	0.043	-0.007	-0.022	0.02	-0.005	-0.021	-0.003	-0.009	0.011
RP7	0.367	0.293	0.387	0.363	0.257	0.378	0.538	0.47	0.0	-0.074	0.009	-0.01	0.002	0.003	0.021	-0.023	0.029	0.025	-0.047
RP8	0.442	0.509	0.436	0.51	0.131	0.34	0.321	0.409	0.486	0.0	0.021	-0.008	-0.008	0.029	-0.033	-0.007	-0.017	-0.025	0.037
AW1	0.321	0.292	0.211	0.251	0.041	0.1	0.075	0.185	0.169	0.266	0.0	-0.052	-0.137	0.03	-0.015	-0.025	-0.007	-0.053	0.052
AW2	0.258	0.312	0.256	0.231	0.094	0.196	0.213	0.203	0.224	0.302	0.676	0.0	-0.163	0.012	0.002	-0.017	0.027	-0.007	-0.018
AW3	0.419	0.39	0.439	0.403	0.167	0.282	0.212	0.229	0.28	0.346	0.624	0.597	0.0	-0.028	0.008	0.029	-0.015	0.039	-0.02
IW1	0.274	0.29	0.278	0.267	0.128	0.188	0.145	0.261	0.227	0.284	0.475	0.49	0.55	0.0	-0.181	-0.248	0.024	-0.083	0.049
IW2	0.244	0.215	0.229	0.23	0.118	0.228	0.235	0.263	0.279	0.244	0.226	0.271	0.357	0.41	0.0	-0.214	0.022	0.032	-0.047
IW3	0.075	0.088	0.148	0.171	0.151	0.116	0.115	0.102	0.079	0.132	0.215	0.251	0.374	0.324	0.282	0.0	-0.052	0.078	-0.02
CW1	0.204	0.18	0.164	0.172	0.186	0.106	0.162	0.145	0.208	0.17	0.204	0.234	0.269	0.371	0.284	0.327	0.0	-0.153	-0.21
CW2	0.04	0.059	0.247	0.187	0.176	0.073	0.156	0.109	0.171	0.133	0.132	0.174	0.295	0.247	0.28	0.442	0.461	0.0	-0.199
CW3	0.079	0.139	0.116	0.129	0.077	0.032	0.026	0.036	-0.001	0.11	0.42	0.345	0.428	0.427	0.242	0.387	0.42	0.426	0.0

Figura 17 - Correlação entre indicadores e componentes

Fonte: Análise no GSCA Pro, com dados simulados pelo autor.

Por fim, o software fornece uma tabela com as correlações entre cada indicador e todos os componentes. Essa informação pode auxiliar na reespecificação do modelo de mensuração, ao indicar possíveis realocações de indicadores entre componentes, com base na força das correlações observadas. Esses resultados estão apresentados na Figura 18.

Correlations between indicators and components

	PF	RP	AW	IW	CW
PF4	0.805	0.49	0.395	0.271	0.136
PF7	0.805	0.427	0.391	0.273	0.161
PF8	0.826	0.497	0.37	0.297	0.218
PF9	0.806	0.465	0.355	0.301	0.204
PF10	0.477	0.349	0.127	0.176	0.181
RP1	0.43	0.64	0.237	0.235	0.087
RP4	0.391	0.755	0.202	0.214	0.14
RP5	0.341	0.741	0.241	0.282	0.119
RP7	0.442	0.802	0.268	0.26	0.152
RP8	0.562	0.698	0.357	0.299	0.173
AW1	0.314	0.219	0.853	0.429	0.329
AW2	0.317	0.311	0.854	0.469	0.324
AW3	0.498	0.368	0.891	0.585	0.424
IW1	0.337	0.303	0.588	0.826	0.446
IW2	0.28	0.343	0.34	0.715	0.338
IW3	0.161	0.148	0.337	0.693	0.487
CW1	0.234	0.219	0.277	0.441	0.786
CW2	0.179	0.178	0.246	0.421	0.78
CW3	0.144	0.054	0.461	0.48	0.801

Figura 18 - Correlação entre indicadores e resíduos de correlação

Fonte: Análise no GSCA Pro, com dados simulados pelo autor.

O GSCA Pro permite a exportação completa dos resultados no formato .csv. Para isso, o usuário deve clicar em **“Export Result”** (Figura 19a), selecionar **“Full result”** (Figura 19b) na janela que se abre e confirmar com **“OK”** (Figura 19c). Também é possível visualizar as pontuações

individuais dos respondentes, que podem incluir pontuações padronizadas dos construtos, pontuações não padronizadas ou pontuações dos indicadores com valores ausentes imputados, acessando **“View Individual Scores”** (Figura 19d) no menu principal.

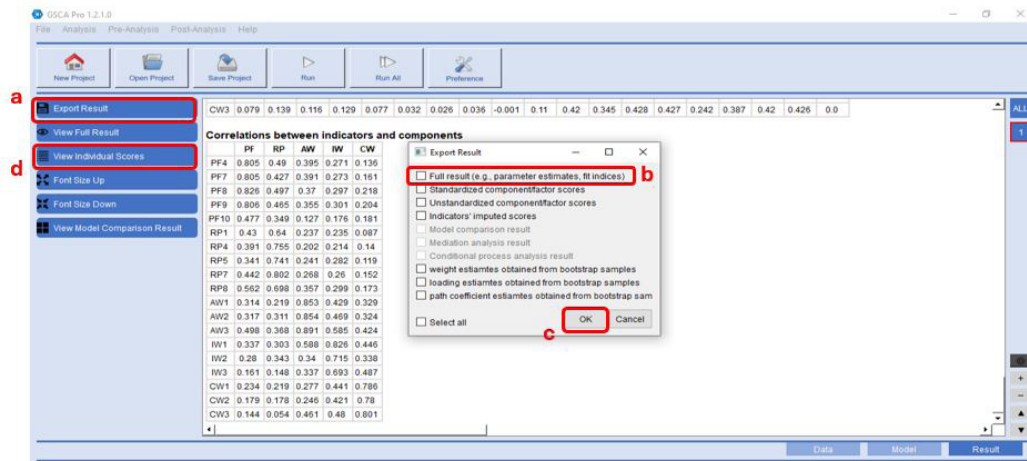


Figura 19 - Exportação de resultados

Fonte: Captura de tela do GSCA Pro, elaborada pelo autor.

A sistematização apresentada no Quadro 1 reúne, de forma organizada, os principais critérios para avaliação de modelos no GSCA Pro.

A sistematização no Quadro 1 resume os principais critérios para a correta interpretação dos resultados do GSCA Pro, permitindo ao usuário compreender as saídas do software e tomar decisões informadas sobre

o modelo teórico. A tabela complementa o tutorial e reforça sua proposta didática, organizando os índices por etapas analíticas, explicando interpretações, valores de referência e usos apropriados. O objetivo é facilitar o uso do GSCA Pro por pesquisadores e estudantes, incentivando sua adoção como uma alternativa viável e acessível para modelagem de equações estruturais em contextos acadêmicos e aplicados.

Quadro 1
Critérios de avaliação de modelos baseados em componentes

Etapa	Índice	Explicação	Valores de referência	Fonte
Ajuste geral do modelo	G	Avaliam o quanto as covariâncias do modelo se aproximam das observadas.	N = 100: GFI ≥ 0,89 e SRMR ≤ 0,09. SRMR ≤ 0,09 é aceitável se 0,85 ≥ GFI < 0,89. N > 100: GFI ≥ 0,93 ou SRMR ≤ 0,08.	Cho et al. (2020)
	G	Variância total explicada pelo modelo (componentes e indicadores)	Varia de 0 a 1 (quanto maior, melhor)	
	G	FIT ajustado pela complexidade do modelo.	Preferir o modelo com maior valor AFIT*	Hwang et al. (2024)
Modelo de Mensuração	L	Variância explicada pelos componentes no modelo estrutural	Varia de 0 a 1 (quanto maior, melhor)	
	L	Variância explicada pelos indicadores no modelo de mensuração	Varia de 0 a 1 (quanto maior, melhor)	
	G	Poder preditivo global do modelo para dados fora da amostra	OPE < 1*	
Weights	L	Poder de predição do modelo de mensuração	OPEm < 1*	Cho et al. (2019)
	L	Poder de predição do modelo estrutural	OPEs < 1*	
	L	Dimensionality	Quando =1 indica unidimensionalidade. Quando > 1 indica multidimensionalidade.	Kaiser (1960)
Loadings		Pesos dos indicadores formativos no componente.	Hwang e Takane (2014); Hwang et al. (2023)	
		Cargas dos indicadores com o componente.	Hwang e Takane (2014); Hwang et al. (2023)	
		Proporção da variância explicada por um único componente em um bloco de indicadores.	Jolliffe e Cadima (2016)	
PVE		Índice de colinearidade entre variáveis predictoras no modelo estrutural.	VIF ≤ 3 ideal; 3 > VIF < indica risco; VIF ≥ 5 indica colinearidade crítica	Hair et al. (2011; 2019); Hwang et al. (2023)
		Coefficientes de caminho entre os componentes.	Hwang et al. (2023)	
		Tamanho do efeito de um componente sobre outro no modelo estrutural.	Cohen (1988); Hwang et al. (2023)	
Path Coefficients		Proporção da variância explicada de cada componente endógeno no modelo estrutural.	Sharma et al. (2019); Hwang et al. (2023)	
		R ²		

Fonte: Elaborado pelo autor com base em Hwang et al. (2024), (*) os valores devem ser interpretados apenas em contextos de comparação entre modelos alternativos. (G) medidas de ajuste global do modelo. (L) medidas de ajuste local.

4. CONCLUSÃO

Este tutorial teve como objetivo apresentar uma linguagem acessível e aplicada, utilizando o GSCA Pro como alternativa metodológica para o PLS-SEM, com foco em pesquisas em Administração e áreas correlatas. A proposta focou na demonstração prática do funcionamento do software, sem a pretensão de comparar diretamente técnicas ou plataformas. Contudo, o modelo utilizado, previamente validado por Mourad e Quevedo (2023), serviu como ponto de ancoragem para ilustrar o potencial da ferramenta. A escolha do GSCA em sua versão padrão, baseada em componentes, se deu em função de sua lógica de estimação baseada em componentes, o que o aproxima conceitualmente do PLS-SEM tradicional, tornando-o uma alternativa adequada para análises que visem à predição e explicação da variância de construtos latentes, com modelos reflexivos e formativos, e sua tolerância a restrições amostrais (Hwang *et al.*, 2024). Por ser gratuito, independente de pacotes adicionais e possuir uma interface gráfica intuitiva, apesar de não estar disponível em português, o GSCA Pro torna-se uma alternativa acessível para expandir o uso de técnicas do PLS-SEM, especialmente em contextos acadêmicos que enfrentam limitações técnicas, financeiras ou computacionais. Espera-se que este material contribua para a expansão do uso do GSCA entre docentes, pesquisadores e estudantes, ao mesmo tempo, em que promove a disseminação de abordagens quantitativas no contexto brasileiro. Como agenda futura, recomenda-se o desenvolvimento de tutoriais com o GSCAm e o IGSCA, além de comparações de tutoriais ou estudos comparativos entre os resultados produzidos por diferentes *softwares* de modelagem, como SmartPLS, lavaan (R), AMOS, LISREL e Mplus. Recomenda-se também analisar criticamente as similaridades e distinções conceituais e operacionais entre os métodos de modelagem existentes, como GSCA, GSCAm, IGSCA, CB-SEM e PLS-SEM, considerando suas características metodológicas, requisitos estatísticos, aderência aos diferentes objetivos de pesquisa e considerando seus critérios de ajuste, requisitos técnicos, potencial de predição e alinhamento com diferentes estratégias de pesquisa em Administração.

AGRADECIMENTO

Ao Professor Heungsun Hwang, da McGill University e desenvolvedor do GSCA Pro, pelas valiosas contribuições, pela revisão criteriosa e pela constante disponibilidade ao longo do desenvolvimento deste tutorial.

REFERÊNCIAS

Benitez, J., Henseler, J., Castillo, A., & Schuberth, F. (2020). How to perform and report an impactful analysis

using partial least squares: Guidelines for confirmatory and explanatory IS research. *Information & Management*, 57(2), 103168. DOI: <https://doi.org/10.1016/j.im.2019.05.003>

Cho, G., & Choi, J. Y. (2020). An empirical comparison of generalized structured component analysis and partial least squares path modeling under variance-based structural equation models. *Behaviormetrika*, 47, 243–272. DOI: <https://doi.org/10.1007/s41237-019-00098-0>

Cho, G., Hwang, H., Sarstedt, M., & Ringle, C. M. (2020). Cutoff criteria for overall model fit indexes in generalized structured component analysis. *Journal of Marketing Analytics*, 8, 189–202. DOI: <https://doi.org/10.1057/s41270-020-00089-1>

Cho, G., Jung, K., & Hwang, H. (2019). Out-of-bag prediction error: A cross validation index for generalized structured component analysis. *Multivariate Behavioral Research*, 54, 505–513. DOI: <https://doi.org/10.1080/0273171.2018.1540340>

Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2nd ed.). Lawrence Erlbaum Associates.

Fornell, C., & Larcker, D. F. (1981). Evaluating structural equation models with unobservable variables and measurement error. *Journal of Marketing Research*, 18(1), 39–50. DOI: <https://doi.org/10.2307/3151312>

Hair, J. F., Gabriel, M. L. D. S., & Patel, V. K. (2014). Modelagem de equações estruturais baseada em covariância (CB-SEM) com o AMOS: Orientações sobre sua aplicação como uma ferramenta de pesquisa de marketing. *Revista Brasileira de Marketing*, 13(2), 44–55. DOI: <https://doi.org/10.5585/remark.v13i2.2718>

Hair, J. F., Howard, M. C., & Nitzl, C. (2020). Assessing measurement model quality in PLS-SEM using confirmatory composite analysis. *Journal of Business Research*, 109, 101–110. DOI: <https://doi.org/10.1016/j.jbusres.2019.11.069>

Hair, J. F., Ringle, C. M., & Sarstedt, M. (2011). PLS-SEM: Indeed a silver bullet. *Journal of Marketing Theory and Practice*, 19(2), 139–152. DOI: <https://doi.org/10.2753/MTP1069-6679190202>

Hair, J. F., Risher, J. J., Sarstedt, M., & Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review*, 31, 2–24. DOI: <https://doi.org/10.1108/EBR-11-2018-0203>

Hwang, H., & Cho, G. (2020). Global least squares path modeling: A full-information alternative to partial least squares path modeling. *Psychometrika*, 85, 947–972. DOI: <https://doi.org/10.1007/s11336-020-09733-2>

- Hwang, H., & Takane, Y. (2004). Generalized structured component analysis. *Psychometrika*, 69(1), 81–99. DOI: <https://doi.org/10.1007/BF02295841>
- Hwang, H., Cho, G., & Choo, H. (2024). GSCA Pro—Free stand-alone software for structural equation modeling. *Structural Equation Modeling: A Multidisciplinary Journal*, 31(4), 696–711. DOI: <https://doi.org/10.1080/10705511.2023.2272294>
- Hwang, H., Sarstedt, M., Cho, G., Choo, H., & Ringle, C. M. (2023). A primer on integrated generalized structured component analysis. *European Business Review*, 35(3), 261–284. DOI: <https://doi.org/10.1108/EBR-11-2022-0224>
- Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: A review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374, e20150202. DOI: <https://doi.org/10.1098/rsta.2015.0202>
- Kaiser, H. F. (1960). The application of electronic computers to factor analysis. *Educational and Psychological Measurement*, 20, 141–151. DOI: <https://doi.org/10.1177/001316446002000116>
- Malhotra, N. K., Lopes, E. L., & Veiga, R. T. (2014). Modelagem de equações estruturais com Lisrel: Uma visão inicial. *Revista Brasileira de Marketing*, 13(2), 28–43. DOI: <https://doi.org/10.5585/remark.v13i2.2698>
- Mourad, A. I., & Quevedo, L. F. A. P. de. (2023). Webrooming in the context of fashion: an antecedent analysis of webrooming attitude, intention and behavior. *Future Studies Research Journal: Trends and Strategies*, 15(1), e0761. DOI: <https://doi.org/10.24023/FutureJournal/2175-5825/2023.v15i1.761>
- Ringle, C. M., Silva, D., & Bido, D. (2014). Modelagem de equações estruturais com utilização do SmartPLS. *Revista Brasileira de Marketing*, 13(2), 54–71. DOI: <https://doi.org/10.5585/remark.v13i2.2717>
- Rönkkö, M., & Cho, E. (2020). An updated guideline for assessing discriminant validity. *Organizational Research Methods*, 25(1), 6–14. DOI: <https://doi.org/10.1177/1094428120968614>
- Sarstedt, M., Hair, J. F., Pick, M., Liengaard, B. D., Rado-mir, L., & Ringle, C. M. (2022). Progress in partial least squares structural equation modeling use in marketing research in the last decade. *Psychology & Marketing*, 39(5), 1035–1064. DOI: <https://doi.org/10.1002/mar.21640>
- Sharma, P., Sarstedt, M., Shmueli, G., Kim, K. H., & Thiele, K. O. (2019). PLS-based model selection: The role of alternative explanations in information systems research. *Journal of the Association for Information Systems*, 20(2), 346–397. DOI: <https://doi.org/10.17705/1.jais.00538>