



GUIA DO USUÁRIO

Guia do Usuário OpenPLS

Passo a passo completo para pesquisadores e profissionais

Versão 0.3.28

2026-08-04

openpls.app · PLS-SEM moderno para pesquisadores

Conteúdo

1	O que é PLS-SEM?	4
1.1	Os blocos de construção	4
1.2	A iteração	4
1.3	O que o OpenPLS oferece a você	5
2	Primeiros passos	6
2.1	A página Projects	6
2.2	Criando um projeto	6
2.3	Clonando um exemplo científico	7
2.4	Sua primeira visão de um projeto	8
3	Conjuntos de dados	8
3.1	O painel de conjunto de dados vazio	9
3.2	Quando o conjunto de dados estiver pronto	10
3.3	Editando códigos de ausência	10
3.4	Gerenciando múltiplos conjuntos de dados	11
3.5	Excluindo um conjunto de dados	11
4	Construindo um modelo	12
4.1	O editor visual	12
4.2	O canvas	13
4.3	A visualização em formulário	15
4.4	Computação ao vivo	16
4.5	Versions	16
5	Computando e lendo resultados	17
5.1	O cabeçalho de Results	17
5.2	Inner summary (padrão)	18
5.3	Paths	19
5.4	Inner model / outer model	19
5.5	Reliability	20
5.6	HTMT	20
5.7	VIF	21
5.8	Effects	21
5.9	Ajuste do modelo	21
6	Métodos avançados	21
6.1	Bootstrap	22
6.2	Multi-Group Analysis (MGA)	24
6.3	MICOM	24
6.4	Moderação	27

6.5	Validade nomológica	27
6.6	PLSc	27
6.7	Cópula gaussiana (endogeneidade)	30
6.8	Viés de método comum (CMB, Lindell-Whitney)	31
6.9	IPMA	31
6.10	PLSpredict	34
6.11	CVPAT	34
6.12	FIMIX-PLS	34
6.13	Construto de ordem superior (HOC)	38
7	Exportações	40
7.1	Relatório PDF	40
7.2	Planilha Excel (XLSX)	40
7.3	Pacote Report JSON	41
7.4	Exportação de modelo (barra de ferramentas do Editor)	41
7.5	Snippets LaTeX	41
7.6	Reprodutibilidade	41
8	Colaboração	42
8.1	O painel da equipe	42
8.2	Papéis	42
8.3	Enviando um convite	43
8.4	O log de atividade	43
8.5	Saindo de um projeto	44
8.6	O que os colaboradores veem	45
9	Configurações e idioma	45
9.1	Configurações do projeto	45
9.2	Idioma	46
9.3	Configurações da conta	48
9.4	Tema	48
10	Ajuda e leituras adicionais	49
10.1	Ajuda no aplicativo	49
10.2	O engine OpenPLS (código aberto)	50
10.3	Suporte, bugs e solicitações de recursos	50
10.4	Citando o OpenPLS	50
11	O AI Companion	51
11.1	Ativando	51
11.2	AI hints: a faixa sempre visível	51
11.3	Chat: a gaveta flutuante	52
11.4	Projetando um modelo a partir de uma pergunta de pesquisa	56

11.5	Projetando um questionário	57
11.6	Method-Selection Assistant	58
11.7	Redação de relatório	61
11.7.1	Methods / Results / Discussion	62
11.7.2	Reviewer defense	62
11.8	A biblioteca de artigos	65
11.9	Cota e privacidade	65
11.10	Desativando	66
12	Pesquisas públicas	66
12.1	Construindo o questionário	66
12.2	Publicando	68
12.2.1	Snapshots de versão	68
12.3	A visão pública do respondente	70
12.4	Assistindo respostas chegarem	70
12.5	Importando respostas como um conjunto de dados	70
12.6	Baixando um CSV bruto	73
12.7	Despublicando	73
12.8	Limites e convenções	73
13	Apêndice	73
13.1	Glossário	74
13.2	Atalhos de teclado	76
13.3	Referências	76

1 O que é PLS-SEM?

Partial Least Squares Structural Equation Modeling (PLS-SEM) é um método para estimação de modelos com **construtos latentes**: coisas que não podemos medir diretamente, apenas por meio de indicadores observáveis. Satisfação do cliente, personalidade da marca e confiança organizacional são todos latentes: ninguém entrega a você uma leitura de “satisfação”; você a infere a partir de itens de questionário que a representam.

O PLS-SEM responde a três perguntas interligadas em uma única estimação:

1. **Mensuração.** Quão bem os indicadores observáveis (itens de questionário, avaliações, leituras de sensores) representam cada construto latente?
2. **Estrutura.** Quão fortemente cada construto afeta os outros? A qualidade percebida impulsiona a satisfação? A confiança medeia o efeito da utilidade sobre a adoção?
3. **Predição.** Quão bem o modelo generaliza? Qual seria o resultado para uma nova observação?

Diferentemente do SEM baseado em covariâncias (LISREL, Mplus, lavaan), o PLS-SEM não exige que os dados sejam multivariados normais, funciona com amostras pequenas e lida sem dificuldades com mensuração **formativa** (indicadores que definem conjuntamente um construto, por exemplo, renda + escolaridade + ocupação → status socioeconômico). Isso o torna a escolha padrão em pesquisa em negócios, marketing, sistemas de informação e, cada vez mais, em saúde e ciências sociais.

1.1 Os blocos de construção

Um modelo PLS-SEM tem quatro tipos de peças:

- **Variáveis latentes (LVs):** os construtos que você quer estudar. Desenhados como círculos.
- **Indicadores / variáveis manifestas (MVs):** as colunas observadas do seu conjunto de dados que medem cada LV. Desenhados como quadrados em diagramas de caminho tradicionais; no OpenPLS, eles ficam na barra lateral e são atribuídos às LVs.
- **Modelo de mensuração / modelo externo:** as setas entre uma LV e seus indicadores. A direção distingue **reflexivo** (Mode A: a LV causa os indicadores, por exemplo, satisfação → sat1..sat4) de **formativo** (Mode B: os indicadores causam a LV, por exemplo, renda + escolaridade → SES).
- **Modelo estrutural / modelo interno:** as setas entre as LVs. São as hipóteses em teste.

1.2 A iteração

O PLS-SEM alterna duas regressões por mínimos quadrados até a convergência:

1. Estima cada LV como um composto ponderado de seus indicadores usando os pesos atuais do modelo interno.

2. Estima os coeficientes de caminho do modelo interno regredindo cada LV endógena em relação aos seus predecessores.

A convergência é rápida (geralmente < 10 iterações). Erros padrão e p-valores vêm do **Bootstrap**: reamostragem dos dados com reposição várias milhares de vezes e reestimação.

1.3 O que o OpenPLS oferece a você

O OpenPLS é uma ferramenta moderna, aberta e nativa da nuvem para PLS-SEM. Em um único projeto você pode:

- Fazer upload de um conjunto de dados (CSV, XLSX, SPSS .sav, Stata .dta), ou **construir um questionário, publicá-lo como uma pesquisa pública e importar as respostas acumuladas como um conjunto de dados com um clique** (capítulo 13).
- Desenhar o modelo visualmente (arrastar de LV para LV), digitá-lo em um formulário, ou **gerar um modelo inicial a partir de uma pergunta de pesquisa com o AI Companion** (capítulo 12).
- Calcular a estimação PLS, com recomputação ao vivo a cada mudança.
- Avaliar a qualidade da mensuração: confiabilidades, AVE, HTMT, VIF.
- Avaliar a qualidade estrutural: R^2 , R^2 ajustado, f^2 , Q^2 , SRMR, dULS, Fornell-Larcker.
- Aplicar Bootstrap nos caminhos para obter p-valores e intervalos de confiança.
- Executar os métodos avançados: MGA, MICOM, moderação, mediação, IPMA, PLSpredict, FIMIX, HOC, PLSc, cópula gaussiana, CVPAT, Validade nomológica, viés de método comum.
- **Obter dicas contextuais de IA em cada aba, conversar com um assistente que tem acesso somente leitura aos dados do seu projeto e redigir seções de Methods / Results / Discussion prontas para publicação, além de defesas antecipadas contra revisores** - tudo fundamentado em uma biblioteca curada de artigos PLS-SEM de acesso aberto (capítulo 12).
- Exportar toda a execução como PDF, XLSX, LaTeX ou um pacote JSON autocontido para reprodutibilidade.
- Convidar colaboradores, rastrear atividades e manter uma trilha de auditoria de cada versão do modelo.

O restante deste guia percorre cada uma dessas etapas na ordem em que você as usaria de fato.

Este guia foi escrito com base no OpenPLS versão 0.3.27 executado em `cloud.openpls.app`. As telas podem diferir ligeiramente em versões posteriores; os fluxos permanecem os mesmos.




Figura 1 Página inicial de Projects: o cabeçalho oferece **New project** e **Examples**; o card do estado vazio no centro oferece as mesmas duas ações.

2 Primeiros passos

Você precisa de uma conta para salvar projetos. Vá até <https://cloud.openpls.app>, cadastre-se com um e-mail, verifique-o e faça login. Você chegará à página **Projects**, seu espaço de trabalho.

2.1 A página Projects

A página Projects (Figura 1) é sua tela inicial. Ela lista todos os projetos aos quais você tem acesso e aponta para duas ações iniciais no cabeçalho, além de um par duplicado dentro do card do estado vazio.

Três maneiras de começar (numeradas na Figura 1):

1. **New project** (canto superior direito), um espaço de trabalho em branco. Você faz upload do seu próprio conjunto de dados e constrói o modelo do zero.
2. **Examples**: a biblioteca de casos de exemplo. Um clique clona um clássico científico de PLS-SEM (ECSI, MOBI, Russett, vários conjuntos de dados sintéticos) para seu espaço de trabalho, com conjunto de dados + modelo pré-configurados.
3. **Create project** no card do estado vazio, atalho para o mesmo diálogo de (1). Use esse ou o botão do cabeçalho, o que estiver mais próximo do seu cursor.

2.2 Criando um projeto

Clicar em qualquer **New project** abre o diálogo mostrado na Figura 2.




Figura 2 O diálogo **New project** com campo de nome, descrição opcional e a ação **Create** no canto inferior direito.

Preencha (numerado na Figura 2):

1. **Project name:** obrigatório, ≥ 2 caracteres. Qualquer coisa, desde “Satisfação do cliente 2026” até “Experimento H1, coorte por país”.
2. **Description:** opcional, até 500 caracteres. Onde você anota a pergunta de pesquisa ou a hipótese que está testando. Útil quando você retorna seis meses depois.
3. Clique em **Create**. Você chega à página de detalhes do projeto recém-criado. Como ainda não há conjunto de dados anexado, o app abre na aba Dataset para que você possa fazer upload imediatamente.

2.3 Clonando um exemplo científico

Se você é novo em PLS-SEM, comece com um modelo conhecidamente bom. Clique em **Examples** no cabeçalho para abrir a biblioteca (Figura 3).

1. Escolha um card que corresponda ao seu domínio (satisfação do cliente, experiência de marca, aceitação de tecnologia, engajamento no trabalho, aplicativos de saúde, ciência política...). Cada um vem com um conjunto de dados + modelo totalmente especificados.
2. Clique em **Clone into my workspace**. O OpenPLS cria uma cópia privada em sua conta. Você pode livremente excluir indicadores, adicionar LVs, alterar caminhos, o original permanece intacto para outros usuários.




Figura 3 A biblioteca Examples. Cada card mostra as estatísticas do conjunto de dados e a citação; clique em qualquer card para abrir e depois em **Clone into my workspace** para criar uma cópia editável.

Os exemplos são casos didáticos de licença aberta da literatura PLS-SEM (*Tenenhau et al. 2005, Brakus & Schmitt 2009, Bakker & Demerouti 2017, Russett 1964, Venkatesh et al. 2012, Davis 1989*). Citações completas estão em cada card. Conjuntos de dados sintéticos são claramente identificados e foram simulados conforme a estrutura de caminho publicada apenas para fins didáticos.

2.4 Sua primeira visão de um projeto

Assim que você está dentro de um projeto, vê a faixa de abas no topo:

- **Dataset:** upload, inspeção, edição das convenções de códigos de ausência
- **Model:** construção do modelo (Editor / Form / Versions)
- **Results:** leitura da saída da computação
- **Advanced:** os 13 métodos avançados
- **Manage:** equipe, log de atividades, configurações do projeto

Vamos percorrer cada aba na sequência. A seguir: upload de um conjunto de dados.

3 Conjuntos de dados

Todo projeto precisa de exatamente um conjunto de dados antes que você possa construir um modelo. O OpenPLS lê **CSV**, **XLSX**, **SPSS .sav** e **Stata .dta**, até 50 MB por arquivo.




Figura 4 Aba Dataset vazia. A faixa de abas ao longo do topo alterna entre Dataset, Model, Results, Advanced, Report e Manage. Abaixo dela, um subtoggle alterna entre fazer upload de um arquivo e construir uma pesquisa pública.

3.1 O painel de conjunto de dados vazio


Um projeto novo abre com a aba Dataset ativa. Se ainda não há dados anexados, você verá a zona de upload mostrada na Figura 4.

Dois passos para inserir dados:

1. Confirme que você está na aba **Dataset**. É a primeira aba em todo projeto.
2. Arraste um arquivo para a zona de soltar tracejada, ou clique nela para abrir o seletor de arquivos do seu SO.

Para uploads de CSV, o OpenPLS abre em seguida um diálogo **CSV separator**. Ele mostra uma prévia das primeiras linhas e sugere automaticamente o separador (, , ; , tabulação ou |); confirme para prosseguir.

CSVs exportados do Excel europeu geralmente usam ‘;’ como separador. O OpenPLS detecta isso automaticamente, mas confirme se a prévia parece correta antes de clicar em Upload; escolher o separador errado é a forma mais rápida de produzir um conjunto de dados sem sentido.



COLUMN	TYPE	MISSING	MIN	MAX	MEAN
imag1	numeric	0	0	10	7.804
imag2	numeric	0	0	10	7.804
imag3	numeric	0	0	10	7.912
imag4	numeric	0	3	10	7.876

Figura 5 Painel Dataset após o upload. O card do conjunto de dados mostra o chip de estado Ready e os sentinelas atuais de códigos de ausência; o painel principal à direita mostra estatísticas por coluna.

3.2 Quando o conjunto de dados estiver pronto

O parsing é feito no servidor e leva um ou dois segundos para arquivos típicos. Ao terminar, o card do conjunto de dados aparece na coluna esquerda e seus detalhes são renderizados à direita (Figura 5). Dois chips são importantes:

1. **Chip de status:** fica verde e mostra “Ready” assim que o parsing é concluído. Se ele permanecer vermelho (“Error”), clique no conjunto de dados para ver a mensagem de erro.
2. **Chip de missing codes:** mostra quais valores numéricos o OpenPLS está tratando como ausentes. O padrão -99, -999 corresponde à convenção do SPSS. Clique no chip para editar.

O painel direito lista cada coluna com seu tipo (numérico, string, misto), o número de células ausentes e (para colunas numéricas) mín, máx e média. Use isso para verificar a sanidade do parsing: uma coluna que você esperava ser numérica e que retornou como `string` geralmente indica uma célula não numérica perdida.

3.3 Editando códigos de ausência

Alguns conjuntos de dados codificam ausência como célula em branco, outros usam -99 (padrão do SPSS), outros ainda usam 9999 ou -1. Errar isso é o **motivo mais comum** para relatos de bug do tipo “por que meu R^2 está tão baixo?”; o modelo trata os valores sentinela como dados reais, degradando as correlações.

Clique no chip de missing-codes para abrir o editor mostrado na Figura 6.

Os três elementos da Figura 6:

1. **Sentinelas existentes:** cada um é um chip. Clique no $\times$ de um chip para removê-lo do conjunto.
2. **Add code:** digite qualquer inteiro (positivo ou negativo, até a convenção do seu conjunto de dados) e clique em **Add**. Ele aparece como um novo chip.
3. **Apply and re-parse:** envia o novo conjunto ao servidor, que relê o arquivo com os senti-




Figura 6 Editor de missing codes. Chips de rascunho podem ser removidos via o x; novos sentinelas são adicionados pelo input; **Apply and re-parse** confirma a mudança e relê o arquivo.

nelas atualizados e atualiza as estatísticas de coluna. Aguarde o spinner do botão parar antes de prosseguir.

Aplicar códigos de ausência refaz o parsing do arquivo do zero. Se você já havia computado um modelo, a computação é invalidada; execute-a novamente após o re-parse.

3.4 Gerenciando múltiplos conjuntos de dados

Um único projeto pode conter vários conjuntos de dados lado a lado (por exemplo, um por país, ou piloto vs. amostra completa). Adicione mais arrastando ou selecionando arquivos adicionais. Cada conjunto de dados recebe seu próprio card na coluna esquerda; clique em um card para torná-lo ativo. Modelos se vinculam a um conjunto de dados específico, então alternar o conjunto de dados ativo na lista de cards apenas altera o que a aba Dataset mostra, o modelo continua apontando para aquilo com que foi criado.

3.5 Excluindo um conjunto de dados

Para excluir um conjunto de dados, passe o mouse sobre seu card na coluna esquerda e clique no ícone de lixeira. A exclusão é imediata e não pode ser desfeita. Se qualquer modelo no projeto ainda referenciar o conjunto de dados excluído, sua computação apresentará erro até que você anexe um conjunto de dados diferente.

Conjuntos de dados são excluídos imediatamente sem forma de desfazer. Qualquer modelo no projeto que ainda aponte para o conjunto de dados excluído dará erro na computação; ou anexe novamente um conjunto de dados diferente na aba Model, ou também exclua o modelo.




Figura 7 O editor visual com a barra de ferramentas (topo), o canvas Vue Flow (centro) e a barra lateral de indicadores (direita).

4 Construindo um modelo

O OpenPLS oferece três formas de moldar o modelo:

- **Editor:** o canvas visual de arrastar e soltar. Este é o fluxo principal e o recurso principal do OpenPLS.
- **Form:** um formulário simples com uma tabela de LVs e uma tabela de caminhos. Mais rápido quando você já conhece o modelo de cor ou está copiando de um artigo.
- **Versions:** o log de auditoria de cada computação anterior. Cada computação faz um snapshot do modelo + resultado, para que você possa restaurar qualquer estado anterior.

Todas as três sub-visões editam o mesmo modelo subjacente. Alterne livremente.

4.1 O editor visual

Clique em **Model** → **Editor** para abrir o canvas mostrado na Figura 7. A barra de ferramentas fica acima do canvas; a barra lateral de indicadores à direita lista cada coluna numérica do conjunto de dados.

Lendo a Figura 7 da esquerda para a direita, a barra de ferramentas expõe:

1. **Seletor de modelo:** um projeto pode conter múltiplos modelos sobre o mesmo conjunto de dados. Escolha um no dropdown.
2. **New model:** cria um novo modelo vazio. O diálogo pede um nome; você pode renomear depois em Settings.
3. **Dataset picker:** cada modelo se vincula a um conjunto de dados. Se você fez upload de mais de um CSV, escolha aqui.
4. **Undo / Redo:** Cmd+Z / Cmd+Shift+Z no macOS, Ctrl+Z / Ctrl+Y no Windows e Linux. Undo desfaz criações de LVs, atribuições de indicadores e desenhos de caminho.
5. **Add LV:** solta um novo círculo de variável latente no canvas em uma posição aleatória e o seleciona automaticamente.
6. **Auto layout:** executa o dagre para organizar os nós da esquerda para a direita em ordem topológica. Forma barata de sair de uma confusão de círculos sobrepostos para algo pronto para publicação.
7. **Fit to window:** recentraliza o canvas em todos os nós visíveis.
8. **Export model:** baixa o modelo como `.openpls.json` (formato completo do OpenPLS, inclui posições) ou `.splsm` (XML compatível com SmartPLS).
9. **Live toggle:** ative e o OpenPLS recomputa o modelo 500 ms após cada mudança. Os coeficientes de caminho são renderizados nas arestas, o R^2 aparece dentro de cada LV endógena. Feedback rápido enquanto você itera.
10. **Save:** grava o modelo atual no banco de dados. Não há autosave; clique em Save (ou Compute, que salva implicitamente) para persistir suas edições.
11. **Compute:** executa a estimação completa no servidor (Bootstrap
 - métricas), escreve um documento Result e navega até a aba Results.

4.2 O canvas

Cada **variável latente** é renderizada como um círculo com:

- O nome da LV
- Uma pílula mostrando o modo de mensuração: **A** (reflexivo) ou **B** (formativo)
- Uma contagem de indicadores atribuídos, por exemplo, “5 MV”
- Uma vez que existam resultados, o valor de R^2 dentro do círculo

Cada **caminho** é renderizado como uma seta entre duas LVs. Na LV de origem, o pequeno ponto azul à direita é a **alça de origem**; na LV de destino, o pequeno ponto verde à esquerda é a **alça de destino**. Arraste de um ponto de origem para um ponto de destino para desenhar um novo caminho. Dê um duplo clique em um caminho existente para excluí-lo.

Clicar com o botão direito ou selecionar uma LV abre o editor à direita (Figura 8).

1. **Name:** texto livre. Renomear se propaga para cada caminho que se refere a esta LV.
2. **Mode A / Mode B:** reflexivo vs. formativo. Reflexivo significa que a LV causa seus indicadores (mude a satisfação, todos os itens sat se movem juntos); formativo significa que os

The screenshot displays the OpenPLS software interface for a project titled "ECSI: Customer Satisfaction". The interface is divided into several sections:

- Sidebar (Left):** Contains navigation options: "Projects", "All projects", "New project", "ECSI: Customer Sati...", and "Examples".
- Top Navigation Bar:** Includes tabs for "DATASET", "MODEL" (active), "RESULTS", "ADVANCED", "REPORT", and "MANAGE". Below these are buttons for "EDITOR", "FORM", and "VERSIONS".
- Central Workspace:**
 - Model Title:** "ECSI: Customer Satisfaction" with a subtitle: "Classic ECSI model (European Customer Satisfaction Index): image, expectations, perceived quality and value drive satisfaction and loyalty. Ideal as a first PLS-SEM entry point."
 - AI Hints:** Two informational cards:
 - Robust indicator counts across all six latent variables:** "All 6 latent variables in your model have at least 4 indicators (ranging from 4 to 5), which comfortably satisfies the rule of thumb of > 3 indicators per reflective construct."
 - All indicator names match dataset columns:** "Every indicator assigned to Image, Expectations, Perceived Quality, Perceived Value, Satisfaction, and Loyalty successfully maps to the 28 columns available in your dataset."
 - Model Controls:** Includes a dropdown for "ECSI: Customer Satisfaction", a "+ NEW MODEL" button, a "DESIGN WITH AI" button, and a "Dataset" dropdown set to "ECSI: Customer Satisfaction".
 - Workflow Buttons:** "ADD LV", "AUTO LAYOUT", "Live" toggle, "SAVE", and "COMPUTE".
 - Path Diagram:** A visual representation of the model with latent variables (Image, Expectations, Perceived Quality, Perceived Value) and their relationships.
 - Right Panel (Latent variable editor):**
 - Latent variable:** A form to edit the selected variable "Image". It includes a "Name" field, a mode selector between "A. REFLECTIVE" and "B. FORMATIVE", and a list of assigned indicators (imag1, imag2, imag3, imag4, imag5).
 - Indicators:** A section with a search bar and a list of indicators. One indicator, "imag1", is shown being dragged to the "Image" latent variable.

Figura 8 LV selecionada. O card à direita permite renomear, alterar o modo de mensuração e escolher indicadores.

Figura 9 A sub-visão Form: tabela de LVs no topo (nome, modo, indicadores), tabela de caminhos abaixo, Save + Compute no canto superior direito.

indicadores definem a LV (renda, escolaridade, ocupação juntos definem SES). Escolha errado e as métricas de confiabilidade se tornam sem sentido (Mode B com interpretação reflexiva) ou falham na convergência (Mode A com um construto formativo).

3. **Indicators:** um multi-select sobre cada coluna numérica no conjunto de dados. Adicionar um indicador aqui aparece imediatamente como uma seta dentro do círculo da LV. Alternativamente, arraste chips da barra lateral direita **Indicators** diretamente para o círculo da LV; o OpenPLS solta o indicador ao liberar.
4. **Delete LV:** o pequeno ícone de lixeira no cabeçalho. Remove a LV e quaisquer caminhos apontando para ou dela.

A barra lateral direita **Indicators** lista cada coluna numérica restante, com um distintivo mostrando qual LV (se houver) já a usa. Um único indicador pode aparecer em múltiplas LVs, mas isso geralmente indica um erro de modelagem; investigue antes de continuar.

4.3 A visualização em formulário

Nem todo usuário quer clicar em círculos. Alterne para **Form** para ver o editor baseado em tabela (Figura 9).

O formulário é um formulário HTML simples. Adicione LVs com o botão no final da tabela de LVs; escolha indicadores em um multi-select em cada linha. Adicione caminhos com o botão abaixo da tabela de caminhos; origem e destino vêm do dropdown de LVs. Tudo o que você pode fazer no editor pode fazer aqui.

Quando usar o formulário: copiar e colar um modelo de um artigo, usuários de teclado ou construção automatizada de modelos.

4.4 Computação ao vivo

O toggle **Live** na barra de ferramentas ativa a recomputação incremental. No momento em que você muda qualquer coisa (adiciona uma LV, conecta um caminho, marca um indicador, renomeia), o OpenPLS faz debounce por 500 ms e então executa uma estimação PLS completa no servidor. O resultado retorna e pinta:

- Coeficientes de caminho em cada aresta
- R^2 e R^2 ajustado dentro de cada LV endógena
- p-valores nos caminhos (de um Bootstrap que roda no último Compute completo, não é reamostrado a cada tecla pressionada)

O chip Live na barra de ferramentas alterna entre **computing...**, **waiting...** e **error** para que você saiba em que estado está o job em segundo plano.

A computação ao vivo é a forma mais rápida de explorar o que acontece quando você adiciona um novo caminho ou reatribui um indicador. Desligue-a para modelos grandes onde você quer fazer muitas edições antes de acionar Compute manualmente.

4.5 Versions

Cada vez que você clica em **Compute**, o OpenPLS faz um snapshot do modelo + resultado completo em uma entrada versionada. Alterne para a sub-visão **Versions** (Figura 10) para navegar por elas.

Cada card de versão mostra:

- **v#**: número sequencial da versão
- O modelo ao qual pertence (um chip)
- **GoF**: o goodness-of-fit do resultado dessa versão, se foi bem-sucedido
- O avatar do criador e uma linha de estatísticas (contagem de LVs, contagem de caminhos)
- **Rename** (lápiz), rotule a versão para referência futura, por exemplo, “pré-teste de invariância” ou “submissão final”
- **Delete**: remove a versão. Os documentos subjacentes de modelo + resultado também são excluídos.

Restaurar uma versão substitui o estado atual do editor ao vivo pelo snapshot. Posições de caminhos, indicadores, modo, tudo.

Comparando duas versões: marque a caixa de seleção em dois cards. Um diff lado a lado abre à direita mostrando quais caminhos foram adicionados, removidos ou alterados entre as duas.




Figura 10 A lista Versions. Cada Compute anterior é um card com as contagens de LV/caminhos, GoF e avatar do criador.

Restaurar uma versão sobrescreve o estado do seu editor ao vivo. Se você tem edições não salvas, clique em Save primeiro (ou faça um novo Compute) para que exista um snapshot para o qual recorrer.

5 Computando e lendo resultados

Uma vez que o modelo tenha pelo menos uma LV endógena e cada LV tenha ≥ 1 indicador, o botão **Compute** na barra de ferramentas do Editor/Form fica azul sólido. Clique nele. A computação roda no servidor; execuções típicas em escala ECSI terminam em 3-6 segundos. Ao ter sucesso, o OpenPLS navega para a aba Results.

5.1 O cabeçalho de Results

A aba Results (Figura 11) abre com quatro cards de KPI no topo, três botões de exportação à direita e uma faixa de abas abaixo para as tabelas detalhadas.

O cabeçalho mostra quatro cards de KPI:

1. **Goodness-of-Fit (GoF):** $\sqrt{(\text{mean}(\text{communality}) \times \text{mean}(R^2))}$. Ajuste geral aproximado; abaixo de 0,10 fraco, 0,25 moderado, 0,36+ forte.
2. **SRMR:** Standardized Root Mean Square Residual. Discrepância entre correlações observadas e implicadas pelo modelo. Abaixo de 0,08 é o corte convencional para bom ajuste; abaixo de 0,10 aceitável. O valor de dULS no subtítulo é outra medida de discrepância.

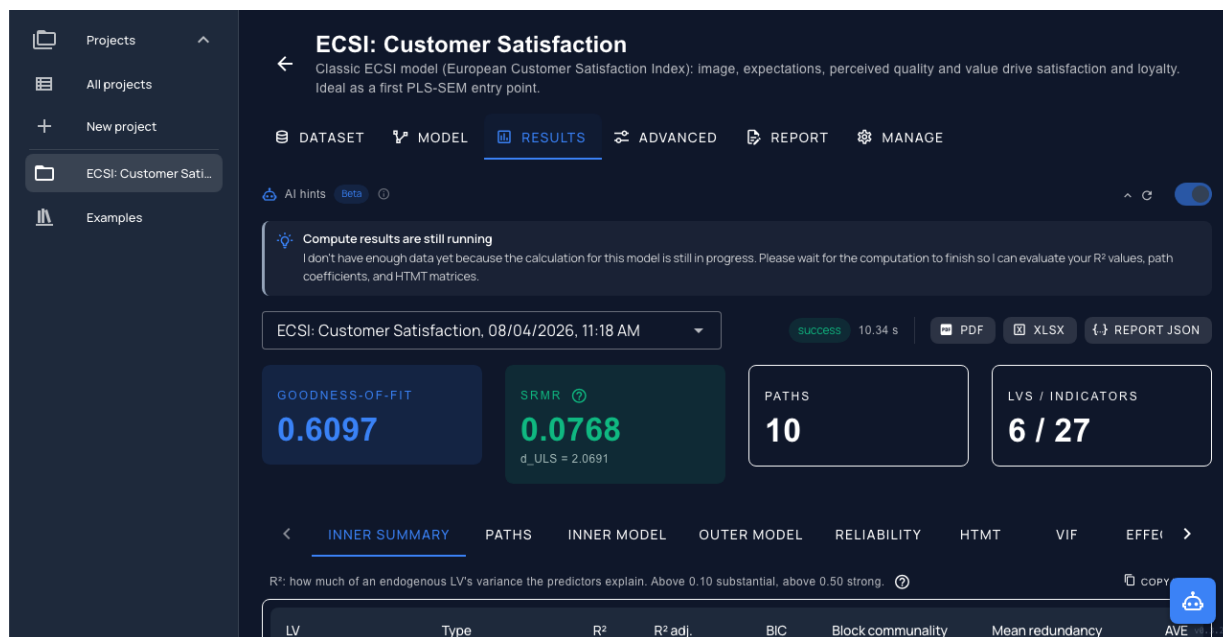


Figura 11 Aba Results: cards de KPI para goodness-of-fit, SRMR, contagem de caminhos, contagem de LV/MV. Abaixo deles, o detalhamento em abas: Inner Summary, Paths, Inner Model, Outer Model, Reliability, HTMT, VIF, Effect Sizes, IPMA.

3. **Paths:** a contagem de caminhos do modelo interno no modelo estimado.

4. **LVS / Indicators:** a contagem de variáveis latentes e o total de indicadores (MVs). Útil como verificação de sanidade ao comparar execuções.

Acima dos KPIs há um dropdown de seleção de resultado listando cada Compute anterior do modelo atual, com carimbo de tempo. Alterne entre Computes históricos sem sair da aba.

À direita do seletor estão os três botões de **export**:

- **PDF:** um relatório pronto para impressão (diagrama de caminho, tabelas, referências).
- **XLSX:** cada tabela de resultado em uma planilha, uma aba por métrica (Paths, Inner summary, Outer loadings, Reliability, HTMT, Fornell-Larcker, VIF, Effects, ...).
- **Report JSON:** um pacote JSON autocontido contendo o modelo, esquema do conjunto de dados e cada tabela de resultado. Ideal para material suplementar em um artigo: reexecute exatamente a mesma computação a partir do pacote depois.

5.2 Inner summary (padrão)

A tabela **Inner Summary** lista cada variável latente com:

- **R²:** variância da LV explicada por seus predecessores. 0,10 fraco, 0,25 moderado, 0,50 forte. LVs exógenas (sem predecessores) mostram 0.
- **R² adj.:** ajustado para o número de preditores. Prefira este quando comparar entre modelos.
- **BIC:** Bayesian Information Criterion para o modelo externo da LV. Menor é melhor; só é significativo entre especificações aninhadas.




Figura 12 A sub-aba Paths: cada caminho do modelo interno com sua estimativa, erro padrão, estatística t, p-valor e IC de 95%.

- **Block communality:** carga quadrada média dos indicadores da LV. Maior = mensuração mais forte.
- **Mean redundancy:** quanto da variância no bloco é “redundante” com os preditores da LV.
- **AVE:** Average Variance Extracted. Acima de 0,5 significa que a LV captura mais da variância dos seus indicadores do que o erro.

5.3 Paths

Altere para a sub-aba **Paths** (Figura 12) para a tabela de coeficientes estruturais.

Para cada caminho (origem → destino), a tabela lista:

- **Estimate:** o coeficiente de caminho padronizado. Interprete como um beta de uma regressão OLS.
- **Std. err.:** do Bootstrap.
- **t:** estimativa / erro padrão. Acima de 1,96 é significativo em $\alpha = 0,05$ em um teste bilateral.
- **p-value:** p do Bootstrap, correspondendo ao t.
- **95% CI (lower, upper):** IC do Bootstrap por percentil. Se ele exclui zero, o caminho é significativo.

Copie a versão pronta para LaTeX pelo pequeno ícone de cópia no canto superior direito da tabela.

5.4 Inner model / outer model

A aba **Inner model** reformula os caminhos em uma tabela mais larga com os pares de LV nas linhas. **Outer model** inverte: uma linha por indicador com sua LV, carga (Mode A) ou peso




Figura 13 A sub-aba HTMT: razões heterotrait-monotrait em uma matriz triangular. Células acima do limiar (0,85 conservador, 0,90 liberal) são destacadas.

(Mode B) e estatística t.

Interprete cargas: acima de 0,708 ($\sqrt{0,5}$) significa que a LV explica $\geq 50\%$ da variância do indicador. Cargas abaixo de 0,4 são candidatas à remoção; entre 0,4 e 0,7 mantenha somente se removê-las degradar o AVE.

5.5 Reliability

A aba Reliability mostra dois índices por LV mais dois diagnósticos em nível de bloco:

- **Cronbach's α** : o índice tradicional. Assume cargas tau-equivalentes; mais conservador.
- **Composite reliability (Dillon-Goldstein ρ)**: o padrão moderno do PLS-SEM. 0,7-0,9 aceitável, $> 0,95$ sugere indicadores redundantes.
- **1º / 2º autovalor**: da matriz de correlação do bloco. Uma lacuna clara entre eles (1º muito maior que 1, 2º ≈ 1) apoia a unidimensionalidade de um bloco reflexivo.

Vise $\alpha > 0,7$ e $\rho > 0,7$ em construtos reflexivos. Para construtos formativos, a confiabilidade não é significativa, verifique o VIF em vez disso.

A confiabilidade consistente de Dijkstra & Henseler (ρ_A) só é relatada quando você executa PLSc (ver Seção 6.6).

5.6 HTMT

A sub-aba **HTMT** (Figura 13) mostra a razão heterotrait-monotrait para cada par de construtos, com células vermelhas destacando valores acima do limiar de validade discriminante.

HTMT é o teste moderno de validade discriminante. Para cada par de construtos ele calcula a razão das correlações “heterotrait” (entre construtos) para as correlações “monotrait” (dentro

do construto). Se essa razão se aproxima de 1, os dois construtos são indistinguíveis.

Limiares:

- **< 0,85** (Henseler, Ringle & Sarstedt 2015, conservador), seguro
- **< 0,90** (Kline 2011, liberal), aceitável
- **≥ 0,90**: mescle os construtos, remova um, ou reinspecione os indicadores

O OpenPLS também executa uma versão via Bootstrap (HTMT-BST) que retorna um intervalo de confiança por par. Se o IC superior exclui 1,0, os construtos são demonstravelmente discriminantes.

5.7 VIF

Variance Inflation Factor. Duas variantes:

- **Outer VIF**: para indicadores dentro de uma LV formativa. Detecta redundância entre itens formativos; mantenha < 5 (< 3 mais estrito).
- **Inner VIF**: para LVs preditoras em cada bloco endógeno. Detecta colinearidade entre preditores; mesmos limiares.

5.8 Effects

Efeitos diretos, indiretos e totais para cada par origem → destino. Útil ao relatar mediação: o efeito direto é a seta que você desenhou, o efeito indireto é a soma de todos os caminhos através de LVs intervenientes, e o total é sua soma.

5.9 Ajuste do modelo

Abaixo da faixa de KPIs, o OpenPLS também mostra:

- **SRMR e dULS**: já abordados acima.
- **Fornell-Larcker matrix**: a alternativa clássica ao HTMT. Correlações quadradas fora da diagonal devem ser menores que $\sqrt{AVE}$ na diagonal para validade discriminante.

Entre HTMT e Fornell-Larcker, o HTMT é o diagnóstico mais recente e mais sensível. Relate ambos se seus revisores esperam qualquer um.

6 Métodos avançados

A aba **Advanced** é onde o OpenPLS vai além de uma execução PLS básica. Treze métodos ficam sob três grupos na navegação lateral:

- **Inferência**: Bootstrap, MGA, MICOM, Moderação, Validade nomológica
- **Robustez**: PLSc, Cópula gaussiana, Viés de método comum
- **Extensões do modelo**: IPMA, PLSpredict, CVPAT, FIMIX-PLS, Modelo de ordem superior




Figura 14 A aba Advanced: 13 métodos na navegação lateral, painel atual à direita.

Cada método segue o mesmo formato: configure as entradas no topo, clique em Run, aguarde o chip de status ficar verde, inspecione as tabelas de resultado abaixo. Cada execução anterior é preservada e selecionável no dropdown “Past runs” na parte inferior (Figura 14).

6.1 Bootstrap

Propósito. Calcular erros padrão, estatísticas t, p-valores e intervalos de confiança para cada coeficiente de caminho e carga externa. Também calcula intervalos bias-corrected accelerated (BCa) para efeitos de mediação (Figura 15).

Entradas.

1. **Iterations:** padrão 500, nível de publicação ≥ 5000 . Cada iteração reamostra com reposição e reestima o modelo, então o tempo de execução é aproximadamente linear neste número.
2. **Seed:** opcional, define o RNG. Defina uma semente se você precisa de erros padrão perfeitamente reproduzíveis.

Clique em **Start bootstrap** para iniciar. Executa em um serviço Cloud Run; o painel transmite progresso + ETA enquanto itera.

Interpretação. Para cada caminho, o Bootstrap fornece uma distribuição sobre B réplicas. Dessa distribuição, o OpenPLS calcula a estimativa média, SE, $t = \text{média}/\text{SE}$, p-valor e ICs por

AI hints

Beta

Run IPMA for Loyalty

Your R^2 for Loyalty = 0.51, making it a strong candidate for importance-performance matrix analysis. Run IPMA in the PLS-SEM software to contrast total effects against latent variable index values.

Evaluate PLSpredict for key endogenous targets

Your R^2 for Satisfaction = 0.71 and Loyalty = 0.51 exceed the 0.19 threshold. Run PLSpredict in the PLS-SEM software to generate case-level predictions and evaluate out-of-sample performance.

Check HTMT between Expectations and Perceived Quality

Your HTMT Expectations↔Perceived Quality = 0.98, signaling potential discriminant validity concerns. Consider treating these constructs as a higher-order construct in the PLS-SEM software.

Method-Selection Assistant

BETA

INFERENCE

AI hints

Beta

Bootstrap

Multi-group analysis

MICOM

Moderation

Nomological validity

ROBUSTNESS

PLSc

Gaussian copula

Common method bias

MODEL EXTENSIONS

IPMA

PLSpredict

CVPAT

FIMIX-PLS

Higher-order model

Evaluate Discriminant Validity Against HTMT Thresholds

Your HTMT between Expectations and Perceived Quality reaches 0.98, exceeding the conservative 0.85 threshold. Review indicator overlap for these latent variables before finalizing model inferences.

Check Fornell-Larcker Criterion Violations

Fornell-Larcker evaluation shows some latent variables share higher correlations with others than their own square root of AVE (e.g. Expectations and Perceived Quality). Inspect cross-loadings to ensure unidimensionality.

Assess Structural Path Significance and Effect Sizes

Your R^2 for Loyalty = 0.51 and Satisfaction = 0.71 show strong explanatory power, but paths like Expectations -> Satisfaction ($p = 0.97$) are non-significant. Consider trimming unsupported paths to streamline the structural model.

Bootstrap

Resampling with replacement for significance tests (t-values, p-values, confidence intervals). Runs on Cloud Run, typically 2-5 minutes for 5000 iterations.

Model

ECSI: Customer Satisfaction

Iterations

500

Confidence I...

95% ...

Seed

42

START BOOTSTRAP

Bootstrap runs

Run

500 iter., success, 2 min ago

success

500 iterations · $\alpha = 0.05$ · Seed 42 · 144.5s

Figura 15 Painel Bootstrap com contagem de iterações, semente e botão Run.

percentil.

6.2 Multi-Group Analysis (MGA)

Propósito. Testar se os coeficientes de caminho diferem entre grupos (mulheres vs. homens, UE vs. EUA, tratamento vs. controle) (Figura 16).

Entradas.

1. **Grouping variable:** uma coluna do conjunto de dados que divide a amostra. Colunas numéricas podem ser divididas por intervalo; colunas de string por valor.
2. **Groups:** um card por grupo. Para colunas de string, marque os valores que pertencem a cada grupo (por exemplo, Grupo A = {Automotive}, Grupo B = {Fashion}). Para colunas numéricas, defina mín/máx.
3. **Permutations:** 200 rápido, 1000 padrão, 5000+ para publicação. O MGA executa um teste baseado em permutação por caminho.

Interpretação. Para cada caminho, a tabela mostra a estimativa em cada grupo e um p-valor sob a hipótese nula “o caminho é igual entre os grupos”. Se $p < 0,05$, o efeito difere de forma significativa entre os grupos.

Sempre execute **MICOM** primeiro. Se a invariância de mensuração falhar na Etapa 2 (composicional), as LVs significam coisas diferentes em cada grupo, e comparar caminhos se torna sem sentido.

6.3 MICOM

Propósito. Testar a **Measurement Invariance of Composite Models** entre dois grupos. Pré-requisito para MGA/moderação entre grupos (Figura 17).

Entradas. Idênticas ao MGA, variável de agrupamento + exatamente dois grupos + contagem de permutações.

Interpretação. Veredicto em três etapas por construto:

1. **Invariância configural:** mesmos indicadores, mesmo algoritmo. Automaticamente satisfeita pelo OpenPLS.
2. **Invariância composicional:** os escores compostos de cada LV se correlacionam próximo a 1 entre os grupos. Um p-valor $< 0,05$ significa que os compostos são significativamente diferentes, pare, os resultados do MGA não são interpretáveis.
3. **Invariância escalar:** as médias e variâncias dos compostos são iguais. Se ambas as Etapas 2 e 3 passam: **invariância completa**. Se apenas a Etapa 2 passa: **invariância parcial**: o MGA ainda é válido para comparar caminhos, apenas não para comparar médias latentes.

AI hints Beta

Run IPMA for Brand Loyalty

Your R^2 for Brand Loyalty = 0.29, making it a strong target construct for the Importance-Performance Map Analysis. Use the advanced tab to run IPMA and identify which experiential dimensions drive loyalty most efficiently.

Evaluate out-of-sample prediction with PLSpredict

With endogenous R^2 values above 0.19 across Brand Loyalty (0.29), Brand Personality (0.24), and Brand Satisfaction (0.24), your model meets the criteria for predictive relevance. Set up PLSpredict in the advanced tab to test case-level indicator predictions.

Test for unobserved heterogeneity using FIMIX-PLS

Your sample size of $n = 380$ provides adequate statistical power to detect unobserved customer segments. Run FIMIX-PLS in the advanced tab to check whether latent segments affect your structural paths.

Method-Selection Assistant BETA

INFERENCE

Bootstrap

Multi-group analysis

MICOM

Moderation

Nomological validity

ROBUSTNESS

PLSc

Gaussian copula

Common method bias

MODEL EXTENSIONS

IPMA

PLSpredict

CVPAT

FIMIX-PLS

Higher-order model

AI hints Beta

Use category column for grouping

Your dataset contains the column category with 380 rows, making it suitable for multi-group analysis in the PLS-SEM software. Check its unique levels to ensure each subgroup meets the minimum sample size of $n > 30$ before splitting.

Run measurement invariance testing first

Before comparing path coefficients across your groups, run the MICOM procedure in the PLS-SEM software to establish measurement invariance. Without configural and compositional invariance, group comparisons lack validity.

Target strong structural paths for group comparison

Your results show a strong path from Brand Satisfaction to Brand Loyalty with estimate = 0.54, and Affective Experience to Brand Personality with estimate = 0.30. These high-impact paths are prime candidates to test for group differences in the MGA tab.

Multi-Group Analysis (MGA)

Compares path coefficients between two or more groups using Henseler's permutation test.

Model

Brand Experience (Brakus & Schmitt)

Grouping variable

category (string)

Groups

Name

Group 1

Values (multi-select)

Automotive

Name

Group 2

Values (multi-select)

Fashion

Permutations

200

COMPUTE MGA

Previous MGA runs

Run

category · 200 permutations · 2 min ago

success

Column: category · Iterations: 200 · Duration: 141.3s

Path coefficients per group

Figura 16 O painel MGA: escolha uma coluna de agrupamento, defina um card por grupo, defina a contagem de permutações.

AI hints

Beta

Run IPMA for Brand Loyalty

Your R^2 for Brand Loyalty = 0.29. Run Importance-Performance Map Analysis in the PLS-SEM software to identify which experience dimensions drive loyalty relative to their performance.

Evaluate PLSpredict for Endogenous Constructs

Your endogenous constructs have meaningful R^2 values, such as Brand Loyalty at 0.29 and Brand Satisfaction at 0.24. Run PLSpredict in the PLS-SEM software to assess out-of-sample predictive relevance using case-level RMSE or MAE values.

Test for Unobserved Heterogeneity via FIMIX-PLS

Your sample size is $n = 380$, which easily clears the threshold for segmentation analysis. Run FIMIX-PLS in the PLS-SEM software to test if unobserved heterogeneity affects your path coefficients.

Method-Selection Assistant

BETA

INFERENCE

Bootstrap

Multi-group analysis

MICOM

Moderation

Nomological validity

ROBUSTNESS

PLSc

Gaussian copula

Common method bias

MODEL EXTENSIONS

IPMA

PLSpredict

CVPAT

FIMIX-PLS

Higher-order model

MICOM – Measurement Invariance

Three-step test (configural, compositional, scalar) that constructs are measured equivalently across two groups before running MGA or moderation.

Step 1 (Configural) same indicators, same algorithm, same data treatment in both groups — auto-satisfied by OpenPLS.

Step 2 (Compositional) the composite scores from group A and group B must correlate close to 1. A p-value below 0.05 means measurement is not comparable.

Step 3 (Scalar) given Step 2 holds, composite means and variances must be equal across groups. If both pass: full invariance. If only Step 2 passes: partial invariance — MGA is still valid for path comparison.

Model

Brand Experience (Brakus & Schmitt)

Grouping variable

category (string)

Groups (exactly two)

Group A

Group 1

Values (multi-select)

Automotive

Group B

Group 2

Values (multi-select)

Fashion

Permutations

200

COMPUTE MICOM

Previous MICOM runs

Run

category · Group 1 vs. Group 2 · 1 min ago

Figura 17 Painel MICOM: mesma UI de coluna de agrupamento e definição de grupo que MGA.

6.4 Moderação

Propósito. Testar se o efeito de X sobre Y depende de um moderador Z. Usa a abordagem em duas etapas (Henseler & Chin 2010) (Figura 18).

Entradas.

1. **Predictor (independent):** o X em $Y = X + Z + X \times Z$.
2. **Moderator:** o Z.
3. **Target (dependent):** o Y.
4. **Interaction LV name:** opcional, o padrão é X_x_Z .

Interpretação. O OpenPLS refita o modelo com uma LV de interação adicional (produto dos escores compostos do preditor e do moderador). A linha **interaction effect** é o resultado principal: se seu p-valor $< 0,05$, o moderador altera a relação $X \rightarrow Y$.

O gráfico de **simple slopes** abaixo das tabelas visualiza isso: $X \rightarrow Y$ em valores baixos ($M - 1$ DP), média e altos ($M + 1$ DP) do moderador. Se as inclinações se abrem em leque, o moderador amplifica X; se convergem, ele atenua.

6.5 Validade nomológica

Propósito. Verificar se cada caminho hipotetizado saiu com o sinal e significância esperados. Verificação de sanidade antes de escrever os resultados.

Entradas. Preenchidas automaticamente pelo seu modelo; cada caminho vira uma linha com um toggle **expected sign**: + para “hipotetizado positivo” ou – para “hipotetizado negativo”. Defina o sinal para cada hipótese, escolha o nível de significância α (padrão 0,05) e clique em Run test.

Interpretação. Para cada hipótese, a tabela mostra o sinal estimado, o p-valor do último Bootstrap e um veredicto (pass / fail) contra o seu sinal esperado em α . Falhas são candidatas para reexaminar ou para relatar como achados nulos.

6.6 PLSc

Propósito. Estimção PLS consistente. Corrige o viés de atenuação do PLS padrão quando os construtos são verdadeiramente common-factor em vez de composite (Figura 19).

Entradas. Nenhuma, clique em Run.

Interpretação. Reexecuta exatamente o mesmo modelo com a correção PLSc aplicada. Os coeficientes de caminho tipicamente se afastam ligeiramente de zero (a correção corrige o viés da atenuação por confiabilidade finita). Relate tanto PLS padrão quanto PLSc se os revisores esperam interpretação baseada em fatores.

Válido apenas quando. Todas as LVs são Mode A (reflexivas). LVs Mode B quebram a suposição do PLSc.

Simple slopes

28

Method-Selection Assistant BETA

INFERENCE

Bootstrap

Multi-group analysis

MICOM

Moderation

Nomological validity

ROBUSTNESS

PLSc

Gaussian copula

Common method bias

MODEL EXTENSIONS

IPMA

PLSpredict

CVPAT

FIMIX-PLS

Higher-order model

PLSc – Consistent PLS

Bias-corrected estimates for reflective constructs (Dijkstra & Henseler 2015). Returns ρ_A , dis-attenuated correlations, and corrected paths/loadings.

Model

ECSI: Customer Satisfaction

COMPUTE PLSc

Past runs

Run

PLSc · just now

success

PLSc stability warning

Maximum dis-attenuated correlation is 0.976 (≥ 0.85 ; Henseler/Ringle/Sarstedt 2015 HTMT threshold).

Maximum inner VIF is 56.68 (≥ 10 ; severe collinearity, Hair et al. 2022).

Under these conditions PLSc can return corrected paths outside $[-1, 1]$. Consider merging the highly-correlated constructs, modelling them as a higher-order construct, or dropping one.

SRMR: 0.061

d_ULS: 1296

Reliability per construct

LV	ρ_A	ρ_C	AVE	R^2	R^2 adj.	BIC
Image	0.858	0.830	0.503	—	—	—
Expectations	0.855	0.847	0.527	0.427	0.425	-129.38
Perceived Quality	0.878	0.872	0.578	0.952	0.952	-750.91
Perceived Value	0.853	0.835	0.563	0.861	0.859	-476.90
Satisfaction	0.891	0.896	0.596	0.877	0.871	-489.66

Figura 19 Painel PLSc, um clique em modelos com apenas LVs Mode A.

29

Method-Selection Assistant

INFERENCE

Bootstrap

Multi-group analysis

MICOM

Moderation

Nomological validity

ROBUSTNESS

PLSc

Gaussian copula

Common method bias

MODEL EXTENSIONS

IPMA

PLSpredict

CVPAT

FIMIX-PLS

Higher-order model

Gaussian copula – endogeneity test

Park & Gupta (2012) / Hult et al. (2018): tests whether a predictor correlates with the error term (endogeneity) and returns endogeneity-corrected path estimates.

Model

ECSI: Customer Satisfaction

Endogenous LV

Satisfaction

Suspected predictors (optional)

200

Bootstrap resamples

42

Seed (optional)

Leave empty to test all predecessors.

COMPUTE COPULA TEST

Past runs

Run

Endo=Satisfaction · just now

success Endogenous LV: Satisfaction · Bootstrap resamples = 200

Copula coefficients per predictor

Predictor	γ (copula term)	SE	t	p	CvM p (non-norm.)	Decision
Image	-0.020	0.226	-0.088	0.930	0.042	no endogeneity detected
Expectations	0.133	0.226	0.591	0.554	0.077	copula not admissible (normal)
Perceived Quality	0.122	0.364	0.334	0.738	0.044	no endogeneity detected
Perceived Value	-0.400	0.255	-1.569	0.117	0.010	no endogeneity detected

Endogeneity-corrected path estimates

COPY CSV

Figura 20 O painel Copula: seletor de LV endógena, reamostragens Bootstrap.

6.7 Cópula gaussiana (endogeneidade)

Propósito. Testar se um preditor é endógeno (correlacionado com o termo de erro). Se sim, retornar estimativas corrigidas para endogeneidade pela abordagem de Park & Gupta (2012) / Hult et al. (2018) (Figura 20).

Entradas.

1. **Endogenous LV:** escolha a LV cujos preditores você suspeita estarem correlacionados com o termo de erro.
2. **Suspected predictors:** opcional; deixe vazio para testar todos os predecessores da LV endógena.
3. **Bootstrap resamples:** padrão 500, aumente para 1000-5000 para ICs em nível de publicação.
4. **Seed:** opcional.

Interpretação. Para cada preditor suspeito, o OpenPLS relata um coeficiente γ do termo de cópula, seu p-valor e um p de CvM (Cramér-von Mises) para não-normalidade do preditor (exigido pelo método). A tabela de augmented-paths mostra os coeficientes corrigidos se o termo de cópula for significativo.

Válido apenas quando. Os preditores são não normais. Se o p de CvM de um preditor for $> 0,10$, a correção por cópula não pode ser confiada.

6.8 Viés de método comum (CMB, Lindell-Whitney)

Propósito. Detectar viés de método via o procedimento de variável marcadora de Lindell & Whitney (2001) (Figura 21).

Entradas.

1. **Marker variable:** uma coluna numérica teoricamente não relacionada que NÃO é um indicador de nenhuma LV no modelo. Exemplos: uma variável demográfica como `tenure_years` ou `age`.
2. **Significance α :** padrão 0,05.

Interpretação. O OpenPLS remove a menor correlação observada marcador-LV de cada correlação entre construtos e relata quais caminhos perdem significância. Caminhos que passam de significativos a não significativos são suspeitos de inflação por método comum.

Válido apenas quando. Seu conjunto de dados tem uma coluna numérica fora do modelo. Caso contrário, escolha uma amostra diferente ou execute o teste de fator único de Harman manualmente.

6.9 IPMA

Propósito. Importance-Performance Map Analysis. Responde “quais construtos importam mais para o alvo e quais deles estão com baixo desempenho?” (Figura 22)

Entradas.

1. **Target LV:** geralmente o resultado que você quer estudar (Loyalty, Adoption, ...).

Interpretação. Para cada predecessor do alvo, o OpenPLS calcula:

- **Importance** = efeito total (direto + indireto) sobre o alvo
- **Performance** = média do escore composto da LV, redimensionada para 0-100

Plotado como um scatter (Performance no x, Importance no y). Superior esquerdo = alta importância, baixo desempenho = a maior alavanca de melhoria. Superior direito = ambos altos = forças a preservar.

Method-Selection Assistant

BETA

INFERENCE

Bootstrap

Multi-group analysis

MICOM

Moderation

Nomological validity

ROBUSTNESS

PLSc

Gaussian copula

Common method bias

MODEL EXTENSIONS

IPMA

PLSpredict

CVPAT

FIMIX-PLS

Higher-order model

Common method bias (Lindell-Whitney)

Marker-variable procedure: partial out the smallest marker-LV correlation and check which path correlations lose significance (Lindell & Whitney 2001).

Model

Employee Engagement (JD-R)

Marker variable

tenure_years (numeric)

Significance level (α)

0.05

RUN TEST

A theoretically unrelated numeric column from the dataset. Cannot be an indicator of any LV in the model.

Past runs

Run

tenure_years · just now

success

Marker variable: tenure_years · $r_M = 0.003$ · $\alpha = 0.05$

Marker-variable correlations

LV	$r(\text{marker, LV})$
Job Resources	0.003
Job Demands	-0.133
Work Engagement	-0.065
Job Satisfaction	0.010
Job Performance	-0.047

Pairwise LV correlations before / after adjustment

COPY LATEX

LV pair	r (unadjusted)	p (unadjusted)	r (adjusted)	p (adjusted)	Verdict
Job Resources ↔ Job Demands	0.060	0.265	0.057	0.287	unchanged
Job Resources ↔ Work Engagement	0.538	< 0.001	0.536	< 0.001	unchanged
Job Resources ↔ Job Satisfaction	0.466	< 0.001	0.464	< 0.001	unchanged
Job Resources ↔ Job Performance	0.375	< 0.001	0.374	< 0.001	unchanged
Job Demands ↔ Work Engagement	-0.174	0.001	-0.177	< 0.001	unchanged

Figura 21 Painel CMB: escolha uma coluna marcadora e execute.

Method-Selection Assistant

BETA

INFERENCE

Bootstrap

Multi-group analysis

MICOM

Moderation

Nomological validity

ROBUSTNESS

PLSc

Gaussian copula

Common method bias

MODEL EXTENSIONS

IPMA

PLSpredict

CVPAT

FIMIX-PLS

Higher-order model

Importance-Performance Map (IPMA)

Identify constructs and indicators with high importance but low performance, prime levers for improvement.

Model

ECSI: Customer Satisfaction

Target latent variable

Expectations

Endogenous LV whose drivers you want to rank.

Scale minimum (optional)

Scale maximum (optional)

Rescales indicator scores to a 0, 100 performance index. Defaults to data min/max.

RUN IPMA

Past IPMA runs

Run

Expectations · just now

success

Target latent variable: Expectations

Latent-variable importance / performance

LV	Importance (total effect)	Performance (0-100)
Image	0.579	73.36

Indicator-level breakdown

LV	Indicator	Outer weight	Normalized weight
Image	imag1	0.098	0.146
	imag2	0.157	0.234
	imag3	0.157	0.233
	imag4	0.077	0.114
	imag5	0.184	0.274
Expectations	expe1	0.106	0.176
	expe2	0.141	0.233
	expe3	0.119	0.197
	expe4	0.099	0.165
	expe5	0.138	0.229
Perceived Quality	qual1	0.107	0.187
	qual2	0.135	0.236
	qual3	0.117	0.206
	qual4	0.096	0.168
	qual5	0.116	0.203
Perceived Value	val1	0.175	0.302

Figura 22 Painel IPMA: escolha a LV alvo, execute.

6.10 PLSpredict

Propósito. Avaliar a relevância preditiva **fora da amostra**. R^2 é dentro da amostra; PLSpredict diz se o modelo generaliza (Figura 23).

Entradas.

1. **k-fold**: padrão 10. Maior = folds de teste menores.
2. **Repeats**: padrão 1. Aumente para 10+ para promediar sobre diferentes atribuições de fold e reduzir variância.
3. **Seed**: para reprodutibilidade.

Interpretação. Para cada indicador, a tabela lista:

- **Q^2_{predict}** : R^2 preditivo validado cruzadamente. Acima de 0 significativo; maior é melhor.
- **RMSE_PLS** vs. **RMSE_LM**: previsões PLS vs. um benchmark linear. Se o RMSE do PLS é menor para a maioria dos indicadores, o PLS tem valor preditivo além da alternativa linear.

6.11 CVPAT

Propósito. Cross-Validated Predictive Ability Test. Compara o modelo PLS contra um benchmark (média do indicador ou modelo linear) via um teste t sobre a perda fora da amostra (Figura 24).

Entradas. Benchmark + k-fold + repetições + semente. Os padrões são seguros.

Interpretação. Para cada LV endógena, o OpenPLS relata a diferença de perda (PLS – benchmark) com um p-valor. Diferença de perda negativa + $p < 0,05$ = PLS prevê melhor que o benchmark, uma afirmação forte.

6.12 FIMIX-PLS

Propósito. Finite-Mixture PLS. Descobre classes latentes de respondentes quando você suspeita de heterogeneidade mas não conhece o agrupamento (Figura 25).

Entradas.

1. **Number of classes (K)**: tente 2..5, compare os critérios de ajuste.
2. **EM restarts**: melhor de n inícios aleatórios. Mais = mais robusto.
3. **Max iterations, tolerance**: controles de convergência; deixe os padrões.

Interpretação. Para cada K, o OpenPLS estima caminhos específicos por classe + uma proporção de mistura ρ por classe. Compare **AIC**, **BIC**, **CAIC** e **entropy (EN)** entre valores de K, o cotovelo no BIC combinado com $EN > 0,6$ identifica o K “certo”.

Uma vez decidido o K, exporte as atribuições de classe e reexecute o PLS padrão por classe para inferência detalhada. Ou use-as como um agrupamento no MGA.

Method-Selection Assistant

INFERENCE

Bootstrap

Multi-group analysis

MICOM

Moderation

Nomological validity

ROBUSTNESS

PLSc

Gaussian copula

Common method bias

MODEL EXTENSIONS

IPMA

PLSpredict

CVPAT

FIMIX-PLS

Higher-order model

PLSpredict

k-fold cross-validated out-of-sample predictive power vs. a linear-model benchmark (Shmueli et al. 2019).

Model

ECSI: Customer Satisfaction

Folds (k)

10

Repeats

1

Seed (optional)

42

Number of cross-validation folds. Common: 5 or 10.

Repeat the k-fold procedure with different splits and average.

RUN PLSPREDICT

Past runs

Run

k=10, no predictive power · just now

success

Overall verdict: no predictive power

k = 10 · Repeats: 1

0 better than LM · 22 worse · 0 tie · 22 total

Indicator summary

Out-of-sample (k-fold cross-validation).

LV	Indicator	RMSE (PLS)	MAE (PLS)	MAPE (PLS)	RMSE (LM)	MAE (LM)	MAPE (LM)	Q ² _PLS
Expectations	expe1	1.832	1.400	27.6%	1.808	1.362	26.4%	
Expectations	expe2	1.953	1.433	31.8%	1.876	1.383	29.4%	
Expectations	expe3	2.121	1.637	36.1%	2.080	1.612	34.3%	
Expectations	expe4	1.536	1.165	17.4%	1.489	1.161	17.1%	
Expectations	expe5	2.081	1.654	32.9%	2.055	1.596	30.6%	
Perceived Quality	qual1	1.903	1.462	23.1%	1.341	1.062	16.6%	
Perceived Quality	qual2	2.068	1.602	25.4%	1.337	1.059	16.3%	
Perceived Quality	qual3	2.201	1.727	36.0%	1.622	1.197	22.0%	
Perceived Quality	qual4	1.619	1.254	21.2%	1.222	0.987	16.0%	
Perceived Quality	qual5	1.971	1.527	32.3%	1.433	1.086	19.3%	
Perceived Value	val1	1.949	1.496	24.9%	1.540	1.149	18.5%	
Perceived Value	val2	1.682	1.245	20.4%	1.560	1.144	17.4%	

Figura 23 Painel PLSpredict: k-fold, repetições, semente.

Method-Selection Assistant

BETA

INFERENCE

Bootstrap

Multi-group analysis

MICOM

Moderation

Nomological validity

ROBUSTNESS

PLSc

Gaussian copula

Common method bias

MODEL EXTENSIONS

IPMA

PLSpredict

CVPAT

FIMIX-PLS

Higher-order model

CVPAT (Cross-Validated Predictive Ability Test)

Compare PLS out-of-sample predictions against an indicator-average or linear-model benchmark using a paired t-test (Liengaard et al. 2021).

Model

ECISI: Customer Satisfaction

Benchmark

IA (indicator average)

Choose which benchmark the PLS model is compared against.

Folds (k)

10

Repeats

1

Seed

42

Significance level (α)

0.05

RUN CVPAT

Past runs

Run

IA, k=10 · just now

success

Benchmark: IA · k = 10 · repeats = 1 · α = 0.05

Overall test

COPY LATEX

n	Loss (PLS)	Loss (benchmark)	Δ (PLS - benchmark)	t	p (1-sided)	Verdict
250	83.605	100.920	-17.315	-6.62	< 0.001	PLS better

Per-construct test

COPY LATEX

LV	Loss (PLS)	Loss (benchmark)	Δ (PLS - benchmark)	p (1-sided)	Verdict
Expectations	18.358	21.673	-3.315	< 0.001	PLS better
Loyalty	19.269	23.292	-4.023	< 0.001	PLS better
Perceived Quality	19.254	23.063	-3.809	< 0.001	PLS better
Perceived Value	14.631	17.481	-2.850	< 0.001	PLS better

Figura 24 Painel CVPAT: seletor de benchmark (IA = indicator average, LM = linear model), k-fold, repetições.

Method-Selection Assistant

BETA

INFERENCE

Bootstrap

Multi-group analysis

MICOM

Moderation

Nomological validity

ROBUSTNESS

PLSc

Gaussian copula

Common method bias

MODEL EXTENSIONS

IPMA

PLSpredict

CVPAT

FIMIX-PLS

Higher-order model

FIMIX-PLS segmentation

Finite-mixture EM detection of unobserved latent classes (Hahn et al. 2002).

Model

ECSI: Customer Satisfaction

Number of classes (K)

3

EM restarts

5

Max iterations

500

Convergence tolerance

0.000001

Seed (optional)

42

RUN FIMIX

Past runs

Run

K = 3 · just now

success K = 3

Log-likelihood: -1068.66

Parameters: 62

Class sizes (mixing proportions ρ)

COPY CSV

Class	ρ (proportion)	n (hard-assigned)
1	0.320	91
2	0.286	73
3	0.394	8

Per-class structural-model paths

Class

Class 1

Per-class structural-model paths

COPY CSV

Path	Estimate
(intercept) → Expectations	-0.349
Image → Expectations	1.012
(intercept) → Perceived Quality	0.285
Expectations → Perceived Quality	0.945
(intercept) → Perceived Value	0.193
Expectations → Perceived Value	0.385
Perceived Quality → Perceived Value	0.456

Figura 25 Painel FIMIX: número de classes, reinícios EM, tolerância.

6.13 Construto de ordem superior (HOC)

Propósito. Combinar múltiplas LVs de primeira ordem em um único construto de segunda ordem por meio da abordagem disjoint em duas etapas (Sarstedt et al. 2019) (Figura 26).

Entradas.

1. **Name:** o nome da LV do HOC, por exemplo, BrandExperience.
2. **First-order LVs:** os componentes a combinar (pelo menos 2).
3. **HOC mode:** A (reflexivo) ou B (formativo).

Interpretação. O OpenPLS executa a etapa 1 (PLS normal para obter escores das LVs de primeira ordem), então a etapa 2 (um novo PLS com o HOC no lugar das quatro dimensões). Relata:

- **Loadings:** LVs de primeira ordem sobre o HOC (Mode A) ou pesos (Mode B).
- **R² (etapa 2):** variância dos alvos subsequentes do HOC explicada.
- **Paths (etapa 2):** coeficientes estruturais no modelo reestimado.

Compare Mode A vs. Mode B refitando com o outro modo e verificando qual produz confiabilidade e caminhos mais limpos.

Method-Selection Assistant

BETA

INFERENCE

Bootstrap

Multi-group analysis

MICOM

Moderation

Nomological validity

ROBUSTNESS

PLSc

Gaussian copula

Common method bias

MODEL EXTENSIONS

IPMA

PLSpredict

CVPAT

FIMIX-PLS

Higher-order model

Higher-order construct (HOC)

Disjoint two-stage approach (Sarstedt et al. 2019): combines multiple first-order LVs into a higher-order construct and re-estimates the structural model.

Model

Brand Experience (Brakus & Schmitt)

Higher-order construct name

BrandExperience

First-order LVs

Sensory Experience

Affective Experience

Intellectual Experience

Behavioral Experience

HOC mode

Mode A (reflective)

Select at least two LVs to combine into the HOC.

COMPUTE HOC

Past runs

Run

BrandExperience · Mode A · just now

success

BrandExperience ← Sensory Experience, Affective Experience, Intellectual Experience, Behavioral Experience · Mode A (reflective)

First-order loadings on the HOC

COPY

First-order LV	Loading
Sensory Experience	0.514
Affective Experience	0.730
Intellectual Experience	0.443
Behavioral Experience	0.409

R² (stage 2)

COPY

CSV

LV	R ²
Brand Loyalty	0.290
Brand Personality	0.238
Brand Satisfaction	0.222
BrandExperience	0.000

Path coefficients (stage 2)

COPY

CSV

Path	Estimate
BrandExperience → Brand Personality	0.488

Figura 26 Painel HOC: nomeie o HOC, escolha 2+ LVs de primeira ordem, escolha Mode A ou B.

7 Exportações

Cada resultado no OpenPLS pode sair da ferramenta em um dos quatro formatos. Os botões de exportação ficam no cabeçalho da aba Results, acima dos cards de KPI, e também estão disponíveis no dropdown de exportação de modelo na barra de ferramentas do Editor.

7.1 Relatório PDF

O que você recebe. Um PDF pronto para impressão com:

- Capa com metadados do modelo + conjunto de dados
- Diagrama de caminho (renderizado a partir das posições atuais do Editor)
- Cada tabela de resultado da aba Results, formatada para impressão
- Referências aos métodos do OpenPLS (cada métrica cita o artigo que a definiu)

Quando usar. Anexar a uma submissão de artigo, compartilhar com um colaborador não técnico, incluir em uma apresentação de slides.

Nome do arquivo. {model_name}_report.pdf, higienizado para remover espaços e barras.

7.2 Planilha Excel (XLSX)

O que você recebe. Uma planilha com uma aba por tabela de resultado. Nomes das abas conforme aparecem no arquivo:

- Overview, metadados da execução (tempo de computação, GoF, SRMR, contagem de LV/caminhos)
- Inner Summary, R^2 , R^2 ajustado, AVE, comunalidade por LV
- Model Fit, SRMR + d_ULS (somente quando computados)
- Path Coefficients, estimativas para cada caminho do modelo interno
- Inner Model, com SE do Bootstrap, t, p, IC quando disponíveis
- Outer Model, cargas (Mode A) ou pesos (Mode B) por indicador
- Effect Sizes f^2 , tamanhos de efeito diretos para cada caminho preditor
- Predictive Relevance Q^2 , redundância validada cruzadamente por LV
- VIF, Outer e VIF, Inner, colinearidade
- HTMT, matriz heterotrait-monotrait
- Reliability, α de Cronbach, confiabilidade composta, autovalores
- Model, LVs e Model, Paths, a própria especificação do modelo

Abas condicionais, adicionadas somente quando a execução avançada correspondente existe:

- Nomological Validity, sinal + veredicto por hipótese
- CMB (Lindell-Whitney), correlações corrigidas por marcador
- CVPAT, teste de habilidade preditiva validada cruzadamente

Quando usar. Revisor quer números brutos, ou você quer reformatar tabelas no estilo da casa do seu artigo.

Nome do arquivo. `{model_name}_results.xlsx`.

7.3 Pacote Report JSON

O que você recebe. Um JSON autocontido com:

- Especificação completa do modelo (LVs, indicadores, caminhos, posições, modo de mensuração)
- Esquema do conjunto de dados (nomes de coluna, tipos, contagens ausentes)
- Cada tabela de resultado verbatim
- Metadados de computação (timestamp, duração, versão do OpenPLS)

Quando usar. Como **material suplementar** para um artigo. Qualquer pessoa que importe o JSON pode inspecionar exatamente o que você estimou sem executar o OpenPLS.

Nome do arquivo. `{model_name}.report.json`.

7.4 Exportação de modelo (barra de ferramentas do Editor)

A barra de ferramentas do Editor tem um ícone de **download** que abre um menu com dois formatos de exportação somente do modelo:

- **JSON (.openpls.json):** modelo OpenPLS completo incluindo posições. Vai e volta: você pode importá-lo em outro projeto do OpenPLS para reutilizar o modelo com um conjunto de dados diferente.
- **SmartPLS (.splsm):** um arquivo XML compatível com SmartPLS 3 e 4. Permite entregar o modelo a um colaborador nessa ferramenta.

Estes são somente do modelo; não contêm resultados. Use o pacote Report JSON para isso.

7.5 Snippets LaTeX

Cada tabela de resultado na aba Results tem um pequeno ícone **Copy LaTeX** no canto superior direito. Clique nele, cole diretamente no código-fonte `.tex` do seu artigo. O LaTeX gerado usa `booktabs` (`\toprule`, `\midrule`, `\bottomrule`) e corresponde ao estilo convencional de tabelas em JMS, MIS Quarterly e revistas similares.

Os snippets LaTeX incorporam o nome do modelo, nome do conjunto de dados e versão do OpenPLS na legenda da tabela para rastreabilidade. Ajuste a legenda no seu artigo se quiser um visual mais limpo.

7.6 Reprodutibilidade

Para um artigo, o pacote ideal de reprodutibilidade é:

1. O **Report JSON** (resultados e modelo + esquema do conjunto de dados).

2. O **conjunto de dados bruto** (um arquivo suplementar, se o licenciamento permitir).
3. Uma breve nota apontando para `openpls.app` para a estimacão.

Qualquer leitor pode então reexecutar exatamente a mesma computacão sem depender da sua instalacão local.

Os valores exportados são os mesmos números que você vê na aba Results. Comparacões contra SmartPLS em conjuntos de dados PLS-SEM publicados estão em andamento; os resultados mais recentes estão vinculados em `openpls.app/validation`.

8 Colaboração

O OpenPLS trata os projetos como espaços de trabalho compartilháveis. Convide coautores, assistentes de pesquisa ou revisores para visualizar ou editar o mesmo modelo. Cada açã deixa uma trilha de auditoria para que você possa ver quem fez o quê e quando.

Tudo relacionado à colaboracão fica em **Manage** na faixa de abas. Três sub-visões: **Team**, **Activity**, **Settings**.

8.1 O painel da equipe

Abra **Manage** → **Team** para chegar ao painel mostrado na Figura 27.

Três seções empilhadas:

1. **Team**: cada membro atual com seu nome, e-mail, avatar e pílula de papel. O proprietário (criador do projeto) é marcado. À direita de cada linha estão as ações de mudanç de papel e remocão. A açã de remocão só é visível para o proprietário.
2. **Invite person**: input de e-mail + dropdown de papel + botão Invite. Envia um e-mail de convite assinado via Resend. O destinatário pode aceitar via um link que abre `/invitations/{id}`.
3. **Pending invitations**: um card por convite pendente com o e-mail convidado, timestamp e uma açã **Revoke**.

8.2 Papéis

Três papéis:

- **Owner**: criador, pode fazer tudo, inclusive excluir o projeto.
- **Editor**: pode editar o conjunto de dados, o modelo, executar computacões, executar métodos avançados, editar configuracões. Não pode excluir o projeto ou convidar novos membros (somente o proprietário pode).
- **Viewer**: somente leitura. Vê cada resultado e exportacão, não pode alterar nada.

Mudanças de papel entram em vigor imediatamente e aparecem no log de atividade.

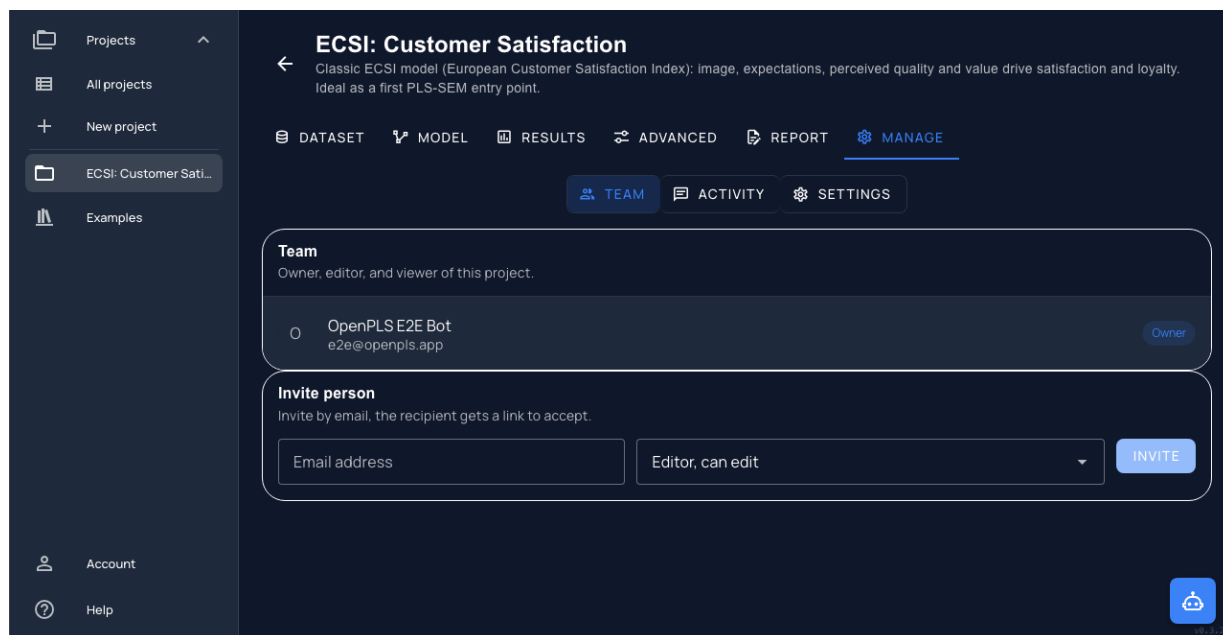


Figura 27 A sub-visão Team: lista de membros no topo, formulário de convite abaixo, convites pendentes na parte inferior.

8.3 Enviando um convite

1. Digite o e-mail do convidado no campo **Email address**.
2. Escolha o papel: **Editor, can edit** ou **Viewer, read only**.
3. Clique em **Invite**.

O OpenPLS cria uma entrada de convite no banco de dados e envia ao convidado um e-mail com o link de aceitação. Se o endereço de e-mail já pertencer a um usuário OpenPLS, o convite chega diretamente na rota `/invitations` dessa pessoa.

Copiar link do convite. Cada card de convite pendente tem um ícone “Copy link” que coloca a URL de aceitação na área de transferência, útil quando os filtros de e-mail do destinatário são agressivos.

Revogando. Clique em **Revoke** em um card pendente. O convite se torna inválido; o link de aceitação não funciona mais.

Usuários convidados que ainda não têm conta no OpenPLS podem criar uma via o fluxo de aceitação (o e-mail deles é pré-preenchido). O convite guarda o lugar deles até que aceitem, sem necessidade de cadastrar-se primeiro e ser convidado novamente.

8.4 O log de atividade

Alterne para a sub-visão **Activity** (Figura 28) para a trilha de auditoria.

O backend registra uma entrada por evento. Eventos atualmente emitidos:

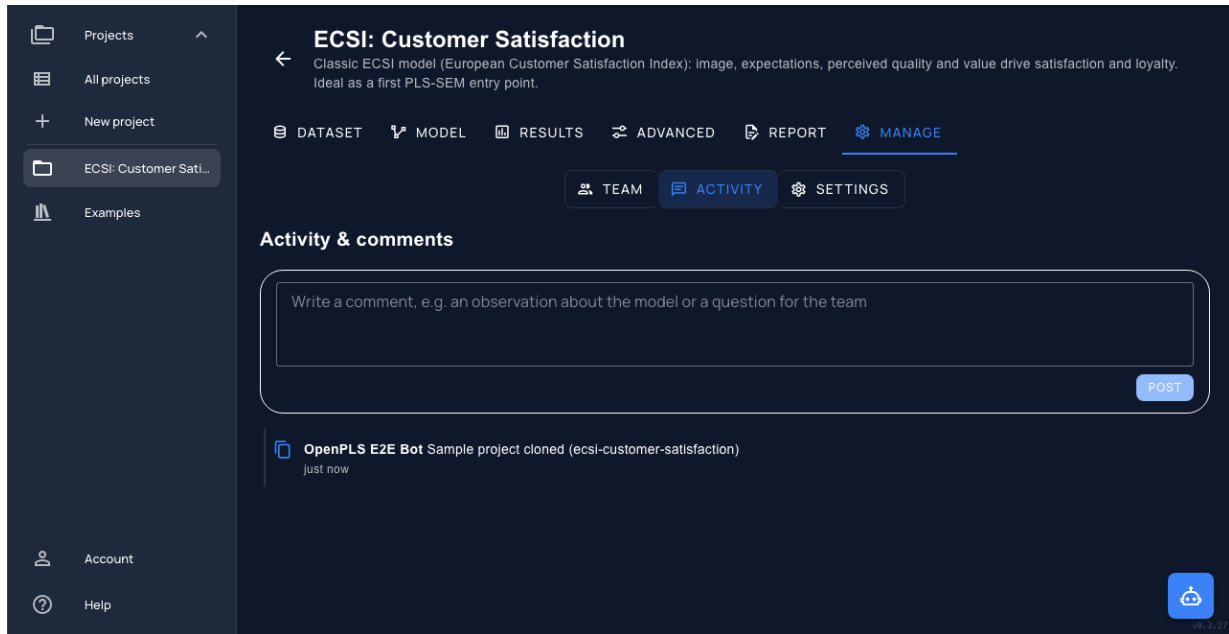


Figura 28 A sub-visão Activity: feed cronológico de cada evento do projeto, com ícones e ator.

- **Eventos de equipe:** membro convidado, convite aceito, convite revogado, e-mail de convite falhou, papel do membro alterado, membro saiu, projeto de exemplo clonado.
- **Modelo computado:** uma computação principal completa foi concluída.
- **Execuções de métodos avançados:** MICOM, Moderation, PLSc, Copula, IPMA, PLS-predict, FIMIX, HOC, Nomological, CMB, CVPAT. Uma entrada por conclusão bem-sucedida.

Não (ainda) registrados: execuções de Bootstrap, execuções de MGA, salvamentos individuais de modelo, uploads de conjuntos de dados e re-parses de conjuntos de dados. Bootstrap e MGA rodam em serviços Cloud Run que gravam seus documentos de execução diretamente sem tocar no log de atividade, verifique o histórico “Past runs” do próprio painel em vez disso.

Comentários. O feed de atividade também inclui um compositor de comentários. Os comentários são armazenados como entradas de primeiro nível e mesclados no feed cronologicamente; eles não são agrupados sob um evento específico. Use comentários para anotar o que um colega deve notar sobre uma execução.

8.5 Saindo de um projeto

Editors e viewers veem um botão **Leave** em sua própria linha na lista da equipe. Clicá-lo remove o projeto do seu espaço de trabalho e libera o assento. O proprietário não pode sair; ele deve primeiro excluir o projeto ou transferir a propriedade.

A transferência de propriedade ainda não está exposta na interface. Na versão atual, o proprietário é a pessoa que clicou em "New project" e permanece proprietário durante todo o ciclo de vida do projeto. A transferência de propriedade está no roadmap; até lá, entre em contato com o suporte se precisar transferir um projeto.

8.6 O que os colaboradores veem

Editors obtêm a mesma interface do proprietário menos as ações da zona de perigo. Viewers veem:

- Todas as abas: Dataset, Model, Results, Advanced, Manage
- Todo o conteúdo somente leitura
- Botões de exportação, os viewers podem baixar PDFs, XLSX, JSON
- Ícones Copy-LaTeX nas tabelas

Viewers não podem:

- Editar o modelo ou conjunto de dados
- Computar ou disparar qualquer método avançado
- Convidar ninguém ou alterar papéis
- Alterar configurações

Se um viewer tenta clicar em uma ação de edição, o OpenPLS mostra um toast sutil "permission denied" em vez de falhar silenciosamente.

9 Configurações e idioma

A sub-visão **Settings** sob Manage lida com os metadados em nível de projeto e a zona de perigo. O **seletor de idioma** na barra superior lida com o locale da interface para a sessão atual e o persiste no seu perfil de usuário para que ele o siga em vários dispositivos.

9.1 Configurações do projeto

Abra **Manage** → **Settings** para chegar ao painel mostrado na Figura 29.

Duas seções:

1. **Project details:** os mesmos campos de nome + descrição do diálogo New-project, editáveis a qualquer momento. Clique em Save para persistir. Um alerta de sucesso confirma a gravação.
2. **Danger zone:** o botão **Delete project**. Clicá-lo abre um diálogo de confirmação que soletra o nome do projeto para dupla verificação. A exclusão é em cascata: o projeto, seus conjuntos de dados, modelos, resultados, versões e todas as execuções de métodos avançados são removidos. Não pode ser desfeito.

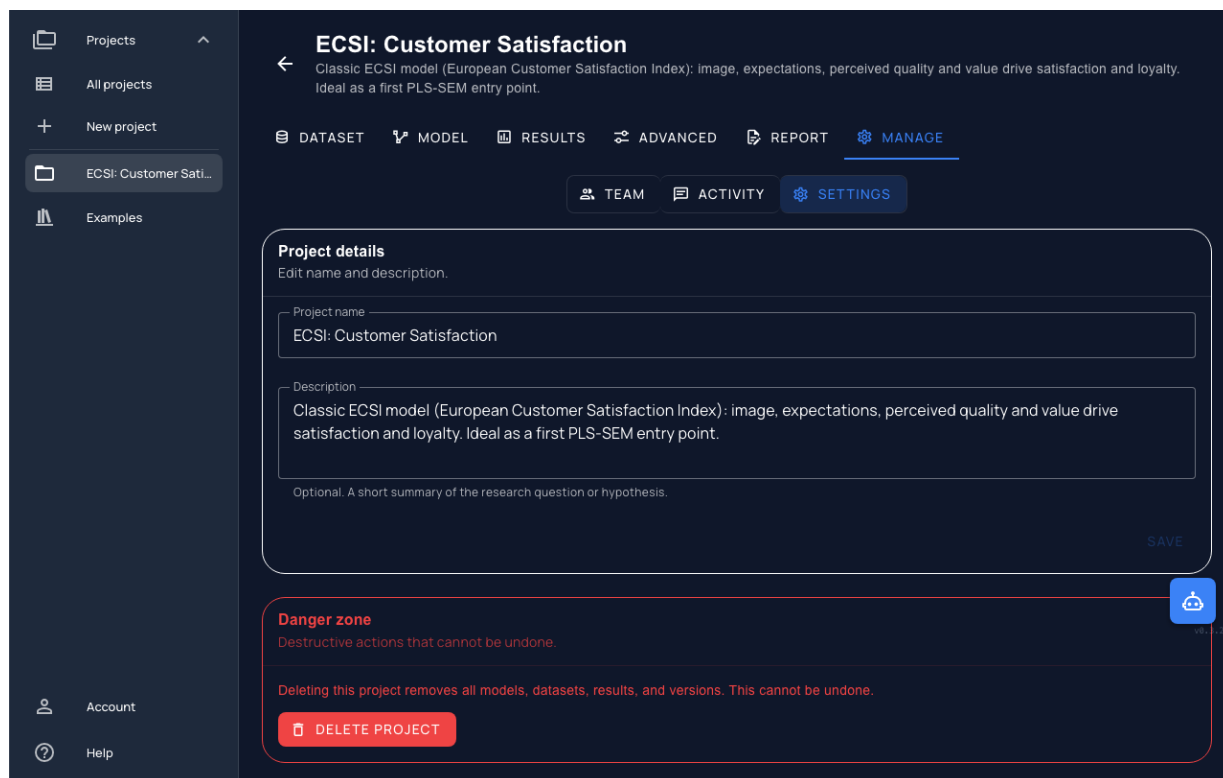


Figura 29 A sub-visão Settings: formulário de nome + descrição no topo, zona de perigo na parte inferior.

Somente o proprietário vê o card da zona de perigo. Editors e viewers veem apenas a seção project-details.

Excluir um projeto também exclui o histórico de convites e o log de atividade. Se você quer um arquivamento da trilha de auditoria antes da exclusão, exporte primeiro a visão Activity (disponível pelo ícone de download na barra de ferramentas da Activity).

9.2 Idioma

O OpenPLS vem com oito locais de interface:

- English (padrão)
- Deutsch
- Español
- Français
- Português (Brasil)
- Simplified Chinese
- Italiano
- Japanese

Clique na bandeira na barra superior para abrir o menu de idiomas (Figura 30).




Figura 30 O dropdown de idioma da barra superior. O locale atual é destacado.

Escolha um locale. O OpenPLS busca o pacote de mensagens (pequeno, ~30-60 KB) e re-renderiza. A escolha é persistida no seu perfil de usuário; da próxima vez que você fizer login de qualquer dispositivo, chegará no mesmo locale.

O que é traduzido.

- Todos os rótulos da interface, botões, diálogos, toasts
- Páginas de ajuda (/help)
- Legendas e títulos de seção do PDF do relatório
- Modelos de e-mail para convites, redefinição de senha, verificação

O que não é traduzido.

- Valores de métricas e nomes de colunas, as estatísticas permanecem no padrão científico (rótulos numéricos de base latina, cabeçalhos de coluna em inglês). Isso é intencional para que os números possam ser copiados de forma limpa para artigos em inglês.
- Citações de projetos de exemplo e descrições longas, as citações científicas estão no idioma original da publicação.

Os modelos de e-mail (convite, redefinição de senha, verificação) estão atualmente apenas em inglês, mesmo quando o locale do perfil do destinatário está definido em outro idioma. A localização completa de e-mails está no roadmap.

9.3 Configurações da conta

Seu próprio perfil fica em /account (link na barra lateral). Editável:

- **Display name:** mostrado no painel da equipe e no log de atividade.
- **Avatar:** clique para fazer upload; PNG ou JPEG, máximo 5 MB, cortado em círculo.
- **Preferred locale:** mesmo efeito do seletor da barra superior, mas persistido diretamente.
- **Password:** altere aqui. Digite a senha atual uma vez e a nova senha duas vezes; um e-mail de confirmação não é necessário.
- **Email preferences:** um único toggle “Receive product updates by email”. E-mails transacionais (convites, redefinição de senha, verificação) são sempre enviados independentemente dessa configuração.

Faça logout pelo botão de avatar redondo no canto superior direito da barra superior (ao lado do toggle de tema e do seletor de idioma).

9.4 Tema

O toggle de tema da barra superior (ícone sol/lua) alterna entre modo claro e escuro para a sessão atual. O modo escuro é o padrão. A escolha do tema é armazenada em `localStorage`, portanto não sincroniza entre dispositivos.

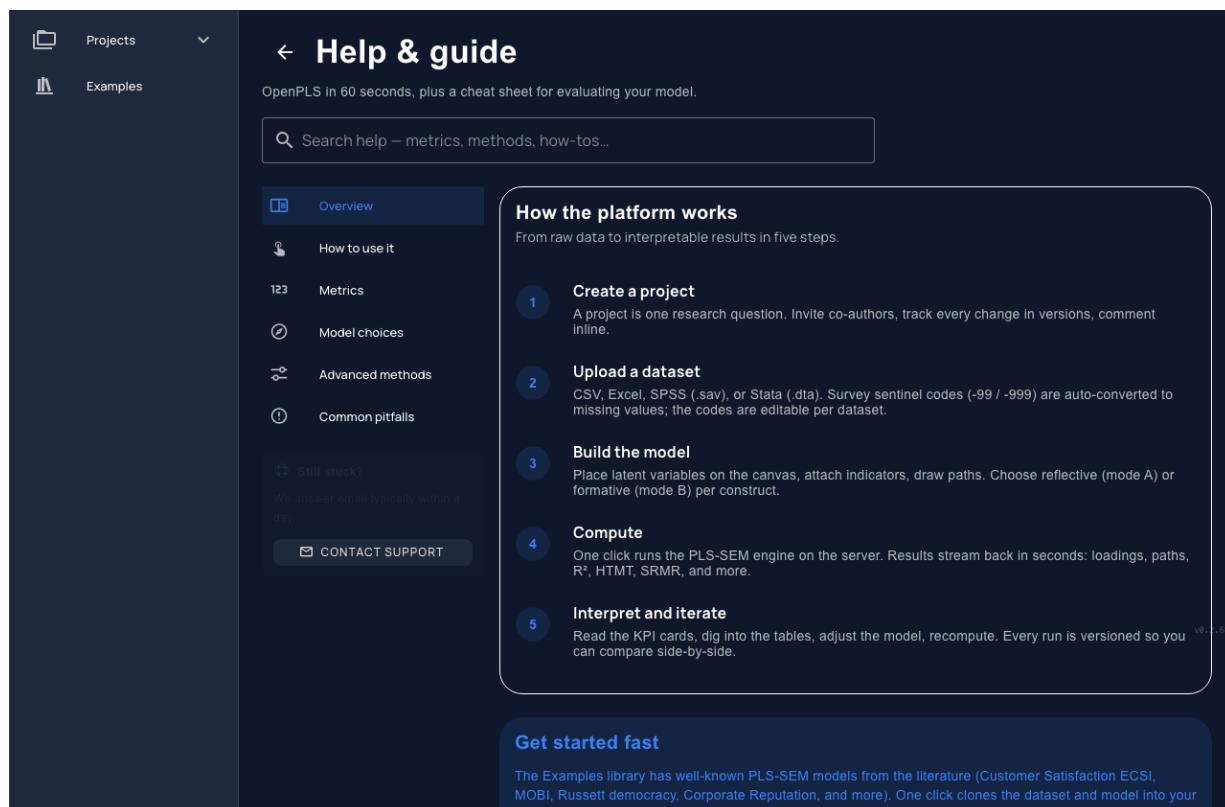


Figura 31 A visão geral da Ajuda: pontos de entrada para bedienung (how-to), metrics, choose-a-method, advanced e common pitfalls.

10 Ajuda e leituras adicionais

10.1 Ajuda no aplicativo

O OpenPLS vem com uma central de ajuda no aplicativo em `/help`, acessível pela barra lateral de qualquer projeto ou por `cloud.openpls.app/help`. A Figura 31 mostra a página de visão geral.

Seis seções:

- **How-to:** guias passo a passo orientados a tarefas espelhando os capítulos deste guia, mas em porções menores. Forma mais rápida de consultar “como faço para...” sem carregar um PDF completo.
- **Metrics:** cada métrica que o OpenPLS relata, com a fórmula, limiares de interpretação e o artigo que a definiu. Se você não tem certeza por que o R^2 ajustado é diferente do R^2 , comece aqui.
- **Choose:** árvores de decisão para perguntas comuns: “quando meu construto é reflexivo vs. formativo?”, “qual método avançado se aplica à minha hipótese?”, “qual deve ser o tamanho do Bootstrap?”.
- **Advanced:** uma página por método avançado com o mesmo conteúdo do Capítulo 6 deste guia, além de exemplos por método e interpretações passo a passo. Deep-links do aplicativo: clicar no pequeno ícone ? em qualquer painel Advanced pula para a âncora

da página de ajuda correspondente.

- **Pitfalls:** os erros de modelagem recorrentes que vemos em tickets de suporte: valores sentinela engolindo observações válidas, modo de mensuração errado, comparar grupos incomparáveis. Leia estes antes do seu primeiro projeto sério.

As páginas de ajuda estão localizadas em todos os oito idiomas da interface.

10.2 O engine OpenPLS (código aberto)

O código de estimação que alimenta o OpenPLS é um pacote Python de código aberto chamado **openpls-engine**, lançado sob GPL-3.0 em <https://github.com/jojacobsen/openpls-engine>. O que você computa na nuvem também pode ser executado localmente com:

```
pip install openpls-engine
```

O pacote inclui:

- O estimador PLS-SEM central (corresponde às saídas do SmartPLS 4 em 4 casas decimais em casos validados)
- Cada método avançado descrito no Capítulo 6
- CLI + API Python para execuções em lote reproduzíveis
- Uma imagem Docker para self-hosting turn-key

Se você quer fazer self-host de toda a interface do OpenPLS, o engine é o componente de computação; consulte o roadmap no repositório para o estado atual da orquestração via Docker Compose.

10.3 Suporte, bugs e solicitações de recursos

Para qualquer coisa relacionada ao aplicativo em nuvem (`cloud.openpls.app`), escreva para hello@openpls.app. Inclua seu ID de projeto (visível na URL) e, se estiver relatando um bug, uma breve descrição do que esperava versus o que aconteceu.

Bugs específicos do engine e solicitações de recursos também podem ser registrados como issues no GitHub em <https://github.com/jojacobsen/openpls-engine/issues>, ou por e-mail se preferir.

10.4 Citando o OpenPLS

Se o OpenPLS produziu resultados no seu artigo, por favor cite:

Jacob, J. (2026). *OpenPLS Engine: An Open-Source Implementation of Partial Least Squares Structural Equation Modeling Validated Against SmartPLS 4 Across 14 Reference Cases*. SSRN Working Paper. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=6869001

Esta citação cobre tanto o engine de estimação quanto o aplicativo em nuvem, pois compartilham uma única implementação validada.

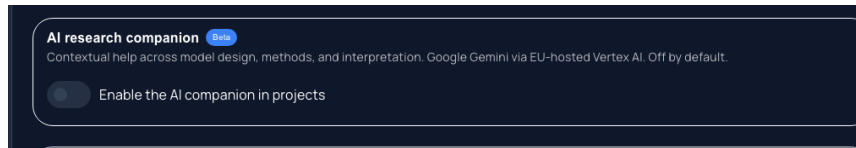


Figura 32 O diálogo de consentimento do AI Companion. Leia os quatro tópicos e clique em **Enable AI Companion**. Se você pular, permanece desativado; você pode ativar depois nas configurações da conta.

11 O AI Companion

O OpenPLS vem com um **AI Companion** - um assistente no aplicativo que lê o estado do seu projeto, cita artigos metodológicos revisados por pares e ajuda com as partes do PLS-SEM que não vêm de clicar em botões: escolher o que executar em seguida, redigir a redação e antecipar do que um revisor irá reclamar.

O Companion é **opt-in**. Nada é chamado até que você aceite o texto de consentimento, e você pode desativá-lo a qualquer momento nas configurações da conta. Este capítulo percorre cada superfície na ordem em que você tipicamente as encontrará.

Cada resposta da IA é fundamentada em duas fontes: (1) os números reais do seu projeto (formato do conjunto de dados, especificação do modelo, resultado mais recente da computação), que o assistente obtém por meio de ferramentas somente leitura; e (2) uma biblioteca curada de artigos PLS-SEM de acesso aberto cujos resumos são recuperados por similaridade semântica com sua pergunta. O assistente não tem acesso de escrita ao seu projeto; cada sugestão aplicada é um clique que você mesmo faz.

11.1 Ativando

Usuários de primeira vez veem um diálogo de opt-in em uma etapa após o login. Ele resume o que o Companion lê (dados do seu projeto), o que ele envia adiante para processamento e o orçamento de uso (um limite suave de 100 turnos por mês por usuário previne uso descontrolado).

Se você dispensou o diálogo anteriormente, abra **Account** → **AI Companion** e ative-o lá. A mesma página também traz um subtoggle para **AI hints** (veja abaixo): com o Companion ligado mas hints desligados, apenas os recursos proativos permanecem silenciosos - o chat, o designer de modelo e a redação de relatório ainda funcionam quando você os invoca.

11.2 AI hints: a faixa sempre visível

Cada aba que tem um próximo passo plausível exibe uma pequena faixa **AI hints** no topo: uma a três sugestões calibradas para o que você tem neste projeto agora. Na aba Dataset ela pode sinalizar uma coluna com 22 % de valores ausentes; em Results ela pode notar que seu R^2 para

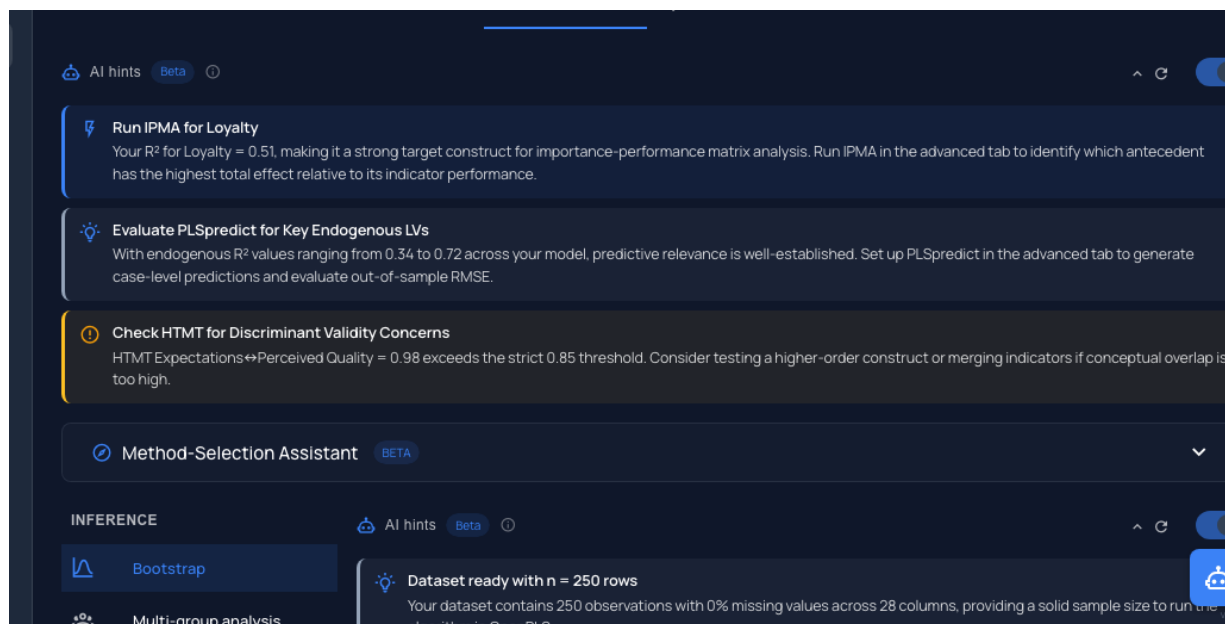


Figura 33 A faixa de AI hints na aba Advanced. O cabeçalho traz um chip **Beta**, um tooltip de informações, refresh, collapse e o toggle on/off. Cada dica tem um ícone de severidade: lâmpada para info, círculo de alerta para aviso, raio para ação.

Loyalty é 0,42 e sugerir executar IPMA; em Advanced ela apontará para qualquer método que o seu estado atual torne mais convincente.

As dicas buscam uma vez por aba por sessão, depois ficam em cache. Pressione refresh para forçar uma releitura quando você acabou de importar um novo conjunto de dados ou editou o modelo.

Desativando as dicas individualmente. Nem todo usuário quer a faixa em seu rosto. O toggle à direita da faixa alterna uma flag por usuário `aiHintsEnabled`: as dicas param de buscar, mas o resto do Companion (chat, designer, relatório) continua funcionando quando você o abre. Off → a faixa se colapsa em um placeholder discreto que fica fora do caminho.

11.3 Chat: a gaveta flutuante

Um pequeno botão de robô fica permanentemente no canto inferior direito. Clique nele para abrir a gaveta de chat.

O estado vazio oferece três prompts prontos:

1. **Explique meus resultados em linguagem simples.** Lê a saída mais recente da computação e escreve um resumo em um parágrafo calibrado para seus números específicos.
2. **Qual método avançado devo executar em seguida?** Aplica o mesmo motor de regras do Method-Selection Assistant (veja abaixo) e retorna uma shortlist ranqueada inline.
3. **Meus construtos são válidos?** Percorre as tabelas de Reliability + HTMT + AVE e sinaliza qualquer violação de limiar pelo nome.

Ou digite a sua própria. Qualquer coisa sobre o projeto - design do modelo, qualidade do

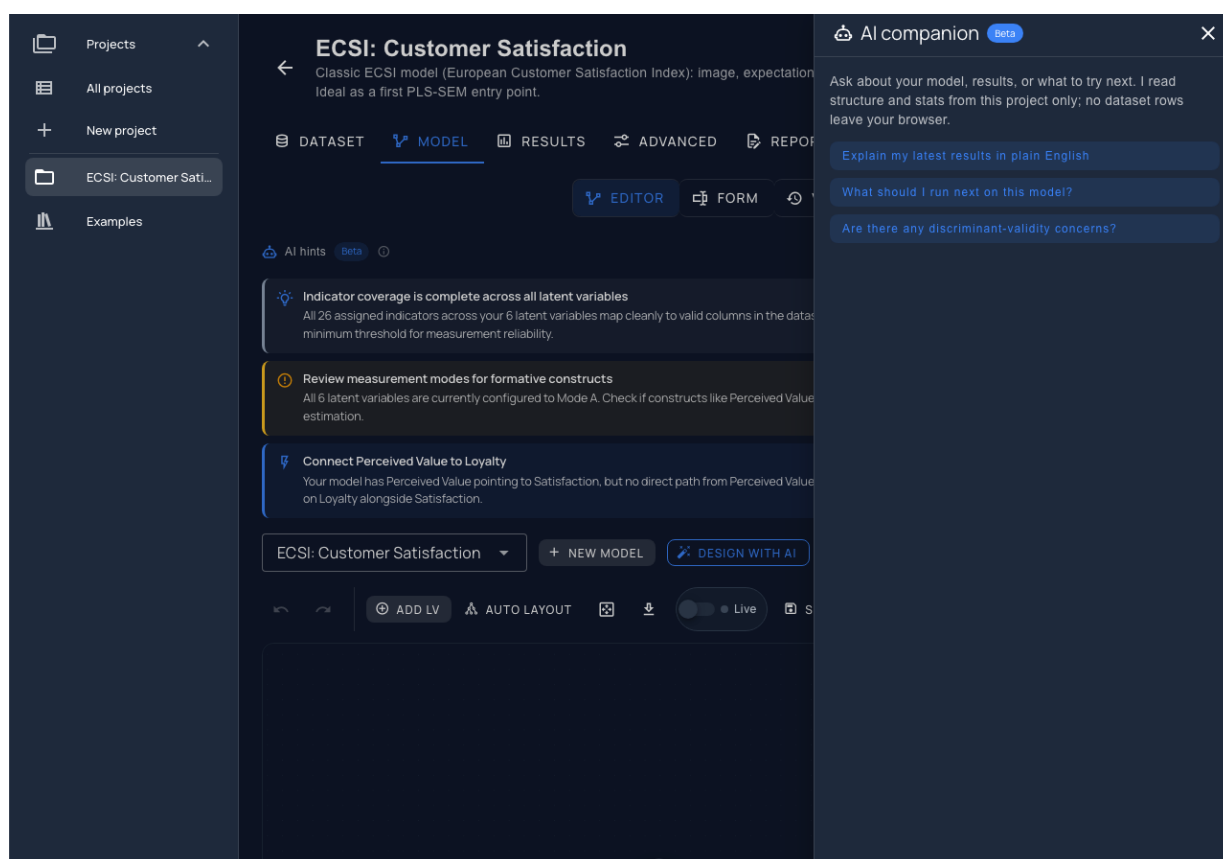


Figura 34 A gaveta do AI Companion, aberta sobre a aba Results. O cabeçalho mostra o título e um chip beta, os blocos de sugestão para usuários de primeira vez oferecem três perguntas prontas, e o compositor na parte inferior traz um contador de cota ao vivo.




Figura 35 Um turno de chat com a linha de ferramentas utilizada visível abaixo da resposta. O Companion chamou `getResults` para puxar o R^2 , β e p-valores reais antes de responder.

conjunto de dados, escolha de método, interpretação de caminho, contestação do revisor - está no escopo. O Companion tem quatro ferramentas somente leitura:

- **getProject** - nome, descrição, contagem de membros
- **getModel** - LVs com modos, indicadores, caminhos estruturais
- **getDataset** - contagem de linhas e colunas, estatísticas por coluna (ausência, mín/máx/média), **nunca os valores reais das linhas**
- **getResults** - R^2 por LV, coeficientes de caminho com p-valores, matrizes HTMT, confiabilidade, veredictos de Fornell-Larcker, SRMR, GoF

A linha de ferramentas utilizada abaixo de cada resposta lhe diz quais delas foram chamadas. Nada mais sai do projeto.

Citações. Quando uma afirmação na resposta se baseia na literatura metodológica, o Companion escreve um role slug entre colchetes (por exemplo, [henseler-2015-htmt]). O frontend renderiza essas como chips-pílula clicáveis mostrando o autor e o ano (por exemplo, **Henseler+ 2015**). Passar o mouse revela o título completo; clicar abre a página do DOI ou do editor em uma nova aba.

A biblioteca de artigos por trás dessas pílulas é um conjunto curado de ~100 referências PLS-

The screenshot displays the OpenPLS software interface. On the left is a sidebar with a 'Projects' list containing 'ECSI: Customer Sati...' and 'Examples'. The main area is titled 'ECSI: Customer Satisfaction' and shows model configuration options like 'Model name', 'Dataset', and 'Latent variables'. The 'Latent variables' section lists six variables: Image, Expectations, Perceived Quality, Perceived Value, Satisfaction, and Loyalty, each with a name, mode (A, reflective), and indicators. Below this is the 'Structural model (paths)' section, which shows a series of 'From' and 'To' relationships between the latent variables. On the right, an 'AI companion' chat window is open, showing a user query and a detailed response with inline citations and procedural/statistical remedies. The chat window also includes a search bar and a '92 turns left this month' indicator.

Figura 36 Citações em chip renderizadas inline em uma resposta de chat. Cada pílula liga à página do DOI do artigo original.

Figura 37 O diálogo do designer de modelo por IA. Digite uma pergunta de pesquisa (obrigatória), liste construtos já em mente (opcional), escolha uma disciplina. Clique em **Submit** para receber uma proposta estruturada.

-SEM de acesso aberto (veja *A biblioteca de artigos* abaixo).

Histórico + persistência. Turnos de chat são salvos por usuário no armazenamento de configurações da conta. Recarregue a página, abra a gaveta, sua conversa ainda está lá. O ícone **Clear conversation** no cabeçalho a apaga.

Cota. 100 turnos de chat por usuário por mês durante o beta. O contador na parte inferior do compositor mostra o que resta. Turnos de design de modelo e redação de relatório compartilham o mesmo balde.

11.4 Projetando um modelo a partir de uma pergunta de pesquisa

Se seu modelo ainda não existe - um projeto novo, nenhuma LV desenhada - abra o **Editor** e clique em **Design with AI**. O diálogo pede sua pergunta de pesquisa e, opcionalmente, os construtos que você já tem em mente e uma dica de disciplina.

Você recebe de volta uma proposta estruturada:

- **3–6 variáveis latentes** com seu modo (A = reflexivo, B = formativo), uma breve justificativa e 3–5 dicas de indicadores por LV (frases descrevendo o que os itens mediriam para este construto
 - não a redação completa do questionário).
- **5–12 caminhos estruturais** cada um com uma hipótese em português simples e uma breve nota de literatura.




Figura 38 O card da proposta. Cada LV mostra modo, dicas de indicadores e justificativa; os caminhos listam origem → destino com hipótese. **Apply** grava o modelo no seu projeto como uma nova versão.

- **2–3 modelos-modelo (blueprint)** da literatura PLS-SEM publicada que compartilham a estrutura.
- **Notas** sobre ressalvas ou especificações alternativas a considerar.

A proposta **não** é gravada no seu projeto até você clicar em **Apply**. Visualize-a, refine seu prompt se necessário (**Refine** regenera) ou descarte e comece de novo.

Uma vez aplicado, o modelo aparece no Editor como um canvas normal arrastável - você pode renomear LVs, adicionar caminhos, redistribuir indicadores. A proposta é um ponto de partida, não um artefato final.

11.5 Projetando um questionário

Uma vez que você tenha um modelo (LVs com modos atribuídos), o OpenPLS pode gerar uma bateria completa de itens: 4–6 itens de questionário por LV com redação, escala Likert, sinalizadores de codificação reversa e citações a escalas validadas quando a LV mapeia para um construto bem conhecido na literatura (Trust, Satisfaction, Loyalty, Perceived Usefulness do TAM e assim por diante).

Abra a aba **Model**, depois a sub-visão **Form**. Se alguma LV não tem itens, você verá um botão **Design items with AI**. Clique nele para abrir o diálogo do designer de questionário.

Figura 39 O diálogo do designer de questionário por IA. Escolha uma escala de resposta (Likert de 5 ou 7 pontos), idioma do público e clique em **Submit**. O diálogo mostra para quais LVs ele construirá itens; aquelas que já têm itens são puladas a menos que você marque **Overwrite existing**.

O resultado é uma tabela de itens por LV: ID do item, redação, flag de codificação reversa, citação da fonte. Passe os olhos, ajuste a redação, remova ou adicione itens, então aplique - os itens aterrissam como indicadores em cada LV.

A partir daqui você tem duas opções para coletar dados de fato: construir um questionário que os respondentes preenchem em uma URL pública (veja o próximo capítulo, *Pesquisas públicas*) ou levar a bateria de itens para uma ferramenta de pesquisa externa e importar as respostas como um CSV.

11.6 Method-Selection Assistant

Uma vez que você tenha resultados computados, a aba Advanced mostra um painel **Method-Selection Assistant** no topo. Clique para expandir.

O assistente olha para o estado do seu projeto - tamanho da amostra, candidatos a agrupamento no conjunto de dados, R^2 por LV endógena, violações HTMT, limiares de confiabilidade - e retorna uma shortlist ranqueada dos métodos avançados que fazem sentido como seu próximo passo:

- **Bootstrap** (High) sempre que você tem um resultado de computação mas ainda não tem intervalos de confiança.
- **MGA + MICOM** (High) quando o conjunto de dados tem uma coluna categórica com 2–5 níveis e tamanho de amostra por grupo suficiente.

ECSI: Customer Satisfaction

Classic ECSI model (European Customer Satisfaction Index): image, expectations, perceived quality and value drive satisfaction and loyalty. Ideal as a first PLS-SEM entry point.

📊 DATASET 🔗 MODEL 📊 RESULTS ⚙️ ADVANCED 📄 REPORT ⚙️ MANAGE

📄 DATA UPLOAD 📄 QUESTIONNAIRE BUILDER

ECSI: Customer Satisfaction

📄 EXPORT

🔄 REGENERATE

🔗 Share as public survey Not published

Publish the questionnaire to a public URL so anyone can fill it in. No account needed for respondents. Anonymous responses stream back into the builder — download as CSV any time.

🔗 PUBLISH

🌐 English 📊 5-point Likert 🕒 Aug 4, 2026, 10:51 AM

👁️ Public Intro Respondents see this

Shown at the top of the public survey. Explain the purpose, expected duration, and how the data will be used.

Thank you for taking part in this short survey. It should take about 5 minutes and helps us understand...

🔒 Internal notes Team only

For your research team only. Never shown to respondents. Use for design decisions, exclusion criteria, sample size targets.

Ensure ethical review and IRB approval are obtained prior to fielding the survey. Conduct a pilot test with a minimum of 30 respondents to check indicator reliability and multicollinearity before final data collection. Data can be exported and analyzed seamlessly using OpenPLS.

👤 Demographic questions

Optional standard fields that get exported alongside your items.

✓ Age

✓ Gender

+ Country

+ Education

+ Profession

+ Language

🖼️ Image Reflective 5-point

📖 Source: Martenson (2007), Journal of Retailing and Consumer Services

Adapted from the European Customer Satisfaction Index (ECSI) framework to measure overall company image.

imag1

The organization has a very positive reputation in the market.

🔍 ×

imag2

I consider this organization to be stable and trustworthy.

🔍 ×

imag3

This organization stands for quality and customer focus.

🔍 ×

imag4

The organization contributes positively to the community.

🔍 ×

imag5

Overall, this organization has a poor public image.

🔍 ×

+ ADD ITEM

⚓ Anchors: Strongly disagree → Strongly agree

👤 Expectations Reflective 5-point

📖 Source: Oliver (1997), McGraw-Hill

Measures customer expectations prior to consumption or service delivery, following standard satisfaction models.

Figura 40 O card do questionário gerado. Cada bloco de LV lista itens com redação + chip de reverse + citação. Edite no local, então **Apply** para gravar no seu modelo.

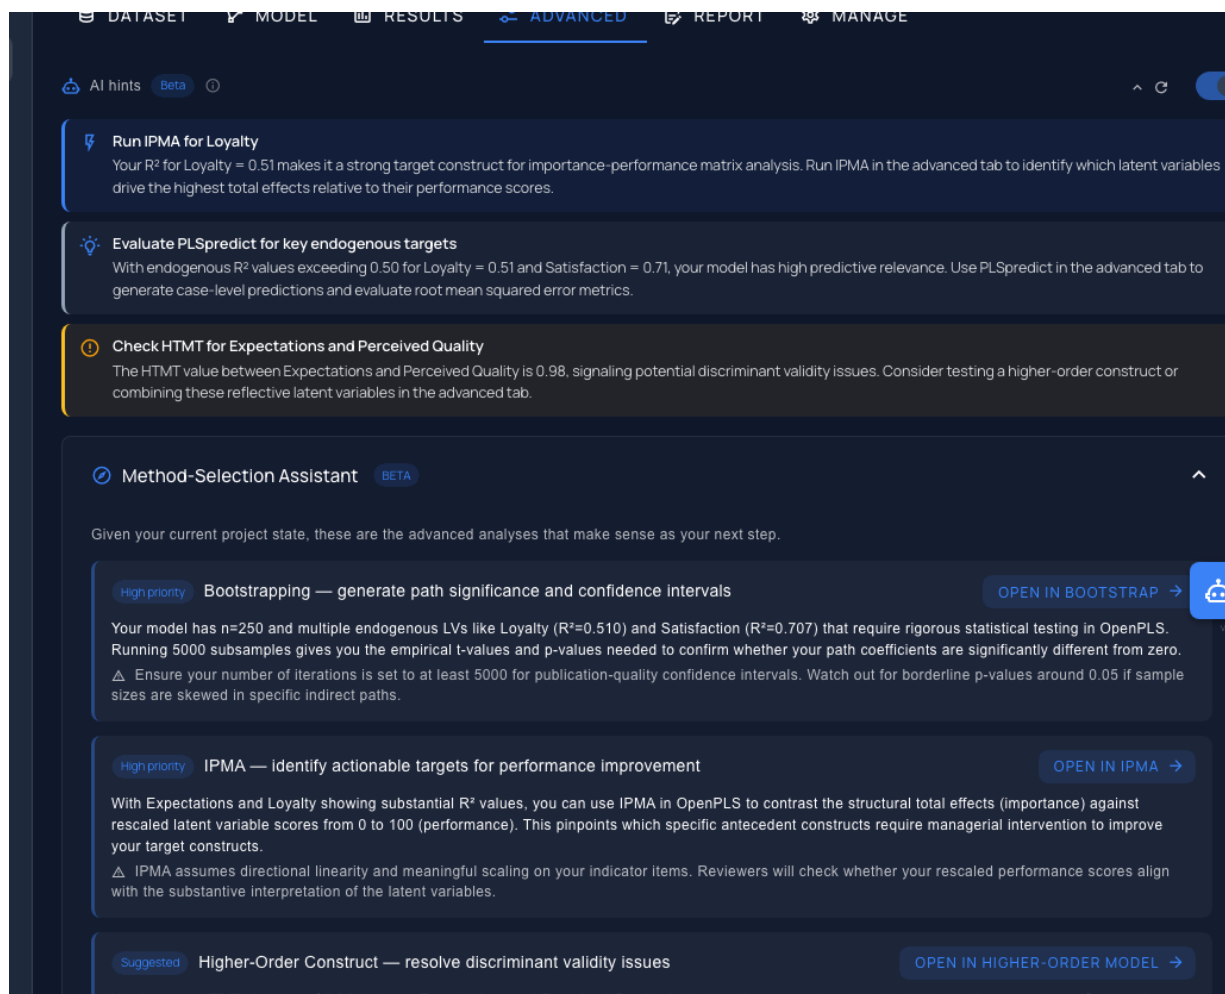


Figura 41 O Method-Selection Assistant expandido. Chips de prioridade (High / Suggested / Optional), um raciocínio de uma frase por método, uma nota de risco e um botão “Open in ...” que navega para a sub-aba Advanced correspondente.

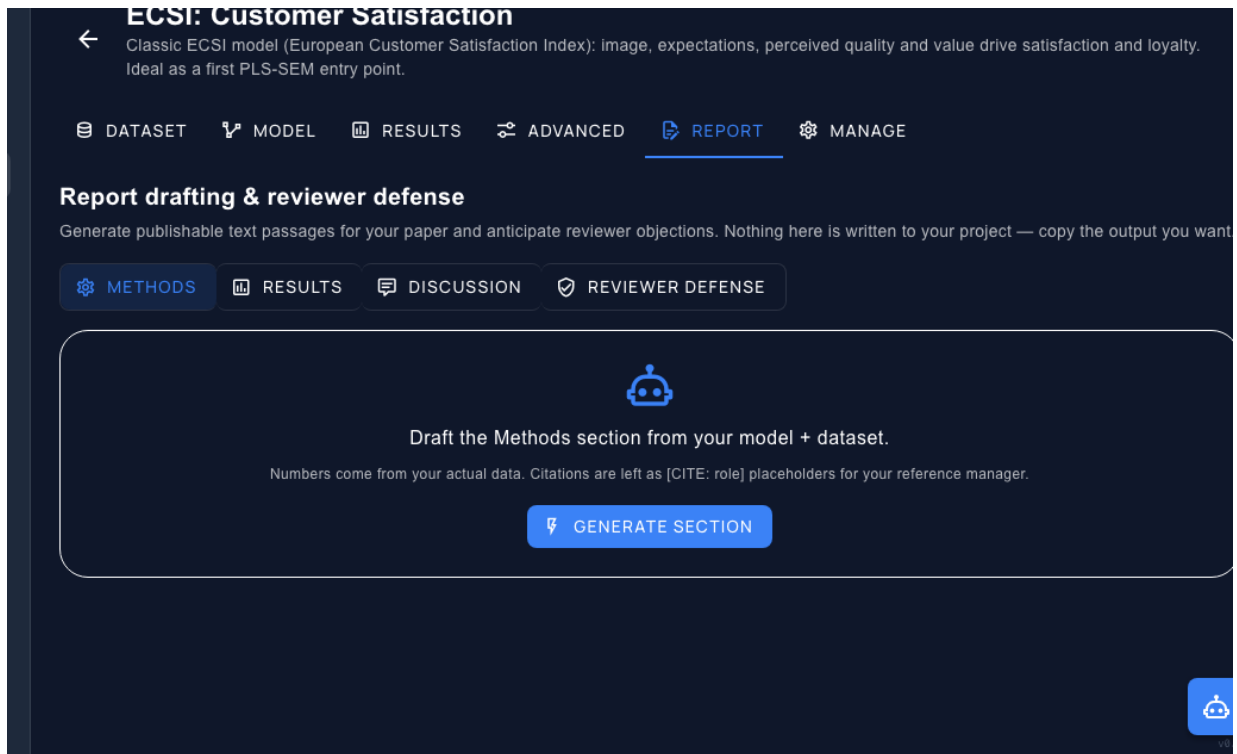


Figura 42 A visão geral da aba Report. Quatro sub-botões - Methods, Results, Discussion, Reviewer defense - e um grande card que abre o drafter correspondente.

- **IPMA** (High) quando uma LV alvo tem $R^2 \geq 0,33$ - variância substantiva suficiente para tornar o ranqueamento dos antecedentes acionável.
- **PLSpredict** (Suggested) quando pelo menos uma LV endógena tem $R^2 \geq 0,19$ e $n \geq 100$.
- **FIMIX-PLS** (Suggested) para $n \geq 200$ como verificação de heterogeneidade.
- **HOC** (Suggested) quando duas LVs têm HTMT próximo a 1 - elas podem ser facetas de primeira ordem do mesmo construto de segunda ordem.
- **PLSc** (Optional) quando todas as LVs são reflexivas - uma verificação de robustez com-mon-factor.
- **Copula / CMB / Nomological / CVPAT** (Optional) como diagnósticos padrão de antecipação do revisor.

Cada sugestão traz o motivo fundamentado nos seus números reais (por exemplo, “LV alvo Loyalty tem $R^2 = 0,42$ - IPMA identifica quais antecedentes importam mais para ação prática”). O botão **Open in ...** (rotulado com o nome específico do método) roteia para a sub-aba Advanced correspondente para que você possa configurar e executar.

O painel busca no clique; nada roda a menos que você o abra. Clique em **Regenerate suggestions** para reler o estado do seu projeto.

11.7 Redação de relatório

Uma nova aba - **Report** - fica entre Advanced e Manage. Seus quatro sub-botões produzem texto pronto para publicação extraído dos seus dados reais.

11.7.1 Methods / Results / Discussion

Escolha uma seção e clique em **Generate section**. Você recebe:

- **Markdown** à esquerda, pronto para copiar em um rascunho ou post de blog. Usa notação estatística Unicode (R^2 , β , χ^2 , f^2) - sem LaTeX dentro da saída Markdown.
- **LaTeX** à direita, pronto para o código-fonte do artigo. Usa R^2 , β , χ^2 , f^2 , convenções `\cite{role}` para um template de revista adequado.
- **Slots de citação** na extremidade direita: uma linha por role entre colchetes que a seção referencia, cada um ligado ao DOI ou página do editor.
- **Notas** - uma ou duas frases de ressalva que o drafter acha que o autor humano deve saber (por exemplo, “seu SRMR de 0,11 está acima do limiar de 0,08 - considere comentar sobre o ajuste”).

O drafter segue as convenções de Hair/Ringle/Sarstedt:

- **Methods** relata amostra, modelo de mensuração, escolhas de estimação, critérios de confiabilidade + validade, indicadores de ajuste do modelo e prevê procedimentos avançados.
- **Results** relata qualidade do modelo de mensuração (α , ρ_c , AVE), validade discriminante (HTMT com quaisquer violações nomeadas), coeficientes de caminho com significância, R^2 por LV endógena com o descritor verbal de Chin 1998 e SRMR.
- **Discussion** interpreta caminhos significativos de forma substantiva, aborda os não significativos, detalha implicações práticas para a LV alvo com o maior R^2 , lista limitações e propõe duas extensões concretas.

Copie qualquer painel pelo botão de ícone de cópia em seu cabeçalho. Regenere com o botão **Regenerate** no cabeçalho da seção - o drafter relê os resultados mais recentes, útil após um Bootstrap novo ou um ajuste no modelo.

11.7.2 Reviewer defense

O quarto sub-botão - **Reviewer defense** - é o modo adversarial do drafter. Clique em **Generate reviewer defense**.

Você recebe quatro a sete objeções antecipadas que um revisor provavelmente levantará, cada uma com:

- **Preocupação** em uma ou duas frases usando os números exatos do seu snapshot.
- **Persona do revisor** - uma breve caracterização (“CB-SEM traditionalist”, “Statistical purist”, “Senior methods editor”) para que você saiba qual enquadramento esperar.
- **Severidade** - Critical, Moderate ou Nitpick.
- **Defesa** - o contra-argumento real, referenciando seus números e citando a biblioteca de artigos inline.
- **Evidência** - os valores específicos do snapshot que apoiam a defesa.
- **Mitigação** - 0–2 frases sobre o que ainda executar antes de submeter, se houver algo.

←

ECSI: Customer Satisfaction

Classic ECSI model (European Customer Satisfaction Index): image, expectations, perceived quality and value drive satisfaction and loyalty. Ideal as a first PLS-SEM entry point.

DATASET

MODEL

RESULTS

ADVANCED

REPORT

MANAGE

Report drafting & reviewer defense

Generate publishable text passages for your paper and anticipate reviewer objections. Nothing here is written to your project — copy the output you want

METHODS

RESULTS

DISCUSSION

REVIEWER DEFENSE

Methods

n = 250

REGENERATE

Markdown

COPY

To evaluate the European Customer Satisfaction Index (ECSI) model, partial least squares structural equation modeling (PLS-SEM) was conducted using OpenPLS. The sample comprised 250 respondents, with Likert-type items serving as the measurement scale. The structural model consisted of six latent variables estimated using mode A: Image (5 indicators), Expectations (5 indicators), Perceived Quality (5 indicators), Perceived Value (4 indicators), Satisfaction (4 indicators), and Loyalty (4 indicators). All indicators were standardised prior to estimation, and the centroid weighting scheme was applied [Hair+ 2019](#). Statistical inference was performed using bootstrapping with 5,000 resamples to generate robust standard errors and confidence intervals [Streukens+ 2016](#). Measurement model reliability and convergent validity were assessed via Cronbach's alpha, composite reliability (pc), and average variance extracted (AVE). Discriminant validity was examined using the Heterotrait-Monotrait (HTMT) ratio of correlations, applying the standard threshold of 0.85 [Henseler+ 2015](#). Global model fit was evaluated using the standardized root mean squared residual (SRMR), referencing the conservative threshold of < 0.08 for approximate fit [Henseler+ 2016](#). Furthermore, additional procedures such as full collinearity assessment were utilized to check for common method bias [Kock 2015](#).

LaTeX

COPY

```

\section*{Methods}
To evaluate the European Customer Satisfaction Index (ECSI) model, partial least squares structural equation modeling (PLS-SEM) was conducted using OpenPLS. The sample comprised 250 respondents, with Likert-type items serving as the measurement scale. The structural model consisted of six latent variables estimated using mode A: Image (5 indicators), Expectations (5 indicators), Perceived Quality (5 indicators), Perceived Value (4 indicators), Satisfaction (4 indicators), and Loyalty (4 indicators). All indicators were standardised prior to estimation, and the centroid weighting scheme was applied \cite{hair-2019-when-to-use}. Statistical inference was performed using bootstrapping with 5,000 resamples to generate robust standard errors and confidence intervals \cite{streukens-2016-bootstrap}. Measurement model reliability and convergent validity were assessed via Cronbach's alpha, composite reliability ($\rho_{cs}$), and average variance extracted (AVE). Discriminant validity was examined using the Heterotrait-Monotrait (HTMT) ratio of correlations, applying the standard threshold of 0.85 \cite{henseler-2015-htmt}. Global model fit was evaluated using the standardized root mean squared residual (SRMR), referencing the conservative threshold of $< 0.08$ for approximate fit \cite{henseler-2016-srmr}. Furthermore, additional procedures such as full collinearity assessment were utilized to check for common method bias \cite{kock-2015-cmb}.

```

Citation slots

Hair+ 2019

When to use and how to report the results of PLS-SEM

Streukens+ 2016

Bootstrapping and PLS-SEM: A step-by-step guide to get more out of your bootstrap results

Henseler+ 2015

A new criterion for assessing discriminant validity in variance-based structural equation modeling

Henseler+ 2016

Testing for goodness-of-fit in structural equation modeling: an assessment of the standardized root mean squared residual (SRMR)

Kock 2015

Common method bias in PLS-SEM: A full collinearity assessment approach

i

Your HTMT values for Expectations-Perceived Quality (0.98), Perceived Quality-Perceived Value (0.88), and Perceived Value-Satisfaction (0.93) exceed the 0.85 threshold, which indicates potential discriminant validity issues that should be addressed in the results.

Figura 43 A seção Methods gerada. Painel Markdown à esquerda, painel LaTeX abaixo, trilho de citações à direita. Cada número no texto rastreia de volta ao projeto.

←

ECSI: Customer Satisfaction

Classic ECSI model (European Customer Satisfaction Index): image, expectations, perceived quality and value drive satisfaction and loyalty. Ideal as a first PLS-SEM entry point.

DATASET

MODEL

RESULTS

ADVANCED

REPORT

MANAGE

Report drafting & reviewer defense

Generate publishable text passages for your paper and anticipate reviewer objections. Nothing here is written to your project — copy the output you want

METHODS

RESULTS

DISCUSSION

REVIEWER DEFENSE

Overall strategy

Lead the revision by acknowledging the severe HTMT violations and immediately performing item purification or higher-order modeling in OpenPLS. Concurrently, execute the missing advanced procedures—specifically bootstrapping, CMB full collinearity assessment, and PLSpredict—while dropping obsolete metrics like GoF in favor of SRMR and contemporary PLS-SEM standards.

REGENERATE

Critical Measurement purist

The HTMT values between Expectations and Perceived Quality (0.98), Perceived Value and Satisfaction (0.93), and Perceived Quality and Perceived Value (0.88) severely violate the standard 0.85 threshold, indicating severe discriminant validity problems.

Defense: While these HTMT values exceed the 0.85 threshold, discriminant validity concerns can sometimes arise in closely related consumer-behavior constructs like quality and expectations. To address this prior to resubmission, you should run a discriminant validity remediation or higher-order structural analysis in OpenPLS.

Evidence: HTMT is 0.98 for Expectations and Perceived Quality, 0.93 for Perceived Value and Satisfaction, and 0.88 for Perceived Quality and Perceived Value.

Mitigation: Examine item cross-loadings in OpenPLS, consider dropping problem items, or re-specify the model with higher-order constructs.

Critical Statistical reviewer

No bootstrap analysis has been run yet, meaning there are no p-values or confidence intervals to validate the statistical significance of the 10 structural paths.

Defense: This is simply an artifact of the initial model run snapshot; bootstrapping must be executed to confirm the significance of the 7 significant paths.

Evidence: Bootstrap is currently set to false in the project snapshot.

Mitigation: Run bootstrapping with 5,000 resamples in OpenPLS to generate bias-corrected confidence intervals.

Critical Methods editor

Common method bias has not been assessed, yet cross-sectional survey data with 250 respondents is highly susceptible to CMB.

Defense: CMB must be explicitly evaluated before final publication to ensure the structural paths are not artifactual [Kock 2015](#).

Evidence: CMB is listed as false in the advanced runs performed.

Mitigation: Perform a full collinearity assessment in OpenPLS to check if inner VIF values remain below 3.3 [Kock 2015](#).

Suggested citations

Kock 2015

Moderate CB-SEM traditionalist

The project reports the Goodness-of-Fit (GoF) index of 0.610, which is known to be methodologically flawed for PLS-SEM validation.

Defense: Although GoF is reported in the snapshot, modern PLS-SEM guidelines discourage its use for model validation, favoring SRMR instead [Henseler+ 2013](#).

Evidence: GoF is 0.610 while SRMR is 0.077.

Mitigation: Drop GoF from the manuscript reporting and rely solely on SRMR and exact model fit diagnostics [Henseler+ 2013](#).

Suggested citations

Henseler+ 2013

Moderate Senior econometrician

Endogeneity and predictive relevance have not been tested, leaving open the possibility of omitted variable bias and unproven out-of-sample predictive power.

Defense: The current model establishes foundational explanatory power with an R^2 up to 0.720, which can be complemented by out-of-sample and endogeneity checks.

Evidence: Copula and PLSpredict are both marked as false in advanced runs.

Mitigation: Run PLSpredict and Gaussian copula tests in OpenPLS to verify out-of-sample performance and check for endogeneity.

Figura 44 Um card de reviewer defense. Chip de severidade (Critical / Moderate / Nitpick), persona do revisor, preocupação, defesa, evidência, mitigação e chips de citações sugeridas.

- **Citações sugeridas** - chips clicáveis para os artigos em que o defensor se apoia.

Um breve parágrafo **Overall strategy** no topo do card lista os dois ou três movimentos que ancoram sua carta de revisão - geralmente “liderar com X, conceder Y como limitação, comprometer-se com Z em um follow-up”.

O defensor é um simulador, não um oráculo. Revisores reais trarão contexto que você não pode prever - objeções teóricas ligadas à sua literatura específica, peculiaridades metodológicas da sua revista alvo, hobby horses pessoais. Use a saída como ensaio, não como garantia.

11.8 A biblioteca de artigos

Cada superfície de IA que produz citações extrai da mesma biblioteca curada - cerca de 100 artigos PLS-SEM de acesso aberto abrangendo metodologia, crítica, aplicações e os clássicos de modelagem (TAM, UTAUT, TPB, SERVQUAL, ACSI, JD-R). Cada entrada é um título, lista de autores, ano, DOI e o resumo tal como aparece na página do editor. Sem texto completo - apenas os metadados que os revisores precisam para encontrar o artigo por conta própria.

A biblioteca é armazenada no mesmo banco de dados que seus projetos e consultada via **busca vetorial semântica**: quando você faz uma pergunta, o assistente embeda sua pergunta com um modelo de embedding multilíngue, encontra os cinco resumos de artigo mais próximos por similaridade de cosseno e os fornece ao LLM como contexto de referência. O modelo então cita usando os role slugs entre colchetes (por exemplo, [hense1er-2015-htmt]), que o frontend substitui por chips-pílula.

Se um chip aparece cinza/plano (não clicável), significa que o assistente citou um role que ainda não está na biblioteca - ou um artigo mais antigo fora da nossa janela de curadoria ou, ocasionalmente, uma alucinação. Chips cinzas são um sinal para verificar manualmente a referência.

11.9 Cota e privacidade

Cota. 100 turnos por usuário por mês durante o beta. Aplica-se separadamente a turnos interpretativos (chat, designer de modelo, drafters de relatório) e a hints (100 buscas de hint por mês). Turnos não são acumulados.

Privacidade. O Companion lê a estrutura do seu projeto e agregados (contagens de linhas, estatísticas de coluna, R^2 , coeficientes de caminho), nunca as linhas reais do questionário. Todo o processamento roda sob termos contratuais de proteção de dados com o provedor do modelo, hospedados na UE, e seus dados nunca são usados para treinar modelos futuros.

11.10 Desativando

Account → **AI Companion** → **toggle off** desativa cada superfície de IA no aplicativo: a gaveta desaparece, a faixa de hints se colapsa, as abas designer + relatório ainda existem, mas seus botões gerar tornam-se inativos com uma dica “not enabled”.

A conversa armazenada é preservada (nada é excluído); reative depois e seu histórico de chat estará exatamente onde você o deixou.

12 Pesquisas públicas

O OpenPLS pode hospedar seu questionário em uma URL pública, coletar respostas anônimas e emendá-las de volta ao seu projeto como um conjunto de dados. Você não precisa de uma ferramenta de pesquisa de terceiros para o fluxo PLS-SEM normal.

O ciclo típico:

1. **Construir** a bateria de itens na aba Model (à mão ou com o designer de questionário por IA - veja o capítulo anterior).
2. **Publicar** o questionário em uma URL pública /q/{slug}.
3. **Compartilhar** a URL com os respondentes. Novas respostas chegam ao builder em tempo quase real.
4. **Importar** as respostas acumuladas como um conjunto de dados com um clique.
5. **Computar** o modelo no seu conjunto de dados recém-criado.

Este capítulo percorre cada etapa.

12.1 Construindo o questionário

Abra a aba **Model** de um projeto, depois a sub-visão **Form**. Se suas LVs ainda não têm indicadores, o painel começa vazio; use o designer de questionário por IA (veja o capítulo 12) ou adicione itens à mão. Cada item é uma coluna no futuro CSV de respostas.

Campos por item:

- **Wording** - a frase que os respondentes veem. Itens com codificação reversa recebem um chip R.
- **Item ID** - gerado automaticamente (por exemplo, TRUST1, SAT2), usado como nome da coluna no conjunto de dados exportado.
- **Reverse coded** - alterne o toggle se a polaridade do item é invertida (respondentes negam mentalmente). A codificação reversa é aplicada automaticamente no momento da importação.
- **LV binding** - herdado do bloco da LV pai; arraste itens entre blocos para reatribuir.

Campos globais (coluna direita):

- **Response scale** - Likert de 5 ou 7 pontos. Aplica-se a todos os itens do tipo Likert; itens

ECSI: Customer Satisfaction

Classic ECSI model (European Customer Satisfaction Index): image, expectations, perceived quality and value drive satisfaction and loyalty. Ideal as a first PLS-SEM entry point.

DATASET MODEL RESULTS ADVANCED REPORT MANAGE

DATA UPLOAD QUESTIONNAIRE BUILDER

ECSI: Customer Satisfaction

Generate 4–6 validated survey items per latent variable (6 LVs in this model). You can then edit anything inline before exporting.

Building items for:

Image · Mode A Expectations · Mode A Perceived Quality · Mode A Perceived Value · Mode A Satisfaction · Mode A Loyalty · Mode A

Response scale: 5-point Likert Language: English

5 answer options: "Strongly disagree, Disagree, Neither, Agree, Strongly agree". Faster to answer, less resolution — good for short surveys, mobile audiences.

Target audience or context (optional)

Helps the assistant adapt wording culturally.

Standard demographics (optional)

Toggle which fields to include alongside your latent-variable items.

✓ Age ✓ Gender + Country + Education + Profession + Language

START MANUALLY GENERATE ITEMS

Figura 45 O painel do questionnaire builder. Esquerda: LVs com seus itens (arraste para reordenar, clique em x para remover, clique na redação para editar). Direita: o card de publicação com escala de resposta, idioma, público-alvo e toggles de demográficos.

abertos e demográficos mantêm seu próprio tipo.

- **Audience language** - o idioma mostrado aos respondentes (English, German, Spanish, French, Italian, Japanese, Portuguese, Chinese). A redação do item permanece no idioma em que você escreveu; apenas o chrome da pesquisa (botões, progresso, página de agradecimento) é traduzido.
- **Demographics** - escolha zero ou mais dos seis campos opcionais integrados (Age, Gender, Country, Education, Language, Profession). Cada um se torna uma coluna no conjunto de dados exportado.
- **Public intro** - um parágrafo que os respondentes veem acima da primeira pergunta. Separado das suas anotações internas (que nunca aparecem na página pública).

12.2 Publicando

A seção **Publish** do painel ativa a pesquisa. Clique em **Publish**: o OpenPLS gera um slug aleatório, escreve um snapshot público do questionário na coleção de respostas e devolve a URL:

`https://cloud.openpls.app/q/f3a8k29b`

Qualquer pessoa com a URL pode responder. Nenhuma conta é necessária - o anonimato é o padrão. A página pública mostra apenas a introdução pública e os próprios itens, formatados responsivamente para celulares e desktops.

Preview abre a pesquisa em uma nova aba para que você possa percorrê-la como um respondente (suas respostas em modo de visualização não são contadas).

12.2.1 Snapshots de versão

Uma vez que respostas comecem a chegar, alterar o questionário cria um dilema de integridade de dados: se você renomear um item ou alterar sua redação no meio do caminho, as respostas acumuladas tornam-se inconsistentes. O OpenPLS lida com isso pedindo que você escolha um caminho ao salvar mudanças em uma pesquisa com respostas existentes:

- **Publish as new version** (recomendado). Aposenta a URL atual, gera um slug novo (/q/...) e zera o contador. Respostas antigas ficam arquivadas sob v1 e permanecem acessíveis para download.
- **Download responses, then save in place.** Mesma URL, mas você baixa um arquivo CSV do lote pré-mudança primeiro.
- **Save in place.** Mesma URL; respostas novas e antigas se misturam. Só use isso para correções de digitação.

Slugs aposentados permanecem online, mas param de aceitar novas respostas; os respondentes veem uma mensagem “no longer accepting responses”. O card de publicação lista todas as versões anteriores com sua contagem final de respostas para que nada seja perdido.

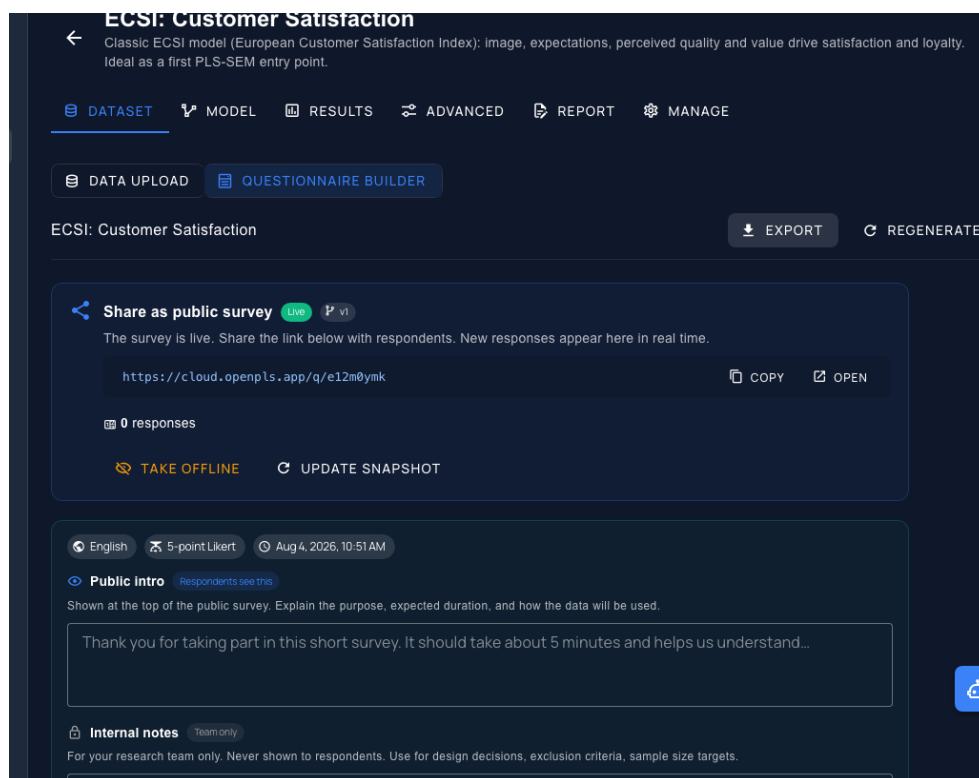


Figura 46 Um card de pesquisa publicada. A URL é mostrada com copy-to-clipboard, contador de respostas ao vivo, três ações (Preview / Unpublish / Publish as new version) e o chip de versão.

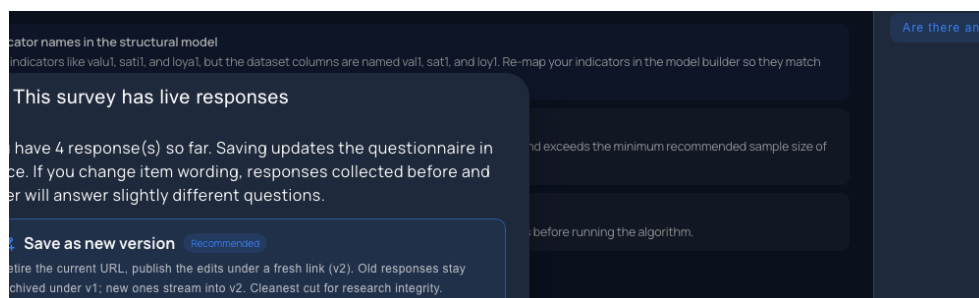


Figura 47 O diálogo de save-warn quando uma pesquisa publicada tem respostas. Três caminhos, cada um com a consequência concreta explicada.

12.3 A visão pública do respondente

Os respondentes veem um formulário limpo, de coluna única, com uma barra de progresso. Os itens são agrupados por LV para que a carga cognitiva permaneça administrável; o próprio nome da LV é ocultado (os respondentes não precisam do rótulo teórico).

Decisões de design que vale a pena conhecer:

- **Seletor de idioma.** Os respondentes podem alternar pelos oito idiomas suportados independentemente do idioma do público que você definiu - útil para implantações internacionais.
- **Guarda de uma resposta por navegador.** Uma vez submetido, um pequeno sinalizador no armazenamento local do navegador previne reenvio acidental do mesmo dispositivo. Não é à prova de adulteração (qualquer respondente determinado pode ignorar limpando o armazenamento ou usando um navegador diferente), mas impede duplos envios honestos.
- **Página de agradecimento.** Após Submit, os respondentes veem um breve reconhecimento. Sem prompt de criação de conta, sem marketing.
- **Mobile-first.** O formulário funciona até ~320 px de viewport; os cards de item se empilham, o seletor de idioma vira um menu compacto.

12.4 Assistindo respostas chegarem

O card de publicação no builder mostra a contagem atual de respostas em tempo quase real (atualiza em poucos segundos após cada envio). Abaixo do contador, uma pequena seção **Recent** lista as últimas cinco submissões com seu timestamp e idioma.

12.5 Importando respostas como um conjunto de dados

Quando você tem respostas suficientes para computar o modelo - para um estudo PLS-SEM típico, pelo menos 100 para trabalho exploratório; 200+ para inferência com qualidade de publicação - clique em **Import as dataset** no card de publicação.

O OpenPLS cria um conjunto de dados novo no seu projeto. Layout de colunas:

- **Colunas item_id** - uma por item da pesquisa, usando os IDs de item TRUST1, TRUST2, ... que você definiu. O valor da célula é a resposta Likert como inteiro (1..5 ou 1..7). Itens com codificação reversa são revertidos na importação para que o código posterior não precise se lembrar.
- **Colunas de demográficos** - uma por campo demográfico que você ativou (age, gender, country, ...). String ou inteiro dependendo do tipo do campo.
- **submitted_at** - timestamp ISO 8601 de quando a resposta foi submetida, útil para filtros temporais ou análise por onda.
- **language** - o idioma que o respondente usou, útil para comparações MICOM/MGA entre idiomas.

ECSI: Customer Satisfaction

About you

Age *

Gender *

Image

Rate each statement on a 5-point scale.

The organization has a very positive reputation in the market.

☐ 1☐ 2☐ 3☐ 4☐ 5

← Strongly disagree Strongly agree →

I consider this organization to be stable and trustworthy.

☐ 1☐ 2☐ 3☐ 4☐ 5

← Strongly disagree Strongly agree →

This organization stands for quality and customer focus.

☐ 1☐ 2☐ 3☐ 4☐ 5

← Strongly disagree Strongly agree →

The organization contributes positively to the community.

☐ 1☐ 2☐ 3☐ 4☐ 5

← Strongly disagree Strongly agree →

Overall, this organization has a poor public image.

☐ 1☐ 2☐ 3☐ 4☐ 5

← Strongly disagree Strongly agree →

Expectations

Rate each statement on a 5-point scale.

I expected the products and services to be highly reliable.

☐ 1☐ 2☐ 3☐ 4☐ 5

← Strongly disagree Strongly agree →

I anticipated receiving personalized attention from the staff.

☐ 1☐ 2☐ 3☐ 4☐ 5

← Strongly disagree Strongly agree →

I expected the overall experience to meet my high standards.

☐ 1☐ 2☐ 3☐ 4☐ 5

← Strongly disagree Strongly agree →

I anticipated encountering numerous problems with the service.

☐ 1☐ 2☐ 3☐ 4☐ 5

← Strongly disagree Strongly agree →

Figura 48 A página pública da pesquisa renderizada no desktop. Seletor de idioma no canto superior direito, barra de progresso, cards de item com botões de rádio, navegação Previous / Next e uma ação Submit final.

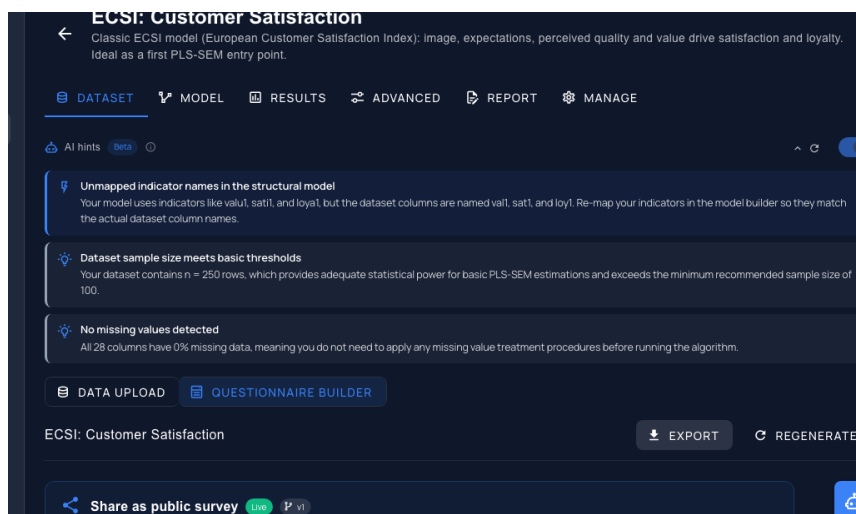


Figura 49 O contador de respostas e a lista recente. O contador atualiza ao vivo; a lista recente mostra submitted_at mais a bandeira do idioma.

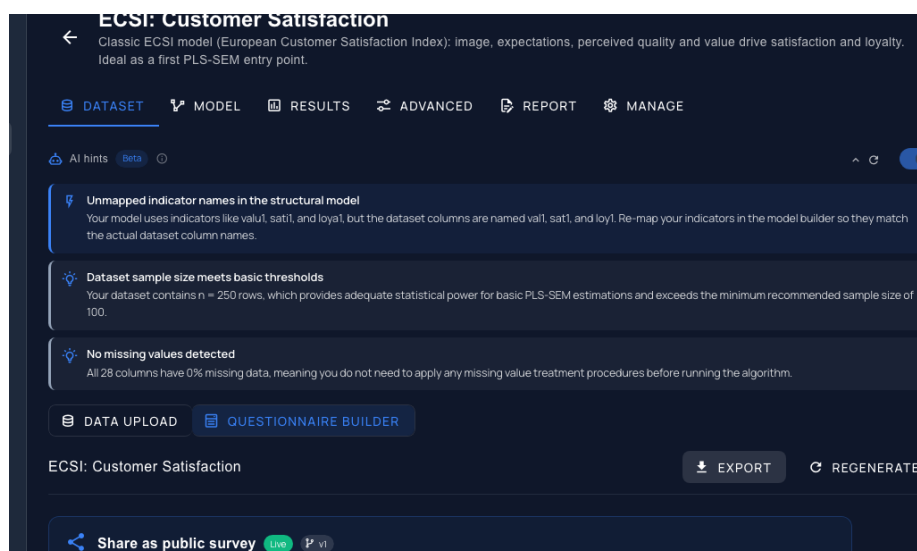


Figura 50 O botão import-as-dataset no card de publicação. O diálogo de confirmação mostra: colunas de item, colunas de demográficos, tamanho da amostra e versão. Clique em **Create dataset** para gravar.

Abra a aba Data; o novo conjunto de dados está Ready. Compute o modelo como de costume. Se você publicar uma nova versão depois, importar novamente grava um conjunto de dados **separado** - o antigo é preservado para que você possa comparar as estimativas antes e depois da mudança do questionário.

12.6 Baixando um CSV bruto

Se você preferir levar as respostas para uma ferramenta externa (R, Stata, SPSS, Python), clique em **Download responses (CSV)** no card de publicação. O CSV tem as mesmas colunas que o conjunto de dados importado. Cada linha é uma submissão; células vazias significam que o respondente pulou aquele campo opcional.

Downloads contam apenas submissões completadas. Respostas parciais (o respondente fechou a aba antes do Submit) não chegam ao banco de dados.

12.7 Despublicando

Unpublish tira a URL do ar. As respostas existentes permanecem acessíveis no builder e ainda podem ser baixadas ou importadas; novos visitantes veem uma página “not accepting responses”. A URL não é liberada - clicar em Publish novamente no mesmo questionário reutiliza o mesmo slug onde possível.

Tenha cuidado: se você publicar → coletar → despublicar → alterar o questionário → republicar → coletar, você terá respostas mistas vinculadas ao mesmo slug de URL. O diálogo de save-warn acima previne isso no fluxo normal de edição, mas despublicar seguido de edição seguido de republicação é uma saída de emergência que o ignora. Prefira **Publish as new version** sempre que o questionário mudar de forma significativa.

12.8 Limites e convenções

- **Limite de respostas por pesquisa:** sem limite rígido durante o beta. O teto suave realista é alguns milhares por pesquisa por projeto antes que o contador ao vivo atrase perceptivelmente. Para 10 000+ respostas, divida em várias pesquisas ou use um provedor externo de painel.
- **Retenção de respostas:** indefinida enquanto o projeto pai existir. Excluir o projeto propaga a exclusão para as respostas.
- **Anonimato:** apenas o que os respondentes inserem é armazenado. Endereço IP, User-Agent e qualquer outro cabeçalho identificador não são persistidos. Se você quer respostas identificáveis (por exemplo, para um estudo de painel), adicione você mesmo um campo de ID de respondente como item de pesquisa.

13 Apêndice

13.1 Glossário

AVE: Average Variance Extracted. Média das cargas dos indicadores ao quadrado para uma LV reflexiva. Acima de 0,5 = a LV explica mais variância em seus indicadores do que o erro.

BIC: Bayesian Information Criterion. Índice de ajuste de modelo que penaliza parâmetros adicionais; menor é melhor; comparável apenas entre especificações aninhadas.

Bootstrap: reamostragem com reposição para derivar erros padrão, p-valores e intervalos de confiança para estatísticas que não têm distribuição analítica.

Composite reliability (ρ_c , ρ_{θ_c}): o padrão moderno para confiabilidade em PLS-SEM. Acima de 0,7 aceitável, acima de 0,95 sugere indicadores redundantes.

CMB: Common Method Bias. Erro sistemático induzido pelo instrumento de mensuração e não pelos construtos sendo medidos. Diagnosticado via marcador Lindell-Whitney ou teste de fator único de Harman.

CVPAT: Cross-Validated Predictive Ability Test. Compara a perda fora da amostra do PLS contra um benchmark (média do indicador ou modelo linear).

Endogeneidade: um preditor é correlacionado com o termo de erro. Viola as suposições do OLS; corrigida no PLS via a abordagem de cópula gaussiana.

LV endógena: um construto com pelo menos um caminho de entrada. Contrasta com exógena.

LV exógena: um construto com apenas caminhos de saída. Sua variância não é explicada pelo modelo.

FIMIX-PLS: Finite-Mixture PLS. Descobre classes latentes quando você suspeita de heterogeneidade não observada.

Formativo (Mode B), modelo de mensuração onde os indicadores causam a LV (renda + escolaridade + ocupação → SES).

Fornell-Larcker: teste clássico de validade discriminante: $\sqrt{AVE(A)} > \text{correlação}(A, B)$ para cada par A, B.

GoF: Goodness-of-Fit. $\sqrt{(\text{mean}(\text{communality}) \times \text{mean}(R^2))}$. Proxy de qualidade geral do modelo.

HTMT: razão Heterotrait-Monotrait. Teste moderno de validade discriminante. Acima de 0,85 (conservador) ou 0,90 (liberal) sugere que os construtos são muito semelhantes.

HOC: Higher-Order Construct. Um construto composto por múltiplas LVs de primeira ordem (por exemplo, Brand Experience = Sensory + Affective + Intellectual + Behavioral).

Indicador / Variável manifesta (MV): uma coluna observada do conjunto de dados que mede uma variável latente.

Modelo interno: os caminhos estruturais entre LVs. Contrasta com modelo externo.

IPMA: Importance-Performance Map Analysis. Identifica quais predecessores de uma LV alvo

combinam alta importância com baixo desempenho (a maior alavanca de melhoria).

Variável latente (LV): um construto não observado medido indiretamente por meio de indicadores.

Carga: a correlação entre um indicador e sua LV em um modelo de mensuração reflexivo.

Modelo de mensuração: as setas entre LVs e seus indicadores. Reflexivo (Mode A) ou Formativo (Mode B).

MGA: Multi-Group Analysis. Testa se os coeficientes de caminho diferem entre grupos.

MICOM: Measurement Invariance of Composite Models. Pré-requisito para MGA/moderação entre grupos.

Mode A: mensuração reflexiva (LV → indicadores).

Mode B: mensuração formativa (indicadores → LV).

Moderação: o efeito de X sobre Y depende de uma terceira variável Z. Testado por um termo de interação $X \times Z$.

Modelo externo: as setas entre LVs e indicadores. Contrasta com modelo interno.

Coefficiente de caminho (β): a força padronizada de uma seta do modelo interno. Interprete como um beta de regressão OLS.

PLSc: PLS consistente. Corrige o viés de atenuação quando os construtos são verdadeiramente common-factor em vez de composite.

PLSpredict: avaliação preditiva fora da amostra via validação cruzada k-fold.

Q²: redundância validada cruzadamente de Stone-Geisser. Acima de 0 = relevância preditiva.

Q²_predict: a variante do Q² do PLSpredict usando CV k-fold.

Reflexivo (Mode A), a LV causa seus indicadores. Mude o construto e todos os indicadores mudam juntos.

R²: variância em uma LV endógena explicada por seus predecessores. Dentro da amostra.

SRMR: Standardized Root Mean Square Residual. Abaixo de 0,08 bom ajuste, abaixo de 0,10 aceitável.

Modelo estrutural: o mesmo que modelo interno.

Estatística t: estimativa do caminho dividida por seu erro padrão do Bootstrap. Acima de ~1,96 significativo em $\alpha = 0,05$.

VIF: Variance Inflation Factor. Abaixo de 5 colinearidade aceitável, abaixo de 3 mais estrito. Aplicado tanto a indicadores formativos (outer VIF) quanto a LVs preditoras em cada bloco endógeno (inner VIF).

13.2 Atalhos de teclado

Editor

- Cmd+Z / Ctrl+Z, desfazer
- Cmd+Shift+Z / Ctrl+Y, refazer
- Delete ou Backspace em uma LV selecionada, remove a LV e seus caminhos
- Duplo clique em uma aresta, remove o caminho

Operações de arrastar no Editor

- Arraste da alça de origem da LV (ponto azul, lado direito) para a alça de destino da LV (ponto verde, lado esquerdo), desenhe um novo caminho
- Arraste um chip de indicador da barra lateral direita para um círculo de LV, atribua o indicador àquela LV

Em todo o app

- Cmd+K / Ctrl+K, futuro: paleta de comandos (roadmap)

13.3 Referências

Bakker, A. B., & Demerouti, E. (2017). Job demands-resources theory: Taking stock and looking forward. *Journal of Occupational Health Psychology*, 22(3), 273-285.

Brakus, J. J., Schmitt, B. H., & Zarantonello, L. (2009). Brand experience: What is it? How is it measured? Does it affect loyalty? *Journal of Marketing*, 73(3), 52-68.

Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3), 319-340.

Dijkstra, T. K., & Henseler, J. (2015). Consistent partial least squares path modeling. *MIS Quarterly*, 39(2), 297-316.

Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2022). *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)*. 3rd ed. Sage.

Hair, J. F., Sarstedt, M., Ringle, C. M., & Gudergan, S. P. (2018). *Advanced Issues in Partial Least Squares Structural Equation Modeling*. Sage.

Henseler, J. (2021). *Composite-Based Structural Equation Modeling: Analyzing Latent and Emergent Variables*. Guilford Press.

Henseler, J., & Chin, W. W. (2010). A comparison of approaches for the analysis of interaction effects between latent variables using partial least squares path modeling. *Structural Equation Modeling*, 17(1), 82-109.

Henseler, J., Ringle, C. M., & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), 115-135.

- Hult, G. T. M., Hair, J. F., Proksch, D., Sarstedt, M., Pinkwart, A., & Ringle, C. M. (2018). Addressing endogeneity in international marketing applications of partial least squares structural equation modeling. *Journal of International Marketing*, 26(3), 1-21.
- Lindell, M. K., & Whitney, D. J. (2001). Accounting for common method variance in cross-sectional research designs. *Journal of Applied Psychology*, 86(1), 114-121.
- Park, S., & Gupta, S. (2012). Handling endogenous regressors by joint estimation using copulas. *Marketing Science*, 31(4), 567-586.
- Russett, B. M. (1964). Inequality and Instability: The Relation of Land Tenure to Politics. *World Politics*, 16(3), 442-454.
- Sarstedt, M., Hair, J. F., Cheah, J.-H., Becker, J.-M., & Ringle, C. M. (2019). How to specify, estimate, and validate higher-order constructs in PLS-SEM. *Australasian Marketing Journal*, 27(3), 197-211.
- Schuberth, F., Rademaker, M. E., & Henseler, J. (2023). Assessing the overall fit of composite models estimated by partial least squares path modeling. *European Journal of Marketing*, 57(6), 1678-1702.
- Shmueli, G., Ray, S., Estrada, J. M. V., & Chatla, S. B. (2016). The elephant in the room: Predictive performance of PLS models. *Journal of Business Research*, 69(10), 4552-4564.
- Tenenhaus, M., Vinzi, V. E., Chatelin, Y.-M., & Lauro, C. (2005). PLS path modeling. *Computational Statistics & Data Analysis*, 48(1), 159-205.
- Venkatesh, V., Thong, J. Y., & Xu, X. (2012). Consumer acceptance and use of information technology: Extending the unified theory of acceptance and use of technology. *MIS Quarterly*, 36(1), 157-178.