

## USO DE IA GENERATIVA PARA OTIMIZAÇÃO DA ANÁLISE DE RESULTADOS DE TESTES SENSORIAIS DE ALIMENTOS

Eduardo Luft<sup>1</sup>, Gabriela Zago<sup>2</sup>, Júlia Favaretto<sup>3</sup>, Edson Moacir Ahlert<sup>4</sup>

**Resumo:** O estudo apresenta a aplicação de inteligência artificial generativa para aprimorar o processamento e a interpretação de resultados de testes sensoriais em uma indústria de bebidas. O processo inicial, baseado em formulários impressos e compilação manual, demandava cerca de duas horas por teste e apresentou maior suscetibilidade a erros de transcrição. A digitalização por meio de tablets e Microsoft Forms reduziu o tempo de preparação, padronizou o registro das respostas e aumentou a rastreabilidade, eliminando integralmente a etapa manual de compilação. Em seguida, artefatos computacionais desenvolvidos com a IA generativa Claude foram estruturados de acordo com as normas ABNT aplicáveis aos testes triangular (NBR ISO 4120:2020) e de ordenação de preferência (NBR ISO 8587:2015), automatizando cálculos estatísticos, interpolando valores críticos quando necessários e gerando relatórios e gráficos instantâneos compatíveis com os métodos convencionais. A comparação entre o processamento manual e o automatizado evidenciou redução expressiva no tempo de análise – de aproximadamente duas horas para poucos minutos – sem perda de precisão estatística ou conformidade metodológica. Os resultados demonstram que a integração entre métodos sensoriais tradicionais e soluções baseadas em IA generativa aumenta a eficiência operacional, reduz variabilidades associadas ao tratamento manual de dados e fortalece a padronização das rotinas de controle de qualidade na indústria de alimentos e bebidas.

**Palavras-chave:** análise sensorial; inteligência artificial generativa; teste triangular; ordenação de preferência; automação de dados.

---

1 Estudante de Engenharia Química - Universidade do Vale do Taquari - Univates. E-mail: [eduardo.luft@universo.univates.br](mailto:eduardo.luft@universo.univates.br)

2 Estudante de Engenharia de Produção - Universidade do Vale do Taquari - Univates. E-mail: [gabriela.zago@universo.univates.br](mailto:gabriela.zago@universo.univates.br)

3 Estudante de Engenharia Química - Universidade do Vale do Taquari - Univates. E-mail: [julia.favaretto@universo.univates.br](mailto:julia.favaretto@universo.univates.br)

4 Professor da Universidade do Vale do Taquari - Univates.

# USE OF GENERATIVE AI FOR OPTIMIZING THE ANALYSIS OF SENSORY FOOD TEST RESULTS

**Abstract:** The study presents the application of generative artificial intelligence to enhance the processing and interpretation of sensory test results in a beverage industry. The initial process, based on printed forms and manual data compilation, required approximately two hours per test and was more susceptible to transcription errors. Digitalization through tablets and Microsoft Forms reduced preparation time, standardized response recording, and increased data traceability, fully eliminating the manual compilation stage. Subsequently, computational artifacts developed with the Claude generative AI were structured according to the ABNT standards applicable to triangle tests (NBR ISO 4120:2020) and preference ranking tests (NBR ISO 8587:2015), automating statistical calculations, interpolating critical values when necessary, and generating instant reports and graphs consistent with conventional methods. The comparison between manual and automated processing demonstrated a substantial reduction in analysis time – from roughly two hours to a few minutes – without loss of statistical accuracy or methodological compliance. The results indicate that integrating traditional sensory evaluation methods with generative AI-based solutions enhances operational efficiency, reduces variability associated with manual data handling, and strengthens the standardization of quality control routines in the food and beverage industry.

**Keywords:** sensory analysis; generative artificial intelligence; triangle test; preference ranking; data automation.

## 1 INTRODUÇÃO

A análise sensorial é um instrumento essencial para o controle de qualidade e o desenvolvimento de produtos alimentícios, permitindo mensurar de forma científica as percepções humanas sobre sabor, aroma, textura e aparência. Essa prática utiliza métodos padronizados, como ABNTs, para garantir resultados reproduzíveis e confiáveis.

Para Dutcosky (2022), a aplicação adequada desses métodos apoia a melhoria contínua, a inovação e a adequação dos produtos às preferências do consumidor, consolidando-se como uma ferramenta estratégica no ambiente industrial.

Entretanto, a crescente demanda produtiva e a limitação de mão de obra qualificada impõem desafios à análise e interpretação dos dados sensoriais. Nesse contexto, ferramentas de inteligência artificial têm sido empregadas para acelerar o tratamento dos dados sensoriais e reduzir erros operacionais. A fundamentação técnica dessas tecnologias será discutida na seção de Referencial Teórico. A integração entre métodos sensoriais, estatística e IA generativa potencializa a eficiência dos processos e fortalece a gestão da qualidade, alinhando-se às exigências de competitividade e inovação da indústria moderna.

Com isso, o intuito do trabalho é otimizar o processo de análise de dados sensoriais, por meio da geração de artefatos em plataformas LLM, como o Claude, que possibilitem otimizar o tempo gasto, padronizar análises e relatórios e assegurar uma tomada de decisão.

## 2 REFERENCIAL TEÓRICO

Esta seção reúne os conceitos essenciais que sustentam o desenvolvimento da proposta. Inicialmente, são apresentados os métodos sensoriais mais utilizados, com destaque para o teste triangular e o teste de ordenação de preferência. Em seguida, abordam-se os princípios da inteligência artificial generativa e sua utilização no tratamento e na interpretação de dados sensoriais. A integração desses fundamentos oferece o suporte teórico necessário para entender de que forma essas tecnologias podem contribuir para o aprimoramento dos processos de análise.

### 2.1 Testes sensoriais: triangular e preferência

A análise sensorial compreende diferentes métodos classificados, de modo geral, em testes discriminativos e testes afetivos. Os testes discriminativos têm como objetivo identificar se existe diferença perceptível entre amostras, enquanto os testes afetivos avaliam a aceitação ou preferência do consumidor, refletindo julgamentos subjetivos (Dutcosky, 2017; Oliveira, 2022).

Entre os testes discriminativos, destaca-se o teste triangular, no qual cada provador recebe três amostras, duas idênticas e uma diferente, e deve identificar aquela que difere das demais. Caso o número de acertos seja superior ao esperado ao acaso, conclui-se que há diferença sensorial significativa entre os produtos comparados (Oliveira, 2022). Os testes de preferência, por sua vez, integram a categoria dos testes afetivos, pois envolvem consumidores não treinados que manifestam sua escolha subjetiva entre produtos.

A análise dos resultados sensoriais geralmente inclui a contagem das respostas favoráveis ou corretas e a aplicação de procedimentos estatísticos, como o teste binomial, para verificar a significância estatística das diferenças observadas (Dutcosky, 2017; ABNT, 2017). Dessa forma, tanto os testes discriminativos quanto os afetivos fornecem informações essenciais para o desenvolvimento e a otimização de produtos.

### 2.2 IA generativa: conceitos e aplicabilidade na análise sensorial

A inteligência artificial generativa compreende modelos capazes de criar novos dados e conteúdos a partir do aprendizado em grandes volumes de informações. Entre suas principais tecnologias estão os Large Language Models (LLMs) e as redes geradoras adversariais (GANs). LLMs são modelos de linguagem treinados com vastas quantidades de texto que aprendem os

padrões linguísticos e conseguem gerar textos coerentes e contextualmente relevantes (Wang *et al.*, 2022). Já as GANs são compostas por duas redes neurais que competem entre si para produzir dados sintéticos realistas, úteis para imagens, sons e também dados sensoriais (Goodfellow *et al.*, 2014).

Na análise sensorial aplicada à indústria alimentícia, a IA generativa tem sido empregada para modelar dados sensoriais complexos e aprimorar a caracterização de atributos como sabor, aroma e textura, reduzindo vieses e aumentando a precisão das avaliações (Observatório De La Economía Latinoamericana, 2024). Tais sistemas utilizam a capacidade dos modelos generativos para interpretar e sintetizar padrões sensoriais conscientes e inconscientes, favorecendo o desenvolvimento de produtos mais atrativos e seguros.

A aplicação destes avanços permite a inovação na ciência sensorial, integrando tecnologias como sensores eletrônicos e softwares baseados em IA generativa para análises rápidas, confiáveis e em grande escala, fundamentais para a competitividade do setor alimentício (Observatório De La Economía Latinoamericana, 2024).

### **3 PROCEDIMENTOS METODOLÓGICOS**

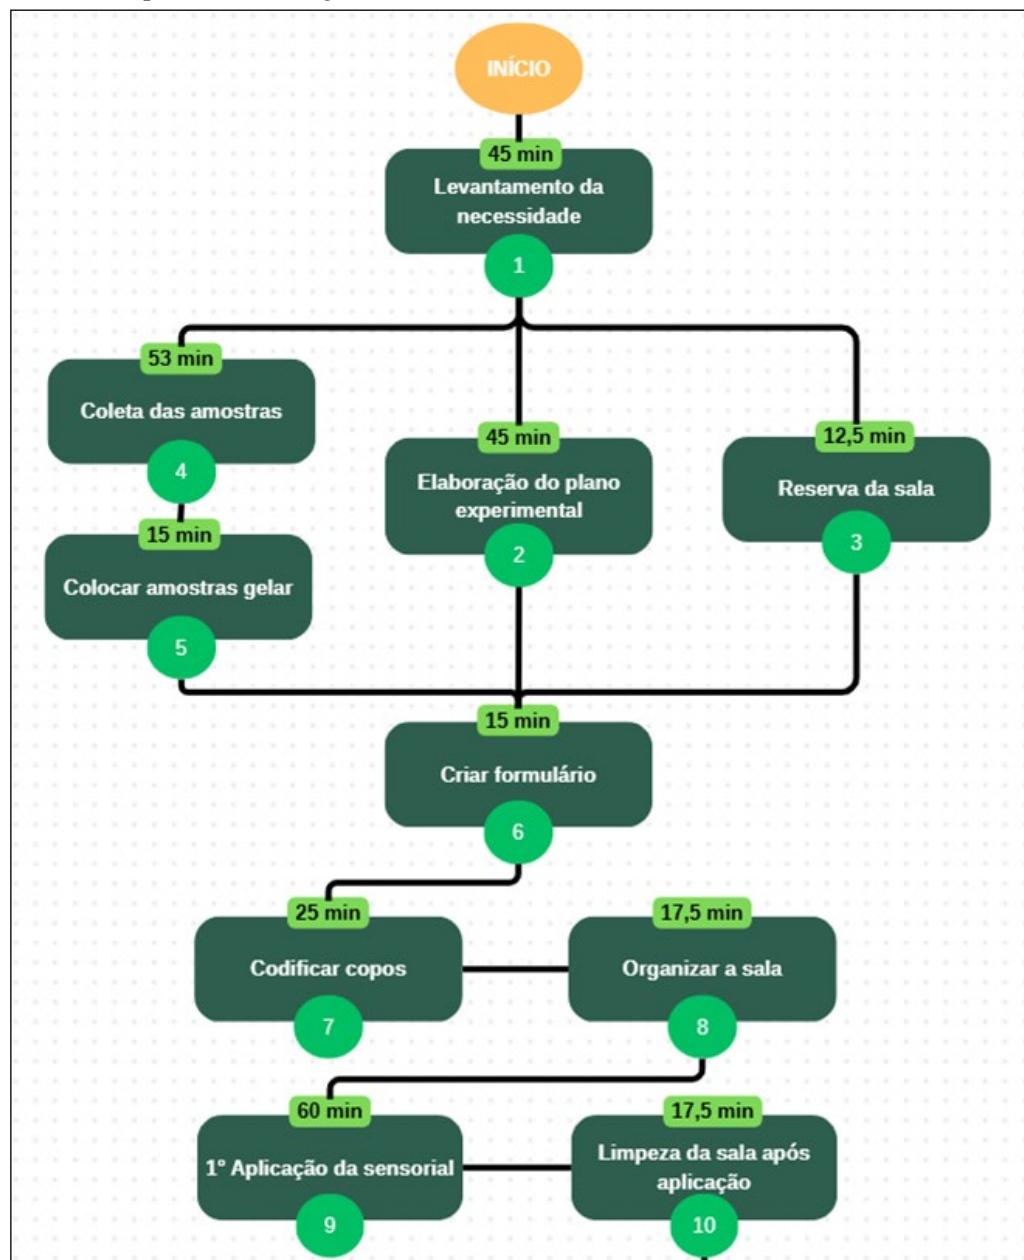
Os procedimentos metodológicos incluem o mapeamento do processo sensorial atual, a identificação de seus principais gargalos e a implementação de melhorias baseadas em digitalização e automação com IA generativa. Também envolve a comparação dos resultados obtidos pelas novas ferramentas com os cálculos previstos nas normas da ABNT, para validar a precisão das análises.

#### **3.1 Introdução ao processo atual**

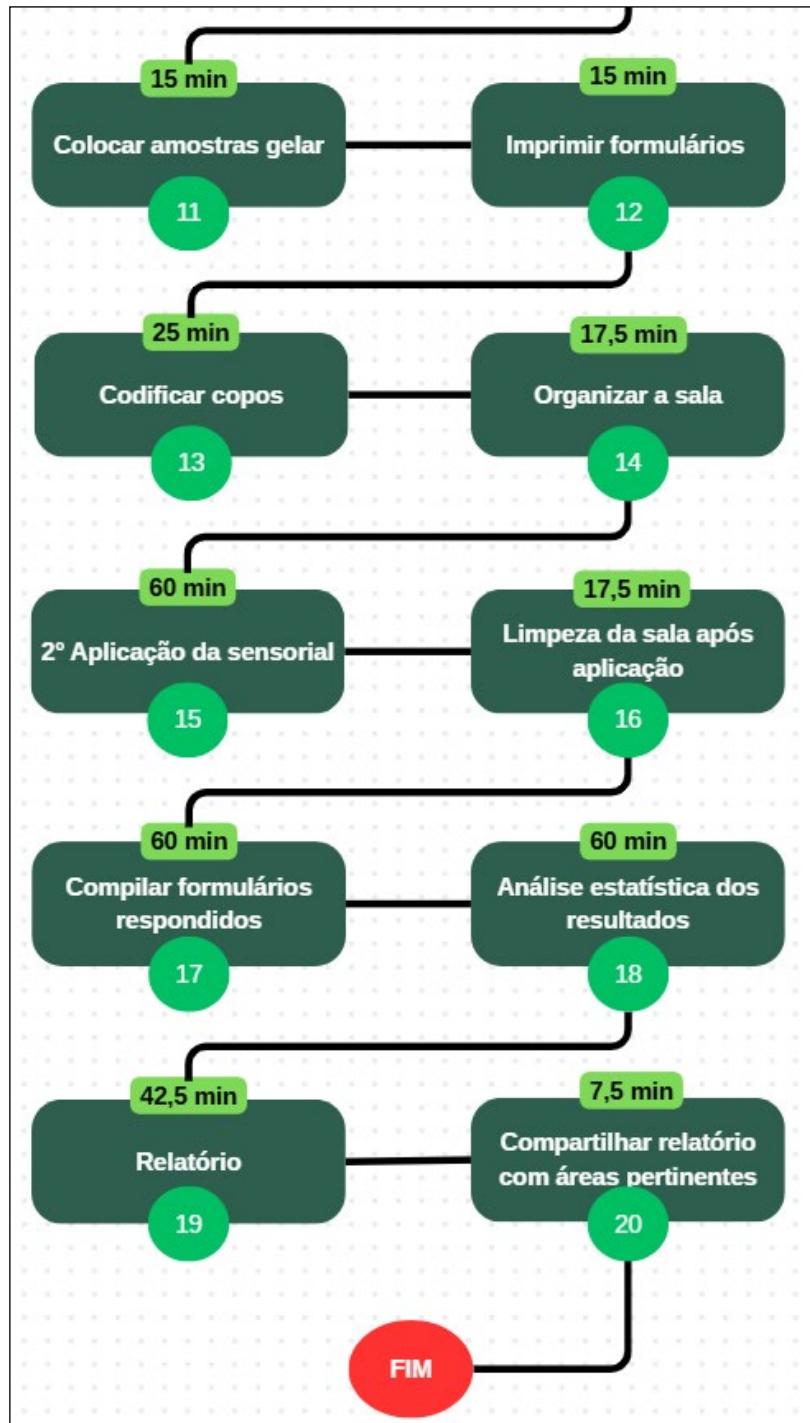
O estudo foi conduzido com base no processo de aplicação de análises sensoriais de uma indústria de bebidas. O processo atual envolve cerca de 20 etapas, desde o planejamento prévio do teste sensorial até a execução e consolidação das avaliações coletadas. As cerca de 20 etapas mencionadas estão representadas nos fluxogramas da Figura 1, que sintetiza desde o planejamento do teste até a consolidação dos resultados pelo painel. Como é utilizado um painel não treinado, normalmente realiza-se duas sessões para cada teste, garantindo a quantidade mínima de participantes exigida para que os resultados tenham validade estatística. Esse fluxo permite que as análises sejam conduzidas com rigor e que os dados obtidos representem de forma confiável a percepção dos consumidores.

Figura 1 - Fluxograma do processo atual na indústria de bebidas

(a) Parte superior do fluxograma



(b) Parte inferior do fluxograma



Fonte: Dos autores (2025).

O processo atual é realizado com formulários impressos, que gera um alto gasto de papel a longo prazo. Além disso, por causa dos formulários impressos é necessário uma hora para compilar esses formulários, tempo esse que quando somado ao processo de análise de dados, resulta em duas horas.

### **3.2 Primeira melhoria: Uso de tablets e Microsoft Forms**

A primeira melhoria implementada no processo consistiu na adoção de tablets para a aplicação dos formulários e na migração da coleta de dados para o Microsoft Forms. Essa mudança substituiu o preenchimento em papel e a posterior compilação manual, etapa que anteriormente consumia cerca de uma hora antes do início da análise estatística.

O uso do Forms permitiu a geração automática de planilhas estruturadas, eliminando erros de transcrição e reduzindo significativamente o tempo total de preparação dos dados. Essa digitalização também padronizou o registro das respostas, aumentando a confiabilidade das informações e favorecendo a rastreabilidade do processo, além de facilitar a acessibilidade aos colaboradores PCDs, que já estão mais familiarizados com o uso de dispositivos eletrônicos. O aluguel desse equipamento é de 200 reais por mês para cada tablet.

### **3.3 Segunda Melhoria: automação com Claude**

A segunda melhoria envolveu a automação da análise dos dados por meio da inteligência artificial Claude, utilizada para processar os resultados imediatamente após a coleta. Essa IA generativa foi selecionada devido à sua capacidade de estruturar rapidamente artefatos funcionais, alinhados às exigências metodológicas das normas aplicáveis. Os prompts foram estruturados de forma a traduzir diretamente as exigências metodológicas das normas ABNT para instruções operacionais, garantindo que os cálculos estatísticos e relatórios gerados pela IA generativa permanecessem compatíveis com os requisitos normativos (Tabela 1).

Quadro 1 - Prompts utilizados para a criação dos artefatos

<b>Tipo de sensorial</b>	<b>Prompt</b>
Análise Triangular	Claude, crie uma planilha que analisa dados de uma sensorial triangular, utilize a ABNT 4120 de análise triangular como parâmetro e ao invés de criar um campo para colocar a avaliação de cada provador, coloque um campo para a quantidade geral de avaliações e um para a quantidade de acertos, e faça a análise com base nisso. Faça gráficos também.

<b>Tipo de sensorial</b>	<b>Prompt</b>
Ordenação de Preferência	Crie um artefato que seja capaz de analisar os dados de uma análise sensorial de ordenação de preferência, use a ABNT 8587 de ordenação como referência, de modo que seja possível colocar a quantidade de votos que cada amostra recebeu em cada colocação para a análise, sem que seja necessário colocar o ranking de cada avaliador individualmente, considere que geralmente são testadas 3 amostras mas é possível de ter testes com mais.

Fonte: Dos autores (2025).

Dessa maneira o Claude desenvolveu os seguintes artefatos Figuras 2 e 3). Um para cada tipo de análise sensorial, com características e entradas que atendem cada caso. Além de criação de gráficos para uso em relatórios.

Figura 2 - Artefato criado para análise sensorial triangular

(a) Dados de entrada do artefato

Claude Content is user-generated and unverified.

**Análise Sensorial Triangular**  
Conforme ABNT NBR ISO 4120

Total de Provedores  
30

Quantidade de Acertos  
15

Nível de Significância ( $\alpha$ )  
5% ( $\alpha = 0,05$ )

**Analizar Dados**

**✓ Diferença Significativa Detectada**

Acertos obtidos: 15  
Valor crítico: 14  
Percentual de acerto: 50.0%

Total de provedores: 30  
Acertos esperados ao acaso: 10.0  
Nível de significância: 5%

**Interpretação:** Com 15 acertos, há evidência estatística suficiente para afirmar que existe diferença perceptível entre as amostras ao nível de significância de 5%.

(b) Análises e gráficos gerados



Fonte: Dos autores(2025).

Figura 3 - Artefato criado para análise sensorial de ordenação de preferência.

(a) Dados de entrada do artefato

The screenshot shows a web-based application titled "Análise Sensorial - Ordenação de Preferência". At the top, it says "ABNT NBR 8587 - Teste de Ordenação". Below this is a section titled "Como usar:" with instructions:

1. Defina o número de amostras testadas
2. Insira quantos julgadores colocaram cada amostra em cada posição
3. A análise estatística será calculada automaticamente

Below the instructions, there is a field labeled "Número de Amostras" with the value "3". The main area contains a table with the following data:

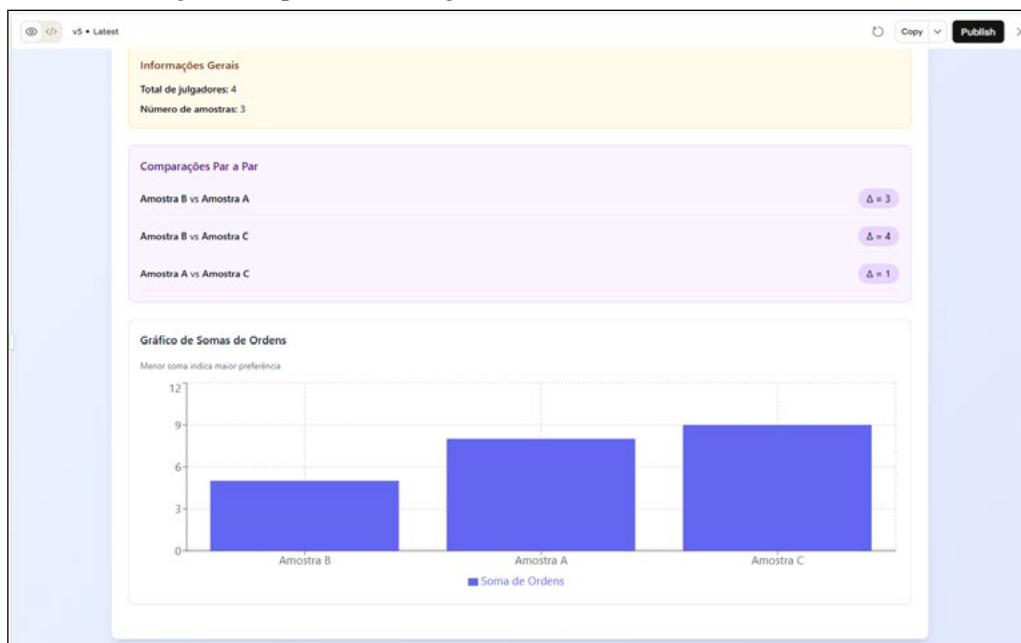
Amostra	1º lugar	2º lugar	3º lugar	Total de Votos	Soma de Ordens
Amostra A	1	2	1	4	8
Amostra B	3	1	0	4	5
Amostra C	1	1	2	4	9

Below the table is a section titled "Ranking de Preferência" with the following results:

- 1º - Amostra B (Soma: 5)
- 2º - Amostra A (Soma: 8)
- 3º - Amostra C (Soma: 9)

At the bottom left, there is a "Informações Gerais" section with "Total de julgadores: 4".

(b) Cálculos e gráficos que o artefato gera



Fonte: Dos autores(2025).

Os resultados gerados pela IA generativa foram comparados ao método tradicional, revelando redução expressiva no tempo de análise, que antes exigia cerca de uma hora e passou a ocorrer em poucos minutos. A validação da ferramenta foi realizada mediante confrontação dos outputs com cálculos feitos conforme as orientações estatísticas da ABNT aplicáveis ao tipo de teste, assegurando consistência, repetibilidade e conformidade normativa.

### 3.4 Validação dos dados

Após a implementação das melhorias, procedeu-se à validação dos resultados para verificar sua conformidade com os padrões estatísticos estabelecidos pelas normas da ABNT. Para validar os dados obtidos com o uso da IA generativa, vamos utilizar os cálculos fornecidos pelos padrões da ABNT. É extremamente importante realizar a validação tendo em vista que a tabela oferecida pela ABNT não possui todos os valores calculados e a IA generativa precisa realizar uma interpolação, o que pode acarretar em erros.

#### 3.4.1 Teste triangular - Análise pelo método convencional

Em situações com número elevado de julgadores, a distribuição binomial pode ser aproximada pela normal, utilizando-se correção de continuidade. O resultado final é interpretado em termos de significância sensorial: se o número de acertos ultrapassar o valor crítico estabelecido pela tabela da norma ou pelo cálculo estatístico, conclui-se que a diferença entre as amostras é reconhecida de forma consistente pelos julgadores (Dutcosky, 2019; Lawless; Heymann, 2010).

Por exemplo, considerando um teste triangular com 74 julgadores válidos e nível de significância de 5%, espera-se que, ao acaso, aproximadamente 24,7 acertos ocorram ( $74 \times (\frac{1}{2})$ ). A variância esperada é  $74 \times (\frac{1}{2}) \times (\frac{1}{2}) = 16,44$ , resultando em um desvio-padrão de aproximadamente 4,06. Para avaliar o resultado obtido, calcula-se a probabilidade de ocorrência de um número igual ou superior de acertos ao observado, sob a hipótese nula.

Se, por exemplo, 32 julgadores identificarem corretamente a amostra diferente, temos  $Z = ((32 - 24,67 - 0,5) / 4,06) = 1,69$ , o que corresponde a um p-valor  $\approx 0,046$ , inferior a 0,05. Assim, temos que 32 é o valor crítico, a partir dele tem diferença significativa entre as amostras.

#### 3.4.2 Teste triangular - Análise pelo artefato desenvolvido

Os dados de entrada para o uso do artefato são a quantidade de provadores/avaliadores, a quantidade de acertos e adota nível de significância  $\alpha = 0,05$ , conforme prática usual em testes discriminativos. Colocando os mesmos dados do exemplo no artefato desenvolvido no Claude temos os seguintes dados de entrada e o seguinte resultado (Figura 4).

Figura 4 - Artefato desenvolvido para sensorial triangular

(a) Dados de entrada

## Análise Sensorial Triangular

Conforme ABNT NBR ISO 4120

Total de Provadores  
74

Quantidade de Acertos  
30

Nível de Significância ( $\alpha$ )  
5% ( $\alpha = 0,05$ )

Analizar Dados   Limpar

(b) Resultado obtido

### X Sem Diferença Significativa

**Acertos obtidos:** 30

**Valor crítico:** 32

**Percentual de acerto:** 40.5%

**Total de provadores:** 74

**Acertos esperados ao acaso:** 24.7

**Nível de significância:** 5%

**Interpretação:** Com 30 acertos de 74 provadores, não há evidência estatística suficiente para afirmar que existe diferença perceptível entre as amostras. São necessários pelo menos 32 acertos para detectar diferença significativa ao nível de 5%.

Fonte: Dos autores (2025).

No caso desse artefato, a revisão da interpolação foi necessária porque o artefato havia arredondado o valor crítico para 34, diferindo do valor correto (32) calculado pelo método convencional segundo a ABNT NBR ISO 4120:2020.

Porém, após a correção, a análise foi obtida em poucos segundos, eliminando a necessidade de cálculos manuais conforme o método convencional.

### 3.4.3 Teste de preferência - Análise pelo método convencional

Da mesma forma, realizamos a validação do artefato da ordenação de preferência, e para isso criamos o seguinte exemplo (Quadro 2), com dados gerados por IA generativa. Nele temos a quantidade de votos que cada amostra ganhou em cada posição. Sendo que cada avaliador tinha que escolher a ordem do seu ranking individual de acordo com a sua preferência pessoal.

Quadro 2 - Dados utilizados para o teste de validação do artefato

Dados para análise	1º lugar	2º lugar	3º lugar
Amostra A	48	30	12
Amostra B	28	34	28
Amostra C	14	26	50

Fonte: Dos autores (2025).

A partir disso, calculamos a soma dos postos, onde resultou em Amostra A = 144, Amostra B = 180 e Amostra C = 216. Com esses dados fazemos o Teste de Friedman, cuja a fórmula é a seguinte:  $Q=12/(nk(k+1)) \sum_{j=1}^k R_j^2 - 3n(k+1)$ , que resulta em 28,80. Após realizamos a comparação par-a-par, onde  $|A-B| = 36$ ;  $|A-C| = 72$ ;  $|B-C| = 36$  e o teste Newell e MacFarlane, a partir disso temos que todas as amostras têm diferenças significativas entre si ao nível de significância de 5%.

Para avaliação de preferência entre as três amostras, calculou-se a soma dos postos por amostra ( $A = 144$ ;  $B = 180$ ;  $C = 216$ ). Aplicou-se o teste não paramétrico de Friedman ( $Q=12/(nk(k+1)) \sum_{j=1}^k R_j^2 - 3n(k+1)$ ) para verificar diferença global entre amostras, adotando nível de significância  $\alpha = 0,05$ ; o valor obtido foi  $Q \approx 28,80$ , indicando diferença global significativa ( $p < 0,001$ ).

Realizaram-se comparações múltiplas par-a-par conforme recomendado pela ABNT NBR ISO 8587:2015 adotou-se o procedimento de Newell e MacFarlane (tabela de diferenças críticas). Com  $\alpha = 0,05$ , a diferença crítica aproximada (transformada em soma de postos) foi  $\approx 26,3$ ; o valor tabelado de Newell e MacFarlane adotado foi 32. As diferenças observadas entre somas de postos foram  $|A-B| = 36$ ;  $|A-C| = 72$ ;  $|B-C| = 36$  todas superiores aos critérios adotados, portanto, conclui-se que todos os pares diferem significativamente ao nível de 5%. Em suma, temos que a amostra preferida foi a A em relação às demais.

### 3.4.4 Teste de preferência - Análise pelo artefato desenvolvido

Ao colocar os dados da tabela no artefato criado devemos inicialmente preencher a quantidade de amostras, a identificação de cada amostra (opcional) e a quantidade de votos que cada amostra recebeu em cada posição. A partir disso é feita instantaneamente a seguinte análise (Figura 5).

Figura 5 - Dados de entrada do artefato e resultados obtidos

(a) Dados de entrada

Número de Amostras					
3					
Amostra	1º lugar	2º lugar	3º lugar	Total de Votos	Soma de Ordens
Amostra	48	30	12	90	144
Amostra	28	34	28	90	180
Amostra	14	26	50	90	216

Ranking de Preferência	
1º - Amostra A	Soma: 144
2º - Amostra B	Soma: 180
3º - Amostra C	Soma: 216

(b) Fórmula de Newell-MacFarlane e comparações par a par

Informações Gerais		
Total de julgadores:	90	
Número de amostras:	3	
Diferença mínima significativa ( $\alpha=0.05$ ):	27	
Calculado pela fórmula de Newell-MacFarlane		
Comparações Par a Par		
Amostra A vs Amostra B	$\Delta = 36$	★ Significativo
Amostra A vs Amostra C	$\Delta = 72$	★ Significativo
Amostra B vs Amostra C	$\Delta = 36$	★ Significativo

(c) Conclusão obtida pelo artefato

**!** **Conclusão da Análise**

Com base no teste de Friedman ( $\alpha = 0,05$ ) e diferença mínima significativa de **27**:

**HÁ DIFERENÇA SIGNIFICATIVA nas seguintes comparações:**

- **Amostra A vs Amostra B** (diferença = 36)
- **Amostra A vs Amostra C** (diferença = 72)
- **Amostra B vs Amostra C** (diferença = 36)

Fonte: Dos autores (2025).

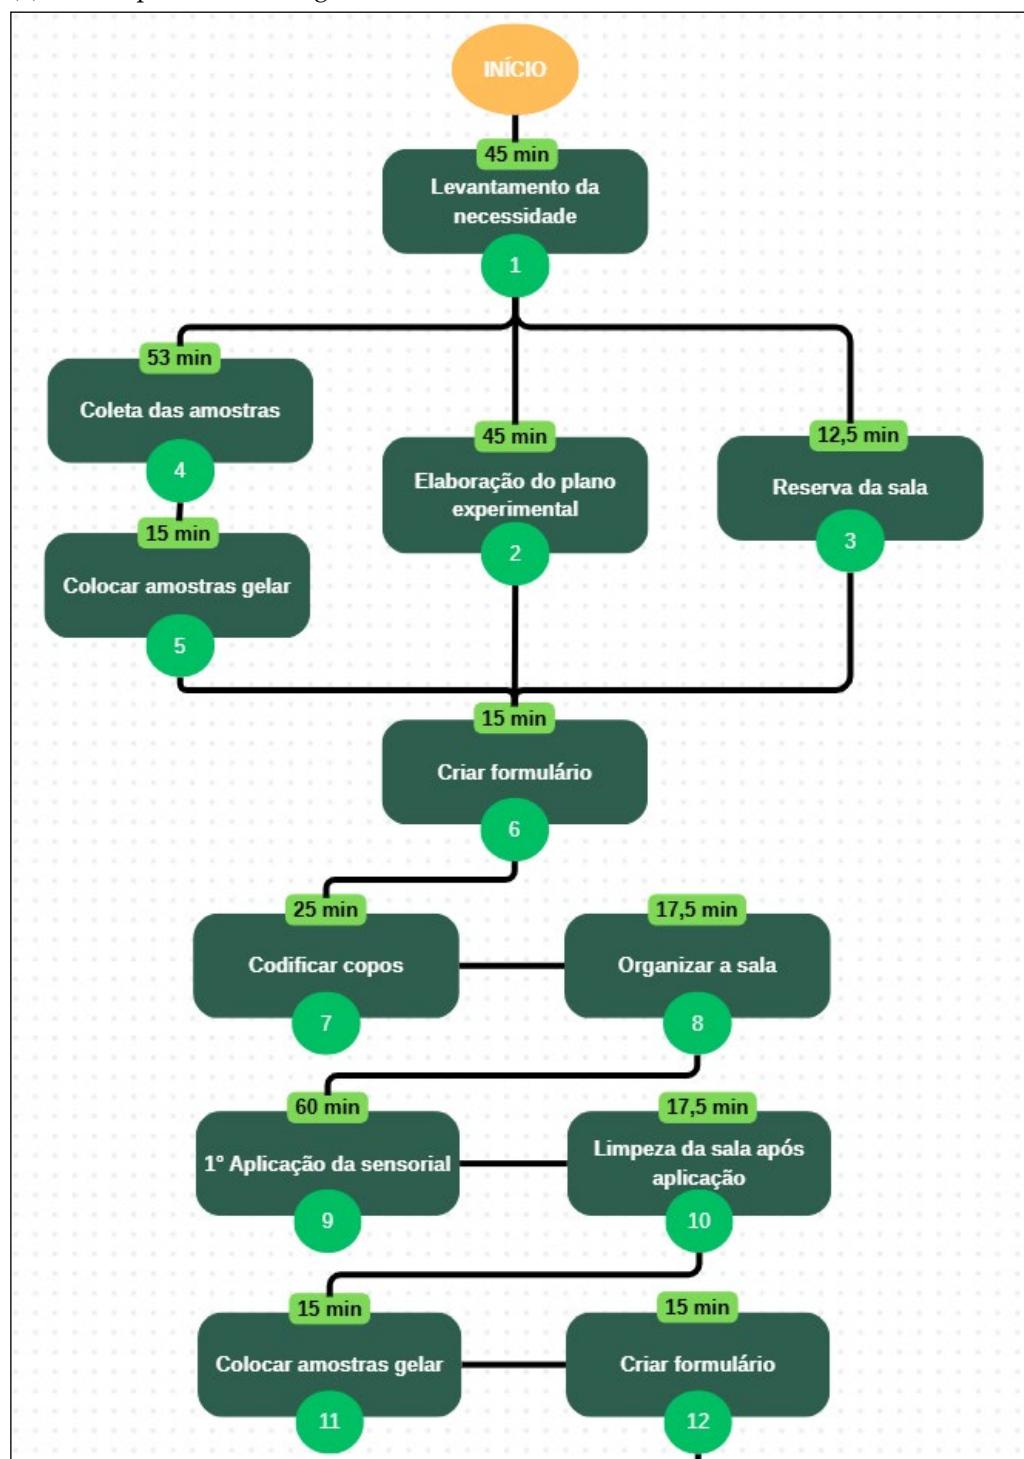
## 4 RESULTADOS E DISCUSSÃO

A implementação das melhorias propostas resultou em avanços mensuráveis no processo de análise sensorial da indústria estudada. A digitalização inicial, por meio da substituição dos formulários impressos pelos questionários eletrônicos no Microsoft Forms, eliminou a etapa manual de compilação dos dados, que anteriormente consumia cerca de uma hora por teste (Figura 6). A geração automática de planilhas estruturadas reduziu erros de transcrição, aumentou a rastreabilidade das informações e facilitou o acesso aos dados para aplicação imediata dos cálculos estatísticos.

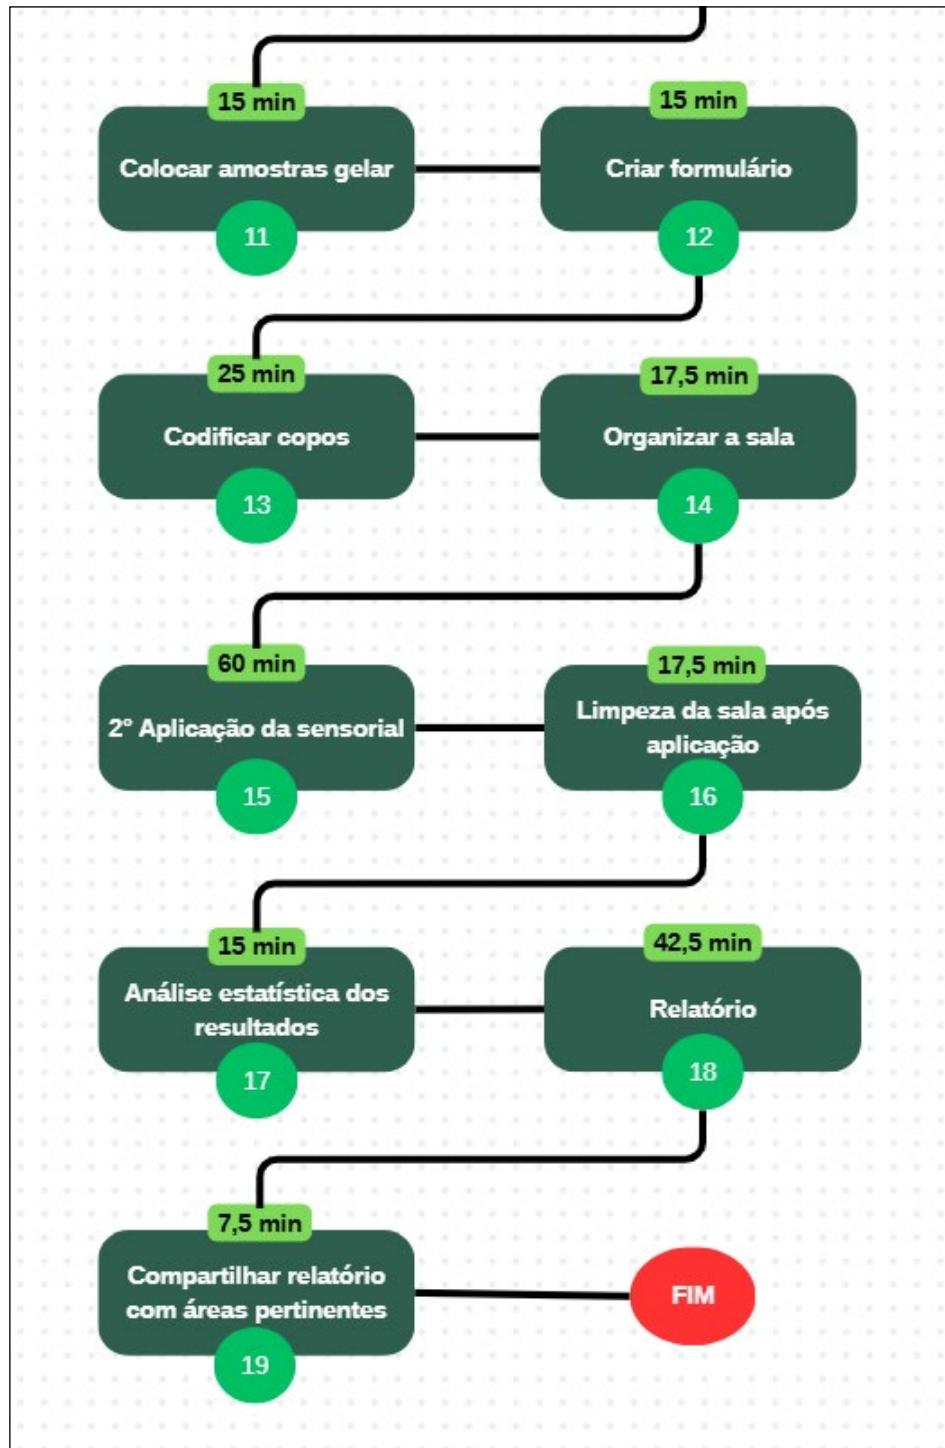
A segunda melhoria, baseada no uso da IA generativa Claude, ampliou ainda mais a eficiência do processo. A criação dos artefatos computacionais específicos para os testes permitiu que os cálculos fossem executados em segundos, com geração automática de gráficos e interpretação estatística conforme as normas da ABNT aplicáveis. Quando comparados com as análises realizadas pelo método convencional, os artefatos demonstraram plena compatibilidade com os resultados obtidos manualmente.

Figura 6 - Fluxograma do processo com as melhorias propostas

(a)Parte superior do fluxograma



(b) Continuação do fluxograma



Fonte: Dos autores (2025).

No conjunto, as melhorias promoveram redução expressiva do tempo total de análise, que anteriormente exigia aproximadamente duas horas para cada teste sensorial, e passaram a gerar resultados confiáveis em poucos minutos. O processo completo, que anteriormente consumia cerca de duas horas, uma hora para compilação manual e outra para análise estatística, passou a ser concluído em poucos minutos com o uso dos artefatos gerados pela IA generativa (Quadro 3).

Quadro 3 - Comparativo dos tempos antes x depois

	Antes das melhorias	Depois das melhorias
Compilação dos dados	1 hora	Não é necessário
Análise de dados	1 hora	15 minutos
Tempo total do processo	Aprox. 9,5 horas	Aprox. 7,7 horas

Fonte: Dos autores (2025).

Os achados reforçam que a integração entre métodos tradicionais de análise sensorial e ferramentas de IA generativa representa um avanço concreto para o ambiente industrial, contribuindo para decisões mais rápidas, embasadas e alinhadas às exigências de competitividade do setor.

## 5 CONSIDERAÇÕES FINAIS

As melhorias implementadas ao longo deste estudo demonstram que a integração entre tecnologias digitais e inteligência artificial generativa representa um avanço estrutural para a análise sensorial no setor de alimentos e bebidas. A transição de formulários impressos para sistemas digitais não apenas reduziu etapas manuais, mas reconfigurou a dinâmica de coleta de dados, tornando-a mais ágil, rastreável e menos suscetível a erros humanos. Essa transformação inicial, embora simples do ponto de vista operacional, foi decisiva para sustentar intervenções posteriores baseadas em automação estatística.

A adoção da IA generativa Claude consolidou o segundo eixo de modernização, elevando o processo de análise sensorial a um novo patamar de eficiência. O desenvolvimento de artefatos capazes de executar cálculos estatísticos alinhados às normas ABNT, gerar análises completas e apresentar gráficos interpretáveis em questão de segundos representa uma inovação diretamente aplicável ao ambiente industrial.

Diferentemente de ferramentas convencionais, esses artefatos foram construídos para traduzir diretrizes normativas em operações automatizadas, preservando a integridade metodológica dos testes triangular e de ordenação de preferência. A compatibilidade entre resultados manuais e automatizados

confirmou que a IA generativa pode atuar como extensão do conhecimento técnico, e não como substituta dos fundamentos estatísticos.

O processo de validação reforçou essa constatação. Ao comparar cálculos realizados manualmente com uso de distribuição binomial, aproximação normal, correção de continuidade, teste de Friedman e método de Newell e MacFarlane com aqueles produzidos pelos artefatos desenvolvidos, observou-se equivalência nos resultados e coerência nas conclusões estatísticas.

A identificação e correção de uma interpolação discrepante no teste triangular evidenciam outro ponto relevante: sistemas baseados em IA, embora eficientes, dependem de supervisão técnica contínua. Esse aspecto reforça que a automação deve ser implementada de maneira crítica e controlada, evitando dependência acrítica da tecnologia.

Os impactos industriais observados foram expressivos. O tempo total de processamento, que anteriormente poderia ultrapassar duas horas por teste sensorial, foi reduzido para minutos, permitindo que equipes técnicas direcionam esforços para atividades de maior valor analítico e estratégico. A eliminação de etapas mecânicas, como compilação manual, reduz falhas operacionais e amplia a confiabilidade das informações utilizadas na tomada de decisão. Além disso, a padronização introduzida pelos artefatos diminui variabilidades entre análises, fortalecendo a reproduzibilidade e a consistência dos resultados ao longo do tempo, aspectos críticos em rotinas de controle de qualidade.

Em uma perspectiva ampliada, o estudo evidencia que a IA generativa tem potencial para se consolidar como ferramenta estratégica para a gestão da qualidade e para o desenvolvimento de produtos. Sua aplicação não se limita à análise sensorial; estende-se a qualquer processo que envolva cálculos repetitivos, interpretação estruturada de dados e geração de relatórios técnicos.

A convergência entre digitalização, estatística aplicada e IA generativa inaugura um cenário em que a eficiência operacional é acompanhada por maior robustez metodológica e por capacidade ampliada de inovação. Essa integração não elimina a necessidade de conhecimento humano, mas amplia a capacidade das equipes técnicas, reduzindo gargalos e qualificando a análise de dados.

Em síntese, os resultados deste trabalho evidenciam que a transformação digital da análise sensorial, potencializada pela IA generativa, representa um avanço sólido e replicável dentro da indústria de alimentos e bebidas. O estudo demonstra que a modernização de processos não é apenas viável, mas necessária para atender às exigências de competitividade, rastreabilidade e precisão analítica exigidas pelo setor. A IA generativa emerge, portanto, não como tendência efêmera, mas como tecnologia estruturante para processos industriais baseados em dados, consolidando-se como aliada estratégica na evolução da qualidade e na tomada de decisão baseada em evidências.

## **REFERÊNCIAS**

- ABNT. Associação Brasileira de Normas Técnicas. NBR ISO 4120:2020 – **Análise sensorial – Metodologia – Teste triangular**. Rio de Janeiro: ABNT, 2020.
- ABNT. Associação Brasileira de Normas Técnicas. NBR ISO 8587:2015 – **Sensory analysis – Methodology – Ranking**. Rio de Janeiro: ABNT, 2015.
- ABNT. Associação Brasileira de Normas Técnicas. NBR ISO 13299:2017 – **Técnicas de análise sensorial – Diretrizes para análises descritivas**. Rio de Janeiro: ABNT, 2017.
- DUTCOSKY, S. D. **Análise Sensorial de Alimentos**. 6. ed. São Paulo: Editora Varela, 2017.
- DUTCOSKY, S. D. **Análise Sensorial de Alimentos..** 4. ed. Curitiba: Champagnat, 2019.
- DUTCOSKY, S. D. **Análise sensorial de alimentos**. 5. ed. Curitiba: Champagnat, 2022.
- GOODFELLOW, Ian *et al.* Generative Adversarial Nets. In: **Proceedings of the 27th International Conference on Neural Information Processing Systems (NIPS 2014)**. Cambridge, MA: MIT Press, 2014. p. 2672–2680.
- ISLAM, Maidul; GURJAR, Kuldeep; SHEIKH, Shabnam A. **How Generative AI Is Reshaping the Beverage Industry? A Study of Innovation, Product Development, and Marketing Strategies**. Preprint – Preprints.org, 25 jun. 2025. Disponível em: <https://www.preprints.org/manuscript/202506.2093>. Acesso em: 19 out. 2025.
- LAWLESS, H. T.; HEYMANN, H. **Sensory Evaluation of Food: Principles and Practices**. 2nd ed. New York: Springer. 2010.
- OLIVEIRA, Cláudia Aparecida de; ANDRADE, Patrícia Lopes; REZENDE, Thaís Karine de Lima. **Controle de qualidade em análise sensorial: uma revisão**. REASE – Revista Ibero-Americana de Humanidades, Ciências e Educação, São Paulo, v. 8, n. 11, p. 3043-3047, nov. 2022. Disponível em: <https://periodicorease.pro.br/rease/article/view/7927>. Acesso em: 18 out. 2025.
- RESENDE, Francine Rubim de; LIMA, Thaís Karine de; ANDRADE, Patrícia Lopes; OLIVEIRA, Cláudia Aparecida de. **Inteligência artificial: inovações e aplicações em análise sensorial**. Revista Observatorio de la Economía Latinoamericana, Curitiba, v. 22, n. 9, p. 1-21, 2024. Disponível em: <https://ojs.observatoriolatinoamericano.com/ojs/index.php/ole/article/view/6541>. Acesso em: 17 out. 2025.
- STRYKER, Cole; SCAPICCHIO, Mark. **O que é a IA generativa?** IBM Think, 2023. Disponível em: <https://www.ibm.com/br-pt/think/topics/generative-ai>. Acesso em: 20 out. 2025.

WANG, X. et al. Large Language Models (LLMs): A systematic study in Administration and Business. **Revista de Administração Mackenzie**, v. 23, n. 6, 2022. Disponível em: <https://www.scielo.br/j/ram/a/GCJHtgxWBNVv7kB73pKbm5m/>. Acesso em: 29 nov. 2025.