UNIVERSIDADE FEDERAL DA PARAÍBA – UFPB
CENTRO DE CIÊNCIAS SOCIAIS APLICADAS – CCSA
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO – PPGA
CURSO DE MESTRADO EM ADMINISTRAÇÃO

ALEXANDRE DA SILVA UZEDA

PROPOSTA E VALIDAÇÃO DE UMA ESCALA DE *DATA LITERACY* PARA GESTORES ACADÊMICOS

João Pessoa – PB
2026

ALEXANDRE DA SILVA UZEDA

PROPOSTA E VALIDAÇÃO DE UMA ESCALA DE *DATA LITERACY* PARA GESTORES ACADÊMICOS

Projeto de dissertação apresentado como requisito parcial para a obtenção do grau de Mestre pelo Programa de Pós-graduação em Administração da Universidade Federal da Paraíba.
Linha de pesquisa: Estratégia, Finanças e Desempenho
Orientador: Prof. Dr. Francisco José da Costa
Coorientador: Prof. Dr. Jailson Santana Carneiro

João Pessoa – PB

2026

ALEXANDRE DA SILVA UZEDA

ERAL DA PARAÍBA - UFPB
AS SOCIAIS APLICADAS - CCSA
RADUAÇÃO EM ADMINISTRAÇÃO - PPGA

ATA DE DEFESA DE DISSERTAÇÃO

Defesa nº 713

Ata da Sessão Pública de Defesa de Dissertação do mestrando **Alexandre da Silva Uzeda** como requisito para obtenção do grau de Mestre em Administração, Área de Concentração em Administração e Sociedade e com Linha de Pesquisa em Finanças e Métodos Quantitativos.

No dia 26 de fevereiro de 2026, às 08 horas, em sala virtual, através do *link* (https://meet.google.com/kje-odud-pnc), reuniu-se a Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Administração, composta pelos membros Prof. Dr. Francisco José da Costa (Orientador – PPGA/UFPB), Prof. Dr. Jailson Santana Carneiro (Coorientador – UFRPE), Prof. Dr. Jairo de Pontes Gomes (Examinador Externo – UFPB) e Prof. Dr. Francisco de Assis Carlos Filho (Examinador Externo – UPE), com a finalidade de julgar a dissertação do aluno **Alexandre da Silva Uzeda** intitulada: **"PROPOSTA E VALIDAÇÃO DE UMA ESCALA DE DATA LITERACY PARA GESTORES ACADÊMICOS"**, para obtenção do grau de Mestre em Administração. O desenvolvimento dos trabalhos seguiu o roteiro de sessão de defesa estabelecido pela coordenação do curso, com abertura, condução e encerramento da sessão solene de defesa realizados pelo presidente Prof. Dr. Francisco José da Costa. Após haver analisado o referido trabalho e arguido o candidato, os membros da Banca Examinadora deliberaram por unanimidade e atribuíram o conceito (X) aprovado, ( ) insuficiente, ( ) reprovado.

Observações da Banca:
O mestrando deve proceder aos ajustes recomendados pela banca e ele repassados.

Proclamados os resultados, o Presidente da Banca Examinadora encerrou os trabalhos, e para constar, confere e assina a presente ata, juntamente com os membros da Banca Examinadora e o aluno.

Documento assinado digitalmente
gov.br FRANCISCO JOSE DA COSTA
Data: 26/02/2026 09:27:28-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Francisco José da Costa
Orientador – PPGA/UFPB

Documento assinado digitalmente
gov.br JAILSON SANTANA CARNEIRO
Data: 26/02/2026 09:34:01-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Jailson Santana Carneiro
Coorientador – UFRPE

Documento assinado digitalmente
gov.br JAIRO DE PONTES GOMES
Data: 26/02/2026 09:29:47-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Jairo de Pontes Gomes
Examinador Externo – UFPB

[redacted]

Prof. Dr. Francisco de Assis Carlos Filho
Examinador Externo – UFPE

Alexandre da Silva Uzeda
Mestrando

U99p Uzeda, Alexandre da Silva.
Proposta e validação de uma escala de data literacy para gestores acadêmicos / Alexandre da Silva Uzeda. - João Pessoa, 2026.
73 f. : il.

Orientação: Francisco José da Costa.
Coorientação: Jailson Santana Carneiro.
Dissertação (Mestrado) - UFPB/CCSA.

1. Literacia de dados (Data literacy). 2. Alfabetização em dados. 3. Gestores acadêmicos. 4. Administração universitária. 5. Competência em dados. I. Costa, Francisco José da. II. Carneiro, Jailson Santana. III. Título.

UFPB/BC CDU 004.65(043)

Dedico este trabalho ao meu filho, Ricky Uzeda, meu melhor presente, meu maior orgulho e meu amor eterno.

AGRADECIMENTOS

A jornada do mestrado é, por natureza, um caminho de constante aprendizado, repleto de desafios, incertezas e descobertas. No entanto, é também uma construção coletiva, e este trabalho jamais teria alcançado a sua forma final sem o apoio fundamental de pessoas e instituições que caminharam ao meu lado.

Aos meus familiares e amigos, que compreenderam minhas ausências, suportaram meus momentos de cansaço e vibraram com cada pequena vitória ao longo destes anos. O amor e o suporte de vocês foram o meu porto seguro.

Ao meu orientador, Prof. Dr. Francisco José da Costa, expresso minha mais profunda e sincera gratidão. Mais do que guiar os rumos desta pesquisa, sua expertise e seu rigor metodológico foram a verdadeira bússola deste trabalho. Ter a oportunidade de construir e validar uma escala sob a orientação do próprio autor do protocolo metodológico adotado foi um privilégio inestimável. Agradeço por sua paciência, por compartilhar seu vasto conhecimento e por me desafiar a manter a excelência científica em cada etapa.

Ao meu coorientador, Prof. Dr. Jailson Santana Carneiro, meu muito obrigado pela parceria indispensável. Suas contribuições pontuais, seu olhar analítico e seu incentivo constante foram pilares fundamentais para o amadurecimento das ideias e para a robustez das análises que estruturam esta dissertação. O trabalho em equipe com vocês formou uma base inabalável para o meu desenvolvimento.

À Universidade Federal da Paraíba (UFPB) e, em especial, ao Programa de Pós-Graduação em Administração (PPGA), por fornecerem o ambiente acadêmico e a infraestrutura necessários para a realização deste estudo.

Ao Instituto Federal da Bahia (IFBA) e aos seus alunos, que gentilmente colaboraram com a etapa do estudo piloto, bem como a todos os gestores acadêmicos que dedicaram seu tempo precioso para responder ao instrumento final. Sem a participação de vocês, esses dados não teriam ganhado vida.

À DGTI na figura de Márcio Melo e Dante Aurélio, sem o meu afastamento não sei se teria condições favoráveis para conclusão deste trabalho. Além disso, gostaria de agradecer especialmente ao meu amigo Rogério Carvalho pelas horas de estudo e dicas de material para estudo.

A todos que, direta ou indiretamente, contribuíram para que esta proposta deixasse de ser apenas uma ideia e se transformasse em uma contribuição real para a gestão acadêmica: o meu muito obrigado.

RESUMO

A proposta desta dissertação teve como objetivo propor e validar uma escala específica para avaliar a alfabetização em dados no contexto da gestão acadêmica. A fundamentação teórica abordou os marcos regulatórios da educação superior brasileira, os desafios da gestão acadêmica contemporânea e os principais modelos internacionais de *data literacy*. A metodologia seguiu um protocolo de desenvolvimento de escalas, abrangendo desde a definição do construto até a aplicação piloto com 167 respondentes de graduação no âmbito do Instituto Federal da Bahia (IFBA), além de uma segunda amostragem com gestores acadêmicos do instituto. A escala resultante foi organizada em três dimensões: competência estatística, computacional e de uso cotidiano, totalizando 21 itens. A pesquisa visa a contribuir com a área de literacia de dados, na medida que os resultados indicam que a escala é válida e confiável para diagnosticar lacunas formativas e subsidiar ações de capacitação, contribuindo para uma gestão acadêmica mais eficiente, crítica e orientada por dados.

Palavras-chave: data literacy; alfabetização em dados; gestão acadêmica.

ABSTRACT

The aim of this dissertation was to propose and validate a specific scale to assess data literacy in the context of academic management. The theoretical foundation addressed the regulatory frameworks of Brazilian higher education, the challenges of contemporary academic management, and the main international models of data literacy. The methodology followed a scale development protocol, ranging from construct definition to pilot application with 167 undergraduate respondents at the Federal Institute of Bahia (IFBA). The resulting scale was organized into three dimensions: statistical, computational, and everyday competency, totaling 21 items. The research aims to contribute to the field of data literacy, as the results indicate that the scale is valid and reliable for diagnosing educational gaps and supporting training initiatives, contributing to more efficient, critical, and data-driven academic management.

Keywords: data literacy; academic management.

LISTA DE FIGURAS

Figura 1 - Aplicabilidade da escala 10
Figura 2 - Estratégias de apresentação da *data literacy* 14
Figura 3 - Passos do desenvolvimento da escala 37

LISTA DE QUADROS

Quadro 1 - Definição e atribuições de coordenadores de curso e chefes de departamento 17
Quadro 2 - Principais tarefas de lideranças e o uso necessário de dados 20
Quadro 3 - Definições de *data literacy* em trabalhos relevantes 23
Quadro 4 - Itens da escala de Chung e Yoo (2022) 31
Quadro 5 - Itens da escala de Öz e Özdemir (2022) 32
Quadro 6 - Itens da escala de Duygulu, Doğan e Yıldız (2025) 33
Quadro 7 - Itens da escala de Kim, Hong e Evans (2024) 34
Quadro 8 - Comparativo dos estudos de escala de *Data Literacy* 35
Quadro 9 - Definição de *Data Literacy* utilizada nessa pesquisa 39
Quadro 10 - Definição das competências 39
Quadro 11 - Quadro de itens da escala de *Data Literacy* 40
Quadro 12 - Itens das competências 58

LISTA DE TABELAS

Tabela 1 - Características gerais da amostra 43
Tabela 2 - Matriz de correlação das variáveis da dimensão competência estatística 44
Tabela 3 - Escores fatoriais dos itens da dimensão Competência Estatística 45
Tabela 4 - Correlação entre os itens da dimensão Competência Computacional 47
Tabela 5 - Escores fatoriais dos itens da dimensão Competência computacional 48
Tabela 6 - Correlação entre os itens da dimensão Competência Uso cotidiano 49
Tabela 7 - Escores fatoriais dos itens da dimensão Competência Uso cotidiano 50
Tabela 8 - Escores fatoriais da segunda amostra 52

Tabela 9 - Medidas de ajuste 55
Tabela 10 - Matriz de variâncias (alpha de Cronbach) 57
Tabela 11 - Uma opção de interpretação dos resultados 59

SUMÁRIO

1 INTRODUÇÃO 8

1.1 APRESENTAÇÃO DOS RECORTES TEMÁTICOS E JUSTIFICATIVAS 10

1.2 QUESTÃO DE PESQUISA E OBJETIVOS 13

1.3 ESTRUTURA DO TRABALHO 13

2 REFERENCIAL TEÓRICO 14

2.1 GESTÃO ACADÊMICA 15

2.1.1 Fundamentos legais e institucionais da gestão acadêmica 15

2.1.2 Evolução histórica da função do gestor acadêmico 17

2.1.3 Complexidade e multinível de atribuições 19

2.2 *DATA LITERACY* 22

2.2.1 Conceito e importância da *data literacy* 22

2.2.2 Dimensões da *data literacy* 24

2.2.3 Competência estatística 25

2.2.4 Competência computacional 26

2.2.5 Competência de uso cotidiano 27

2.2.6 Aplicações na gestão acadêmica 28

2.2.7 Planejamento pedagógico e curricular 28

2.2.8 Gestão da evasão e permanência estudantil 28

2.2.9 Avaliação institucional e regulatória 29

2.2.10 Tomada de decisão orçamentária e de recursos humanos 29

2.2.11 Comunicação institucional e prestação de contas 30

2.3 MENSURAÇÃO DE *DATA LITERACY* 30

2.4 RESUMO DO CAPÍTULO 36

3 MÉTODO 36

3.1 PROTOCOLO DE DESENVOLVIMENTO DE ESCALA 37

4 CONSTRUÇÃO DA ESCALA 38

4.1 PASSO 1 – ESPECIFICAÇÃO DO DOMÍNIO DO CONSTRUTO 39

4.2 PASSO 2 – GERAÇÃO DE ITENS E VALIDAÇÃO DE FACE 40

4.3 PASSOS 3 E 4 – DECISÕES SOBRE AS RESPOSTAS E CONSTRUÇÃO DO INSTRUMENTO 41
4.4 PASSO 5 – PRIMEIRA AMOSTRAGEM 41
4.5 PASSO 6 – PRIMEIROS PROCEDIMENTOS DE LIMPEZA DA ESCALA 42
4.5.1 Análise exploratória preliminar 42
4.5.2 Descrição geral da amostra 43
4.5.3 Análise das variáveis das dimensões 44
4.5.3.1 Dimensão Competência Estatística 44
4.5.3.2 Dimensão Competência Computacional 46
4.5.3.3 Dimensão Competência Uso Cotidiano 48
4.6 PASSO 7 – ATIVIDADE DE CAMPO ADICIONAIS 50
4.7 PASSO 8 – PROCEDIMENTO ADICIONAIS DE LIMPEZA 52
4.7.1 Análise Fatorial Exploratória 52
4.7.3 Construto 1 – Competência estatística 53
4.7.4 Construto 2 – Competência Computacional 54
4.7.5 Construto 3 – Competência de Uso 54
4.7.6 Procedimento com a TRI e resultados consolidados 55
4.8 PASSO 9 – ANÁLISES DE VALIDADE E CONFIABILIDADE 56
4.9 PASSO 10 – DESENVOLVIMENTO DE RECOMENDAÇÕES 58
5 CONSIDERAÇÕES FINAIS 59
5.1 RESULTADOS DOS OBJETIVOS DEFINIDOS 60
5.2 LIMITAÇÕES DO ESTUDO E SUGESTÕES DE ESTUDOS FUTUROS 62
APÊNDICE I 67

1 INTRODUÇÃO

Ao menos desde os anos 2000, com a digitalização crescente das atividades de controle acadêmico, as instituições de ensino superior e técnico têm experimentado um crescente aumento na quantidade de dados gerados em seus ambientes, especialmente em relação ao desempenho acadêmico de alunos, aos indicadores de gestão administrativa e aos resultados de pesquisa.

Nesse cenário de aumento de dados, o conceito de *academic analytics* surge como uma abordagem estratégica que utiliza dados e ferramentas analíticas para avaliar e aprimorar processos educacionais em instituições de ensino superior, incluindo o monitoramento do desempenho dos alunos, a avaliação de currículos e a identificação de fatores que influenciam a evasão escolar. No entanto, para que a aplicação do *academic analytics* seja eficaz, é fundamental que gestores e tomadores de decisão possuam um nível adequado de **literacia de dados**[1], ou seja, a capacidade de entender, interpretar e usar dados de maneira informada e crítica.

Um dos principais desafios enfrentados por gestores acadêmicos, muitas vezes sem formação específica em gestão, é a sobrecarga de trabalho e o acúmulo de funções. Com efeito, temos uma grande diversidade de métricas e alto volume de dados. Até temos pessoal com conhecimento, mas, na universidade, muitas vezes, esse conhecimento não é incorporado ao processo de tomada de decisões.

Isso pode levar a dificuldades na tomada de decisões informadas e na implementação de práticas baseadas em evidências. Além disso, a falta de conhecimentos específicos na área de gestão pode limitar a eficácia desses profissionais em suas funções administrativas.

A capacidade de compreender, interpretar e utilizar dados para a tomada de decisões fundamentadas é conhecida como *data literacy*, que envolve um conjunto de competências essenciais no atual ambiente organizacional. No entanto, a pesquisa de Ghodoosi *et al.* (2024) indica que os dados estão se tornando uma linguagem universal em todos os setores e que ainda há uma lacuna entre as competências em *data literacy* exigidas pelo mundo organizacional e aquelas efetivamente dominadas pelos profissionais (Ghodoosi *et al.*, 2024).

O contexto acadêmico não está imune a essa realidade. Gestores acadêmicos, responsáveis por coordenar processos institucionais e pedagógicos, dependem cada vez mais

[1] Utilizaremos os termos ‘literacia de dados’, ‘letramento de dados’, ‘*data literacy’* e ‘alfabetização de dados’ como sinônimos.

da análise de dados para otimizar recursos, avaliar desempenhos e formular estratégias eficazes. Embora existam escalas para medir habilidades relacionadas ao letramento digital e estatístico, constatamos a ausência de uma escala específica para medir e desenvolver a *data literacy* de gestores educacionais da base operacional (coordenadores, chefes de departamentos).

O estudo de Ghodoosi *et al.* (2024) destaca a necessidade de um modelo educacional adaptado às demandas específicas de diferentes setores e perfis profissionais. O ensino de competências básicas associadas ao *data literacy* ainda é genérico, desconsiderando a diversidade de habilidades necessárias em diferentes funções organizacionais ou diferentes tipos de organizações. Isso reforça a importância de se desenvolver instrumentos que possam avaliar e guiar a capacitação de gestores acadêmicos dentro de suas realidades institucionais. Além disso, a ausência de processos bem definidos e a falta de integração entre sistemas de informação podem levar a retrabalhos e inconsistências nos dados, comprometendo a qualidade das informações utilizadas na gestão acadêmica.

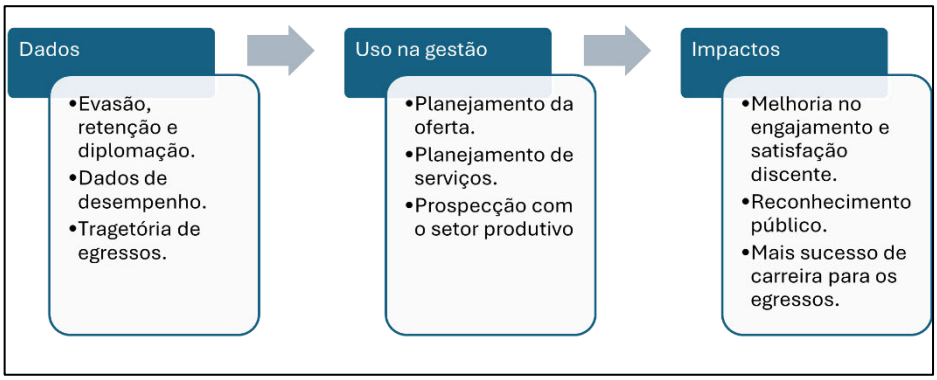
Assim, é essencial desenvolver ferramentas que auxiliem os gestores acadêmicos na interpretação e utilização dos dados de forma eficaz. O problema não parece ser ferramental. Com efeito, nesta década de 2020, algumas ferramentas já vêm se tornando reconhecidas na literatura e no mercado, podendo ser utilizadas para análise e manipulação de dados coletados. Dentre elas, destacam-se: i) ***Microsoft Excel***: para a organização inicial dos dados e análises descritivas; ii) ***R e/ou RStudio***: para a análise estatística, incluindo análise fatorial exploratória e confirmatória; iii) ***Python (Pandas, NumPy, Scikit-learn)***: para a manipulação e visualização de dados; iv) ***SPSS***: para testes de confiabilidade e análise fatorial; e v) ***Power BI e Tableau***: para a criação de *dashboards* interativos e exploração visual dos dados.

Essas ferramentas não apenas são amplamente utilizadas para manipulação e análise de dados, mas também desempenham um papel fundamental na construção e validação de escalas científicas, permitindo análises estatísticas robustas e visualização de padrões nos dados coletados. Os maiores problemas parecem estar, quando escrevemos este trabalho, na capacidade das lideranças de acessarem, absorverem e efetivamente usarem estes dados.

A Figura 1 apresenta os principais elementos que justificam a necessidade do estudo e demonstram a aplicabilidade de uma escala de avaliação em literacia de dados. Apesar da disponibilidade de diversas ferramentas para análise de dados, ainda há uma lacuna na mensuração das competências em *data literacy* dos gestores acadêmicos. Nesse sentido, esta pesquisa propõe validar uma escala de *data literacy* especificamente voltada para gestores

acadêmicos. A pesquisa adota uma abordagem metodológica para desenvolver um instrumento que mensure objetivamente essas competências. Além disso, espera-se que esta escala auxilie na identificação de lacunas na formação e no desenvolvimento profissional desses gestores, permitindo intervenções mais direcionadas para o aprimoramento da gestão acadêmica baseada em dados.

Figura 1 - Aplicabilidade da escala



Fonte: Elaboração própria

1.1 APRESENTAÇÃO DOS RECORTES TEMÁTICOS E JUSTIFICATIVAS

O avanço da sociedade da informação e a crescente dependência dos dados para embasar decisões estratégicas e operacionais têm impulsionado a necessidade de desenvolver competências em ***data literacy*** (alfabetização em dados). Nesse contexto, a **alfabetização em dados** emerge como uma competência essencial para gestores acadêmicos, capacitando-os a interpretar, analisar e utilizar dados de maneira eficaz na tomada de decisões. Dessa forma, compreender o papel dos gestores acadêmicos se torna fundamental para contextualizar a relevância da alfabetização em dados nesse cenário.

Os gestores acadêmicos são profissionais responsáveis pela administração e tomada de decisões em instituições de ensino superior. Eles atuam em diversas frentes, como planejamento estratégico, gestão de recursos financeiros e humanos, supervisão de processos acadêmicos e desenvolvimento institucional (Kanan; Zanelli, 2011). Sua função é garantir a eficiência operacional e o alinhamento das instituições às políticas educacionais e às demandas do mercado de trabalho.

Nesse contexto, a capacidade de interpretar e utilizar dados se torna uma competência essencial para a atuação eficaz desses profissionais. Assim, a alfabetização em dados se refere

à capacidade de um indivíduo em compreender e utilizar dados de forma informada (Ridsdale *et al*., 2015).

No ambiente acadêmico, gestores com alta proficiência em dados podem otimizar processos administrativos, aprimorar a qualidade do ensino e promover a inovação institucional. Estudos indicam que a implementação de práticas de governança de dados em universidades contribui para a melhoria na qualidade das informações e na eficiência dos processos internos (Buss *et al.*, 2021).

Apesar da importância reconhecida da alfabetização em dados, há escassez de ferramentas validadas que a mensurem entre gestores acadêmicos no Brasil. A criação e a validação de uma escala específica preenchem essa lacuna, oferecendo um instrumento para diagnóstico e desenvolvimento profissional. Além disso, a escala serviria como guia para programas de capacitação, assegurando que os gestores adquiram as competências necessárias para conduzir uma gestão orientada por dados.

A construção de instrumentos de medida, como escalas e questionários, exige um processo rigoroso de validação para garantir sua confiabilidade e validade. Na área da saúde, por exemplo, a adaptação e a validação de questionários têm sido amplamente utilizadas para avaliar competências específicas, assegurando que os instrumentos sejam culturalmente adequados e sólidos. A aplicação de metodologias semelhantes no desenvolvimento de uma escala de alfabetização em dados garantiria a precisão e a relevância do instrumento para o contexto dos gestores acadêmicos.

A ausência de instrumentos validados especificamente para medir a alfabetização em dados entre gestores acadêmicos dificulta tanto a identificação de suas necessidades formativas quanto a implementação de políticas educacionais eficazes. Um processo de validação rigoroso garantiria que a escala desenvolvida avaliasse com precisão as competências desses profissionais, fornecendo subsídios essenciais para intervenções direcionadas e melhorias na gestão acadêmica.

Gestores acadêmicos proficientes em alfabetização em dados estão mais aptos a tomar decisões informadas, baseadas em evidências, o que pode resultar em melhorias significativas nos processos institucionais. A aplicação de conceitos de governança de dados, por exemplo, tem demonstrado potencial para aprimorar a qualidade das informações e a eficiência operacional em instituições de ensino superior (Buss *et al.*, 2021)

Investir na alfabetização em dados dos gestores acadêmicos não apenas aprimora a tomada de decisão, mas também fortalece a cultura institucional orientada por evidências.

Com uma escala validada, seria possível mapear o nível de competência em dados dos gestores, identificar áreas de melhoria e desenvolver programas de capacitação específicos, promovendo uma gestão mais eficaz e alinhada às demandas contemporâneas do ambiente educacional.

No entanto, um dos principais desafios enfrentados por esses gestores está relacionado à crescente quantidade de dados educacionais e institucionais que precisam ser analisados para embasar suas decisões. A educação superior tem se tornado cada vez mais dependente de métricas de desempenho, de avaliação institucional e de indicadores de qualidade, exigindo que os gestores possuam habilidades adequadas para interpretar e utilizar essas informações de maneira eficaz (Kanan; Zanelli, 2011).

A crescente digitalização das atividades acadêmicas e a expansão das bases de dados institucionais impõem desafios significativos para a gestão universitária. Em um ambiente em que decisões informadas são essenciais para a eficiência operacional e a qualidade educacional, a capacidade de compreender e utilizar dados se torna um diferencial crítico para gestores acadêmicos.

Diante desse contexto, torna-se essencial desenvolver e validar uma escala de *data literacy* específica para gestores acadêmicos. Essa ferramenta pode contribuir para a identificação de lacunas de conhecimento, auxiliar no desenvolvimento de programas de capacitação e aprimorar a qualidade da gestão acadêmica. A compreensão mais profunda do papel dos dados na educação superior e o fortalecimento das competências analíticas entre os gestores podem resultar em tomadas de decisões mais fundamentadas e eficazes, beneficiando as instituições e a comunidade acadêmica como um todo.

Para medir a alfabetização de dados, é preciso primeiro decompô-la em um conjunto de competências ou fatores observáveis. A literatura apresenta diversas definições, que vão desde a capacidade de entender o que os dados significam, incluindo como ler diagramas corretamente (Chung; Yoo, 2022) até um processo mais complexo que inclui extrair informações, resolver problemas e usar dados para persuadir e tomar decisões racionais. Estudos que se propõem a criar ferramentas de medição utilizam essas definições para construir um quadro conceitual mais robusto.

Dessa forma, esta pesquisa se propõe a preencher essa lacuna, desenvolvendo e validando um instrumento capaz de medir o nível de ***data literacy*** dos gestores acadêmicos. A expectativa é que essa ferramenta contribua para a implementação de uma cultura organizacional mais orientada por dados, promovendo melhores práticas de gestão e maior

eficiência institucional.

1.2 QUESTÃO DE PESQUISA E OBJETIVOS

Diante do crescente papel dos dados nas tomadas de decisão em diversas esferas, surge um problema global que integra uma questão fundamental para o avanço da educação e da gestão acadêmica: como avaliar as competências de *data literacy* de gestores acadêmicos de modo a garantir maior eficiência de gestão? Essa questão envolve o desenvolvimento e a validação de uma escala de mensuração da competência em *data literacy*, a identificação dos principais componentes e dimensões do letramento de dados relevantes para gestores acadêmicos, a criação de um instrumento confiável e válido para avaliar essa competência e, por fim, a utilização dos resultados para aprimorar as práticas de gestão acadêmica baseadas em dados. Para responder a esse desafio, apresentamos os objetivos desta pesquisa.

Nosso **objetivo central** é **desenvolver uma escala para mensuração da competência em alfabetização de dados entre gestores acadêmicos**. Especificamente, buscaremos: i) identificar os principais conceitos e dimensões que compõem a *data literacy* no contexto da gestão acadêmica; ii) validar a escala de medição seguindo o processo completo de validação seguindo o modelo proposto por Costa (2011). Proposta inicial, com base na literatura e na percepção de especialistas na área, aplicação de procedimentos metodológicos apropriados para testar empiricamente a confiabilidade e validade da escala desenvolvida.

1.3 ESTRUTURA DO TRABALHO

Além deste capítulo de introdução, esta dissertação estará organizada em capítulos, cada um contendo uma função específica para conduzir a pesquisa desde a contextualização teórica até a apresentação dos resultados e conclusões. Serão apresentados o contexto da pesquisa, a definição do problema, as questões de pesquisa e os objetivos do estudo.

Em seguida, detalharemos o referencial teórico. Posteriormente, a abordagem metodológica adotada para a construção e a validação da escala de *data literacy* para gestores acadêmicos. São descritos os procedimentos para a elaboração dos itens, a validação, a coleta de dados e as análises estatísticas utilizadas para avaliar a validade e a confiabilidade do instrumento.

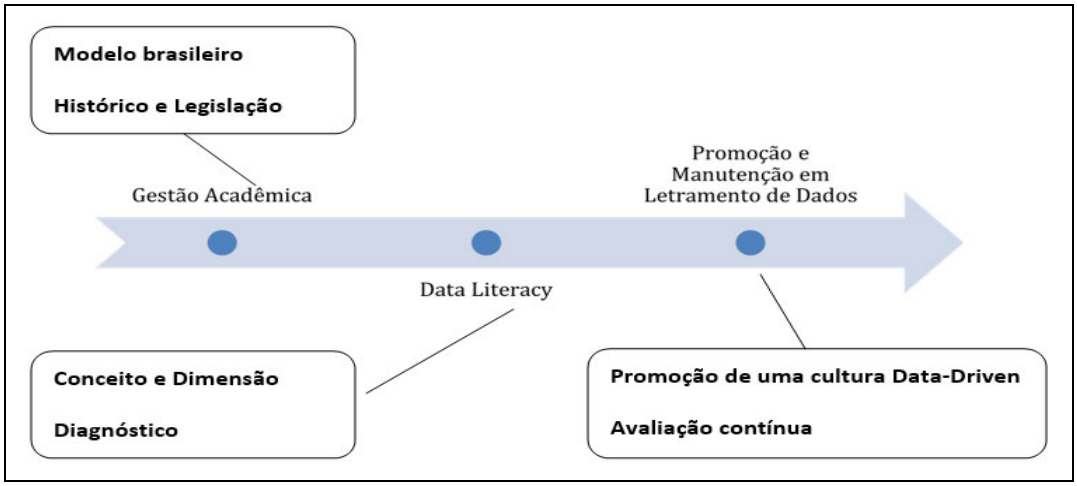
2 REFERENCIAL TEÓRICO

A alfabetização em dados refere-se, basicamente, à capacidade de ler, trabalhar, analisar e comunicar-se com dados. No contexto organizacional, essa competência permite que os profissionais tomem decisões informadas baseadas em evidências extraídas de dados. A crescente digitalização e a disponibilidade massiva de informações tornam a alfabetização em dados uma habilidade essencial na atualidade.

Desse modo, neste capítulo temos como objetivo apresentar os recortes temáticos para servir de base para a pesquisa, de forma a ampliar a discussão sobre os principais conceitos de letramento em dados. Além disso, buscamos abordar como a alfabetização em dados pode impactar as decisões acadêmicas e como desenvolver tal instrumento é crucial para diagnosticar o nível de competência desses profissionais em relação ao uso e à gestão de dados, permitindo a implementação de programas de capacitação mais direcionados e eficazes.

A organização deste capítulo está disposta da seguinte maneira: no tópico 2.1, apresentaremos uma introdução à gestão acadêmica; em seguida, abordaremos o tema de *data literacy*; na sequência, apresentaremos os conceitos, as dimensões, a promoção e a manutenção de letramento de dados. Os elementos dessa estratégia podem ser visualizados na Figura 2.

Figura 2 - Estratégias de apresentação da *data literacy*



Fonte: Elaboração própria

2.1 GESTÃO ACADÊMICA

A gestão acadêmica nas Instituições de Ensino Superior (IES) brasileiras tem passado por profundas transformações nas últimas décadas, impulsionadas por mudanças regulatórias, expansão do sistema federal, processos de avaliação institucional e crescente digitalização da administração universitária. Nesse contexto, o papel do gestor acadêmico — em especial, coordenadores de curso, chefes de departamento e pró-reitores — tornou-se mais complexo, exigindo competências múltiplas que vão além das atribuições pedagógicas tradicionais.

2.1.1 Fundamentos legais e institucionais da gestão acadêmica

A gestão acadêmica no Brasil ancora-se em um conjunto normativo que estabelece as funções, os princípios e as diretrizes que regem a atuação dos gestores nas IES. Esse marco legal não apenas define o escopo administrativo e pedagógico da função, como também enfatiza a necessidade de práticas baseadas em evidências e na avaliação sistemática de resultados.

O ponto de partida para compreender a gestão acadêmica é a Lei nº 9.394/1996, conhecida como Lei de Diretrizes e Bases da Educação Nacional (LDB), cujo artigo 53 dispõe sobre a autonomia universitária (Brasil, 1996). As universidades têm a prerrogativa de elaborar seus planos de ensino, projetos pedagógicos, regulamentações internas e procedimentos administrativos, respeitando as diretrizes gerais emanadas pelo Estado (Brasil, 1996). Essa autonomia, porém, é condicionada à responsabilidade de garantir qualidade e efetividade nas ações educacionais, o que pressupõe a utilização de mecanismos sistemáticos de coleta e análise de dados institucionais (Brasil, 1996).

A gestão, prevista no artigo 14 da mesma LDB, complementa esse cenário ao determinar que a administração educacional deva ser realizada com base em princípios de participação e transparência (Brasil, 1996). Nesse contexto, a adoção de práticas de gestão orientadas por dados, na atualidade, é fundamental para assegurar a prestação de contas à comunidade acadêmica e à sociedade em geral.

Outro dispositivo essencial é a Lei nº 10.861/2004, que instituiu o Sistema Nacional de Avaliação da Educação Superior (SINAES) (Brasil, 2004). O SINAES estabelece a avaliação de cursos de graduação, de instituições de ensino e de desempenho dos estudantes, exigindo o monitoramento sistemático de indicadores quantitativos e qualitativos (Brasil, 2004).

A avaliação institucional, por exemplo, envolve dimensões como gestão acadêmica, planejamento e desenvolvimento institucional, políticas de ensino, pesquisa e extensão — todas baseadas em evidências documentadas e mensuráveis (Brasil, 2004).

Complementarmente, o Decreto nº 9.235/2017 regulamenta os processos de regulação, supervisão e avaliação das IES, reforçando a exigência de práticas administrativas embasadas em dados (Brasil, 2017). A normativa detalha as condições para autorização, reconhecimento e renovação de cursos e para o recredenciamento de instituições, baseando-se em informações registradas em sistemas oficiais, como o e-MEC e o Censo da Educação Superior (Brasil, 2017).

O conjunto desses instrumentos legais gera implicações diretas para a gestão acadêmica, dentre as quais se destacam: a necessidade de elaboração de relatórios periódicos de desempenho acadêmico e financeiro; a exigência de monitoramento de indicadores como taxa de evasão, taxa de diplomação, desempenho no Exame Nacional de Desempenho de Estudantes (ENADE) e inserção de egressos no mercado de trabalho; a obrigatoriedade de participação em processos de avaliação externa e autoavaliação institucional, organizados pelas Comissões Próprias de Avaliação (CPA).

Além desses marcos federais, cabe ressaltar que muitas universidades, como a UFPB, adotam suas próprias normativas internas — como regimentos gerais, resoluções de conselhos superiores e planos de desenvolvimento institucional (PDI)[2] — que detalham ainda mais os parâmetros de atuação dos gestores acadêmicos, sempre com base em evidências sistematizadas. Como exemplo de norma a ser implementada, a UFPB cita em seu PDI 2024-2028 a necessidade de elaboração de documentos e normativos internos que tratarão de temas como: governança em segurança da informação e governança de proteção de dados pessoais.

Portanto, o arcabouço normativo que rege a gestão acadêmica no Brasil não apenas legitima a autonomia das instituições, como também impõe a seus gestores a responsabilidade de atuar com rigor técnico, capacidade analítica e compromisso com a transparência. Em última instância, o cumprimento eficaz dessas obrigações depende diretamente do domínio de competências associadas à alfabetização em dados (*data literacy*).

Para compreender melhor a natureza e o escopo das responsabilidades desses

[2] Tanto a UFPB quanto o IFBA alinham seus PDIs às diretrizes do Ministério da Educação, contemplando dimensões como o projeto pedagógico institucional, o perfil do corpo docente, a infraestrutura e a gestão. Exemplo no IFBA é a meta de criação até 2022 uma política de padronização dos procedimentos de gestão documental e do gerenciamento/armazenamento de arquivos virtuais/digitais em parcerias com os campi e setores responsáveis pela gestão documental.

profissionais, o Quadro 1 apresenta suas definições e atribuições principais, com base em estudos de referência sobre o tema. A partir das funções descritas, é possível observar que tanto o Coordenador de Curso quanto o Chefe de Departamento ocupam posições estratégicas, nas quais a tomada de decisão depende diretamente da coleta, análise e comunicação eficaz de informações acadêmicas, administrativas e institucionais. Assim, a atuação eficiente desses gestores demanda competências técnicas e analíticas consistentes, reforçando a necessidade de formação e avaliação em *data literacy*, conforme propõe esta dissertação.

Quadro 1 - Definição e atribuições de coordenadores de curso e chefes de departamento

Cargo	Definição	Principais Atribuições
Coordenador de Curso	Profissional responsável por organizar e supervisionar as atividades pedagógicas e administrativas de um curso, articulando docentes, discentes e gestão institucional.	• Elaborar e implementar o Projeto Pedagógico do Curso (PPC); • Planejar e coordenar a oferta de disciplinas; • Monitorar indicadores de desempenho acadêmico; • Atuar em conselhos, comissões e processos avaliativos internos e externos.[3]
Chefe de Departamento	Docente eleito ou designado para liderar um departamento acadêmico, com responsabilidade pela gestão de pessoal, recursos e atividades de ensino, pesquisa e extensão.	• Distribuir a carga horária entre docentes; •Coordenar atividades acadêmicas e administrativas do departamento; • Gerenciar recursos físicos e humanos; • Representar o departamento nos colegiados superiores e instâncias decisórias.[4]

Fonte: Elaboração própria

2.1.2 Evolução histórica da função do gestor acadêmico

A função do gestor acadêmico nas IES tem sofrido profundas transformações nas últimas décadas, em razão da complexificação do sistema educacional brasileiro e do fortalecimento de políticas públicas de avaliação, expansão e regulação. De um papel originalmente pedagógico e técnico, o Coordenador de Curso e o Chefe de Departamento passaram a ocupar posições estratégicas, com atribuições administrativas, financeiras e institucionais cada vez mais robustas.

Historicamente, esses gestores eram concebidos como articuladores de processos didático-curriculares, concentrando sua atuação na organização da oferta de disciplinas, acompanhamento docente e supervisão de projetos pedagógicos. Entretanto, a promulgação

[3] Fontes: Brasil (1996, arts. 53 e 54), Brasil (2004) e Frade *et al*. (2024).
[4] Fonte: Brasil (2017, art. 16).

da Lei nº 9.394/1996 (LDB) marcou o início de um novo paradigma na educação superior, ao estabelecer a autonomia universitária e a exigência de gestão democrática e eficaz (Brasil, 1996). Essa mudança estrutural colocou sobre os ombros dos gestores acadêmicos a responsabilidade de alinhar a execução pedagógica às diretrizes legais, às institucionais e aos princípios de qualidade e eficiência.

A complexidade se acentuou com a criação do SINAES, por meio da Lei nº 10.861/2004, que introduziu avaliações sistemáticas do desempenho institucional, dos cursos e dos estudantes (Brasil, 2004). Como apontam Souza Aragão *et al*. (2019), esse contexto obrigou os coordenadores de curso a lidarem com relatórios, dados estatísticos e indicadores de desempenho — como conceito ENADE, taxa de retenção e perfil de egressos — como ferramentas centrais da gestão acadêmica.

A intensificação das políticas de expansão da educação superior, com destaque para o Programa de Apoio a Planos de Reestruturação e Expansão das Universidades Federais (REUNI) e o Fundo de Financiamento ao Estudante do Ensino Superior (FIES), contribuiu para um aumento do número de cursos, da diversidade do corpo discente e da complexidade operacional das instituições. Segundo Santos, Sordi e Lopes (2024), o Coordenador de Curso deixou de ser apenas um especialista na área de conhecimento para se tornar um gestor intermediário, responsável por integrar a dimensão pedagógica às demandas institucionais, legais e sociais — um papel frequentemente exercido sem formação específica para tal.

Além disso, a digitalização da gestão universitária trouxe consigo a necessidade de lidar com plataformas integradas de dados acadêmicos, como sistemas de gestão acadêmica, relatórios de avaliação, *dashboards* institucionais e documentos regulatórios. Como argumentam Morais *et al*. (2024), essa transição impôs aos gestores acadêmicos o desafio de se apropriar de ferramentas tecnológicas e desenvolver competências analíticas para interpretar dados e tomar decisões em tempo hábil.

Esse novo cenário, portanto, exige que o gestor acadêmico domine não apenas os aspectos normativos e pedagógicos do seu papel, mas também seja capaz de utilizar dados de forma crítica, ética e estratégica. Como alertam Santos, Sordi e Lopes (2024), sem formação adequada para a leitura, análise e uso dos dados institucionais, corre-se o risco de uma atuação baseada apenas na intuição ou na repetição de práticas pouco eficazes — o que compromete a gestão baseada em evidências e o planejamento acadêmico de qualidade.

2.1.3 Complexidade e multinível de atribuições

A gestão acadêmica envolve múltiplas camadas de responsabilidade. Segundo Frade *et al*. (2024), o Coordenador de Curso é responsável pela elaboração e monitoramento do Projeto Pedagógico de Curso (PPC), gestão de pessoas, infraestrutura, finanças e representação institucional. Essa atuação exige não apenas habilidades interpessoais e pedagógicas, mas também capacidade de análise e uso de dados educacionais, orçamentários e estratégicos.

Frade *et al*. (2024) também ressaltam que os gestores acadêmicos operam em um contexto no qual a gestão administrativa e pedagógica é indissociável. Atividades como o planejamento da oferta de disciplinas, a análise de indicadores de desempenho acadêmico, a avaliação institucional, a gestão de orçamentos e a articulação com o mercado de trabalho requerem a capacidade de coletar, interpretar e integrar informações provenientes de múltiplas fontes de dados.

Essa atuação transversal e multinível torna imprescindível a capacidade de o gestor navegar entre diferentes sistemas de dados — acadêmicos, administrativos e financeiros — e tomar decisões baseadas na interpretação crítica dessas informações. Segundo Ghodoosi *et al*. (2024), a competência em *data literacy* torna-se, nesse contexto, uma habilidade estratégica, pois permite que o gestor compreenda não apenas o que os dados indicam, mas também suas limitações, implicações e possibilidades de ação.

Além disso, o uso crescente de sistemas informatizados e de indicadores do Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP)/Ministério da Educação (MEC), como o Conceito Preliminar de Curso (CPC) e o Índice Geral de Cursos (IGC), assim como a participação em processos de avaliação externa, como o ENADE, ampliam a necessidade de competência técnica para lidar com dados complexos e integrados.

Diante da crescente complexidade da gestão acadêmica nas IES brasileiras, a atuação dos coordenadores de curso e chefes de departamento exige o domínio de múltiplas competências técnicas e analíticas. Essas funções, cada vez mais atravessadas pela necessidade de coleta, interpretação e uso estratégico de dados, demandam níveis elevados de alfabetização em dados (*data literacy*).

Para ilustrar a centralidade dos dados nas atividades cotidianas desses gestores, o Quadro 2 sintetiza as principais tarefas administrativas e os respectivos usos de dados associados. Como se observa, a maioria das responsabilidades administrativas e acadêmicas

exige a capacidade de acessar, compreender, analisar e comunicar dados de diferentes naturezas. Essa realidade reforça a necessidade de um instrumento específico para avaliar o nível de competência em *data literacy* dos gestores acadêmicos, adaptado às particularidades do contexto institucional brasileiro.

A gestão acadêmica, historicamente associada à organização de processos pedagógicos e administrativos, passou a assumir um papel estratégico nas IES, na medida em que o cenário educacional se tornou mais regulado, competitivo e orientado por resultados. Segundo Frade *et al*. (2024), a gestão acadêmica moderna exige uma atuação simultaneamente pedagógica, administrativa e política, o que requer planejamento sistemático, avaliação contínua e prestação de contas transparente, ancorados em evidências empíricas.

Quadro 2 - Principais tarefas de lideranças e o uso necessário de dados

Tarefa Administrativa	Uso de Dados Necessário	Exemplo Prático
Planejamento curricular e revisão do Projeto Pedagógico do Curso (PPC)	Taxas de evasão e reprovação, avaliações institucionais, histórico de matrículas	Revisar ementa de disciplina com alta reprovação com base em dados de avaliação institucional.
Oferta semestral de disciplinas	Dados de matrícula, demanda histórica, carga horária docente	Ajustar número de turmas conforme histórico de matrículas e disponibilidade docente.
Gestão da evasão e retenção	Perfil socioeconômico, rendimento acadêmico, taxa de evasão por semestre	Implementar ações para grupos com maior risco de evasão baseado em dados de perfil estudantil.
Acompanhamento de avaliações institucionais	Resultados do ENADE, relatórios da CPA, avaliações docentes	Reformular estratégias pedagógicas após resultados abaixo da média no ENADE.
Elaboração de relatórios e prestação de contas	Dados de matrícula, desempenho acadêmico, relatórios financeiros e operacionais	Justificar solicitação de ampliação de vagas com base em relatório de desempenho institucional.
Gestão de recursos didáticos e infraestrutura	Taxa de uso dos espaços, registros de manutenção, número de alunos por equipamento	Realocar recursos para laboratórios com alta demanda e baixa eficiência.
Acompanhamento de estágios e egressos	Relatórios de estágio, dados de empregabilidade e convênios	Priorizar convênios com maior índice de efetivação de estágio.
Participação em conselhos	Estatísticas acadêmicas, dados financeiros, demandas institucionais	Deliberar sobre ajustes curriculares com base em dados de evasão e desempenho.
Processos avaliativos e regulatórios externos	Planilhas de infraestrutura, pessoal, desempenho do curso	Apresentar evidências para reconhecimento de curso a partir de indicadores acadêmicos.

Fonte: Elaboração própria, baseada em Brasil (1996), Frade *et al*. (2024), Gama e Santos (2020)

Essa transformação foi intensificada pela implementação de políticas públicas como o SINAES, instituído pela Lei nº 10.861/2004, que enfatizou a necessidade de monitoramento sistemático de indicadores de desempenho, tais como CPC e o IGC, taxa de sucesso acadêmico e avaliação da infraestrutura (Brasil, 2004).

A atuação dos gestores acadêmicos, portanto, demanda não apenas capacidade de liderança e conhecimento pedagógico, mas também habilidades analíticas para interpretar, contextualizar e utilizar uma ampla variedade de dados institucionais. Como destacam Gama e Santos (2020), o gestor acadêmico deve ser capaz de identificar padrões em informações sobre rendimento discente, evasão, inserção profissional de egressos, resultados de avaliações externas, além de dados orçamentários e logísticos da instituição.

Além das demandas institucionais, a crescente pressão por *accountability*[5] e eficiência administrativa também influencia a gestão acadêmica contemporânea. Frade *et al*. (2024) destacam que coordenadores e chefes de departamento lidam diariamente com desafios como o planejamento orçamentário, o ajuste de oferta de disciplinas, a gestão de projetos pedagógicos e a implementação de ações de permanência estudantil — todas essas atividades requerem a utilização sistemática de bases de dados acadêmicos e administrativos.

Nesse sentido, o gestor acadêmico atua como um decisor orientado por dados, o que pressupõe competências específicas para a leitura crítica, interpretação, integração e comunicação de informações quantitativas e qualitativas.

Contudo, como observam Ghodoosi *et al*. (2024), embora o uso de dados nas organizações seja reconhecido como estratégico, ainda há uma lacuna substancial na formação de profissionais para lidar de maneira crítica e eficaz com dados no ambiente de trabalho. No contexto educacional, essa lacuna é agravada pela ausência de instrumentos validados para diagnosticar o nível de competência em *data literacy* entre gestores acadêmicos.

A centralidade dos dados no cotidiano da gestão acadêmica contemporânea torna inadiável o desenvolvimento de instrumentos específicos para mensurar, monitorar e aperfeiçoar a competência em *data literacy* desses profissionais, possibilitando uma gestão mais eficaz, ética e orientada por evidências.

---

[5]Termo em inglês, que de forma ampla significa algo como obrigação de prestar contas, responsabilizar-se e responder por suas ações e decisões.

2.2 *DATA LITERACY*

A participação efetiva em um mundo gradualmente mais orientado por dados depende da capacidade dos indivíduos de interagir criticamente com essas informações. Gutiérrez (2019) destaca que, para resgatar a participação política em um domínio de dados, é necessário um certo grau de capacitação, questionando onde se estabelecem as linhas de separação entre especialistas e cidadãos comuns.

2.2.1 Conceito e importância da *data literacy*

No contexto das IES, a competência em *data literacy* é essencial para que gestores acadêmicos tomem decisões informadas, baseadas em evidências concretas. Com a crescente digitalização das instituições de ensino, a habilidade de lidar com dados tornou-se uma exigência fundamental para a eficácia administrativa e acadêmica.

Segundo Echtenbruck *et al*. (2025), a alfabetização em dados envolve não apenas habilidades técnicas, mas também uma compreensão crítica do contexto em que os dados são produzidos e utilizados. Essa perspectiva amplia o escopo da *data literacy*, incorporando aspectos éticos e sociais na análise e aplicação de dados.

No contexto educacional brasileiro, já ocorreu iniciativa no intuito de desenvolver e promover a literacia de dados desde a Educação Básica. Reznik, Giannella e Kosminsky (2023) apontam para a importância do uso de metodologias lúdicas e da visualização de dados no processo de ensino-aprendizagem para crianças, visando aproximar os alunos do conhecimento de forma engajadora. Além disso, a avaliação dessas competências é fundamental para identificar lacunas e direcionar estratégias educativas.

A literacia de dados não se limita ao domínio técnico; envolve também uma compreensão crítica sobre a origem, o contexto e as implicações dos dados. Arruda (2020) enfatiza que para utilizar dados de forma responsável é necessário saber de onde eles vieram, como foram gerados e com qual propósito, permitindo uma postura mais ativa e consciente na sociedade.

Para esta pesquisa, que visa desenvolver uma escala voltada a gestores acadêmicos, adotamos como referência principal o modelo proposto por Echtenbruck *et al*. (2025), por ser o mais recente e o único especificamente desenhado para o ambiente de educação superior

Seu *framework* integra sete dimensões essenciais, mas iremos trabalhar apenas três

aspectos, desde a coleta e governança de dados até a comunicação ética de resultados, alinhando-se diretamente às demandas dos gestores de IES. Apesar de existirem outras definições relevantes, como a de Mandinach e Gummer (2016) e a de Ridsdale *et al*. (2015), o trabalho de Echtenbruck *et al*. (2025) destaca-se pelos motivos a seguir:

1. Contextualização institucional: aborda explicitamente a tomada de decisão em IES;
2. Aplicabilidade prática: inclui competências como "julgar a qualidade dos dados" e "integrar sistemas acadêmicos";
3. Rigor metodológico: foi validado em universidades europeias, com potencial de adaptação ao cenário brasileiro.

O Quadro 3 sintetiza essa e outras definições-chave de *data literacy*, destacando suas contribuições e limitações para o estudo em questão.

Quadro 3 - Definições de *data literacy* em trabalhos relevantes

Autores	Definição	Comentário
Echtenbruck et al. (2025)	É o Conjunto integrado de competências para coletar, gerenciar, avaliar criticamente e aplicar dados em contextos organizacionais, com atenção à ética e comunicação.	Mais adequada para esta pesquisa, pois propõe um modelo específico para a educação superior, incluindo dimensões como governança de dados e tomada de decisão institucional.
Mandinach e Gummer (2016)	É a Capacidade de transformar dados em informação acionável, envolvendo compreensão, interpretação e uso ético em processos decisórios.	Foca em educadores, mas é adaptável a gestores acadêmicos, pela ênfase em decisões pedagógicas. Limitação: não aborda dados administrativos.
Ridsdale et al. (2015)	É a Habilidade de ler, analisar, argumentar com dados e comunicar insights, combinando conhecimentos estatísticos, tecnológicos e críticos.	Abordagem técnica útil para operacionalizar itens da escala, mas exige adaptação para incluir gestão de recursos humanos/financeiros.
D'Ignazio e Bhargava (2015)	É a Competência para entender, criar e compartilhar representações de dados, considerando poder, ética e impacto social.	Destaque para comunicação (importante para relatórios institucionais), mas pouco explora análise preditiva.

Fonte: Elaboração própria

Como demonstrado no Quadro 3, a definição de Echtenbruck *et al*. (2025) emerge como a mais adequada para fundamentar esta pesquisa, por seu enfoque na gestão acadêmica e sua estrutura multidimensional. Enquanto outros modelos trazem contribuições pontuais (como habilidades técnicas ou comunicação), o *framework* proposto por esses autores oferece uma visão holística, essencial para desenvolver uma escala que avalie:

- A capacidade dos gestores de **interpretar dados regulatórios** (ex.: SINAES);
- Seu domínio sobre **ferramentas analíticas** em contextos decisórios;

- Sua competência para **comunicar *insights*** a *stakeholders* internos e externos.

Assim, adotaremos esse modelo como eixo central para a operacionalização do constructo *data literacy* neste estudo, adaptando-o às particularidades das IES brasileiras como diversidade de dados, gestão acadêmica e administrativa, análise de evasão, melhoria de desempenho, dentre outros. As demais definições do Quadro 3 servirão como complementos para enriquecer dimensões específicas da escala, como ética (D'Ignazio; Bhargava, 2015) e análise crítica (Ridsdale *et al*., 2015).

Diversos modelos foram propostos para estruturar as competências relacionadas à *data literacy*. O modelo desenvolvido por Echtenbruck *et al*. (2025) destaca sete áreas principais: promover um ambiente institucional que valorize o uso de dados; garantir a disponibilidade e acessibilidade de dados relevantes; organizar e manter dados de forma eficiente; aplicar técnicas analíticas para extrair *insights* significativos; julgar a qualidade e relevância dos dados disponíveis; compreender e contextualizar os dados analisados; compartilhar informações de maneira transparente e ética. Essas dimensões fornecem um *framework* abrangente para o desenvolvimento de programas de formação e avaliação da *data literacy* em contextos acadêmicos.

2.2.2 Dimensões da data literacy

A *data literacy*, no contexto da gestão, representa um avanço em relação à simples interpretação de informações prontas. Ela capacita o gestor a participar ativamente do ciclo de vida dos dados, desde a formulação de questões pertinentes até a análise crítica dos resultados.

Para o gestor acadêmico, isso significa transcender a tarefa de preencher relatórios e passar a utilizar os dados para construir um diagnóstico preciso do seu curso ou departamento, formulando hipóteses sobre as causas de fenômenos como a evasão discente ou o baixo rendimento em certas disciplinas. Essa abordagem proativa, fundamentada em evidências, transforma a gestão, tornando-a mais estratégica e alinhada às demandas institucionais e regulatórias.

O desenvolvimento da *data literacy* não ocorre de forma isolada, mas pela integração de múltiplas habilidades. Não basta dominar uma ferramenta computacional sem a devida compreensão estatística para interpretar os resultados, ou analisar dados sem uma visão crítica

sobre seu contexto e suas possíveis limitações. Portanto, a competência em *data literacy* é intrinsecamente multidisciplinar, exigindo que o gestor acadêmico combine conhecimentos técnicos com um pensamento crítico e analítico. Essa sinergia é o que permite transformar dados em informação acionável, como defendem Mandinach e Gummer (2016), e em insights capazes de fundamentar decisões que promovam a melhoria contínua dos processos educacionais e administrativos da instituição.

Portanto, o que significa competência? A compreensão do que define um profissional como 'competente' passou por transformações significativas na última década, migrando de uma visão estática de acúmulo de diplomas para uma perspectiva centrada na entrega e no comportamento. No cenário das Instituições de Ensino Superior (IES) brasileiras, essa mudança é impulsionada pela necessidade de responder com eficiência a um sistema de gestão cada vez mais complexo e normatizado (DALMAU; SILVA; CANTO, 2023).

De acordo com Barbosa et al. (2022), a competência no setor público deve ser compreendida como um 'comportamento observável', estruturado na tríade de conhecimentos, habilidades e atitudes, mas que só ganha valor real quando gera um resultado concreto para a instituição. Essa abordagem é fundamental para a administração pública brasileira, pois permite que o diagnóstico de competências deixe de ser subjetivo e passe a ser baseado em evidências de desempenho (BARBOSA et al., 2022).

Nas Universidades Federais, a implementação de modelos de gestão por competências tem se tornado um pilar estratégico para alinhar o desenvolvimento dos servidores aos objetivos do Plano de Desenvolvimento Institucional (PDI) (DALMAU; SILVA; CANTO, 2023). Para esses autores, a competência não é um recurso isolado, mas sim o produto da integração de diversos subsistemas de gestão que buscam a excelência na prestação do serviço público. Assim, o letramento de dados — objeto central deste estudo — manifesta-se como uma competência gerencial crítica, onde o saber técnico e o domínio instrumental precisam convergir para um 'saber agir' que sustente decisões institucionais eficazes.

2.2.3 Competência estatística

A competência estatística é o alicerce que permite ao gestor extrair significado e validade dos dados institucionais. O domínio de conceitos como média, mediana e desvio padrão é fundamental para resumir e compreender o desempenho acadêmico, enquanto a aplicação de técnicas como correlação e regressão possibilita a identificação de relações entre

variáveis, como a influência do perfil socioeconômico na taxa de diplomação. Sem essa base, o gestor corre o risco de tirar conclusões equivocadas de análises superficiais, comprometendo a qualidade e a eficácia de suas decisões. A estatística oferece, portanto, as ferramentas necessárias para testar hipóteses e validar tendências, conferindo maior robustez à gestão baseada em evidências.

Além da capacidade de realizar análises, a competência estatística se manifesta na habilidade de comunicar os resultados de forma clara e precisa. A escolha correta de um gráfico para representar uma tendência ou a tradução de um jargão estatístico para uma linguagem acessível são cruciais para engajar diferentes públicos, como docentes, discentes e a alta administração. Como destacam D'Ignazio e Klein (2020), uma visualização de dados eficaz não é apenas um recurso estético, mas uma ferramenta poderosa, capaz de simplificar a complexidade e direcionar a atenção para os insights mais relevantes. Para o gestor acadêmico, saber "contar uma história com dados" é fundamental para justificar a necessidade de recursos, defender mudanças curriculares ou apresentar os resultados de seu setor em avaliações institucionais.

2.2.4 Competência computacional

A competência computacional viabiliza a aplicação prática da *data literacy* em um ambiente com grande volume de informações. O domínio de ferramentas como o *Microsoft Excel* permite a organização inicial de dados e análises descritivas, enquanto *softwares* mais avançados como R, Python ou SPSS são essenciais para executar análises estatísticas complexas, como a análise fatorial. Adicionalmente, plataformas de *Business Intelligence* como Power BI e Tableau capacitam o gestor a criar painéis de controle (*dashboards*) interativos, possibilitando o monitoramento contínuo e visual de indicadores-chave de desempenho (KPIs) acadêmico e administrativo. O uso dessas tecnologias automatiza tarefas repetitivas e amplia a capacidade analítica do gestor.

O desenvolvimento da competência computacional promove maior autonomia e agilidade na tomada de decisão. Gestores que dominam essas ferramentas reduzem a

dependência de equipes técnicas ou do setor de TI para obter e analisar dados, podendo explorar as informações de maneira independente para responder a questionamentos pontuais do dia a dia.

Essa autonomia, como sugerido por Mandinach e Schildkamp (2021), é crucial no contexto dinâmico da gestão acadêmica, em que decisões sobre alocação de turmas, ajuste de horários ou acompanhamento de estudantes em risco precisam ser tomadas de forma rápida e informada. Assim, a proficiência computacional não é um fim em si mesma, mas um meio para que o gestor tenha um acesso mais direto e eficiente às evidências que fundamentam seu trabalho.

2.2.5 Competência de uso cotidiano

A capacidade de analisar dados no uso cotidiano representa uma competência essencial para gestores que atuam em contextos organizacionais cada vez mais orientados por dados. No cotidiano da gestão, essa competência se traduz na habilidade de interpretar relatórios, identificar padrões em planilhas, compreender *dashboards* e tomar decisões com base em evidências extraídas de múltiplas fontes de dados estruturados e não estruturados. Trata-se de uma competência prática da alfabetização em dados, que envolve não apenas o entendimento técnico das informações, mas também o julgamento crítico sobre sua relevância e confiabilidade (Mandinach; Gummer, 2016).

Em ambientes educacionais, por exemplo, gestores precisam analisar indicadores de desempenho acadêmico, dados de evasão, satisfação discente e resultados de avaliações institucionais para promover melhorias contínuas. Essa análise cotidiana exige um nível funcional de fluência em dados, no qual o gestor consegue transformar dados em ações, alinhando-os aos objetivos estratégicos da instituição.

Além disso, a utilização constante de dados no cotidiano profissional favorece o desenvolvimento de uma cultura organizacional orientada por evidências, o que fortalece a qualidade da tomada de decisão e a legitimidade das ações gestoras, além de propor mudanças de objetivos de trabalho com base em dados.

Em um nível mais estratégico, a literacia de dados capacita o gestor a justificar decisões complexas e de alto impacto, como a reformulação do Projeto Pedagógico de um Curso (PPC), por exemplo, a partir de uma sólida base informacional. Essa atuação exige não

apenas identificar como as decisões são tomadas, mas também compreender criticamente as limitações dos indicadores, especialmente quando a qualidade dos dados é questionável.

A maturidade na gestão de dados é atingida quando o profissional consegue avaliar os riscos morais e legais associados ao uso de informações sensíveis, como avaliações docentes, e é capaz de usar análises preditivas para propor mudanças nos objetivos de trabalho, alinhando as metas futuras às tendências apontadas pelos dados.

2.2.6 Aplicações na gestão acadêmica

No contexto das IES, o uso estratégico de dados tem se tornado central para garantir qualidade, efetividade e conformidade regulatória nas práticas de gestão acadêmica. A alfabetização em dados (*data literacy*) permite aos gestores interpretarem os diferentes fluxos de informação institucional e transformá-los em decisões fundamentadas, transparentes e eficazes. De acordo com Kim, Hong e Evans (2024), profissionais do ensino superior com alta autoeficácia em *data literacy* demonstram maior capacidade de responder de forma proativa a exigências como a avaliação institucional, a gestão da permanência estudantil e o alinhamento de currículos às diretrizes nacionais. Isso reforça a ideia de que, na prática da gestão, *data literacy* é uma competência transversal e estratégica. A seguir, detalham-se algumas das principais áreas em que a *data literacy* é aplicada pelos gestores acadêmicos.

2.2.7 Planejamento pedagógico e curricular

Gestores utilizam dados históricos de matrícula, taxas de aprovação/reprovação, *feedbacks* de avaliações institucionais e resultados do ENADE para subsidiar decisões sobre:

- Reformulação de ementas e sequências de pré-requisitos;
- Criação, fusão ou extinção de disciplinas;
- Adequação da carga horária docente à demanda efetiva do curso.

Segundo Echtenbruck *et al*. (2025), esse tipo de uso exige a integração de diferentes fontes de dados e a capacidade de contextualizar as evidências em relação ao perfil do corpo discente.

2.2.8 Gestão da evasão e permanência estudantil

A análise preditiva da evasão tem ganhado espaço no planejamento acadêmico, com o uso de *dashboards* que cruzam dados de frequência, desempenho, perfil socioeconômico e formas de ingresso. Um gestor alfabetizado em dados é capaz de:

- Detectar padrões de evasão por semestre, turno ou tipo de disciplina;
- Propor estratégias de acolhimento e tutoria baseadas em evidências;
- Apresentar indicadores que justifiquem programas de apoio institucional (monitorias, bolsas).

Como indicam Moyo e Bangani (2025), gestores que compreendem a lógica dos dados educacionais podem atuar preventivamente, e não apenas de forma reativa, diante dos desafios da retenção discente.

2.2.9 Avaliação institucional e regulatória

As comissões próprias de avaliação (CPA) e os processos de recredenciamento institucional demandam ampla coleta e análise de dados. A *data literacy* permite:

- Organizar e apresentar dados de infraestrutura, desempenho de curso e empregabilidade;
- Interpretar resultados do ENADE com criticidade;
- Relacionar os dados coletados com os requisitos legais estabelecidos pelo SINAES.

Esse tipo de competência é essencial para manter a conformidade institucional e garantir boas avaliações externas, com impacto direto na reputação e financiamento da IES.

2.2.10 Tomada de decisão orçamentária e de recursos humanos

Além da dimensão pedagógica, gestores precisam lidar com alocação de carga horária, dimensionamento de turmas, uso de salas e laboratórios, e até mesmo com orçamento departamental. A *data literacy* permite:

- Analisar indicadores de custo por aluno, por disciplina e por curso;
- Decidir com base em dados sobre a viabilidade da oferta de novas turmas;
- Justificar contratações ou remanejamentos com base em dados objetivos.

Como observa Taş (2024), o domínio de competências em dados permite aos gestores dialogarem com áreas como planejamento institucional, finanças e tecnologia da informação

(TI) com maior autoridade e precisão.

2.2.11 Comunicação institucional e prestação de contas

Um gestor alfabetizado em dados também sabe comunicar resultados com clareza, utilizando visualizações apropriadas, linguagem acessível e contextualização ética. Isso se aplica às seguintes situações:

- Apresentação de relatórios para conselhos e colegiados;
- Justificativa de ações administrativas junto à reitoria;
- Divulgação de indicadores de desempenho à comunidade acadêmica.

Essa habilidade fortalece a transparência e a governança institucional, promovendo maior engajamento de estudantes, docentes e técnicos. A alfabetização de dados abrange uma ampla gama de competências e habilidades. Embora existam várias definições, alguns estudos que são relativamente novos na área educacional podem ser citados nesse trabalho. A seguir, iremos examinar alguns deles mais detalhadamente antes de formular nossa própria pesquisa.

2.3 MENSURAÇÃO DE *DATA LITERACY*

Para medir a alfabetização de dados, é preciso primeiro decompô-la em um conjunto de competências ou fatores observáveis. A literatura apresenta diversas definições, que vão desde a capacidade de entender o que os dados significam, incluindo como ler diagramas corretamente (Chung; Yoo, 2022) até um processo mais complexo que inclui extrair informações, resolver problemas e usar dados para persuadir e tomar decisões racionais. Estudos que se propõem a criar ferramentas de medição utilizam essas definições para construir um quadro conceitual mais robusto.

O estudo de Chung e Yoo (2022) focado em estudantes universitários, por exemplo, desenvolveu um modelo que, após validação estatística, resultou em uma estrutura de seis dimensões. São elas: **compreensão e coleta de dados,** que é a capacidade de formular uma hipótese e, a partir dela, determinar, pesquisar e coletar os dados adequados para sua verificação; **análise de dados** sendo habilidades práticas de refinar, processar e interpretar

dados, como identificar valores atípicos, calcular médias ou transformar dados brutos em tabelas e gráficos; **avaliação de dados** em que é o componente crítico de verificação envolve analisar a fonte dos dados para julgar sua confiabilidade e avaliar se há distorções ou exageros na interpretação dos resultados; **utilização de ferramentas de dados,** que é a proficiência no uso de *softwares* como *Excel*, programas estatísticos ou aplicativos para analisar, gerenciar e interpretar informações com eficiência e precisão; **representação de dados,** que é a competência de visualizar dados de forma eficaz, escolhendo o método (tabelas, gráficos etc.) que melhor se adapta ao conteúdo e ao objetivo da comunicação; e a c**omunicação baseada em dados** sendo essa a capacidade de usar dados para apoiar objetivamente um argumento e persuadir efetivamente uma audiência, mesmo que esta tenha opiniões divergentes. A pesquisa medida na forma de uma escala *Likert* de 4 pontos (muito não ~ muito verdadeiro). Os dados foram coletados de 3.510 ingressantes da universidade. A seguir, o quadro 4 representa os itens da escala de Chung e Yoo (2022).

Quadro 4 - Itens da escala de Chung e Yoo (2022)

Itens	Definição
Entendendo seus dados	Capacidade de entender o tipo e o conteúdo dos dados para resolver problemas.
Planejar e coletar análise de dados	Capacidade de executar a coleta de dados criando um plano para coletar e analisar dados.
Análise de dados	Capacidade de refinar e analisar dados.
Avaliação de dados	Capacidade de detectar erros no processo e resultados da análise de dados e avaliar os resultados da análise de dados com pensamento crítico.
Uso de ferramentas de dados	Capacidade de analisar e gerenciar dados com eficiência e precisão usando as ferramentas certas.
Representação de dados	Capacidade de visualizar dados usando tabelas, gráficos etc., para transmitir significado
Comunicação orientada por dados	Capacidade de explicar e persuadir os outros com base em dados.

Fonte: Chung e Yoo (2022)

O estudo de Öz e Özdemir (2022), realizado na Turquia, com educadores adotou uma abordagem diferente, focada não apenas nas habilidades, mas também na disposição e autopercepção, resultando em uma escala com três fatores principais.

A **autoeficácia**, que é a percepção e o conhecimento do educador sobre sua própria capacidade de aplicar a análise de dados, como distinguir tipos de dados (quantitativos vs. qualitativos), interpretar tabelas e gráficos, e confirmar a precisão das informações; **experiência** sendo que é as vivências práticas anteriores do educador com análise e alfabetização de dados, incluindo a familiaridade com *softwares* (*Excel*, SPSS), o conceito de

mineração de dados e a aplicação de dados para atingir metas profissionais; **atitude** que é os sentimentos e pensamentos dos educadores sobre a necessidade e a importância das habilidades de dados em sua profissão, como a crença de que decisões devem ser baseadas em dados e que treinamentos na área são necessários. A escala foi preparada levando-se em conta a escala *Likert* de 5 pontos.

O formulário foi preparado na forma de (1) discordo totalmente, (2) não concordo, (3) estou indeciso, (4) concordo, (5) concordo totalmente. A amostra foi aplicada 820 professores e administradores que trabalhavam em escolas públicas no ano letivo de 2021-2022. O quadro 5 mostra os 35 itens que foram criadas por Öz e Özdemir (2022).

Quadro 5 - Itens da escala de Öz e Özdemir (2022)

Fatores	**Itens**
Autoeficácia	Posso distinguir os dados que encontro em minha vida diária.
	Sei distinguir entre dados quantitativos e qualitativos.
	Sou capaz de vincular dados.
	Posso entender se os dois pontos de dados são diretos ou inversamente proporcionais um ao outro.
	Quando preciso acessar alguns dados, sei onde encontrá-los.
	Posso acessar qualquer tipo de dados de que preciso.
	Os dados me dão uma ideia de por que algumas metas não são atingidas.
	Posso extrair os dados que coletei e obter resultados significativos.
	Os dados não apenas me dão uma ideia, mas também me ajudam a ver as lacunas e preenchê-las.
	Sou capaz de interpretar tabelas e gráficos com informações estatísticas.
	Acho que interpretar dados é uma habilidade tão básica quanto ler e escrever.
	Acho que sou competente na avaliação dos dados que encontro em minha profissão.
	Quando vejo dados sobre educação, posso confirmar a precisão dessas informações de várias fontes.
Experiência	Estou familiarizado com pelo menos um programa de análise de dados (como Excel, SPSS, Maxquda, Nvivo, etc.)
	Acho que sou competente na visualização de dados com gráficos.
	Conheço o conceito de mineração de dados.
	Verifico os gráficos de desempenho do curso de meus alunos nas plataformas digitais (por exemplo, escola, eba, zoom, etc.) que eles usam.
	Sou capaz de fazer discussões e comentários sobre a análise de dados.
	Já criei gráficos e tabelas usando um programa de computador antes.
	Acompanho os dados sobre educação no mundo.
	Conheço o conceito de um conjunto de dados.
	Examino estatisticamente a mudança nas notas dos exames de meus alunos.
	Acho que estou familiarizado com os conceitos estatísticos básicos (moda, mediana, desvio padrão, média aritmética, etc.).
	Uso os dados de forma eficaz para atingir um conjunto de metas profissionais.
Atitude	Acho que os dados são necessários para a estruturação, o registro e análise fácil das informações.
	Considero importante que as decisões sejam tomadas com base em dados no sistema educacional.
	As habilidades de análise de dados me tornam um educador melhor.
	Acho que o treinamento em serviço é necessário para a análise de dados.

	Quando me deparo com dados estatísticos sobre educação, eu os examino cuidadosamente.
	A visualização de dados é importante para ver relações significativas

Fonte: Öz e Özdemir (2022)

O estudo de Duygulu, Doğan e Yıldız (2025), focado no ambiente escolar, também na Turquia, posiciona a literacia em dados como uma ferramenta organizacional essencial para a melhoria institucional. A sua fundamentação teórica baseia-se na premissa de que professores e administradores, com a literacia em dados, podem tomar decisões mais eficazes, melhorar os processos de ensino e aprendizagem e promover uma "cultura de dados" na escola. A literacia em dados é vista como um pré-requisito para a tomada de decisões baseada em dados.

O processo de geração de itens da escala reflete essa orientação prática e organizacional. Primeiro eles realizaram uma revisão abrangente da literatura**:** Duygulu, Doğan e Yıldız (2025) realizaram uma revisão da literatura para criar um rascunho inicial com 61 itens. Em seguida, foi feita uma revisão por especialistas: o rascunho foi submetido a três especialistas acadêmicos e do ministério da educação da Turquia que avaliaram a clareza, relevância e escopo dos itens. Tendo base no *feedback* dos especialistas, múltiplos itens foram removidos, combinados ou reformulados e com isso foi realizado um refinamento dos itens. Por exemplo, itens considerados pouco claros, não diretamente relacionados com a literacia em dados ou redundantes foram eliminados, resultando em uma versão final de 13 itens para análise fatorial.

Esse processo de refinamento visava garantir que a escala se concentrasse nas competências práticas relevantes para o contexto escolar. A pesquisa foi na forma de uma escala *Likert* de 5 pontos, estendendo alternativas de "concordo totalmente" a "discordo totalmente". A amostragem foi formada por 338 professores e administradores escolares que estão em serviço ativo no ano educacional de 2023-2024 em Kastamonu. Os itens da escala são mostrados no quadro 6.

Quadro 6 - Itens da escala de Duygulu, Doğan e Yıldız (2025)

Fatores	Itens
Identificação de dados	Eu posso tabular dados textuais
	Posso explicar o conceito de dados.
	Posso definir o conceito de "dados factuais"
	Posso listar os tipos de dados usados em processos educacionais e instrucionais.
	Posso listar as funções dos dados nos processos de ensino.
	Posso converter dados textuais em ferramentas visuais.
Uso de dados	Posso explicar o conceito de "fontes de dados secundárias".

	Posso explicar o conceito de pirâmide de informações.
	Tenho conhecimento sobre ferramentas de armazenamento de dados na escola.
	Posso me beneficiar de fontes de dados digitais na escola.
Gestão de dados	Posso listar as características específicas dos dados.
	Tenho conhecimento sobre ferramentas de armazenamento de dados.
	Posso listar as etapas do processo de gerenciamento de dados.

Fonte: Duygulu, Doğan e Yıldız (2025)

Já o estudo de Kim, Hong e Evans (2024) aborda a literacia em dados no ensino superior, definindo-a como uma competência multifacetada, essencial para a vida pessoal e profissional. Crucialmente, essa escala foi projetada para medir a autoeficácia — os julgamentos de um indivíduo sobre suas capacidades percebidas para realizar tarefas ou ações. A sua base conceitual é mais ampla, situando a literacia em dados na interseção da literacia informacional, literacia estatística e estudos críticos de dados.

O processo de geração de itens por Kim, Hong e Evans (2024) foi igualmente sistemático, mas com um foco diferente. Primeiro foi feita a análise conceitual e comparativa. Os autores realizaram uma análise aprofundada da literatura para dissecar a definição de literacia em dados e comparar quadros de competências existentes, identificando 15 elementos-chave. Depois disso foi realizado o desenvolvimento e revisão de itens. A partir desses elementos, foi gerada uma lista inicial de 44 itens.

Um painel de quatro especialistas em literacia informacional, ciência de dados e psicometria revisou os itens quanto à sua formulação e clareza, refinando a lista para 33 itens organizados em 10 elementos conceituais, como "Limpeza de Dados", "Análise de Dados" e "Ética de Dados". A escala final foi projetada para que os participantes avaliassem os seus níveis de confiança numa escala de 1 ("Nenhum conhecimento") a 5 ("Especialista"). Um total de 1025 participantes responderam à pesquisa. A seguir os itens da escala são exibidos no quadro 7.

Quadro 7 - Itens da escala de Kim, Hong e Evans (2024)

Elementos Conceituais	Itens
Coleta de dados	Definindo o que são dados
	Descrevendo quais são os diferentes tipos e formatos de dados
	Explicando o valor real e potencial dos dados
Limpeza de dados	Coleta de dados primários, como pesquisas, observações, experimentos, questionários ou entrevistas
	Localizar dados secundários de fontes impressas/eletrônicas, como artigos de periódicos e publicações governamentais
	Acessar e localizar dados secundários de informações armazenadas eletronicamente, como sites, APIs e bancos de dados

Análise de dados	Identificar erros de dados, incluindo dados corrompidos, formatados incorretamente, duplicados ou incompletos
Visualização de Dados	Exibição e resumo de dados usando estatísticas descritivas
	Usando estatísticas inferenciais para tirar inferências significativas de dados
	Empregar análise preditiva para fazer previsões e direcionar decisões
	Aplicação de mineração de dados para explorar padrões e tendências de dados
	Comunicar por escrito e verbalmente os resultados da análise de dados/análise
Data Storytelling	Selecionando ferramentas apropriadas para criar visualizações de dados
	Criar visualizações de dados úteis e significativas usando gráficos, tabelas e gráficos usando um conjunto de dados escolhido
	Interpretação de visualizações de dados para identificar pontos de interesse
Organização de Dados	Apresentando insights de dados adaptados a um público específico.
	Usando uma técnica de storyboard para planejar o conteúdo e a estrutura de uma apresentação de dados.
	Usando uma estrutura narrativa para criar apresentações de dados atraentes
Conscientização de dados	Avaliar fontes de dados para garantir que atendam às necessidades definidas
	Determinar se os dados atendem à qualidade exigida para um determinado propósito.
	Avaliar criticamente os dados para o tipo e a quantidade certos para dar suporte ao uso pretendido.
Avaliação da qualidade dos dados	Categorizar e classificar dados para torná-los mais acessíveis para uso
	Organizar e distribuir dados entre arquivos, incluindo convenções de nomenclatura de arquivos, estrutura de diretórios, controle de versão
	Documentar dados para melhorar a localização e acessibilidade dos dados (por exemplo, livro de códigos, dicionário de dados, arquivo README, metadados)
Armazenamento de dados	Diferenciando entre diferentes dispositivos de armazenamento de dados
	Identificar vários métodos e estratégias de backup de dados
	Determinando as melhores opções de armazenamento para armazenamento de dados de curto e longo prazo
Ética de Dados	Localizar leis, regulamentos e diretrizes, como FERPA, HIPAA e GDPR, para lidar com segurança e privacidade de dados
	Utilizando técnicas de desidentificação para proteger dados pessoais
	Determinação da propriedade de dados e direitos de uso – ou seja, direitos de propriedade intelectual e licenciamento
	Identificar as melhores práticas atuais em citação de dados, incluindo o uso de identificadores permanentes, nomeadamente Identificadores de Objetos Digitais

Fonte: Adaptado de Kim, Hong e Evans (2024)

Essas divergências de estruturas — a de Chung e Yoo (2022) focada em habilidades processuais; a de Öz e Özdemir (2022) aplicada em percepções e atitudes; a Duygulu, Doğan e Yıldız (2025) visando medir competências aplicadas num contexto profissional específico (gestão escolar); e a de Kim, Hong e Evans (2024) medem também as percepções e atitudes (autoeficácia) de estudantes em um espectro mais vasto de habilidades de dados — sublinha a natureza profundamente contextual da alfabetização de dados. Diferentes papéis e contextos exigem diferentes conjuntos de habilidades e uma abordagem "tamanho único" para a educação em dados é evidentemente inadequada. A seguir são apresentadas as escalas no quadro 8.

Quadro 8 - Comparativo dos estudos de escala de *Data Literacy*

Autores	Público-Alvo	Dimensões	Quantidade de Itens
Chung & Yoo (2022)	Estudantes universitários calouros	1) Compreensão de dados 2) Análise de dados 3) Uso de ferramentas de dados 4) Comunicação baseada em dados	21
Öz & Özdemir (2022)	Educadores	1) Coleta e compreensão de dados 2) Análise de dados 3) Uso para tomada de decisão	30
Duygulu, Doğan & Yıldız (2025)	Professores e gestores escolares	1) Identificação de dados 2) Uso de dados 3) Gestão de dados	24
Kim, Hong & Evans (2024)	Estudantes do ensino superior	1) Identificação de dados 2) Processamento de dados 3) Gerenciamento e compartilhamento de dados	31

Fonte: Elaboração própria

2.4 RESUMO DO CAPÍTULO

Este capítulo fundamenta a pesquisa ao explorar os dois pilares centrais do estudo: a gestão acadêmica e a *data literacy*. Inicialmente, discute-se a evolução do papel do gestor acadêmico, que, impulsionado por marcos regulatórios como a LDB e o SINAES, transcendeu de uma função puramente pedagógica para uma posição estratégica e multinível. Demonstra-se que atividades cotidianas de coordenadores e chefes de departamento como planejamento curricular, gestão da evasão e prestação de contas se tornaram intrinsecamente dependentes da coleta, análise e interpretação de dados.

Em seguida, o capítulo conceitua a *data literacy* como a competência essencial para que esses gestores atuem de forma eficaz nesse novo cenário. O texto detalha as competências que a compõem, como a estatística, a computacional e a aplicação crítica no cotidiano profissional. São apresentadas aplicações práticas que conectam essa alfabetização à melhoria do planejamento pedagógico, ao monitoramento da permanência estudantil e à tomada de decisão baseada em evidências.

Por fim, a análise da literatura sobre a mensuração da *data literacy* revela a complexidade em avaliar tal competência, destacando a existência de diferentes modelos e escalas, como os focados em processos e habilidades e os centrados na autoeficácia e atitude. A diversidade dessas abordagens ressalta a natureza contextual da *data literacy* e reforça a lacuna de um instrumento específico e validado para a realidade dos gestores acadêmicos no Brasil, justificando a proposta desta pesquisa.

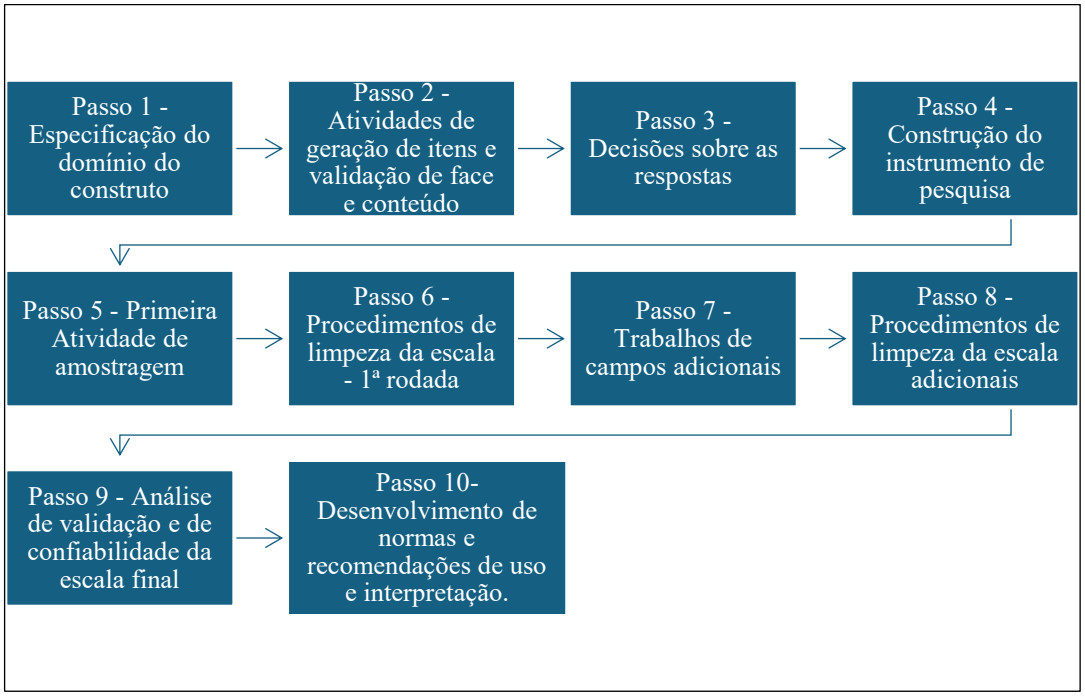
3 MÉTODO

Este capítulo tem como objetivo detalhar os procedimentos metodológicos que serão desenvolvidos nesta pesquisa. Sendo assim, realizaremos uma revisão da literatura para identificar a necessidade de uma escala específica que avalie a alfabetização em dados entre gestores acadêmicos. Em seguida, estabeleceremos critérios claros que a escala deve atender, como validade, confiabilidade e aplicabilidade no contexto acadêmico. Também criaremos os itens da escala com base em teorias existentes sobre *data literacy* e gestão acadêmica. Por fim, aplicaremos a escala em um grupo piloto de gestores acadêmicos para verificar sua funcionalidade e identificar possíveis melhorias. Além disso, analisaremos os dados coletados para avaliar a validade e a confiabilidade da escala.

3.1 PROTOCOLO DE DESENVOLVIMENTO DE ESCALA

O protocolo de desenvolvimento de uma escala segue passos bem definidos e dependentes do estágio anterior. A literatura apresenta uma série de trabalhos desenvolvidos para orientar pesquisadores no processo de criação ou adaptação de escalas. Para este trabalho optamos por seguir os 10 passos de desenvolvimento de escala presente em Costa (2011).

Figura 3 - Passos do desenvolvimento da escala



Fonte: Costa (2011)

A seguir são detalhados os 10 passos propostos no modelo de Costa (2011) para a construção da escala, cabe destacar que o processo é um mix de procedimentos qualitativos e quantitativos.

- **Passo 1-** A especificação do domínio do construto refere-se ao processo de delimitar com precisão o conceito a ser mensurado, bem como suas respectivas dimensões.
- **Passo 2 –** Atividades de geração de itens e validação de face e conteúdo: geração de indicadores que possam ser utilizados para mensurar o construto.
- **Passo 3 –** Decisões sobre as respostas: consiste na análise das alternativas e decisão sobre qual escala de averiguação será utilizada e qual o número de pontos.
- **Passo 4 –** Construção do Instrumento de Pesquisa: refere-se a colocar o conjunto de itens gerados em um instrumento de campo que viabilize a coleta de dados.
- **Passo 5 –** Primeira atividade de Amostragem: tem por finalidade a obtenção dos primeiros resultados para a realização de alguns testes exploratórios preliminares.
- **Passo 6 –** Primeiros procedimentos de limpeza da escala: o propósito é eliminar itens que não tem maiores contribuições para a escala de maneira "evidente".
- **Passo 7 –** Atividades de campo adicionais: visa levantar novos dados para o aprimoramento da escala, testando novamente a escala, e caso necessário, realizando novas limpezas.
- **Passo 8 –** Procedimentos de limpeza da escala adicionais: aplicam-se sobre os dados da nova amostra, como procedimentos exploratórios diversos e análise fatorial confirmatória.
- **Passo 9 –** Análise de validade e de confiabilidade da escala: serve para confirmar que a escala gerada tem características de validade e de confiabilidade.
- **Passo 10 –** Desenvolvimento de normas e recomendações de uso e interpretação: objetiva apresentar as instruções de uso para os potenciais interessados na escala (Santos, 2014).

No próximo capítulo abordaremos os procedimentos de construção da escala, por meio da apresentação dos passos sugeridos por Costa (2011), além de apresentação dos conceitos das dimensões estudadas.

4 CONSTRUÇÃO DA ESCALA

O presente capítulo dedica-se à exposição e à análise dos dados coletados na pesquisa de campo. A apresentação dos resultados é segmentada de acordo com os dois processos de amostragem empregados. A primeira amostragem concerne na pesquisa entre alunos graduados e a segunda será implementada entre gestores. Antes de cada processo é realizado um detalhamento das análises descritivas e exploratórias.

4.1 PASSO 1 – ESPECIFICAÇÃO DO DOMÍNIO DO CONSTRUTO

Na especificação do construto, inicialmente foi realizada uma extensa revisão de literatura sobre letramento em dados, buscando identificar suas principais dimensões e competências. Esse esforço está materializado no capítulo 2. Conforme observado no item 2.3, a literatura apresenta algumas possibilidades de mensuração de *Data Literacy*. Entretanto, verificamos dois pontos centrais: o primeiro é de que o foco das escalas não engloba gestores universitários; e o segundo é de que são escalas extensas e com dimensões que, em certa medida se sobrepõem. No quadro abaixo segue a definição que utilizaremos para esta pesquisa em *Data literacy*.

Quadro 9 - Definição de *Data Literacy* utilizada nessa pesquisa

Autor	Definição
Ridsdale et al. (2015)	É a Habilidade de ler, analisar, argumentar com dados e comunicar insights, combinando conhecimentos estatísticos, tecnológicos e críticos.

Fonte: Elaboração própria

Ainda no passo 1 são descritas as competências que são esperadas de um gestor acadêmico no construto *Data literacy.*

Quadro 10 - Definição das competências

Competências	**Definição**
Competência estatística	É a capacidade de realizar análises a partir de gráficos, ter domínio de conceitos como média, mediana e desvio padrão, além de realizar aplicação de técnicas como, por exemplo, correlação e regressão.
Competência computacional	É a competência que viabiliza a aplicação prática da *data literacy* em um ambiente com grande volume de informações. O domínio de ferramentas como o Microsoft Excel permite a organização inicial de dados e análises descritivas, enquanto softwares mais avançados como *R, Python* ou *SPSS* são essenciais para executar análises estatísticas

	complexas, como a análise fatorial.
Competência de uso cotidiano	É a capacidade de analisar dados no uso cotidiano. No cotidiano da gestão, essa competência se traduz na habilidade de interpretar relatórios, identificar padrões em planilhas, compreender dashboards e tomar decisões com base em evidências extraídas de múltiplas fontes de dados estruturados e não estruturados.

Fonte: Elaboração própria

4.2 PASSO 2 – GERAÇÃO DE ITENS E VALIDAÇÃO DE FACE

Com base nesse levantamento teórico, foi elaborado um conjunto inicial de afirmativas relacionadas à capacidade de ler, interpretar, analisar e argumentar com dados. Cada item foi cuidadosamente redigido para ser claro, objetivo e unívoco, evitando-se jargões técnicos excessivos e ambiguidades (Costa, 2011).

A prospecção de itens considerou os trabalhos já desenvolvidos sobre a mensuração de *Data Literacy*, mas também outros estudos (e.g. Brito *et al*., 2022; Reznik *et al*., 2023) que abordavam a temática e que serviram de inspiração para a geração de itens pelo autor. Considerando que essa é uma etapa inicial, optamos por manter um mínimo de cinco itens por competência visando as etapas posteriores de limpeza de dados. Para tanto apresentamos o quadro 11, que expõe os itens da escala em estudo.

Quadro 11 - Quadro de itens da escala de *Data Literacy*

Competência	Item
Estatística	Entender o que são margens de erros em pesquisa eleitorais.
	Compreender o significado de índices econômicos (ex: Impacto da inflação no orçamento universitário).
	Interpretar o significado de gráficos (ex: evolução da evasão em um curso).
	Entender conteúdos envolvendo médias e proporções.
	Usar o gráfico correto ao exibir meus dados.
	Fazer pesquisas de dados estatísticos on-line (ex: pesquisa de clima organizacional).
	Defender uma ideia com dados estatísticos.
	Trabalhar em problemas envolvendo dados e estatísticas.
Computacional	Manusear dados em uma planilha eletrônica (como as do Excel).
	Utilizar painel de indicadores (*dashboard*) em computadores.
	Gerar gráficos digitais em programas específicos (ex: *Excel, Power BI*).
	Construir uma planilha a partir de dados da internet.
	Utilizar programas específicos para organizar dados.
Uso cotidiano	Usar informações quantitativas no meu cotidiano (ex: ao falar da quantidade de alunos por turma)
	Argumentar com base em dados e resultados numéricos (ex: percentuais...).
	Justificar uma decisão a partir de informação numérica (ex: mudar o PPC de um curso).
	Explicar a outra pessoa os resultados de uma análise de dados estatísticos.
	Identificar como os gestores tomam decisões baseadas em dados.
	Compreender as limitações de indicadores por má qualidade dos dados.

	Avaliar os riscos morais e legais do uso de dados (ex. dados de avaliação de docentes).
	Propor mudança de objetivos de trabalho com base em dados estatísticos preditivos.

Fonte: Elaboração própria

Após a definição dos itens, realizou-se, inicialmente, uma etapa de validação de conteúdo e face com dois doutores em administração. Posteriormente, uma nova etapa junto aos pesquisadores foi executada visando garantir uma maior aderência ao público da pesquisa. Já existiam estudos com itens disponíveis em língua estrangeira e que foram traduzidos e adaptados para a geração de itens. A análise dos resultados da validação de face e conteúdo não indicou a necessidade de exclusão de nenhum item.

4.3 PASSOS 3 E 4 – DECISÕES SOBRE AS RESPOSTAS E CONSTRUÇÃO DO INSTRUMENTO

Na definição da escala de verificação para mensuração dos itens, como o intuito era ter um rótulo atrelado, ela foi projetada no formato tipo *Likert* de 5 pontos para domínio de competências. Foram fixados 5 níveis de domínio, abaixo descritos: (1) Não consigo; (2) Consigo muito pouco; (3) Consigo pouco; (4) Consigo bem; e (5) Consigo muito bem. O instrumento foi assim estruturado no *Google Forms*.

Sobre o Passo 4, inicialmente, foi realizada uma extensa revisão de literatura sobre letramento em dados, buscando-se identificar suas principais dimensões e competências. Com base nesse levantamento teórico, foi elaborado um conjunto inicial de afirmativas relacionadas à capacidade de ler, interpretar, analisar e argumentar com dados. Cada item foi cuidadosamente redigido para ser claro, objetivo e unívoco, evitando-se jargões técnicos excessivos e ambiguidades. Ainda neste passo o instrumento de pesquisa foi elaborado com o conjunto de 21 itens.

Foram apresentadas 5 questões associadas à instituição, curso, horário de estudo, bem como sexo e idade. Em seguida, foram apresentados os itens das dimensões, estatística, computacional e uso cotidiano, separados em dois blocos para evitar potenciais erros de preenchimento. Além da apresentação das dimensões foram expostas as 2 escalas de um único item para mensurar os demais construtos da pesquisa, Foco e Perseverança. O questionário utilizado na primeira amostragem está apresentado no apêndice I.

4.4 PASSO 5 – PRIMEIRA AMOSTRAGEM

Para assegurar que os itens da escala eram pertinentes e representativos do construto de letramento em dados, o instrumento preliminar foi submetido a um estudo piloto com uma amostra reduzida de 167 alunos de graduação do Instituto Federal da Bahia (IFBA). A escolha desse público foi decorrente da facilidade de acesso a ele, bem como sua recorrência na utilização na etapa inicial de limpeza de itens em pesquisas como a que estamos desenvolvendo. O objetivo desta etapa foi verificar a consistência interna da escala, ou seja, o grau em que os itens apresentam aderência a cada dimensão.

A coleta de dados foi realizada nos dias 01 a 06 de julho de 2025. A aplicação se deu por aplicação mediante formulário do *Google Forms*. Além do formulário ser enviado por *e-mail,* foi disponibilizado via sistema SUAP (Sistema Unificado de Administração Pública) o link para participação dos alunos. A disponibilização no SUAP também foi de extrema importância, pois o discente sempre que entrasse no sistema teria o lembrete de participação na pesquisa. O acompanhamento foi realizado através do painel de respostas do *Google Forms*.

Para todas as análises fatoriais realizadas, utilizamos o método de extração dos componentes principais; e para o número de fatores, decidimos deixar sua definição pelos autovalores; e em relação à rotação, a opção foi pela rotação ortogonal a partir do método varimax.

4.5 PASSO 6 – PRIMEIROS PROCEDIMENTOS DE LIMPEZA DA ESCALA

A primeira etapa de amostragem teve como objetivo promover a depuração da escala, consistindo na aplicação de um conjunto de procedimentos exploratórios voltados à identificação e à eliminação de itens que apresentavam baixo ajuste ou inadequação à estrutura proposta.

4.5.1 Análise exploratória preliminar

Esta etapa envolveu um conjunto de procedimentos preparatórios aplicados à planilha e aos dados, conforme preconizado pelo modelo de Costa (2011). Nesta primeira atividade não houve erros de digitação por ser um questionário com dados do *Google Forms* e os campos de digitação livre não apresentaram erros. No banco de dados analisado não foram identificados indícios de equívocos tipo de anomalia que inviabilizasse a análise. No processo

de avaliação das entradas também foi verificado se algum respondente havia selecionado a mesma alternativa para todos os itens da escala.

Não houve *missing values* devido a coleta ter sido online, com respostas obrigatórias. Dos 167 respondentes 162 eram dados válidos por terem respostas completas. Foi estabelecido o critério, segundo Costa (2011), de que a exclusão de variáveis com mais de 10% de valores ausentes deveria ser excluída. Desse modo, com base nesse critério, nenhuma variável apresentou a necessidade de exclusão.

Após a análise de resposta única das entradas e da verificação de dados ausentes nas variáveis, procedeu-se à identificação de *outliers*. Para isso, as variáveis foram padronizadas em escores Z (média = 0; desvio-padrão = 1). Consideraram-se valores extremos aqueles com escores inferiores a -3 ou superiores a 3. De acordo com esse critério, não foram identificados *outliers* no conjunto de dados. Além disso, avaliou-se a variabilidade das respostas em cada variável, observando-se uma boa dispersão dos valores, o que indica que as variáveis apresentam amplitude adequada para os objetivos da pesquisa.

4.5.2 Descrição geral da amostra

Na tabela 1 apresentamos as características gerais da amostra. Na variável relacionada ao horário do curso, tivemos horários diversos, sendo 79,6% noturno, representando a maior parcela dos estudantes. Já o matutino ficou com 4,9%, 5,6% vespertino e 9,9% no turno integral, que representa manhã e tarde. Quanto ao sexo de nascimento dos respondentes a maioria esteve concentrada em 52,2% masculino contra 43,8% feminino, o que pode estar relacionado ao fato de cursos de tecnologia normalmente serem formado por maior número de homens do que de mulheres.

Tabela 1 - Características gerais da amostra

Horário do Curso		**Sexo de Nascimento**		**Atualmente, você está trabalhando?**	
Matutino	4,9%	Masculino	56,2%	Não, estou apenas estudando.	48,8%
Noturno	79,6%	Feminino	43,8%	Estou estagiando	12,3%

Vespertino	5,6%			Estou em emprego até 20h por semana	9,3%
Integral	9,9%			Estou em emprego de mais de 20h por semana	29,6%

Fonte: Dados da pesquisa (2025)

Ainda conforme a tabela 1, para a variável trabalho, a maioria dos respondentes (48,8%) afirmou não está trabalhando, resultado que pode estar relacionado ao fato de serem estudantes universitários. “Estou em emprego de mais de 20h por semana” foi o segundo maior resultado com (29,6%). A análise da amostra revelou ainda que parte dos respondentes estavam em alguma atividade remunerada. 12,3% encontram-se estagiando e 9,3% estão em emprego de até 20h semanais, que pode estar relacionado ao fato de a maioria dos respondentes estudarem no período noturno (79,6%).

4.5.3 Análise das variáveis das dimensões

Com o objetivo de facilitar a análise dos resultados da primeira amostragem da coleta de dados, os resultados foram organizados pelas dimensões. Na primeira parte, analisam-se as características da dimensão “Competência Estatística”; na segunda, da dimensão “Competência Computacional”; e, por fim, da dimensão “Competência de Uso cotidiano”.

4.5.3.1 Dimensão Competência Estatística

Para examinar as relações bivariadas entre os oito itens da escala, foi calculada uma matriz de correlação de Pearson (ver tabela 2). Os resultados indicaram que todas as associações entre os itens (EST01 a EST08) foram positivas e estatisticamente significativas ($p < 0,01$). As magnitudes dos coeficientes variaram de moderadas a fortes, situando-se entre $r = 0,436$ e $r = 0,810$. Observou-se a correlação de maior magnitude entre os itens EST03 e EST04 ($r = 0,810$), seguida pela associação entre EST07 e EST08 ($r = 0,794$).

A predominância de correlações elevadas, especificamente aquelas superiores a 0,70, sugere uma forte convergência entre os indicadores e aponta para uma provável alta consistência interna do construto avaliado.

Tabela 2 - Matriz de correlação das variáveis da dimensão competência estatística

	EST01	EST02	EST03	EST04	EST05	EST06	EST07	EST08
EST01	1	,624**	,709**	,638**	,554**	,494**	,515**	,436**
EST02		1	,569**	,528**	,514**	,513**	,536**	,535**
EST03			1	,810**	,771**	,647**	,630**	,625**
EST04				1	,780**	,615**	,617**	,695**
EST05					1	,783**	,665**	,714**
EST06						1	,740**	,716**
EST07							1	,794**
EST08								1

Nota: A correlação é significativa no nível 0,01 ($p < 0.01$)
Fonte: Dados da pesquisa (2025)

Ainda na avaliação, realizamos o teste de adequação da amostra com o teste de KMO (0,886) e de esfericidade de Bartlett, apresentando significância estatística (χ^2= 1059,89, gl=28) a p<0,001, sendo confirmada a adequação dos itens para da dimensão competência estatística para a análise fatorial.

A estrutura latente dos dados foi investigada por meio da Análise de Componentes Principais, por meio da qual se verificou uma convergência clara dos itens para um único domínio (autovalor > 1), apresentando um valor de 5,465, enquanto os demais componentes mostraram-se residuais.

O dado mais relevante, contudo, é a porcentagem de variância explicada: esse único fator é responsável por 68,308% da variabilidade das respostas. Esse resultado sugere que o instrumento possui solidez estatística e que os itens estão, de fato, mensurando um mesmo fenômeno subjacente, dispensando a necessidade de subdivisão em múltiplas dimensões.

A análise da estrutura interna da escala foi aprofundada por meio da inspeção da Matriz de Componentes. Os resultados demonstraram uma excelente qualidade psicométrica dos itens, uma vez que todas as variáveis apresentaram cargas fatoriais expressivas, situando-se muito acima do limiar mínimo recomendado de 0,40 (cf. Costa, 2011).

As cargas oscilaram entre **0,72** (para o item sobre índices econômicos) e **0,88** (para o item referente ao uso de gráficos), indicando que todas as questões contribuem significativamente para a definição do construto. Essa alta saturação dos itens no único componente extraído reforça a coesão interna do instrumento e confirma que todos os oito itens propostos são relevantes para mensurar a competência estatística pretendida, não havendo necessidade de exclusão de nenhuma variável. Os dados estão na Tabela 3.

Tabela 3 - Escores fatoriais dos itens da dimensão Competência Estatística

COD	**ITENS**	**Escore fatorial**

EST01	Entender o que são margens de erros em pesquisa eleitorais.	,744
EST02	Compreender o significado de índices econômicos (ex: Impacto da inflação no orçamento universitário).	,716
EST03	Interpretar o significado de gráficos (ex: evolução da evasão em um curso).	,875
EST04	Entender conteúdos envolvendo médias e proporções.	,865
EST05	Usar o gráfico correto ao exibir meus dados.	,883
EST06	Fazer pesquisas de dados estatísticos on-line (ex: pesquisa de clima organizacional).	,838
EST07	Defender uma ideia com dados estatísticos.	,835
EST08	Trabalhar em problemas envolvendo dados e estatísticas.	,840

Fonte: Dados da pesquisa (2025)

Para aferir a consistência interna da escala, calculou-se o coeficiente Alfa de Cronbach. A análise, baseada nos oito itens do instrumento, revelou uma correlação média de r = 0,635. Consequentemente, obteve-se um valor de Alfa de Cronbach de alpha = 0,932, o que denota um nível de confiabilidade excelente, superando amplamente os pontos de corte mínimos recomendados por Costa (2011) devendo ser > 0,700. Esses resultados confirmam a homogeneidade dos itens e a precisão do instrumento para a mensuração do construto proposto.

Assim, a estrutura interna e a confiabilidade do instrumento foram avaliadas por meio da Análise de Componentes Principais (ACP) e do coeficiente Alfa de Cronbach, respectivamente. A análise fatorial confirmou a unidimensionalidade da escala, retendo um único componente com autovalor de 5,47, capaz de explicar 68,31% da variância total. As cargas fatoriais revelaram-se robustas, oscilando entre 0,72 e 0,88, o que evidencia a forte aderência dos itens ao construto proposto. Dessa forma, a decisão foi de manter a versão integral da escala com seus oito itens originais.

4.5.3.2 Dimensão Competência Computacional

Preliminarmente à extração dos fatores, examinou-se a matriz de correlações entre os cinco itens que compõem a dimensão de Competência Computacional. A inspeção dos dados, conforme a Tabela 4, revelou a existência de associações positivas e estatisticamente significativas ($p < 0,01$) entre todos os pares de variáveis.

Os coeficientes de correlação oscilaram entre **0,50** e **0,76**, denotando uma conectividade robusta entre os itens. Destaca-se a forte associação entre as variáveis COMPU01 e COMPU04 (0,76), sugerindo uma coerência teórica subjacente.

A magnitude dessas correlações indica que a matriz é adequada para a fatoração, uma vez que os itens compartilham variância suficiente para a formação de um construto comum, sem apresentar problemas de multicolinearidade excessiva (valores > 0,90).

Tabela 4 - Correlação entre os itens da dimensão Competência Computacional

	COMPU01	COMPU02	COMPU03	COMPU04	COMPU05
COMPU01	1	,674**	,672**	,756**	,504**
COMPU02		1	,695**	,675**	,715**
COMPU03			1	,743**	,645**
COMPU04				1	,579**
COMPU05					1

Fonte: Dados da pesquisa (2025)

A adequação da amostra para a realização da Análise Fatorial Exploratória (AFE) foi verificada por meio do índice de Kaiser-Meyer-Olkin (KMO) e do Teste de Esfericidade de Bartlett. O valor de KMO obtido foi de **0,852**, o que classifica a adequação amostral como adequada segundo os parâmetros estabelecidos na literatura (Costa, 2011), indicando uma proporção substancial de variância comum entre os itens. Concomitantemente, o Teste de Esfericidade de Bartlett mostrou-se estatisticamente significativo ($X^2 = 536,69$; $p < 0,001$), rejeitando a hipótese de que a matriz de correlações seria uma matriz identidade. Esses indicadores, em conjunto, confirmam a fatorabilidade da matriz de dados e autorizam o prosseguimento da análise para a extração dos componentes.

Após a verificação da adequabilidade da amostra, procedeu-se à análise da variância total explicada para determinar o número de fatores a serem retidos. Adotando-se o critério de Kaiser (autovalores superiores a 1), a estrutura revelou-se estritamente unidimensional, com a extração de um único componente principal. Esse fator apresentou um autovalor inicial de **3,67** e demonstrou um poder explicativo notável, sendo responsável por **73,35%** da variância total dos dados. A disparidade entre o primeiro e o segundo autovalor (0,56) corrobora a decisão de manter a solução unifatorial, evidenciando que os itens de competência computacional convergem de forma robusta para um mesmo construto latente.

A validade da estrutura interna foi validada pela inspeção da Matriz de Componentes, que evidenciou uma saturação extremamente elevada de todos os itens no fator extraído, conforme a tabela 5.

As cargas fatoriais situaram-se em um patamar superior a **0,79**, oscilando entre **0,80** (para o uso de programas específicos) e **0,88** (para a construção de planilhas a partir de dados da web).

É notável a homogeneidade das cargas, especialmente entre os itens referentes ao uso de *dashboards* e à geração de gráficos digitais (ambos com 0,88), o que demonstra que todas as variáveis propostas possuem um peso equivalente e substancial na definição da competência computacional. A ausência de itens com cargas baixas ou ambíguas reforça a decisão de manter a escala em sua integralidade, atestando a solidez do modelo unifatorial.

Tabela 5 - Escores fatoriais dos itens da dimensão Competência computacional

COD	ITENS	Escore fatorial
COMPU01	Manusear dados em uma planilha eletrônica (como as do Excel).	,843
COMPU02	Utilizar painel de indicadores (dashboard) em computadores.	,879
COMPU03	Gerar gráficos digitais em programas específicos (ex: Excel, Power BI).	,879
COMPU04	Construir uma planilha a partir de dados da internet.	,880
COMPU05	Utilizar programas específicos para organizar dados.	,798

Fonte: Dados da pesquisa (2025)

Para ratificar a qualidade psicométrica da dimensão, avaliou-se a consistência interna por meio do coeficiente Alfa de Cronbach. A análise revelou um índice de precisão extremamente elevado, atingindo o valor de **0,908**. Esse resultado situa a confiabilidade da escala no patamar de **excelência** ($\alpha > 0,90$), superando amplamente os critérios mínimos exigidos pela literatura especializada. Tal coeficiente confirma que os cinco itens propostos possuem uma alta homogeneidade, comportando-se de maneira estável e consistente na mensuração da competência computacional, o que assegura a fidedignidade dos dados coletados para as inferências subsequentes.

4.5.3.3 Dimensão Competência Uso Cotidiano

Como etapa preliminar aos procedimentos de redução de dados, a matriz de correlações entre os oito itens da dimensão de Competência de Uso Cotidiano foi inspecionada. A análise evidenciou um padrão de interdependência robusto, com todas as variáveis apresentando correlações positivas e estatisticamente significativas ($p < 0,01$).

Os coeficientes de Pearson oscilaram entre **0,59** e **0,81**, indicando associações de média a forte magnitude. Destaca-se a elevada coerência entre os itens USO05 e USO06 (r = 0,81), que apresentaram a maior variância compartilhada.

Importante notar que, apesar das fortes associações, não foram observados valores indicativos de multicolinearidade excessiva (r > 0,90), o que sugere que cada item contribui com informação distinta para o construto, legitimando a aplicação da Análise Fatorial Exploratória.

Tabela 6 - Correlação entre os itens da dimensão Competência Uso cotidiano

	USO01	USO02	USO03	USO04	USO05	USO06	USO07	USO08
USO01	1	,782**	,718**	,693**	,665**	,654**	,587**	,631**
USO02		1	,806**	,782**	,694**	,700**	,666**	,673**
USO03			1	,793**	,711**	,725**	,678**	,687**
USO04				1	,784**	,740**	,687**	,645**
USO05					1	,813**	,703**	,742**
USO06						1	,726**	,709**
USO07							1	,730**
USO08								1

Fonte: Dados da pesquisa (2025)

A viabilidade da análise fatorial foi confirmada por meio dos testes de adequação amostral, que apresentaram os melhores indicadores entre todas as dimensões avaliadas até o momento.

O índice Kaiser-Meyer-Olkin (KMO) atingiu o valor de **0,93**, situando-se como muito adequada pela literatura psicométrica (Costa, 2011). Esse resultado denota uma variância comum extraordinária entre os itens.

O Teste de Esfericidade de Bartlett corroborou a fatorabilidade da matriz, rejeitando a hipótese nula com alta significância estatística (X^2 = 1190,75; p < 0,001). Diante dessa robustez, prosseguiu-se com a extração dos fatores.

A análise da variância total explicada ratificou a estrutura unidimensional sugerida pelos indicadores anteriores. A aplicação do critério de Kaiser resultou na extração de um único componente principal, que obteve um autovalor expressivo de **5,99**. Esse fator isolado demonstrou uma capacidade explicativa superior, retendo **74,81%** da variância total dos dados, confirmando que os oito itens de uso cotidiano convergem de forma coesa e predominante para um único construto.

A análise da Matriz de Componentes confirmou a solidez estrutural da dimensão, revelando cargas fatoriais de magnitude excepcional para todos os itens. As saturações

variaram em um intervalo estreito e elevado, situando-se entre **0,83** (para a avaliação de riscos morais e legais) e **0,89** (para a capacidade de explicar resultados estatísticos a terceiros).

É notável a homogeneidade das cargas, especialmente nos itens que envolvem tomada de decisão e argumentação — como 'justificar decisões' (0,886) e 'identificar decisões de gestores' (0,884) — que se mostraram centrais para a definição do fator. A ausência de cargas inferiores a 0,80 atesta que todas as variáveis propostas possuem um poder discriminativo muito forte e são imprescindíveis para a mensuração do construto, validando a manutenção da escala em sua integridade.

Tabela 7 - Escores fatoriais dos itens da dimensão Competência Uso cotidiano

COD	ITENS	Escore fatorial
USO01	Usar informações quantitativas no meu cotidiano (ex: ao falar da quantidade de alunos por turma)	,827
USO02	Argumentar com base em dados e resultados numéricos (ex: percentuais...).	,883
USO03	Justificar uma decisão a partir de informação numérica (ex: mudar o PPC de um curso).	,886
USO04	Explicar a outra pessoa os resultados de uma análise de dados estatísticos.	,887
USO05	Identificar como os gestores tomam decisões baseadas em dados.	,884
USO06	Compreender as limitações de indicadores por má qualidade dos dados.	,878
USO07	Avaliar os riscos morais e legais do uso de dados (ex. dados de avaliação de docentes).	,833
USO08	Propor mudança de objetivos de trabalho com base em dados estatísticos preditivos.	,839

Fonte: Dados da pesquisa (2025)

A avaliação da consistência interna consolidou os achados da análise fatorial, apresentando o indicador de confiabilidade mais elevado entre todas as dimensões investigadas. O coeficiente Alfa de Cronbach atingiu o valor de **0,952**, um índice que denota uma precisão psicométrica excepcional. Esse resultado situa a escala em um patamar de altíssima confiabilidade ($\alpha > 0,95$), indicando uma homogeneidade quase absoluta entre as respostas. Tal consistência assegura que os oito itens propostos não apenas mensuram o mesmo construto, mas o fazem com extrema estabilidade, minimizando a variância de erro e conferindo grande segurança às inferências estatísticas derivadas desta dimensão.

4.6 PASSO 7 – ATIVIDADE DE CAMPO ADICIONAIS

Neste segundo estudo a coleta de dados foi novamente realizada por meio de um instrumento *online* elaborado na ferramenta *Google Forms*, composto pelos itens da versão inicial da escala mais a três medidas do tipo *single-item,* uma por dimensão, para obtenção de avaliações globais, que foram utilizadas posteriormente na análise de validade convergente.

Esses três itens foram apresentados em escala de *phrase completion* (Silva Jr.; Costa, 2014) de 11 pontos e foram os seguintes: Competência Estatística – "*Seu conhecimento ESTATÍSTICO para trabalho com dados e indicadores é, no geral...* (de 0 – muito ruim a 10 – muito bom)"; Competência Estatística – "*No geral, seu conhecimento COMPUTACIONAL para trabalho com dados e indicadores é...* (de 0 – muito ruim a 10 – muito bom)"; Competência de uso: "*No geral, como é sua capacidade de trabalhar usando dados e indicadores no seu trabalho de gestão de forma?" (escala de 11 pontos, de 0 – muito ruim a 10 – muito bom)*".

O questionário também reuniu informações descritivas dos respondentes, como idade, sexo e região de residência. A divulgação do instrumento ocorreu por duas vias: (i) envio direto a gestores das IES de vínculo dos autores; e (ii) distribuição para uma amostra adicional de mais de 800 endereços de *e-mail* obtidos em páginas públicas de IES brasileiras. Essa estratégia ampliou o alcance da pesquisa e permitiu captar participantes de diferentes regiões e contextos institucionais.

Os dados foram coletados nos meses de outubro e novembro de 2025 e a amostra final contou com 203 respondentes com respostas válidas, todos exercendo função gerencial nas IES pesquisadas.

Quanto ao perfil sociodemográfico, observou-se equilíbrio entre os sexos, sendo 52,2% do sexo masculino e 47,8% do sexo feminino. A faixa etária predominante foi de 41 a 50 anos (37,9%), seguida por 31 a 40 anos (29,6%) e acima de 50 anos (30,5%), indicando um grupo composto majoritariamente por profissionais com experiência consolidada (apenas 2% possuíam até 30 anos).

No que se refere à formação acadêmica, a maior parte possuía doutorado (57,1%), seguido de mestrado (20,7%), especialização ou residência (16,7%) e graduação (5,4%), revelando uma amostra altamente qualificada. Em relação à grande área de formação, destacam-se as de Ciências Sociais Aplicadas (24,1%), Ciências Exatas e da Terra (20,7%) e Ciências Humanas (18,2%). A maioria dos respondentes informou possuir dedicação integral ao trabalho (84,7%).

Na extração de frequência das categorias de respostas dos itens da escala, observamos que, em mais da metade dos itens, a frequência da primeira categoria ('Não consigo') era menos que 5%, e apenas um dos 21 itens delas teve frequência acima de 15%. Nesses termos, optamos por recategorizar as opções resposta, reunindo a frequências das duas categorias mais baixas ('Não Consigo' e 'Consigo muito pouco').

4.7 PASSO 8 - PROCEDIMENTO ADICIONAIS DE LIMPEZA

Com a estrutura das dimensões devidamente estabelecida, na segunda amostragem, avançou-se para uma fase crítica de controle de qualidade dos dados: os procedimentos adicionais de limpeza da escala. Este passo não se trata apenas de uma formalidade estatística, mas de um esforço deliberado para elevar a precisão das inferências. A intenção aqui é submeter os dados a um escrutínio mais detalhado, verificando se há ruídos residuais ou anomalias que passaram pelos filtros iniciais. Ao realizar esse refinamento, buscamos assegurar que o instrumento final seja não apenas teoricamente coerente, mas também matematicamente robusto para suportar as conclusões da pesquisa.

4.7.1 Análise Fatorial Exploratória

Na extração fatorial (AFE), os testes de viabilidade foram todos favoráveis (Bartlett – qui-quadrado=3504.96, 210gl, p<0,001; KMO=0,95). O melhor modelo foi o de 3 fatores, com variância explicada de 75%.

A tabela 8 mostra apenas os valores com cargas fatoriais acima de 0,3. Por meio dos resultados, observamos que os itens ficaram retidos em seus respectivos fatores, reforçando a estrutura trifatorial para o Letramento em dados.

Tabela 8 - Escores fatoriais da segunda amostra

Códigos	Itens	Fatores		
		F1	F2	F3
EST1	Entender o que são margens de erros em pesquisa eleitorais.		0,70	
EST2	Compreender o significado de índices econômicos (ex: Impacto da inflação no orçamento universitário).		0,58	0,31
EST3	Interpretar o significado de gráficos (ex: evolução da evasão em um curso).	0,34	0,82	
EST4	Entender conteúdos envolvendo médias e proporções.		0,83	
EST5	Usar o gráfico correto ao exibir meus dados.		0,80	
EST6	Fazer pesquisas de dados estatísticos on-line (ex: pesquisa de clima organizacional).		0,71	0,36
EST7	Defender uma ideia com dados estatísticos.	0,38	0,67	0,31
EST8	Trabalhar em problemas envolvendo dados e estatísticas.		0,68	0,40
COMP1	Manusear dados em uma planilha eletrônica (como as do Excel).			0,80
COMP2	Utilizar painel de indicadores (dashboard) em computadores.			0,79
COMP3	Gerar gráficos digitais em programas específicos (ex: Excel, Power BI).		0,39	0,74

COMP4	Construir uma planilha a partir de dados da internet.	0,32	0,40	0,72
COMP5	Utilizar programas específicos para organizar dados.			0,73
USO1	Usar informações quantitativas no meu cotidiano (ex: ao falar da quantidade de alunos por turma)	0,73	0,31	
USO2	Argumentar com base em dados e resultados numéricos (ex: percentuais...).	0,78	0,36	
USO3	Justificar uma decisão a partir de informação numérica (ex: mudar o PPC de um curso).	0,77	0,35	
USO4	Explicar a outra pessoa os resultados de uma análise de dados estatísticos.	0,69	0,42	0,37
USO5	Identificar como os gestores tomam decisões baseadas em dados.	0,74	0,36	0,32
USO6	Compreender as limitações de indicadores por má qualidade dos dados.	0,76	0,42	
USO7	Avaliar os riscos morais e legais do uso de dados (ex. dados de avaliação de docentes).	0,80		
USO8	Propor mudança de objetivos de trabalho com base em dados estatísticos preditivos.	0,78		0,32

Fonte: Dados da pesquisa (2025)

4.7.2 Análise Fatorial Confirmatória

Realizamos a AFC seguido as indicações da literatura especializada (Costa, 2021, Hair et al., 2021), optamos pela extração por dimensão. O processo iterativo seguiu essa sequência: (1) extração fatorial inicial; (2) análise preliminar dos escores fatoriais e indicadores de ajuste; (3) exclusões de itens, se necessárias; (4) nova rodada de extração de medidas.

4.7.3 Construto 1 – Competência estatística

A calibração inicial do modelo, na primeira rodada da AFC, indicou problemas substanciais de ajuste, especialmente no valor elevado de χ^2/gl (acima de 6) e no RMSEA (acima de 0,15). Diante desse cenário, optou-se pela exclusão do item EST7, tanto por sua baixa contribuição ao modelo quanto por questões de coerência semântica. Na segunda rodada, contudo, a remoção do item não resultou em melhora significativa: os índices de ajuste permaneceram muito semelhantes e observou-se uma carga fatorial relativamente baixa para o item EST2, que então foi removido.

Mesmo após essa exclusão, o modelo ainda apresentava indicadores insatisfatórios. Prosseguindo no refinamento, identificou-se que o item EST6 apresentava o menor carregamento fatorial entre os remanescentes. Sua retirada produziu melhora expressiva, resultando em índices de ajuste considerados adequados.

Na rodada final, o modelo apresentou $\chi^2=7,82$, com 4 graus de liberdade ($p=0,094$), razão $\chi^2/gl=1,95$, além de valores elevados de ajuste incremental (CFI=0,993; TLI=0,982) e um RMSEA=0,069, dentro dos limites aceitáveis para modelos parcimoniosos.

4.7.4 Construto 2 – Competência Computacional

Esta dimensão passou por um processo de refinamento semelhante ao aplicado à dimensão anterior. Na primeira extração, os escores apresentaram desempenho insatisfatório, indicando necessidade de ajustes. Após a inspeção inicial, observou-se melhora nas cargas dos itens COMP 2 e COMP 5.

Analisando os conteúdos dos itens, observamos que COMP5 apresentava menor alinhamento conceitual com os demais indicadores da dimensão. Por essa razão, testou-se o modelo excluindo o item CC5, o que resultou em avanços significativos na qualidade do ajuste.

Com a exclusão desse item, o modelo apresentou indicadores robustos e dentro dos padrões de excelência, demonstrando boa adequação aos dados empíricos. A solução final mostrou χ^2=0,12, com 1 gl (p=0,732), razão χ^2/gl=0,12, além de índices incrementais perfeitos (CFI=1,000; TLI=1,000) e um RMSEA=0,05, valor considerado satisfatório para modelos parcimoniosos.

4.7.5 Construto 3 – Competência de Uso

Esta competência passou por um processo de refinamento mais extenso, em razão do desempenho insatisfatório apresentado na primeira rodada da AFC. Inicialmente, todos os indicadores exibiram índices inadequados de ajuste, o que demandou a revisão detalhada de cada item. A primeira modificação consistiu na exclusão do item USO6, cuja permanência prejudicava os índices globais do modelo; contudo, mesmo após sua retirada, as medidas de ajuste continuaram fora dos parâmetros desejáveis.

Na sequência, o item USO7 foi excluído devido à carga fatorial abaixo de 0,70. Após essas exclusões sequenciais, o modelo apresentou melhora significativa nos indicadores e a especificação final evidenciou χ^2=20,72, com 8 graus de liberdade (p=0,008), razão χ^2/gl=2,65, além de valores elevados de ajuste incremental (CFI=0,987; TLI=0,975) e um RMSEA=0,08, nível aceitável para modelos com maior complexidade estrutural.

De posse dos itens resultantes, que foram, como observados, de boa adequação psicométrica da AFC, procedemos então à TRI, detalhada abaixo.

4.7.6 Procedimento com a TRI e resultados consolidados

Na estimação dos parâmetros da TRI, utilizamos o método *Graded Response Model* (GRM), adequado a variáveis politômicas. Nesse procedimento são estimados um parâmetro de discriminação (a) e múltiplos parâmetros de dificuldade (b), correspondentes às transições entre categorias de resposta.

Como utilizamos quatro categorias ordenadas, foram estimados três parâmetros de dificuldade por item, conforme a lógica do modelo (Stanke; Bulut, 2019). As análises foram conduzidas no *software R*, utilizando-se o pacote *ltm* (Rizopoulos, 2006; 2022). Na análise, os itens foram considerados adequados quando apresentaram valores de discriminação acima de 0,50, sendo classificados como muito bons quando superiores a 1,00.

Para os parâmetros de dificuldade, adotamos como critério a ordenação crescente das categorias, pressuposto essencial da TRI politômica, além da expectativa de que os valores se situassem no intervalo de −3 a +3.

Os itens oriundos do procedimento da AFC foram então implementados, tendo-se observado, em todas as três extrações, medidas adequadas por itens, sinalizando, portanto, boa adequação dos itens para mensuração dos fatores latentes. Os achados das duas abordagens puderam ser integrados e consolidados e estão exibidos na tabela 9.

Tabela 9 - Medidas de ajuste

Var	Enunciado	Cargas (AFC)	Parâmetros estimados da TRI			
			a	b1	b2	B3
Dimensão de Competência Estatística χ^2=7,82, 4 gl, p-value=0,094; χ^2/gl=1,95; CFI=0,993; TLI=0,982; RMSEA=0,069						
EST1	Entender o que são margens de erros em pesquisa eleitorais.	0,73	2,73	-2,09	-1,35	-0,06
EST3	Interpretar o significado de gráficos (ex: evolução da evasão em um curso).	0,81	3,63	-2,56	-1,54	-0,34
EST4	Entender conteúdos envolvendo médias e proporções (ex. crescimento populacional).	0,89	4,76	-1,97	-1,18	-0,14
EST5	Usar o gráfico correto ao exibir meus dados.	0,70	2,70	-2,68	-1,09	0,19
EST8	Trabalhar em problemas envolvendo dados e estatísticas.	0,71	2,93	-1,45	-0,70	0,42
Dimensão Competência Computacional χ^2=0,12, 1 gl, p-value=0,732; χ^2/gl=0,12; CFI=1,000; TLI=1,000; RMSEA=0,05						
COM1	Manusear dados em uma planilha eletrônica (como	0,81	3,51	-1,7	-0,95	0,39

	as do Excel).					
COM2	Utilizar painel de indicadores (dashboard) em computadores.	0,76	2,29	-0,88	0,05	1,07
COM3	Gerar gráficos digitais em programas específicos (ex: Excel, Power BI).	0,85	3,89	-1,12	-0,30	0,84
COM4	Construir uma planilha a partir de dados da internet.	0,94	4,44	-1,19	-0,51	0,41
Dimensão de Competência de uso						
χ^2=20,72, 8 gl, p-value=0,01; χ^2/gl=2,65; CFI=0,987; TLI=0,975; RMSEA=0,08						
USO1	Usar informações quantitativas no meu cotidiano (ex: ao falar da quantidade de alunos por turma).	0,83	3,41	-2,33	-1,33	0,27
USO2	Argumentar com base em dados e resultados numéricos (ex: percentuais...).	0,90	4,55	-2,02	-1,31	0,22
USU3	Justificar uma decisão a partir de informação numérica (ex: mudar o PPC de um curso).	0,91	4,30	-1,88	-1,00	0,33
USO4	Explicar a outra pessoa os resultados de uma análise de dados estatísticos.	0,79	3,20	-1,95	-0,87	0,44
USO5	Identificar como os gestores tomam decisões baseadas em dados.	0,75	2,92	-1,82	-0,65	0,88
USO8	Propor mudança de objetivos de trabalho com base em dados estatísticos preditivos.	0,76	3,25	-1,41	-0,50	0,74

Fonte: dados da pesquisa (2025)

4.8 PASSO 9 - ANÁLISES DE VALIDADE E CONFIABILIDADE

A qualidade psicométrica final do modelo foi atestada por meio da análise conjunta dos índices de consistência interna e da matriz de variâncias (tabela 10). No que tange à confiabilidade, os coeficientes Alfa de Cronbach revelaram-se excepcionais para todas as dimensões latentes, variando de **0,90** (Competência Computacional) a **0,94** (Uso Cotidiano), superando amplamente os patamares mínimos recomendados pela literatura ($\alpha > 0,70$).

Paralelamente, a validade convergente foi confirmada pelos valores da Variância Média Extraída (AVE), dispostos na diagonal principal da matriz. Todas as dimensões apresentaram AVEs superiores a **0,60** (0,61, 0,69 e 0,68), indicando que as variáveis latentes explicam mais da metade da variância dos seus respectivos indicadores, demonstrando a capacidade dos itens em representar fidedignamente os construtos propostos.

A análise das variâncias compartilhadas (elementos fora da diagonal) permitiu compreender a dinâmica relacional entre as competências. Observou-se uma distinção clara da dimensão **Computacional**, que apresentou variâncias compartilhadas moderadas tanto com a Estatística (0,40) quanto com o Uso Cotidiano (0,39).

Por outro lado, a relação entre **Competência Estatística** e **Uso Cotidiano** revelou-se a mais intensa do modelo, com uma variância compartilhada de **0,66**. Esse dado sugere uma forte interdependência teórica, indicando que a capacidade de aplicar dados no cotidiano

(argumentação e decisão) está intrinsecamente ligada ao domínio dos conceitos estatísticos fundamentais, embora a dimensão Computacional opere como uma ferramenta de suporte mais independente no ecossistema de letramento de dados.

Tabela 10 - Matriz de variâncias (alpha de Cronbach)

Dimensões de Competência	Alpha de Cronbach	Matriz de variâncias extraída e compartilhada		
		Estatística	Computacional	Uso
Estatística	0,92	0,61		
Computacional	0,90	0,40	0,69	
Uso cotidiano	0,94	0,66	0,39	0,68

Fonte: dados da pesquisa (2025)

A operacionalização do construto de letramento de dados foi realizada por meio de uma matriz de competências dividida em três dimensões interdependentes, conforme detalhado no quadro 12. O instrumento foi estruturado para capturar a autopercepção dos participantes em diferentes níveis de complexidade, variando desde a compreensão passiva de conceitos até a aplicação ativa na tomada de decisão.

A primeira dimensão, Competência Estatística, foca no domínio conceitual e na literacia gráfica. Os itens foram elaborados para avaliar a capacidade de leitura do mundo através de números, sem necessariamente exigir a realização de cálculos matemáticos avançados.

Perguntas como 'Entender o que são margens de erro' ou 'Interpretar o significado de gráficos' buscam aferir se o sujeito possui o vocabulário estatístico necessário para consumir informações críticas, como pesquisas eleitorais ou indicadores educacionais (ex: evasão escolar).

A segunda dimensão, **Competência Computacional**, aborda o viés instrumental do letramento, reconhecendo que a manipulação de dados na atualidade é mediada por tecnologia, os itens investigam a proficiência técnica no uso de *softwares* essenciais. A escala abrange desde tarefas operacionais básicas, como *'Manusear dados em uma planilha eletrônica'*, até competências de visualização mais sofisticadas, como a criação de *'painéis de indicadores (dashboards)'* e a geração de gráficos digitais, refletindo a necessidade de traduzir dados brutos em informação visual.

Por fim, a dimensão de **Competência de Uso** representa a aplicação pragmática e

social dos dados. Esta seção avalia a capacidade do participante de integrar os dados à sua rotina profissional e argumentativa. Itens como *'Justificar uma decisão a partir de informação numérica'* e *'Argumentar com base em dados'* transcendem a técnica, focando na habilidade de utilizar a evidência estatística como ferramenta de persuasão, planejamento estratégico e mudança organizacional.

Quadro 12 - Itens das competências

Dimensões	**Itens:** ***Sobre as indicações seguir, indique em que NÍVEL você consegue realizar cada uma.***
Competência estatística	Entender o que são margens de erros em pesquisa eleitorais.
	Interpretar o significado de gráficos (ex: evolução da evasão em um curso).
	Entender conteúdos envolvendo médias e proporções (ex. crescimento populacional).
	Usar o gráfico correto ao exibir meus dados.
	Trabalhar em problemas envolvendo dados e estatísticas.
Competência computacional	Manusear dados em uma planilha eletrônica (como as do Excel).
	Utilizar painel de indicadores (dashboard) em computadores.
	Gerar gráficos digitais em programas específicos (ex: Excel, Power BI).
	Construir uma planilha a partir de dados da internet.
Competência de uso	Usar informações quantitativas no meu cotidiano (ex: ao falar da quantidade de alunos por turma).
	Argumentar com base em dados e resultados numéricos (ex: percentuais...).
	Justificar uma decisão a partir de informação numérica (ex: mudar o PPC de um curso).
	Explicar a outra pessoa os resultados de uma análise de dados estatísticos.
	Identificar como os gestores tomam decisões baseadas em dados.
	Propor mudança de objetivos de trabalho com base em dados estatísticos preditivos.

Fonte: dados da pesquisa (2025)

4.9 PASSO 10 – DESENVOLVIMENTO DE RECOMENDAÇÕES

Na tabela 11 podemos visualizar a categorização dos participantes em faixas de desempenho — Baixo (até 3,0), Moderado (3,0 a 4,0) e Elevado (acima de 4,0). Isso permitiu mapear as necessidades específicas de desenvolvimento para cada dimensão do letramento de dados.

A análise da **Competência Estatística** revela um perfil predominantemente intermediário. Com 59,1% da amostra situada no nível Moderado e apenas 2,0% no nível Baixo, nota-se que o grupo possui um domínio conceitual básico consolidado. O desafio gerencial, nesse caso, não é corretivo, mas evolutivo: as ações de desenvolvimento devem focar na transição desse amplo contingente mediano para o nível de excelência, aprofundando conceitos que permitam análises mais sofisticadas.

Em contraste, a **Competência Computacional** apresenta o cenário de maior heterogeneidade e polarização. Embora registre o maior percentual de excelência entre todas as dimensões (52,2% no nível Elevado), é também a área com a maior lacuna de proficiência, concentrando 12,3% dos participantes no nível Baixo — um índice significativamente superior ao das outras competências.

Esse dado sugere um 'abismo digital' interno: enquanto metade do grupo domina as ferramentas tecnológicas, uma parcela relevante ainda carece de instrumentalização básica, demandando treinamentos de nivelamento técnico (como uso de planilhas e *dashboards*) antes de se avançar para tópicos analíticos complexos.

Por fim, a dimensão de **Uso Cotidiano** demonstrou o equilíbrio mais positivo do diagnóstico. A amostra divide-se quase equitativamente entre os níveis Moderado (47,3%) e Elevado (48,3%), com uma taxa residual de apenas 4,4% no nível Baixo. Isso indica que, uma vez compreendidos os dados (Estatística) e operadas as ferramentas (Computacional), os participantes sentem-se seguros para aplicar esse conhecimento na tomada de decisão e na argumentação diária, validando a efetividade prática do letramento de dados no contexto organizacional investigado.

Tabela 11 - Uma opção de interpretação dos resultados

Faixa de média	**Nível de confiança**	**Percentual esperado**		
		Estatística	**Computacional**	**Uso**
Até 3,0	**Baixo**	**2,0**	**12,3**	**4,4**
Acima de 3,0 até 4,0		**59,1**	**35,5**	**47,3**
Acima de 4,0	**Moderado Elevado**	**38,9**	**52,2**	**48,3**

Fonte: Elaborado pelos autores

5 CONSIDERAÇÕES FINAIS

Neste capítulo foram apresentados os resultados deste estudo. Inicialmente foram apresentados todos os passos de construção da escala de literacia de dados dos gestores do

Instituto Federal da Bahia (IFBA), conforme modelo proposto por Costa (2011). Durante a construção da escala foram desenvolvidas análises dos construtos competência estatística, competência computacional e competência de uso cotidiano além dos procedimentos de limpeza da escala.

A análise psicométrica empreendida neste capítulo permitiu validar empiricamente a estrutura das dimensões propostas, demonstrando indicadores de robustez estatística excepcionais. A aplicação sequencial da Análise Fatorial Exploratória (AFE), precedida pela verificação dos pressupostos de análise fatorial (KMO e Bartlett), confirmou a unidimensionalidade de cada um dos construtos investigados — competência estatística, computacional e de uso cotidiano.

Em todas as análises observou-se uma variância explicada expressiva (superando o patamar de 68%) e cargas fatoriais consistentemente elevadas, o que atesta a validade interna do instrumento. Adicionalmente, os índices de confiabilidade, aferidos pelo Alfa de Cronbach, situaram-se invariavelmente no nível de excelência ($\alpha > 0,90$), garantindo que a escala possui a precisão necessária para mensurar os fenômenos propostos com estabilidade e baixo erro de medida.

Sob a ótica descritiva e substantiva, os resultados evidenciam que os participantes percebem essas competências de maneira integrada e coerente, não como habilidades fragmentadas. A forte correlação entre os itens, aliada a médias que denotam uma autoavaliação moderadamente positiva, sugere que o instrumento é sensível o suficiente para captar diferentes níveis de proficiência em letramento de dados.

A consistência dos achados entre as três dimensões reforça a tese de que a capacidade de interpretar estatísticas, manusear ferramentas computacionais e aplicar esses conhecimentos na tomada de decisão cotidiana compõem um conjunto de competências interligadas e mensuráveis, legitimando o uso da escala para diagnósticos acadêmicos e organizacionais.

5.1 RESULTADOS DOS OBJETIVOS DEFINIDOS

Os procedimentos de validação aplicados à segunda amostragem ratificaram a robustez psicométrica do instrumento, apresentando indicadores de confiabilidade e validade que corroboram a estrutura teórica proposta.

Uma distinção fundamental emerge ao comparar a estrutura fatorial proposta por esta

pesquisa com o modelo de Öz e Özdemir (2022). Enquanto a pesquisa estrutura sua escala em três dimensões de *competência* tangível — Estatística, Computacional e Uso Cotidiano Öz e Özdemir (2022) adotam uma abordagem eminentemente psicossocial para educadores, focada em *Autoeficácia*, *Experiência* e *Atitude.*

Convém notar que os achados da pesquisa desafiam, em parte, a premissa de que a "atitude" ou "autoeficácia" sejam construtos suficientes para o diagnóstico de *data literacy* em ambientes de gestão. Ao identificar uma correlação forte (0,66) entre a **Competência Estatística** e a **Competência de Uso Cotidiano,** para o gestor acadêmico, portanto, "achar importante" — algo que Carmichael *et al.* (2010) também identificam como fácil de endossar entre estudantes — não se traduz automaticamente em capacidade operacional sem o lastro estatístico.

Um ponto de diálogo robusto ocorre entre os achados da pesquisa e o estudo de Chung e Yoo (2022) sobre estudantes universitários. Chung e Yoo (2022) identificaram que, entre seis fatores de *data literacy*, a **Utilização de Ferramentas de Dados** apresentou as pontuações mais baixas e preocupantes. De forma análoga, esta pesquisa diagnosticou o que denominou de "abismo digital" na dimensão **Competência Computacional** entre os gestores: trata-se da área com maior heterogeneidade, concentrando simultaneamente o maior percentual de excelência (52,2%) e a maior lacuna de proficiência básica (12,3%)

Essa convergência sugere, preliminarmente, que a barreira instrumental (o domínio do software, da planilha, do *dashboard*) é um gargalo transversal, afetando tanto calouros na Coreia quanto gestores experientes. No entanto, a pesquisa avança ao demonstrar que a competência computacional opera com certa independência estatística em relação às outras dimensões (variância compartilhada moderada de 0,40 com Estatística).

Isso reforça a tese de Chung e Yoo (2022) de que a alfabetização de dados não pode ser tratada como um bloco só; a proficiência em ferramentas exige intervenções pedagógicas distintas daquelas voltadas para a análise crítica ou estatística.

Por fim, é essencial notar como a presente pesquisa responde à demanda por contextualização levantada por Öz e Özdemir (2022). Esses autores argumentam que a alfabetização de dados deve ser medida com ferramentas específicas para o público-alvo (educadores, no caso deles) para ter validade. Já esta pesquisa valida essa premissa ao rejeitar escalas genéricas e desenvolver itens específicos para a gestão (ex: "Impacto da inflação no orçamento universitário", "evolução da evasão").

5.2 LIMITAÇÕES DO ESTUDO E SUGESTÕES DE ESTUDOS FUTUROS

Como todo empreendimento científico, esta pesquisa possui fronteiras que delimitam o alcance de suas conclusões. A primeira limitação reside na natureza do desenho metodológico. Por se tratar de um estudo de corte transversal, capturamos uma 'fotografia' do momento atual das competências dos participantes, o que nos impede de estabelecer relações de causa e efeito definitivas ao longo do tempo.

Além disso, o uso de medidas de autoavaliação — inerente à aplicação de escalas psicométricas — traz consigo o risco do viés de desejabilidade social. É possível que, em alguns casos, a percepção dos respondentes sobre suas próprias competências (especialmente na dimensão computacional e de uso) seja ligeiramente superestimada em relação à sua proficiência real, influenciada pelo desejo de projetar uma imagem profissional positiva. Embora os rigorosos testes estatísticos tenham confirmado a consistência das respostas, a subjetividade da autoimagem é um fator que deve ser considerado na interpretação dos níveis de 'excelência' encontrados.

Por fim, a técnica de amostragem apresentada, embora adequada aos objetivos exploratórios deste estudo, requer cautela na generalização dos resultados para outros contextos profissionais ou grupos demográficos distintos daqueles aqui investigados.

As limitações aqui expostas, contudo, abrem caminhos férteis para novas investigações. Uma agenda de pesquisa futura poderia se beneficiar da aplicação de métodos mistos (qualitativos e quantitativos).

Seria enriquecedor complementar os dados estatísticos com entrevistas em profundidade ou grupos focais, buscando compreender *como* os sujeitos processam a tomada de decisão no cotidiano e quais barreiras específicas eles enfrentam ao tentar aplicar conceitos estatísticos em suas rotinas de trabalho.

Outra vertente promissora seria a realização de estudos. Pesquisas futuras poderiam avaliar a eficácia de intervenções educativas — como treinamentos focados nas lacunas computacionais identificadas neste estudo — medindo as competências antes e depois da capacitação. Isso permitiria verificar se o desenvolvimento da dimensão técnica (computacional) impulsiona diretamente a qualidade da dimensão aplicada (uso cotidiano).

Por fim, sugere-se a replicação deste instrumento em diferentes setores e níveis hierárquicos. Comparar o letramento de dados entre gestores e equipes operacionais, ou entre setor público e privado, poderia revelar nuances culturais importantes sobre como diferentes

ambientes organizacionais fomentam ou inibem o uso de dados para a tomada de decisão.

REFERÊNCIAS

ARRUDA, S. A. G. **Exploring *data literacy***: concepts and determinants for data skills development. 2020. Dissertação (Mestrado em Gestão). Universidade de Coimbra, 2020. Disponível em: https://hdl.handle.net/10316/94716. Acesso em: 19 maio 2025.

BARBOSA, M. A. C. et al. Escala de competências gerenciais para o setor público. *Cadernos EBAPE.BR*, Rio de Janeiro, v. 20, n. 2, p. 218-233, 2022.

BRASIL. **Decreto nº 9.235, de 15 de dezembro de 2017**. Dispõe sobre o exercício das funções de regulação, supervisão e avaliação das instituições de educação superior e dos cursos superiores de graduação e de pós-graduação no sistema federal de ensino. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2017/decreto/d9235.htm. Acesso em: 19 maio 2025.

BRASIL. **Lei nº 9.394, de 20 de dezembro de 1996**. Estabelece as diretrizes e bases da educação nacional. Disponível em: http://www.planalto.gov.br/ccivil_03/leis/l9394.htm. Acesso em: 28 abr. 2025.

BRASIL. **Lei nº 10.861, de 14 de abril de 200**4. Institui o Sistema Nacional de Avaliação da Educação Superior – SINAES. Disponível em: http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2004/lei/l10.861.htm. Acesso em: 28 abr. 2025.

BUSS, C.; SALM JUNIOR, J. F.; METZNER, F. S.; ROSA, D. D. A. Gestão de dados acadêmicos: a aplicação dos conceitos de governança de dados para melhoria nos processos de utilização das informações do sistema de gestão de dados acadêmicos. **Revista Ibero-Americana de Ciência da Informação**, v. 14, n. 2, p. 401–419, 18 maio 2021.

BRITO, L. S.; FRANÇA, J. B. S.; DIAS, A. F. S.; VIVACQUA, A. S. **Design de uma Escala para Avaliação de Literacia de Dados.** Anais do I Workshop Investigações em Interação Humano-Dados (WIDE 2022). Anais... *Em*: WORKSHOP INVESTIGAÇÕES EM INTERAÇÃO HUMANO-DADOS. Brasil: Sociedade Brasileira de Computação, 17 out. 2022. Disponível em: <https://sol.sbc.org.br/index.php/wide/article/view/22957>. Acesso em: 13 mar. 2025

CALZADA PRADO, Javier; MARZAL, Miguel Ángel. Incorporating data literacy into information literacy programs: core competencies and contents. **Libri**, v. 63, n. 2, p. 123-134, 2013.

COSTA, F. J. da. **Mensuração e desenvolvimento de escalas:** aplicações em Administração. Rio de Janeiro: Ciência Moderna, 2011.

DALMAU, M. B. L.; SILVA, C. S.; CANTO, J. P. A implementação do modelo de Gestão por Competências nas universidades federais brasileiras: caminhos percorridos e desafios enfrentados. *Revista Internacional de Educação Superior*, v. 9, p. e023020, 2023.

D'IGNAZIO, C.; BHARGAVA, R. Approaches to building big data literacy. *In*: **BLOOMBERG DATA FOR GOOD EXCHANGE.** New York, NY, USA, 2015. Disponível em: https://dam-prod2.media.mit.edu/x/2016/10/20/Edu_D%27Ignazio_52.pdf. Acesso em: 19 maio 2025.

D'IGNAZIO, C.; KLEIN, L. F. **Data Feminism**. [s.l.] The MIT Press, 2020. https://doi.org/10.7551/mitpress/11805.001.0001 Acesso em :18 de Junho de 2025

ECHTENBRUCK, M. M.; FÜHLES-UBACH, S.; NAUJOKS, B.; KALIVA, E. **A data literacy competence model for higher education and research**. 2025. Disponível em: https://arxiv.org/abs/2504.15690. Acesso em: 19 maio 2025.

FRADE, C. M.; COELHO, A. L. de A. L.; PESSOA, M. F.; MORAIS, L. A. de. Transição do papel de professor a professor-gestor: um estudo com coordenadores de cursos de pós-graduação de uma instituição federal de ensino superior. **Perspectivas Contemporâneas**, [S. l.], v. 19, n. 1, p. 1–19, 2024. DOI: 10.54372/pc.2024.v19.3619. Disponível em: https://revista2.grupointegrado.br/revista/index.php/perspectivascontemporaneas/article/view/3619. Acesso em: 19 maio. 2025.

GAMA, M. E. R.; SANTOS, J. T. D. L. Gestão na educação superior e as avaliações de suas práticas. **Avaliação:** Revista da Avaliação da Educação Superior (Campinas), v. 25, n. 2, p. 458–476, ago. 2020.

GHODOOSI, B.; TORRISI-STEELE, G.; WEST, T.; HEIDARI, M. Perceptions of data literacy and data literacy education. **Journal of Librarianship and Information Science**, 2024. DOI: https://doi.org/10.1177/09610006241246789. Disponível em: https://journals.sagepub.com/doi/epub/10.1177/09610006241246789. Acesso em: 19 maio 2025.

GUTIÉRREZ, M. Participação num ambiente datificado: questões sobre literacia de dados. **Comunicação e Sociedade**, v. 36, p. 37–55, 20 dez. 2019.

KANAN, L. A.; ZANELLI, J. C. Envolvimento de docentes-gestores com o trabalho no contexto universitário. **Psicologia & Sociedade**, v. 23, n. 1, p. 56–65, abr. 2011.

KIM, J.; HONG, L.; EVANS, S. Toward measuring data literacy for higher education: developing and validating a data literacy self-efficacy scale. **Journal of the Association for Information Science and Technology**, v. 75, n. 8, p. 916–931, 2024. DOI: https://doi.org/10.1002/asi.24934

MANDINACH, E. B.; SCHILDKAMP, K. Misconceptions about data-based decision making in education: An exploration of the literature. **Studies in Educational Evaluation**, v. 69, p. 100842, jun. 2021. DOI: https://doi.org/10.1016/j.stueduc.2020.100842

MARTÍN GONZÁLEZ, Y.; IGLESIAS RODRÍGUEZ, A. Alfabetización en datos: Diseño de un nuevo escenario formativo para el contexto universitario. **Revista Ibero-Americana de Ciência da Informação**, v. 14, n. 1, p. 318–330, 16 jan. 2021.

MORAIS, L. A. de; SILVA, A. P. da; SOUZA, M. C. de; OLIVEIRA, R. A. de. Transição do papel de professor a professor-gestor: um estudo com coordenadores de cursos de pós-graduação de uma instituição federal de ensino superior. **Perspectivas Contemporâneas**, [S. l.], v. 19, n. 1, p. 1–19, 2024. DOI: 10.54372/pc.2024.v19.3619. Disponível em: https://revista2.grupointegrado.br/revista/index.php/perspectivascontemporaneas/article/view/3619. Acesso em: 19 maio. 2025.

MOYO, M.; BANGANI, S. Data literacy training needs of researchers at South African universities. **Global Knowledge, Memory and Communication**, v. 74, n. 11, p.1–18, 2025. DOI: https://doi.org/10.1108/GKMC-02-2023-0041

REZNIK, R. I.; GIANNELLA, J. R.; KOSMINSKY, D. **Apontamentos sobre o ensino-aprendizado da literacia de dados para crianças no Brasil com o apoio do lúdico e da visualização de dados**. *In*: WORKSHOP INVESTIGAÇÕES EM INTERAÇÃO HUMANO-DADOS (WIDE), 2., 2023, Brasil. Anais [...]. Brasil: Sociedade Brasileira de Computação, 16 out. 2023. Disponível em: https://sol.sbc.org.br/index.php/wide/article/view/26868. Acesso em: 19 mar. 2025

RIDSDALE, C.; ROTHWELL, J.; SMIT, M.; ALI-HASSAN, H.; BLIEMEL, M.; IRVINE, D.; KELLEY, D.; MATWIN, S.; WUETHERICK , B. **Strategies and best practices for data literacy education**: knowledge synthesis report. 2015. Disponível em: http://hdl.handle.net/10222/64578. Acesso em: 19 maio 2025.

RODRIGUES DELBIANCO, N.; BARROS, S. T.; VIDOTTI, S. A. B. G.; CONEGLIAN, C. S. Alfabetização de dados no contexto da ciência da informação: análise dos cursos de graduação no Brasil. **Encontros Bibli:** Revista Eletrônica de Biblioteconomia e Ciência da Informação, v. 28, p. 1–19, 2023. DOI: 10.5007/1518-2924.2023.e94094. Disponível em: https://periodicos.ufsc.br/index.php/eb/article/view/94094. Acesso em: 20 maio. 2025.

SANTOS, J. C.; SORDI, M. R. L.; LOPES, A. C. O papel da coordenação de curso de graduação na conjuntura da educação como negócio. **Revista Eletrônica de Educação**, [S. l.], v. 18, n. 1, p. e432752, 2024. DOI: 10.14244/198271994327. Disponível em: https://reveduc.ufscar.br/index.php/reveduc/article/view/4327. Acesso em: 20 maio. 2025.

SANTOS, J. C. L. **Confiança dos cidadãos na gestão pública:** análise de antecedentes e proposta de uma escala de mensuração. Programa de Pós-Graduação em Administração. Universidade Federal da Paraíba, 2014. Mestrado em administração. Disponível em: https://repositorio.ufpb.br/. Acesso em 29 de fevereiro de 2025.

SOUZA ARAGÃO, J. E. de O.; ZUCCOLOTTO, P. A. D. G. L.; BOVÉRIO, M. A.; PEREIRA, V. T. Desafios do coordenador na gestão de cursos de graduação: um estudo comparativo em universidade pública e privada. **Revista de Gestão e Avaliação Educacional,** [S. l.], v. 1, n. 1, p. 1–16, 2019. DOI: 10.5902/2318133834412. Disponível em: https://periodicos.ufsm.br/regae/article/view/34412. Acesso em: 19 maio. 2025.

SHIELDS, M. Information Literacy, Statistical Literacy, Data Literacy. **IASSIST Quarterly**, v. 28, n. 2, p. 6, 16 ago. 2005.

TAŞ, E. Data literacy education through university-industry collaboration. **Information and**

Learning Sciences, v. 125, n. 5/6, p. 389–405, 2024. https://doi.org/10.1108/ILS-06-2023-0077

MANDINACH, E.; GUMMER, E. (2016). What does it mean for teachers to be data literate: Laying out the skills, knowledge, and dispositions. **Teaching and Teacher Education.** 60. https://doi.org/10.1016/j.tate.2016.07.011.

CHUNG, Y.; YOU, J. W. Validation of Data Literacy Scale for University Students and Analysis of Freshmen Data Literacy－The Case of A University. **The Korean Association of General Education**, v. 16, n. 5, p. 245–260, 31 out. 2022. https://doi.org/10.46392/kjge.2022.16.5.245. Acesso em 18 de julho de 2025

ÖZ, S.; ÖZDEMİR, A. Validity and Reliability Study on The Development of Data Literacy Scale for Educators. **International Journal of Contemporary Educational Research**, v. 9, n. 3, p. 649–661, 30 out. 2022. https://doi.org/10.33200/ijcer.1079774 Acesso em 18 de julho de 2025.

WOLFF, Annika et al. Creating an understanding of data literacy for a data-driven society. **The Journal of Community Informatics**, v. 12, n. 3, p. 9-26, 2016.

APÊNDICE I

QUESTIONÁRIO

1. Em qual instituição de ensino você estuda? _____

2. Qual o seu curso: _____

3. Qual o horário de seu curso?
[ ] Matutino (manhã) [ ] Vespertino (tarde)
[ ] Noturno [ ] Integral (manhã e tarde)

4. Por favor, indique seu sexo de nascimento.
[ ] Masculino [ ] Feminino

5. Qual sua idade (em anos)? _____

6. De 0 (nível baixo) a 10 (nível alto), aponte o quanto você consegue manter o foco em objetivos que demandam esforço contínuo e muito tempo para realizar.

Nível baixo	0	1	2	3	4	5	6	7	8	9	10	Nível alto

7. A seguir temos uma série de afirmações e pedimos que você reflita e indique em que nível você consegue realizar cada uma.

1. Não Consigo	2. Consigo muito pouco	3. Consigo pouco	4. Consigo bem	5. Consigo muito bem

Situação	Quanto consegue realizar				
Entender o que são margens de erros em pesquisa eleitorais.	1	2	3	4	5
Compreender o significado de índices econômicos (ex: Impacto da inflação no orçamento universitário).	1	2	3	4	5
Interpretar o significado de gráficos (ex: evolução da evasão em um curso).	1	2	3	4	5
Entender conteúdos envolvendo médias e proporções.	1	2	3	4	5
Usar o gráfico correto ao exibir meus dados.	1	2	3	4	5
Fazer pesquisas de dados estatísticos on-line (ex: pesquisa de clima organizacional).	1	2	3	4	5
Defender uma ideia com dados estatísticos.	1	2	3	4	5
Trabalhar em problemas envolvendo dados e estatísticas.	1	2	3	4	5

8. A seguir temos uma série de afirmações e pedimos que você reflita e indique em que nível você consegue realizar cada uma.

1. Não Consigo	2. Consigo muito pouco	3. Consigo pouco	4. Consigo bem	5. Consigo muito bem

Situação	Quanto consegue realizar

Manusear dados em uma planilha eletrônica (como as do Excel).	1	2	3	4	5
Utilizar painel de indicadores (dashboard) em computadores.	1	2	3	4	5
Gerar gráficos digitais em programas específicos (ex: Excel, Power BI).	1	2	3	4	5
Construir uma planilha a partir de dados da internet.	1	2	3	4	5
Utilizar programas específicos para organizar dados.	1	2	3	4	5

9. De 0 (nível baixo) a 10 (nível alto), aponte o quanto você é perseverante para alcançar seus objetivos pessoais.

Nível baixo	0	1	2	3	4	5	6	7	8	9	10	Nível alto

10. *A seguir temos uma série de afirmações e pedimos que você reflita e indique em que nível você consegue realizar cada uma.*

1. Não Consigo	2. Consigo muito pouco	3. Consigo pouco	4. Consigo bem	5. Consigo muito bem

Situação	Quanto consegue realizar				
Usar informações quantitativas no meu cotidiano (ex: ao falar da quantidade de alunos por turma)	1	2	3	4	5
Argumentar com base em dados e resultados numéricos (ex: percentuais...).	1	2	3	4	5
Justificar uma decisão a partir de informação numérica (ex: mudar o PPC de um curso).	1	2	3	4	5
Explicar a outra pessoa os resultados de uma análise de dados estatísticos.	1	2	3	4	5
Identificar como os gestores tomam decisões baseadas em dados.	1	2	3	4	5
Compreender as limitações de indicadores por má qualidade dos dados.	1	2	3	4	5
Avaliar os riscos morais e legais do uso de dados (ex. dados de avaliação de docentes).	1	2	3	4	5
Propor mudança de objetivos de trabalho com base em dados estatísticos preditivos.	1	2	3	4	5