

**ÁREA TEMÁTICA: TECNOLOGIA, INTELIGÊNCIA ARTIFICIAL E
TRANSFORMAÇÃO DIGITAL EM ADMINISTRAÇÃO**

**INÉRCIA, VIÉS COGNITIVO E A BOLA-DE-NEVE INVISÍVEL: UM ENSAIO
TEÓRICO SOBRE A DÍVIDA DE DADOS NAS ORGANIZAÇÕES**

Resumo

Este artigo investiga por que a dívida de dados persiste nas organizações, mesmo quando seus custos são conhecidos. Partindo da transformação digital como reposicionamento estratégico dos dados, o artigo articula uma explicação multinível ancorada no viés do status quo (nível individual) e na inércia organizacional (nível estrutural). O artigo propõe um modelo conceitual que integra mecanismos cognitivos (aversão à perda, custos de transição, custos irrecuperáveis, incerteza e arrependimento antecipado) e dimensões de inércia (insight, ação, psicológica, estrutural e econômica) para explicar a formação de um ciclo cumulativo — o “efeito bola-de-neve” — que alimenta o acúmulo de dívida de dados. Do modelo proposto derivam proposições testáveis em que a dívida de dados atua como mediadora, elevando custos operacionais com reconciliação e saneamento, ampliando riscos regulatórios por falhas de rastreabilidade e reduzindo a capacidade analítica necessária para gerar valor de negócio. Em termos práticos, o artigo oferece diretrizes para priorização de intervenções que combinem governança de dados, literacia e reconfigurações organizacionais; em termos acadêmicos, avança a agenda ao deslocar o debate de soluções exclusivamente técnicas para uma explicação sociotécnica do fenômeno. Por fim, o artigo sugere caminhos de pesquisa com métodos mistos para mensurar simultaneamente percepções individuais e rigidezes institucionais, bem como avaliar efeitos em desempenho, agilidade e conformidade.

Palavras-chave: dívida de dados; viés do status quo; inércia organizacional; governança de dados.

Abstract

This theoretical essay explains why data debt persists despite widespread awareness of its costs. Viewing digital transformation as the strategic primacy of data, we advance a multilevel account that combines status quo bias (individual level) and organizational inertia (structural level). We propose a conceptual model integrating cognitive mechanisms (loss aversion, switching costs, sunk costs, uncertainty, and anticipated regret) with inertia dimensions (insight, action, psychological, structural, and economic) to explain a cumulative “snowball effect” that drives data-debt accumulation. From this model we derive testable propositions in which data debt acts as a mediator that increases operational costs for data cleaning and reconciliation, heightens regulatory risks due to weak traceability, and diminishes analytic capability required to convert data into business value. Practically, the study offers guidance to prioritize interventions that combine data governance, data literacy, and organizational (re)design; academically, it shifts the debate from purely technical remedies to a sociotechnical explanation of the phenomenon. We outline mixed-methods research avenues to jointly assess individual perceptions and institutional rigidities and to evaluate impacts on performance, agility, and compliance.

Keywords: data debt; status quo bias; organizational inertia; data governance.

1. INTRODUÇÃO

1.1 Problema e Objetivo de Pesquisa

A transformação digital recolocou os recursos digitais — especialmente os dados — no centro da estratégia organizacional, exigindo a reconfiguração de processos, estruturas e talentos em torno deles (Piccoli; Grover; Rodriguez, 2024). Pressionadas por prazos curtos e pela inovação contínua, equipes de TI assumem compromissos de curto prazo que geram dívidas técnicas (Cunningham, 1992) e, por analogia, dívidas de dados, entendidas como passivos resultantes de decisões subótimas na gestão de dados, cujos “juros” aparecem na forma de retrabalho, falhas analíticas e riscos regulatórios (Ambler, 2022).

Embora já exista literatura técnica que descreve antecedentes e consequências desse passivo (Butters; Wilson; Burton, 2020; Ruissalo; Rinta-Kahila; Penttinen, 2025), permanece a questão central: por que as organizações toleram, e frequentemente reproduzem tal passivo, mesmo cientes de seus custos?

Cabe destacar que ainda são escassos os estudos que exploram os mecanismos comportamentais e estruturais que sustentam esse passivo (Nielsen; Madsen; Lungu, 2020; Bogner; Verdecchia; Gerostathopoulos, 2021; Mäki; Penttinen; Rinta-Kahila, 2023).

Nesse contexto, este ensaio defende a tese de que *“a dívida de dados não é apenas técnica, mas consequência de fatores psicológicos e estruturais que influenciam o comportamento decisório e a adaptabilidade organizacional”*. Para examiná-la, mobiliza-se uma perspectiva multinível — individual e institucional — ancorada no viés do status quo (Samuelson; Zeckhauser, 1988) e na inércia organizacional (Hannan; Freeman, 1984). O objetivo geral deste trabalho é desenvolver um modelo conceitual que explique como esses dois mecanismos perpetuam práticas inadequadas de gestão de dados, orientando a formulação de proposições testáveis.

1.2 Justificativa e Contribuições Esperadas

Contribuição Acadêmica: O estudo busca preencher a lacuna teórica identificada por Nielsen et al. (2020) ao articular variáveis cognitivas e estruturais em um modelo integrado, ampliando o debate além de soluções técnicas.

Contribuição Gerencial: Ao evidenciar como pressões por time-to-market, déficits de literacia em dados e governança fragmentada convergem para a perpetuação da dívida de dados (Sigma Software, 2024), o estudo busca oferecer diretrizes para priorizar intervenções que reduzam custos operacionais e riscos regulatórios.

Contribuição Metodológica: Ao propor um framework multinível que combina lentes das ciências comportamentais e organizacionais; esse arcabouço pode ser aplicado em estudos de campo que utilizem métodos mistos para mensurar tanto percepções individuais quanto rigidezes institucionais.

Impacto Social: Ao incentivar práticas de curadoria alinhadas aos princípios FAIR (Go FAIR, 2023), o modelo contribui para maior transparência e reuso de dados, favorecendo inovações em serviços públicos, saúde e finanças que dependem de dados confiáveis.

Em síntese, o trabalho visa explicar por que a dívida de dados persiste, oferecer bases para intervenções práticas e estabelecer um panorama de pesquisa que conecte fatores humanos e estruturais ao desempenho organizacional em ambientes orientados por dados.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Dívida Tecnológica e Dívida de Dados

O conceito de *technical debt*, ou dívida técnica (tradução nossa), descreve os compromissos futuros criados por decisões de curto prazo em engenharia de software (Cunningham, 1992). Em ambientes de dados, atalhos semelhantes, como adiar modelagem semântica, ignorar princípios FAIR ou manter *pipelines* ad-hoc, geram a chamada *data debt*, ou dívida de dados (tradução nossa): um passivo que deprecia gradualmente o valor informacional (Butters; Wilson; Burton, 2020) e eleva custos de integração, reduz a confiança analítica e dificulta iniciativas de IA (Knudsen, 2018).

Esse passivo emerge, sobretudo, quando pressões de *time-to-market* encontram déficits de literacia analítica e governança fragmentada. A adoção de soluções mínimas viáveis, a dispersão de responsabilidades sobre dados e os sistemas legados heterogêneos reforçam inconsistências, silos e postergações de saneamento (Otto, 2011; Tallon; Ramirez; Short, 2013; Ambler, 2023). Assim, práticas essenciais de modelagem, documentação e curadoria são sacrificadas, perpetuando um estoque invisível de dívida (Giannini; Ziffer; Della Valle, 2023; Borgman et al., 2018).

As consequências extrapolam o domínio técnico. Dados inconsistentes inflacionam esforços de reconciliação e retrabalho (Redman, 2018), propagam vieses em modelos de IA (Hahn; Sales, 2025) e ampliam o risco regulatório quando faltam trilhas de auditoria exigidas por GDPR e LGPD (Rhahla; Allegue; Abdellatif, 2021). Além disso, ao minar a capacidade analítica — entendida como a orquestração de gestão, tecnologia e pessoas para converter dados em vantagem competitiva (Davenport; Harris, 2018; Wang et al., 2024) — a dívida de dados transforma-se de problema técnico em questão central de resiliência e agilidade estratégicas.

2.2 Lentes teóricas propostas

Apesar de se conhecerem os fatores técnicos, ainda se questiona por que as organizações deixam a dívida de dados crescer. A resposta exige considerar, além dos aspectos técnicos, influências comportamentais e estruturais que escapam mesmo à Governança de Dados (GD) — aqui entendida como o arranjo de papéis, políticas e mecanismos que tratam dados como ativos (Khatri; Brown, 2010).

Nível individual – Viés do Status Quo (VSQ). Segundo Samuelson e Zeckhauser (1988), decisores superestimam riscos de mudança e subestimam benefícios, preferindo fluxos já dominados. Kim e Kankanhalli (2009) mostram que, quanto maior o risco percebido na migração, maior a resistência.

Nível organizacional – Inércia Organizacional. Estruturas e rotinas criam um “peso” que dificulta adaptações (Hannan; Freeman, 1984). Moradi et al. (2021) distinguem cinco dimensões de inércia — insight, ação, psicológica, estrutural e econômica. Contratos que mantêm bases legadas ilustram o problema: quanto mais tempo um

sistema vigora, mais processos se moldam a ele e mais custosa parece a mudança (Polites; Karahanna, 2012).

A interação entre VSQ e inércia explica por que princípios FAIR e automação de *data lineage* avançam lentamente mesmo em empresas “data-driven”.

2.3 Viés do Status Quo

O Viés do Status Quo (VSQ) é a preferência sistemática por manter o estado atual, mesmo diante de alternativas superiores (Samuelson; Zeckhauser, 1988). Em gestão de dados, manifesta-se na aversão a migrar esquemas legados, no temor de *downtime* e na supervalorização dos custos de aprendizagem, alimentando a dívida. Revisão em Sistemas de Informação de Nugawela e Sedera (2022) confirma o VSQ como barreira à adoção de novas plataformas e práticas de governança.

O VSQ descreve a tendência de preferir o arranjo vigente mesmo diante de alternativas superiores (Samuelson; Zeckhauser, 1988). Em Sistemas de Informação, isso se manifesta na manutenção de bases legadas e processos consolidados, pois exigem menor esforço cognitivo e preservam legitimidade (Kim; Kankanhalli, 2009). A literatura mapeia cinco variáveis que sustentam essa preferência:

Custos de transição: gastos financeiros, relacionais e psicológicos associados à troca de sistemas aumentam a dependência tecnológica (Burnham; Frels; Mahajan, 2003; Klemperer, 1995).

Aversão à perda: perdas esperadas pesam mais do que ganhos equivalentes, levando gestores a superestimar riscos de substituição de sistemas (Kahneman; Tversky, 1979; Cenfetelli, 2004).

Custos irrecuperáveis: investimentos já realizados ancoram decisões futuras, mesmo diante de resultados insatisfatórios (Staw, 1976; Arkes; Blumer, 1985; Keil; Mann; Rai, 2000).

Incerteza percebida: ambiguidades tecnológicas e regulatórias valorizam opções “seguras”, reforçando a paralisia decisória (Fichman, 1992; Benaroch; Lichtenstein; Robinson, 2006).

Arrependimento antecipado: o temor de errar eleva a propensão a manter o sistema atual (Zeelenberg, 1999; Kim; Chan; Kankanhalli, 2012).

Esses fatores combinam pressões cognitivas, emocionais e econômicas que favorecem arquiteturas estáticas e, consequentemente, o acúmulo de dívida de dados.

2.4 Inércia Organizacional

Hannan e Freeman (1984) definem inércia organizacional (IO) como a rigidez estrutural que limita respostas rápidas ao ambiente. Singh e Lumsden (1990) ampliaram o conceito, mostrando por que padrões permanecem mesmo sob forte pressão externa. Estudos recentes detalham cinco dimensões de inércia que impactam diretamente a gestão de dados (Godkin; Allcorn, 2008; Moradi et al., 2021):

Inércia de insight: falhas de percepção impedem a organização de reconhecer sinais de mudança, perpetuando modelos mentais obsoletos (March; Olsen, 1975; Schein, 2022).

Inércia psicológica: medo de perder relacionamentos ou competências gera resistência emocional à mudança (Huang et al., 2012).

Inércia de ação: demora na execução mesmo após identificar a necessidade de mudança; supera-se com mobilização de agência em transformações digitais (Hedberg; Ericson, 1997; Kaganer; Gregory; Sarker, 2023).

Inércia estrutural: a complexidade e interdependência de processos e sistemas torna alterações custosas e lentas (Tushman; O'Reilly, 1996; Haskamp et al., 2021).

Inércia econômica: compromissos orçamentários e contratos de longo prazo incentivam a manutenção de *data warehouses* legados, ampliando o passivo de dados (Besson; Rowe, 2012).

A interação dessas dimensões incentiva “*quick fixes*”, postergando o saneamento e reforçando a dívida de dados.

2.5 Convergência das Lentes Teóricas no Fenômeno da Dívida de Dados

A evolução conceitual das teorias indica que tanto VSQ quanto IO migraram de domínios gerais como finanças e ecologia organizacional para aplicações digitais. Na fase mais recente, ambos convergem sobre ativos de dados, oferecendo lentes complementares, onde o VSQ captura barreiras cognitivo-comportamentais e a IO revela barreiras estruturais e processuais.

Complementarmente, o reconhecimento das terminologias específicas de dívida (*curation, quality, analytics*) permite mapear quais dimensões de VSQ/IO são mais críticas a cada tipo de passivo.

Enquanto o viés do status quo opera no nível micro, influenciando percepções individuais sobre risco e esforço, a inércia organizacional atua no nível macro, influenciando estruturas, rotinas e alocações de recursos. Em conjunto, elas explicam:

Persistência do passivo: mesmo após incidentes que expõem dados defeituosos, decisões tendem a restaurar o sistema pré-crise em vez de redesenhar o processo (VSQ + inércia de ação).

Efeito bola de neve: atrasos cumulativos tornam a remediação progressivamente mais cara, retroalimentando a aversão a mudanças (exemplo: custos irrecuperáveis + inércia econômica).

Falsa sensação de segurança: ausência de métricas visíveis reduz a percepção de urgência (inércia de insight), reforçando o status quo.

Esta sinergia teórica fornece a base para derivar as proposições causais, apresentadas no próximo tópico, bem como um modelo conceitual que integra variáveis dos dois domínios para explicar o acúmulo e os impactos da dívida de dados.

3 PROPOSIÇÕES E MODELO CONCEITUAL

O modelo conceitual integra forças comportamentais ligadas ao viés do status quo e dimensões da inércia organizacional. Juntas, elas explicam por que a dívida de dados (DD) se acumula e, como construto mediador, eleva o custo operacional de dados (COD), fragiliza a capacidade analítica (CA) e amplia o risco regulatório (RR).

P1 – Custos de transição: quanto maiores os custos financeiros, relacionais ou psicológicos de migração (Thatcher; Oliver, 2001), maior a tendência de preservar sistemas legados cheios de inconsistências, aprofundando o passivo de dados.

P2+P3 – Aversão à perda e arrependimento antecipado: perdas percebidas pesam mais que ganhos equivalentes (Kahneman; Tversky, 1979). Para evitar o risco de “erro”, gestores subinvestem em governança, perpetuando a DD.

P4 – Custos irrecuperáveis e escalonamento de compromisso: altos desembolsos já realizados em licenças e customizações ancoram decisões futuras (Staw, 1976), levando à manutenção de bases ineficientes mesmo diante de baixo desempenho.

P5 – Incerteza e adiamento: quando o retorno de projetos de saneamento de dados é ambíguo (Fichman, 1992), prevalece a estratégia de esperar, permitindo que problemas de qualidade cresçam silenciosamente.

P6 – Inércia estrutural: a complexa interconexão de subsistemas eleva o custo da inovação (Tushman; O'Reilly, 1996). Integrar metadados ou novas camadas de governança exige reconfigurações amplas, frequentemente adiadas.

P7 – Inércia de insight: bloqueios cognitivos reduzem a sensibilidade a falhas em dados (Hedberg; Wolff, 2001); sem auditoria eficaz, conjuntos degradados continuam em uso.

P8 – Inércia de ação: burocracias e dispersão de responsabilidades fazem com que iniciativas de saneamento sejam reiteradamente postergadas, apesar de riscos reconhecidos (Godkin; Allcorn, 2008).

P9 – Inércia econômica: para amortizar investimentos antigos, organizações evitam novas plataformas mais flexíveis (Besson; Rowe, 2012), comprometendo o desempenho analítico futuro.

P10 – Inércia psicológica: práticas obsoletas persistem porque oferecem sensação de controle e reforçam identidades profissionais (Huang et al., 2013).

P11 – Efeito bola de neve (VSQ + IO): a interação entre o viés do status quo e a inércia organizacional gera um efeito bola de neve que intensifica o acúmulo da dívida de dados

A combinação entre fatores comportamentais e estruturais cria um ciclo cumulativo que favorece a persistência e o agravamento da dívida de dados. O viés do status quo leva os decisores a superestimar riscos e custos da mudança, optando por manter sistemas e práticas obsoletas (Samuelson; Zeckhauser, 1988; Kim; Kankanhalli, 2009). Em paralelo, as diversas manifestações da inércia organizacional — como rigidez estrutural, bloqueios cognitivos e restrições orçamentárias — dificultam a execução de intervenções corretivas (Hannan; Freeman, 1984; Moradi et al., 2021).

Essa convergência reforça a postergação de mudanças, permitindo que falhas se acumulem e aumentem o custo de remediação futura. A cada adiamento, os problemas se tornam mais complexos, gerando um efeito bola de neve que amplia exponencialmente a dívida de dados ao longo do tempo. Na figura 1 é representado o efeito “bola de neve” descrito na proposição 11.

Figura 1 – Efeito bola de neve da interação VSQ x IO



Fonte: Elaborado pelo autor (2025).

P12a – Custos operacionais: o acúmulo de dívida de dados eleva despesas com limpeza, reconciliação e validação, pois inconsistências obrigam a refazer continuamente tarefas de manutenção. Conforme Butters, Wilson e Burton (2020), esse ciclo de correções aumenta gastos com mão de obra e infraestrutura, drenando recursos que poderiam financiar iniciativas de inovação.


P12b – Riscos regulatórios: ambientes com elevada dívida de dados carecem de governança e rastreabilidade, dificultando a conformidade com LGPD e GDPR. A ausência de trilhas de auditoria e metadados confiáveis amplia a probabilidade de sanções e danos reputacionais, convertendo a dívida de dados em passivo jurídico e estratégico.

P12c – Capacidade analítica: dados incompletos ou conflitantes comprometem a precisão de análises e modelos de IA. Hahn e Sales (2025) mostram que bases degradadas demandam mais ciclos de teste e processamento, gerando resultados menos confiáveis e limitando a conversão de dados em vantagem competitiva.

3.2 Modelo Conceitual

Nesse tópico é apresentado o modelo conceitual, figura 2, que demonstra como os fatores comportamentais e estruturais alimentam a dívida de dados, que por sua vez gera custos extras, riscos regulatórios e perda de capacidade analítica.

Figura 2 – Modelo conceitual



Legenda: (+) indica aumento e (-) indica redução.

Fonte: Elaborado pelo autor (2025).

O modelo conceitual integra custos monetários, vieses de decisão e diversas formas de inércia para explicar como a dívida de dados surge, se acumula e impacta as organizações. As proposições P1–P5 mostram que vieses psicológicos — percepção de altos custos de migração, aversão a perdas, ancoragem em investimentos já feitos, temor de responsabilização e incerteza quanto aos benefícios — adiam iniciativas de refatoração. Já P6–P10 tratam da inércia institucional, cuja rigidez estrutural e acomodação mental cristalizam dependências técnicas e mascaram a degradação dos dados. A combinação dessas forças (P11) gera um efeito cumulativo que acelera o passivo e, conforme P12a–P12c, eleva custos operacionais, aumenta a exposição a sanções regulatórias e reduz a capacidade analítica, pois a inconsistência dos dados compromete a confiabilidade dos insights.

4. CONSIDERAÇÕES FINAIS

Este estudo busca demonstrar que a dívida de dados é um passivo organizacional enraizado não só em fatores técnicos, mas também psicológicos e estruturais. O modelo conceitual proposto articula mecanismos cognitivos (viés do status quo) e institucionais (inércia organizacional) para explicar por que práticas obsoletas se perpetuam, gerando um acúmulo silencioso de custos com dados, riscos regulatórios e ineficiência analítica.

As proposições teóricas indicam que a manutenção dessa dívida eleva despesas operacionais com reconciliação e limpeza, aumenta o risco regulatório por falta de trilhas de auditoria e limita a capacidade analítica ao apoiar-se em dados inconsistentes. O estudo sugere caminhos de pesquisa com métodos mistos para mensurar simultaneamente percepções individuais e rigidezes institucionais, bem como avaliar efeitos em desempenho, agilidade e conformidade. Por fim, reconhecer a natureza multidimensional do problema sugere intervenções que combinem soluções tecnológicas a mudanças culturais e organizacionais, oferecendo aos pesquisadores e gestores novos caminhos para aprimorar a governança de dados e sustentar a transformação digital.

REFERÊNCIAS

- AMBLER, S. Data Debt 101: What it is, and How to Address it. 2022. Disponível em: <https://www.dataversity.net>. Acesso em: abr. 2025.
- AMBLER, S. Data debt: addressing enterprise data quality problems. **AgileData Essays**, 2023.
- AMBURGEY, T. L.; KELLY, D. Path dependence and organizational inertia: Argument and empirical example. **Organization Science**, v. 2, n. 1, p. 135-158, 1991.
- ARKES, H. R.; BLUMER, C. The psychology of sunk cost. **Organizational Behavior and Human Decision Processes**, v. 35, n. 1, p. 124-140, 1985.
- BENAROCH, M.; LICHTENSTEIN, Y.; ROBINSON, K. Real options in information technology risk management: an empirical validation of risk-option relationships. **MIS Quarterly**, v. 30, n. 4, p. 827-864, 2006.
- BOGNER, J.; VERDECCHIA, R.; GEROSTATHOPOULOS, I. Characterizing technical debt and antipatterns in AI-based systems: a systematic mapping study. In: **IEEE/ACM International Conference on Technical Debt**, 4., 2021, Virtual. Anais. Piscataway: IEEE, p. 64-73, 2021.
- BORGMAN, C. L. Open Data, Grey Data, and Stewardship: Universities at the Privacy Frontier. **Berkeley Technology Law Journal**, Berkeley, v. 33, n. 2, p. 365–412, 2018.
- BURNHAM, T.; FRELS, J.; MAHAJAN, V. *Consumer Switching Costs: A Typology, Antecedents, and Consequences*. **Journal of the Academy of Marketing Science**, v. 31, n. 2, p. 109–126, 2003.
- BUTTERS, O. W.; WILSON, R. C.; BURTON, P. R. Recognizing, reporting and reducing the data-curation debt of cohort studies. **International Journal of Epidemiology**, v. 49, n. 4, p. 1067-1074, 2020.
- CENFETELLI, R. T. Inhibitors and enablers as dual factor concepts in technology usage. **Journal of the Association for Information Systems**, v. 5, n. 11-12, p. 472-492, 2004.
- CUNNINGHAM, W. The WyCash portfolio management system. In: **OOPSLA Experience Reports**. Vancouver: ACM, 1992.
- DAVENPORT, T.; HARRIS, J. *Competição analítica: vencendo através da nova ciência*. Tradução de Fernanda Lufti. Rio de Janeiro: Alta Books, 320 p. 2018.

- FICHMAN, R. G. Information technology diffusion: a review of empirical research. In: **International Conference on Information Systems – ICIS**, 13., 1992, Dallas. Proceedings... p. 195-206, 1992.
- GIANNINI, F.; ZIFFER, G.; DELLA VALLE, E. cPNN: Continuous Progressive Neural Networks for Evolving Streaming Time Series. In: **2023 International Joint Conference on Neural Networks (IJCNN)**: IEEE, p. 1-8, 2023.
- GODKIN, L.; ALLCORN, S. Overcoming organizational inertia: a tripartite model for achieving strategic organizational change. **Journal of Applied Business and Economics**, v. 8, n. 1, p. 82-95, 2008.
- GO FAIR Initiative. **FAIR Principles**. 2023. Disponível em: <https://www.go-fair.org/fair-principles/>. Acesso em: fev. 2025.
- HAHN, N.; SALES, A. Data Smells Are Sneaky. **Proceedings of the 27th International Conference on Enterprise Information Systems**, p. 479-488, 2025.
- HANNAN, M. T.; FREEMAN, J. Structural inertia and organizational change. **American Sociological Review**, v. 49, n. 2, p. 149-164, 1984.
- HASKAMP, T.; DREMEL, C.; MARX, C.; UEBERNICKEL, F. Understanding inertia in digital transformation: a literature review and multilevel research framework. In: **International Conference on Information Systems (ICIS)**, 42., 2021, Austin. Anais... Atlanta: Association for Information Systems, 2021.
- HEDBERG, B.; ERICSON, A. Insiktströghet och manövertröghet i organisationers omorientering [Insight inertia and action inertia in organizational reorientation, tradução nossa]. In: HEDBERG, B.; SJÖSTRAND, S. E. (Org.). *Fran företagskriser till industripolitik*. Malmö: Liber, p. 54-66, 1997.
- HEDBERG, B.; WOLF, R. Organizing, Learning, and Strategizing: From Construction to Discovery. In: NONAKA, I. *Handbook of Organizational Learning & Knowledge*. **Oxford University Press**, 2001.
- HUANG, H. C.; LAI, M.-C.; LIN, L.-H.; CHEN, C.-T. Overcoming organizational inertia to strengthen business model innovation: an open innovation perspective. **Journal of Organizational Change Management**, v. 26, n. 6, p. 977-1002, 2013.
- KAGANER, E.; GREGORY, R. W.; SARKER, S. A process for managing digital transformation: an organizational inertia perspective. **Journal of the Association for Information Systems**, v. 24, n. 4, p. 1005-1030, 2023.
- KAHNEMAN, D.; TVERSKY, A. Prospect theory: An analysis of decision under risk. **Econometrica**, v. 47, n. 2, p. 263-292, 1979.
- KEIL, M.; MANN, J.; RAI, A. Why Software Projects Escalate: An Empirical Analysis and Test of Four Theoretical Models. **MIS Quarterly**, v. 24, n. 4, p. 631–664, dez. 2000.
- KELLY, D.; AMBURGEY, T. L. Organizational inertia and momentum: A dynamic model of strategic change. **Academy of Management Journal**, v. 34, n. 3, p. 591-612, 1991.
- KHATRI, V.; BROWN, C. V. Designing Data Governance. **Communications of the ACM**, v. 53, n. 1, p. 148-152, 2010.

KIM, H.; KANKANHALLI, A. Investigating user resistance to information systems implementation: a status quo bias perspective. **MIS Quarterly**, v. 33, n. 3, p. 567-582, 2009.

KLEMPERER, P. Competition when consumers have switching costs: an overview with applications to industrial organisation, macroeconomics, and international trade. **Review of Economic Studies**, v. 62, n. 4, p. 515-539, 1995.

KNUDSEN, E. The enterprise data debt crisis. Database Trends & Applications, 2018. Disponível em: The Enterprise Data Debt Crisis – Database Trends and Applications. Acesso em: fev. 2025.

MÄKI, N.; PENTTINEN, E.; RINTA-KAHILA, T. A domino effect: interdependencies among different types of technical debt. In: **Hawaii International Conference on System Sciences**, 56., 2023, Maui. Anais. Washington, DC: IEEE Computer Society, p. 5949-5958, 2023.

MARCH, J. G.; OLSEN, J. P. The uncertainty of the past: organizational learning under ambiguity. **European Journal of Political Research**, v. 3, n. 2, p. 147-171, 1975.

McKINSEY & COMPANY. Fixing the Data Debt: Why Clean Data is the Future of Scalable Analytics. 2024. Disponível em: <https://www.mckinsey.com>. Acesso em: abr. 2025.

MORADI, E.; JAFARI, S. M.; DOORBASH, Z. M.; MIRZAEI, A. Impact of organizational inertia on business model innovation, open innovation and corporate performance. **Asia Pacific Management Review**, v. 26, n. 1, p. 171-179, 2021.

NIELSEN, M. E.; MADSEN, C. Ø.; LUNGU, M. F. Technical debt management: a systematic literature review and research agenda for digital government. In: VIALE PEREIRA, G. et al. (Org.). Electronic Government. **Lecture Notes in Computer Science**, v. 12219. Springer, 2020.

NUGAWELA, S.; SEDERA, D. Status quo bias in users' information systems adoption and continuance intentions: a literature review and framework. In: **Proceedings of the Australasian Conference on Information Systems**. Sydney, 2022.

OTTO, B. A morphology of the organisation of data governance. In: **European Conference on Information Systems (ECIS)**, Helsinki, 2011.

PICCOLI, G.; GROVER, V.; RODRIGUEZ, J. Digital transformation requires digital resource primacy: Clarification and future research directions. **Journal of strategic information systems**, v. 33, n. 2, p. 101835–101835, 2024.

POLITES, G.; KARAHANNA, E. Shackled to the Status Quo: The Inhibiting Effects of Incumbent System Habit, Switching Costs, and Inertia on New System Acceptance. **MIS Quarterly**, v. 36, n. 1, p. 21-42, 2012.

REDMAN, T. If your data is bad, your machine learning tools are useless. **Harvard Business Review**, 2018. Disponível em: [If Your Data Is Bad, Your Machine Learning Tools Are Useless](https://hbr.org/2018/11/if-your-data-is-bad-your-machine-learning-tools-are-useless). Acesso em Mai. 2025.

REDMAN, T. Bad Data Is Sapping Your Team's Productivity. **Harvard Business Review**, 2022. Disponível em: <https://hbr.org/2022/11/bad-data-is-sapping-your-teams-productivity>. Acesso em: Abr. 2025

RHAHLA, M.; ALLEGUE, S.; ABDELLATIF, T. Guidelines for GDPR compliance in

- Big Data systems. ***Journal of Information Security and Applications***, v. 61, p. 102896, 2021.
- RINTA-KAHILA, T.; PENTTINEN, E.; LYYTINEN, K. Getting Trapped in Technical Debt: Sociotechnical Analysis of a Legacy System's Replacement. ***MIS Quarterly***, v. 47, n. 1, p. 1–32, 2023.
- RUISSALO, J.; RINTA-KAHILA, T.; PENTTINEN, E. It's payback time! Developing a strategy to resolve technical debt. ***Journal of Information Technology Teaching Cases***, 2025.
- SAMUELSON, W.; ZECKHAUSER, R. Status quo bias in decision making. ***Journal of Risk and Uncertainty***, v. 1, n. 1, p. 7-59, 1988.
- SCHEIN, E.; SCHEIN, P. *Cultura organizacional e liderança*. 5. ed. São Paulo: Atlas, 328p. 2022.
- SCHREYÖGG, G.; SYDOW, J. Organizational path dependence: A process view. ***Organization Studies***, v. 32, n. 3, p. 321-335, 2011.
- SINGH, J. V.; LUMSDEN, C. J. Theory and research in organizational ecology. ***Annual Review of Sociology***, v. 16, n. 1, p. 161–195, 1990.
- STAW, B. Knee-deep in the Big Muddy: a study of escalating commitment to a chosen course of action. ***Organizational Behavior and Human Performance***, v. 16, n. 1, p. 27–44, 1976.
- TALLON, P.; RAMIREZ, R.; SHORT, J. The information artifact in IT governance: toward a theory of information governance. ***Journal of Management Information Systems***, v. 30, n. 3, p. 141-178, 2013.
- TUSHMAN, M. L.; O'REILLY, C. A. Ambidextrous organizations: managing evolutionary and revolutionary change. ***California Management Review***, Berkeley, v. 38, n. 4, p. 8-29, 1996.
- TVERSKY, A.; KAHNEMAN, D. Loss Aversion in Riskless Choice: A Reference-Dependent Model. ***Quarterly Journal of Economics***, Cambridge, v. 106, n. 4, p. 1039–1061, 1991.
- WANG, N.; CHEN, B.; WANG, L.; et al. Big data analytics capability and social innovation: the mediating role of knowledge exploration and exploitation. ***Humanities and Social Sciences Communications***, v. 11, n. 1, p. 1-18, 2024.
- ZEELLENBERG, M. Anticipated regret, expected feedback and behavioral decision making. ***Journal of Behavioral Decision Making***, v. 12, n. 2, p. 93–106, 1999.