RCMOS – Revista Científica Multidisciplinar O Saber. ISSN: 2675-9128. São Paulo-SP.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

A inteligência artificial generativa só gera valor real quando é construída sobre processos maduros e dados confiáveis

Generative artificial intelligence only creates real value when it is built on mature processes and reliable data

La inteligencia artificial generativa solo genera valor real cuando se construye sobre procesos maduros y datos confiables

Luiz Gastão Schuhli Camara
MBA em Gestão Estratégica de Dados e Business Intelligence pelo IBPEX/Uninter. Tecnólogo em Desenvolvimento de Sistemas Web pela Faculdade OPET.

RESUMO

A rápida difusão da inteligência artificial generativa nas organizações tem sido acompanhada por expectativas elevadas de ganhos de produtividade, mas também por indícios de que parcela relevante das iniciativas não ultrapassa a fase de prova de conceito. Este artigo investiga, por meio de revisão de literatura de natureza qualitativa e exploratória, as condições organizacionais que permitem converter essa tecnologia em valor econômico sustentável. O corpus analisado reúne estudos publicados até dezembro de 2024 nas áreas de sistemas de informação, gestão de processos de negócio, qualidade e governança de dados, economia da inovação e gestão de riscos em inteligência artificial. A análise mostra que os modelos de linguagem de grande escala operam por geração probabilística, o que os torna dependentes da qualidade do contexto informacional em que são inseridos, e que os ganhos de produtividade observados em estudos experimentais se concentram em tarefas bem delimitadas e submetidas a supervisão humana qualificada. Com apoio na teoria dos ativos complementares e nos modelos de maturidade de processos, sustenta-se que a inteligência artificial generativa amplifica a capacidade organizacional preexistente em vez de substituí-la. Conclui-se que processos documentados, mensurados e governados, associados a dados de qualidade verificável e a estruturas formais de gestão de riscos, constituem pré-condições para que a tecnologia produza resultados confiáveis, escaláveis e auditáveis.

Palavras-chave: Inteligência artificial generativa. Gestão de processos de negócio. Maturidade de processos. Qualidade de dados. Governança de dados.

ABSTRACT

The rapid diffusion of generative artificial intelligence in organizations has been accompanied by high expectations of productivity gains, but also by signs that a significant share of initiatives does not move beyond the proof of concept stage. This article investigates, through a qualitative and exploratory literature review, the organizational conditions that allow this technology to be converted into sustainable economic value. The corpus brings together studies published up to December 2024 in the fields of information systems, business process management, data quality and governance, economics of innovation and artificial intelligence risk management. The analysis shows that large language models operate through probabilistic generation, which makes them dependent on the quality of the informational context in which they are embedded, and that the productivity gains observed in experimental studies are concentrated in well defined tasks performed under qualified human supervision. Drawing on the theory of complementary assets and on process maturity models, the article argues that generative artificial intelligence amplifies pre-existing organizational capability rather than replacing it. It concludes that documented, measured and governed processes, combined with data of verifiable quality and formal risk management structures, are preconditions for the technology to deliver reliable, scalable and auditable results.

Keywords: Generative artificial intelligence. Business process management. Process maturity. Data quality. Data governance.

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

1 INTRODUÇÃO

O lançamento público de interfaces conversacionais baseadas em modelos de linguagem de grande escala, no final de 2022, deslocou a inteligência artificial generativa do ambiente dos laboratórios de pesquisa para o cotidiano das organizações em velocidade raramente observada na história das tecnologias da informação. Levantamento conduzido pela McKinsey & Company com 1.363 respondentes indicou que 65% das organizações já utilizavam regularmente a inteligência artificial generativa no início de 2024, proporção quase duas vezes superior à registrada dez meses antes (SINGLA et al., 2024). No plano das expectativas econômicas, o McKinsey Global Institute estimou que a tecnologia poderia adicionar entre 2,6 e 4,4 trilhões de dólares por ano à economia global, considerando 63 casos de uso distribuídos por diferentes funções empresariais (CHUI et al., 2023). Números dessa magnitude explicam o volume de investimentos e a pressão exercida sobre gestores para adotar a tecnologia com rapidez.

O entusiasmo inicial, contudo, convive com sinais consistentes de frustração. A Gartner (2024) projetou que ao menos 30% dos projetos de inteligência artificial generativa seriam abandonados após a prova de conceito até o final de 2025, apontando como causas a baixa qualidade dos dados, controles de risco inadequados, custos crescentes e valor de negócio pouco claro. Na mesma direção, 44% dos respondentes da pesquisa da McKinsey relataram ao menos uma consequência negativa decorrente do uso da tecnologia, sendo a imprecisão dos resultados o risco mais frequentemente experimentado (SINGLA et al., 2024). Esse descompasso entre potencial anunciado e valor efetivamente capturado reproduz, em nova escala, o paradoxo da produtividade discutido por Brynjolfsson e Hitt (2000) a respeito das gerações anteriores de tecnologia da informação, cujos benefícios só se materializaram quando acompanhados de transformações organizacionais complementares.

Diante desse cenário, o presente artigo parte da seguinte questão de pesquisa: quais condições organizacionais determinam a capacidade de a inteligência artificial generativa gerar valor real, mensurável e sustentável? A hipótese de trabalho é que o desempenho da tecnologia em ambiente corporativo não decorre apenas da sofisticação dos modelos, mas sobretudo da maturidade dos processos em que eles são inseridos e da confiabilidade dos dados que os alimentam. O objetivo geral consiste em examinar, à luz da literatura científica e de referenciais normativos publicados até dezembro de 2024, os fundamentos teóricos que sustentam essa hipótese. O texto está organizado em seis eixos analíticos, que tratam da natureza técnica dos modelos de linguagem, das evidências empíricas de produtividade, da teoria dos ativos complementares, da maturidade de processos, da

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

qualidade e governança de dados e, por fim, da gestão de riscos e da supervisão humana.

2 METODOLOGIA

Trata-se de pesquisa de abordagem qualitativa, de natureza básica e de objetivo exploratório, desenvolvida por meio de procedimento bibliográfico e documental. Segundo Gil (2017), a pesquisa exploratória é adequada quando se pretende proporcionar maior familiaridade com um problema ainda pouco sistematizado, tornando-o mais explícito e permitindo a construção de hipóteses fundamentadas. A inteligência artificial generativa aplicada ao contexto organizacional enquadra-se nessa condição, uma vez que a produção científica sobre o tema é recente, dispersa entre disciplinas distintas e marcada pela coexistência de estudos empíricos rigorosos com relatórios de mercado de caráter mais prospectivo. A pesquisa bibliográfica, nesse caso, cumpre a função de articular conhecimentos consolidados em campos tradicionais com evidências produzidas em período recente. Adotou-se o formato de revisão integrativa, conforme a tipologia proposta por Snyder (2019), que a distingue da revisão sistemática por seu propósito de avaliar, criticar e sintetizar a literatura de modo a gerar novos enquadramentos teóricos, admitindo a combinação de fontes de diferentes naturezas metodológicas. A organização da análise seguiu a orientação de Webster e Watson (2002), para quem uma revisão de literatura de qualidade deve ser centrada em conceitos, e não em autores, agrupando as contribuições segundo as categorias analíticas que efetivamente explicam o fenômeno estudado. Dessa forma, as obras selecionadas foram distribuídas em seis categorias temáticas, que correspondem às seções de desenvolvimento deste artigo e permitem examinar a relação entre tecnologia, processos, dados e governança de forma articulada.

As fontes foram identificadas nas bases Scopus, Web of Science, ACM Digital Library e IEEE Xplore, complementadas pelo Google Acadêmico e pelos repositórios oficiais de organismos normativos, como o National Institute of Standards and Technology (NIST), a International Organization for Standardization (ISO) e o Jornal Oficial da União Europeia. Utilizaram-se combinações de descritores em língua inglesa relacionados a modelos de linguagem de grande escala, inteligência artificial generativa, produtividade, gestão de processos de negócio, maturidade de processos, qualidade de dados, governança de dados e gestão de riscos em inteligência artificial. Foram priorizados artigos publicados em periódicos revisados por pares, anais de conferências de referência, livros de autores consolidados nas respectivas áreas e documentos normativos. Relatórios institucionais de consultorias e institutos de pesquisa foram incluídos apenas quando apresentavam metodologia de coleta explícita, sendo utilizados como evidência complementar e não como base

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

teórica.

Estabeleceu-se como corte temporal o mês de dezembro de 2024, de modo que nenhuma fonte publicada após essa data foi considerada. Os critérios de inclusão compreenderam a pertinência direta à questão de pesquisa, a rastreabilidade da publicação por meio de identificadores verificáveis e a relevância da obra em sua área, observada pela recorrência de citação na literatura especializada. Foram excluídos textos de opinião sem fundamentação empírica ou teórica, materiais promocionais de fornecedores de tecnologia e publicações sem autoria ou origem identificável. Reconhece-se como limitação o fato de parte das evidências sobre inteligência artificial generativa estar disponível em documentos de trabalho ainda não submetidos a revisão por pares, razão pela qual tais estudos foram interpretados com cautela e confrontados com a literatura consolidada.

3 FUNDAMENTOS DOS MODELOS DE LINGUAGEM E A NATUREZA PROBABILÍSTICA DA GERAÇÃO

A base técnica da inteligência artificial generativa contemporânea é a arquitetura Transformer, apresentada por Vaswani et al. (2017), que substituiu as estruturas recorrentes até então dominantes no processamento de linguagem natural por um mecanismo de atenção capaz de relacionar diretamente todos os elementos de uma sequência. Essa mudança permitiu paralelizar o treinamento e, consequentemente, explorar volumes de texto antes inviáveis. Bommasani et al. (2021) propuseram a expressão modelos de fundação para designar sistemas treinados sobre dados amplos e em larga escala, posteriormente adaptáveis a uma grande variedade de tarefas. Os autores chamam atenção para dois fenômenos associados a esses modelos, a emergência de capacidades não explicitamente programadas e a homogeneização, pela qual muitas aplicações passam a depender de um número reduzido de modelos de base, de modo que seus defeitos também se propagam para todas as aplicações derivadas.

Brown et al. (2020) demonstraram, com o modelo GPT-3 e seus 175 bilhões de parâmetros, que modelos suficientemente grandes conseguem executar tarefas novas a partir de poucas demonstrações apresentadas no próprio texto de entrada, sem necessidade de novo treinamento. Paralelamente, Kaplan et al. (2020) descreveram leis de escala segundo as quais o desempenho dos modelos de linguagem melhora de forma previsível, seguindo relações de potência, à medida que aumentam o número de parâmetros, o volume de dados e a capacidade computacional empregada no treinamento. Essas contribuições ajudam a compreender a rapidez do avanço técnico observado a partir de 2020, mas também evidenciam um aspecto frequentemente negligenciado na discussão gerencial. A

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

competência desses sistemas deriva de regularidades estatísticas aprendidas a partir do corpus de treinamento, e não de acesso direto a fatos verificados sobre o mundo ou sobre uma organização específica.

O passo seguinte no amadurecimento técnico dos modelos foi o alinhamento a instruções humanas. Ouyang et al. (2022) mostraram que o ajuste fino com aprendizado por reforço a partir de avaliações humanas tornou um modelo de 1,3 bilhão de parâmetros preferível, na avaliação de anotadores, às respostas do GPT-3 original, cem vezes maior. O resultado indica que a utilidade prática do modelo depende menos do tamanho e mais da qualidade do processo de retroalimentação que orienta seu comportamento, o que antecipa um argumento central deste artigo. Ainda assim, o objetivo de treinamento desses sistemas permanece sendo a produção de continuações plausíveis para um texto de entrada. Plausibilidade linguística e correção factual são propriedades distintas, e o alinhamento reduz, mas não elimina, a distância entre elas.

Essa distância manifesta-se no fenômeno conhecido como alucinação. Ji et al. (2023) distinguem a alucinação intrínseca, em que o texto gerado contradiz o conteúdo da fonte fornecida, da alucinação extrínseca, em que o conteúdo gerado não pode ser verificado a partir dessa fonte. Huang et al. (2023) ampliaram essa taxonomia para os modelos de linguagem de grande escala, separando falhas de factualidade, relativas ao conhecimento do mundo, de falhas de fidelidade, relativas à aderência às instruções e ao contexto fornecido pelo usuário. O NIST adotou o termo confabulação para designar a produção confiante de conteúdo falso ou enganoso e o incluiu entre os riscos específicos da tecnologia (NATIONAL INSTITUTE OF STANDARDS AND TECHNOLOGY, 2024). Em perspectiva crítica, Bender et al. (2021) argumentaram que esses modelos combinam formas linguísticas observadas no treinamento sem referência ao significado, o que torna a fluência do texto um indicador pouco confiável de sua veracidade.

Para a gestão organizacional, essas características técnicas têm uma consequência direta. Um modelo de linguagem não conhece as regras de negócio, as políticas internas, os contratos vigentes nem o histórico de clientes de uma empresa, a menos que essas informações sejam fornecidas de maneira estruturada no momento do uso. Quando o contexto fornecido é incompleto, contraditório ou desatualizado, o modelo tende a preencher as lacunas com conteúdo estatisticamente provável, porém potencialmente incorreto. Disso decorre que a confiabilidade de uma aplicação de inteligência artificial generativa é uma propriedade do sistema sociotécnico como um todo, formado pelo modelo, pelos dados que o alimentam, pelos processos que delimitam sua atuação e pelas pessoas que supervisionam seus resultados. As seções seguintes examinam cada um desses componentes à luz da literatura especializada.

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

RCMOS – Revista Científica Multidisciplinar O Saber. ISSN: 2675-9128. São Paulo-SP.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

4 EVIDÊNCIAS EMPÍRICAS SOBRE PRODUTIVIDADE E OS LIMITES DOS GANHOS OBSERVADOS

Entre os primeiros estudos experimentais rigorosos sobre o tema, destaca-se o trabalho de Noy e Zhang (2023), publicado na revista Science. Os autores recrutaram 453 profissionais com formação superior para executar tarefas de redação típicas de suas ocupações, como comunicados, relatórios curtos e análises, e designaram aleatoriamente metade deles para utilizar o ChatGPT. O grupo com acesso à ferramenta reduziu o tempo de execução em 40% e elevou a qualidade avaliada dos textos em 18%. Os pesquisadores observaram ainda que a tecnologia comprimiu a desigualdade de desempenho entre os participantes, beneficiando de modo mais intenso aqueles com resultados iniciais inferiores. Trata-se de evidência robusta de que, em tarefas de escrita bem definidas, com critérios de avaliação claros e resultado verificável por especialistas, a inteligência artificial generativa produz ganhos expressivos.

Em ambiente real de trabalho, Brynjolfsson, Li e Raymond (2023) analisaram a introdução gradual de um assistente conversacional baseado em inteligência artificial generativa junto a 5.179 agentes de atendimento ao cliente de uma empresa de software. O uso da ferramenta elevou em 14%, em média, o número de chamados resolvidos por hora, com aumento de 34% entre os agentes iniciantes e menos qualificados e impacto mínimo entre os mais experientes. A interpretação dos autores é particularmente relevante para o argumento aqui desenvolvido. Os autores apresentam evidências de que a ferramenta disseminou, para toda a força de trabalho, práticas antes concentradas nos atendentes mais capazes, ajudando os novatos a avançar mais rapidamente na curva de experiência. Infere-se daí que o valor gerado dependeu da existência de um processo de atendimento estruturado, de um grande volume de conversas registradas e de indicadores de resultado capazes de evidenciar quais práticas funcionavam melhor.

O estudo de campo conduzido por Dell'Acqua et al. (2023) com 758 consultores do Boston Consulting Group, cerca de 7% dos profissionais de nível individual da empresa, acrescentou uma dimensão decisiva à discussão. Em tarefas situadas dentro da fronteira de capacidade do modelo, os consultores que utilizaram o GPT-4 concluíram 12,2% mais tarefas, trabalharam 25,1% mais rápido e entregaram resultados de qualidade mais de 40% superior à do grupo de controle. Entretanto, em uma tarefa deliberadamente desenhada para ficar fora dessa fronteira, os usuários da ferramenta tiveram probabilidade 19 pontos percentuais menor de chegar à solução correta. Os autores cunharam a expressão fronteira tecnológica irregular para descrever o fato de que tarefas aparentemente

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

semelhantes em dificuldade podem estar em lados opostos da capacidade do modelo, sem que essa divisão seja visível ao usuário. A Figura 1 consolida os principais resultados dos três estudos.

Figura 1 – Ganhos de desempenho associados ao uso de inteligência artificial generativa em estudos experimentais

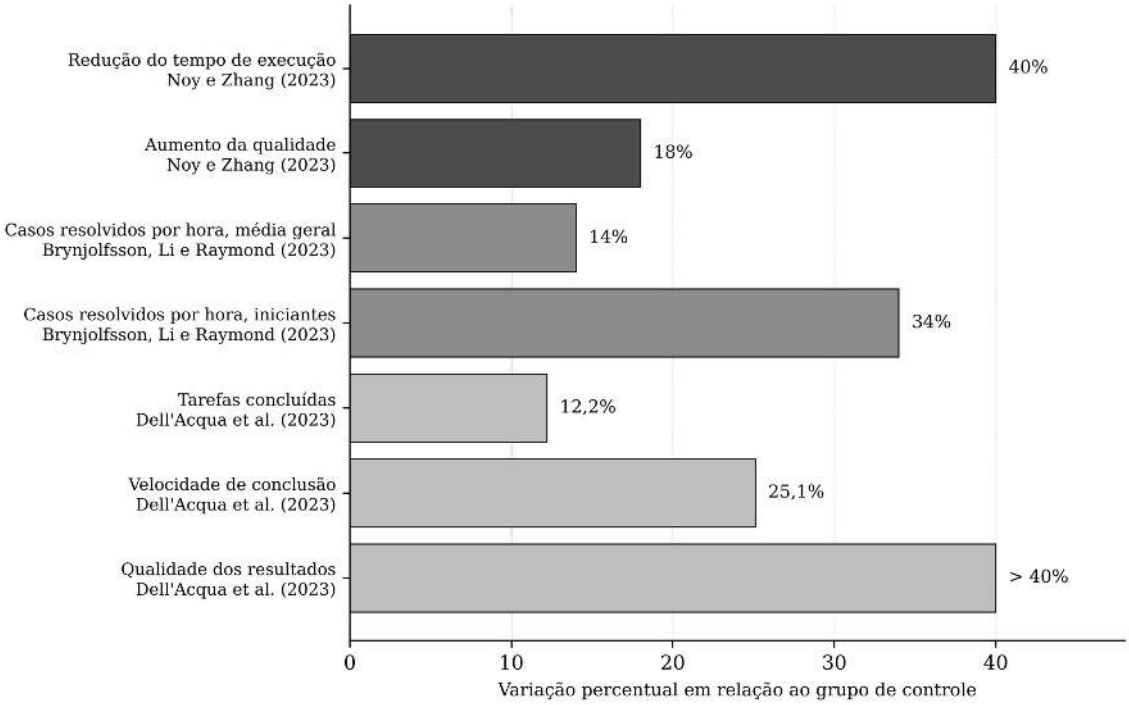

Fonte: Elaborado pelo autor com base em Noy e Zhang (2023), Brynjolfsson, Li e Raymond (2023) e Dell'Acqua et al. (2023).

A leitura conjunta desses resultados exige cautela metodológica. As métricas não são diretamente comparáveis entre si, pois cada estudo adotou tarefas, populações e critérios de avaliação próprios, e a Figura 1 deve ser interpretada como síntese de magnitudes, e não como ranking de efeitos. O ponto comum entre os experimentos é que os ganhos se concentraram em tarefas delimitadas, com objetivo explícito, critério de qualidade conhecido e possibilidade de verificação humana. Eloundou et al. (2023) estimaram que cerca de 80% da força de trabalho dos Estados Unidos poderia ter ao menos 10% de suas tarefas afetadas por modelos de linguagem, e aproximadamente 19% dos trabalhadores poderiam ter metade ou mais de suas tarefas expostas. A unidade de análise relevante, segundo esses autores, é a tarefa, e não a ocupação inteira, o que pressupõe que a organização conheça e decomponha seus próprios fluxos de trabalho.

Existe, por fim, uma distância considerável entre ganhos medidos no nível da tarefa e valor capturado no nível da firma. Os experimentos citados ocorreram em condições controladas, com tarefas selecionadas pelos pesquisadores e resultados avaliados por especialistas, situação bastante diferente

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

da operação cotidiana de uma empresa, na qual as tarefas se encadeiam em processos, dependem de sistemas legados e envolvem múltiplas áreas. O próprio McKinsey Global Institute observou que cerca de 75% do valor potencial estimado para a tecnologia se concentrava em quatro áreas, a saber, operações de atendimento ao cliente, marketing e vendas, engenharia de software e pesquisa e desenvolvimento (CHUI et al., 2023). Converter ganhos pontuais em resultado econômico agregado depende, assim, de reorganizar processos e integrar a tecnologia a fluxos de trabalho existentes, tema que a teoria dos ativos complementares permite examinar com maior profundidade.

5 A INTELIGÊNCIA ARTIFICIAL GENERATIVA COMO TECNOLOGIA DE PROPÓSITO GERAL E O PAPEL DOS ATIVOS COMPLEMENTARES

Bresnahan e Trajtenberg (1995) definiram as tecnologias de propósito geral como inovações que reúnem três características, a saber, a difusão por muitos setores da economia, o potencial de aperfeiçoamento técnico contínuo e a capacidade de estimular inovações complementares nos setores que as adotam. A máquina a vapor, a eletricidade e os semicondutores são exemplos clássicos dessa categoria. Eloundou et al. (2023) argumentaram que os modelos de linguagem de grande escala apresentam essas três propriedades, o que justificaria tratá-los como tecnologia de propósito geral. A consequência teórica dessa classificação é importante, pois tecnologias desse tipo raramente geram ganhos imediatos. Seu impacto depende de um longo período de invenção complementar, durante o qual as organizações redesenham processos, desenvolvem competências e reestruturam a forma como o trabalho é realizado.

Essa dinâmica já havia sido documentada na literatura sobre tecnologia da informação. Brynjolfsson e Hitt (2000) mostraram que o retorno dos investimentos em computação variava de forma acentuada entre empresas e que essa variação era explicada sobretudo por investimentos organizacionais complementares, como novos processos de negócio, práticas de trabalho descentralizadas, capacitação de pessoas e sistemas de incentivo. Segundo os autores, o volume desses ativos intangíveis complementares poderia ser até uma ordem de grandeza superior ao investimento na própria tecnologia. Empresas que apenas sobrepunham computadores a rotinas antigas obtinham resultados modestos, enquanto aquelas que combinavam tecnologia e reorganização alcançavam ganhos de produtividade significativos. O paralelo com a inteligência artificial generativa é evidente, pois o acesso a modelos de linguagem tornou-se relativamente barato, mas a reorganização necessária para utilizá-los bem permanece custosa.

Brynjolfsson, Rock e Syverson (2021) formalizaram esse fenômeno por meio do conceito de curva J

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

da produtividade. Quando uma tecnologia de propósito geral surge, as empresas investem pesadamente em ativos intangíveis, como redesenho de processos, dados e capital humano, que não são adequadamente capturados pelas estatísticas convencionais. Nesse primeiro momento, a produtividade medida tende a ser subestimada, pois os insumos aumentam sem que os produtos correspondentes apareçam. Somente mais tarde, quando esses intangíveis começam a gerar retorno, a produtividade medida passa a ser superestimada em relação ao esforço corrente. A frustração relatada em pesquisas recentes sobre a adoção da inteligência artificial generativa é coerente com a fase inicial dessa curva e sugere que os resultados dependerão menos da compra de tecnologia e mais da construção paciente dos ativos que a complementam.

A visão baseada em recursos oferece uma lente adicional para interpretar o problema. Barney (1991) sustentou que apenas recursos valiosos, raros, difíceis de imitar e não substituíveis podem sustentar vantagem competitiva duradoura. Modelos de linguagem de uso geral, acessados por interfaces de programação disponíveis a qualquer empresa, não atendem a esses critérios, pois são amplamente acessíveis e facilmente replicáveis por concorrentes. O que permanece raro e difícil de imitar são os dados proprietários, os processos idiossincráticos e o conhecimento organizacional acumulado. Bharadwaj (2000) demonstrou empiricamente que empresas com maior capacidade de tecnologia da informação, entendida como a combinação de infraestrutura, recursos humanos e ativos intangíveis habilitados pela tecnologia, apresentavam desempenho superior. Teece, Pisano e Shuen (1997), por sua vez, enfatizaram as capacidades dinâmicas, isto é, a habilidade de integrar, construir e reconfigurar competências internas diante de ambientes em rápida mudança.

Mikalef e Gupta (2021) transpuseram essa perspectiva para a inteligência artificial ao conceituar a capacidade de inteligência artificial como a combinação de recursos tangíveis, incluindo dados, tecnologia e recursos básicos, recursos humanos, abrangendo competências técnicas e de negócio, e recursos intangíveis, como coordenação entre áreas, capacidade de mudança organizacional e disposição para assumir riscos. Os autores verificaram empiricamente que essa capacidade está associada positivamente à criatividade organizacional e ao desempenho das empresas. Para o argumento deste artigo, a contribuição é decisiva, pois mostra que o modelo de linguagem constitui apenas um dos componentes tangíveis de uma capacidade muito mais ampla. Processos maduros e dados confiáveis são justamente os ativos complementares que transformam um recurso amplamente disponível em fonte de valor diferenciado, e cada um deles será examinado a seguir.

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

6 MATURIDADE DE PROCESSOS COMO CONDIÇÃO PARA A CAPTURA DE VALOR

Davenport (1993) definiu o processo de negócio como um conjunto estruturado e mensurável de atividades desenhado para produzir um resultado específico para determinado cliente ou mercado, e argumentou que a tecnologia da informação alcança seu maior potencial quando utilizada para inovar processos, e não apenas para acelerar tarefas isoladas. Dumas et al. (2018) sistematizaram a gestão de processos de negócio em um ciclo de vida composto por identificação, descoberta, análise, redesenho, implementação e monitoramento e controle. Cada uma dessas etapas produz artefatos que interessam diretamente à aplicação da inteligência artificial generativa, como modelos de processo documentados, regras de decisão explícitas, indicadores de desempenho e registros de execução. Sem esses artefatos, a organização não dispõe de referência objetiva para definir o que o modelo deve fazer, quais limites deve respeitar e como seu resultado será avaliado.

A noção de maturidade foi consolidada pelo Modelo de Maturidade da Capacidade, desenvolvido no Software Engineering Institute. Paulk et al. (1993) descreveram cinco níveis sucessivos, denominados inicial, repetível, definido, gerenciado e otimizado, e mostraram que a previsibilidade dos resultados cresce à medida que os processos passam a ser documentados, padronizados e controlados quantitativamente. No nível inicial, o desempenho depende da competência e do esforço individual de pessoas específicas, o que torna os resultados instáveis. Rosemann e de Bruin (2005) estenderam essa lógica para a gestão de processos de negócio em geral, propondo um modelo de maturidade com seis fatores, que são alinhamento estratégico, governança, métodos, tecnologia da informação, pessoas e cultura. Ambos os modelos convergem na ideia de que a capacidade de melhorar resultados depende da capacidade prévia de compreendê-los e medi-los.

Hammer (2007) propôs o Modelo de Maturidade de Processos e Empresas, que distingue cinco habilitadores de processo, a saber, desenho, executores, responsável pelo processo, infraestrutura e métricas, de quatro capacidades organizacionais, que são liderança, cultura, competência e governança. O autor observou que processos com habilitadores fortes não se sustentam em empresas cujas capacidades organizacionais são frágeis. Décadas antes, o mesmo autor havia alertado que automatizar processos mal concebidos apenas acelera a ineficiência, defendendo o redesenho radical em vez da simples automação de rotinas existentes (HAMMER, 1990). O alerta é especialmente pertinente para a inteligência artificial generativa. Inserir um modelo de linguagem em um fluxo de trabalho sem documentação, com variações não controladas e responsabilidades difusas tende a automatizar a própria variabilidade do processo, multiplicando erros em vez de reduzi-los.

A mineração de processos oferece um caminho metodológico para enfrentar esse problema. Van der

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

Aalst (2016) descreve três tipos de técnica aplicados a registros de eventos dos sistemas de informação, que são a descoberta do processo efetivamente executado, a verificação de conformidade entre o processo real e o modelo documentado e o aprimoramento do modelo com informações de desempenho. Essas técnicas frequentemente revelam diferenças significativas entre o processo idealizado e o processo praticado, informação indispensável para decidir onde a inteligência artificial generativa pode agregar valor. A experiência com a automação robótica de processos é ilustrativa. Van der Aalst, Bichler e Heinzl (2018) observaram que essa tecnologia funciona bem em tarefas estruturadas, repetitivas e de alto volume, cujas regras são conhecidas. A inteligência artificial generativa amplia o alcance da automação para tarefas menos estruturadas, mas não dispensa a clareza sobre objetivos, regras e exceções.

A literatura recente de gestão de processos já incorpora explicitamente a inteligência artificial em seu horizonte teórico. Dumas et al. (2023) propuseram o conceito de sistemas de gestão de processos aumentados por inteligência artificial, capazes de atuar com autonomia dentro de um quadro de restrições definido pela organização, explicar suas decisões e buscar melhorias contínuas de forma proativa. A ideia de autonomia enquadrada é central, pois pressupõe que objetivos, restrições, regras de negócio e critérios de desempenho estejam previamente explicitados. Beverungen et al. (2021) acrescentam que a gestão de processos em um mundo hiperconectado envolve tensões permanentes, como a convivência entre padronização e flexibilidade e entre controle e autonomia. Em síntese, processos maduros fornecem precisamente o enquadramento que permite à inteligência artificial generativa operar com autonomia útil, sem perder previsibilidade e capacidade de prestação de contas.

7 QUALIDADE E GOVERNANÇA DE DADOS COMO FUNDAMENTO DA CONFIABILIDADE

Wang e Strong (1996) conduziram um dos estudos mais influentes sobre qualidade de dados ao investigar empiricamente o que os próprios consumidores de dados consideram relevante. Os autores concluíram que qualidade de dados significa adequação ao uso e identificaram quatro categorias de atributos, que são a qualidade intrínseca, relacionada a precisão e credibilidade, a qualidade contextual, relacionada a relevância, atualidade e completude, a qualidade representacional, relacionada a interpretabilidade e consistência, e a qualidade de acessibilidade. Essa abordagem multidimensional permanece atual, pois mostra que um dado pode ser correto e, ainda assim, inadequado para determinado uso. Redman (2008) reforçou a tese de que os dados devem ser gerenciados como ativo organizacional, argumentando que dados de baixa qualidade geram custos

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

operacionais elevados, decisões equivocadas e perda de confiança, frequentemente sem que a origem do problema seja percebida pelos gestores.

A governança de dados estabelece quem decide e quem responde pelas decisões relativas aos dados. Khatri e Brown (2010) organizaram essas decisões em cinco domínios interdependentes, a saber, princípios de dados, qualidade de dados, metadados, acesso aos dados e ciclo de vida dos dados, e destacaram que a definição clara de responsabilidades é condição para que os dados sejam tratados como ativo. O guia de referência da DAMA International (2017) consolidou esse entendimento ao posicionar a governança de dados no centro de onze áreas de conhecimento da gestão de dados, entre as quais arquitetura, modelagem, integração, qualidade, metadados e segurança. Para a inteligência artificial generativa, a governança de metadados assume importância particular, pois a capacidade de um modelo interpretar corretamente uma informação depende de saber sua origem, sua data de validade, seu significado e seu grau de confiabilidade.

A literatura de aprendizado de máquina fornece evidências contundentes sobre os efeitos da negligência com os dados. Sambasivan et al. (2021) entrevistaram 53 profissionais que desenvolviam sistemas de inteligência artificial em domínios de alto impacto e constataram que 92% deles haviam vivenciado ao menos uma cascata de dados, isto é, uma sequência de efeitos negativos acumulados e muitas vezes tardiamente percebidos, originada em problemas de dados. Os autores atribuem o fenômeno à desvalorização do trabalho com dados em comparação com o trabalho de desenvolvimento de modelos. Sculley et al. (2015) já haviam demonstrado que, em sistemas de aprendizado de máquina em produção, o código do modelo representa uma fração pequena do sistema total, e que as dependências de dados geram dívida técnica mais custosa que as dependências de código. Amershi et al. (2019), em estudo realizado na Microsoft, identificaram a gestão de dados como um dos desafios mais difíceis no desenvolvimento de aplicações de inteligência artificial.

Esse conjunto de evidências sustenta o movimento denominado inteligência artificial centrada em dados. Zha et al. (2023) descrevem essa abordagem como o deslocamento do foco da pesquisa e da prática, do aperfeiçoamento contínuo da arquitetura dos modelos para a engenharia sistemática dos dados que os alimentam. Whang et al. (2023) analisaram os desafios de coleta, validação e limpeza de dados no aprendizado profundo e mostraram que a qualidade dos dados de entrada condiciona diretamente a robustez e a equidade dos resultados. Polyzotis et al. (2018) descreveram os desafios do ciclo de vida dos dados em aprendizado de máquina de produção, enfatizando a necessidade de validação contínua. Gebru et al. (2021), por sua vez, propuseram a documentação padronizada de conjuntos de dados, registrando motivação, composição, processo de coleta e usos recomendados, prática que aproxima a gestão de dados das exigências de rastreabilidade típicas de processos

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

maduros.

No contexto corporativo, a principal forma de conectar um modelo de linguagem ao conhecimento da organização é a geração aumentada por recuperação. Lewis et al. (2020) propuseram essa arquitetura, que combina a memória paramétrica do modelo com um índice não paramétrico de documentos consultado no momento da geração, e demonstraram ganhos de especificidade e factualidade em tarefas intensivas em conhecimento. Gao et al. (2023) revisaram a evolução dessa abordagem e a apontaram como uma das estratégias mais promissoras para reduzir alucinações e incorporar conhecimento atualizado. Há, contudo, uma implicação frequentemente subestimada. Quando o modelo passa a responder com base nos documentos internos da empresa, a confiabilidade da resposta torna-se dependente da qualidade desses documentos. Bases desatualizadas, versões conflitantes de políticas e cadastros inconsistentes são reproduzidos com aparência de autoridade, o que transfere o problema da confiabilidade do modelo para a governança dos dados.

8 GOVERNANÇA, GESTÃO DE RISCOS E O PAPEL DA SUPERVISÃO HUMANA

A consolidação de referenciais normativos para a inteligência artificial reforça a centralidade de processos e dados. A Estrutura de Gestão de Riscos de Inteligência Artificial publicada pelo National Institute of Standards and Technology (2023) organiza a gestão de riscos em quatro funções, denominadas governar, mapear, medir e gerenciar, e define como características de sistemas confiáveis a validade e a confiabilidade, a segurança, a segurança cibernética e a resiliência, a responsabilização e a transparência, a explicabilidade e a interpretabilidade, a proteção da privacidade e a equidade com gestão de vieses nocivos. A função governar, posicionada como transversal às demais, exige políticas, papéis e responsabilidades formalmente estabelecidos. Em termos práticos, trata-se de uma exigência de maturidade organizacional, pois não é possível mapear, medir ou gerenciar riscos de sistemas inseridos em processos que não foram previamente descritos.

Em julho de 2024, o NIST publicou um perfil específico para a inteligência artificial generativa, que identifica doze riscos exclusivos ou agravados por essa tecnologia, entre os quais a confabulação, a privacidade de dados, a integridade da informação, a segurança da informação, a propriedade intelectual e a configuração da interação entre humanos e inteligência artificial (NATIONAL INSTITUTE OF STANDARDS AND TECHNOLOGY, 2024). O documento associa a cada risco ações sugeridas, organizadas segundo as quatro funções da estrutura original. Em paralelo, a norma ISO/IEC 42001 especificou requisitos para estabelecer, implementar, manter e melhorar continuamente um sistema de gestão de inteligência artificial nas organizações (INTERNATIONAL

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

ORGANIZATION FOR STANDARDIZATION; INTERNATIONAL ELECTROTECHNICAL COMMISSION, 2023). Ao adotar a lógica dos sistemas de gestão, a norma trata a inteligência artificial como objeto de processos documentados, auditáveis e sujeitos a melhoria contínua, aproximando-a das práticas já consolidadas em gestão da qualidade e da segurança da informação.

No plano regulatório, o Regulamento (UE) 2024/1689, conhecido como Lei de Inteligência Artificial da União Europeia, estabeleceu uma abordagem baseada em níveis de risco, com obrigações proporcionais ao potencial de dano de cada aplicação (EUROPEAN UNION, 2024). Para sistemas classificados como de alto risco, o regulamento exige que os conjuntos de dados de treinamento, validação e teste sejam submetidos a práticas de governança e gestão de dados adequadas à finalidade pretendida, além de documentação técnica e registro de eventos que permitam a rastreabilidade do funcionamento. Para os modelos de inteligência artificial de finalidade geral, são previstas obrigações de documentação técnica e de divulgação de informações sobre os dados utilizados no treinamento. Independentemente da jurisdição em que uma organização opere, o texto sinaliza uma tendência normativa clara, segundo a qual qualidade de dados e rastreabilidade de processos deixam de ser boas práticas opcionais e passam a ser requisitos de conformidade.

A supervisão humana constitui outro componente indispensável do sistema. Raisch e Krakowski (2021) descreveram o paradoxo entre automação e aumento das capacidades humanas, argumentando que as duas abordagens são interdependentes ao longo do tempo e que privilegiar exclusivamente a automação pode levar à perda de conhecimento e à rigidez organizacional. Shrestha, Ben-Menahem e Von Krogh (2019) propuseram estruturas alternativas de decisão entre humanos e algoritmos, que vão da delegação completa ao algoritmo a arranjos híbridos sequenciais e agregados, e indicaram que a escolha adequada depende de características do problema, como a necessidade de interpretabilidade, o tamanho do espaço de alternativas e a velocidade exigida. O estudo de Dell'Acqua et al. (2023) mostrou, adicionalmente, que os consultores que utilizaram o modelo em uma tarefa situada fora de sua fronteira de capacidade tiveram desempenho inferior ao de quem trabalhou sem a ferramenta, o que evidencia que a supervisão só é eficaz quando o supervisor domina o processo e conhece os limites da tecnologia.

A literatura gerencial confirma que o sucesso depende mais de escolhas organizacionais do que de escolhas tecnológicas. Davenport e Ronanki (2018), ao analisar 152 projetos de inteligência artificial, concluíram que as empresas obtinham melhores resultados com uma abordagem incremental do que com iniciativas transformadoras de grande ambição, e recomendaram que a adoção partisse da compreensão das tecnologias disponíveis, da formação de um portfólio de projetos priorizados e de projetos piloto bem delimitados antes de qualquer expansão. Fountaine, McCarthy e Saleh (2019)

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

observaram que a maioria das empresas permanecia presa a projetos piloto isolados e que a escala dependia de romper silos entre áreas, formar equipes multidisciplinares e substituir decisões baseadas em experiência individual por decisões baseadas em dados. As causas de abandono apontadas pela Gartner (2024), ou seja, dados de baixa qualidade, controles de risco inadequados, custos crescentes e valor de negócio pouco claro, correspondem precisamente às lacunas de governança, de dados e de processos discutidas ao longo deste artigo.

9 CONCLUSÃO

Este artigo examinou, à luz da literatura publicada até dezembro de 2024, as condições organizacionais que permitem à inteligência artificial generativa produzir valor real. A análise partiu do contraste entre a rápida adoção da tecnologia e os sinais de frustração registrados em pesquisas de mercado e chegou a uma conclusão central, a de que o desempenho dessa tecnologia em ambiente corporativo é determinado em grande medida por fatores externos ao modelo, notadamente a maturidade dos processos e a confiabilidade dos dados.

No plano técnico, verificou-se que os modelos de linguagem de grande escala aprendem regularidades estatísticas e produzem continuações plausíveis, o que não equivale a produzir conteúdo verdadeiro. A literatura sobre alucinação e confabulação mostra que esse limite é estrutural e não um defeito pontual a ser eliminado por versões futuras. Por essa razão, a confiabilidade deve ser compreendida como propriedade do sistema sociotécnico, que reúne modelo, dados, processos e pessoas, e não como atributo exclusivo da tecnologia adquirida.

As evidências experimentais confirmam que os ganhos de produtividade são reais e, em alguns casos, expressivos. No entanto, esses ganhos concentraram-se em tarefas delimitadas, com objetivos explícitos, critérios de qualidade conhecidos e supervisão humana qualificada. Quando a tarefa ultrapassou a fronteira de capacidade do modelo, o uso da ferramenta prejudicou o desempenho, o que demonstra que conhecer os limites do processo é tão importante quanto conhecer as possibilidades da tecnologia.

A teoria das tecnologias de propósito geral e a literatura sobre ativos complementares explicam por que a adoção tende a gerar resultados modestos no curto prazo. Assim como ocorreu com as gerações anteriores de tecnologia da informação, o retorno depende de investimentos em ativos intangíveis, como redesenho de processos, qualificação de pessoas e estruturação de dados, cuja maturação é lenta e cujo efeito aparece com defasagem. A curva J da produtividade oferece uma explicação consistente para a frustração inicial observada em muitas organizações.

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

A visão baseada em recursos permite concluir que o acesso a modelos de linguagem de uso geral dificilmente sustenta vantagem competitiva, uma vez que se trata de recurso amplamente disponível. A diferenciação decorre da combinação desse recurso com ativos raros e difíceis de imitar, como dados proprietários de qualidade, processos bem desenhados e conhecimento organizacional acumulado. Nesse sentido, a inteligência artificial generativa amplifica capacidades preexistentes, tornando mais produtivas as organizações já bem estruturadas e expondo as fragilidades das demais. Os modelos de maturidade de processos e a literatura recente sobre sistemas de gestão de processos aumentados por inteligência artificial indicam que a autonomia útil de um sistema depende de um enquadramento previamente definido. Processos documentados, mensurados e com responsáveis claramente atribuídos fornecem as regras, os limites e os critérios de avaliação que permitem à tecnologia atuar com previsibilidade. Automatizar processos imaturos, ao contrário, tende a reproduzir em maior escala a variabilidade e os erros já existentes.

A literatura sobre qualidade e governança de dados demonstra que problemas de dados são a origem mais frequente de falhas em sistemas de inteligência artificial e que seus efeitos costumam ser cumulativos e tardiamente percebidos. A disseminação da geração aumentada por recuperação torna essa questão ainda mais crítica, pois transfere para os documentos e cadastros internos a responsabilidade pela correção das respostas. Os referenciais do NIST, a norma ISO/IEC 42001 e o regulamento europeu convergem ao tratar a governança de dados e a rastreabilidade como requisitos estruturais.

Como implicação prática, recomenda-se que as organizações avaliem a maturidade de seus processos e a qualidade de seus dados antes de ampliar investimentos em inteligência artificial generativa, priorizando casos de uso delimitados e mensuráveis. Como limitação, reconhece-se que parte das evidências provém de documentos de trabalho e de relatórios institucionais, e que o estudo não testou empiricamente a relação proposta. Pesquisas futuras poderão verificar, por meio de estudos quantitativos com diferentes setores, em que medida indicadores de maturidade de processos e de qualidade de dados explicam a variação dos resultados obtidos com a tecnologia.

REFERÊNCIAS

AMERSHI, S. et al. Software engineering for machine learning: a case study. In: INTERNATIONAL CONFERENCE ON SOFTWARE ENGINEERING: SOFTWARE ENGINEERING IN PRACTICE, 41., 2019, Montreal. **Proceedings** [...]. Piscataway: IEEE, 2019. p. 291-300.

BARNEY, J. Firm resources and sustained competitive advantage. **Journal of Management**, v. 17, n. 1, p. 99-120, 1991.

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

BENDER, E. M. et al. On the dangers of stochastic parrots: can language models be too big? In: ACM CONFERENCE ON FAIRNESS, ACCOUNTABILITY, AND TRANSPARENCY, 2021, [S. l.]. **Proceedings** [...]. New York: ACM, 2021. p. 610-623.

BEVERUNGEN, D. et al. Seven paradoxes of business process management in a hyper-connected world. **Business & Information Systems Engineering**, v. 63, n. 2, p. 145-156, 2021.

BHARADWAJ, A. S. A resource-based perspective on information technology capability and firm performance: an empirical investigation. **MIS Quarterly**, v. 24, n. 1, p. 169-196, 2000.

BOMMASANI, R. et al. **On the opportunities and risks of foundation models**. Stanford: Center for Research on Foundation Models, 2021. arXiv:2108.07258.

BRESNAHAN, T. F.; TRAJTENBERG, M. General purpose technologies: 'engines of growth'? **Journal of Econometrics**, v. 65, n. 1, p. 83-108, 1995.

BROWN, T. B. et al. Language models are few-shot learners. **Advances in Neural Information Processing Systems**, v. 33, p. 1877-1901, 2020.

BRYNJOLFSSON, E.; HITT, L. M. Beyond computation: information technology, organizational transformation and business performance. **Journal of Economic Perspectives**, v. 14, n. 4, p. 23-48, 2000.

BRYNJOLFSSON, E.; LI, D.; RAYMOND, L. R. **Generative AI at work**. Cambridge: National Bureau of Economic Research, 2023. (NBER Working Paper, n. 31161).

BRYNJOLFSSON, E.; ROCK, D.; SYVERSON, C. The productivity J-curve: how intangibles complement general purpose technologies. **American Economic Journal: Macroeconomics**, v. 13, n. 1, p. 333-372, 2021.

CHUI, M. et al. **The economic potential of generative AI**: the next productivity frontier. [S. l.]: McKinsey Global Institute, 2023.

DAMA INTERNATIONAL. **DAMA-DMBOK**: data management body of knowledge. 2. ed. Basking Ridge: Technics Publications, 2017.

DAVENPORT, T. H. **Process innovation**: reengineering work through information technology. Boston: Harvard Business School Press, 1993.

DAVENPORT, T. H.; RONANKI, R. Artificial intelligence for the real world. **Harvard Business Review**, v. 96, n. 1, p. 108-116, 2018.

DELL'ACQUA, F. et al. **Navigating the jagged technological frontier**: field experimental evidence of the effects of AI on knowledge worker productivity and quality. Boston: Harvard Business School, 2023. (Working Paper, n. 24-013).

DUMAS, M. et al. **Fundamentals of business process management**. 2. ed. Berlin: Springer, 2018.

DUMAS, M. et al. AI-augmented business process management systems: a research manifesto. **ACM Transactions on Management Information Systems**, v. 14, n. 1, art. 11, p. 1-19, 2023.

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

ELOUNDOU, T. et al. **GPTs are GPTs**: an early look at the labor market impact potential of large language models. [S. l.]: arXiv, 2023. arXiv:2303.10130.

EUROPEAN UNION. Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). **Official Journal of the European Union**, Luxembourg, L series, 12 July 2024.

FOUNTAINE, T.; McCARTHY, B.; SALEH, T. Building the AI-powered organization. **Harvard Business Review**, v. 97, n. 4, p. 62-73, 2019.

GAO, Y. et al. **Retrieval-augmented generation for large language models**: a survey. [S. l.]: arXiv, 2023. arXiv:2312.10997.

GARTNER. **Gartner predicts 30% of generative AI projects will be abandoned after proof of concept by end of 2025**. Sydney: Gartner, 29 jul. 2024. Press release.

GEBRU, T. et al. Datasheets for datasets. **Communications of the ACM**, v. 64, n. 12, p. 86-92, 2021.

GIL, A. C. **Como elaborar projetos de pesquisa**. 6. ed. São Paulo: Atlas, 2017.

HAMMER, M. Reengineering work: don't automate, obliterate. **Harvard Business Review**, v. 68, n. 4, p. 104-112, 1990.

HAMMER, M. The process audit. **Harvard Business Review**, v. 85, n. 4, p. 111-123, 2007.

HUANG, L. et al. **A survey on hallucination in large language models**: principles, taxonomy, challenges, and open questions. [S. l.]: arXiv, 2023. arXiv:2311.05232.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION; INTERNATIONAL ELECTROTECHNICAL COMMISSION. **ISO/IEC 42001**: information technology, artificial intelligence, management system. Geneva: ISO, 2023.

JI, Z. et al. Survey of hallucination in natural language generation. **ACM Computing Surveys**, v. 55, n. 12, art. 248, p. 1-38, 2023.

KAPLAN, J. et al. **Scaling laws for neural language models**. [S. l.]: arXiv, 2020. arXiv:2001.08361.

KHATRI, V.; BROWN, C. V. Designing data governance. **Communications of the ACM**, v. 53, n. 1, p. 148-152, 2010.

LEWIS, P. et al. Retrieval-augmented generation for knowledge-intensive NLP tasks. **Advances in Neural Information Processing Systems**, v. 33, p. 9459-9474, 2020.

MIKALEF, P.; GUPTA, M. Artificial intelligence capability: conceptualization, measurement calibration, and empirical study on its impact on organizational creativity and firm performance. **Information & Management**, v. 58, n. 3, art. 103434, 2021.

NATIONAL INSTITUTE OF STANDARDS AND TECHNOLOGY. **Artificial intelligence risk**

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

management framework (AI RMF 1.0). Gaithersburg: NIST, 2023. (NIST AI 100-1).

NATIONAL INSTITUTE OF STANDARDS AND TECHNOLOGY. **Artificial intelligence risk management framework**: generative artificial intelligence profile. Gaithersburg: NIST, 2024. (NIST AI 600-1).

NOY, S.; ZHANG, W. Experimental evidence on the productivity effects of generative artificial intelligence. **Science**, v. 381, n. 6654, p. 187-192, 2023.

OUYANG, L. et al. Training language models to follow instructions with human feedback. **Advances in Neural Information Processing Systems**, v. 35, p. 27730-27744, 2022.

PAULK, M. C. et al. Capability maturity model, version 1.1. **IEEE Software**, v. 10, n. 4, p. 18-27, 1993.

POLYZOTIS, N. et al. Data lifecycle challenges in production machine learning: a survey. **ACM SIGMOD Record**, v. 47, n. 2, p. 17-28, 2018.

RAISCH, S.; KRAKOWSKI, S. Artificial intelligence and management: the automation-augmentation paradox. **Academy of Management Review**, v. 46, n. 1, p. 192-210, 2021.

REDMAN, T. C. **Data driven**: profiting from your most important business asset. Boston: Harvard Business Press, 2008.

ROSEMANN, M.; DE BRUIN, T. Towards a business process management maturity model. In: EUROPEAN CONFERENCE ON INFORMATION SYSTEMS, 13., 2005, Regensburg. **Proceedings** [...]. Regensburg: ECIS, 2005.

SAMBASIVAN, N. et al. "Everyone wants to do the model work, not the data work": data cascades in high-stakes AI. In: CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS, 2021, Yokohama. **Proceedings** [...]. New York: ACM, 2021. p. 1-15.

SCULLEY, D. et al. Hidden technical debt in machine learning systems. **Advances in Neural Information Processing Systems**, v. 28, p. 2503-2511, 2015.

SHRESTHA, Y. R.; BEN-MENAHEM, S. M.; VON KROGH, G. Organizational decision-making structures in the age of artificial intelligence. **California Management Review**, v. 61, n. 4, p. 66-83, 2019.

SINGLA, A. et al. **The state of AI in early 2024**: gen AI adoption spikes and starts to generate value. [S. l.]: McKinsey & Company, 2024.

SNYDER, H. Literature review as a research methodology: an overview and guidelines. **Journal of Business Research**, v. 104, p. 333-339, 2019.

TEECE, D. J.; PISANO, G.; SHUEN, A. Dynamic capabilities and strategic management. **Strategic Management Journal**, v. 18, n. 7, p. 509-533, 1997.

VAN DER AALST, W. M. P. **Process mining**: data science in action. 2. ed. Berlin: Springer, 2016.

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.

Ano V, v.2 2024 | submissão: 15/07/2024 | aceito: 20/07/2024 | publicação: 25/07/2024

VAN DER AALST, W. M. P.; BICHLER, M.; HEINZL, A. Robotic process automation. **Business & Information Systems Engineering**, v. 60, n. 4, p. 269-272, 2018.

VASWANI, A. et al. Attention is all you need. **Advances in Neural Information Processing Systems**, v. 30, p. 5998-6008, 2017.

WANG, R. Y.; STRONG, D. M. Beyond accuracy: what data quality means to data consumers. **Journal of Management Information Systems**, v. 12, n. 4, p. 5-33, 1996.

WEBSTER, J.; WATSON, R. T. Analyzing the past to prepare for the future: writing a literature review. **MIS Quarterly**, v. 26, n. 2, p. xiii-xxiii, 2002.

WHANG, S. E. et al. Data collection and quality challenges in deep learning: a data-centric AI perspective. **The VLDB Journal**, v. 32, n. 4, p. 791-813, 2023.

ZHA, D. et al. **Data-centric artificial intelligence**: a survey. [S. l.]: arXiv, 2023. arXiv:2303.10158.

Este é um artigo publicado em acesso aberto (Open Access) sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja corretamente citado.