Machine Translated by Google

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

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

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

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 convencimentos 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, que os tornam dependentes da qualidade do contexto informacional em que são inseridos, e que os ganhos de produtividade distribuídos em estudos experimentais se concentram em tarefas bem delimitadas e submetidas a supervisão humana acima. Com apoio na teoria dos ativos complementares e nos modelos de maturidade de processos, sustenta-se que a inteligência artificial generativa amplifique a capacidade organizacional preexistente em vez de substituí-la.

Conclui-se que processos documentados, mensurados e governados, associados a dados de qualidade verificáveis e as estruturas formais de gestão de riscos, pré-condições específicas 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.

RESUMO *A*

rápida difusão da inteligência artificial generativa nas organizações tem sido acompanhada por altas expectativas de ganhos de produtividade, mas também por indícios de que uma parcela significativa das iniciativas não ultrapassa a fase de prova de conceito. Este artigo investiga, por meio de uma revisão bibliográfica qualitativa e exploratória, as condições organizacionais que permitem que essa tecnologia se converta em valor econômico sustentável. O corpus reúne estudos publicados até dezembro de 2024 nas áreas de sistemas de informação, gestão de processos de negócios, qualidade e governança de dados, economia da inovação e gestão de riscos em inteligência artificial. A análise demonstra que grandes modelos de linguagem operam por meio de geração probabilística, o que os torna dependentes da qualidade do contexto informacional em que estão inseridos, e que os ganhos de produtividade observados em estudos experimentais se concentram em tarefas bem definidas, executadas sob supervisão humana qualificada. Com base na teoria dos ativos complementares e em modelos de maturidade de processos, o artigo argumenta que a inteligência artificial generativa amplifica a capacidade organizacional preexistente, em vez de substituí-la. Conclui-se que processos documentados, mensurados e governados, combinados com dados de qualidade verificável e estruturas formais de gestão de riscos, são pré-condições para que a tecnologia forneça resultados confiáveis, escaláveis e auditáveis.

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

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

Machine Translated by Google
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

1 INTRODUÇÃO

O lançamento público de interfaces conversacionais baseadas em modelos de linguagem de grande porte escala, no final de 2022, deslocou a inteligência artificial generativa do ambiente dos laboratórios de pesquisa para o cotidiano das organizações em velocidade relatada na história das tecnologias da informação. Levantamento progressivo pela McKinsey & Company com 1.363 entrevistados indicaram que 65% das organizações já utilizavam regularmente 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 estima 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 os investidores para adotar a tecnologia com rapidez.

A emoção inicial, contudo, convive com sinais consistentes de frustração. 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 entrevistados da pesquisa da McKinsey afirmaram ao menos uma consequência negativa decorrente do uso da tecnologia, sendo a imprecisão dos resultados ou risco mais frequentemente experimentado (SINGLA et al., 2024). Esse descompasso entre potencial anunciado e valor obtidos capturados, em nova escala, o paradoxo da produção calculada por Brynjolfsson e Hitt (2000) a respeito das gerações anteriores de tecnologia da informação, quais benefícios só se materializaram quando acompanhados de transformações organizacionais complementar.

Diante desse cenário, o presente artigo parte da seguinte questão de pesquisa: quais condições as organizações determinam a capacidade de uma inteligência artificial generativa gerar valor real, mensurável e sustentável? A hipótese de trabalho é que o desempenho da tecnologia no 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 sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja devidamente citado.

Machine Translated by Google
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

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 desenvolvido por meio de procedimento bibliográfico e documental. Segundo Gil (2017), uma pesquisa exploratória adequada é 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 nessa condição, uma vez que a produção científica sobre o tema é recente, dispersa entre disciplinas distintas e marcadas pela coexistência de estudos empíricos rigorosos com relatórios de mercado caráter mais prospectivo. A pesquisa bibliográfica, nesse caso, cumpre a função de articulação 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 distinguir a 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 metodológicos. A organização da análise de melhoria 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 conhecimento estudado. Dessa forma, as obras designadas foram distribuídas em seis categorias temáticas, que leia as cláusulas de desenvolvimento deste artigo e permita consultar 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 Instituto Nacional de Padrões e Tecnologia (NIST), uma organização internacional Organization for Standardization (ISO) e o Jornal Oficial da União Europeia. Utilizaram-se codificação de descritores em língua inglesa relacionados a modelos de linguagem de grande escala, inteligência artificial generativa, produtividade, gestão de processos de negócio, maturidade de negócio processos, qualidade de dados, governança de dados e gestão de riscos em inteligência artificial. Foram artigos prioritários publicados em periódicos revisados por pares, anais de conferências de referência, livros de autores consolidados nas respectivas áreas e documentos normativos. Relatórios instituições de consultoria e institutos de pesquisa foram incluídos apenas quando foram apresentados metodologia de coleta explícita, sendo utilizada como evidência complementar e não como base

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

Machine Translated by Google

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

teórico.

Estabeleceu-se como corte temporal o mês de dezembro de 2024, de modo que nenhuma fonte publicada essa após 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 citações 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 ou fato de parte das evidências sobre inteligência artificial generativa estarão disponíveis 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 EA NATUREZA PROBABILÍSTICA DA GERAÇÃO

A base técnica da inteligência artificial generativa contemporânea é a arquitetura Transformer, apresentado por Vaswani et al. (2017), que substituiu as estruturas recorrentes até então dominantes não há 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) pro posto a expressão modelos de fundação para projetar sistemas treinados sobre dados amplos e em larga escala escala, posteriormente adaptável a uma grande variedade de tarefas. Os autores chamam atenção para duas especificidades associadas a esses modelos, a emergência de capacidades não explicitamente programadas e a homogeneização, pelas quais muitas aplicações passam a depender de um número limitado de modelos de base, de modo que seus defeitos também se propagam para todos os aplicações.

Brown et al. (2020) descobriu, com o modelo GPT-3 e seus 175 bilhões de parâmetros, que modelos suficientemente grandes permitem executar tarefas novas a partir de previsões apresentações no próprio texto de entrada, sem necessidade de novo treinamento. Paralelamente, Kaplan et al. (2020) Descreveram leis de escala segundo como quais o desempenho dos modelos de linguagem melhorar de forma previsível, observando relações de poder, à medida que aumente 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 apresentado a partir de 2020, mas também evidenciaram um aspecto frequentemente negligenciado na discussão gerencial. UM

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

Machine Translated by Google
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

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

O passo seguinte no amadurecimento técnico dos modelos foi o alinhamento com instruções humanas. Ouyang et al. (2022) mostrou que o ajuste fino com aprendizado por reforço a partir de avaliações humano tornou-se um modelo de 1,3 bilhão de parâmetros preferenciais, na avaliação de anotadores, às respostas do GPT-3 original, cem vezes maior. O resultado indica que a praticidade 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 não conhecida 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, relativa ao conhecimento do mundo, de falhas de fidelidade, relativa à aderência às instruções e o contexto fornecido pelo usuário. O NIST atualizou o termo confabulação para designar a produção confiável de conteúdo falso ou enganoso e incluído entre os riscos específicos da tecnologia (INSTITUTO NACIONAL DE PADRÕES E TECNOLOGIA, 2024). Em perspectiva crítica, Bender et al. (2021) argumentaram que esses modelos combinavam 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 for incompleto, contraditório ou desatualizado, o modelo tende a preencher lacunas com conteúdo estatisticamente provável, porém potencialmente perigoso. Disso decorre que a confiabilidade de uma aplicação de inteligência artificial generativa é uma propriedade do sistema sociotécnico como um todo, formada pelo modelo, pelos dados que o alimentam, pelos processos que delimitam sua atuação e pelas pessoas que supervisionaram seus resultados. As instruções a seguir examinam cada um desses componentes à luz da literatura especializada.

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

Machine Translated by Google
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 específicos 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 usar o ChatGPT. O grupo com acesso à ferramenta impediu 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 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 aumentou em 14%, em média, o número de chamadas resolvidas por hora, com aumento de 34% entre os agentes iniciantes e menos obstáculos e impacto mínimo entre os mais experientes. A interpretação dos autores é especialmente relevante para o argumento aqui desenvolvido. Os autores apresentam evidências de que a ferramenta disseminou, para toda a força de trabalho, práticas antes de equipamentos nos atendentes mais capazes, ajudando os novatos a avançar mais rapidamente na curva de experiência. Infere-se daí que o valor gerado dependia 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 contínuo de Dell'Acqua et al. (2023) com 758 consultores da Boston Consulting Grupo, cerca de 7% dos profissionais de nível individual da empresa, acrescentou uma dimensão determinantes 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% superiores ao grupo de controle. Entretanto, em uma tarefa deliberadamente projetado 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 sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja devidamente citado.

Machine Translated by Google
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

semelhantes em dificuldade podem estar em lados opostos da capacidade do modelo, sem que essa a 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

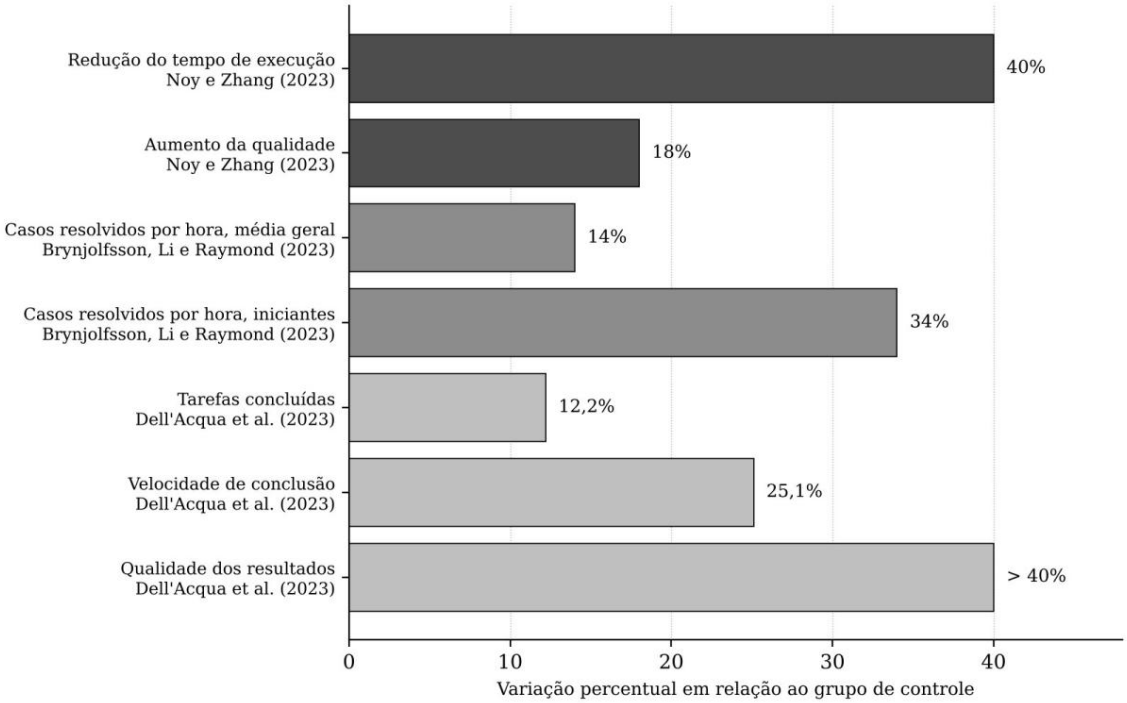

Fonte: Elaborado pelo autor com base em Noy e Zhang (2023), Brynjolfsson, Li e Raymond (2023) e Dell'Acqua et al. (2023).

A leitura conjunta desses resultados exige cautela metodológica. As métricas não são diretamente comparáveis entre si, pois cada estudo estudou tarefas, políticas 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 concentrem em tarefas delimitadas, com objetivo explícito, classificações de qualidade conhecidas e possibilidade de seleção 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 Poderia ter metade ou mais de suas tarefas expostas. A unidade de análise relevante, segundos esses autores, é uma tarefa, e não uma ocupação inteira, o que pressupõe que a organização conheça e descomponha seus próprios fluxos de trabalho.

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

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

Machine Translated by Google
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

da operação cotidiana de uma empresa, na qual as tarefas se encadeiam em processos, dependendo de sistemas legados e envolvimento em múltiplas áreas. O próprio McKinsey Global Institute inspirou que cerca de 75% do valor potencial estimado para a tecnologia se concentrou 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 aos 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 aprimoramento técnico contínuo e capacidade de estímulo a inovações complementares em setores que as adotamos. 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 apresentar essas três propriedades, o que justificaria tratá-las como tecnologia de propósito geral. UM A consequência teórica dessa classificação é importante, pois esse tipo de tecnologias gera excessivamente 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) demonstraram que o retorno dos investimentos em computação variava de forma acentuada entre empresas e essa variação era explicada principalmente 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 poderiam ser até uma ordem de grandeza superior ao investimento na própria tecnologia. Empresas que apenas sobrepunham computadores a rotinas antigas obtinham resultados modestos, enquanto aqueles que combinaram tecnologia e reorganização alcançaram 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 permanecem custosos.

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

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

Machine Translated by Google
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

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 capturados pelas estatísticas aleatórias. Nesse primeiro momento, um
A produtividade medida tende a ser subestimada, pois os insumos aumentam sem que os produtos correspondência correspondente. Só mais tarde, quando esses intangíveis começarem a gerar retorno, a produtividade medida passa a ser superestimada em relação ao esforço atual. Uma frustração relatado 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 competitiva. Modelos de linguagem de uso geral, acessados por interfaces de programação disponível para qualquer empresa, não atende a esses critérios, pois são amplamente acessível e facilmente replicável 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, apresentam desempenho superior. Teece, Pisano e Shuen (1997), por sua vez, enfatizei as capacidades dinâmicas, isto é, a habilidade de integrar, construir e reconfigurar competências internas diante de ambientes em rápida mudança.

Mikalef e Gupta (2021) transpôs 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 cooperativo entre áreas, capacidade de mudança organizacional e provisão para assumir riscos. Os autores verificaram empiricamente que essa capacidade está associado associado à criatividade organizacional e ao desempenho das empresas. Pará o argumento deste artigo, a contribuição é fundamental, 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 exclusivamente disponível em fonte de valor diferenciado, e cada um deles será examinado a seguir.

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

Machine Translated by Google

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 desenhadas 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 acelerar para 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 de inteligência da geração artificial, como modelos de processo documentados, regras de decisão explícitas, indicadores de desempenho e registros de execução. Sem esses artistas, a organização não dispõe de referência objetiva para definir o que o modelo deve fazer, quais limites devem ser respeitados e como seu resultado será avaliado.

A noção de maturidade foi consolidada pelo Modelo de Maturidade da Capacidade, desenvolvido no Instituto de Engenharia de Software. Paulk et al. (1993) descrevem cinco níveis sucessivos, denominados inicial, repetível, definido, gerenciado e otimizado, e mostrou 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 recursos fortes não se sustentam em empresas instituições organizacionais são frágeis. Décadas antes, o mesmo autor havia alertado que automatizar processos mal concebidos apenas acelerar a ineficiência, defendendo a 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 tendem 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 sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja devidamente citado.

Machine Translated by Google
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

Aalst (2016) descreve três tipos de técnicas aplicadas a registros de eventos dos sistemas de informação, que é 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 importantes entre o processo idealizado e o processo praticado, informação necessária 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. Uma inteligência artificial generativa amplia o alcance da automação para tarefas menos estruturadas, mas não dispensa a clara sobre objetivos, regras e abordagens.

A literatura recente de gestão de processos já incorpora especificamente a inteligência artificial em seu horizonte teórico. Dumas et al. (2023) pro proposto o conceito de sistemas de gestão de processos aprimorados por inteligência artificial, capazes de atuar com autonomia dentro de um quadro de restrições definidas 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 são previamente explicitados. Beverungen et al. (2021) Acrescenta que a gestão de processos em um mundo hiperconectado envolve esforços permanentes, como a convivência entre padronização e flexibilidade e entre controle e autonomia. Em resumo, processos maduros fornecem com precisão 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 a qualidade dos dados ao Investigue empiricamente se os próprios consumidores de dados são relevantes. Os autores concluíram que a qualidade dos dados significa adequação ao uso e identificaram quatro categorias de atributos, que são de qualidade intrínseca, relacionados a correção e correção, a qualidade contextual, relacionado a relevância, atualidade e completude, a qualidade representacional, relacionado à interpretabilidade e consistência, e à qualidade de acessibilidade. Essa abordagem multidimensional permanece atual, pois mostra que um dado pode ser correto e, ainda assim, inadequada para uso específico. 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 sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja devidamente citado.

Machine Translated by Google
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

operacionais superiores, decisões equivocadas e perda de confiança, muitas vezes sem que a origem do problema seja percebido 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 Destacam que a definição clara de responsabilidades é condição para que os dados sejam tratados como ativo. O guia de referência da DAMA International (2017) consolida 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 generativa artificial, a governança de metadados assume importância particular, pois a capacidade de um modelo interpretar corretamente uma informação depende de saber sua origem, seus dados de validade, seu significado e seu grau de confiabilidade.

A literatura de aprendizado de máquina fornece evidências relevantes sobre os efeitos da negligenciar com os dados. Sambasivan et al. (2021) entrevistaram 53 profissionais que desenvolveram sistemas de inteligência artificial em domínios de alto impacto e constataram que 92% deles tinham vivenciado ao menos uma cascata de dados, isto é, uma sequência de efeitos negativos acumulados e muitas vezes tardiamente percebidos, originados em problemas de dados. Os autores atribuem o afeta a desvalorização do trabalho com dados em comparação com o trabalho de desenvolvimento de modelos. Sculley et al. (2015) já foi demonstrado que, em sistemas de aprendizado de máquina em produção, o código do modelo representa uma pequena fração 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 focada em dados. Zha et al. (2023) descrevem essa abordagem como o posicionamento 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 mostrou que a qualidade dos dados de entrada condicional diretamente a robustez e o patrimônio 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, pro apresentado a documentação padronizada de conjuntos de dados, registrando motivação, composição, processo de coleta e usos recomendados, prática que aproxima a gestão de dados da critério de rastreabilidade típica de processos

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

Machine Translated by Google
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

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) pro essa colocada arquitetura, que combina a memória paramétrica do modelo com um índice não paramétrico de documentos consultados no momento da geração, e avanços 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, no entanto, uma implicação frequentemente subestimada. Quando o modelo passa a responder com base nos documentos internos da empresa, a confiabilidade a 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 conversão 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, recomendações governar, mapear, medir e gerenciar, e definir como características dos sistemas confiança a validade e a confiabilidade, a segurança, a segurança cibernética e a resiliência, a responsabilização e transparência, explicabilidade e interpretabilidade, proteção da privacidade e a equidade com gestão de vidas contratadas. A função governamental, posicionada como transversal às demais, exige políticas, papéis e responsabilidades formalmente definidas. Em termos práticos, trata-se de uma exigência de maturidade organizacional, pois não é possível mapear, medir ou gerenciamento de 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, integridade da informação, segurança da informação, propriedade intelectual e a configuração da interação entre humanos e inteligência artificial (NATIONAL INSTITUTO DE PADRÕES E TECNOLOGIA, 2024). O documento associa a cada risco ações sugeridas, organizadas segundo as quatro funções da estrutura original. Em paralelo, a norma ISO/IEC 42001 especifica 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 sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja devidamente citado.

Machine Translated by Google
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

ORGANIZAÇÃO PARA NORMALIZAÇÃO; ELETROTÉCNICA INTERNACIONAL
COMISSÃO, 2023). Ao adotar a lógica dos sistemas de gestão, a norma trata a inteligência artificial como objeto de processos documentados, auditáveis e sujeitos à 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, distribuída uma abordagem baseada em níveis de risco, com obrigação proporcionais ao potencial de dano de cada aplicação (UNIÃO EUROPEIA, 2024). Para sistemas classificado como de alto risco, o regulamento exige que os conjuntos de dados de treinamento, validação e testes sejam submetidos a práticas de governança e gestão de dados apropriadas pretendida, além de documentação técnica e registro de eventos que permitem a rastreabilidade do funcionamento. Para os modelos de inteligência artificial de propósito 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 opera, o texto sinaliza uma tendência normativa clara, segundo a qualidade de dados e rastreabilidade de processos deixa de ser boas práticas 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 privilegiam exclusivamente a A automação pode levar à perda de conhecimento e à dor organizacional. Shrestha, Ben-Menahem e Von Krogh (2019) para estabelecer 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 das características do problema, como a necessidade de interpretabilidade, o tamanho do espaço de alternativas e a velocidade são comuns. O estudo de Dell'Acqua et al. (2023) Demonstramos, adicionalmente, que os consultores que utilizaram o modelo em uma tarefa definida fora de sua fronteira de desempenho teve 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 obtiveram melhores resultados com uma abordagem incremental do que com iniciativas transformadoras de grande ambição, e recomendo 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 sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja devidamente citado.

Machine Translated by Google
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

observaram que a maioria das empresas permanece presa a projetos piloto isolados e que a escala depende de romper silos entre áreas, formar equipes multidisciplinares e substituir decisões básicas 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 o valor do negócio é um pouco claro, exigindo precisamente às lacunas de governança, de dados e de processos discutidos ao longo deste artigo.

9 CONCLUSÃO

Este artigo examina, à luz da literatura publicada até dezembro de 2024, as condições organizações que permitem inteligência artificial generativa produzindo valor real. Uma análise partiu do contraste entre a rápida adoção da tecnologia e os sinais de frustração registrados em pesquisas de mercado e chegou a uma decisão 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 confiabilidade dos dados.

No plano técnico, é garantido que os modelos de linguagem de grande escala aprendem regularidades estatísticas e obtidas continuações plausíveis, o que não equivale a produção de conteúdo verdadeiro. Uma literatura sobre alucinação e confabulação mostra que esse limite é estrutural e não um defeito pontual a ser excluído por versões futuras. Por essa razão, a confiabilidade deve ser compreendida como propriedade do sistema sociotécnico, que reúne modelos, 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. Quando a tarefa ultrapassou a fronteira de capacidade do modelo, o uso da ferramenta prejudicou o desempenho, o que demonstrar 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 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 sob a licença CreativeCommons Attribution, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o trabalho original seja devidamente citado.

Machine Translated by Google

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

Uma visão baseada em recursos permite concluir que o acesso a modelos de linguagem de uso geral embora a vantagem competitiva seja sustentável, uma vez que se trata de recurso extremamente disponível. A diferença 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 aumentos por inteligência artificial indicam que a autonomia útil de um sistema depende de um enquadramento previamente definido. Processos documentados, mensurados e com responsáveis claramente mencionados, fornecendo 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.
Uma literatura sobre qualidade e governança de dados demonstra que problemas de dados têm origem mais frequentes de falhas em sistemas de inteligência artificial e que seus efeitos costumam ser cumulativos e tardiamente percebidos. A prevenção 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 estrutural.

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, autorizar-se que parte das evidências comprovadas de documentos de trabalho e de relatórios institucionais, e que o estudo não foi testado 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 a qualidade dos dados explica a variação dos resultados obtidos com a tecnologia.

REFERÊNCIAS

AMERSHI, S. et al. Engenharia de software para aprendizado de máquina: um estudo de caso. In: CONFERÊNCIA INTERNACIONAL DE ENGENHARIA DE SOFTWARE: ENGENHARIA DE SOFTWARE NA PRÁTICA, 41., 2019, Montreal. **Anais** [...]. Piscataway: IEEE, 2019. p. 291-300.

BARNEY, J. Recursos da empresa e vantagem competitiva sustentada. **Journal of Management,** v. 17, n. 1, p. 99-120, 1991.

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

Machine Translated by Google

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

BENDER, EM et al. Sobre os perigos dos papagaios estocásticos: os modelos de linguagem podem ser grandes demais? In: ACM CONFERENCE ON FAIRNESS, ACCOUNTABILITY, AND TRANSPARENCY, 2021, [S. l.]. **Proceedings** [...]. New York: ACM, 2021. p. 610-623.

BEVERUNGEN, D. et al. Sete paradoxos da gestão de processos de negócios em um mundo hiperconectado. **Business & Information Systems Engineering,** v. 63, n. 2, p. 145-156, 2021.

BHARADWAJ, AS. Uma perspectiva baseada em recursos sobre a capacidade da tecnologia da informação e o desempenho da empresa: uma investigação empírica. **MIS Quarterly,** v. 24, n. 1, p. 169-196, 2000.

BOMMASANI, R. et al. **Sobre as oportunidades e os riscos dos modelos de fundação.** Stanford: Centro de Pesquisa em Modelos de Fundação, 2021. arXiv:2108.07258.

BRESNAHAN, TF; TRAJTENBERG, M. Tecnologias de propósito geral: 'motores de crescimento'? **Revista de Econometria,** v. 65, n. 1, p. 83-108, 1995.

BROWN, TB et al. Modelos de linguagem são aprendizes com poucos exemplos. **Advances in Neural Information Processing Systems,** v. 33, p. 1877-1901, 2020.

BRYNJOLFSSON, E.; HITT, LM Além da computação: tecnologia da informação, transformação organizacional e desempenho empresarial. **Journal of Economic Perspectives,** v. 14, n. 4, p. 23-48, 2000.

BRYNJOLFSSON, E.; LI, D.; RAYMOND, LR. **IA generativa em ação.** Cambridge: National Bureau of Economic Research, 2023. (NBER Working Paper, n. 31161).

BRYNJOLFSSON, E.; ROCK, D.; SYVERSON, C. A curva J da produtividade: como os ativos intangíveis complementam as tecnologias de uso geral. **American Economic Journal: Macroeconomics,** v. 13, n. 1, p. 333-372, 2021.

CHUI, M. et al. **O potencial econômico da IA generativa:** a próxima fronteira da produtividade. [S. l.]: McKinsey Global Institute, 2023.

DAMA INTERNATIONAL. **DAMA-DMBOK:** corpo de conhecimento em gestão de dados. 2ª ed. Basking Ridge: Technics Publications, 2017.

DAVENPORT, TH **Inovação de processos:** reengenharia do trabalho por meio da tecnologia da informação. Boston: Harvard Business School Press, 1993.

DAVENPORT, TH; RONANKI, R. Inteligência artificial para o mundo real. **Harvard Business Review,** v. 96, n. 1, p. 108-116, 2018.

DELL'ACQUA, F. et al. **Navegando pela fronteira tecnológica irregular:** evidências experimentais de campo dos efeitos da IA na produtividade e qualidade dos trabalhadores do conhecimento. Boston: Harvard Business School, 2023. (Working Paper, n. 24-013).

DUMAS, M. et al. **Fundamentos da gestão de processos de negócios.** 2ª ed. Berlim: Springer, 2018.

DUMAS, M. et al. Sistemas de gerenciamento de processos de negócios aumentados por IA: um manifesto de pesquisa. **ACM Transactions on Management Information Systems,** v. 14, n. 1, art. 11, p. 1-19, 2023.

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

Machine Translated by Google

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

ELOUNDOU, T. et al. **GPTs são GPTs:** uma análise inicial do potencial de impacto no mercado de trabalho de grandes modelos de linguagem. [S. l.]: arXiv, 2023. arXiv:2303.10130.

UNIÃO EUROPEIA. Regulamento (UE) 2024/1689 do Parlamento Europeu e do Conselho, de 13 de junho de 2024, que estabelece regras harmonizadas em matéria de inteligência artificial (Lei da Inteligência Artificial). **Jornal Oficial da União Europeia,** Luxemburgo, série L, 12 de julho de 2024.

FOUNTAINE, T.; McCARTHY, B.; SALEH, T. Construindo a organização impulsionada por IA. **Harvard Business Review,** v. 97, n. 4, p. 62-73, 2019.

GAO, Y. et al. **Geração aumentada por recuperação para grandes modelos de linguagem:** uma revisão. [S. l.]: arXiv, 2023. arXiv:2312.10997.

Gartner **prevê que 30% dos projetos de IA generativa serão abandonados após a prova de conceito até o final de 2025.** Sydney: Gartner, 29 de julho de 2024. Comunicado de imprensa.

GEBRU, T. et al. Folhas de dados para conjuntos de dados. **Communications of the ACM,** v. 64, n. 12, p. 86-92, 2021.

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

HAMMER, M. Reengenharia do trabalho: não automatize, elimine. **Harvard Business Review,** v. 68, n. 4, p. 104-112, 1990.

HAMMER, M. A auditoria de processos. **Harvard Business Review,** v. 85, n. 4, p. 111-123, 2007.

HUANG, L. et al. **Um levantamento sobre alucinações em grandes modelos de linguagem:** princípios, taxonomia, desafios e questões em aberto. [S. l.]: arXiv, 2023. arXiv:2311.05232.

ORGANIZAÇÃO INTERNACIONAL DE NORMALIZAÇÃO; COMISSÃO ELETROTÉCNICA INTERNACIONAL. **ISO/IEC 42001:** Tecnologia da informação, inteligência artificial, sistema de gestão. Genebra: ISO, 2023.

JI, Z. et al. Levantamento de alucinações na geração de linguagem natural. **ACM Computing Surveys,** v. 55, n. 12, art. 248, p. 1-38, 2023.

KAPLAN, J. et al. **Leis de escala para modelos de linguagem neural.** [S. l.]: arXiv, 2020. arXiv:2001.08361.

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

LEWIS, P. et al. Geração aumentada por recuperação para tarefas de PNL intensivas em conhecimento. **Advances in Neural Information Processing Systems,** v. 33, p. 9459-9474, 2020.

MIKALEF, P.; GUPTA, M. Capacidade de inteligência artificial: conceitualização, calibração de medição e estudo empírico sobre seu impacto na criatividade organizacional e no desempenho da empresa. **Informação e Gestão,** v. 58, n. 3, art. 103434, 2021.

INSTITUTO NACIONAL DE PADRÕES E TECNOLOGIA. **Risco da inteligência artificial**

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

Machine Translated by Google

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

Estrutura de gestão (AI RMF 1.0). Gaithersburg: NIST, 2023. (NIST AI 100-1).

INSTITUTO NACIONAL DE PADRÕES E TECNOLOGIA. **Estrutura de gerenciamento de riscos de inteligência artificial:** perfil de inteligência artificial generativa. Gaithersburg: NIST, 2024. (NIST AI 600-1).

NOY, S.; ZHANG, W. Evidências experimentais sobre os efeitos da inteligência artificial generativa na produtividade. **Science,** v. 381, n. 6654, p. 187-192, 2023.

OUYANG, L. et al. Treinamento de modelos de linguagem para seguir instruções com feedback humano. **Advances in Neural Information Processing Systems,** v. 35, p. 27730-27744, 2022.

PAULK, MC et al. Modelo de maturidade de capacidade, versão 1.1. **IEEE Software,** v. 10, n. 4, p. 18-27, 1993.

POLYZOTIS, N. et al. Desafios do ciclo de vida dos dados em aprendizado de máquina em produção: uma revisão. **ACM SIGMOD Record,** v. 47, n. 2, p. 17-28, 2018.

RAISCH, S.; KRAKOWSKI, S. Inteligência artificial e gestão: o paradoxo da automação-aumento. **Academy of Management Review,** v. 46, n. 1, p. 192-210, 2021.

REDMAN, TC. **Orientado por dados:** lucrando com o ativo mais importante do seu negócio. Boston: Harvard Business Press, 2008.

ROSEMANN, M.; DE BRUIN, T. Rumo a um modelo de maturidade de gestão de processos de negócios. In: 13ª Conferência Europeia de Sistemas de Informação, 2005, Regensburg.
Atas [...]. Regensburg: ECIS, 2005.

SAMBASIVAN, N. et al. "Todos querem fazer o trabalho de modelagem, não o trabalho de dados": cascatas de dados em IA de alto risco. In: CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS, 2021, Yokohama. **Proceedings** [...]. New York: ACM, 2021. p. 1-15.

SCULLEY, D. et al. Dívida técnica oculta em sistemas de aprendizado de máquina. **Advances in Neural Information Processing Systems,** v. 28, p. 2503-2511, 2015.

SHRESTHA, YR; BEN-MENAHEM, SM; VON KROGH, G. Estruturas de tomada de decisão organizacional na era da inteligência artificial. **California Management Review,** v. 61, n. 4, p. 66-83, 2019.

SINGLA, A. et al. **O estado da IA no início de 2024:** a adoção da IA de geração de energia dispara e começa a gerar valor. [S. l.]: McKinsey & Company, 2024.

SNYDER, H. Revisão de literatura como metodologia de pesquisa: uma visão geral e diretrizes. **Journal of Business Research,** v. 104, p. 333-339, 2019.

TEECE, DJ; PISANO, G.; SHUEN, A. Capacidades dinâmicas e gestão estratégica. **Strategic Management Journal,** v. 18, n. 7, p. 509-533, 1997.

VAN DER AALST, WMP **Mineração de processos:** ciência de dados em ação. 2. ed. Berlim: Springer, 2016.

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

Machine Translated by Google

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

VAN DER AALST, WMP; BICHLER, M.; HEINZL, A. Automação robótica de processos. **Business & Information Systems Engineering,** v. 60, n. 4, p. 269-272, 2018.

VASWANI, A. et al. Atenção é tudo o que você precisa. **Advances in Neural Information Processing Systems,** v. 30, p. 5998-6008, 2017.

WANG, RY; STRONG, DM Além da precisão: o que a qualidade dos dados significa para os consumidores de dados. **Revista de Sistemas de Informação Gerencial,** v. 12, n. 4, p. 5-33, 1996.

WEBSTER, J.; WATSON, RT. Analisando o passado para preparar o futuro: escrevendo uma revisão da literatura. **MIS Quarterly,** v. 26, n. 2, p. xiii-xxiii, 2002.

WHANG, SE et al. Desafios de coleta e qualidade de dados em aprendizado profundo: uma perspectiva de IA centrada em dados. **The VLDB Journal,** v. 32, n. 4, p. 791-813, 2023.

ZHA, D. et al. **Inteligência artificial centrada em dados:** uma revisão. [S. l.]: arXiv, 2023. arXiv:2303.10158.

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