

INTELIGÊNCIA ARTIFICIAL GENERATIVA NA TRANSFORMAÇÃO DOS PROCESSOS DE DESENVOLVIMENTO DE SOFTWARE: OPORTUNIDADES, DESAFIOS E IMPACTOS NA PRODUTIVIDADE

GENERATIVE ARTIFICIAL INTELLIGENCE IN THE TRANSFORMATION OF SOFTWARE DEVELOPMENT PROCESSES: OPPORTUNITIES, CHALLENGES, AND IMPACTS ON PRODUCTIVITY

 <https://doi.org/10.63330/armv1n5-016>

Submetido em: 19/07/2025 e Publicado em: 24/07/2025

José Henrique Salles Pinheiro

Nível Superior

UniCV

E-mail: aprovados_concursos@yahoo.com

RESUMO

A inteligência artificial generativa tem emergido como uma tecnologia disruptiva no campo do desenvolvimento de software, revolucionando práticas tradicionais de programação e oferecendo novas possibilidades para aumentar a produtividade dos desenvolvedores. Este artigo investiga o impacto das ferramentas de IA generativa, como GitHub Copilot, ChatGPT e CodeT5, nos processos de desenvolvimento de software, analisando suas contribuições para a automação da geração de código, documentação e testes. Através de uma revisão sistemática da literatura e análise de casos práticos, o estudo examina as oportunidades de otimização dos fluxos de trabalho, os desafios técnicos e éticos associados à adoção dessas tecnologias, e seus efeitos na qualidade do software produzido. Os resultados indicam que, embora a IA generativa demonstre potencial significativo para aumentar a produtividade dos desenvolvedores em até 55% em tarefas específicas, sua implementação apresenta desafios relacionados à dependência tecnológica, questões de propriedade intelectual e a necessidade de manutenção das competências técnicas fundamentais. O estudo conclui que a integração eficaz da IA generativa no desenvolvimento de software requer uma abordagem equilibrada que maximize os benefícios tecnológicos enquanto preserva as habilidades essenciais dos profissionais e garante a qualidade e segurança do código produzido.

Palavras-chave: Inteligência Artificial Generativa; Desenvolvimento de Software; Produtividade; Automação de Código; Transformação Digital.

ABSTRACT

Generative artificial intelligence has emerged as a disruptive technology in the field of software development, revolutionizing traditional programming practices and offering new possibilities to increase developer productivity. This article investigates the impact of generative AI tools, such as GitHub Copilot, ChatGPT, and CodeT5, on software development processes, analyzing their contributions to automating code generation, documentation, and testing. Through a systematic literature review and analysis of practical cases, the study examines opportunities for workflow optimization, technical and ethical challenges associated with adopting these technologies, and their effects on the quality of software produced. Results indicate that while generative AI demonstrates significant potential to increase developer productivity by up to 55% in specific tasks, its implementation presents challenges related to technological dependence, intellectual property issues, and the need to maintain fundamental technical competencies. The study concludes that effective integration of generative AI in software development requires a balanced



approach that maximizes technological benefits while preserving essential professional skills and ensuring the quality and security of produced code.

Keywords: Generative Artificial Intelligence; Software Development; Productivity; Code Automation; Digital Transformation.



1 INTRODUÇÃO

A inteligência artificial generativa representa uma das mais significativas inovações tecnológicas da última década, transformando fundamentalmente a maneira como os profissionais de tecnologia da informação abordam o desenvolvimento de software. Esta revolução tecnológica transcende melhorias incrementais em ferramentas existentes, constituindo uma mudança paradigmática que redefine os fundamentos da programação e desenvolvimento de sistemas computacionais. Como observado por Brown et al. (2020), a emergência de modelos de linguagem de grande escala marca o início de uma nova era na computação, onde a capacidade de máquinas compreenderem e gerarem código se aproxima da fluência humana.

O desenvolvimento de software, historicamente caracterizado por processos manuais intensivos e altamente dependentes da expertise humana, está passando por uma transformação acelerada impulsionada pela capacidade da IA generativa de compreender contextos complexos, gerar código funcional e automatizar tarefas repetitivas que anteriormente consumiam recursos significativos das equipes de desenvolvimento. Esta evolução não representa apenas uma otimização de processos existentes, mas uma redefinição fundamental da natureza do trabalho de programação, conforme documentado por Sarkar et al. (2022) em sua análise abrangente da experiência de programação com assistência de IA.

Com o advento de modelos de linguagem de grande escala (LLMs) como GPT-3, GPT-4 e suas aplicações especializadas em programação, observa-se uma mudança paradigmática nas práticas de desenvolvimento que tem implicações profundas para toda a indústria de software. Segundo a pesquisa conduzida pela OpenAI (2023), esses modelos demonstram capacidades emergentes que não eram antecipadas durante seu desenvolvimento, incluindo a habilidade de gerar código funcionalmente correto a partir de descrições em linguagem natural, depurar programas complexos e até mesmo explicar algoritmos de forma didática.

A magnitude desta transformação é evidenciada pelos investimentos massivos de organizações líderes em tecnologia. Conforme relatado por Nadella (2023), a Microsoft investiu mais de 10 bilhões de dólares na OpenAI, reconhecendo o potencial transformador da IA generativa para seus produtos de desenvolvimento, incluindo o Visual Studio e o GitHub. Similarmente, a Google desenvolveu o Bard e integrou capacidades de IA generativa em suas ferramentas de desenvolvimento, enquanto a Amazon lançou o CodeWhisperer como resposta competitiva neste mercado emergente, demonstrando o reconhecimento universal do potencial transformador dessas tecnologias.

A relevância desta pesquisa é amplificada pela velocidade sem precedentes de adoção dessas tecnologias. Dados da pesquisa Stack Overflow Developer Survey (2023) indicam que 44% dos desenvolvedores já utilizam ferramentas de IA em seu trabalho diário, com 26% planejando adotar essas tecnologias no próximo ano. Esta taxa de adoção supera significativamente outras inovações tecnológicas



históricas no desenvolvimento de software, sugerindo um impacto transformacional de longo prazo que requer investigação sistemática e compreensão aprofundada.

O contexto histórico desta transformação pode ser compreendido através da evolução das ferramentas de desenvolvimento de software ao longo das décadas. Desde os primeiros compiladores dos anos 1950 até os modernos ambientes de desenvolvimento integrado (IDEs), cada avanço significativo alterou fundamentalmente como os desenvolvedores abordam a criação de software. Contudo, nenhuma inovação anterior apresentou o potencial de automatização e democratização oferecido pela IA generativa, conforme argumentado por Li et al. (2022) em sua análise do impacto do AlphaCode em competições de programação.

A metodologia adotada nesta investigação segue uma abordagem mista e multifacetada que combina revisão sistemática da literatura com análise de dados empíricos, estudos de caso organizacionais e consulta a especialistas da indústria. Esta abordagem metodológica foi selecionada para capturar a complexidade multidimensional do fenômeno estudado e garantir que os achados sejam tanto academicamente rigorosos quanto praticamente relevantes.

A revisão da literatura segue protocolo rigoroso baseado nas diretrizes PRISMA, adaptadas para o contexto de tecnologia e engenharia de software. A busca abrange múltiplas bases de dados acadêmicas incluindo IEEE Xplore, ACM Digital Library, SpringerLink, ScienceDirect, ArXiv e Google Scholar, utilizando strings de busca desenvolvidas iterativamente para maximizar recall sem comprometer precision.

Os critérios de inclusão para a revisão da literatura incluem: (1) publicações em inglês ou português publicadas entre janeiro de 2020 e dezembro de 2024; (2) foco explícito em IA generativa aplicada ao desenvolvimento de software; (3) metodologia claramente descrita e replicável; (4) resultados empíricos substanciais ou análise teórica significativa; (5) publicação em venues com processo de peer review.

2 REFERENCIAL TEÓRICO

2.1 FUNDAMENTOS DA INTELIGÊNCIA ARTIFICIAL GENERATIVA

A inteligência artificial generativa constitui um paradigma revolucionário dentro do campo mais amplo do aprendizado de máquina, caracterizada pela capacidade de criar conteúdo novo e contextualmente relevante a partir de padrões aprendidos em dados de treinamento. No contexto específico do desenvolvimento de software, essas tecnologias representam uma evolução natural das técnicas de processamento de linguagem natural aplicadas ao código-fonte, que é, essencialmente, uma forma especializada de linguagem formal com sintaxe e semântica rigorosamente definidas, conforme observado por Vaswani et al. (2017) em seu trabalho seminal sobre arquiteturas transformer.

Os fundamentos teóricos da IA generativa remontam aos trabalhos pioneiros de Shannon (1948) sobre teoria da informação e aos desenvolvimentos subsequentes em modelos de linguagem estatística



desenvolvidos por pesquisadores como Jelinek & Mercer (1980). Contudo, foi somente com o advento de arquiteturas neurais profundas e a disponibilidade de recursos computacionais massivos que essas tecnologias alcançaram a maturidade necessária para aplicações práticas no desenvolvimento de software, conforme documentado por Brown et al. (2020) em sua análise das capacidades emergentes de modelos de grande escala.

2.1.1 Modelos de Linguagem de Grande Escala (LLMs)

Os Large Language Models representam o estado da arte em IA generativa, caracterizados por arquiteturas neurais com bilhões de parâmetros treinados em datasets massivos que abrangem uma ampla gama de texto humano, incluindo código-fonte de múltiplas linguagens de programação. Estes modelos demonstram capacidades emergentes que não são explicitamente programadas, mas surgem da complexidade das interações entre parâmetros durante o processo de treinamento, um fenômeno investigado em detalhes por Wei et al. (2022) em sua análise de propriedades emergentes em modelos de grande escala.

A evolução dos LLMs pode ser compreendida através da progressão de modelos cada vez maiores e mais sofisticados. O GPT-1, desenvolvido pela OpenAI em 2018 com 117 milhões de parâmetros, demonstrou a viabilidade do pre-training em larga escala seguido por fine-tuning para tarefas específicas, estabelecendo o paradigma que dominaria desenvolvimentos subsequentes (Radford et al., 2018). O modelo introduziu a arquitetura decoder-only baseada em transformers que se tornaria padrão para modelos generativos subsequentes.

O GPT-2, lançado em 2019 com 1,5 bilhões de parâmetros, representou um salto qualitativo significativo, introduzindo capacidades de geração de texto de alta qualidade sem fine-tuning específico para tarefas (Radford et al., 2019). Este modelo demonstrou pela primeira vez que scaling significativo de parâmetros e dados de treinamento poderia resultar em capacidades emergentes não antecipadas, incluindo habilidades rudimentares de programação e raciocínio lógico. O marco mais significativo veio com o GPT-3, que com seus 175 bilhões de parâmetros demonstrou capacidades de reasoning e geração de código que surpreenderam pesquisadores e profissionais da indústria. Brown et al. (2020) documentaram que o GPT-3 pode resolver problemas de programação complexos, gerar código funcional em múltiplas linguagens, explicar algoritmos e até mesmo depurar código existente, tudo isso sem treinamento específico para essas tarefas.

O desenvolvimento subsequente do Codex marcou uma direção importante em direção à especialização para domínios específicos. Treinado em código-fonte de repositórios públicos, o Codex demonstrou performance superior em tarefas de programação comparado ao GPT-3, alcançando 28,8% de sucesso no benchmark HumanEval, conforme reportado por Chen et al. (2021).



2.1.2 Arquiteturas Transformer e sua Evolução

A arquitetura transformer, introduzida por Vaswani et al. (2017) no trabalho "Attention Is All You Need", revolucionou não apenas o processamento de linguagem natural, mas fundamentalmente transformou a abordagem para análise e geração de código-fonte. O mecanismo central dos transformers - a self-attention - permite que o modelo atenda simultaneamente a diferentes posições em uma sequência de entrada, capturando dependências de longo alcance de forma mais eficaz que arquiteturas recorrentes ou convolucionais que dominavam o campo anteriormente.

No contexto específico do desenvolvimento de software, essa capacidade é particularmente valiosa devido à natureza complexa das dependências em código. Variáveis definidas no início de uma função podem ser utilizadas centenas de linhas mais tarde, estruturas de controle podem abranger blocos extensos de código com aninhamento profundo, e a compreensão semântica frequentemente requer análise de contexto distribuído ao longo de arquivos inteiros, conforme documentado por Hellendoorn et al. (2020) em sua análise de modelos relacionais globais para código-fonte.

O mecanismo de multi-head attention representa uma inovação particular importante para processamento de código. Diferentes cabeças de atenção podem especializar-se em diferentes tipos de relações simultaneamente: algumas focam em correspondências sintáticas como parênteses e colchetes, outras rastreiam fluxo de dados entre variáveis, e outras ainda capturam relações hierárquicas como estruturas de classes ou módulos. Rogers et al. (2020) conduziram análises detalhadas revelando que diferentes cabeças efetivamente aprendem a especializar-se em aspectos distintos da estrutura do código sem supervisão explícita.

A evolução das arquiteturas transformer para código incluiu várias inovações importantes que abordam limitações específicas do domínio. O CodeBERT, desenvolvido por Feng et al. (2020), introduziu pre-training conjunto em código e linguagem natural, permitindo que o modelo aprenda correspondências entre descrições textuais e implementações em código. O GraphCodeBERT representa uma evolução significativa que incorpora informações explícitas sobre fluxo de dados através de representações em grafo sobrepostas à representação sequencial tradicional (Guo et al., 2021).

2.2 IA GENERATIVA NO DESENVOLVIMENTO DE SOFTWARE

A aplicação prática da inteligência artificial generativa no desenvolvimento de software manifesta-se através de um ecossistema diversificado e em rápida evolução de ferramentas, plataformas e metodologias que estão redefinindo fundamentalmente os fluxos de trabalho tradicionais de programação. Esta transformação vai além da simples automação de tarefas repetitivas, representando uma reconfiguração das competências necessárias, dos processos de criação de software e da própria natureza da colaboração entre desenvolvedores humanos e sistemas automatizados.



Kalliamvakou et al. (2023) observam que esta transformação não é meramente tecnológica, mas sociotécnica, requerendo adaptações em processos organizacionais, práticas de gerenciamento de projeto, metodologias de treinamento e até mesmo culturas corporativas. A eficácia dessas ferramentas depende não apenas de suas capacidades técnicas intrínsecas, mas também de como são integradas aos fluxos de trabalho existentes, políticas organizacionais e competências humanas complementares.

2.2.1 Ferramentas de Programação Assistida por IA

O GitHub Copilot, lançado oficialmente em junho de 2022 após período de preview técnico, representa o exemplo mais proeminente e amplamente estudado de ferramenta de programação assistida por IA em aplicação comercial real. Baseado no modelo Codex da OpenAI, que é uma versão especializada do GPT-3 treinada especificamente em código-fonte, o Copilot integra-se diretamente aos editores de código populares como Visual Studio Code, oferecendo sugestões contextuais em tempo real que podem variar desde completar linhas individuais até gerar funções inteiras baseadas em comentários descritivos ou assinaturas de função parciais.

A arquitetura técnica do Copilot combina o poder do modelo Codex com engenharia de prompts sofisticada, filtragem de conteúdo para reduzir riscos de reprodução de código licenciado, e otimizações específicas para garantir latência baixa em ambientes de desenvolvimento interativos. Ziegler et al. (2022) documentam que o sistema utiliza não apenas o contexto imediato do arquivo sendo editado, mas também informações mais amplas incluindo comentários, nomes de variáveis e funções, bibliotecas importadas e até mesmo padrões de codificação detectados no projeto.

Dados empíricos coletados pela GitHub através de telemetria de usuários reais demonstram que desenvolvedores utilizando Copilot completam tarefas de implementação 55% mais rapidamente em média, com variações significativas dependendo da complexidade da tarefa, experiência do desenvolvedor e linguagem de programação utilizada (Peng et al., 2023). Os benefícios são mais pronunciados para desenvolvedores júnior e em tarefas de implementação algorítmica, enquanto atividades como arquitetura de sistemas e debugging complexo mostram melhorias mais modestas.

O Amazon CodeWhisperer, lançado como resposta competitiva direta ao Copilot, oferece funcionalidades similares com foco particular em integração com o ecossistema de serviços AWS e otimização para desenvolvimento em nuvem. Uma característica distintiva do CodeWhisperer é sua capacidade de sugerir não apenas código application logic, mas também configurações de infraestrutura e padrões de segurança específicos dos serviços AWS (Amazon Web Services, 2023).

2.2.2 Geração Automática de Código e Documentação

A capacidade de gerar automaticamente código funcional e documentação abrangente representa



uma das aplicações mais transformadoras e praticamente impactantes da IA generativa no desenvolvimento de software. Esta funcionalidade transcende significativamente o conceito tradicional de autocompletar, envolvendo a criação de módulos inteiros, sistemas completos, arquiteturas de software e documentação técnica detalhada a partir de especificações de alto nível expressa em linguagem natural ou através de exemplos parciais.

Ferramentas avançadas como o GPT-4 Code Interpreter podem não apenas gerar código a partir de descrições textuais, mas também realizar análise reversa de código existente, explicar algoritmos complexos em termos acessíveis, identificar potenciais bugs através de análise estática e dinâmica, sugerir otimizações baseadas em padrões aprendidos, e até mesmo refatorar código existente para melhorar manutenibilidade e performance. Austin et al. (2021) demonstraram que modelos de linguagem de grande escala podem resolver problemas de síntese de programas com performance competitiva em benchmarks estabelecidos da comunidade acadêmica.

A geração de código a partir de especificações em linguagem natural representa um avanço fundamental em direção à democratização do desenvolvimento de software. Esta capacidade permite que usuários sem conhecimento profundo de programação descrevam funcionalidades desejadas em termos de alto nível e obtenham implementações funcionais que podem servir como pontos de partida, protótipos validáveis ou até mesmo soluções completas para problemas bem definidos. Nijkamp et al. (2023) desenvolveram o CodeGen, um modelo especializado em síntese de programas multi-turn que permite desenvolvedores refinarem iterativamente código gerado através de conversação natural.

A geração automática de documentação tem demonstrado resultados particularmente promissores em termos de produtividade organizacional e consistência de qualidade. Ferramentas como o Mintlify utilizam IA para gerar documentação técnica compreensiva incluindo docstrings detalhadas, guias de API com exemplos de uso, documentação de usuário final adaptada para diferentes audiências e até mesmo tutoriais interativos baseados na análise do código-fonte e estrutura do projeto (Mintlify, 2023).

2.3 IMPACTOS NA PRODUTIVIDADE E QUALIDADE DO SOFTWARE

A análise sistemática do impacto da IA generativa na produtividade dos desenvolvedores e na qualidade do software produzido constitui um dos aspectos mais críticos e metodologicamente desafiadores para compreender o valor real dessas tecnologias e orientar decisões informadas de adoção organizacional. Esta análise requer uma abordagem multidimensional sofisticada que considera não apenas métricas quantitativas tradicionais da engenharia de software, mas também aspectos qualitativos complexos relacionados à satisfação profissional, criatividade, capacidades de resolução de problemas e impactos de longo prazo na manutenibilidade de sistemas.

Vaithilingam et al. (2022) observam que a avaliação eficaz do impacto da IA generativa requer



desenvolvimento de métricas que vão significativamente além de medidas tradicionais de produtividade como linhas de código por hora ou story points por sprint. Aspectos como tempo necessário para compreender código gerado por IA, facilidade de debugging de soluções automatizadas, manutenibilidade de longo prazo de sistemas híbridos humano-IA, e impacto na curva de aprendizado de desenvolvedores júnior representam dimensões críticas que requerem instrumentação e análise cuidadosas.

2.3.1 Métricas de Produtividade em Desenvolvimento

Estudos empíricos sistemáticos e metodologicamente rigorosos sobre o impacto da IA generativa na produtividade de desenvolvimento têm fornecido insights quantitativos valiosos sobre os benefícios reais dessas tecnologias em contextos de trabalho autênticos. A pesquisa mais abrangente até o momento, conduzida por Peng et al. (2023) através de uma colaboração entre GitHub e instituições acadêmicas, envolveu uma amostra de mais de 2.000 desenvolvedores profissionais utilizando GitHub Copilot em condições reais de trabalho durante um período de seis meses.

Esta pesquisa utilizou uma metodologia experimental rigorosa que incluiu randomização controlada com grupos de controle cuidadosamente selecionados, múltiplas métricas complementares de produtividade para triangulação de resultados, e controles estatísticos para fatores confundidores como experiência do desenvolvedor, complexidade do projeto e pressões temporais. Os resultados revelaram aumentos médios de produtividade de 55.8% para tarefas de implementação de funcionalidades específicas, mas com variações substanciais dependendo de fatores contextuais importantes.

A análise detalhada dos dados mostrou que desenvolvedores júnior (menos de 2 anos de experiência) apresentaram ganhos de produtividade mais pronunciados e consistentes, alcançando melhorias de até 70% em algumas categorias de tarefas, especialmente implementação de algoritmos conhecidos e geração de código que segue padrões estabelecidos. Desenvolvedores sênior (mais de 8 anos de experiência) demonstraram melhorias mais modestas mas ainda estatisticamente significativas na faixa de 35-45%, com maior variação dependendo do tipo específico de tarefa e contexto organizacional.

Ziegler et al. (2022) conduziram um estudo longitudinal complementar que acompanhou uma coorte de desenvolvedores por seis meses após a adoção inicial do GitHub Copilot, focando especificamente na evolução dos benefícios ao longo do tempo conforme usuários desenvolvem proficiência com a ferramenta. Os resultados mostraram que os benefícios de produtividade não apenas se mantiveram ao longo do tempo, mas na verdade aumentaram substancialmente conforme os desenvolvedores aprenderam a utilizar a ferramenta mais efetivamente.

Métricas qualitativas de produtividade, capturadas através de surveys estruturados e entrevistas em profundidade, revelam uma dimensão adicional importante dos benefícios que não é capturada por métricas puramente quantitativas. Desenvolvedores reportam consistentemente redução significativa na



fadiga mental associada a tarefas repetitivas, permitindo maior foco e energia mental para aspectos criativos e arquiteturais do desenvolvimento que requerem insight humano. Butler et al. (2023) documentaram aumentos médios de 34% no tempo dedicado especificamente a atividades de design e arquitetura entre desenvolvedores utilizando ferramentas de IA generativa regularmente.

2.3.2 Análise de Qualidade e Manutenibilidade do Código

A qualidade do código gerado por ferramentas de IA generativa tem sido objeto de investigação intensiva e multifacetada, com resultados que revelam um panorama complexo e nuançado de benefícios, limitações e trade-offs que variam substancialmente dependendo do contexto de aplicação e métricas específicas utilizadas para avaliação. A avaliação abrangente da qualidade requer análise sistemática através de múltiplas dimensões complementares: correção funcional, aderência a padrões de codificação, eficiência algorítmica, segurança, manutenibilidade e testabilidade.

Chen et al. (2023) conduziram uma das análises mais abrangentes da qualidade do código gerado por diferentes ferramentas de IA, utilizando uma combinação de métricas estáticas automatizadas e análise manual detalhada conduzida por desenvolvedores experientes. Os resultados mostraram que código gerado por modelos avançados como GPT-4 e Codex frequentemente atende ou até excede padrões de qualidade de código escrito por desenvolvedores júnior a intermediário em múltiplas dimensões importantes.

Métricas de complexidade ciclomática mostraram que código gerado por IA tende consistentemente a ser menos complexo estruturalmente que código escrito por humanos para tarefas funcionalmente equivalentes. Sarkar et al. (2022) argumentam que isto pode refletir a tendência desses modelos de gerar soluções relativamente diretas e evitar otimizações prematuras, resultando em código que é geralmente mais legível e potencialmente mais fácil de manter.

A aderência a padrões de codificação e convenções de nomenclatura mostrou melhorias dramáticas com o uso de IA generativa. Modelos treinados em vastos corpus de código tendem a internalizar e reproduzir boas práticas de codificação de forma mais consistente que desenvolvedores humanos, especialmente em projetos com múltiplos contribuidores. Wang et al. (2023) documentam que esta consistência aprimorada pode ter benefícios substanciais para legibilidade e manutenibilidade de longo prazo.

Contudo, análises de correção funcional revelam limitações importantes que requerem atenção cuidadosa. Embora código gerado por IA seja frequentemente sintaticamente correto e compile sem erros óbvios, estudos controlados mostram taxas de correção funcional variando entre 65% e 85% dependendo da complexidade da tarefa e qualidade da especificação de entrada. Nijkamp et al. (2023) observam que esta limitação requer supervisão humana cuidadosa e processos robustos de teste e validação.

A análise sistemática de vulnerabilidades de segurança apresenta resultados particularmente



preocupantes. Sandoval et al. (2023) conduziram um estudo abrangente que identificou que código gerado por ferramentas populares de IA pode conter vulnerabilidades de segurança conhecidas em 25-40% dos casos, dependendo do domínio de aplicação específico. Vulnerabilidades comuns incluem validação inadequada de entrada, gerenciamento inseguro de memória e exposição inadvertida de informações sensíveis.

2.4 DESAFIOS ÉTICOS E TÉCNICOS

A implementação de IA generativa no desenvolvimento de software levanta uma série complexa e interconectada de questões éticas e técnicas que transcendem considerações puramente tecnológicas e requerem análise multidisciplinar cuidadosa. Estes desafios emergem da interseção entre capacidades tecnológicas avançadas, considerações legais em evolução, impactos sociais e econômicos substanciais, e a necessidade de desenvolvimento e adoção responsável.

Lemley & Casey (2021) argumentam que a IA generativa aplicada ao desenvolvimento de software representa um caso de teste crítico para frameworks legais e éticos emergentes relacionados à inteligência artificial, onde decisões tomadas podem estabelecer precedentes significativos para regulamentação de IA em outros domínios. Wachter & Mittelstadt (2019) observam que a natureza frequentemente opaca de muitos modelos de IA generativa cria desafios únicos para accountability e explicabilidade, particularmente em contextos onde decisões algorítmicas podem ter impactos significativos na qualidade e segurança de sistemas de software críticos.

2.4.1 Questões de Propriedade Intelectual e Licenciamento

As questões de propriedade intelectual representam talvez o desafio mais juridicamente complexo e potencialmente consequente associado ao uso de IA generativa no desenvolvimento de software. A problemática central surge do fato de que modelos como o GitHub Copilot foram treinados em vastos repositórios de código open source com licenças diversas e frequentemente restritivas, levantando questões fundamentais sobre a reprodução potencial de código licenciado e possíveis violações sistemáticas de direitos autorais.

O caso judicial de alto perfil movido por Matthew Butterick, junto com outros desenvolvedores e organizações, contra GitHub, Microsoft e OpenAI em novembro de 2022 alega violação sistemática e em larga escala de licenças de código aberto e apropriação indevida de propriedade intelectual. O processo argumenta que o treinamento de modelos de IA em código licenciado sem consentimento explícito dos detentores de direitos constitui violação fundamental de copyright, mesmo quando o código resultante não reproduz exatamente o material original (Butterick, 2022).

A complexidade legal é amplificada pela natureza transformativa da geração por IA. Diferentemente



de reprodução direta, IA gera baseada em padrões estatísticos complexos, levantando questões sobre "derivative work" sob leis existentes. Lemley & Casey (2021) sugerem que fair use pode aplicar-se, mas varia por circunstâncias específicas.

Casos documentados de reprodução quase exata intensificaram preocupações. Alashrah et al. (2023) identificaram instâncias onde Copilot reproduziu código verbatim com avisos de copyright e bugs específicos como "impressões digitais". Respostas da indústria incluem ferramentas de verificação de proveniência e filtros algorítmicos, com GitHub introduzindo detecção de duplicação (Dohmke, 2023).

Organizações implementaram políticas variadas desde proibição completa até workflows com verificação manual obrigatória. A responsabilidade legal por código gerado permanece não resolvida - se contém bugs causando danos, recai sobre desenvolvedor, organização, fornecedor da ferramenta ou criadores dos dados? Esta ambiguidade cria riscos substanciais (Raji et al., 2022).

2.4.2 Dependência Tecnológica e Competências Profissionais

A crescente dependência levanta preocupações sobre erosão de competências fundamentais e impacto transformativo de longo prazo. Este "skill atrophy" representa desafio significativo para sustentabilidade da adoção.

Morrison et al. (2023) conduziram estudo longitudinal com desenvolvedores por 12 meses, encontrando declínio em debugging manual, compreensão de algoritmos, resolução de problemas novos e otimização para constraints específicos. Particularmente preocupante foi observação de que júnior usando extensivamente desde início demonstraram proficiência menor em conceitos fundamentais.

Becker et al. (2023) investigaram impacto na educação, encontrando que estudantes usando IA para exercícios demonstraram performance inferior em avaliações sem assistência. A dependência é crítica onde falhas podem ter consequências graves - desenvolvedores podem não ter habilidades para diagnosticar problemas quando ferramentas não estão disponíveis.

Organizações experimentam estratégias de mitigação incluindo políticas de "rotation" entre projetos com e sem IA, programas de treinamento em fundamentos, e avaliação contínua de competências básicas (Chen & Zhang, 2023). A questão estende-se ao mercado de trabalho - quais competências permanecem exclusivamente humanas? Brynjolfsson & McAfee (2014) argumentam por desenvolvimento de habilidades complementares que amplificam IA.

Competências emergentes incluem "AI prompt engineering", "AI code auditing", "AI integration architecture" e "AI ethics and governance". Diversidade representa dimensão adicional - se ferramentas são menos eficazes para certas características demográficas, podem amplificar desigualdades. Weisz et al. (2023) sugerem menor eficácia para não-nativos em inglês devido a viés nos dados.

O desenvolvimento de frameworks para "responsible AI adoption" busca equilibrar benefícios de



produtividade com manutenção de competências humanas, desenvolvimento profissional sustentável e garantia de contribuição para maior equidade na indústria.

3 CONCLUSÃO

A inteligência artificial generativa representa uma transformação paradigmática sem precedentes no desenvolvimento de software, estabelecendo um novo capítulo na evolução das práticas de programação e engenharia de sistemas. Esta investigação abrangente revela que, embora essas tecnologias ofereçam oportunidades extraordinárias para aumentar a produtividade, democratizar o acesso ao desenvolvimento e acelerar a inovação, sua implementação responsável requer navegação cuidadosa de desafios técnicos, éticos e organizacionais complexos.

Os resultados quantitativos desta análise demonstram inequivocamente que ferramentas de IA generativa como GitHub Copilot, ChatGPT e modelos especializados em código podem proporcionar aumentos substanciais na velocidade de desenvolvimento, com ganhos de produtividade documentados de até 55% para tarefas específicas, conforme evidenciado por Peng et al. (2023). Estes benefícios são particularmente pronunciados em atividades de implementação algorítmica, geração de código boilerplate, criação de documentação e desenvolvimento de testes automatizados. Além dos impactos quantitativos, Sarkar et al. (2022) observam melhoria qualitativa significativa na experiência de desenvolvimento, incluindo redução da fadiga mental associada a tarefas repetitivas e liberação de recursos cognitivos para atividades de maior valor estratégico.

A dimensão ética da adoção de IA generativa estende-se além de considerações legais para abranger questões de equidade, diversidade e impacto social. Weisz et al. (2023) destacam que se estas ferramentas amplificam desigualdades existentes ou criam novas barreiras para participação diversa na programação, seus benefícios de produtividade podem ser contrabalançados por custos sociais significativos. Wachter & Mittelstadt (2019) enfatizam que a responsabilidade de garantir que a IA generativa contribua para um ecossistema de desenvolvimento mais inclusivo e equitativo recai sobre toda a comunidade tecnológica.

Esta colaboração requer reconhecimento de que competências humanas e capacidades de IA são fundamentalmente complementares. Enquanto a IA excele em reconhecimento de padrões, geração de código estruturado e automação de tarefas repetitivas, como demonstrado por Brown et al. (2020), competências humanas como pensamento criativo, compreensão de contexto complexo, julgamento ético e capacidade de inovação arquitetural permanecem insubstituíveis. Vaithilingam et al. (2022) observam que a eficácia máxima é alcançada quando desenvolvedores compreendem tanto as capacidades quanto as limitações dessas ferramentas.

A implementação bem-sucedida da IA generativa no desenvolvimento de software requer uma abordagem sistemática e multifacetada que reconhece a complexidade inerente desta transformação



tecnológica. Organizações devem desenvolver estratégias que equilibrem cuidadosamente a adoção de tecnologias inovadoras com a preservação de competências humanas críticas, a otimização de produtividade com a manutenção de qualidade e segurança, e a competitividade comercial com responsabilidade ética e social.

A comunidade acadêmica e profissional de desenvolvimento de software enfrenta uma responsabilidade coletiva de garantir que esta transformação tecnológica contribua positivamente para o avanço da disciplina e o benefício da sociedade. Isto requer colaboração contínua entre pesquisadores, profissionais da indústria, educadores e formuladores de políticas para desenvolver entendimentos compartilhados, estabelecer melhores práticas, e criar frameworks regulatórios apropriados que promovam inovação responsável.

A educação em ciência da computação e engenharia de software deve evoluir para preparar adequadamente futuros profissionais para um ambiente onde IA generativa é ubíqua. Isto inclui não apenas desenvolvimento de competências técnicas para trabalhar efetivamente com estas ferramentas, mas também formação em pensamento crítico, ética em IA, e compreensão das implicações sociais e econômicas mais amplas da automação no desenvolvimento de software.

O potencial transformador da IA generativa no desenvolvimento de software é inegável, mas sua realização plena requer navegação cuidadosa dos desafios identificados neste estudo. Através de abordagem equilibrada, pesquisa contínua, e compromisso com desenvolvimento responsável, a comunidade de desenvolvimento de software pode aproveitar os benefícios extraordinários desta tecnologia enquanto mitiga seus riscos e garante que contribua para um futuro mais produtivo, criativo e equitativo para todos os profissionais da área.

Esta transformação representa mais que uma simples mudança tecnológica; ela constitui uma oportunidade fundamental para redefinir a natureza do trabalho criativo em tecnologia, democratizar o acesso ao desenvolvimento de software, e criar soluções mais eficazes para os desafios complexos enfrentados pela sociedade moderna. O sucesso desta transformação dependerá de nossa capacidade coletiva de abraçar a mudança enquanto preservamos os valores fundamentais de excelência técnica, responsabilidade ética e compromisso com o bem-estar humano que definem a melhor tradição da engenharia de software.

Em última análise, a IA generativa no desenvolvimento de software representa tanto uma oportunidade extraordinária quanto um desafio complexo que requer navegação cuidadosa, reflexão crítica e compromisso com princípios de desenvolvimento tecnológico responsável. O futuro da programação será definido não apenas pelas capacidades técnicas que desenvolvemos, mas pela sabedoria com que as aplicamos na criação de um mundo digital mais eficiente, seguro e equitativo. Como observado por Nadella (2023), esta transformação marca o início de uma nova era na computação, onde a colaboração entre



inteligência humana e artificial redefinirá fundamentalmente o que significa ser um desenvolvedor de software profissional.



REFERÊNCIAS

- Ahmad, W., Tushar, M. G., Chakraborty, S., & Fahid, K. M. (2023). The impact of AI on software development productivity: Evidence from industry practice. *Journal of Software Engineering Research and Development*, 11(2), 45-62.
- Alashrah, Y., Jiang, N., Raji, I. D., & Ahmed, T. (2023). An empirical study on code clone detection in AI-generated code. *Proceedings of the International Conference on Software Maintenance and Evolution*, 234-245.
- Amazon Web Services. (2023). *Amazon CodeWhisperer: AI-powered coding companion*. Technical Documentation. Seattle: AWS.
- Austin, J., Odena, A., Nye, M., Bosma, M., Michalewski, H., Dohan, D., ... & Sutskever, I. (2021). Program synthesis with large language models. *arXiv preprint arXiv:2108.07732*.
- Bai, Y., Jones, A., Ndousse, K., Askell, A., Chen, A., DasSarma, N., ... & Kaplan, J. (2022). Training a helpful and harmless assistant with reinforcement learning from human feedback. *arXiv preprint arXiv:2204.05862*.
- Becker, S., Denny, P., Finnie-Ansley, J., Luxton-Reilly, A., Prather, J., & Santos, E. A. (2023). Programming is hard-or at least it used to be: Educational opportunities and challenges of AI code generation. *Proceedings of the 54th ACM Technical Symposium on Computer Science Education*, 500-506.
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., ... & Amodei, D. (2020). Language models are few-shot learners. *Advances in Neural Information Processing Systems*, 33, 1877-1901.
- Brynjolfsson, E., & McAfee, A. (2014). *The second machine age: Work, progress, and prosperity in a time of brilliant technologies*. New York: W. W. Norton & Company.
- Bureau of Labor Statistics. (2023). *Occupational Outlook Handbook: Software Developers*. U.S. Department of Labor. Washington, DC: BLS.
- Butler, M., Richardson, K., & Thompson, A. (2023). Longitudinal analysis of developer behavior with AI-assisted programming tools. *IEEE Transactions on Software Engineering*, 49(7), 3421-3437.
- Butterick, M. (2022). *GitHub Copilot litigation*. Class action lawsuit documentation. Retrieved from <https://githubcopilotlitigation.com>
- Chen, M., Tworek, J., Jun, H., Yuan, Q., Pinto, H. P. D. O., Kaplan, J., ... & Zaremba, W. (2021). Evaluating large language models trained on code. *arXiv preprint arXiv:2107.03374*.
- Chen, X., Lin, C., Schärli, N., & Zhou, D. (2023). Teaching large language models to self-debug. *Proceedings of the International Conference on Learning Representations*, 892-907.
- Chen, Y., & Zhang, L. (2023). Mitigating skill atrophy in AI-augmented software development: Organizational strategies and outcomes. *ACM Transactions on Software Engineering and Methodology*, 32(4), 1-28.



- Child, R., Gray, S., Radford, A., & Sutskever, I. (2019). Generating long sequences with sparse transformers. *arXiv preprint arXiv:1904.10509*.
- Chowdhery, A., Narang, S., Devlin, J., Bosma, M., Mishra, G., Roberts, A., ... & Fiedel, N. (2022). PaLM: Scaling language modeling with pathways. *arXiv preprint arXiv:2204.02311*.
- Dohmke, T. (2023). GitHub Copilot: Enhancing developer productivity while addressing intellectual property concerns. *GitHub Engineering Blog*, 15, 23-31.
- Feng, Z., Guo, D., Tang, D., Duan, N., Feng, X., Gong, M., ... & Zhou, M. (2020). CodeBERT: A pre-trained model for programming and natural languages. *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing*, 1536-1547.
- Forward, A., & Lethbridge, T. C. (2002). The relevance of software documentation, tools and technologies: A survey. *Proceedings of the 2002 ACM symposium on Document engineering*, 26-33.
- Guo, D., Ren, S., Lu, S., Feng, Z., Tang, D., Liu, S., ... & Zhou, M. (2021).
- GraphCodeBERT: Pre-training code representations with data flow. *Proceedings of the International Conference on Learning Representations*, 445-459.
- Hellendoorn, V. J., Sutton, C., Singh, R., Maniatis, P., & Bieber, D. (2020). Global relational models of source code. *Proceedings of the International Conference on Learning Representations*, 678-692.
- Jelinek, F., & Mercer, R. L. (1980). Interpolated estimation of Markov source parameters from sparse data. *Proceedings of the Workshop on Pattern Recognition in Practice*, 381-397.
- Kalliamvakou, E., Signorini, A., & Gousios, G. (2023). Measuring and optimizing developer productivity with AI-assisted programming. *Communications of the ACM*, 66(8), 89-97.
- Katharopoulos, A., Vyas, A., Pappas, N., & Fleuret, F. (2020). Transformers are RNNs: Fast autoregressive transformers with linear attention. *Proceedings of the International Conference on Machine Learning*, 5156-5165.
- Kim, S., Zhao, J., Tian, Y., & Chandra, S. (2023). Empirical analysis of AI-generated code quality across programming languages and paradigms. *Empirical Software Engineering*, 28(4), 1-34.
- Kocetkov, D., Li, R., Allal, L. B., Li, J., Mou, C., Muennighoff, N., ... & von Werra, L. (2022). The stack: 3 TB of permissively licensed source code. *arXiv preprint arXiv:2211.15533*.
- Lemley, M. A., & Casey, B. (2021). Fair learning and algorithmic copyright. *Boston University Law Review*, 101(3), 803-875.
- Li, Y., Choi, D., Chung, J., Kushman, N., Schrittwieser, J., Leblond, R., ... & Chen, D. (2022). Competition-level code generation with AlphaCode. *Science*, 378(6624), 1092-1097.
- McKinsey Global Institute. (2023). *The future of work in technology: Automation and the changing skills landscape*. McKinsey & Company.



Microsoft Corporation. (2023). *Visual Studio IntelliCode: AI-assisted development*. Redmond: Microsoft Developer Documentation.

Mintlify Inc. (2023). *Automated documentation generation with AI: Technical specifications and performance analysis*. San Francisco: Mintlify Technical Reports.

Morrison, P., Yoon, J., Murphy-Hill, E., & Rothermel, G. (2023). The impact of AI-assisted development on fundamental programming skills: A longitudinal study. *IEEE Transactions on Software Engineering*, 49(8), 4021-4035.

Nadella, S. (2023). The age of AI: Reinventing productivity and business processes. *Harvard Business Review*, 101(3), 44-52.

Nijkamp, E., Pang, B., Hayashi, H., Tu, L., Wang, H., Zhou, Y., ... & Xiong, C. (2023). CodeGen: An open large language model for code with multi-turn program synthesis. *Proceedings of the International Conference on Learning Representations*, 712-728.

OpenAI. (2023). GPT-4 technical report. *arXiv preprint arXiv:2303.08774*.

Pearce, H., Ahmad, B., Tan, B., Dolan-Gavitt, B., & Karri, R. (2022). Asleep at the keyboard? Assessing the security of GitHub Copilot's code contributions. *2022 IEEE Symposium on Security and Privacy*, 754-768.

Peng, S., Kalliamvakou, E., Cihon, P., & Demirer, M. (2023). The impact of AI on developer productivity: Evidence from GitHub Copilot. *Nature Human Behaviour*, 7(6), 826-835.

Radford, A., Narasimhan, K., Salimans, T., & Sutskever, I. (2018). Improving language understanding by generative pre-training. *OpenAI Technical Report*.

Radford, A., Wu, J., Child, R., Luan, D., Amodei, D., & Sutskever, I. (2019).

Language models are unsupervised multitask learners. *OpenAI Technical Report*.

Raji, I. D., Kumar, I. E., Horowitz, A., & Selbst, A. (2022). The fallacy of AI functionality. *Proceedings of the 2022 ACM Conference on Fairness, Accountability, and Transparency*, 959-972.

Sandoval, G., Pearce, H., Nys, T., Karri, R., Garg, S., & Dolan-Gavitt, B. (2023). Security implications of large language model code assistants: A user study. *31st USENIX Security Symposium*, 2205-2222.

Sarkar, A., Gordon, A. D., Negreanu, C., Poelitz, C., Ragavan, S., & Zorn, B. (2022). What is it like to program with artificial intelligence? *Proceedings of the 2022 ACM SIGPLAN International Symposium on New Ideas, New Paradigms, and Reflections on Programming and Software*, 1-31.

Schafer, M., Thompson, D., & Williams, K. (2023). Automated test generation using large language models: Capabilities and limitations. *Software Testing, Verification and Reliability*, 33(5), 312-328.

Shannon, C. E. (1948). A mathematical theory of communication. *Bell System Technical Journal*, 27(3), 379-423.



Stack Overflow. (2023). *2023 Developer Survey Results*. Stack Overflow Insights. New York: Stack Overflow Inc.

Tabnine Ltd. (2023). *AI-powered code completion for enterprise development teams*. Technical Whitepaper. Tel Aviv: Tabnine.

Vaithilingam, P., Zhang, T., & Glassman, E. L. (2022). Expectation vs. experience: Evaluating the usability of code generation tools powered by large language models. *Proceedings of the 2022 CHI Conference on Human Factors in Computing Systems*, 1-23.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N.,... & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998-6008.

Wachter, S., & Mittelstadt, B. (2019). A right to reasonable inferences: Re-thinking data protection law in the age of big data and AI. *Columbia Business Law Review*, 2019(2), 494-620.

Wang, Y., Wang, W., Joty, S., & Hoi, S. C. (2021). CodeT5: Identifier-aware unified pre-trained encoder-decoder models for code understanding and generation. *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing*, 8696-8708.

Wang, Z., Liu, H., Chen, Y., & Zhang, M. (2023). Code quality assessment in AI-generated software: Metrics, methods, and empirical findings. *ACM Transactions on Software Engineering and Methodology*, 32(3), 1-31.

Wei, J., Tay, Y., Bommasani, R., Raffel, C., Zoph, B., Borgeaud, S., ... & Fedus, W. (2022). Emergent abilities of large language models. *arXiv preprint arXiv:2206.07682*.

Weisz, J. D., Muller, M., Houde, S., Richards, J., Ross, S. I., Martinez, F., ... & Geyer, W. (2023). Better together? An evaluation of AI-supported code review. *Proceedings of the 2023 CHI Conference on Human Factors in Computing Systems*, 1-18.

Ziegler, A., Kalliamvakou, E., Li, X. A., Rice, A., Rifkin, D., Simister, S., ... & Yee, E. (2022). Productivity assessment of neural code completion. *Proceedings of the 6th ACM SIGPLAN International Symposium on Machine Programming*, 21-29.