

Quem faz cada etapa? A IA generativa como executora de tarefas e a mudança na rotina de trabalho

Who performs each step? Generative AI as a task executor and the change in work routines

Daniela Hayoshi¹

RESUMO

Ferramentas de inteligência artificial (IA) generativa se difundiram rapidamente entre profissionais, e experimentos mostram ganhos expressivos em tarefas isoladas. Ainda assim, os efeitos médios sobre salários e horas registradas têm sido pequenos, embora já haja mudanças na organização das tarefas. Este artigo conceitual propõe que parte importante dessa distância se explica pela forma como as pessoas representam a tecnologia: a IA generativa tende a ser percebida como uma ferramenta de perguntas e respostas, e não como executora de etapas de um processo, muito menos de rotinas recorrentes que seguem acontecendo enquanto a pessoa apenas verifica o resultado. Com base em literaturas sobre a abordagem de tarefas na economia do trabalho, níveis de automação, confiança e dependência excessiva em sistemas automatizados, desenho e redesenho do trabalho, quadros sociotécnicos, transferência de treinamento e formação de hábitos, o artigo desenvolve um modelo em cinco elementos (percepção, decomposição, alocação, verificação e rotinização) e argumenta que a pergunta relevante deixa de ser “como eu peço?” e passa a ser “quem faz cada etapa?”, com três destinos possíveis para cada etapa: a IA sozinha, a IA com verificação humana ou a pessoa. São formuladas sete proposições testáveis e discutidas implicações para pesquisa, para o desenho de treinamentos e para organizações. O artigo não apresenta dados novos; sua contribuição é organizar evidências dispersas em um mecanismo explícito e falseável.

Palavras-chave: inteligência artificial generativa; delegação; níveis de automação; redesenho do trabalho; confiança em automação; hábitos.

¹Pesquisadora independente. São José do Rio Preto, SP, Brasil. E-mail: dani@danihayoshi.com

ABSTRACT

Generative artificial intelligence (AI) tools have spread rapidly among professionals, and experiments show substantial gains on isolated tasks. Yet average effects on earnings and recorded hours have been small, although changes in task organization are already evident. This conceptual article proposes that an important part of this gap is explained by how people represent the technology: generative AI tends to be perceived as a question-and-answer tool rather than as an executor of process steps, let alone of recurring routines that keep running while the person only checks the result. Drawing on literatures on the task-based approach in labor economics, levels of automation, trust and overreliance in automated systems, work design and redesign, sociotechnical frames, transfer of training, and habit formation, the article develops a five-element model (perception, decomposition, allocation, verification, and routinization) and argues that the relevant question shifts from “how do I ask?” to “who performs each step?”, with three possible destinations for each step: AI alone, AI with human verification, or the person. Seven testable propositions are formulated, and implications for research, training design, and organizations are discussed. The article presents no new data; its contribution is to organize dispersed evidence into an explicit, falsifiable mechanism.

Keywords: generative artificial intelligence; delegation; levels of automation; work redesign; trust in automation; habits.

1. INTRODUÇÃO

Em poucos anos, ferramentas de IA generativa passaram a estar ao alcance de grande parte dos profissionais do conhecimento. A evidência experimental sobre seus efeitos em tarefas específicas é, em muitos casos, positiva. Em um experimento pré-registrado com 453 profissionais com formação superior, o acesso ao ChatGPT em tarefas de escrita reduziu o tempo médio em 40% e elevou a qualidade avaliada em 18% (Noy & Zhang, 2023). Em uma empresa de software com 5.172 atendentes, a introdução de um assistente conversacional aumentou em 15%, em média, os chamados resolvidos por hora, com ganhos maiores entre os trabalhadores menos experientes (Brynjolfsson et al., 2025). Em um experimento com 758 consultores da Boston Consulting Group, o uso do GPT-4 em tarefas dentro da capacidade do modelo aumentou a quantidade de tarefas concluídas, a velocidade e a qualidade; em uma tarefa escolhida para ficar fora dessa capacidade, porém, quem usou IA

teve 19 pontos percentuais a menos de probabilidade de chegar à resposta correta (Dell'Acqua et al., 2026).

Os efeitos agregados, por outro lado, têm sido pequenos. Combinando pesquisas de adoção com registros administrativos na Dinamarca, Humlum e Vestergaard (2025) observam que as iniciativas das empresas, inclusive treinamentos, aumentam a adoção de chatbots, mas estimam efeitos próximos de zero sobre salários e horas registradas, com economia média de tempo da ordem de 3%. Há muitas explicações possíveis para essa distância: defasagens típicas da difusão de tecnologias, custos de reorganização, repasse limitado de ganhos de produtividade para salários, limitações das próprias ferramentas. Este artigo não pretende substituí-las. Propõe acrescentar uma explicação de nível individual e cognitivo, que ajuda a entender por que o acesso, e mesmo o uso frequente, nem sempre se traduz em mudança na forma como o trabalho é feito.

O argumento central é que a IA generativa costuma ser percebida, e portanto usada, como uma ferramenta de perguntas e respostas. A interface de conversa favorece essa leitura: escreve-se algo, recebe-se uma resposta. Nesse enquadramento, a IA serve para tirar dúvidas, redigir um texto ou resumir um documento, interações pontuais que começam e terminam na mesma janela. O que fica fora do campo de visão é outra possibilidade: tratar a IA como executora de etapas de um processo de trabalho, e de rotinas recorrentes em que a execução acontece com regularidade e a pessoa passa a verificar em vez de fazer. A diferença não é de grau de uso. É de unidade de análise. No primeiro enquadramento, a pergunta relevante é “como eu peço?”. No segundo, é “quem faz cada etapa?”.

Essa troca de pergunta tem consequências práticas. A primeira leva naturalmente a investir em técnicas de formulação de pedidos (prompts) e no conhecimento de funções da ferramenta, que é o conteúdo dominante de muitos treinamentos. A segunda leva a olhar para o processo de trabalho, decompô-lo, decidir para cada etapa se ela deve ser executada pela IA sozinha, pela IA com verificação humana ou pela própria pessoa, e definir como a verificação será feita. Essa segunda pergunta não é nova. A economia do trabalho analisa a tecnologia tarefa a tarefa há décadas (Autor et al., 2003); a engenharia de fatores humanos discute níveis de automação por função (Parasuraman et al., 2000); a psicologia organizacional estuda como as pessoas redesenham o próprio trabalho (Wrzesniewski & Dutton, 2001). O que este artigo propõe é aplicar essas tradições, de forma integrada, ao problema da adoção cotidiana da IA generativa por profissionais que não têm formação

técnica e que, na prática, precisam tomar sozinhos decisões de alocação que antes cabiam a engenheiros e projetistas de sistemas.

A contribuição pretendida é específica: (a) nomear e delimitar o enquadramento “pergunta e resposta” como barreira à mudança na rotina; (b) propor um modelo conceitual com cinco elementos encadeados (percepção, decomposição, alocação, verificação e rotinização) e duas alças de retroalimentação; (c) derivar proposições testáveis a partir do modelo; e (d) indicar implicações para pesquisa e prática. O artigo é conceitual e não apresenta dados próprios. Onde a evidência existente é fraca ou indireta, isso é dito.

2. REFERENCIAL TEÓRICO

2.1 Tecnologia, tarefas e a unidade de análise

A abordagem baseada em tarefas mudou a forma como a economia estuda os efeitos da tecnologia sobre o trabalho. Autor, Levy e Murnane (2003) mostraram que a informatização afetou ocupações por meio das tarefas que as compõem: substituiu tarefas rotineiras, codificáveis em regras explícitas, e complementou tarefas não rotineiras de análise e interação. A unidade de análise relevante deixou de ser a ocupação ou o trabalhador e passou a ser a tarefa.

Estudos recentes sobre IA generativa adotam a mesma lente. Eloundou et al. (2024) estimam o potencial de impacto dos grandes modelos de linguagem avaliando a exposição de cada tarefa das ocupações, e não das ocupações como um todo. A implicação, raramente explicitada, é que o efeito da IA depende de alguém decidir, tarefa a tarefa, onde ela entra. Em organizações com áreas de tecnologia, essa decisão pode ser tomada por quem projeta sistemas. No uso cotidiano de assistentes de propósito geral, ela é tomada, ou deixa de ser tomada, por cada profissional.

Raisch e Krakowski (2021) argumentam que, em gestão, automação e ampliação (*augmentation*) das capacidades humanas não são alternativas excludentes, mas se alimentam ao longo do tempo: tarefas inicialmente ampliadas podem vir a ser automatizadas, e a automação de algumas libera atenção para outras. Essa visão dinâmica é útil aqui, porque sugere que a alocação de etapas entre pessoa e IA não é fixa e pode mudar à medida que se acumula experiência com o desempenho da IA em cada etapa.

2.2 Níveis de automação e alocação de funções

A engenharia de fatores humanos oferece o vocabulário mais preciso para pensar a divisão do trabalho entre pessoas e sistemas automatizados. Parasuraman, Sheridan e Wickens (2000) propõem que a automação pode ser aplicada a quatro classes de funções (aquisição de informação, análise da informação, seleção de decisão e implementação da ação) e, em cada uma, em graus que vão da ausência de automação à execução totalmente autônoma. O modelo recomenda que o grau de automação de cada função seja escolhido considerando as consequências para o desempenho humano, como carga de trabalho, consciência da situação e perda de habilidades, além da confiabilidade do sistema e do custo das decisões erradas.

Duas ideias desse modelo são centrais para este artigo. A primeira é que um mesmo processo pode, e frequentemente deve, combinar etapas com graus diferentes de automação. A segunda é que a decisão sobre o grau de automação é uma decisão de desenho, que pode ser feita de forma deliberada. A classificação em três destinos proposta adiante (IA sozinha, IA com verificação humana, pessoa) é uma simplificação deliberada dessa escala, pensada para ser utilizável por profissionais sem formação em engenharia.

2.3 Confiança, dependência excessiva e verificação

Delegar é sempre também uma questão de confiança. Parasuraman e Riley (1997) distinguem o uso adequado da automação de três desvios: o mau uso (*misuse*), quando se confia demais e se deixa de monitorar; o desuso (*disuse*), quando se deixa de usar a automação que ajudaria; e o abuso (*abuse*), quando se automatiza sem considerar as consequências para as pessoas envolvidas. Lee e See (2004) argumentam que o objetivo não é aumentar ou reduzir a confiança, mas calibrá-la à capacidade real do sistema em cada contexto, e que a confiança se forma em parte por processos afetivos e heurísticos, nem sempre por avaliação deliberada.

A literatura documenta os dois tipos de erro. Skitka, Mosier e Burdick (1999) mostraram que pessoas apoiadas por sistemas automatizados cometem erros de omissão, ao não perceber problemas que o sistema não sinalizou, e de comissão, ao seguir recomendações erradas. No sentido oposto, Dietvorst, Simmons e Massey (2015) observaram que pessoas passam a evitar algoritmos depois de vê-los errar, mesmo quando eles erram menos que seres humanos. Mau uso e desuso, portanto, são riscos simultâneos.

Com a IA generativa, esses riscos ganham características próprias. Uma meta-análise de 106 experimentos encontrou que, em média, combinações de humanos e IA tiveram desempenho inferior ao melhor dos dois isoladamente, com perdas em tarefas de decisão e ganhos em tarefas de criação de conteúdo; quando os humanos sozinhos superavam a IA, a combinação tendia a ganhar, e quando a IA superava os humanos, a combinação tendia a perder (Vaccaro et al., 2024). Em uma pesquisa com 319 profissionais do conhecimento, maior confiança na IA esteve associada a menos pensamento crítico, e maior autoconfiança na tarefa, a mais pensamento crítico; o esforço crítico relatado se deslocou para a verificação de informações, a integração de respostas e a supervisão da tarefa (Lee et al., 2025). Tankelevitch et al. (2024) descrevem o uso de IA generativa como metacognitivamente exigente: requer consciência dos próprios objetivos, capacidade de decompor a tarefa, confiança ajustada na própria capacidade de avaliar o resultado e decisões sobre se, quando e como incorporar a IA ao fluxo de trabalho.

Há também evidência sobre intervenções. Funções de “forçamento cognitivo”, que obrigam a pessoa a refletir antes de aceitar uma recomendação, reduziram a dependência excessiva em decisões assistidas por IA, embora tenham sido avaliadas de forma menos favorável pelos usuários (Buçinca et al., 2021). Em um experimento com estudantes do ensino médio, o acesso irrestrito a um assistente baseado em GPT-4 melhorou o desempenho durante a prática, mas prejudicou o desempenho posterior sem a ferramenta; uma versão com salvaguardas pedagógicas atenuou esse efeito (Bastani et al., 2025). Em estudo de campo sobre o uso de IA em diagnóstico médico, Lebovitz, Lifshitz-Assaf e Levina (2022) observaram que apenas os profissionais que interrogavam ativamente os resultados da IA, em vez de aceitá-los ou rejeitá-los em bloco, conseguiram incorporá-la de forma útil a julgamentos críticos.

O conjunto sugere que a verificação não é um complemento opcional da delegação, mas a condição que a torna possível sem cair no mau uso nem no desuso. Sugere também que a verificação é mais provável quando é planejada: quando a pessoa sabe, antes de receber a resposta, o que vai checar.

2.4 Desenho e redesenho do trabalho

A tradição de desenho do trabalho parte da premissa de que a forma como as tarefas são organizadas afeta desempenho e motivação. O modelo das características do trabalho de Hackman e Oldham (1976) identifica variedade de habilidades, identidade da tarefa,

significado, autonomia e retorno como dimensões que influenciam estados psicológicos e resultados. Morgeson e Humphrey (2006) ampliaram esse repertório para incluir características de conhecimento, sociais e contextuais. Essas abordagens têm em comum tratar a tarefa, e não a ferramenta, como objeto de análise.

A literatura de *job crafting* acrescentou que as próprias pessoas redesenham o trabalho. Wrzesniewski e Dutton (2001) descrevem mudanças que o trabalhador faz nos limites de suas tarefas, nas suas relações e na forma de interpretar o próprio trabalho; Tims e Bakker (2010) definem o *job crafting* como mudanças iniciadas pelo empregado nos níveis de demandas e recursos do trabalho. Para o argumento deste artigo, essa literatura tem duas implicações. Primeiro, reorganizar o próprio trabalho é um comportamento que as pessoas já praticam e que pode ser estimulado. Segundo, a introdução de uma tecnologia de propósito geral cria uma oportunidade de redesenho, mas não a realiza por si: alguém precisa olhar para as tarefas e decidir o que muda.

2.5 Quadros sociotécnicos e modelos mentais da IA

Orlikowski e Gash (1994) propuseram o conceito de quadros tecnológicos (*technological frames*): os pressupostos, expectativas e conhecimentos que as pessoas usam para entender uma tecnologia, que condicionam como ela é adotada e usada. Quadros diferentes entre grupos de uma mesma organização ajudam a explicar usos e resultados diferentes de uma mesma tecnologia.

A hipótese deste artigo pode ser formulada nesses termos. O quadro dominante da IA generativa entre profissionais seria o de uma ferramenta de perguntas e respostas, reforçado pela interface de conversa e pela analogia com mecanismos de busca. Esse quadro não é errado; ele descreve bem parte do que a tecnologia faz. Mas é estreito, porque não inclui a ideia de execução de etapas nem a de rotina. Estudos com não especialistas reforçam a relevância dos modelos mentais. Zamfirescu-Pereira et al. (2023) observaram que pessoas sem formação em IA exploravam pedidos de forma oportunista e não sistemática, generalizavam a partir de um único sucesso ou fracasso e traziam para a interação expectativas próprias da instrução entre pessoas, a ponto de evitar estratégias eficazes mesmo depois de vê-las funcionar.

O estudo de campo mais próximo do argumento aqui desenvolvido testou precisamente uma intervenção sobre modelos mentais. Farach et al. (2026) realizaram um experimento com 388 funcionários de uma grande varejista, todos com acesso ao mesmo

assistente (Microsoft Copilot). Em uma das tarefas, um treinamento adaptado do currículo AI Mindset, que busca substituir o modelo mental de “mecanismo de busca” pelo de “parceira de pensamento”, usa a metáfora do “estagiário inteligente” e inclui prática guiada de pedidos iterativos, foi comparado a um treinamento padrão sobre a interface, as funções e a sintaxe básica de pedidos. O desfecho principal especificado, a qualidade contínua dos documentos avaliada por um modelo de linguagem, não diferiu entre os grupos ($p = 0,223$), em parte porque 68% dos documentos atingiram a nota máxima. Em um modelo binário exploratório, com limiar definido após observar esse efeito teto, o grupo do treinamento de reenquadramento teve chance cerca de duas vezes maior de produzir um documento com nota máxima (razão de chances de 2,07; 77,0% contra 61,8%), mas o resultado não se manteve sob limites de Lee para perdas diferenciais, que foram elevadas (55% contra 37% de documentos não entregues). O tratamento ocorreu à tarde e o controle pela manhã, o estudo não foi pré-registrado, e a mudança de crenças observada provavelmente reflete, segundo os próprios autores, recuperação de um efeito negativo da tarefa anterior. Na outra tarefa do mesmo estudo, um roteiro obrigatório de colaboração em duplas mediada pela IA reduziu a qualidade e a produção de documentos; 23 das 62 duplas com dados de adesão não conseguiram se reunir de forma síncrona, como o roteiro exigia.

O estudo é relevante por duas razões. Mostra que é possível comparar formatos de intervenção mantendo a ferramenta constante, e documenta com franqueza as dificuldades de medida desse tipo de pesquisa. Seu resultado é, no máximo, sugestivo de que intervenções sobre modelos mentais podem importar. Ele não testa, porém, o enquadramento proposto aqui. O treinamento avaliado desloca a IA de mecanismo de busca para interlocutora, mantendo a conversa como unidade de uso; não pede às pessoas que decomponham processos, aloquem etapas ou planejem verificações, e mede a qualidade de um documento produzido no mesmo dia, não a mudança na rotina semanas depois.

2.6 O que se sabe sobre treinar ferramentas e pedidos

Se o problema fosse sobretudo técnico, ensinar a ferramenta e a formulação de pedidos deveria resolvê-lo. A evidência a esse respeito é limitada. Em um experimento com 157 estudantes de engenharia, quem recebeu treinamento estruturado em técnicas de pedido teve desempenho superior, em tarefas de análise de dados e programação, a quem usou IA sem treinamento e a quem não usou IA (Garg et al., 2025). O resultado é favorável, mas obtido com estudantes, em tarefas delimitadas, com medida logo após a intervenção.

Um dado mais ambíguo vem do experimento com consultores citado na introdução. Dell'Acqua et al. (2026) incluíram um terceiro braço: acesso ao GPT-4 acompanhado de uma visão geral de engenharia de pedidos, com vídeos e documentos sobre estratégias de uso. Nas tarefas dentro da fronteira de capacidade do modelo, esse grupo teve ganhos de qualidade um pouco maiores que o grupo apenas com acesso. Na tarefa fora da fronteira, os dois grupos com IA erraram mais que o grupo sem IA, e a queda foi maior no grupo com a visão geral de pedidos (24,5 contra 13,9 pontos percentuais, segundo as estimativas dos autores). Esse resultado não demonstra que treinar pedidos prejudica o julgamento, e os autores não o interpretam assim. Mas é compatível com a ideia de que saber pedir melhor não ensina a decidir o que pedir. Na versão de trabalho do mesmo estudo, os autores descrevem dois padrões de uso bem-sucedido: “centauros”, que dividem e delegam atividades entre si e a IA, e “ciborgues”, que integram a IA continuamente ao fluxo da tarefa (Dell'Acqua et al., 2023). Ambos envolvem decisões, explícitas ou tácitas, sobre a divisão do trabalho.

Há ainda uma razão estrutural para duvidar da durabilidade de treinamentos centrados em técnica: as técnicas acompanham os modelos. Em experimentos pré-registrados com geração de imagens, cerca de metade dos ganhos obtidos com um modelo mais novo, em uma das tarefas, veio da adaptação dos próprios pedidos pelos usuários ao novo modelo (Jahani et al., 2026). Uma habilidade atrelada à versão da ferramenta tende a ter vida curta.

2.7 Transferência de treinamento e formação de hábitos

Mesmo quando uma intervenção ensina algo útil, permanece o problema de levar o aprendizado para o trabalho e mantê-lo. Baldwin e Ford (1988) definem a transferência como a generalização do que foi aprendido para o contexto de trabalho e sua manutenção ao longo do tempo, e organizam seus determinantes em características dos participantes, desenho do treinamento e ambiente de trabalho. A meta-análise de Blume et al. (2010), com 89 estudos, confirmou a importância de fatores como motivação e apoio do ambiente, e mostrou que as relações entre esses fatores e a transferência foram mais fortes para habilidades “abertas”, que exigem julgamento, do que para habilidades “fechadas”, como operar um software específico. Os autores também observaram que medidas de transferência obtidas da mesma fonte e no mesmo contexto tendem a inflar as relações, um alerta para avaliações baseadas em autorrelato.


A psicologia social oferece dois mecanismos complementares. O primeiro são as intenções de implementação, planos do tipo “se a situação Y ocorrer, farei X”, que especificam quando, onde e como agir (Gollwitzer, 1999). Em meta-análise com 94 testes independentes, esses planos tiveram efeito de magnitude média a grande sobre o alcance de metas ($d = 0,65$), favorecendo tanto o início da ação quanto sua proteção contra distrações (Gollwitzer & Sheeran, 2006). O segundo é o hábito, entendido como associação entre contexto e resposta construída pela repetição, que passa a ser acionada pelo contexto com pouca deliberação (Wood & Neal, 2007). Em um estudo de campo, o tempo para que comportamentos diários atingissem 95% do seu nível máximo de automaticidade variou de 18 a 254 dias, e perder uma oportunidade isolada não comprometeu materialmente o processo (Lally et al., 2010).

Para o argumento deste artigo, essas literaturas indicam que mudar a percepção da IA é necessário mas não suficiente. Uma mudança que se limita ao entendimento tende a se dissipar se não for convertida em comportamentos específicos, ligados a gatilhos estáveis e repetidos. É por isso que o modelo proposto termina na rotinização.

3. MODELO CONCEITUAL

O modelo proposto descreve como a percepção da IA generativa como executora de etapas pode se converter em mudança na rotina de trabalho. Ele tem cinco elementos encadeados, duas alças de retroalimentação e um conjunto de moderadores (Figura 1). Os elementos são apresentados em sequência por clareza, mas, na prática, podem se sobrepor e se repetir.

Figura 1 – Modelo conceitual: da percepção da IA como executora à rotinização



3.1 Percepção: de ferramenta de respostas a executora de etapas

O ponto de partida é o quadro que a pessoa usa para entender a IA. No quadro “pergunta e resposta”, a IA é um lugar para onde se leva uma dúvida ou um pedido isolado, e o valor esperado está na qualidade da resposta. No quadro “executora de etapas”, a IA é um recurso ao qual se atribui a execução de partes de um processo, e o valor esperado está na redistribuição do trabalho. Os dois quadros não são excludentes, mas levam a perguntas diferentes. O primeiro leva a “como formular melhor o pedido?”. O segundo leva a “quais etapas deste processo poderiam ser executadas pela IA, e como eu saberia se foram bem executadas?”.

O quadro de execução tem uma extensão importante: a rotina. Uma etapa que se repete toda semana com as mesmas entradas e o mesmo formato de saída pode deixar de ser um pedido e passar a ser uma rotina, executada com regularidade. No limite, com recursos técnicos adequados, essa rotina pode acontecer de forma contínua, sem intervenção a cada ciclo, restando à pessoa verificar os resultados. O modelo não supõe que todo profissional chegue a esse ponto, nem que deva chegar. Supõe que, sem o quadro de execução, essa possibilidade sequer é considerada.

Uma escolha de linguagem acompanha esse quadro. Metáforas que aproximam a IA de uma pessoa, como “assistente”, “estagiário” ou “parceira”, são comuns e podem facilitar o primeiro contato. O modelo aqui proposto não depende delas e sugere que podem até desviar a atenção do processo para a relação com a ferramenta. Executar uma etapa sob verificação é uma descrição funcional; não requer que a IA seja imaginada como alguém.

3.2 Decomposição: tornar o processo visível

A segunda condição é decompor um processo de trabalho em etapas com entradas e saídas identificáveis. Essa capacidade aparece na literatura como componente metacognitivo do uso de IA generativa (Tankelevitch et al., 2024) e, de forma mais ampla, como base da análise de tarefas (Autor et al., 2003). A decomposição cumpre três funções. Torna explícitas etapas que costumam ser executadas sem reflexão. Revela etapas que existem apenas por costume e podem ser eliminadas, o que é uma forma de redesenho no sentido de Wrzesniewski e Dutton (2001). E cria a unidade sobre a qual a alocação será decidida.

A decomposição útil tem granularidade intermediária. Etapas amplas demais (“cuidar do financeiro”) não permitem decidir quem executa; etapas minúsculas demais tornam o processo de decisão mais custoso do que o ganho. Um critério prático é que cada etapa tenha uma entrada que possa ser entregue e uma saída que possa ser verificada.

Antes da decomposição, convém esclarecer o objetivo do processo, distinguindo resultado de atividade. “Enviar lembretes a clientes com pagamento em atraso” é uma atividade; “reduzir a inadimplência sem desgastar a relação com o cliente” é um resultado. Etapas só podem ser avaliadas em relação a um resultado, e a clareza sobre o objetivo é condição para que se perceba quais etapas contribuem para ele.

3.3 Alocação: três destinos para cada etapa

O núcleo do modelo é a decisão, para cada etapa, sobre quem a executa. O modelo propõe três destinos, que simplificam a escala de níveis de automação de Parasuraman et al. (2000), apresentados na Tabela 1.

Tabela 1 – Três destinos para cada etapa de um processo

Destino	Quando é indicado	Papel da pessoa	Risco principal
IA sozinha	Etapa dentro da capacidade da IA, erro de baixo custo e facilmente percebido nas etapas seguintes	Definir a entrada e o formato; inspecionar por amostragem	Mau uso: erro que se propaga sem ser notado
IA com verificação humana	Etapa dentro ou perto da capacidade da IA, mas com erro de custo relevante ou difícil de perceber depois	Verificar cada execução segundo critério definido antes	Verificação que vira formalidade com o tempo
Pessoa	Etapa fora da capacidade da IA, que exige julgamento contextual, relação pessoal ou responsabilidade que não se delega, ou cuja verificação custaria mais que a execução	Executar	Desuso: manter com a pessoa o que poderia ser delegado

Fonte: elaborada pela autora (2026).

Quatro critérios orientam a alocação. O primeiro é a capacidade da IA na etapa, que não pode ser presumida a partir da dificuldade aparente: a fronteira de capacidade é irregular, e tarefas de dificuldade semelhante podem ficar de lados diferentes dela (Dell’Acqua et al., 2026). O segundo é o custo do erro: se um erro pode chegar a um cliente, a um paciente ou a uma decisão importante sem ser percebido, a etapa não deve ficar com a IA sem verificação. O terceiro é a verificabilidade: se a pessoa não consegue dizer como

perceberia um erro, a etapa não está pronta para ser delegada sem verificação. O quarto é o custo total: preparar a entrada, verificar a saída e corrigir erros consome tempo, e se essa soma supera o tempo da execução manual, a delegação não compensa.

Uma regra de dados acompanha a alocação. Informações pessoais ou sensíveis de clientes, pacientes ou colaboradores não devem ser entregues à IA sem base legal e garantias adequadas; frequentemente, a etapa pode ser executada com códigos, campos em branco ou dados fictícios, e a pessoa completa o resultado depois. A alocação, portanto, decide também o que não entra na IA.

3.4 Verificação: decidir antes como se confere

A verificação é o que permite delegar sem cair no mau uso nem no desuso (Parasuraman & Riley, 1997). O modelo enfatiza três características. A primeira é que o critério de verificação seja definido antes da execução, e não improvisado diante da resposta. Saber de antemão o que se vai checar (“todos os itens da lista de entrada aparecem na saída?”, “algum valor foi alterado?”, “há algo que não deveria estar ali?”) torna a verificação mais rápida e menos sujeita à aparência de qualidade da resposta, que é justamente o que alimenta o viés de automação (Skitka et al., 1999). Esse planejamento prévio tem afinidade com as funções de forçamento cognitivo estudadas por Buçinca et al. (2021).

A segunda característica é que a verificação tenha custo conhecido. Uma verificação que leva mais tempo do que a execução manual tende a ser abandonada ou feita de forma superficial. Medir esse tempo, ao menos aproximadamente, é parte da decisão de alocação.

A terceira é que a verificação alimente a alocação. Erros detectados indicam que a etapa talvez deva mudar de destino, que a entrada estava incompleta ou que o formato pedido era ambíguo. Acertos repetidos podem justificar reduzir a verificação, passando, por exemplo, de verificação integral a verificação por amostragem. Essa é a primeira alça de retroalimentação do modelo, e corresponde à ideia de calibração da confiança de Lee e See (2004): a confiança se ajusta à evidência acumulada sobre o desempenho do sistema em cada etapa, e não a uma impressão geral sobre a IA.

3.5 Rotinização: da decisão ao hábito

O último elemento converte a decisão em comportamento recorrente. Uma etapa delegada uma vez é um experimento; uma etapa delegada toda semana, no mesmo momento, com as mesmas entradas, o mesmo formato e a mesma verificação, é uma rotina. O modelo propõe que a rotina dependa de três condições, cada uma apoiada em literatura específica.

A primeira é a especificidade do plano. Uma intenção vaga (“vou usar mais a IA”) tem pouca chance de se realizar; um plano que especifica quando, com que entrada e com que verificação a etapa será executada funciona como intenção de implementação (Gollwitzer, 1999; Gollwitzer & Sheeran, 2006). A segunda é a primeira execução próxima da decisão. Executar a rotina pela primeira vez logo após decidi-la reduz a incerteza sobre o que acontecerá e inicia a repetição. A terceira é a estabilidade do contexto. Hábitos se formam pela repetição em contextos consistentes (Wood & Neal, 2007), e esse processo pode levar semanas ou meses (Lally et al., 2010). Um gatilho estável, como um dia e horário fixos ou um evento recorrente do próprio processo, favorece a formação do hábito.

A rotina também representa uma mudança no papel da pessoa. Nas etapas rotinizadas, ela deixa de executar e passa a preparar entradas e verificar saídas. Com recursos técnicos adequados e etapas suficientemente estáveis, a própria execução pode passar a ocorrer sem acionamento manual a cada ciclo, em rotinas contínuas que a pessoa supervisiona. O modelo trata esse ponto como o extremo de um contínuo, não como meta universal: a supervisão de rotinas que funcionam sozinhas está sujeita, de forma ainda mais aguda, aos riscos de complacência descritos pela literatura de automação (Parasuraman & Riley, 1997; Skitka et al., 1999).

A segunda alça de retroalimentação liga a rotina à percepção. Rotinas que funcionam fornecem evidência concreta de que a IA pode executar etapas, o que tende a reforçar o quadro de execução e a facilitar a identificação de novas etapas e novos processos. Rotinas que falham, se a verificação funcionar, levam à realocação e não necessariamente ao abandono da IA.

3.6 Moderadores

O modelo prevê que a força das relações entre os elementos varie conforme cinco moderadores. A fronteira de capacidade da IA na tarefa determina quanto há para delegar

(Dell’Acqua et al., 2026). O custo do erro determina quanto da delegação exige verificação. A autonomia da pessoa sobre o próprio trabalho, uma das dimensões clássicas do desenho do trabalho (Hackman & Oldham, 1976), condiciona sua possibilidade de alterar processos. O apoio do ambiente, um dos determinantes mais consistentes da transferência de treinamento (Blume et al., 2010), afeta a manutenção da mudança. E as regras sobre dados e sobre o uso de IA na organização podem restringir quais etapas podem ser delegadas.

3.7 Síntese

A Tabela 2 resume os elementos do modelo, sua base teórica principal e indicadores que poderiam ser usados para observá-los.

Tabela 2 – Elementos do modelo, base teórica e indicadores observáveis

Elemento	Pergunta-chave	Base teórica principal	Indicadores possíveis
Percepção	A IA é vista como executora de etapas ou só como fonte de respostas?	Quadros tecnológicos (Orlikowski & Gash, 1994); metacognição (Tankelevitch et al., 2024)	Itens de escala sobre modelo mental; tipo de uso descrito em entrevistas
Decomposição	O processo foi dividido em etapas com entrada e saída?	Abordagem de tarefas (Autor et al., 2003); <i>job crafting</i> (Wrzesniewski & Dutton, 2001)	Número e granularidade das etapas listadas; etapas eliminadas
Alocação	Quem executa cada etapa: IA, IA com verificação ou pessoa?	Níveis de automação (Parasuraman et al., 2000); automação e ampliação (Raisch & Krakowski, 2021)	Distribuição das etapas entre os três destinos; adequação avaliada por especialistas
Verificação	Como se sabe que a execução está boa, e isso foi definido antes?	Uso, mau uso e desuso (Parasuraman & Riley, 1997); calibração da confiança (Lee & See, 2004)	Critérios escritos antes da execução; detecção de erros plantados; tempo de verificação
Rotinização	Alguma etapa passou a ser executada de forma recorrente?	Intenções de implementação (Gollwitzer & Sheeran, 2006); hábitos (Wood & Neal, 2007; Lally et al., 2010)	Frequência de execução em registros de uso; manutenção após semanas

Fonte: elaborada pela autora (2026).

4. PROPOSIÇÕES TESTÁVEIS

As proposições a seguir derivam do modelo. Foram redigidas de modo que resultados contrários sejam possíveis e interpretáveis.

P1 (percepção e tipo de uso). Profissionais que percebem a IA generativa como executora de etapas usarão a IA com maior frequência para executar partes de processos

recorrentes do que profissionais que a percebem principalmente como ferramenta de perguntas e respostas, controlando a frequência geral de uso e a experiência prévia.

P2 (decomposição como mediadora). A relação entre a percepção da IA como executora e a delegação de etapas será mediada pela decomposição explícita dos processos: intervenções que alteram a percepção sem levar à decomposição de um processo concreto produzirão menos delegação do que intervenções que incluem a decomposição.

P3 (alocação explícita versus técnica de pedidos). Intervenções centradas na decisão sobre quem executa cada etapa produzirão maior delegação de execução e maior uso recorrente do que intervenções de mesma duração centradas em funções da ferramenta e técnicas de formulação de pedidos, mantida constante a ferramenta.

P4 (verificação planejada). Definir o critério de verificação antes da execução reduzirá a aceitação de resultados errados em etapas em que a IA tende a falhar (menos mau uso) sem reduzir o uso da IA em etapas em que ela é confiável (sem mais desuso).

P5 (calibração ao longo do tempo). Entre pessoas que verificam sistematicamente, a alocação das etapas mudará com a experiência: etapas com erros detectados tenderão a passar para destinos com mais participação humana, e etapas com acertos repetidos, para destinos com menos verificação. Entre pessoas que não verificam, a alocação tenderá a permanecer estável independentemente do desempenho da IA.

P6 (rotinização e durabilidade). A probabilidade de que o uso da IA se mantenha semanas após uma intervenção será maior quando a intervenção resultar em pelo menos uma rotina específica (com momento, entrada, formato e verificação definidos) executada pela primeira vez logo após a decisão. A diferença entre intervenções que produzem rotinas e as que não produzem será maior em medidas tardias do que em medidas imediatas.

P7 (condições de contorno). Os efeitos previstos em P1 a P6 serão mais fortes quando a pessoa tem autonomia para alterar o próprio processo, quando o processo tem etapas repetitivas dentro da fronteira de capacidade da IA e quando o ambiente de trabalho apoia a mudança; serão mais fracos, ou nulos, entre pessoas que já usam a IA de forma intensiva para executar etapas, e o efeito sobre o tempo poderá ser negativo quando o custo de preparar e verificar superar o custo da execução manual.

Algumas proposições podem se revelar falsas sem que o modelo inteiro caia. Se P3 se confirmar para delegação mas não para uso recorrente, por exemplo, o enquadramento

mudaria o modo de usar sem mudar a rotina, o que apontaria para a rotinização como o elo frágil e indicaria onde concentrar esforços.

5. IMPLICAÇÕES PARA PESQUISA E PRÁTICA

5.1 Para a pesquisa

Medir o tipo de uso, não só a frequência. Boa parte da pesquisa sobre adoção mede se as pessoas usam a IA e com que frequência. O modelo sugere que importa também o que é delegado. Registros de uso das plataformas, codificados por avaliadores independentes, permitem distinguir pedidos de informação, de redação pontual e de execução de etapas de processos recorrentes. Essa distinção é preferível ao autorrelato, cujas limitações a literatura de transferência já documentou (Blume et al., 2010).

Medir a verificação diretamente. A verificação pode ser observada com tarefas que contêm erros ou restrições plantadas, com o tempo gasto em verificação e com a existência de critérios definidos antes da execução. Medidas desse tipo permitiriam testar P4 e P5 e distinguir uso calibrado de mau uso.

Medir a durabilidade. Muitos estudos avaliam desempenho no mesmo dia da intervenção. O argumento deste artigo é sobre mudança na rotina, o que exige medidas semanas depois, preferencialmente a partir de registros de uso. O tempo de formação de hábitos observado por Lally et al. (2010) sugere que mesmo algumas semanas captam apenas o início do processo.

Comparar intervenções com a ferramenta constante. Farach et al. (2026) mostram que é possível comparar formatos de treinamento mantendo a mesma ferramenta, e também quais armadilhas evitar: efeito teto em rubricas, perdas diferenciais entre grupos, confusão entre condição e horário, avaliação automática sensível ao tamanho do texto e ausência de pré-registro. Comparações entre intervenções centradas na alocação de etapas e intervenções centradas em técnica de pedidos, com duração e prática equivalentes, avaliadores cegos e desfechos definidos previamente, seriam o teste mais direto de P3.

Isolar componentes. Intervenções baseadas no modelo combinariam vários elementos (decomposição, alocação, verificação, rotina). Desenhos que retiram um componente de cada vez ajudariam a identificar quais deles respondem pelos efeitos, na

linha da recomendação de descrever intervenções no nível de seus componentes ativos (Michie et al., 2013).

5.2 Para o desenho de treinamentos

Começar pelo processo, não pela ferramenta. Um treinamento orientado pelo modelo partiria de um processo real do participante, não de tarefas genéricas. Essa escolha é coerente com a recomendação clássica de aproximar a situação de treino da situação de trabalho (Baldwin & Ford, 1988) e com o achado de que fatores de transferência pesam mais em habilidades que exigem julgamento (Blume et al., 2010).

Trocar a pergunta. Em vez de concentrar o tempo em formular pedidos, o treinamento poderia concentrá-lo em decompor o processo, decidir o destino de cada etapa e definir como cada execução será verificada. Uma tabela simples com três colunas (a IA faz; a IA faz e eu verifico; eu faço) é uma forma possível de tornar essa decisão concreta e discutível.

Demonstrar a verificação. Mostrar ao vivo uma etapa sendo executada pela IA e verificada segundo critérios definidos antes pode ser mais útil do que mostrar como o pedido foi formulado, porque modela o comportamento que o modelo considera crítico.

Terminar com uma rotina executada. Em vez de terminar com recomendações gerais, o treinamento terminaria com ao menos uma rotina definida (momento, entrada, formato, verificação) e executada pela primeira vez antes do fim, com um gatilho estável para a repetição seguinte.

5.3 Para organizações

Tratar a alocação como decisão de gestão. A decisão sobre quais etapas a IA executa, com ou sem verificação, tem consequências de qualidade, risco e responsabilidade. Pode ser registrada, revista periodicamente e discutida em equipe, como outras decisões sobre processos.

Definir critérios de verificação para etapas críticas. Para etapas cujo erro chega a clientes ou a decisões importantes, a organização pode exigir que exista um critério de verificação explícito e alguém responsável por aplicá-lo.

Estabelecer regras de dados claras. A delegação de etapas envolve entregar material à IA. Regras simples sobre o que nunca entra na ferramenta, e sobre como substituir dados

sensíveis por códigos ou campos em branco, reduzem riscos e também a insegurança que leva ao desuso.

Apoiar a manutenção. Dado o peso do ambiente na transferência (Blume et al., 2010), retomar periodicamente as rotinas criadas, perguntar se continuam rodando e o que mudou pode ser mais eficaz do que oferecer novos treinamentos.

Atenção ao papel de supervisão. À medida que mais etapas passam a ser executadas pela IA e verificadas por pessoas, cresce a importância de evitar que a verificação se torne formalidade. A literatura sobre complacência e viés de automação (Parasuraman & Riley, 1997; Skitka et al., 1999) e a evidência de que maior confiança na IA se associa a menos pensamento crítico (Lee et al., 2025) recomendam revisões periódicas por amostragem, mesmo de rotinas que funcionam bem.

6. LIMITAÇÕES

Ausência de teste empírico. O modelo é conceitual. As literaturas que o sustentam tratam de fenômenos próximos, como automação industrial e aeronáutica, sistemas de apoio à decisão, hábitos de saúde e treinamento corporativo, mas nenhuma delas testou a sequência proposta com IA generativa. A evidência mais próxima, o estudo de Farach et al. (2026), avalia outra intervenção e tem limitações reconhecidas pelos próprios autores.

Seleção e leitura da literatura. A revisão é narrativa e seletiva. Foram escolhidas literaturas que ajudam a construir o argumento, e é possível que estudos relevantes, inclusive contrários, tenham ficado de fora. Uma revisão sistemática sobre intervenções de treinamento em IA generativa seria um complemento útil.

Simplificação dos níveis de automação. Os três destinos propostos simplificam uma escala mais rica (Parasuraman et al., 2000). A simplificação busca utilidade prática, mas pode esconder distinções importantes, como entre verificação integral e por amostragem, ou entre IA que executa e IA que apenas sugere.

Linearidade aparente. O modelo é apresentado em sequência, mas o uso real pode começar em qualquer ponto. Uma pessoa pode criar uma rotina por imitação antes de mudar sua percepção da IA. As alças de retroalimentação atenuam esse problema sem resolvê-lo.

Explicação parcial. O artigo propõe uma explicação de nível individual para a distância entre ganhos em tarefas e efeitos agregados. Fatores organizacionais, econômicos

e tecnológicos, como custos de reorganização, repasse limitado de ganhos e restrições das ferramentas, continuam relevantes e podem ser mais importantes em muitos contextos (Humlum & Vestergaard, 2025).

Escopo de aplicação. O modelo pressupõe que a pessoa tenha alguma autonomia sobre o próprio processo de trabalho. Em ocupações muito reguladas ou com processos definidos centralmente, a decisão de alocação cabe a outros atores, e o modelo se aplicaria mais a eles do que ao trabalhador individual.

Mudança tecnológica. A fronteira de capacidade da IA se desloca rapidamente (Dell'Acqua et al., 2026). Isso reforça o argumento a favor de ensinar uma forma de decidir em vez de uma técnica, mas implica que alocações feitas hoje podem ficar desatualizadas e que o modelo precisa de revisão contínua. A disponibilidade crescente de recursos para executar rotinas sem acionamento manual pode tornar a rotinização mais fácil e, ao mesmo tempo, os riscos de complacência mais sérios.

Privacidade e responsabilidade. Delegar etapas implica entregar informações a sistemas externos e redistribuir responsabilidades. O modelo inclui uma regra de dados, mas não trata em profundidade questões jurídicas e éticas que variam por setor e país.

7. CONCLUSÃO

A distância entre o que a IA generativa consegue fazer em tarefas isoladas e o que muda na rotina dos profissionais tem muitas causas. Este artigo examinou uma delas, de natureza cognitiva: enquanto a IA for percebida principalmente como uma ferramenta de perguntas e respostas, a questão que parecerá mais importante será como pedir melhor, e o uso tenderá a permanecer pontual. A alternativa proposta é trocar essa questão por outra, mais antiga e mais ligada ao trabalho: quem faz cada etapa.

O modelo apresentado organiza essa troca em cinco elementos: perceber a IA como executora de etapas; decompor processos reais; alocar cada etapa à IA sozinha, à IA com verificação humana ou à pessoa; definir antes da execução como cada resultado será verificado; e converter as decisões em rotinas recorrentes com gatilhos estáveis. Nenhum desses elementos é novo. A contribuição está em reuni-los em uma sequência explícita, apoiada em literaturas que raramente dialogam entre si, e em derivar dela proposições que podem ser testadas e, eventualmente, refutadas.

Se as proposições se confirmarem, a implicação para treinamentos e organizações é clara:

investir menos em técnica de pedidos e mais em análise de processos, decisões de alocação, verificação planejada e manutenção de rotinas. Se não se confirmarem, saber disso também será útil, porque indicará que a explicação para a mudança limitada está em outro lugar.

DECLARAÇÃO DE INTERESSES

A autora declara não haver conflito de interesses. A autora atua como empreendedora em negócios que utilizam ferramentas de IA generativa e oferece conteúdo educacional sobre o tema; nenhuma empresa fornecedora de IA financiou ou revisou este trabalho.

DECLARAÇÃO SOBRE USO DE INTELIGÊNCIA ARTIFICIAL

Ferramentas de IA generativa foram utilizadas na preparação deste manuscrito para apoio à revisão de texto, organização de referências e tradução do resumo. A concepção do argumento, a seleção da literatura, a análise e as conclusões são de responsabilidade da autora, que revisou e validou todo o conteúdo.

REFERÊNCIAS

- Autor, D. H., Levy, F., & Murnane, R. J. (2003). The skill content of recent technological change: An empirical exploration. *The Quarterly Journal of Economics*, 118(4), 1279–1333. <https://doi.org/10.1162/003355303322552801>
- Baldwin, T. T., & Ford, J. K. (1988). Transfer of training: A review and directions for future research. *Personnel Psychology*, 41(1), 63–105. <https://doi.org/10.1111/j.17446570.1988.tb00632.x>
- Bastani, H., Bastani, O., Sungu, A., Ge, H., Kabakçı, Ö., & Mariman, R. (2025). Generative AI without guardrails can harm learning: Evidence from high school mathematics. *Proceedings of the National Academy of Sciences*, 122(26), e2422633122. <https://doi.org/10.1073/pnas.2422633122>
- Blume, B. D., Ford, J. K., Baldwin, T. T., & Huang, J. L. (2010). Transfer of training: A metaanalytic review. *Journal of Management*, 36(4), 1065–1105. <https://doi.org/10.1177/0149206309352880>
- Brynjolfsson, E., Li, D., & Raymond, L. (2025). Generative AI at work. *The Quarterly Journal of Economics*, 140(2), 889–942. <https://doi.org/10.1093/qje/qjae044>
- Buçinca, Z., Malaya, M. B., & Gajos, K. Z. (2021). To trust or to think: Cognitive forcing functions can reduce overreliance on AI in AI-assisted decision-making. *Proceedings of the ACM on Human-Computer Interaction*, 5(CSCW1), 1–21. <https://doi.org/10.1145/3449287>

- Dell'Acqua, F., McFowland III, E., Mollick, E. R., Lifshitz-Assaf, H., Kellogg, K., Rajendran, S., Kraye, L., Candelon, F., & Lakhani, K. R. (2023). *Navigating the jagged technological frontier: Field experimental evidence of the effects of AI on knowledge worker productivity and quality* (Harvard Business School Working Paper No. 24-013). <https://doi.org/10.2139/ssrn.4573321>
- Dell'Acqua, F., McFowland III, E., Mollick, E., Lifshitz, H., Kellogg, K. C., Rajendran, S., Kraye, L., Candelon, F., & Lakhani, K. R. (2026). Navigating the jagged technological frontier: Field experimental evidence of the effects of artificial intelligence on knowledge worker productivity and quality. *Organization Science*, 37(2), 403–423. <https://doi.org/10.1287/orsc.2025.21838>
- Dietvorst, B. J., Simmons, J. P., & Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err. *Journal of Experimental Psychology: General*, 144(1), 114–126. <https://doi.org/10.1037/xge0000033>
- Eloundou, T., Manning, S., Mishkin, P., & Rock, D. (2024). GPTs are GPTs: Labor market impact potential of LLMs. *Science*, 384(6702), 1306–1308. <https://doi.org/10.1126/science.adj0998>
- Farach, A., Cambon, A., Tankelevitch, L., Hsueh, C., & Janssen, R. (2026). *Scaffolding human–AI collaboration: A field experiment on behavioral protocols and cognitive reframing* (arXiv:2604.08678v2) [Preprint]. arXiv. <https://arxiv.org/abs/2604.08678>
- Garg, A., Soodhani, K. N., & Rajendran, R. (2025). Enhancing data analysis and programming skills through structured prompt training: The impact of generative AI in engineering education. *Computers and Education: Artificial Intelligence*, 8, 100380. <https://doi.org/10.1016/j.caeai.2025.100380>
- Gollwitzer, P. M. (1999). Implementation intentions: Strong effects of simple plans. *American Psychologist*, 54(7), 493–503. <https://doi.org/10.1037/0003-066X.54.7.493>
- Gollwitzer, P. M., & Sheeran, P. (2006). Implementation intentions and goal achievement: A meta-analysis of effects and processes. *Advances in Experimental Social Psychology*, 38, 69–119. [https://doi.org/10.1016/S0065-2601\(06\)38002-1](https://doi.org/10.1016/S0065-2601(06)38002-1)
- Hackman, J. R., & Oldham, G. R. (1976). Motivation through the design of work: Test of a theory. *Organizational Behavior and Human Performance*, 16(2), 250–279. [https://doi.org/10.1016/0030-5073\(76\)90016-7](https://doi.org/10.1016/0030-5073(76)90016-7)
- Humlum, A., & Vestergaard, E. (2025). *Large language models, small labor market effects* (NBER Working Paper No. 33777). National Bureau of Economic Research. <https://www.nber.org/papers/w33777>
- Jahani, E., Manning, B. S., Zhang, J., TuYe, H.-Y., Alsobay, M., Nicolaides, C., Suri, S., & Holtz, D. (2026). Prompt adaptation as a dynamic complement in generative AI systems.

Information Systems Research. Advance online publication.
<https://doi.org/10.1287/isre.2025.2029>

- Lally, P., van Jaarsveld, C. H. M., Potts, H. W. W., & Wardle, J. (2010). How are habits formed: Modelling habit formation in the real world. *European Journal of Social Psychology*, 40(6), 998–1009. <https://doi.org/10.1002/ejsp.674>
- Lebovitz, S., Lifshitz-Assaf, H., & Levina, N. (2022). To engage or not to engage with AI for critical judgments: How professionals deal with opacity when using AI for medical diagnosis. *Organization Science*, 33(1), 126–148.
<https://doi.org/10.1287/orsc.2021.1549>
- Lee, H.-P., Sarkar, A., Tankelevitch, L., Drosos, I., Rintel, S., Banks, R., & Wilson, N. (2025). The impact of generative AI on critical thinking: Self-reported reductions in cognitive effort and confidence effects from a survey of knowledge workers. In *Proceedings of the 2025 CHI Conference on Human Factors in Computing Systems* (pp. 1–22). ACM.
<https://doi.org/10.1145/3706598.3713778>
- Lee, J. D., & See, K. A. (2004). Trust in automation: Designing for appropriate reliance. *Human Factors*, 46(1), 50–80. https://doi.org/10.1518/hfes.46.1.50_30392
- Michie, S., Richardson, M., Johnston, M., Abraham, C., Francis, J., Hardeman, W., Eccles, M. P., Cane, J., & Wood, C. E. (2013). The behavior change technique taxonomy (v1) of 93 hierarchically clustered techniques: Building an international consensus for the reporting of behavior change interventions. *Annals of Behavioral Medicine*, 46(1), 81–95.
<https://doi.org/10.1007/s12160-013-9486-6>
- Morgeson, F. P., & Humphrey, S. E. (2006). The Work Design Questionnaire (WDQ): Developing and validating a comprehensive measure for assessing job design and the nature of work. *Journal of Applied Psychology*, 91(6), 1321–1339.
<https://doi.org/10.1037/0021-9010.91.6.1321>
- Noy, S., & Zhang, W. (2023). Experimental evidence on the productivity effects of generative artificial intelligence. *Science*, 381(6654), 187–192.
<https://doi.org/10.1126/science.adh2586>
- Orlikowski, W. J., & Gash, D. C. (1994). Technological frames: Making sense of information technology in organizations. *ACM Transactions on Information Systems*, 12(2), 174–207. <https://doi.org/10.1145/196734.196745>
- Parasuraman, R., & Riley, V. (1997). Humans and automation: Use, misuse, disuse, abuse. *Human Factors*, 39(2), 230–253. <https://doi.org/10.1518/001872097778543886>
- Parasuraman, R., Sheridan, T. B., & Wickens, C. D. (2000). A model for types and levels of human interaction with automation. *IEEE Transactions on Systems, Man, and*

Cybernetics – Part A: Systems and Humans, 30(3), 286–297.
<https://doi.org/10.1109/3468.844354>

Raisch, S., & Krakowski, S. (2021). Artificial intelligence and management: The automation–augmentation paradox. *Academy of Management Review*, 46(1), 192–210.
<https://doi.org/10.5465/amr.2018.0072>

Skitka, L. J., Mosier, K. L., & Burdick, M. (1999). Does automation bias decision-making? *International Journal of Human-Computer Studies*, 51(5), 991–1006.
<https://doi.org/10.1006/ijhc.1999.0252>

Tankelevitch, L., Kewenig, V., Simkute, A., Scott, A. E., Sarkar, A., Sellen, A., & Rintel, S. (2024). The metacognitive demands and opportunities of generative AI. In *Proceedings of the CHI Conference on Human Factors in Computing Systems* (pp. 1–24). ACM.
<https://doi.org/10.1145/3613904.3642902>

Tims, M., & Bakker, A. B. (2010). Job crafting: Towards a new model of individual job redesign. *SA Journal of Industrial Psychology*, 36(2).
<https://doi.org/10.4102/sajip.v36i2.841>

Vaccaro, M., Almaatouq, A., & Malone, T. (2024). When combinations of humans and AI are useful: A systematic review and meta-analysis. *Nature Human Behaviour*, 8(12), 2293–2303. <https://doi.org/10.1038/s41562-024-02024-1>

Wood, W., & Neal, D. T. (2007). A new look at habits and the habit-goal interface. *Psychological Review*, 114(4), 843–863.
<https://doi.org/10.1037/0033-295X.114.4.843>

Wrzesniewski, A., & Dutton, J. E. (2001). Crafting a job: Revisioning employees as active crafters of their work. *Academy of Management Review*, 26(2), 179–201.
<https://doi.org/10.2307/259118>

Zamfirescu-Pereira, J. D., Wong, R. Y., Hartmann, B., & Yang, Q. (2023). Why Johnny can't prompt: How non-AI experts try (and fail) to design LLM prompts. In *Proceedings of the 2023 CHI Conference on Human Factors in Computing Systems* (pp. 1–21). ACM.
<https://doi.org/10.1145/3544548.3581388>