

Gastrack Framework: Estratégia Humano-IA e Previsão na Era do Mercado Livre de Gás Natural

LAURA VISINTAINER LERMAN¹; FERNANDA SCHNEIDER THEBIT²; MÁRCIO VINICIUS CAMPOS DA ROCHA³; HENRIQUE SALES DE SOUZA⁴; ALEXANDRE KAPPEL²

¹ UNIVERSIDADE TÉCNICA DE MUNIQUE, MUNIQUE - ALEMANHA; ² EVCOMX, ENCANTADO - RS - BRASIL; ³ COMPANHIA DE GAS DE SP - COMGÁS, SÃO PAULO - SP - BRASIL; ⁴ COMPANHIA DE GÁS DE SÃO PAULO - COMGÁS, SÃO PAULO - SP - BRASIL.

Resumo

A liberalização do mercado de gás natural criou novas oportunidades para consumidores industriais, permitindo maior flexibilidade na contratação e potencial para a otimização de custos. No entanto, esse novo cenário também introduz complexidade: para usufruir plenamente do mercado livre, grandes consumidores precisam prever seu consumo de gás com precisão, a fim de evitar penalidades e negociar de forma mais eficiente. Nesse contexto, um importante agente do setor de distribuição de gás natural redefiniu seu papel, apoiando clientes na interpretação das dinâmicas de mercado e na transformação de dados operacionais em insights estratégicos. Este estudo apresenta o Gastrack Framework, uma estratégia humano-IA desenvolvida para auxiliar consultores e clientes industriais na gestão do conhecimento e na previsão da demanda de gás natural no ambiente do mercado livre. O framework integra modelos de previsão de consumo com técnicas de inteligência artificial explicável (XAI), que tornam as previsões transparentes e interpretáveis. Ele também incorpora uma camada de inteligência contextual que agrega indicadores setoriais e notícias de mercado confiáveis, enriquecendo as previsões com compreensão qualitativa. Em sua essência, o Gastrack é capaz de replicar o comportamento humano de busca por conhecimento, atuando como um agente cognitivo que media interações entre consultores e clientes.

Palavras-chave: inteligência artificial explication; gás natural; humano e inteligencia e artificial; gestão de conhecimento; agente de AI.

1. Introdução

A abertura do mercado de gás natural tem alterado substancialmente a forma como grandes consumidores industriais contratam energia, ao incorporar maior flexibilidade, alternativas de suprimento e oportunidades de otimização de custos (Campos et al., 2020; Ximenes et al. 2023). Em contrapartida, trata-se de um setor fortemente regulamentado e o ambiente de mercado livre amplia a complexidade operacional e contratual: erros na previsão de consumo podem resultar em penalidades, ineficiências de portfólio e decisões comerciais subótimas (Baleroni & de Carvalho, 2020). Adicionalmente, previsões inconsistentes ou pouco confiáveis deterioram a experiência do cliente e podem acelerar a troca de fornecedor, tornando qualidade, governança e comunicabilidade da previsão fatores críticos não apenas para eficiência, mas também para retenção e relacionamento (Varandas, 2021).

Nesse contexto, distribuidoras e comercializadoras expandem seu papel para além do fornecimento (Calôba & Lins, 2005), atuando como provedoras de consultoria orientada a dados. Essa consultoria especializada demanda integrar dados operacionais do cliente, sinais de mercado e conhecimento tácito de especialistas para produzir recomendações acionáveis, em especial na estimativa de demanda e no desenho de estratégias de contratação (Araujo, 2023). Assim, fortalecer a relação com o cliente por meio de previsões robustas, justificativas claras e decisões auditáveis torna-se requisito central, pois conecta desempenho analítico a confiança, continuidade contratual e diferenciação competitiva.

Do ponto de vista teórico, três eixos são particularmente relevantes para sustentar decisões em consultoria energética: gestão do conhecimento, colaboração Humano-IA e eXplainable Artificial Intelligence (XAI). Em ambientes sujeitos a mudanças regulatórias e tecnológicas, a gestão do conhecimento reduz dependência de expertise individual e aumenta consistência decisória. Nonaka e Takeuchi (1995) descrevem a criação organizacional de conhecimento como um ciclo de conversão entre conhecimento tácito e explícito; em consultoria energética, esse ciclo se manifesta quando interpretações e experiências de especialistas são externalizadas como hipóteses, regras operacionais e narrativas justificadas, passíveis de reutilização e auditoria. Em paralelo, agentes baseados em grandes modelos de linguagem (LLMs) podem atuar como mediadores cognitivos ao automatizar busca, síntese e interação em linguagem natural. No entanto, seu valor depende de como são acoplados ao trabalho humano, suportando verificação, negociação de significados e registro de premissas em ciclos iterativos de feedback (Tseng & Chang, 2025). Por fim, embora técnicas de aprendizado de máquina (ML) tenham avançado na previsão de séries temporais, sua adoção em contextos consultivos e decisórios no setor energético requer transparência e auditabilidade. A XAI busca tornar previsões e recomendações mais compreensíveis, elevando confiança e capacidade de inspeção. Métodos locais de explicação (Ribeiro et al., 2016) e técnicas baseadas em atribuição (Lundberg & Lee, 2017) permitem identificar variáveis influentes e comunicar limites do modelo — aspecto especialmente relevante em ambientes industriais nos quais riscos operacionais e contratuais demandam justificativas rastreáveis.

Além disso, papel do consultor no ciclo de previsão-decisão no mercado livre de gás natural é crucial para ferramentas como Gastrack possam gerar resultados. Por exemplo, em domínios regulados e fortemente condicionados por contratos, penalidades e restrições operacionais, o consultor atua como agente humano de decisão e elemento de governança tecnológica e social, exercendo funções que extrapolam a simples comunicação de resultados. Nessa perspectiva, os resultados do Gastrack Framework não devem ser tratadas apenas como mecanismo de maximização da previsão de consumo de gás natural, mas como componente de um sistema decisório no qual explicabilidade e governança de premissas são requisitos consultivos. O valor do modelo está no papel do consultor em analisar os dados e tomar as melhores decisões para os clientes. Ainda assim, persiste uma lacuna na literatura e na prática aplicada: abordagens de previsão frequentemente posicionam explicabilidade como etapa posterior e desconectada do fluxo decisório, enquanto mecanismos de gestão do conhecimento e governança de premissas raramente são integrados de forma sistemática ao ciclo previsão-decisão em contextos regulados. No mercado livre de gás, a decisão não depende somente de desempenho estatístico, mas da capacidade de vincular previsões a premissas contratuais, eventos operacionais, evidências externas e justificativas verificáveis, reduzindo risco de penalidades e sustentando o relacionamento consultivo com o consumidor industrial e posicionando o consultor como peça central nessa transição, promovendo, assim, uma melhor interface Humano-Agente ou Humano-IA.

Motivado por esse cenário, este estudo propõe e avalia o Gastrack Framework, um artefato desenvolvido segundo Design Science Research (DSR), que integra: (i) modelagem preditiva baseada em ML, (ii) módulos de XAI para transparência, inspeção e auditoria de fatores explicativos, e (iii) mecanismos de gestão do conhecimento para codificação e recuperação de premissas, eventos e evidências relevantes ao contexto decisório. O Gastrack é concebido como ferramenta de trabalho do consultor, isto é, um artefato instrumental que organiza e sustenta a atividade consultiva com rastreabilidade e governança.

Nesse arranjo, a relação Humano-IA é operacionalizada de modo instrumental e governado: o consultor permanece como agente humano responsável pela decisão, enquanto utiliza o Gastrack para ampliar capacidade analítica e padronizar a justificativa. Assim, em vez de atuar como mero canal de comunicação, o consultor é reposicionado como orquestrador do raciocínio e curador de contexto, utilizando Gastrack Framework, como mecanismo de escalabilidade cognitiva, redução de assimetria informacional e fortalecimento da auditabilidade.

O desenvolvimento do Gastrack Framework ocorre de forma iterativa com ciclos de construção e refinamento orientados por requisitos de campo e feedback de stakeholders. A avaliação do artefato é conduzida por métodos apropriados ao domínio, considerando qualidade das explicações, tempo de decisão, consistência das recomendações, conformidade regulatória/auditável e indicadores de relacionamento. Nessa perspectiva, o framework reposiciona o uso de IA no mercado livre de gás: em vez de tratar IA apenas como automação de previsão, estrutura agentes como mediadores orientados ao relacionamento com o consumidor industrial, capazes de incorporar contexto, reduzir risco decisório e transformar dados e conhecimento em recomendações justificáveis e auditáveis. Isso contribui para retenção e diferenciação competitiva. Como principais contribuições, o trabalho propõe uma arquitetura integrada que acopla modelagem preditiva, explicabilidade e captura sistemática de premissas e eventos ao ciclo decisório, assegurando rastreabilidade de evidências e justificativas. Além disso, define uma estratégia Humano-IA orientada à decisão consultiva, na qual um agente atua como mediador da interação e reduzindo a assimetria entre modelos e especialistas, de modo a promover recomendações mais auditáveis e consistentes.

2. Metodologia

Este estudo fundamenta-se no DSR, amplamente adotado na área de Sistemas de Informação e Engenharia para o desenvolvimento de artefatos voltados à solução de problemas organizacionais complexos. Diferentemente de abordagens puramente explanatórias, a DSR é orientada à construção intencional de soluções cujo propósito é gerar utilidade prática sem abdicar do rigor científico.

A escolha da DSR justifica-se pela natureza do problema investigado: a necessidade de estruturar um artefato capaz de integrar modelos preditivos baseados em ML, mecanismos de XAI e práticas de gestão do conhecimento no contexto do mercado livre de gás natural que apoiam o processo decisório do consultor. Trata-se de um ambiente caracterizado por incerteza contratual, assimetria informacional e elevada complexidade regulatória, no qual decisões baseadas exclusivamente em previsão algorítmica tendem a ser insuficientes.

Conforme argumentam Venable et al. (2016), a DSR deve articular ciclos iterativos de construção e avaliação, combinando episódios formativos e naturalísticos para fortalecer a validade prática do artefato. Assim, a pesquisa estrutura-se em três fases interdependentes: (i) identificação do problema e definição de requisitos; (ii) design e desenvolvimento do artefato; e (iii) avaliação qualitativa com especialistas do domínio.

2.1. Fundamentação Teórica da Estratégia de Design

A construção do Gastrack Framework é teoricamente sustentada por três eixos principais:

- *Design Science Research* e avaliação estruturada, conforme o framework FEDS (Venable et al., 2016);
- Explicabilidade e diretrizes éticas em IA, conforme Nevanperä et al. (2021);
- Colaboração *Humano-IA* e papel ampliado da IA em processos de design, conforme Gau et al. (2025), com foco no papel do consultor.

A literatura enfatiza que artefatos baseados em IA devem incorporar princípios de transparência desde sua concepção, especialmente em contextos decisórios sensíveis (Nevanperä et al., 2021). No mercado livre de gás, decisões equivocadas podem gerar penalidades financeiras significativas, reforçando a necessidade de interpretabilidade das previsões por parte dos consultores.

Além disso, estudos indicam que a IA não deve ser concebida apenas como ferramenta automatizada, mas como componente colaborativo no processo de design e tomada de decisão (Gau et al., 2025). Tal perspectiva fundamenta a proposta de um modelo Humano-IA mediado, no qual o sistema não substitui o consultor, mas amplia sua capacidade analítica.

Por fim, a adoção organizacional de IA depende de maturidade estrutural e alinhamento estratégico (Nahringbauer, 2025). Assim, o framework proposto incorpora mecanismos de aprendizado contínuo e adaptação contextual.

2.2. Fase I – Identificação do Problema e Requisitos de Design

A primeira fase consistiu na delimitação estruturada do problema organizacional. A investigação envolveu revisão sistemática da literatura sobre previsão de consumo energético, gestão de risco contratual, relação Humano-IA, relacionamento com os clientes e explicabilidade em sistemas de IA, combinada à análise exploratória do domínio por meio de interação com especialistas do setor.

Foram identificados quatro desafios centrais: variabilidade e imprevisibilidade do consumo; penalidades por desvios contratuais; dificuldade de interpretação de modelos preditivos;

necessidade de mediação entre previsão técnica e decisão estratégica por parte dos consultores.

A partir disso, estabeleceram-se requisitos que orientaram o desenvolvimento do artefato: integração de modelos preditivos; implementação de técnicas de XAI; incorporação de conhecimento contextual; suporte à mediação consultor–cliente por meio da interação Humano-IA. A ênfase na explicabilidade está alinhada às recomendações de Nevanperä et al. (2021), que defendem a operacionalização prática de princípios éticos no ciclo de desenvolvimento de sistemas de IA e também do papel do consultor no processo decisório.

2.3 Fase II – Design e Desenvolvimento do Gastrack Framework

A segunda fase envolveu a concepção e desenvolvimento iterativo do Gastrack Framework. O processo incluiu modelagem arquitetural, prototipação conceitual e refinamento por meio de entrevistas com especialistas.

O framework foi estruturado em três camadas interdependentes:

- Camada 1 – Inteligência Preditiva: Responsável pela modelagem de consumo via ML e geração de explicações por meio de técnicas de XAI.
- Camada 2 – Mediação de Conhecimento: Destinada à tradução das previsões em recomendações estratégicas, integrando contexto contratual, histórico organizacional e critérios de negociação.
- Camada 3 – Aprendizado Colaborativo: são incorporados feedbacks humanos e de teste para ajuste progressivo do sistema, fortalecendo aprendizagem organizacional em conjunto com os consultores.

Essa estrutura operacionaliza a concepção de IA como mediadora de conhecimento, aproximando-se da visão exploratória proposta por Gau et al. (2025), na qual agentes inteligentes participam ativamente do processo de design e decisão. No caso, essa interação Humano-IA torna-se estratégica para/com o relacionamento com os clientes.

2.4 Fase III – Avaliação do Artefato

A avaliação foi conduzida por meio de entrevistas semi-estruturadas com especialistas do setor. Seguindo o framework FEDS (Venable et al., 2016), a avaliação assumiu caráter predominantemente formativo e naturalístico, permitindo testar o artefato em contexto próximo à realidade operacional.


Os dados coletados foram submetidos à análise temática qualitativa, identificando padrões de percepção e oportunidades de refinamento.

2.5 Síntese Metodológica

A Tabela 1 apresenta a consolidação das fases do estudo, e a Figura 1 complementa essa visualização.

Tabela 1 - Síntese das Fases da Design Science Research

Fase	Objetivo	Estratégias Metodológicas	Resultado Principal
Identificação	Compreensão do problema e requisitos	Revisão sistemática + análise exploratória	Definição de requisitos técnicos e organizacionais
Design	Construção do framework	Modelagem, co-design, prototipação	Arquitetura em três camadas
Avaliação	Verificação de utilidade e aplicabilidade	Workshops e entrevistas	Evidências formativas e refinamento



2.6 Contribuição Metodológica

O artigo demonstra que a aplicação da DSR ao contexto do mercado livre de gás permite integrar rigor técnico e relevância organizacional em um contexto altamente competitivo. A principal contribuição metodológica reside na articulação entre: princípios de explicabilidade e ética em IA; colaboração Humano-IA; avaliação estruturada; incorporação de ciclos de aprendizagem organizacional; melhoria da relação consultor-clientes. Ao se posicionar o consultor na relação Humano-IA, o estudo amplia o

escopo tradicional de sistemas preditivos, contribuindo para a literatura de DSR aplicada à energia e à IA.

3. Resultados

O Gastrack Framework estrutura o processo consultivo como um ciclo de co-inteligência Humano-IA, no qual previsões quantitativas e interpretações qualitativas são produzidas, explicadas e refinadas com base em feedback de consultores especializadas. Os resultados do Gastrack são analisados por consultores experientes que o utilizam como uma ferramenta estratégica para melhorar relação com seus clientes industriais.

3.1 Camada de inteligência preditiva (ML + XAI)

A camada de inteligência preditiva é composta por um pipeline de modelagem supervisionada para séries temporais. A engenharia de atributos é realizada por meio da derivação sistemática de *features* temporais e sazonais, incluindo termos autorregressivos, estatísticas de janela móvel, diferenças e taxas de variação, além de decomposição harmônica para representar sazonalidades. Quando disponíveis, variáveis exógenas adicionais podem ser incorporadas, permitindo, assim, a captura de drivers contextuais e efeitos de intervenção.

A estimação é conduzida com modelos de regressão baseados em ML. O desempenho é avaliado por comparação com benchmarks representativos, utilizando validação temporal apropriada e métricas de erro compatíveis com o objetivo de negócio.

As previsões são acompanhadas por técnicas de XAI para atribuição de importância e análise de contribuição de variáveis, com três finalidades: (a) identificar e quantificar fatores determinantes do consumo previsto, (b) permitir verificação de coerência com o conhecimento operacional do consultor e (c) sustentar comunicação auditável e transparente dos resultados ao cliente. Dessa forma, a camada fornece estimativas preditivas e evidências interpretáveis, elevando rastreabilidade, confiabilidade e aplicabilidade na tomada de decisão dos consultores de gás natural.

3.2 Camada de mediação de conhecimento (consultor–cliente)

A camada de mediação de conhecimento operacionaliza a interface entre resultados analíticos e o processo decisório por meio de interação em linguagem natural sob restrições explícitas de governança. O agente Gastrack atua como mecanismo mediador de conhecimento para o consultor, registrando hipóteses e premissas, recuperando histórico de decisões e eventos operacionais e promovendo a externalização de justificativas tácitas em explicações explícitas e rastreáveis. O objetivo é converter a previsão em um artefato deliberativo em vez de um *output* numérico para que o consultor consiga direcionar a melhor estratégia para seus clientes.

3.2.1 Arquitetura multiagente e governança de resposta

Para suportar mediação em linguagem natural com controle de qualidade e conformidade, a implementação adota uma arquitetura multiagente. Nessa configuração, um módulo Orquestrador encaminha cada consulta para um agente especializado segundo uma taxonomia de tarefas e um conjunto de regras determinísticas de roteamento.

Um princípio de desenho central é a restrição de “inferência zero” em domínios de alta criticidade. Nessas classes, a resposta deve ser produzida sob o paradigma de geração fundamentada em

recuperação. Essa política reduz alucinações, melhora calibração epistêmica e eleva auditabilidade, ao custo controlado de maior dependência de cobertura das bases e maior taxa de abstenção quando evidências são insuficientes.


O Orquestrador opera como ponto único para aplicação de políticas e registro de trilha de auditoria. Esse desenho favorece governança em ambiente corporativo e suporta mecanismos *human-in-the-loop* para casos ambíguos ou de baixa evidência. Dessa forma, promovendo que as saídas sejam mais precisas para os consultores.

3.3 Camada de inteligência contextual e aprendizado colaborativo

Para reduzir o risco de previsões estatisticamente adequadas, porém desalinhadas ao contexto operacional e setorial, o framework incorpora uma camada de inteligência contextual. Esses sinais são tratados como evidências auxiliares para: (i) explicar desvios entre previsão e realizado, (ii) sustentar ajustes justificados quando aplicável e (iii) aprimorar a comunicação e rastreabilidade junto ao cliente.

A aquisição e organização desses sinais é operacionalizada por dois workflows complementares em desenvolvimento(1) Orquestração e cobertura setorial. Este workflow mantém conjuntos de Setor. Cada conjunto é encaminhado para o workflow responsável pela extração e estruturação do conteúdo,

(2) Extração, estruturação e persistência. Este workflow captura conteúdo e metadados relevantes. Em seguida, um módulo de extração orientado por IA transforma o material coletado em registros estruturados.



4. Discussão

O Gastrack Framework estrutura-se como um modelo de co-inteligência Humano-IA, integrando dimensões quantitativas e qualitativas para apoiar a tomada de decisão no mercado livre de gás. Na dimensão quantitativa, a Inteligência Preditiva consolida dados históricos, operacionais e externos, aplicando modelos preditivos com suporte de XAI para geração de previsões e justificativas baseadas em fatores determinantes. Na dimensão qualitativa, as Interpretações Qualitativas incorporam entrevistas, painéis de especialistas e avaliações iterativas, promovendo análise crítica, utilidade percebida e adoção do sistema. Ambas convergem para uma Camada de Mediação de Conhecimento (Consultor-Cliente), sustentada por arquitetura multiagente, registro de premissas e explicações auditáveis, operacionalizadas pelo *Gastrack AI Agent*. O framework é complementado por uma Camada de Inteligência Contextual e Aprendizado Colaborativo, responsável por estruturar padrões e regras e promover aprendizado contínuo por meio de ciclos de feedback. Em síntese, o modelo integra previsão, explicabilidade, mediação organizacional e aprendizado adaptativo, posicionando a IA como mediadora estratégica de conhecimento.

4.1. Reposicionando a previsão como processo sociotécnico de gestão do conhecimento

Tradicionalmente, sistemas de previsão de consumo são concebidos como artefatos técnicos cujo valor deriva predominantemente da acurácia estatística. O Gastrack Framework desloca esse eixo: a previsão deixa de ser apenas um output numérico e passa a ser entendida como um processo sociotécnico de gestão do conhecimento, no qual estimativas quantitativas e interpretações qualitativas são produzidas, explicadas e refinadas ao longo do tempo.

Esse reposicionamento dialoga diretamente com a literatura de XAI no relacionamento com os clientes em relação com a cadeias de suprimentos. Em decisões complexas, a utilidade prática da previsão depende da inteligibilidade dos critérios, *trade-offs* e justificativas que conectam o modelo ao contexto operacional. Chen et al. (2025) evidenciam a necessidade de instrumentação explicável em processos decisórios de supply chain, enquanto Kilari (2023) sustenta que a adoção organizacional de previsões é condicionada pela mitigação do “*black box*”, sobretudo quando previsões informam planejamento e precificação. Assim, o Gastrack internaliza a premissa de que: modelos de ML produzem estimativas; a decisão emerge da interpretação contextualizada dessas estimativas. O valor do framework, portanto, desloca-se para a capacidade de converter *outputs* preditivos em conhecimento acionável, incorporando premissas operacionais, restrições de operação e experiência acumulada.

Contribuição teórica 1: o framework propõe a previsão como prática deliberativa e cumulativa de gestão do conhecimento, reduzindo a lacuna entre previsão como “resultado técnico” e decisão como “processo organizacional”.

4.2. O agente de IA como mediador cognitivo entre domínios

Ao operar como agente cognitivo, o Gastrack não se limita a automatizar inferência preditiva: ele funciona como mediador socio-técnico. Essa função pode ser lida a partir de Castelfranchi (1998), que argumenta que sistemas sociais multiagentes dependem de mecanismos de delegação, adoção de metas e coordenação antecipatória para viabilizar cooperação. No Gastrack, a dinâmica se estrutura como: o consultor delega ao agente tarefas analíticas; o agente traduz resultados técnicos em narrativas compreensíveis; o cliente adota recomendações com base na explicação fornecida.

Essa dinâmica é compatível com achados contemporâneos de co-design humano-IA, em que o agente deixa de ser ferramenta passiva e passa a atuar como “colega cognitivo” (Tseng & Chang, 2025; Zhou et al., 2024), ampliando exploração, síntese e capacidade de convergência. No Gastrack, essa colaboração se materializa na explicitação de premissas, registro de feedback e ajuste progressivo de recomendações. Em termos organizacionais, o agente passa a operar como infraestrutura de boundary work (Carlile, 2004), promovendo transferência, tradução e transformação de conhecimento entre domínios heterogêneos.

Contribuição teórica 2: o framework conceptualiza o agente como mediador cognitivo que organiza a colaboração consultor–cliente como coordenação orientada a evidências e negociação de premissas.

4.3. Redução da assimetria de informação via XAI e implicações de governança

Do ponto de vista tecnológico, a integração de XAI no Gastrack reduz assimetrias de informação entre especialistas e usuários de negócio. Chen et al. (2025) mostram que mecanismos de explicação estruturada e rastreabilidade ampliam o entendimento e a utilidade decisória em problemas de cadeias de suprimentos; Kilari (2023) reforça que explicabilidade contribui para confiança e *accountability* ao tornar o raciocínio do modelo examinável. No Gastrack, a explicação vai além de “*feature importance*”: incorpora justificativas contextualizadas, registro de premissas e histórico de revisões e *feedback*. Dessa forma, a explicação não é mero recurso de interface, mas uma condição de governança do processo decisório.

Essa concepção se aproxima da agenda de governança de agentes proposta por Kolt (2025), que argumenta que sistemas agentivos exigem visibilidade e *accountability* estruturadas para mitigar riscos associados à delegação automatizada. Ao registrar premissas, evidências e revisões, o Gastrack institui mecanismos que favorecem transparência decisória, rastreabilidade organizacional e responsabilização compartilhada.

Contribuição teórica 3: o framework reposiciona XAI como infraestrutura de governança, reduzindo assimetria informacional e convertendo previsão em evidência auditável para decisões organizacionais.

5. Conclusão

Este artigo apresenta o Gastrack Framework como uma estratégia Humano-IA para apoiar simultaneamente gestão do conhecimento e previsão de consumo no mercado livre de gás natural. Nessa estratégia, o consultor é formalizado como agente humano responsável pela decisão, utilizando o Gastrack como ferramenta estruturante de sua prática consultiva. Ao integrar modelagem preditiva supervisionada, técnicas de XAI, inteligência contextual e uma arquitetura multiagente, o framework propõe uma reconfiguração da prática preditiva para consultores no mercado de gás natural. As previsões deixam de ser apenas estimativas numéricas e passam a constituir artefatos deliberativos, rastreáveis e acionáveis, cuja validação e aplicação permanecem sob *accountability* humana, mostrando a importância da relação Humano-IA.

O desenho do Gastrack combina três dimensões complementares, utilizada pelo consultor no exercício de sua função decisória, melhorando sua relação com os clítenes.. A dimensão analítica, sustentada por modelos de ML, assegura robustez estatística e aderência ao comportamento histórico do consumo, ampliando a capacidade diagnóstica do consultor em diferentes contextos. A dimensão

explicativa, apoiada em XAI, reduz assimetria informacional entre especialistas técnicos e usuários de negócio, fornecendo ao consultor elementos estruturados para justificar recomendações, interpretar desvios e sustentar negociações com base em evidências e promover uma melhor consultoria para seus clientes. A dimensão organizacional institui uma memória operacional que transforma previsões em conhecimento cumulativo sob curadoria e validação do agente humano. O consultor a utiliza como um fechamento da sua análise.

Do ponto de vista teórico, o framework sustenta as seguintes contribuições principais. Primeiro, a previsão é redefinida como processo de gestão do conhecimento mediado por agente humano (consultor). Trata-se de prática deliberativa, negociável e auditável, na qual o consultor estrutura premissas, valida hipóteses e formaliza justificativas, deslocando o foco da acurácia isolada para a qualidade argumentativa e institucional da decisão com base nos seus conhecimentos prévios do mercado de gás natural. Segundo, a explicabilidade é concebida como infraestrutura de coordenação e accountability, operando como mecanismo organizacional que apoia o consultor na construção de uma lógica verificável e no alinhamento entre domínios técnico, comercial e regulatório. Terceiro, a arquitetura multiagente estabelece modelo de suporte automatizado sob supervisão humana, no qual o consultor mantém autoridade decisória e responsabilidade institucional.

De forma geral, o Gastrack demonstra que a explicabilidade não deve ser compreendida apenas como exigência ética ou regulatória, mas como mecanismo estruturante da prática consultiva e da governança decisória. Ao posicionar o consultor como usuário ativo e responsável pela ferramenta, o framework explicita uma relação Humano-IA de natureza instrumental e governada. O Gastrack amplia capacidade analítica, consistência argumentativa e rastreabilidade, enquanto a decisão permanece ancorada em julgamento especializado do consultor.

Apesar dos avanços, a consolidação empírica do framework demanda investigação adicional. Recomenda-se aplicação longitudinal em múltiplos clientes e setores com desenho quase experimental. Sugere-se também avaliação quantitativa de desempenho e impacto econômico, incluindo métricas como redução de penalidades contratuais, eficiência em renegociações e otimização de alocação de capacidade. Adicionalmente, é necessária evolução contínua da governança de dados e da curadoria de fontes contextuais, assegurando qualidade, relevância e confiabilidade das evidências externas utilizadas pelo consultor.

Em síntese, o Gastrack Framework sugere que o futuro da previsão em ambientes industriais regulados não reside apenas em modelos mais precisos, mas em arquiteturas sociotécnicas que empoderem o consultor como agente humano responsável, tornando o raciocínio explícito, auditável e cumulativo. Ao articular inteligência preditiva, explicabilidade e mediação colaborativa instrumental, o framework oferece base conceitual e operacional para reimaginar a previsão como prática de co-inteligência orientada à decisão responsável sob governança humana explícita, retratada, nesse contexto, no papel do consultor de gás natural.

6. Agradecimentos

Agradecemos à Alexander von Humboldt Foundation pela concessão da bolsa, bem como ao P&D Comgás pelo apoio oferecido ao projeto.

Referências

Araujo, E. C. D. (2023). *Infraestrutura avançada de medição para gestão inteligente de gás natural em clientes industriais*.

- Baleroni, R. B., & de Carvalho, I. L. (2020). *Dificuldades regulatórias do mercado livre de gás em duto e novos modelos de comercialização de gás*.
- Calôba, G. M., & Lins, M. P. E. (2005). Análise da eficiência das distribuidoras de gás natural brasileiras utilizando Análise Envoltória de Dados. *Simpósio Brasileiro de Pesquisa Operacional* (Vol. 37).
- Campos, A. F., Júnior, A. O. P., & Felipe, E. S. (2020). Reflexões sobre o Programa Novo Mercado de Gás: Abertura de mercado, transição e expansão do setor de gás natural no Brasil. *Revista Brasileira de Energia*, 26(2).
- Carlile, P. R. (2004). Transferring, translating, and transforming knowledge. *Organization Science*, 15(5), 555–568.
- Gau, M., Kretzer, F., Maedche, A., & vom Brocke, J. (2025). AI-based design science research: An exploratory framework for leveraging artificial intelligence in design science research. In (Eds.), *International Conference on Design Science Research in Information Systems and Technology* (pp. 18–31). Springer Nature Switzerland.
- Giunti, G., & Doherty, C. P. (2024). Cocreating an automated mHealth apps systematic review process with generative AI: Design science research approach. *JMIR Medical Education*, 10, e48949.
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. In I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 30). Curran Associates, Inc.
- Nahringbauer, G. (2025). *A model to utilize artificial intelligence in start-ups: Design science research* (Submitted master's thesis/manuscript).
- Nevanperä, M., Rajamäki, J., & Helin, J. (2021). Design science research and designing ethical guidelines for the SHAPES AI developers. *Procedia Computer Science*, 192, 2330–2339.
- Nonaka, I., & Takeuchi, H. (1995). *The knowledge-creating company: How Japanese companies create the dynamics of innovation*. Oxford University Press.
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “Why should I trust you?”: Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. [páginas]). Association for Computing Machinery.
- Tseng, Y.-C., & Chang, Y.-Y. (2025). Interdisciplinary co-design with LLM-based multi-agents. In *HCI 2025* (Lecture Notes in Computer Science, Vol. 15783, pp. Springer.
- Venable, J., Pries-Heje, J., & Baskerville, R. (2016). FEDS: A framework for evaluation in design science research. *European Journal of Information Systems*, 25(1), 77–89.
- Venkiteela, S. (2025). n8n: An open-source workflow automation platform for enterprise integration. *International Journal of Computer Applications*, 187(63).
- Varandas, B. D. S. (2021). *Otimização da previsão de consumos de eletricidade e de gás natural*.

Ximenes, V. V. (2023). *Abertura do mercado de gás natural no Brasil: O papel do modelo de entradas e saídas na promoção da concorrência* (Trabalho de Conclusão de Curso, Bacharelado em Ciências Econômicas). Instituto de Economia, Universidade Federal do Rio de Janeiro.

Yin, R. K. (2014). *Case study research: Design and methods* (5th ed.). Sage Publications.