INTELIGÊNCIA ARTIFICIAL APLICADA À GESTÃO DE FRANQUIAS

ARTIFICIAL INTELLIGENCE IN FRANCHISE MANAGEMENT



Projeto mostra como a IA pode melhorar a gestão de redes de negócio, diagnosticando e desenhando planos de ação para cada unidade de forma mais ágil e menos custosa

The project demonstrates how AI can enhance the management of business networks by diagnosing and designing action plans for each unit in a more agile and cost-effective manner.

Daniel Saldanha Guedes – Doutorando pela Fundação Dom Cabral
E-mail: danielsaldanhaguedes@gmail.com
Paulo Renato de Sousa – Professor da Fundação Dom Cabral
E-mail: paulorenato@fdc.org.br



Resumo

Objetivo: apresentar o potencial para implantação de um sistema de gestão de redes de negócio, baseado em Inteligência Artificial (IA), demonstrando oportunidades e desafios dessa abordagem.

Estado da arte: muito tem sido pesquisado sobre IA; no entanto, ainda é lenta a aplicação desta tecnologia para gestão de redes de negócio. Faltam estudos de aplicações da IA em redes de negócios, considerando suas particularidades. Franquias, por exemplo, têm desafios próprios relacionados à heterogeneidade das unidades e à variabilidade de operações.

Escopo: foi realizada intervenção em duas redes de franquia na área de alimentação com modelagem adotada em projetos ágeis, inspirada nos conceitos de Avaliação de Requisitos ou Exame de Requisitos.

Originalidade: o artigo apresenta uma nova forma de gestão de redes de franquia, com o uso da inteligência artificial, capaz de tornar as unidades mais eficientes.

Impactos: o relato de intervenção oferece *insights* sobre como usar IA na gestão de redes de negócio.

Palavras-chave: Inteligência Artificial, gestão de redes, *franchising*, varejo, modelos preditivos, consultoria de campo.

ODS: 8 - Trabalho Decente e Crescimento Econômico; 9 - Indústria, Inovação e Infraestrutura.

ABSTRACT

Objective: *Present the potential of implementing a business network management system using artificial intelligence (AI) and demonstrate the opportunities and challenges associated with this approach.*

Current Research Status: *Much research has been conducted on AI; however, the application of this technology to business network management remains slow. There is a lack of studies on AI applications in business networks that consider their particularities. Franchises, for instance, face unique challenges related to the heterogeneity of their units and the variability of operations.*

Scope: *An intervention was performed in two franchises within the food sector, using a model adapted from agile projects, drawing on the concepts of Requirements Assessment or Requirements Examination.*

Originality: *The article introduces a novel approach to managing franchise networks by employing artificial intelligence, which can enhance the efficiency of the units.*

Impacts: *The intervention report provides insights into the use of AI in managing business networks.*

Keywords: *Artificial intelligence, network management, franchising, retail, predictive models, field consulting.*

SDGs: 8 – Decent Work and Economic Growth; 9 – Industry, Innovation and Infrastructure.

A gestão de redes de negócio, seja de franquias ou de varejo, tem enfrentado desafios crescentes, em especial aqueles relacionados aos altos custos operacionais e à dificuldade de assegurar resultados consistentes em cada unidade. À medida que a necessidade de expansão e replicação aumenta, a complexidade e os custos também crescem[1]. Nesse cenário, o modelo tradicional de gestão, baseado na interação direta e frequente de consultores com lojas ou franqueados, tem apresentado limitações significativas, sobretudo no que diz respeito a escalabilidade e eficiência. Esses desafios são ainda mais evidentes em redes de grande porte, em que a complexidade operacional exacerba os gargalos existentes.

Estudos mostram que suporte adequado é crítico para a sobrevivência dos franqueados[2]. No entanto, por outro lado, a sobrecarga de trabalho enfrentada pelos consultores compromete a eficácia do modelo atual. Com a demanda de atender a um número crescente de unidades, esses profissionais enfrentam dificuldades para oferecer suporte de qualidade, o que resulta em diagnósticos menos precisos e planos de ação frequentemente inadequados às necessidades específicas de cada loja. Além disso, a forte dependência de visitas presenciais eleva os custos financeiros e logísticos, e torna o processo insustentável no longo prazo.

Nesse contexto desafiador, a Inteligência Artificial surge como uma solução promissora. Modelos preditivos e prescritivos, aliados a sistemas de aprendizado de

máquina, têm demonstrado potencial para otimizar processos e decisões[3], e oferecem suporte mais assertivo e eficiente. Este artigo apresenta uma intervenção inovadora que utiliza essas tecnologias para transformar a gestão de redes de franquias.

A intervenção ocorreu em duas redes de franquias de grande porte, ambas enfrentando problemas similares de altos custos e baixa eficiência. O trabalho foi conduzido por um grupo interdisciplinar de especialistas, incluindo consultores experientes e gestores de operações das franqueadoras. A principal hipótese era que a automação poderia superar as limitações humanas no diagnóstico e na prescrição de soluções, ampliando o alcance e a eficácia das ações de suporte.

Os resultados obtidos foram expressivos e apontaram para uma significativa redução de custos e melhorias operacionais em diversos níveis. Este estudo detalha o processo de desenvolvimento e implantação do modelo, bem como os impactos observados nas redes participantes. Por fim, são compartilhadas as lições aprendidas, e apresentadas recomendações para replicação em outros contextos organizacionais.

ESTADO DA ARTE

A aplicação de Inteligência Artificial em redes de franquias é um campo ainda pouco explorado[4], apesar do crescente interesse por essa tecnologia em outros setores empresariais. Estudos apontam que a IA tem sido amplamente empregada para otimizar processos e aprimorar a tomada de decisão em áreas como logística, *marketing* e gestão de estoques[5]. No entanto, seu uso no contexto de suporte a redes de negócios, particularmente em franquias, apresenta desafios específicos que demandam maior investigação. Quando combinados os termos *Artificial Intelligence* e *Franchising*, a busca na base de dados Ebscohost resulta em apenas seis artigos.

A análise da literatura revela que grande parte das iniciativas de IA nas empresas concentra-se em ferramentas de automação e análise preditiva, com foco na eficiência operacional ou na elaboração de planos de desenvolvimento estratégico, para expandir a escala dos negócios de forma eficiente[6]. No entanto, poucos estudos abordam a integração de sistemas prescritivos para melhorar o relacionamento entre franqueadoras e franqueados, o que garante resultados mais consistentes. Esse aspecto é crucial, pois a eficácia da gestão de redes depende tanto de diagnósticos precisos quanto da implementação de soluções adaptadas às necessidades locais. Esses diagnósticos e implementações são tradicionalmente realizados por consultores especialistas, indivíduos cujo desempenho supera o de outros membros da equipe[7].

Pesquisas recentes sugerem que o sucesso de intervenções baseadas em IA está diretamente relacionado ao engajamento dos *stakeholders* e à prontidão tecnológica das organizações, em termos de infraestrutura, capital humano e recursos financeiros[8]. Redes de franquias, apresentam desafios únicos nesse sentido, dada a heterogeneidade das unidades e a variabilidade de suas operações[9]. Esses fatores ressaltam a necessidade de soluções personalizadas e adaptáveis, que considerem as especificidades de cada contexto[10].

O relacionamento entre franqueador e franqueado apresenta uma dinâmica única que combina elementos de transação comercial independente com característica de um relacionamento comercial contínuo[11]. Apesar do reconhecimento potencial da IA, a adoção de novas tecnologias e metodologias de gestão em redes de franquias ainda enfrenta barreiras significativas. Entre elas, destacam-se a resistência organizacional e a complexidade de implementação[12]. Estudos enfatizam que superar essas barreiras requer não apenas uma abordagem técnica robusta, mas também estratégias eficazes de comunicação e gestão da mudança[13].

Essa revisão fornece o pano de fundo teórico para a intervenção descrita neste artigo, que busca preencher lacunas práticas e acadêmicas relacionadas ao uso da IA na gestão de redes de negócios.

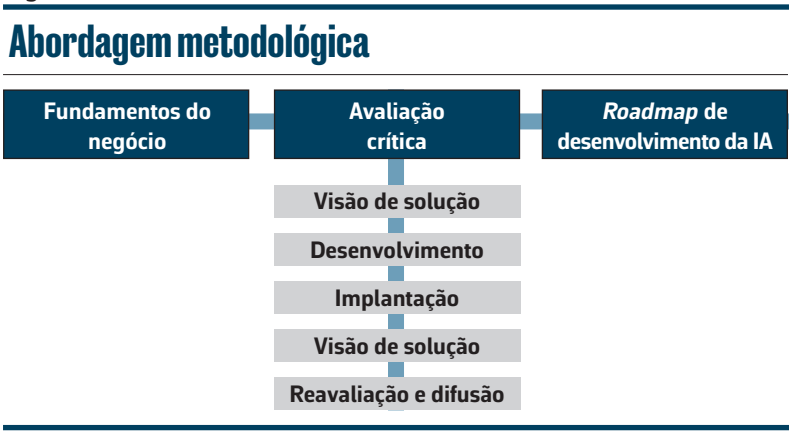
METODOLOGIA

A intervenção aconteceu em duas redes de franquias, ambas do setor de alimentação, com 127 e 255 unidades franqueadas em operação respectivamente, com presença nacional capilarizada em diferentes estados, e presença internacional.

A metodologia é inspirada nos conceitos de Avaliação de Requisitos, prática recomendada para projetos ágeis[14].

A Avaliação de Requisitos (ou Exame de Requisitos) é uma prática utilizada para verificar se os requisitos de um sistema são claros, consistentes e alinhados às necessidades das partes interessadas. Esse processo envolve uma análise colaborativa, na qual a equipe de desenvolvimento e as partes interessadas revisam os

Figura 1.



requisitos para identificar ambiguidades, conflitos e oportunidades de melhoria[15].

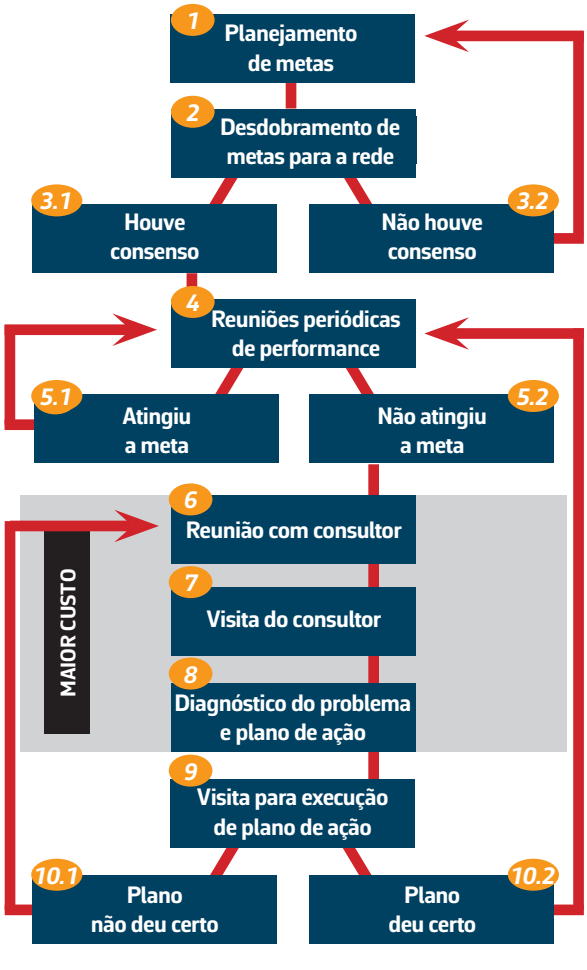
Em metodologias ágeis, essa prática foi adaptada para os ciclos interativos, promovendo *feedback* contínuo e rápida adaptação a mudanças. A avaliação constante dos requisitos ajuda a evitar retrabalho e garante que as entregas incrementais de *software* sejam sempre alinhadas com as expectativas do cliente[16].

A Avaliação de Requisitos também contribui para a mitigação de riscos no projeto ao garantir maior qualidade nas entregas e facilitar a comunicação entre todos os envolvidos no desenvolvimento do sistema.

A metodologia desdobra-se em cinco ciclos (Figura 1): avaliaçao crítica, com modelagem do problema e desenho de escopo de solução, considerando fundamentos do negócio e aspectos tecnológicos capazes de endereçar o desafio; visão de solução, que define os entregáveis do projeto; desenvolvimento da solução; implantação da solução; e reavaliação e difusão de revisão.

Foram envolvidos no projeto os *stakeholders*: a) gestores das franqueadoras; b) times de consultoria; c) franqueados; e; d) desenvolvedores da solução de IA, liderados pelos Diretores de Tecnologia das franqueadoras envolvidas no projeto. Cada ciclo começou com a explicitação da questão a ser tratada e a definição das ações e respectivas atividades, prosseguiu com a implementação dessas ações e atividades e, finalmente, trouxe a avaliação dos resultados e exploração de aprendizados. As análises e ações foram facilitadas e mediadas pelo uso de ferramentas de apoio. Os ciclos foram conduzidos pelo primeiro autor deste artigo (pesquisador principal) e por profissionais do time de gestão das franqueadoras, que formaram um grupo de coordenação dos trabalhos, sob os preceitos da metodologia escolhida.

Figura 2.



APRESENTAÇÃO DO CASO

Avaliação crítica

A avaliação crítica mostrou que a gestão tradicional das franquias baseia-se no fluxo representado da Figura 2. Metas são planejadas e desdobradas para a rede. Quando não há consenso, repensa-se o planejamento. Quando o consenso é atingido, a estratégia é executada e são feitas reuniões periódicas de *performance* para verificar o desempenho das unidades. Se as metas não são atingidas, a principal alavanca de reversão de resultados é a combinação onerosa de viagens com o trabalho de executivos(as) que cumprem papel de consultores internos ou gestores de grupos de lojas. Então, é feito um diagnóstico do problema e executado um plano de ação, que pode ou não resolver os problemas das unidades de baixa *performance*.

Avaliou-se que, as etapas mais caras e com maior potencial de impacto no negócio eram justamente as 6, 7 e 8, reunião e visita do consultor, diagnóstico do problema, e estabelecimento do plano de ação, respectivamente. São etapas que envolvem altos custos de viagens e trabalho de pessoal qualificado.

Além dos desafios de prover pessoal qualificado para atender uma crescente número de lojas/franquias com visitas periódicas, verificou-se o alto risco de a visita/consultoria não ser exitosa. Isso pode ocorrer por falha na etapa de diagnóstico (que acaba resultando em planos de

ação inócuos), ou pela pressa com que as visitas acabam sendo feitas, visto que o profissional precisa dar conta de um número grande e crescente de lojas/franquias, frequentemente superior à sua capacidade de atendimento.

A avaliação crítica considerou que, em ambas as redes, havia um problema composto por: a) altos custos com suporte ao franqueado, fundamentalmente calcados nas visitas dos consultores às unidades franqueadas; b) sobrecarga dos consultores com alto volume de lojas sob sua supervisão; c) baixa eficiência do trabalho da consultoria que, em geral, não vinha conseguindo reverter a *performance* ruim das lojas atendidas; e; d) percepção geral de baixa qualidade do trabalho da consultoria, tanto por parte dos franqueados quanto da direção das próprias franqueadoras.

Visão de solução

Para superar o desafio, criou-se um grupo de trabalho em ambas as empresas, com a presença do time de consultoria e dos gestores da área de operações das franqueadoras. A primeira etapa do processo envolveu uma investigação sobre o método adotado pelos profissionais que auferiam os melhores resultados em sua atividade de consultoria, e que eram tidos como eficientes, por ter não apenas boa avaliação de seus franqueados, mas também resultados concretos de reversão de *performance* das lojas/franquias sob sua gestão.

Observou-se que o método empírico adotado pelos profissionais de alta *performance* era um diagnóstico causa-efeito, calcado em visitas de campo e em conversas com operadores de loja/franquia, sejam gerentes, líderes de unidades e/ou franqueados. Após o diagnóstico, sucedia-se um exame de opções, verificando-se quais práticas, ferramentas e/ou soluções seriam apropriadas para mitigar as causas que resultavam em efeitos indesejáveis. Por fim, prescreviam-se planos de ação previamente conhecidos e testados.

Chegou-se à conclusão de que tanto o diagnóstico quanto a prescrição baseavam-se mais em um sistema preditivo-prescritivo intuitivo dos profissionais experientes do que numa criatividade humana. Os melhores eram exímios aplicadores de soluções conhecidas e já testadas, mais do que criadores de métodos novos.

Esse sistema, portanto, seria passível de automação via IA. E mais: um sistema preditivo-prescritivo feito IA poderia melhorar os resultados do processo. Em primeiro lugar, poderia diagnosticar melhor, dada sua capacidade superior de analisar e aprender com cenários para um número infinito de lojas. Em segundo lugar, poderia prescrever planos de ação em qualidade e quantidade impossíveis para um ser humano, por mais dedicado e capacitado que fosse.

Com a automação do processo de diagnóstico e confecção de planos de ação de forma mais ágeis, as viagens para fins de diagnóstico poderiam ser reduzidas. Além disso, havia o potencial de dispensar as viagens de execução de planos de ação se estes fossem abordados rapidamente, enquanto os problemas ainda eram simples de serem contornados pelo próprio franqueado, sem necessidade de intervenção da equipe de consultoria da franqueadora.

Considerou-se que o sistema de IA poderia também passar a analisar as lojas boas com potencial de virarem ótimas, e as ótimas com potencial de virarem excepcionais. Além de ser uma oportunidade de atingir crescimento superior em relação às metas gerais das redes, esse caminho também poderia proporcionar maior êxito com os resultados da consultoria, pois havia consenso no grupo de trabalho de que é mais fácil transformar uma loja/franquia boa em ótima do que uma ruim em boa.

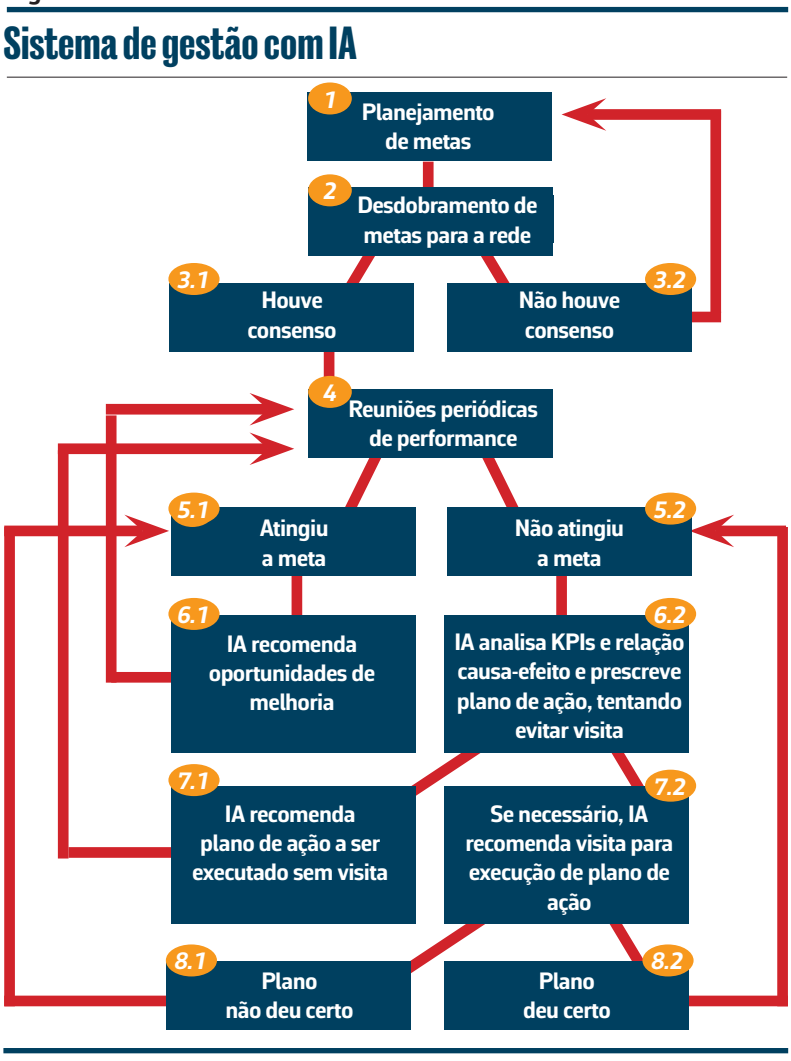
O uso de IA poderia, portanto, tornar as franqueadoras mais lucrativas a partir de duas perspectivas: a) a melhor *performance* das franquias gera aumento de *royalties*, e consequentemente, impulsiona o faturamento das franqueadoras; e b) a redução de custos de viagens e do número de consultores melhora a margem de lucro das franqueadoras.

A Figura 3 mostra o fluxo de gestão alternativo desenvolvido. As etapas 6, 7 e 8 do fluxo tradicional são substituídas pela etapa 6, feita via IA, que passa a atender também as franquias que atingem e/ou superam as metas, e que historicamente eram desprestigiadas e/ou não priorizadas.

Desenvolvimento

Durante o desenvolvimento, houve revisão dos processos existentes utilizados no suporte às lojas/franquias. O grupo observou vários buracos de processo. Havia etapas não escritas que cada consultor realizava da forma que achava correto, e outras que estavam escritas mas eram evitadas ou cumpridas de forma protocolar, pois a crença geral era de que de nada serviam.

Figura 3.



Para revisão dos processos, tomou-se como base a metodologia *lean*. Foram feitas visitas de campo para diálogo e interação com franqueados e equipes de lojas, o que possibilitou a revisão de todos os processos. O resultado foi a atualização de manuais de operações e criação de novos processos operacionais padrão, que serviu de base ao desenvolvimento do sistema. Antes de serem formalmente aceitos, foram testados em lojas/franquias, com resultados satisfatórios.

Como a construção de um *software* requer investimento e tempo significativos, e considerando que o grupo intensionava experimentar hipóteses com agilidade e baixo custo, optou-se por desenvolver uma solução simples, baseada em planilhas de Excel. A ideia era emular em Excel boa parte do processo de diagnóstico e prescrição que um futuro sistema computacional faria, o que serviria de base para o *briefing* oferecido ao time de tecnologia para futuro desenvolvimento de um *software* mais robusto.

Optou-se por limitar o teste, em um primeiro momento, às relações de causa-efeito, para gerar diagnósticos pré-formatados de forma simplificada. Depois, tais diagnósticos indicariam uma das opções de planos de ação previamente prescritos. Assim, as planilhas Excel, inicialmente desenvolvidas como protótipos, foram aplicadas em campo para coleta de *feedback* e ajustes. Os consultores começaram a utilizá-las para realizar diagnósticos e prescrever planos de ação, o que permitiu uma transição gradual para o sistema automatizado. Essa etapa foi crucial para preparar os usuários finais e ajustar a solução com base em cenários reais de operação.

Nesta fase, optou-se por um processo de automação parcial, em que o consultor fazia o *input* manual de alguns dados na planilha, recebendo respostas instantâneas em um esquema de "*ifs*". Ou seja, mediante um *input*, obtinha-se um *output* com recomendações, a partir de um banco de respostas como pode ser visto na Figura 4.

Na Figura 4, observa-se, nos campos verdes, os *inputs* feitos por um consultor, que indicou o volume de *leads* recebidos pela área comercial de uma franquia, e as vendas resultantes desses *leads* em determinado período. O sistema responde, nos campos azuis, à taxa de conversão. Para taxa de conversão inferior a 50%, o diagnóstico é de baixa conversão, e já há ações catalogadas para esse problema. A tabela em formato 5W2H é preenchida automaticamente com o plano de ação comercial, com duas ações a serem tomadas.

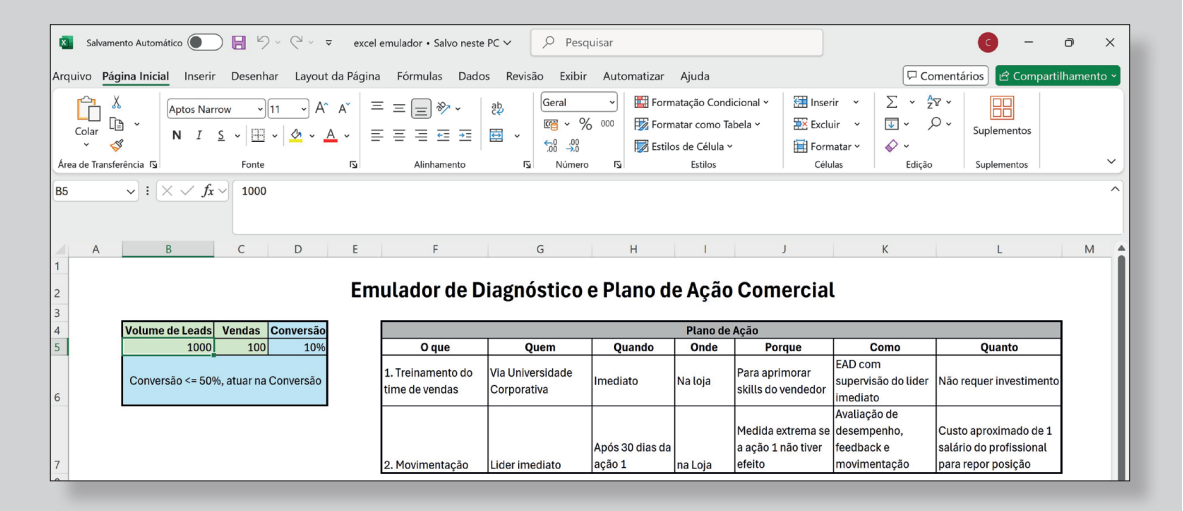
Com base nos testes inicias nas planilhas, considerando todos os processos que impactam nos *Key Performance Indicator* (Indicador-Chave de Desempenho, KPIs) em que os consultores podiam atuar, foi preparado um *briefing* entregue aos CTOs das companhias envolvidas. Com isso, os Diretores de Tecnologia deram início ao desenvolvimento de um sistema computacional robusto de IA, batizado de SOPHIA.

O sistema deveria não apenas ser capaz de gerar diagnósticos e prescrições, mas também ser totalmente integrado com os sistemas ERP, de onde emanavam as informações base para todas as análises de *performance*. Com isso, o consultor não precisaria mais digitar dados como fazia manualmente nas planilhas de Excel, pois o próprio sistema integrado acessaria os dados de cada loja, gerando diagnóstico e planos de ação.

No momento, o Sophia está na sua versão 1, ainda limitado aos diagnósticos e planos de ação da área comercial, mas com a ambição de avançar para todas as demais áreas de negócios de ambas as franqueadoras.

Figura 4.

Tela da planilha Excel emuladora de diagnóstico e plano de ação comercial



A Figura 5 mostra a arquitetura computacional desenvolvida

Por fim, foram aplicadas simulações com conjuntos de dados controlados para validar a eficácia do sistema proposto. Esses testes ajudaram a identificar possíveis ajustes nos algoritmos e refinar a interface do usuário, o que garantiu que a solução fosse intuitiva e eficaz para os consultores e gestores das franquias.

Implantação

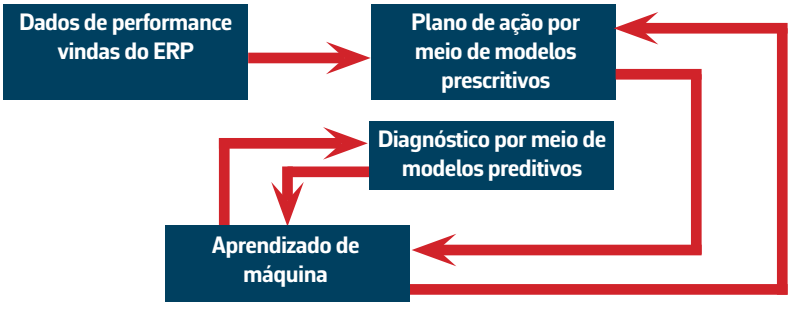
A implantação se deu em etapas, optando-se por fazer o *rollout* considerando cada grupo de franquias de cada um dos consultores. O tempo de implantação médio foi de duas semanas por etapa/consultor em cada uma das redes.

Cada etapa se iniciou com treinamento operacional dos consultores para usar o sistema. O treinamento dos consultores foi feito pelo time de tecnologia de cada uma das franqueadoras, utilizando-se dados reais do grupo de franquias em questão. Durante o treinamento, todos os recursos do Sophia foram explorados, da ferramenta/menu de diagnóstico para a ferramenta/menu de plano de ação.

Em seguida, foram realizados testes de uso da ferramenta em uma franquia de cada regional. A franquia escolhida para testar a ferramenta e treinar o consultor foi definida pelos próprios consultores. A maioria optou por unidades de baixa *performance* com indicadores de desempenho desajustados, e preferiu aprender com as situações mais complexas.

Figura 5.

Arquitetura computacional da solução Sophia



O maior desafio de implementação se deu nas regionais em que os consultores eram menos rigorosos com os franqueados no uso dos sistemas de gestão de loja. Nesses casos, havia dados desatualizados ou incompletos que, quando considerados pelo Sophia, resultavam em diagnósticos imprecisos. Foi necessário pausar o processo de diagnóstico para que o consultor, junto com o(s) franqueado(s), fizesse a atualização do *Enterprise Resource Planning* (Planejamento de Recursos Empresariais, ERP) da loja. Só então, com o banco de dados atualizado, o diagnóstico com o Sophia foi refeito e passou a funcionar efetivamente. Nos casos em que esse fenômeno foi percebido, houve um atraso médio de um dia por

loja no processo de implantação, o que não teve impacto em termos de planejamento e custos.

Observou-se que os primeiros diagnósticos e planos de ação se utilizaram apenas da biblioteca de informações inicialmente imputada, resultando em diagnósticos e planos menos precisos e mais simples. À medida que o sistema foi sendo submetido às informações reais das dezenas de franquias, e os consultores/usuários foram oferecendo *feedback* sobre os diagnósticos e planos apresentados pelo Sophia, os resultados foram ficando cada vez mais refinados.

Para exemplificar como o sistema foi implementado e aperfeiçoado, vejamos as análises de taxa de conversão de vendas. Inicialmente, o Sophia identificava as vendas realizadas, dividia pelo número de *leads* e achava a taxa de conversão. Na sequência, comparava a taxa encontrada com os parâmetros da biblioteca fornecida originalmente pelo emulador em Excel, indicava se a referida taxa era boa ou ruim e recomendava ações previstas no esquema de causa-efeito do emulador para aquele perfil de conversão.

À medida que os consultores foram indicando que existiam tipos de *leads* diferentes, com origens distintas (por exemplo, visitas de clientes passantes que viram a fachada da unidade e entraram, e/ou, cadastros oriundos de *marketing* digital), o sistema foi aprendendo que certos tipos de origem resultavam em diferentes taxas de conversão, e que o conceito de bom ou ruim não era estanque, mas flutuava de acordo com o perfil dos *leads*. Os diagnósticos passaram a considerar esses diferentes tipos de origem de *leads* e a fazer recomendações mais assertivas, inclusive, recomendando investimentos nos *leads* que tinham melhor taxa de conversão.

Tabela 1

Resultados da mudança para consultoria baseada em IA

Impacto	Estimativa de ganhos
Melhora na *performance* dos franqueados que estavam abaixo das metas de vendas e faturamento	Conversão média passou de 31% para 43%, e faturamento cresceu cerca de 17%, o que também impactou nas receitas de *royalties* da franqueadora na mesma proporção.
Redução do custo com time de consultoria	Anteriormente, cada consultor atendia 40 unidades; agora, consegue supervisionar 52 unidades.
Redução do número de visitas e do consequente custo de viagens	Antes, o plano de suporte contemplava três visitas por ano por unidade franqueada, e vinha se mostrando insuficiente, com indicações de que deveria aumentar para quatro ou cinco visitas anuais. Com o projeto SOPHIA, optou-se por manter o número de visitas em um primeiro momento, e já se constatou que, em algumas franquias, será possível reduzir para duas visitas anuais.
Redirecionamento estratégico do trabalho do time de consultoria	Se antes os consultores precisavam fazer microgestão das unidades, agora dedicam-se a estreitar relacionamento e tratar dos planos de ação mais complexos. Além dos benefícios para franqueadoras e franqueados, melhorou o *feedback* dos consultores quanto à qualidade de vida no trabalho.
Melhora do *Net Promoter Score* (NPS) que mede a satisfação do franqueado com as franqueadoras	Antes do projeto SOPHIA, o NPS era de 72%; na última medição, chegou a 84,3%.
Melhora na assertividade dos investimentos para geração de *leads*	O Sophia lançou luz sobre os diferentes tipos de *leads* e passou a ajudar no direcionamento dos investimentos para geração de *leads* com melhor taxa de conversão

Com acúmulo de diagnósticos e consequente ampliação do treinamento da IA, observou-se que o sistema passou a considerar ainda o perfil de cidade onde se situava a franquia, pois a localidade influenciava não apenas o perfil de conversão por tipo de *lead*, mas também os tipos de *leads* existentes. O sistema ainda aprendeu a comparar o perfil de resultados entre os diferentes tipos de cidade, sofisticando a percepção de eficiência nos diagnósticos, o que levou à criação de *clusters* de unidades por similaridades.

RESULTADOS DO PROJETO

A adoção da solução SOPHIA teve impactos positivos em ambas as franqueadoras participantes do projeto.

Em relação à estrutura de pessoal, especialmente da consultoria destinada ao suporte à rede de franquias com foco em aumento de *performance*, antes do projeto o número de consultores era insuficiente para fazer frente às necessidades e demandas impostas pelos franqueados. No momento, a percepção é de que o número de profissionais não apenas dá conta da rede atual como também suporta um crescimento em número de unidades. Outro aspecto notório foi a redução de custos de viagens de visitas da consultoria.

Em grande parte, os franqueados reportam maior satisfação com o novo formato de consultoria, voltado menos a *checklists* e visitas orientativas, e mais à implementação dos planos de ação resultantes dos diagnósticos e recomendações do SOPHIA. Além disso, houve ganho no relacionamento com franqueados de boa ou excelente performance que, antes, eram deixados em segundo plano.

Para os franqueadores, os ganhos já começam a aparecer, no crescimento de *royalties*, na redução de custos com viagens e folha de pagamento do time de consultoria, e na melhoria geral da percepção de qualidade do suporte por parte dos franqueados, visível no *Net Promoter Score* (NPS) da Rede.

O novo processo possibilitou também o direcionamento do time de consultoria para funções eminentemente humanas, notadamente aquelas voltadas à manutenção do bom relacionamento com franqueados e/ou gestores de lojas/franquias, e à implementação de planos de ação complexos, em que a experiência e presença dos consultores fazem muita diferença. Colateralmente, espera-se obter uma redução do *turnover* do time da consultoria, que muitas vezes optava por sair do emprego para buscar posições menos estressantes.

PRINCIPAIS APRENDIZADOS

A intervenção apresentada neste artigo mostra caminhos para se utilizar a IA de forma efetiva na solução de uma questão central na relação entre franqueados e franqueadoras: o suporte e a consultoria que se destinam a elevar a *performance* e os resultados das lojas/franquias. Os aprendizados a seguir podem ajudar outras organizações a adotarem IA na gestão de redes:

1- É preciso envolver os *stakeholders*: a implementação de mudanças substanciais em redes como a que tratamos neste artigo depende do envolvimento de todos os *stakeholders*, sob pena de a solução ser descontinuada prematuramente com o argumento de que não funciona, ou pior, de que os franqueados não estão aptos para "esse tipo de inovação". No caso apresentado, o *board* das franqueadoras contribuiu dando sinal verde para o projeto, a área de tecnologia foi decisiva para que o projeto saísse do papel, os consultores colaboraram trasnferindo *know-how* para a IA, e os franqueados participaram indicando suas expectativas e necessidades.

2- Contratar ferramentas de mercado nem sempre resolve: cada rede de negócios tem suas peculiaridades e, muitas vezes, ferramentas e soluções de prateleira não atendem às necessidades. Há uma proliferação de sistemas com base em IA, mas a maioria são microsserviços que servem para parte do processo, mas não seriam capazes de dar conta de mudança tão substancial quanto a tratada neste artigo. Gestores não devem se acomodar e, eventualmente, precisam se desafiar a construir ferramentas e soluções novas, feitas sob medida para as necessidades do negócio, e que se integrem com ferramentas pré-existentes.

3- Os resultados devem ser pensados no longo prazo: uma intervenção dessa natureza é um projeto de longo prazo, transdepartamental. Assim sendo, não deve ser encarada como medida imediatista apenas para que gestores e sócios da empresa possam dizer que estão alinhados com os modismos de mercado. No caso apresentado, o projeto encontra-se no seu segundo ano, já com bons resulados, mas tudo indica que sua maturidade se dará por volta do quarto ou quinto ano, quando a solução estará totalmente funcional e a IA bem mais treinada, podendo oferecer diagnósticos e planos de ação cada vez mais sofisticados e assertivos.

4- Testar um Mínimo Produto Viável (MVP) facilita a construção de uma solução definitiva: vale pensar no desenvolvimento das ferramentas de IA em etapas. No caso apresentado, ter modelado a solução por meio de MVP em Excel, apesar de todas as limitações, foi muito importante, pois: a) permitiu engajar os consultores, que seriam os principais usuários da solução, logo no início do projeto, a partir do banco de dados de diagnósticos e planos de ação que iria treinar a IA. Além disso, também motivou todos os outros *stakeholders*, que viram a ideia sair do papel rapidamente ; b) melhorou a qualidade do *briefing* dado a *posteriori* para o time de tecnologia, que conseguiu desenvolver com mais rapidez a solução final. No caso apresentado, a fase de testes com Excel modelou boa parte do que seria a solução final.

5- A IA possibilita impactos que vão além dos planejados inicialmente: o projeto começou com um claro foco de melhorar os diagnósticos e planos de ação para franquias deficitárias, ao mesmo tempo em que se pretendia reduzir custos com o processo. Contudo, ao olhar o problema de forma mais ampla, notou-se que havia uma oportunidade enorme de se melhorar também o processo de suporte para as franquias de boa e alta *performance*, que originalmente não faziam parte do escopo do projeto. No caso apresentado, os resultados iniciais auferidos com as franquias de boa ou excelente *performance* já demonstram serem tão ou mais promissores do que os comparados com as franquias de baixa *performance* que sempre foram foco do projeto.

NOTAS

1. Combs, J. G., Michael, S. C., & Castrogiovanni, G. J. (2004). Franchising: A Review and Avenues to Greater Theoretical Diversity. *Journal of Management, 30*(6), 907–931. https://doi.org/10.1016/j.jm.2004.06.006
2. Nijmeijer, K. J., Fabbricotti, I. N., & Huijsman, R. (2014). Making Franchising Work: A Framework Based on a Systematic Review. International *Journal of Management Reviews, 16*(1), 62–83. https://doi.org/10.1111/ijmr.12009
3. Bertsimas, D., & Kallus, N. (2014). Da análise *preditiva à prescritiva* . arXiv preprint arXiv: 1402.5481. https://arxiv.org/abs/1402.5481
4. Lee, C. K. H., Choy, K. L., Ho, G. T. S., & Lin, C. (2016). A cloud-based responsive replenishment system in a franchise business model using a fuzzy logic approach. *Expert Systems, 33*(1), 14–29. https://doi.org/10.1111/exsy.12117
5. Vasconcelos, F.C., Coelho, F.S., & Correia, E.O. (2021). Tomada de decisão nas organizações: o que muda com a Inteligência Artificial? *Estudos Avançados, 35*(103), 37–54. https://doi.org/10.1590/s0103 -4014.2021.35103.004
6. Wu, C. H., Ho, G. T. S., Lam, C. H. Y., & Ip, W. H. (2015). Franchising decision support system for formulating a center positioning strategy. *Industrial Management & Data Systems, 115*(5), 853–882. https://doi.org/10.1108/IMDS-10-2014-0291
7. Hoffman, R. R., Ziebell, D., Feltovich, P. J., Moon, B. M., & Fiore, S. F. (2011). Franchise Experts. *IEEE Intelligent Systems, 26*(5), 72–77. https://doi.org/10.1109/MIS.2011.85
8. Alarefi, M. (2024). The Impact of Artificial Intelligence on Business Performance in Saudi Arabia: The Role of Technological Readiness and Data Quality. *Engineering, Technology & Applied Science Research, 14*(5), 16802–16807. https://doi.org/10.48084/etasr.7871
9. Cumberland, D. M., & Litalien, B. C. (2018). Social franchising: A systematic review. *Journal of Marketing Channels, 25*(3), 137–156. https://doi.org/10.1080/1046669X.2019.1657757
10. Alon, I., Apriliyanti, I. D., & Henríquez Parodi, M. C. (2021). A systematic review of international franchising. *Multinational Business Review (Emerald Group Publishing Limited), 29*(1), 43–69. https://doi.org/10.1108/MBR-01-2020-0019
11. Bishara, N. D., & Schipani, C. A. (2014). A Corporate Governance Perspective on the Franchisor-Franchisee Relationship. Stanford *Journal of Law, Business & Finance, 19*(2), 303–329.
12. Ciccarelli, CD, Queiroz, FCBP, Araújo Júnior, LQ, Queiroz, JV, & Lima, JCF (2016). *Modelagem e formatação de franquias. Revista Espacios, 37* (38), 1–14. Disponível em: https ://www .revistaespacios .com /a16v37n38 /16373804 .html
13. Fulop, C., & Foward, J. (1997). Insights into Franchising: A Review of Empirical and Theoretical Perspectives. *Service Industries Journal, 17*(4), 603–625. https://doi.org/10.1080/02642069700000037
14. Ochodek, M., & Kopczyńska, S. (2018). Perceived importance of agile requirements engineering practices – A survey. *Journal of Systems & Software, 143*, 29–43. https://doi.org/10.1016/j.jss.2018.05.012
15. Sommerville, I. (2011). *Engenharia de software* (9ª ed.). Addison-Wesley
16. Pressman, R.S. (2014). *Engenharia de software: Uma abordagem de praticante* (8ª ed.). McGraw-Hill Education.

CONFLITOS DE INTERESSE
Os autores não têm conflitos de interesse a declarar.

CONTRIBUIÇÃO DE AUTORIA
Daniel Saldanha Guedes: Conceitualização; Curadoria de Dados; Análise Formal; Investigação; Metodologia; Validação; Visualização; Redação - rascunho original; Redação - Revisão e edição
Paulo Renato de Sousa: Conceitualização; Supervisão.

Submetido 25-12-2024. **Aprovado** 29-01-2025. Avaliado pelos editores convidados.
Versão original. DOI: https://doi.org/10.12660/gvexec.v24n1.2025. 92688