

USO DE INTELIGÊNCIA ARTIFICIAL GENERATIVA E GEOMARKETING: ANÁLISE COMPARATIVA

Use of Generative Artificial Intelligence and Geomarketing: A Comparative Analysis

JOÃO VICTOR RADOMKSY VIAPIANA

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL - UFRGS

RAQUEL JANISSEK-MUNIZ

UFRGS

CARLA BONATO MARCOLIN

FACULDADE DE GESTÃO E NEGÓCIOS - FAGEN/UFU

Comunicação:

O XIII SINGEP foi realizado em conjunto com a 13th Conferência Internacional do CIK (CYRUS Institute of Knowledge), em formato híbrido, com sede presencial na UNINOVE - Universidade Nove de Julho, no Brasil.

Agradecimento à órgão de fomento:

Agradecemos em especial à Universidade Federal do Rio Grande do Sul (UFRGS), mais especificamente seu Programa de Pós-Graduação em Inteligência Estratégica e Inovação, organizado e mentorado pela Prof.^a Dra. Raquel Janissek-Muniz, e pelo valioso auxílio técnico da Prof.^a Dra. Carla Bonato Marcolin. Foi deste curso que nasceu o projeto e o artigo.

USO DE INTELIGÊNCIA ARTIFICIAL GENERATIVA E GEOMARKETING: ANÁLISE COMPARATIVA

Objetivo do estudo

Avaliar a confiabilidade, sensibilidade e eficácia dos modelos de Inteligência Artificial Generativa na priorização de bairros para abertura de negócios, comparando recomendações com e sem dados estruturados, tomando Porto Alegre como estudo de caso para uma tomada de decisão territorial.

Relevância/originalidade

O estudo busca preencher lacunas sobre uso de IA generativa no geomarketing, oferecendo análise empírica comparativa de modelos LLM. Assim, destacando o potencial dessas ferramentas para decisões territoriais, integrando dados estruturados e inferências qualitativas de contextos presentes no ambiente urbano.

Metodologia/abordagem

Aplicação de prompts a dois modelos de IA em cenários com e sem dados estruturados por bairro. Análise comparativa baseada nos critérios de confiabilidade, sensibilidade à informação e eficácia, comparando respostas aos indicadores oficiais e tradicionais ao geomarketing.

Principais resultados

Ambos os modelos geraram recomendações coerentes e bem alinhadas com as práticas de geomarketing, mesmo que tenham alterado as indicações ao receberem dados estruturados. O ChatGPT-4o adotou abordagem quantitativa ponderada, enquanto o DeepSeek-V2 combinou análise quantitativa com filtros qualitativos e consistência contextual.

Contribuições teóricas/metodológicas

Amplia evidências sobre a integração de IA generativa em Sistemas de Apoio à Decisão Espacial. Demonstra abordagens distintas de raciocínio em LLMs, propondo critérios de avaliação para decisões territoriais e destacando sensibilidade das IAs à qualidade e organização dos dados.

Contribuições sociais/para a gestão

Oferece subsídios para gestores e consultores utilizarem IA generativa como apoio a decisões de localização, potencializando análises de mercado, identificando oportunidades e complementando métodos tradicionais de geomarketing com interpretações qualitativas e contextuais dos territórios.

Palavras-chave: IA Generativa, Modelos de Linguagem de Grande Porte (LLMs), Geomarketing, Sistemas de Apoio à Decisão Espacial (SDSS)

Use of Generative Artificial Intelligence and Geomarketing: A Comparative Analysis

Study purpose

To assess the reliability, sensitivity, and effectiveness of ChatGPT-4o and DeepSeek-V2 in prioritizing neighborhoods for new business openings, comparing recommendations with and without structured data, using Porto Alegre as a geomarketing case study.

Relevance / originality

The study addresses a gap on generative AI use in geomarketing, offering an empirical comparative analysis of LLM models. It highlights these tools' potential for territorial decisions by integrating structured data and qualitative inferences in urban market contexts.

Methodology / approach

Standardized prompts were applied to two AI models in scenarios with and without neighborhood-level structured data. Comparative analysis used criteria of reliability, information sensitivity, and efficacy, employing official indicators and geomarketing methods.

Main results

Both models generated recommendations aligned with geomarketing practices, even though changing outputs when given access to structured data. ChatGPT-4o adopted a weighted quantitative approach, while DeepSeek-V2 combined quantitative analysis with qualitative filters and contextual consistency.

Theoretical / methodological contributions

Expands evidence on integrating generative AI into Spatial Decision Support Systems. Demonstrates distinct LLM reasoning approaches, proposes evaluation criteria for territorial decisions, and highlights AI sensitivity to the quality and organization of data.

Social / management contributions

Provides managers and consultants with insights on using generative AI to support location decisions, enhancing market analysis, identifying opportunities, and complementing traditional geomarketing methods with qualitative and contextual interpretations of territories.

Keywords: Generative AI, Large Language Models, Geomarketing, Spatial Decision Support System (SDSS)

USO DE INTELIGÊNCIA ARTIFICIAL GENERATIVA E GEOMARKETING: ANÁLISE COMPARATIVA

1. Introdução

Com o avanço do século XXI, a disponibilidade de dados e o maior acesso à informação tem impulsionado decisores nas organizações a definirem estratégias de forma mais assertiva baseadas em dados, criando culturas de negócio conhecidas como *data-driven* ou *intelligence-driven*, que demonstram impacto direto na performance organizacional (MIKALEF et al., 2019). Segundo Rohrbeck e Kum (2018), além da adoção de uma cultura orientada por dados, empresas preparadas para o futuro desenvolvem práticas de *foresight* corporativo que integram uma ampla gama de fontes de dados internas e externas, estruturadas e não estruturadas, fortalecendo suas capacidades de antecipação e sua agilidade estratégica em ambientes dinâmicos.

Dentre as diversas abordagens de *foresight*, Inteligência Estratégica Antecipativa (IEA) é o processo coletivo e proativo através do qual os membros da organização coletam e utilizam informações pertinentes relacionadas aos seus ambientes interno e sobretudo externo, com o objetivo de reforçar sua competitividade (LESCA, 2003). Seu uso tem como foco ajudar a criar oportunidades de negócios, inovar, adaptar-se ao ambiente, evitar surpresas estratégicas, reduzir riscos e incerteza geral. Ao articular sinais do ambiente externo a informações provenientes de fontes internas e externas, a IEA amplia a capacidade das organizações de identificar mudanças emergentes e construir vantagens competitivas sustentáveis (Janissek-Muniz, 2016).

Alinhado com os objetivos da inteligência antecipativa, o campo de estudos do geomarketing, segundo Cavion e Philipps (2016), visa a aplicação prática de dados demográficos e socioeconômicos georreferenciados para transformar esses dados espaciais em inteligência estratégica territorial. De forma tradicional, o geomarketing tem estado fundamentado predominantemente em análises quantitativas, apresentando limitações significativas quando se trata de captar as dimensões qualitativas e subjetivas dos territórios, como percepções de segurança, reputação simbólica e tendências emergentes de valorização urbana. Birkin, Clarke e Clarke (2002) já destacavam que, apesar do avanço nos modelos de previsão de desempenho territorial e locacional, as abordagens baseadas exclusivamente em dados demográficos e históricos de consumo tendem a desconsiderar fatores contextuais, sociais e culturais que influenciam o comportamento dos consumidores e a atratividade territorial.

Segundo Herhausen et al. (2024), o marketing tem incorporado cada vez mais capacidades da Inteligência Artificial (IA) e do aprendizado de máquina para lidar com a crescente complexidade e o volume de dados oriundos de diversas fontes, especialmente dados textuais não estruturados. Essas tecnologias possibilitam a análise de avaliações online, postagens em redes sociais e outros grandes volumes de dados, potencialmente ampliando a geração de insights a partir dessas informações.

A introdução da arquitetura de *transformers*, no artigo "Attention is All You Need" (VASWANI et al., 2017), e o surgimento dos Modelos de Linguagem de Grande Porte (LLMs), como os *Generative Pre-trained Transformers* (GPT), abriram novas fronteiras para a aplicação da inteligência artificial em análises territoriais de geomarketing. Essas técnicas de aprendizado de máquina e processamento de linguagem permitem a análise de grandes volumes de dados complexos em texto, disponíveis na internet, para identificar padrões ocultos, prever comportamentos e avaliar

contextos que previamente não estavam disponíveis de forma estruturada (TABESH, 2022).

Embora o campo da IA aplicada ao geomarketing venha avançando, estudos como o de Ansari (2023) destacam que a integração de Inteligência Artificial no geomarketing, especialmente em aplicações de análise preditiva e tomada de decisão, permanece limitada, com poucos trabalhos abordando essa convergência de forma empírica ou aplicada. Embora o potencial pareça ser promissor, é importante compreender se os LLMs conseguem gerar recomendações coerentes e confiáveis para decisões estratégicas de localização, e em que medida essas recomendações se alinham, ou divergem, dos resultados obtidos atualmente no geomarketing. No presente trabalho, parte-se da hipótese de que esses sistemas podem oferecer suporte relevante na priorização territorial de negócios, especialmente quando confrontados com os métodos conhecidos do geomarketing.

Com isso, esse artigo tem como objetivo avaliar a confiabilidade, a sensibilidade e a eficácia de modelos de IA generativa, especificamente o ChatGPT-4o e o DeepSeek-V2 (DeepThink R1), na priorização de bairros para a abertura de negócios físicos em ambiente urbano. Em específico, o estudo propõe testar e comparar a capacidade dos modelos de IA em recomendar os bairros mais adequados para a abertura de negócios na cidade de Porto Alegre, capital do estado do Rio Grande do Sul, Brasil. A análise busca verificar se as recomendações geradas pelas IAs mantêm coerência interna (confiabilidade), são sensíveis à introdução de dados quantitativos (sensibilidade) e se aderem, na prática, aos padrões de concentração competitiva do setor analisado (eficácia). Adicionalmente, o trabalho busca contribuir ao debate sobre a integração de tecnologias de IA generativa aos processos de geomarketing, apontando possibilidades para a evolução da análise territorial rumo a práticas mais qualitativas e alinhadas à Inteligência Estratégica Antecipativa. O trabalho também busca destacar as limitações atuais dos modelos testados e propor sugestões para pesquisas futuras na área.

2. Fundamentação Teórica

A fundamentação teórica deste estudo parte da compreensão de como as transformações recentes na geração e uso de dados estão impactando os processos de tomada de decisão estratégica, especificamente voltados para decisões territoriais. O avanço das tecnologias de Inteligência Artificial, especialmente os LLMs, tem ampliado as possibilidades de análise territorial ao integrar diferentes fontes de informação e diferentes formas de processamento de dados. Nesse contexto, torna-se relevante explorar conceitos que envolvem a tomada de decisão com o avanço dos LLMs, e os conceitos de decisão territorial do campo de estudos de geomarketing, oferecendo um panorama das bases conceituais que sustentam este estudo.

2.1 Tomada de Decisão e LLM's

A crescente complexidade dos mercados, o volume de dados disponível e a pressão por decisões mais rápidas e fundamentadas exigem das organizações uma reestruturação nos seus modelos de decisão. Como argumenta Tabesh (2022), gestores enfrentam hoje o desafio de integrar ferramentas de Inteligência Artificial (IA) sem perder o controle estratégico de suas decisões. Neste contexto, para melhor explorar esse desafio, o autor delimita três tipos principais de decisões no contexto gerencial: as analíticas, fundamentadas em dados e análises estruturadas; as intuitivas, baseadas na experiência e julgamento do gestor; e as automatizadas, delegadas a sistemas inteligentes que operam com baixa ou nenhuma intervenção humana.

Complementando essa discussão, Oppioli et al. (2022), em uma revisão estruturada da literatura sobre IA aplicada à decisão gerencial, identificam cinco grandes áreas de aplicação que ajudam a delimitar o papel prático desses sistemas: (1) previsão e classificação; (2) suporte à tomada de decisão sob incerteza; (3) aplicação em casos práticos organizacionais; (4) sistemas de gestão do conhecimento; e (5) extração automatizada de informações relevantes. Esses usos apontam para uma convergência entre a IA e os tradicionais Sistemas de Apoio à Decisão (DSS), reforçando a ideia de que os modelos inteligentes hoje não substituem o gestor, mas ampliam sua capacidade analítica.

No entanto, permanece a dúvida sobre o quanto esses sistemas são capazes de simular o raciocínio humano ou se atuam apenas como mecanismos estatísticos avançados que auxiliam no reconhecimento de padrões. Essa reflexão ganha fôlego quando se considera a ascensão de Modelos de Linguagem de Grande Porte (LLMs), como os modelos baseados em GPT, que aparentam raciocinar e construir argumentos. Nesse sentido, Karapantelakis et al. (2024) discutem o uso de LLMs em contextos onde o pensamento crítico é essencial, propondo uma descrição que diferencia tipos de raciocínio: dedutivo (que parte de regras gerais para conclusões específicas), indutivo (baseado na generalização a partir de exemplos), abduutivo (inferência das causas mais prováveis a partir de evidências) e análogo (baseado em comparações e similaridades). Tais categorias são particularmente relevantes quando pensamos em decisões de negócios com componente espacial, como a seleção de localizações estratégicas. Nessas situações, espera-se que o modelo considere múltiplos fatores e suas relações implícitas: renda local, distribuição populacional, presença de concorrentes, entre outros.

Modelos como o GPT, embora ainda não consigam raciocinar como humanos, já são capazes de estruturar sequências lógicas através de técnicas como Chain-of-Thought (WEI et al., 2022), aumentando a transparência e a coerência das respostas, principalmente quando inseridos em fluxos de tomada de decisão com múltiplas variáveis. Essa abordagem consiste em induzir o modelo a explicitar os passos intermediários de raciocínio antes de apresentar uma resposta final, simulando um processo de pensamento mais complexo. Essa diferença estrutural entre modelos reforça a importância de avaliar como diferentes arquiteturas de LLMs se comportam frente a problemas decisórios complexos, como a priorização territorial de negócios.

2.2 Geomarketing

Os Sistemas de Apoio à Decisão (DSS), segundo Crossland et al. (1995), desempenham um papel de integrar modelos analíticos, bases de dados e interfaces amigáveis para auxiliar na resolução de problemas complexos. No contexto das decisões territoriais, onde a variável espacial é determinante, os Sistemas de Apoio à Decisão Espacial (SDSS) se destacam como evolução natural dos DSS. Os SDSS combinam dados geográficos com modelos de análise para otimizar escolhas territoriais, promovendo decisões mais ágeis, precisas e visualmente compreensíveis, particularmente em cenários de alta complexidade, como o da expansão de negócios (CROSSLAND et al., 1995).

Inserido nesse contexto tem-se o Geomarketing, definido por Cavion e Philipps (2016) como um campo interdisciplinar que se ancora em três pilares fundamentais - Geografia, Cartografia e Marketing - e que, com o apoio de tecnologias como os Sistemas de Informação Geográfica (SIG), busca transformar dados espaciais em inteligência estratégica territorial. De acordo com os autores, o Geomarketing pode ser compreendido como o conjunto de técnicas que permitem analisar realidades

socioeconômicas sob uma perspectiva territorial, utilizando ferramentas cartográficas e estatísticas para subsidiar decisões. Sua origem está intimamente ligada à consolidação dos SIG nas décadas de 1980 e 1990, quando empresas começaram a perceber que atributos como localização, proximidade de concorrentes, densidade populacional e infraestrutura urbana impactavam diretamente no desempenho comercial.

Como destaca Ben Aissa et al. (2024), o geomarketing busca integrar a dimensão geográfica às análises de marketing, utilizando os Sistemas de Informação Geográfica (GIS) como suporte fundamental para a escolha de localizações. Ainda que o autor não detalhe de forma direta todos os indicadores usados em análises locais, ele enfatiza a necessidade de estudos empíricos futuros que validem, de maneira quantitativa e qualitativa, quais variáveis são mais eficazes na identificação de oportunidades comerciais e satisfação do cliente. Dessa forma, o autor reforça que o geomarketing, como prática em amadurecimento, exige tanto um embasamento técnico quanto sensibilidade contextual às dinâmicas espaciais de consumo, que exploramos neste artigo por meio dos testes de uso da IA Generativa.

2.3 Critérios para Avaliação de Modelos de IA

A análise comparativa de modelos de inteligência artificial como ferramentas para apoio à decisão estratégica requer uma definição de critérios bem fundamentados para sua avaliação. Nesse contexto, a literatura sobre *Decision Support Systems* (DSS) e *Spatial Decision Support Systems* (SDSS) tem contribuído para o desenvolvimento de abordagens que buscam assegurar a confiabilidade e a utilidade das recomendações geradas por sistemas baseados em IA (Crossland et al., 1995; Soori et al., 2024).

Conforme destacado no trabalho de Soori et al. (2024), modelos que apresentam estrutura argumentativa coerente, com raciocínio claro e alinhado ao objetivo da decisão, tendem a oferecer maior confiabilidade e robustez ao processo decisório. O conceito de consistência lógica das respostas ressalta que a clareza lógica é um requisito básico para garantir a utilidade das recomendações geradas por IA, especialmente quando aplicadas em contextos de tomada de decisão. Outro conceito advindo da revisão de Soori et al. (2024) é a sensibilidade à informação, que diz respeito à capacidade de um sistema de IA em ajustar suas respostas conforme novas informações são introduzidas. Modelos mais eficazes tendem a incorporar técnicas de aprendizado contínuo, feedback dinâmico e integração de múltiplas fontes de dados para refinar suas sugestões ao longo do tempo.


Complementando os critérios de análise de IAs voltadas para SDSS no geomarketing, a análise da concentração competitiva setorial surge como um referencial para validar a atratividade territorial de áreas urbanas e a eficácia de um modelo de recomendação territorial. O modelo gravitacional de Huff (1963) oferece suporte teórico ao afirmar que a atratividade de um ponto comercial é proporcional à massa de oferta presente na região. Essa perspectiva do autor sustenta a ideia de que áreas com maior densidade de estabelecimentos de um mesmo setor tendem a atrair mais consumidores, funcionando como polos de atração competitiva.

3. Método

Com o objetivo de avaliar o uso de Modelos de Linguagem de Grande Porte (LLMs), baseados na tecnologia GPT, no apoio à tomada de decisão territorial estratégica, propõe-se verificar a confiabilidade, sensibilidade à informação e eficácia atual das recomendações geradas por IA generativa na priorização de bairros para instalação de negócios, comparando-as com os resultados obtidos via análise de

geomarketing baseada em dados estruturados. O estudo foi estruturado em cinco etapas principais, conforme Figura 1.

Figura 1 - Desenho de pesquisa



Fonte: Elaborado pelo autor (2025)

3.1 Contextualização da Pesquisa

A cidade de Porto Alegre, no estado do Rio Grande do Sul, Brasil, foi selecionada como território de aplicação deste estudo por reunir uma série de características que favorecem a experimentação com modelos de linguagem de grande porte (LLMs) em análises locais. Trata-se de um importante centro urbano do Brasil, com disponibilidade de dados públicos segmentados por bairro, advindos dos dados oficiais do IBGE, com auxílio de plataformas de geomarketing especializadas, como o Space Data, utilizado neste estudo. De acordo com dados oficiais, a cidade conta com uma população estimada de 1.389.322 habitantes (IBGE, 2024), a 11^o mais populosa do Brasil. Com um salário médio formal de 4,0 salários-mínimos (2022), PIB per capita de R\$ 54.647,38 (2021) e IDHM de 0,805 (2010), a cidade conta com um alto grau de urbanização e diversidade econômica.

A delimitação dos bairros considerada neste estudo segue a divisão oficial adotada pelo Instituto Brasileiro de Geografia e Estatística (IBGE), conforme divulgado na malha de setores censitários do Censo Demográfico de 2022. Essa definição espacial contempla 94 bairros oficialmente reconhecidos dentro dos limites do município de Porto Alegre, todos incorporados na análise com suas respectivas variáveis sociodemográficas e econômicas completas. Os arquivos vetoriais geoespaciais utilizados como referência estão disponíveis nos repositórios oficiais do IBGE e são citados nas referências deste artigo.


A escolha dos modelos de negócio a serem utilizados neste estudo foi estratégica e por conveniência, visando avaliar a capacidade dos modelos de IA em serviços e contextos socioeconômicos contrastantes. São eles: (1) Cafeteria de padrão médio, com foco em público jovem (20 a 35 anos) das classes sociais A, B e C, conforme segmentação do IBGE. (2) Academia

de baixo custo, com público amplo em faixa etária, voltada principalmente às classes sociais D e E, com ênfase em acessibilidade e alto potencial de adesão em bairros populares. Foram estas exatas descrições acima as utilizadas para inserção nos prompts.

O modelo de cafeteria, voltado para o público das classes A, B e C, foi escolhido por representar estabelecimentos com público-alvo de classes sociais mais elevadas. Bairros com predominância de classes A e B são, em geral, menos frequentes no contexto urbano das cidades, incluindo Porto Alegre, região deste estudo. No caso de Porto Alegre, por exemplo, apenas 9 dos 94 bairros possuem rendas médias mensais per capita acima de R\$ 10.000,00, como pode ser verificado na planilha completa com os dados socioeconômicos presentes no Anexo II. Visualmente, este ponto é ilustrado

na Figura 2, que apresenta a distribuição espacial da predominância de classes sociais na cidade, advinda da plataforma de geomarketing Space Data, com dados oficiais do Censo Demográfico (IBGE).

Figura 2 - Distribuição da Predominância de Classes Sociais em Porto Alegre



Fonte: Plataforma de Geomarketing Space Data (2025)

A escolha de uma academia voltada para o público das classes D e E visa observar como os modelos se comportam em bairros de maior vulnerabilidade social, mais predominantes na cidade de Porto Alegre. Conforme os dados oficiais do IBGE da cidade, presentes no Anexo II, 43 dos 94 bairros possuem rendas médias mensais per capita abaixo de R\$ 3.500,00, por exemplo. A intenção desta diferenciação no público-alvo do modelo de negócio com isso é testar a capacidade das IAs de considerar atributos qualitativos e estruturais em territórios onde a carência de serviços pode representar, simultaneamente, riscos e oportunidades de mercado.

3.2 Escolha dos Modelos de Inteligência Artificial

A definição dos modelos de Inteligência Artificial a serem utilizados nesta pesquisa seguiu critérios metodológicos que visam assegurar diversidade arquitetônica e contrastes funcionais relevantes ao objetivo do estudo. A seleção intencional recaiu sobre dois Large Language Models (LLMs) de destaque: o ChatGPT-4o, desenvolvido pela OpenAI, e o DeepSeek-V2 (DeepThinking R1), criado por pesquisadores chineses da DeepSeek. A principal razão para esta escolha foi garantir que o experimento

capturasse não apenas diferenças de desempenho em termos de acurácia ou velocidade de resposta, mas também as implicações qualitativas da forma como diferentes arquiteturas de IA processam tarefas de tomada de decisão territorial.

Segundo a OpenAI, empresa criadora do ChatGPT-4o, este modelo representa a atual geração de LLMs com foco em versatilidade e velocidade operacional. Essa arquitetura é orientada para fluidez conversacional, com grande capacidade de adaptação a diferentes temas, o que o torna adequado para aplicações generalistas em ambientes corporativos, educacionais e de consumo. Por outro lado, segundo a empresa chinesa DeepSeek, o modelo DeepSeek-V2 (DeepThinking R1) foi projetado com ênfase em raciocínio estruturado e progressivo. Este modelo incorpora, de forma explícita, técnicas como *Chain-of-Thought prompting*, que estimulam a decomposição lógica de problemas em etapas intermediárias, buscando maior rigor argumentativo nas respostas.

Essa dualidade entre um modelo com foco em versatilidade e outro com foco em raciocínio foi intencional para o desenho experimental deste trabalho. Através dessa comparação, o estudo buscou explorar como as diferentes abordagens cognitivas artificiais impactam o processo de análise territorial e de tomada de decisão estratégica. Por fim, cabe destacar que ambos os modelos utilizados são de uso público e acessíveis via interfaces web no momento da realização deste estudo, o que garante reprodutibilidade metodológica e permite que outros pesquisadores possam replicar ou expandir o experimento com facilidade.

3.3 Definição dos Critérios para Avaliação dos Resultados

Para a adequada avaliação dos resultados obtidos pelos modelos de linguagem utilizados neste estudo, foram definidos três critérios analíticos principais: a confiabilidade, a sensibilidade e a eficácia de modelos de IA generativa. A definição desses critérios foi orientada tanto pela revisão da literatura sobre análise de sistemas de apoio à decisão (DSS e SDSS), como por práticas metodológicas adotadas em estudos anteriores que envolvem a comparação de sistemas de recomendação, como destaca Soori et al. (2024).

O critério de confiabilidade diz respeito à capacidade do sistema de fornecer respostas lógicas, estruturadas e coerentes com os objetivos da decisão a ser tomada. Isso envolve garantir que as recomendações geradas pela IA sejam claras, livres de contradições e fundamentadas de maneira alinhada ao problema em questão. Como destacam Soori et al. (2024), a qualidade da decisão em sistemas de apoio baseados em IA depende diretamente da robustez lógica das respostas, da capacidade de gerar recomendações confiáveis e da aderência ao contexto informacional e aos objetivos do processo decisório.

A sensibilidade à informação pode ser entendida como a capacidade dos sistemas de apoio à decisão baseados em IA de ajustar suas recomendações conforme novos dados são introduzidos e processados em tempo real. Esse aspecto é fundamental para garantir que o modelo permaneça responsivo a diferentes contextos informacionais e dinâmicas operacionais. Como destacado por Soori et al. (2024), a integração de técnicas de aprendizado contínuo, processamento em tempo real e loops de feedback permite que os DSS baseados em IA adaptem suas respostas e aprimorem sua eficácia à medida que recebem novas entradas de dados. No presente estudo, a comparação entre as respostas geradas com e sem dados estruturados buscou mensurar justamente essa sensibilidade, evidenciando como diferentes inputs impactam o output das recomendações.

Por fim, o critério de aderência à concentração competitiva setorial (medida de eficácia do modelo) está fundamentado nas premissas do modelo gravitacional de Huff (1963), que

defende que a atratividade de um local comercial aumenta proporcionalmente à sua massa de oferta, ou seja, ao número e à relevância dos estabelecimentos presentes. Esse modelo, originalmente desenvolvido para delimitar áreas de influência de centros comerciais, tornou-se uma referência teórica importante no campo do geomarketing para explicar por que regiões com maior concentração de um determinado setor tendem a atrair maior fluxo de consumidores. Dessa forma, analisou-se se os bairros recomendados pelas IAs coincidem com áreas que, na prática, já apresentam maior presença de negócios do segmento avaliado (cafeterias ou academias), considerando-se que essa concentração é um indicador objetivo de viabilidade territorial.

A definição desses critérios permite que a avaliação dos modelos de IA neste estudo vá além da simples comparação de respostas, incorporando elementos de análise quali e quanti, alinhados com as melhores práticas de validação de sistemas de suporte à decisão.

3.4 Aplicação Inicial: *Prompt* sem dados estruturados

A primeira etapa experimental do estudo consistiu na aplicação de um *prompt* genérico e não estruturado em ambos os modelos de IA. O *prompt* aplicado foi o mesmo para todos os casos, com linguagem direta, objetiva e replicável. Em cada interação, os modelos receberam a seguinte instrução:

"De forma direta e objetiva, recomende, em ordem de prioridade, os três melhores bairros para abertura de uma [modelo de negócio e descrição de público], em Porto Alegre, RS"

Durante esta fase, nenhuma fonte externa de dados - como censos, bancos de dados socioeconômicos ou documentos técnicos - foi utilizada para enriquecer o *input* das IAs. O resultado de cada interação foi cuidadosamente documentado e transcrito integralmente, preservando tanto a redação original das respostas quanto a ordem de prioridade sugerida por cada modelo. Ao final da coleta, as respostas obtidas de ambos os LLMs foram organizadas por modelo de IA e por tipo de negócio. As respostas completas podem ser consultadas integralmente no Anexo I.

3.5 Aplicação do *Prompt* com Dados Estruturados por Bairro

Na etapa seguinte, o mesmo *prompt* foi reaplicado em uma nova interação, desta vez com o fornecimento de uma tabela completa com os dados sociodemográficos detalhados por bairro em Porto Alegre. Estes dados incluem: Renda média domiciliar; Densidade demográfica; Número de domicílios por classe social segundo os critérios oficiais do IBGE; Habitantes por faixa etária; Número total de empresas ativas. A exata planilha que foi fornecida para o algoritmo se encontra também no Anexo II deste artigo.

Os dados utilizados foram obtidos a partir de fontes oficiais como: IBGE - Censo Demográfico 2022, Projeções Oficiais do Censo de 2018 e Receita Federal - Dados de Pessoa Jurídica pelo CNAE, atualizados até 2022. As informações foram processadas e organizadas por meio da plataforma Space Data, ferramenta de geomarketing da empresa brasileira Space Hunters, que integra diferentes camadas espaciais e de consumo com painéis analíticos de apoio à decisão. A principal intenção desta interação foi conseguir compreender o quanto cada modelo de IA consegue absorver e usar informações estruturadas na sua análise, e sua sensibilidade a essa informação quando comparadas às respostas do modelo sem acesso a estes dados. Esta etapa do estudo é baseada nos princípios de avaliação de IAs baseados na sensibilidade da informação, como destacado por Soori et al. (2024) em nosso referencial teórico.

4. Resultados

As respostas de cada modelo foram avaliadas por três critérios: (1) Confiabilidade: se os argumentos utilizados pela IA se mostraram coerentes no contexto proposto, buscando realizar uma análise qualitativa do modelo. (2) Sensibilidade à informação: se houve mudança significativa entre as respostas com e sem dados estruturados, tanto nos bairros indicados quanto na ordem de prioridade para abertura recomendada. (3) Eficácia: Este critério avaliou se os bairros recomendados pelos modelos de IA coincidem com os bairros que apresentam maior concentração de empresas no setor de interesse, segundo dados da Receita Federal e classificação do Cadastro Nacional de Atividades Econômicas (CNAE). Partiu-se da premissa de que regiões mais atrativas para determinado tipo de negócio tendem a concentrar maior número de estabelecimentos do mesmo segmento, indicando atratividade comercial e validação prática da escolha.

A análise foi realizada de forma individual em cada um dos dois modelos de negócio selecionados. Posteriormente, foi avaliado o teste como um todo para encaminhar nossas conclusões. Para realizar a análise detalhada dos resultados obtidos nas interações com os modelos de linguagem ChatGPT-4o e DeepSeek-V2 (DeepThinking R1), foram registradas as recomendações resumidas dos modelos na Figura 3, disposta nesta seção.

Figura 3 - Comparação dos Resultados de Bairros Recomendados

3.3 Aplicação Inicial: Prompt sem dados estruturados	3.4 Aplicação do Prompt com dados estruturados por bairro																																
CAFETERIA PORTO ALEGRE <table> <tr> <th>ChatGPT-4o</th><th>DeepSeek-V</th></tr> <tr> <td>1. Cidade Baixa</td><td>Bom Fim</td></tr> <tr> <td>2. Moinhos de Vento</td><td>Moinhos de Vento</td></tr> <tr> <td>3. Bom Fim</td><td>Cidade Baixa</td></tr> </table> ACADEMIA PORTO ALEGRE <table> <tr> <th>ChatGPT-4o</th><th>DeepSeek-V</th></tr> <tr> <td>1. Restinga</td><td>Restinga</td></tr> <tr> <td>2. Santo Antonio</td><td>Rubem Berta</td></tr> <tr> <td>3. Cidade Baixa</td><td>Lomba do Pinheiro</td></tr> </table>	ChatGPT-4o	DeepSeek-V	1. Cidade Baixa	Bom Fim	2. Moinhos de Vento	Moinhos de Vento	3. Bom Fim	Cidade Baixa	ChatGPT-4o	DeepSeek-V	1. Restinga	Restinga	2. Santo Antonio	Rubem Berta	3. Cidade Baixa	Lomba do Pinheiro	CAFETERIA PORTO ALEGRE <table> <tr> <th>ChatGPT-4o</th><th>DeepSeek-V</th></tr> <tr> <td>1. Centro Histórico</td><td>Petrópolis</td></tr> <tr> <td>2. Petrópolis</td><td>Menino Deus</td></tr> <tr> <td>3. Sarandi</td><td>Bom Fim</td></tr> </table> ACADEMIA PORTO ALEGRE <table> <tr> <th>ChatGPT-4o</th><th>DeepSeek-V</th></tr> <tr> <td>1. Mário Quintana</td><td>Lomba do Pinheiro</td></tr> <tr> <td>2. Restinga</td><td>Restinga</td></tr> <tr> <td>3. Lomba do Pinheiro</td><td>Mário Quintana</td></tr> </table>	ChatGPT-4o	DeepSeek-V	1. Centro Histórico	Petrópolis	2. Petrópolis	Menino Deus	3. Sarandi	Bom Fim	ChatGPT-4o	DeepSeek-V	1. Mário Quintana	Lomba do Pinheiro	2. Restinga	Restinga	3. Lomba do Pinheiro	Mário Quintana
ChatGPT-4o	DeepSeek-V																																
1. Cidade Baixa	Bom Fim																																
2. Moinhos de Vento	Moinhos de Vento																																
3. Bom Fim	Cidade Baixa																																
ChatGPT-4o	DeepSeek-V																																
1. Restinga	Restinga																																
2. Santo Antonio	Rubem Berta																																
3. Cidade Baixa	Lomba do Pinheiro																																
ChatGPT-4o	DeepSeek-V																																
1. Centro Histórico	Petrópolis																																
2. Petrópolis	Menino Deus																																
3. Sarandi	Bom Fim																																
ChatGPT-4o	DeepSeek-V																																
1. Mário Quintana	Lomba do Pinheiro																																
2. Restinga	Restinga																																
3. Lomba do Pinheiro	Mário Quintana																																

Fonte: Elaborado pelo Autor (2025)

4.1 Resultados por Modelo de Negócio

Nesta primeira subseção, os resultados são apresentados de forma segmentada por modelo de negócio, para ambos os modelos de Inteligência Artificial. Essa organização permite visualizar com maior clareza as diferenças nas respostas dos modelos em função das particularidades de cada segmento e modelo de negócio. As transcrições completas das interações com as IAs estão disponíveis no Anexo I, permitindo a consulta integral das respostas obtidas. Na subseção seguinte, os resultados serão avaliados de acordo com os critérios de avaliação definidos previamente na metodologia.

4.1.1 Cafeteria

Na interação inicial, sem acesso aos dados estruturados, tanto o ChatGPT-4o quanto o DeepSeek-V2 (DeepThinking R1) priorizaram bairros reconhecidos pelo perfil

jovem, de alto poder aquisitivo e apelo cultural. O ChatGPT-4o indicou como principais bairros para a abertura da cafeteria a Cidade Baixa, em primeiro lugar, seguida por Moinhos de Vento e Bom Fim. O modelo justificou a escolha com base na presença de jovens adultos das classes A e B, destacando aspectos culturais qualitativos, como no caso da Cidade Baixa, descrita como “Região boêmia e cultural, ideal para cafés com personalidade”.

O DeepSeek-V2 (DeepThinking R1), por sua vez, recomendou inicialmente Bom Fim, Moinhos de Vento e Cidade Baixa. A argumentação também destacou a presença de público jovem e observações qualitativas, como no caso do Bom Fim, caracterizado por “alta circulação, vida noturna e cultural, forte apelo a cafeterias modernas”, e o Moinhos de Vento, por apresentar um “ambiente sofisticado mas com demanda por opções descontraídas e qualidade”. Quando os dados estruturados foram fornecidos, ambos os modelos alteraram significativamente suas recomendações. O ChatGPT-4o passou a priorizar o Centro Histórico, seguido de Petrópolis e Sarandi. Questionado sobre como realizou sua análise, o modelo apresentou uma metodologia quantitativa baseada em pontuação ponderada, atribuindo pesos aos critérios utilizados. A decisão foi fortemente influenciada pelo número de habitantes entre 20 e 35 anos e pela presença de domicílios das classes A, B e C somadas (ambos indicadores com peso de 40%), enquanto a renda média recebeu peso de apenas 20%. Apesar de ter consumido praticamente todas as variáveis, o ChatGPT-4o não considerou o número de empresas no cálculo final de sua pontuação ponderada. O modelo DeepSeek-V2 (DeepThinking R1) indicou, após receber acesso aos dados, os bairros Petrópolis, Menino Deus e Bom Fim como mais indicados para a cafeteria. A mudança de prioridade refletiu o consumo de todas as variáveis fornecidas, mas com um critério distinto: o modelo não ponderou os indicadores com pesos diferentes, assumindo que todos tinham a mesma influência na hierarquia final. Além disso, introduziu etapas adicionais de validação e exclusão com base na coerência entre perfil do bairro e modelo de negócio. Um exemplo foi a exclusão do Centro Histórico, classificado como área com perfil comercial e transitório, o que o modelo considerou incompatível com o objetivo do negócio, mesmo que isso não tenha sido explicitamente solicitado no *prompt*. Ambos os modelos demonstraram diferentes formas de raciocínio: enquanto o ChatGPT-4o privilegiou uma análise quantitativa ponderada, o DeepSeek-V2 (DeepThinking R1) combinou uso integral dos dados com filtros qualitativos e lógicas próprias de consistência, reforçando visões distintas sobre como interpretar um mesmo conjunto de informações.

4.1.2 Academia

Para o modelo de negócio voltado à implantação de academias acessíveis às classes D e E, ambos os modelos de IA priorizaram, nas interações sem dados estruturados, bairros com alta densidade populacional e perfil popular. O ChatGPT-4o recomendou inicialmente Restinga, Santo Antônio e Cidade Baixa, destacando a presença de população das classes D e E e aspectos como comércio local e infraestrutura comunitária. A Restinga, por exemplo, foi descrita como um bairro com praças, campos de futebol e comércio diversificado. Já o DeepSeek-V2 (DeepThinking R1) indicou Restinga, Rubem Berta e Lomba do Pinheiro, justificando com baixa concorrência de academias e carência de serviços de fitness.

Com os dados estruturados, ambos ajustaram suas recomendações. O ChatGPT-4o passou a priorizar Mário Quintana, seguido de Restinga e Lomba do Pinheiro. O modelo utilizou quatro critérios: número absoluto e proporção de domicílios das classes D e E,

população total e renda média (quanto menor, melhor), sem atribuir pesos diferentes. A média dos rankings definiu a pontuação final. Assim como na cafeteria, o número de empresas foi ignorado, e não houve filtros qualitativos. O DeepSeek-V2 (DeepThinking R1), com acesso aos dados, indicou Lomba do Pinheiro, Restinga e Mário Quintana. Considerou os mesmos critérios, também sem pesos, e aplicou filtros qualitativos, como a exclusão de bairros com população muito baixa (Pedra Redonda e São Caetano). Diferente do teste anterior, o modelo não utilizou todas as variáveis da planilha, desconsiderando também o número de empresas.

4.2 Avaliação dos Resultados por Critério

Após a apresentação dos resultados por modelo de negócio, esta subseção dedica-se à análise comparativa dos desempenhos dos LLMs com base nos critérios definidos na metodologia. Ela está organizada para que possa-se avaliar respectivamente os critérios de Confiabilidade, Sensibilidade à Informação e Eficácia. Essa etapa busca estabelecer, de forma sistemática, as principais diferenças de desempenho entre os modelos.

4.2.1 Confiabilidade

Os dois modelos analisados, ChatGPT-4o e DeepSeek-V2 (DeepThinking R1) apresentaram consistência adequada ao contexto solicitado de análise nas suas recomendações, baseando-se em premissas de Geomarketing vistas por tanto para o modelo de cafeteria quanto para o de academia. O ChatGPT-4o, ao ser exposto aos dados estruturados, reforçou sua tendência de organizar as respostas de forma quantitativa, utilizando médias e ponderações para hierarquizar os bairros. A abordagem gerou justificativas mais objetivas, com foco em indicadores como renda média, densidade populacional e classes sociais.

Por adotar uma lógica mais rígida, o ChatGPT-4o assumiu algumas premissas generalistas, como considerar a presença de jovens adultos e classes A, B e C como fatores determinantes, de forma a valorizá-los mais perante outros indicadores. Essa tendência evidencia um espaço para intervenção humana visando ajustar parâmetros de análise, de modo a adequar as recomendações da IA às características específicas de cada modelo de negócio. Por sua vez, o DeepSeek-V2 (DeepThinking R1) utilizou de um perfil de raciocínio mais interpretativo, esperado de um modelo de IA desenhado para tal.

O modelo fundamentou suas escolhas de forma matemática, adicionando filtros por meio de premissas coerentes e se utilizando de percepções qualitativas, como o perfil cultural e urbano do bairro. Este modelo incorporou de forma mais eficiente as informações a ele oferecidas, utilizando-se da atividade comercial da região na análise quantitativa. O mesmo não aplicou pesos matemáticos explícitos nas análises, o que lhe conferiu uma argumentação mais flexível e facilmente justificável, uma vez que o modelo não assumiu nenhuma premissa que considere algum indicador como mais relevante e importante frente aos demais.

4.2.2 Sensibilidade à Informação

Ambos os modelos demonstraram alta sensibilidade à introdução dos dados estruturados. No caso da cafeteria, enquanto na interação inicial os dois modelos sugeriram os mesmos bairros (Cidade Baixa, Moinhos de Vento e Bom Fim) variando apenas a ordem, a introdução dos dados levou a mudanças substanciais nas recomendações. O ChatGPT-4o passou a priorizar o Centro Histórico, seguido de Petrópolis e Sarandi,

enquanto o DeepSeek-V2 priorizou Petrópolis, Menino Deus e Bom Fim.

Curiosamente, para o modelo de academia, o comportamento dos modelos se inverteu: na interação inicial, houve divergência nas recomendações, com apenas o bairro Restinga aparecendo nas sugestões de ambos. Após a introdução dos dados estruturados, houve alinhamento total nas sugestões dos três bairros indicados, Lomba do Pinheiro, Restinga e Mário Quintana, embora em ordens diferentes. Esse padrão de comportamento pode sugerir que a disponibilização de dados estruturados tem um poder de alinhamento e convergência nos modelos de IA que varia conforme o modelo de negócio e público-alvo selecionado, indicando que não é apenas a incorporação de dados quantitativos que trará alinhamento entre dois modelos de IA diferentes.

4.2.3 Eficácia (Aderência à Concentração Competitiva Setorial)

A avaliação de aderência foi realizada por meio da análise do número de empresas estabelecidas nos bairros indicados, utilizando dados oficiais da Receita Federal (2022) classificados pelos respectivos CNAEs. A premissa adotada segue o modelo probabilístico de Huff (1963), segundo o qual locais mais atrativos tendem a concentrar estabelecimentos do mesmo segmento, refletindo dinâmicas de mercado competitivas. Para o modelo da cafeteria, considerou-se o CNAE da classe 5611-2 - Restaurantes e Outros Estabelecimentos de Serviços de Alimentação e Bebidas.

Observou-se que os bairros recomendados, tanto na interação inicial quanto após o fornecimento dos dados estruturados, estão quase todos entre os treze bairros com maior número de empresas de alimentação da cidade de Porto Alegre, que ao todo contém 94 bairros segundo o IBGE. A única exceção foi o bairro Bom Fim, que, apesar de ocupar a 28ª posição em número absoluto de empresas, não apresenta um índice tão baixo de empresas de alimentação por habitante, o que pode reforçar sua atratividade qualitativa. O número de empresas de alimentação por bairro nos bairros selecionados pela IA no estudo estão representados em formato de tabela comparativa na Tabela 1, nesta seção.

Tabela 1 - Quadro Comparativo Atividades de Empresas de Alimentação por Bairro em Porto Alegre, Ressaltando os Bairros Selecionados pela IA no Estudo Proposto.

Bairros Recomendados	Número de CNAE's (Empresas de Alimentação)	População (hab.)	Empresas de Alimentação por Habitante	Ranking de Bairros por Número de Empresas de Alimentação
Cidade Baixa	301	13.014	0,02312893807	3º
Moinhos de Vento	189	10.011	0,01887923284	13º
Bom Fim	112	10.278	0,01089706169	28º
Centro Historico	485	30.366	0,01597181058	1º
Petropolis	232	37.701	0,006153682926	8º
Sarandi	342	51.699	0,006615214994	2º
Menino Deus	211	27.960	0,007546494993	12º

Fonte: Space Data (Classificação Nacional de Atividades Econômicas - Receita Federal 2022)

No caso da academia, foi utilizado o CNAE 9313-1/00 - Atividades de Condicionamento Físico. A análise revelou que os bairros indicados, como a Restinga, Lomba do Pinheiro, Mário Quintana e Rubem Berta, em geral, não figuram entre as regiões com maior número absoluto de academias. Esse fato, porém, é coerente com a estratégia de mercado pretendida, voltado para classes D e E, uma vez que os bairros com maior concentração de academias em Porto Alegre estão majoritariamente situados em áreas de maior poder aquisitivo, tendo como primeiro colocado o bairro Petrópolis (renda média de R\$ 8.920), em segundo o bairro Menino Deus (renda média de R\$ 7.210) e Auxiliadora (renda média de R\$ 8.060). O número de academias por bairro nos bairros selecionados pela IA no estudo estão representados em formato de tabela comparativa na Tabela 2, nesta seção.

Tabela 2 - Quadro Comparativo de Academias por Bairro em Porto Alegre, ressaltando os Bairros Selecionados pela IA no Estudo Proposto.

Bairros Recomendados	Número de CNAE's (Academias)	População (hab.)	Academias por Habitante	Ranking de Bairros por Número de Academias
Cidade Baixa	15	13.014	0,001152604887	19º
Restinga	7	62.538	0,0001119319454	33º
Santo Antônio	7	13.103	0,0005342288026	34º
Rubem Berta	13	27.930	0,0004654493376	22º
Lomba do Pinheiro	5	58.867	0,00008493723139	46º
Sarandi	20	51.699	0,000386854678	12º

Fonte: Space Data (Classificação Nacional de Atividades Econômicas - Receita Federal 2022)

Assim, os resultados apontam que, apesar das abordagens distintas, ambos os modelos demonstraram sensibilidade ao contexto competitivo setorial: ora reconhecendo polos consolidados (como no caso das cafeterias), ora revelando oportunidades em mercados pouco explorados (como nas academias).

5. Conclusões

O objetivo principal deste trabalho foi avaliar o grau de confiabilidade, sensibilidade e eficácia de modelos de linguagem de grande porte (LLMs), especificamente o ChatGPT-4o e o DeepSeek-V2 (*DeepThinking* R1), na priorização de bairros para a abertura de novos negócios em ambiente urbano, utilizando como estudo de caso a cidade de Porto Alegre. A metodologia proposta, baseada na comparação entre interações sem e com dados estruturados de geomarketing, permitiu verificar que ambos os modelos foram capazes de estruturar recomendações minimamente consistentes, adaptáveis às informações fornecidas e alinhadas com práticas conhecidas de análise territorial.

A importância dos resultados encontrados reside no fato de que ambos os modelos demonstraram uma linha lógica de análise coerente, utilizando dados comuns a prática do geomarketing, com uma boa capacidade de uso dos dados estruturados, sensibilidade às variáveis críticas para decisão territorial e, principalmente, habilidade em gerar recomendações que, na maioria dos casos, coincidem com bairros reconhecidos por sua atratividade comercial setorial. Além disso, o estudo revelou diferenças interessantes no comportamento dos modelos: enquanto o ChatGPT-4o apresentou uma abordagem mais quantitativa e estruturada, o DeepSeek-V2 (*DeepThinking* R1) se destacou por conseguir utilizar uma análise quantitativa junto a uma leitura

mais contextual dos territórios, característica esperada de um modelo criado com o foco na resolução de problemas complexos.

Em termos práticos, os resultados reforçam que a aplicação de modelos de linguagem como suporte ao geomarketing permite complementar os tradicionais Sistemas de Apoio à Decisão Espacial (SDSS). A capacidade que testemunhamos de utilizar informações não estruturadas, gerar inferências contextuais e absorver dados sociodemográficos permite que os LLMs funcionem como ferramentas para enriquecer análises territoriais. Entretanto, o método usado também apresenta limitações que merecem ser consideradas. Primeiramente, a análise restringiu-se a uma única cidade (Porto Alegre), o que limita a generalização dos resultados para realidades urbanas de diferentes escalas, níveis de complexidade e contextos culturais. Testes futuros em cidades de pequeno porte, localidades remotas e em países de diferentes estágios de desenvolvimento poderiam ampliar a compreensão sobre a eficácia desses modelos. Além disso, não foi avaliado neste estudo o grau de estabilidade das respostas fornecidas pelos modelos para o mesmo prompt em diferentes interações, o que poderia revelar variações no raciocínio e, por consequência, em algumas análises descritas.

Outra limitação natural refere-se à base de dados utilizada: as informações sobre empresas são atualizadas até 2022, enquanto dados socioeconômicos de classe social e faixa de renda derivam de projeções do Censo 2018, devido à indisponibilidade completa dos dados do Censo 2022 até o momento da publicação. Soma-se a isso o problema de dependência da qualidade dos dados estruturados: ambos os modelos apresentaram alta sensibilidade aos inputs, o que reforça a necessidade de rigor na organização, seleção e veracidade das informações fornecidas à IA, uma vez que toda a análise quantitativa deriva desse input.

Para pesquisas futuras, sugere-se expandir a análise para diferentes tipos de negócios e perfis de público, testar a aplicabilidade dos modelos em outras cidades e contextos geográficos, avaliar sistematicamente a estabilidade das respostas dos LLMs frente a múltiplas execuções e testes, além de testar diferentes modelos de LLMs, como o modelo de reflexão avançada do ChatGPT (o3). Além disso, seria interessante e promissor explorar formas híbridas de integração entre LLMs e plataformas tradicionais de geomarketing, aproveitando e combinando as vantagens analíticas de cada abordagem. Ao passo que as tecnologias em Inteligência Artificial avançam em muitas frentes, pesquisas como essa representam uma linha promissora para a evolução da inteligência estratégica aplicada à escolha territorial.

6. REFERÊNCIAS

- Ansari, O. B. (2023). Geomarketing intelligence in the era of artificial intelligence and computer science (Master's thesis). Triagon Academy, Malta.
- Ben Aissa, N., Belamhitou, M., & Reklou, A. (2024). Mapping consumer behavior: A literature review of geomarketing research. *International Journal of Advanced Research in Innovation, Management & Social Sciences*, 7(1). <https://doi.org/10.57109/210>
- Birkin, M., Clarke, G., & Clarke, M. (2002). Retail geography and intelligent network planning. Wiley.
- Cavion, R., & Philips, J. (2006). Os fundamentos do geomarketing: cartografia, geografia e marketing. In Congresso Brasileiro de Cadastro Técnico Multifinalitário – COBRAC. Universidade Federal de Santa Catarina.
- Crossland, M. D., Wynne, B. E., & Perkins, W. C. (1995). Spatial decision support systems: An overview of technology and a test of efficacy. *Decision Support Systems*, 14, 219–235.
- DeepSeek. (2024). DeepSeek-V2 [Large language model]. <https://www.deepseek.com>
- Herhausen, D., Bernitter, S. F., Ngai, E. W. T., Kumar, A., & Delen, D. (2024). Machine learning in marketing: Recent progress and future research directions. *Journal of Business Research*, 170. <https://doi.org/10.1016/j.jbusres.2023.114254>
- Huff, D. L. (1963). A probabilistic analysis of shopping center trade areas. *Land Economics*, 39(1), 81–90. <https://www.jstor.org/stable/3144521>

- Instituto Brasileiro de Geografia e Estatística (IBGE). (2023). Malhas de setores censitários e divisões intramunicipais: Censo Demográfico 2022. <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais/26565-malhas-de-setores-censitarios-divisoes-intramunicipais.html>
- Janissek-Muniz, R. (2016). Fatores críticos em projetos de inteligência estratégica antecipativa e coletiva. *Revista Inteligência Competitiva*, 6(2), 147–180.
- Karapantelakis, A., Falkner, M., Schotten, H. D., et al. (2024). A survey on the integration of generative AI for critical thinking in mobile networks. Preprint.
- Lesca, H. (2003). *Veille stratégique: La méthode L.E.SCA* (2nd ed.). EMS Management & Société.
- Mikalef, P., Boura, M., Lekakos, G., & Krogstie, J. (2019). Big data analytics and firm performance: Findings from a mixed-method approach. *Journal of Business Research*, 98, 261–276.
- OpenAI. (2024). ChatGPT-4o (version 4.0) [Large language model]. <https://chat.openai.com/>
- Oppioli, M., Gatti, F., D'Amico, M., & Bonfanti, A. (2022). The role of artificial intelligence for management decision: A structured literature review. *Management Decision*. Advance online publication.
- Rohrbeck, R., & Kum, M. E. (2018). Corporate foresight and its impact on firm performance: A longitudinal analysis. *Technological Forecasting and Social Change*, 129, 105–116.
- Soori, M., et al. (2024). AI-based decision support systems in Industry 4.0: A review. *Journal of Economy and Technology*. <https://doi.org/10.1016/j.ject.2024.08.005>
- Space Hunters. (2025). Space Data: Plataforma de geomarketing e inteligência territorial. <https://data.spacehunters.com.br/>
- Tabesh, P. (2022). Who's making the decisions? How managers can harness artificial intelligence and remain in charge. *Journal of Business Strategy*, 43(6), 373–380. <https://doi.org/10.1108/JBS-05-2021-0090>
- Vaswani, A., et al. (2017). Attention is all you need. In *Advances in Neural Information Processing Systems (NeurIPS)*, 30. <https://arxiv.org/abs/1706.03762>
- Wei, J., et al. (2022). Chain of thought prompting elicits reasoning in large language models. <https://arxiv.org/abs/2201.11903>

ANEXO I - Interações com IAs

O arquivo contendo as transcrições exatas das interações com as Inteligências Artificiais está disponível em:

<https://docs.google.com/document/d/1JXGfvZTm96lnnhq579VdwoVqKvmC9LdAaElBTSnnbXA/edit?usp=sharing>

(Acesso público. Para melhor visualização, recomenda-se abrir em um computador.)

ANEXO II – Planilha com Dados Estruturados por Bairro Utilizada nos Testes

A planilha contendo os dados utilizados como input nos testes com as inteligências artificiais está disponível em:

<https://docs.google.com/spreadsheets/d/1X63qFJlPkKLecmWla5sOJvm6QxlaIbhl/edit?usp=sharing&oid=107919646971718171196&rtpof=true&sd=true>

(Acesso público. Para melhor visualização, recomenda-se abrir em um computador.)