

Universidade do Algarve
Escola Superior de Gestão, Hotelaria e Turismo
Mestrado em Gestão de PME

Pedro André dos Santos Esteves

Dissertação de Mestrado

**Implementação de um sistema de recomendação de
restaurantes, para empresários, na área metropolitana
de Lisboa**

Ano Letivo - 2023/2024

Dissertação de Mestrado

para obtenção do Grau de Mestre em Gestão de PME

Trabalho efetuado sob a orientação de:

Prof. Doutor Marco Paulo Santos Carrasco

Implementação de um sistema de recomendação de restaurantes, para empresários, na área metropolitana de Lisboa

Declaração de autoria do trabalho

Declaro ser o autor deste trabalho, que é original e inédito. Autores e trabalhos consultados estão devidamente citados no texto e constam da listagem de referências incluída.

Pedro André dos Santos Esteves

©Copyright: Pedro André dos Santos Esteves

A Universidade do Algarve reserva para si o direito, em conformidade com o disposto no Código do Direito de Autor e dos direitos Conexos, de arquivar, reproduzir e publicar a obra, independentemente do meio utilizado, bem como de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição para fins meramente educacionais ou de investigação e não comerciais, conquanto seja dado o devido crédito ao autor e editor respetivos.

Resumo

O presente trabalho tem como objetivo a implementação de um sistema de recomendação de restaurantes para empresários na Área Metropolitana de Lisboa (AML), utilizando *Large Language Models* (LLMs) para a análise de sentimentos contidos em comentários de restaurantes, provenientes da plataforma online DIG-IN (ex-Zomato). Para sustentar a abordagem metodológica, foi realizada uma revisão da literatura sobre a utilização de LLMs e a análise de sentimentos no setor da restauração.

A revisão da literatura realizada centrou-se na exploração de diferentes abordagens de sistemas de recomendação e análise de sentimentos.

Foram analisados modelos tradicionais, como o DINESERV, e a sua adaptação para plataformas digitais, bem como técnicas mais recentes, como a Análise de Sentimento Baseada em Aspectos (ABSA). Esta revisão destaca também a crescente relevância dos LLMs como ferramentas robustas para interpretar grandes volumes de dados textuais, especialmente em setores como a restauração e o turismo.

A metodologia adotada segue uma estrutura organizada em três fases principais. Na primeira fase, efetuou-se o pré-processamento dos dados, compilando e organizando conjuntos de dados (*datasets*) relativos às características dos restaurantes na AML, como o tipo de cozinha, localização, número de comentários e avaliações.

Na segunda fase, foram definidos os atributos e dimensões relevantes para a satisfação dos clientes, sendo aplicada uma extração de palavras-chave dos comentários disponíveis na plataforma. Esta extração foi conduzida com o apoio dos LLMs, que permitiram identificar termos e expressões associados a aspetos críticos da experiência gastronómica.

Na terceira fase, foram desenvolvidos e aplicados *prompts* aos modelos GPT-4 (versão de 2024-05-13), GPT-3.5 Turbo, e Mistral 7B Instruct para a classificação dos atributos contidos nos comentários. Estes modelos analisaram a polaridade dos sentimentos relacionados com aspetos como a qualidade da comida, o serviço, o ambiente e outros fatores que influenciam a experiência dos clientes.

A principal aplicação prática deste estudo foi a construção de um protótipo de uma ferramenta que permite a potenciais investidores avaliar o cenário competitivo na AML. Esta ferramenta não apenas analisa o potencial de implementação de determinado tipo de restaurante em diferentes localizações, mas também oferece uma visão detalhada dos concorrentes, com base na análise de sentimentos extraída dos comentários dos consumidores.

Além disso, o estudo abordou a adaptação do modelo DINESERV para a análise automática de comentários em plataformas digitais, simplificando os seus 29 critérios originais em 10 novos critérios, mais adequados à natureza concisa das avaliações online. A viabilidade da utilização de grandes modelos de linguagem (LLMs) para a extração, identificação e classificação de atributos relevantes na análise de sentimento foi demonstrada com sucesso, abrindo portas para futuras investigações que explorem o seu potencial em outras áreas da restauração e do turismo.

Palavras-chave: Grandes Modelos de Linguagem, Avaliações *Online*, Restauração, Processamento de Linguagem Natural (PLN), Análise de Sentimento Baseado em Aspectos (ABSA), Engenharia de *prompts*.

Abstract

The present work aims to implement a restaurant recommendation system for entrepreneurs in the Lisbon Metropolitan Area (AML), using Large Language Models (LLMs) for sentiment analysis of restaurant reviews sourced from the online platform DIG-IN (formerly Zomato). To support the methodological approach, a literature review was conducted on the use of LLMs and sentiment analysis in the restaurant industry.

The literature review focused on exploring different approaches to recommendation systems and sentiment analysis. Traditional models, such as DINESERV, and their adaptation to digital platforms were analyzed, as well as more recent techniques like Aspect-Based Sentiment Analysis (ABSA). This review also highlights the growing relevance of LLMs as robust tools for interpreting large volumes of textual data, especially in sectors such as restaurants and tourism.

The methodology adopted follows a structure organized into three main phases. In the first phase, data preprocessing was carried out, compiling and organizing datasets related to restaurant characteristics in the AML, such as type of cuisine, location, number of reviews, and ratings.

In the second phase, relevant attributes and dimensions for customer satisfaction were defined, and a keyword extraction from the reviews available on the platform was conducted. This extraction was supported by LLMs, which helped identify terms and expressions associated with critical aspects of the dining experience.

In the third phase, prompts were developed and applied to the GPT-4 (2024-05-13 version), GPT-3.5 Turbo, and Mistral 7B Instruct models to classify the attributes found in the reviews. These models analyzed the sentiment polarity related to aspects such as food quality, service, ambiance, and other factors that influence the customer experience.

The main practical application of this study was the construction of a prototype tool that allows potential investors to assess the competitive landscape in the AML. This tool not only analyzes the potential for implementing specific types of restaurants in different locations but also provides a detailed overview of competitors based on sentiment analysis extracted from consumer reviews.

Additionally, the study addressed the adaptation of the DINESERV model for the automatic analysis of reviews on digital platforms, simplifying its 29 original criteria into 10 new criteria, more suited to the concise nature of online reviews. The viability of using Large Language Models (LLMs) to extract, identify, and classify relevant attributes in sentiment analysis was successfully demonstrated, opening the door for future research to explore their potential in other areas of the restaurant and tourism industries.

Keywords: Large Language Models(LLM), Online Reviews, Restaurant Industry, Natural Language Processing (NLP), Aspect-Based Sentiment Analysis (ABSA), Prompt engineering.

Índice

1. Introdução.....	1
1.1. Contextualização do tema.....	1
1.2. Objetivos da investigação.....	3
1.3. Estrutura.....	3
2. Enquadramento Teórico.....	5
2.1. Relevância dos dados aplicados à gestão.....	5
2.2. Aprendizagem de máquina (machine learning), modelos de processamento de linguagem natural e modelos de linguagem (LLMs).....	8
2.2.1. O que é a aprendizagem de máquina (machine learning)?.....	8
2.2.2. Processadores de Linguagem Natural (PLN).....	9
2.2.3. Large Language Models (LLMs).....	10
2.3. Linguagem de programação informática para o pré-processamento de dados.....	12
2.4. Contextualização dos estudos que visam melhorar a decisão de investimento na restauração.....	14
2.4.1. Origem dos dados dos estudos (datasets).....	14
2.4.2. Abrangência geográfica.....	16
2.4.3. Técnicas utilizadas.....	16
2.5. Análise de sentimentos.....	20
2.5.1. O método ABSA (Aspect-Based Sentiment Analysis).....	23
2.6. Definição de um referencial para avaliar a experiência num restaurante.....	26
2.6.1. Medindo a satisfação do consumidor na restauração.....	27
2.6.2. Analisando a evolução de modelos conceptuais para aferir a satisfação do cliente.....	29
2.6.3. DINESERV - Um referencial multidimensional para a análise de sentimentos....	34
2.6.4. Adaptando o referencial DINESERV.....	38
3. Metodologia.....	42
3.1. Origem dos dados.....	43
3.2. Caracterização dos dados.....	44
3.3. Definição da amostra.....	46
3.4. Personalização de uma instrução (prompt) para aferir a precisão do ChatGPT na análise.....	51
3.4.1. Comparação entre classificação geral feita pelos clientes vs. a classificação feita pela máquina.....	54
3.4.2. Obtenção da classificação por dimensão do referencial.....	57
3.4.3. Estabelecer atributos para o referencial.....	59
3.4.4. Associação dos 10 atributos às dimensões.....	61
3.4.5. Estabelecer palavras-chave para os atributos do modelo.....	65
3.5. Modelos para a análise de sentimento aos comentários.....	68
3.5.1. Aferindo-se a precisão dos modelos - Classificação geral pelo cliente vs. classificação geral pelos modelos.....	69
3.5.2. Aferindo-se a concordância na classificação dos atributos, entre modelos.....	80
3.5.3. Aferindo-se a concordância na classificação dos atributos, entre humano e	

modelos.....	82
3.6. Aplicação do sistema de análise num protótipo de ferramenta de recomendação...	87
4. Discussão dos resultados.....	91
4.1. Análise da concordância dos modelos.....	91
4.2. Processamento de todos os comentários da categoria 'Italian'.....	92
4.3. Relevância da ferramenta prototipada para o investidor.....	93
5. Conclusão.....	95

Índice de figuras

Figura 1. Página online da plataforma DIG-IN, na versão para PC.....	2
Figura 2. O diagrama propõe a ciência de dados como resultado da capacidade humana em conjunto com a capacidade das máquinas.....	6
Figura 3. Para a aprendizagem de máquina entregar valor à organização, a participação humana ainda se verifica no início e no final do processamento automático dos dados.....	8
Figura 4. Utilização, por indústria da inteligência artificial generativa, resultante de um questionário aplicado a 1.684 funcionários dos diversos níveis dentro das empresas.....	11
Figura 5. Linguagens de programação mais utilizadas por programadores em 2023.....	13
Figura 6. Razões para a utilização da linguagem Python em 2022.....	13
Figura 7. Línguas mais utilizadas para conteúdo online em 2024.....	19
Figura 8. Amostra de 4 comentários recolhidos da plataforma TripAdvisor, sobre um restaurante na Praia da Rocha, em Portimão, em 15 de Janeiro de 2024....	21
Figura 9. No comentário a), a amarelo destaca-se um aspecto neutro, a verde um positivo e a vermelho um negativo.....	24
Figura 10. Amostra do comentário a). Na primeira linha do comentário, destacam-se três aspectos diferentes, cada um com uma polaridade de sentimento.....	25
Figura 11. Exemplo sobre os critérios de avaliação específicos da plataforma TripAdvisor.com, sobre um restaurante na Praia da Rocha, em Portimão.....	26
Figura 12. Exemplo de comentário de cliente na TripAdvisor.com, sobre um restaurante na Praia da Rocha, em Portimão.....	28
Figura 13. Exemplo de comentário de cliente na TripAdvisor.com, sobre um restaurante na Praia da Rocha, em Portimão.....	28
Figura 14. Exemplo de comentário de cliente na TripAdvisor.com, sobre um restaurante na Praia da Rocha, em Portimão.....	29
Figura 15. Exemplos de comentários de clientes na TripAdvisor.com, sobre um restaurante na Praia da Rocha, em Portimão.....	37
Figura 16. Os 10 tipos de cozinha mais frequentes no conjunto dos 15.892 restaurantes.....	47
Figura 17. Restaurantes com um só tipo de cozinha, das top 10 categorias.....	48
Figura 18. Número de comentários escritos com um só tipo de cozinha associado, das top 10 categorias.....	49
Figura 19. Média de comentários por restaurante da categoria.....	49
Figura 20. Amostra de 3 dos 15 comentários constantes na primeira página de comentários na plataforma TripAdvisor.com, de um restaurante na Praia da Rocha, em Portimão.....	54
Figura 21. Cronologia de Large Language Models no mercado.....	68
Figura 22. Taxa de concordância entre os modelos para cada atributo.....	81
Figura 23. Comparativo entre modelos, pela empresa OpenAI.....	87
Figura 24. Ferramenta em funcionamento - Localização escolhida na área da	

rotunda Marquês de Pombal (38.725033, -9.151035).....	88
Figura 25. Ferramenta em funcionamento - Auscultação de um restaurante específico.....	89
Figura 26. Ferramenta em funcionamento - Gráficos radar por restaurante.....	90
Figura 27. Diferenças das classificações gerais feitas pelos clientes e o modelo GPT 3.5 Turbo.....	93

Índice de tabelas

Tabela 1. Resumo de técnicas utilizadas pelos investigadores.....	18
Tabela 2. Lacunas-chave identificadas no modelo GAP, com exemplos de casos que remetem para cada lacuna.....	31
Tabela 3. Dimensões identificadas pelo modelo SERVQUAL e exemplos de casos que remetem para esta dimensão.....	32
Tabela 4. Dimensões identificadas pelo modelo DINESERV e exemplos de casos que remetem para esta dimensão.....	34
Tabela 5. As 5 dimensões do modelo DINESERV, dimensões da análise e respectivos 29 critérios de avaliação.....	35
Tabela 6. Resumo dos 15 novos critérios de avaliação, derivados do modelo DINESERV...41	41
Tabela 7. Exemplo do conjunto de dados (dataset) dos restaurantes pré-processados.....	45
Tabela 8. Exemplo do conjunto de dados (dataset) das avaliações pré-processado.....	46
Tabela 8. Tabela das classificações feitas pelos clientes em comparação com as classificações dadas pela máquina.....	56
Tabela 9. Tabela com as classificações dadas pela máquina, por dimensão do modelo de análise.....	58
Tabela 10. Os 10 atributos resultantes da pesquisa dos autores e correspondência com outras publicações.....	60
Tabela 11. Tabela com os atributos relacionados com as dimensões.....	63
Tabela 12. Tabela com o que cada atributo pretende capturar, de acordo com os autores...64	64
Tabela 13. Tabela com as palavras-chave, por atributo, e respectiva contagem.....	67
Tabela 15. Tabela (parte 2) com as classificações dos atributos feitas pelo LLM ChatGPT 3.5 Turbo.....	73
Tabela 16. Tabela (parte 1) com as classificações dos atributos feitas pelo LLM ChatGPT 4o_2024-05-13.....	75
Tabela 17. Tabela (parte 2) com as classificações dos atributos feitas pelo LLM ChatGPT 4o_2024-05-13.....	76
Tabela 18. Tabela (parte 1) com as classificações dos atributos feitas pelo LLM Mistral 7B Instruct (Free).....	77
Tabela 19. Tabela (parte 2) com as classificações dos atributos feitas pelo LLM Mistral 7B Instruct (Free).....	78
Tabela 20. Exemplo 1 de um teste de concordância entre o humano e o modelo.....	84
Tabela 20. Exemplo 2 de um teste de concordância entre o humano e o modelo.....	85
Tabela 23. Resultados da taxa de concordância entre os 3 modelos em estudo.....	86

Índice de anexos

Anexo 1. Restante amostra dos 15 comentários feitos na plataforma Tripadvisor.com, a um restaurante na Praia da Rocha, em Portimão.....	105
---	-----

Lista de acrónimos e siglas

ABSA - Aspect-Based Sentiment Analysis
AML - Área Metropolitana de Lisboa
APIs - Application Programming Interfaces
DIG-IN - Nome de plataforma online
eWOM - Electronic Word of Mouth
GPT - Generative Pre-trained Transformer
LLMs - Large Language Models
PME - Pequena e Média Empresa
PLN - Processamento de Linguagem Natural
SLA - Service Level Agreement
UGC - User Generated Content
WOM - Word of Mouth

1. Introdução

1.1. Contextualização do tema

Atualmente, a existência de conteúdo online gerado por utilizadores (*user generated content* - UGC) em websites e plataformas de avaliação e reservas de restaurantes permite que os consumidores obtenham informações detalhadas sobre o serviço de um restaurante, com base nas experiências de clientes anteriores. Como indicam Asani et al. (2021, p.1) "A escolha de um restaurante, entre várias opções desconhecidas, é um dos principais usos dos sistemas de recomendação de restaurantes, especialmente por parte de turistas e viajantes".

Este conteúdo gerado pelos utilizadores funciona como uma forma de comunicação boca-a-boca (*word of mouth* - WOM) (Amaral et al., 2014), sendo relevante para os empresários da restauração que desejem acompanhar as percepções dos consumidores. Um empresário interessado em analisar a concorrência pode utilizar os perfis online dos seus concorrentes para estudar os comentários dos clientes, identificando os níveis de satisfação ou insatisfação.

Esta análise baseia-se frequentemente em processos de análise de sentimento, que consistem em identificar a polaridade de um comentário (positivo, neutro ou negativo) (Ahmed et al., 2023). Com base nessas informações, um investidor pode concentrar-se em aspetos que os clientes da concorrência consideram importantes, mas que possam estar a ser descurados.

No entanto, realizar uma análise detalhada de um elevado número de comentários exige um esforço cognitivo considerável e uma concentração intensa em tarefas repetitivas. Por exemplo, seria impraticável, em tempo útil, um empresário examinar manualmente 10.000 comentários dos seus concorrentes.

A evolução da tecnologia computacional trouxe metodologias que permitem a análise de sentimentos em larga escala, algo que seria difícil de se realizar manualmente. As tecnologias de processamento de linguagem natural e inteligência artificial generativa, facilitam a análise de grandes volumes de comentários em menor tempo (Jim et al., 2024). Estas abordagens requerem que a máquina processe os comentários enquadrando a qualidade do serviço como ela é

percepcionada pelos clientes, utilizando modelos desenvolvidos nas últimas décadas, nomeadamente.

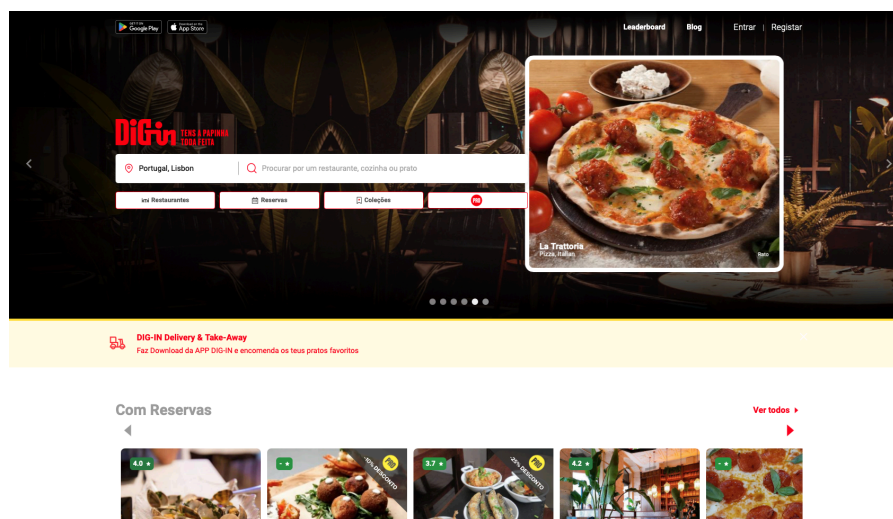
O modelo DINESERV (*Dining Service Quality*), por exemplo, é uma ferramenta que avalia a qualidade do serviço em restaurantes, considerando cinco dimensões: tangibilidade, confiabilidade, responsividade, segurança e empatia (Stevens et al., 1995). Tradicionalmente, esta avaliação era feita presencialmente através de questionários, antes da existência das plataformas de *feedback* online.

Com a crescente utilização de programas informáticos, torna-se necessário adaptar estes modelos para processos de análise mais completos e eficientes. Para a construção da ferramenta proposta nesta dissertação, foi fundamental a recolha de dados sobre restaurantes e respetivos comentários de utilizadores.

Neste contexto, foram obtidos 1.043.882 comentários de uma plataforma que opera em Portugal, denominada DIG-IN, que passou por um processo de rebranding, tendo anteriormente operado sob o nome Zomato Portugal. A DIG-IN é uma PME com uma década de atividade no mercado português, o que torna relevante a sua utilização nesta investigação.

Figura 1

Página online da plataforma DIG-IN, na versão para PC.



Assim, com os dados fornecidos pela DIG-IN, fez-se o pré-processamento dos dados utilizando a linguagem de programação Python, o que permitiu o

desenvolvimento de uma ferramenta capaz de avaliar detalhadamente a concorrência e a perceção do público em relação aos restaurantes.

1.2. Objetivos da investigação

É objetivo deste trabalho a criação de uma ferramenta que permita a um investidor identificar o potencial de implementação de um determinado tipo de restaurante, na Área Metropolitana de Lisboa.

Tendo em conta este objetivo geral, surgem como específicos os seguintes:

- a. Interpretar e preparar os dados recolhidos da plataforma Dig-IN (ex-Zomato), relativos aos restaurantes e respetivos comentários, utilizando a linguagem de programação Python;
- b. Desenvolver um modelo de análise de comentários, com base na literatura existente, e aplicar diferentes modelos de processamento de linguagem natural (PLN) para obter resultados comparáveis;
- c. Apresentar os resultados obtidos e implementá-los num protótipo de ferramenta que apoie a tomada de decisão no investimento em restaurantes.

1.3. Estrutura

Este estudo organiza-se em cinco capítulos: introdução, enquadramento teórico, metodologia, discussão dos resultados e conclusão.

No Capítulo 1, faz-se a contextualização do tema, apresentando-se o tópico da dissertação e a sua relevância para o setor da restauração;

O Capítulo 2 revê a literatura relevante, abordando a importância dos dados para a gestão e a tecnologia utilizada no estudo. Apresenta ainda a análise de sentimento e a ABSA (*Aspect-Based Sentiment Analysis*)¹, introduzindo o conceito de grandes modelos de linguagem natural (LLMs), como o ChatGPT e o Mistral;

¹ A *Aspect-Based Sentiment Analysis* (ABSA) identifica sentimentos sobre aspectos específicos de um texto, como diferentes características de um produto ou serviço.

O Capítulo 3 descreve a metodologia utilizada, com foco no pré-processamento de dados e nas técnicas de análise de sentimentos com recurso à linguagem Python;

No Capítulo 4, são discutidos os resultados da classificação dos sentimentos nos comentários, de acordo com os atributos definidos;

Por fim, o Capítulo 5 apresenta as conclusões, limitações e sugestões para investigações futuras.

2. Enquadramento Teórico

2.1. Relevância dos dados aplicados à gestão

Quando a análise de dados computacional não estava disponível, a implementação de negócios, como restaurantes, baseava-se principalmente na intuição e na percepção de mercado por parte do investidor. Contudo, a evolução tecnológica trouxe novas formas de suporte à decisão, através de dados concretos e da utilização de técnicas e programas informáticos que permitem obter melhores conclusões.

Entre as várias opções disponíveis, destaca-se a aprendizagem automática, cuja complementaridade com a intuição e o conhecimento humano tem demonstrado bons resultados em diversos setores económicos a nível global. A aprendizagem automática, ou *machine learning*, surge como o substituto do processamento manual de dados, superando as limitações humanas na análise de grandes volumes de informação.

Num artigo publicado na *Harvard Business Review* (HBR), Cassie Kozyrkov, ex-cientista chefe de decisão de dados da Google e atual membro do conselho de inovação do Federal Reserve Bank de Nova Iorque, sublinha a importância de as empresas investirem no desenvolvimento das competências dos seus analistas de dados, referindo a necessidade de estes aprimorarem o seu conhecimento na área. Embora a tecnologia atual permita um processamento mais eficiente de grandes volumes de dados, a sua seleção e interpretação ainda requerem a intervenção humana, nomeadamente na identificação das fontes de dados, na sua pertinência e nos seus objetivos, para assegurar a relevância para o negócio em questão (Kozyrkov, 2018). Além da capacidade de interpretação, a autora defende que os analistas de dados devem desenvolver competências na visualização e comunicação de resultados, de forma a apresentá-los de modo claro e acessível a todas as partes interessadas (Kozyrkov, 2018).

Figura 2.

O diagrama propõe a ciência de dados como resultado da capacidade humana em conjunto com a capacidade das máquinas.



Fonte: Elaboração própria.

Desta forma, constata-se que a ciência de dados se situa na interseção entre o conhecimento humano sobre um negócio e os seus objetivos, e a capacidade computacional das máquinas modernas. Esta relação configura uma simbiose entre máquinas e seres humanos, permitindo a obtenção de inteligência para apoiar a tomada de decisões.

Nos últimos anos, a introdução de tecnologias de inteligência artificial generativa, sustentadas em modelos desenvolvidos através da aprendizagem automática, como os modelos ChatGPT da empresa OpenAI, tem gerado uma transformação significativa na interpretação de dados. Eric Colson afirma que "para decisões rotineiras, que dependem apenas de dados estruturados, o ideal é delegar essas decisões à inteligência artificial, uma vez que está menos sujeita aos enviesamentos cognitivos humanos" (Colson, 2019, p.126).

Adicionalmente, Colson, (2019), sublinha a importância de se dar maior atenção à forma como os dados são obtidos, mais ainda do que à forma como são utilizados em conjunto com a inteligência artificial.

Assim, inicia-se este estudo com a consciência de que, para aplicar dados à gestão, é imprescindível (ainda) a compreensão por parte do analista, nomeadamente em relação ao que pretende estudar e ao que deve procurar ou extrair para esse estudo. Quando este processo de escolha é aliado à capacidade computacional das máquinas, torna-se possível obter dados relevantes para a tomada de decisão.

Esta abordagem é reforçada por Siegel, (2018), especialista em aprendizagem automática e inteligência artificial, que propõe um processo em cinco etapas para a implementação de um modelo preditivo eficaz na gestão (Siegel, 2018, p.36):

1. Definir o objetivo do modelo preditivo a ser desenvolvido;
2. Estabelecer o que se pretende prever, garantindo que tal previsão sirva um propósito concreto no contexto do negócio;
3. Extrair, processar e preparar os dados para serem utilizados pela máquina;
4. Aplicar os dados processados à aprendizagem automática;
5. Implementar o modelo preditivo na operação, em conformidade com os objetivos definidos.

Desta forma, reforça-se a ideia de que a ciência de dados e a sua aplicação na gestão dependem de uma colaboração estreita entre humanos e máquinas. O papel do ser humano continua a ser central, especialmente na obtenção dos dados e na utilização dos resultados para a gestão do negócio, em função dos objetivos e da cultura da organização.

Por ora, a ciência de dados continuará a desempenhar este papel até que se atinja um ponto de transformação. Schwab, fundador do Fórum Económico Mundial, sugere que esse ponto de viragem ocorrerá quando a primeira máquina de inteligência artificial integrar um conselho de administração (Schwab, 2017).

Atualmente, ainda que as máquinas não tomem decisões de forma autónoma, os resultados obtidos através do seu trabalho já exercem uma influência considerável na tomada de decisão. Assim, é fundamental aprofundar o conhecimento sobre o modo como as máquinas processam os dados, para que se possa utilizar estas técnicas e este novo paradigma de forma eficaz, beneficiando as empresas e os investidores.

2.2. Aprendizagem de máquina (*machine learning*), modelos de processamento de linguagem natural e modelos de linguagem (LLMs)

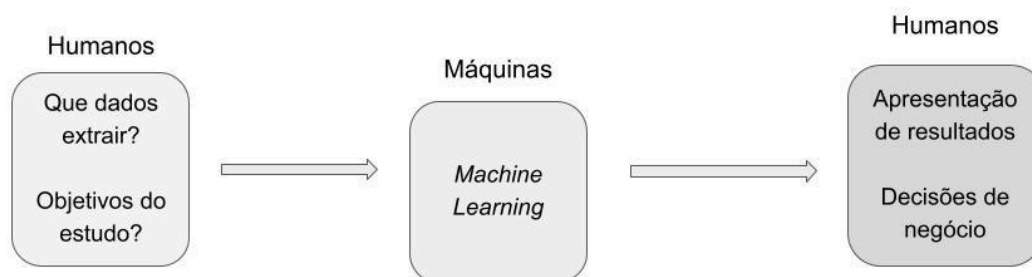
2.2.1. O que é a aprendizagem de máquina (*machine learning*)?

A Aprendizagem de Máquina é definida como um conjunto de técnicas computacionais que possibilitam a extração de conhecimento a partir de grandes volumes de dados que, se não forem devidamente organizados e processados, podem ser de pouca utilidade na tomada de decisões empresariais. Esta técnica situa-se "na interseção da estatística, inteligência artificial e ciência computacional, sendo também conhecida como análise preditiva ou aprendizagem estatística" (Muller & Guido, 2016, p.1).

Contudo, para que a máquina possa aprender com os dados e classificá-los de maneira coerente com os objetivos definidos, é essencial a intervenção humana tanto antes como após o processo de análise.

Figura 3.

Para a aprendizagem de máquina entregar valor à organização, a participação humana ainda se verifica no início e no final do processamento automático dos dados.



Fonte: Elaboração própria.

Verifica-se que esse processo é fruto do binómio humano-máquina que, em conjunto, consegue estabelecer objetivos, extrair dados relevantes e processá-los, retirando conclusões em seguida.

Este processo reflete uma cooperação entre humanos e máquinas, onde, em conjunto, estabelecem-se objetivos, extraem-se dados relevantes e processam-se os mesmos, chegando-se a conclusões úteis. Deste modo, é fundamental salientar

que a aprendizagem de máquina, por si só, não é suficiente para a tomada de decisões no âmbito dos negócios. É necessária a presença de profissionais qualificados em análise de dados e ciência de dados, capazes de identificar as informações a extrair e de interpretar adequadamente os resultados.

A aprendizagem de máquina integra-se, assim, num processo de organização holístico, sendo uma ferramenta destinada a alcançar os objetivos definidos pela administração da empresa. Além disso, esta tecnologia potencia o desenvolvimento da inteligência artificial (Santos, 2023) e funciona como o motor que impulsiona a aprendizagem e a obtenção de resultados que se aproximam dos alcançados por humanos, com a diferença de que a capacidade computacional não sofre de fadiga ou enviesamentos.

Deste modo, a aprendizagem de máquina representa a primeira etapa para a criação de inteligência artificial. Como se verá, esta tecnologia permitirá o processamento de texto e linguagem natural, além de possibilitar a geração de modelos de linguagem natural que, atualmente, são utilizados para interações conversacionais naturais com utilizadores humanos.

2.2.2. Processadores de Linguagem Natural (PLN)

Recentemente, no mundo digital, assistiu-se à introdução de diversas ferramentas de inteligência artificial, em particular das denominadas generativas.

Estes produtos resultam da evolução contínua da inteligência artificial, sobretudo no que respeita à capacidade de Processamento de Linguagem Natural (PLN).

O PLN teve as suas origens nas tentativas iniciais de tradução automática e, ao longo do tempo, evoluiu para incluir uma variedade de técnicas de aprendizagem automática e de processamento de texto. Contudo, ganhou maior relevância ao integrar técnicas de aprendizagem de máquina, o que potenciou a sua eficácia (Nadkarni et al., 2011).

No contexto deste trabalho, esta tecnologia demonstra a sua utilidade ao permitir a análise do sentimento subjacente aos comentários deixados pelos clientes. O PLN, alavancado pela capacidade das máquinas de aprenderem com os

dados, constitui a base para o desenvolvimento daquilo que atualmente se conhece como inteligência artificial generativa.

Em conjunto, o PLN e as técnicas de aprendizagem de máquina possibilitaram a criação de grandes modelos de linguagem que, além de possibilitarem interações conversacionais fluidas com humanos, possuem a capacidade de se auto aperfeiçoarem sem necessidade de intervenção humana (Huang et al., 2022).

2.2.3. Large Language Models (LLMs)

Os *Large Language Models* (LLMs) são sistemas de inteligência artificial concebidos para interagir diretamente com a linguagem humana. Estes modelos são baseados em técnicas de aprendizagem automática e redes neurais profundas (*Deep Learning*), sendo treinados com grandes volumes de dados textuais. Entre os mais conhecidos destaca-se o ChatGPT², um sistema que permite uma conversa fluida entre humanos e máquinas. Esta ferramenta tem a capacidade de interpretar o contexto da conversa, bem como identificar o uso de sarcasmo e ironia, demonstrando a sua versatilidade (Törnberg, 2023).

Destaca-se, assim, a capacidade desta tecnologia de substituir o papel de um analista humano, sendo essa uma das principais propostas de valor das empresas que desenvolvem tais ferramentas. Num artigo sobre os desafios e oportunidades da inteligência artificial na educação, o investigador e professor da Universidade Aberta, Arnaldo Santos, cita um relatório do Marketing AI Institute, que afirma que "a IA veio para ficar, e todos os líderes em educação e formação devem aprender a compreender e a extrair vantagens desta tecnologia", (Antonuccio, 2023, como citado em Santos, 2023, p.1).

O desenvolvimento da inteligência artificial, em geral, visa criar uma solução que simula as capacidades e competências humanas, através de programas de computador. O objetivo é que, por meio desta simulação, os computadores consigam replicar o funcionamento do cérebro humano, simulando as suas competências e capacidades (Oliveira, 2019).


² Desenvolvido pela empresa OpenAI, foi lançado em novembro de 2022. É um modelo de linguagem baseado na arquitetura GPT (*Generative Pre-trained Transformer*).

Dado que a inteligência artificial é uma tecnologia perene, é crucial compreender o que esta pode realizar e como pode ser utilizada. Por exemplo, o ChatGPT, ferramenta de inteligência artificial generativa da OpenAI, é um modelo de linguagem natural que permite gerar textos, programar em várias linguagens, analisar dados, entre outras capacidades. Como um *Generative Pre-Trained Transformer* (GPT), este modelo tem a habilidade de executar tarefas criativas, anteriormente exclusivas da capacidade humana.

A sua disseminação já é notória em vários setores económicos e indústrias. Num relatório de 1 de agosto de 2023, intitulado *The State of AI in 2023: Generative AI's Breakout Year*, a consultora McKinsey & Company refere que "a Inteligência Artificial Generativa já capturou o interesse da comunidade empresarial (...), sendo utilizada tanto no trabalho como fora dele" (Chui et al., 2023). O relatório acrescenta que "dois terços dos respondentes esperam que as suas organizações aumentem os investimentos em IA nos próximos três anos".

Figura 4.

Utilização, por indústria da inteligência artificial generativa, resultante de um questionário aplicado a 1.684 funcionários dos diversos níveis dentro das empresas.



As figuras podem não somar 100%, devido ao arredondamento. Na Ásia-Pacífico, n = 164; na Europa, n = 515; na América do Norte, n = 392; na Grande China (incluindo Hong Kong e Taiwan), n = 337; e em mercados em desenvolvimento (incluindo Índia, América Latina e Médio Oriente e Norte de África), n = 276. Para indústrias avançadas (inclui automóveis e montagem, aeroespacial e defesa, e eletrónica avançada), n = 96; para serviços empresariais, jurídicos e profissionais, n = 215; para bens de consumo e retalho, n = 128; para energia e materiais, n = 96; para serviços financeiros, n = 248; para cuidados de saúde, farmacêutica e produtos médicos, n = 130; e para tecnologia, media e telecomunicações, n = 244. Para executivos seniores, n = 541; para gestores seniores, n = 437; e para gestores intermédios, n = 339. Para respondentes nascidos em 1964 ou antes, n = 143; para respondentes nascidos entre 1965 e 1980, n = 268; e para respondentes nascidos entre 1981 e 1996, n = 556. Não estavam disponíveis dados de idade para todos os respondentes. Para respondentes que se identificam como homens, n = 1.025; para respondentes que se identificam como mulheres, n = 658. A amostra também incluiu respondentes que se identificaram como "não binários" ou "outro", mas não um número suficientemente grande para ser estatisticamente significativo.

(McKinsey & Company, 2023)

Dado o seu carácter imparável, refletido nas elevadas taxas de adoção a nível global, a tecnologia de inteligência artificial será aqui utilizada com o propósito de auxiliar na investigação e análise dos dados a processar, conforme já mencionado. No final deste estudo, será avaliada a precisão destes programas em tarefas que, até então, estavam reservadas aos analistas humanos.


No entanto, importa destacar que o uso desta tecnologia ainda requer supervisão humana. Embora estes programas de computador tenham demonstrado uma elevada eficiência na execução das tarefas previamente discutidas, persistem preocupações relacionadas com a sua capacidade de discernimento em questões éticas e preconceitos culturais, bem como sobre a qualidade dos resultados finais, que podem apresentar enviesamentos (Rodrigues e Rodrigues, 2023).

Assim, é fundamental sublinhar que as ferramentas de inteligência artificial devem ser utilizadas em conjunto com a supervisão humana, e não de forma autónoma. Embora a sua implementação permita acelerar e aprimorar o trabalho realizado por humanos, é essencial que os resultados produzidos pelos programas de inteligência artificial generativa sejam cuidadosamente revistos, sob o risco de se obterem resultados diferentes do esperado inicialmente.

2.3. Linguagem de programação informática para o pré-processamento de dados.

À data da elaboração desta dissertação, a linguagem de programação Python é amplamente reconhecida como a principal ferramenta para o pré-processamento de dados no campo da aprendizagem de máquina. De acordo com a *Statista*, uma plataforma online especializada na recolha e visualização de dados, Python é reportada como uma das linguagens de programação mais utilizadas globalmente pelos programadores.


Figura 5
Linguagens de programação mais utilizadas por programadores em 2023.



(Statista, 2024)

De acordo com o *ranking* apresentado na figura 5, a linguagem Python ocupa o terceiro lugar entre as diversas linguagens de programação disponíveis para os programadores atuais, sendo utilizada por 49,3% dos inquiridos no estudo que deu origem a estes dados. Este facto reforça a sua popularidade e relevância no contexto do desenvolvimento e processamento de dados, especialmente no domínio da aprendizagem de máquina.

Figura 6.
Razões para a utilização da linguagem Python em 2022.



(Statista, 2024)

Dessa ampla utilização por parte da comunidade internacional de programadores, 54,0% dos inquiridos utilizam Python para análise de dados, 38,0% para aplicações de *machine learning* (aprendizagem automática) e 32,0% para técnicas de *web parsing/scraping*³, utilizadas na extração de dados online, como se pode constatar na figura 6.

Assim, é natural que Python desempenhe um papel central no desenvolvimento desta dissertação de mestrado. Tendo sido a linguagem escolhida para o tratamento dos dados, torna-se necessário enquadrá-la e apresentá-la com maior detalhe, de forma a clarificar o seu papel e as suas capacidades no contexto do trabalho a ser realizado.

2.4. Contextualização dos estudos que visam melhorar a decisão de investimento na restauração

2.4.1. Origem dos dados dos estudos (*datasets*)

Consultando a literatura mais recente sobre a temática, verifica-se que diversos estudos, incluindo artigos científicos e dissertações, se dedicam à análise da escolha ideal para a localização e gestão de restaurantes. Os dados utilizados nesses estudos (*datasets*) provêm, em grande parte, de plataformas digitais de restaurantes, como a Yelp.com, Koubi.com, Zomato e Facebook.com. Estas plataformas são amplamente utilizadas tanto por clientes à procura de restaurantes, como por restaurantes que nelas listam os seus serviços com o intuito de aumentar o seu alcance e atrair mais clientes.

Para ilustrar a magnitude deste fenómeno, tome-se o exemplo do Facebook.com, que, em 2023, registou mais de 3 mil milhões de utilizadores mensais ativos, conhecidos como *Monthly Active Users*.

Por exemplo, no seu estudo sobre a escolha geográfica ideal para a localização de restaurantes, os autores identificaram 75 características relevantes a partir de uma análise de 1.515 restaurantes na cidade de Nova Iorque, nos Estados Unidos. Estes dados foram extraídos da plataforma Yelp.com, utilizando APIs⁴ que

³ Web parsing/scraping é o processo de extrair dados de websites de forma automatizada, sem necessidade de interação manual.

⁴ Uma API (*Application Programming Interface*) é um conjunto de regras que permite a comunicação entre diferentes *softwares*, facilitando a troca de dados e a execução de funcionalidades de forma integrada.

facilitam a comunicação e transferência de dados entre softwares (Shihab & Oishi, 2018).

Outro estudo, publicado no *International Journal of Hospitality Management*, utilizou também a Yelp.com para recolher cerca de 250.000 avaliações online de restaurantes, feitas entre 2005 e 2017. Esta pesquisa focou-se no impacto das avaliações sobre estratégias de preços, considerando as características espaciais dos restaurantes e o perfil do mercado-alvo (Kim et al., 2022).

Na China, os investigadores extraíram dados de 794 restaurantes a partir da plataforma Koubei.com, compreendendo revisões registadas entre outubro de 2006 e abril de 2010. Cada revisão inclui avaliações dos clientes em várias dimensões, como comida, qualidade do serviço, ambiente, preço e valor, complementadas por comentários (Wang & Yan, 2017).

A plataforma Facebook.com foi igualmente utilizada para a extração de dados de negócios do setor alimentar em Singapura. Os investigadores recolheram dados de 20.877 perfis de Facebook de restaurantes, distribuídos por 357 categorias relacionadas com comida (Lin et al., 2016).

Por fim, em Bangalore, Índia, um autor usou a plataforma Zomato para propor um sistema de recomendação de restaurantes, baseando-se em dados de 12.000 estabelecimentos alimentares na cidade, que é reconhecida como a "capital" das tecnologias de informação do país (Sushmitha, 2020).

Estes exemplos demonstram que as plataformas digitais não só agregam e acumulam grandes volumes de dados sobre determinados setores ou áreas de negócio, como também permitem a extração desses dados para fins académicos e de apoio à decisão empresarial. A relevância da informação disponível nestas plataformas é, assim, evidente para estudos em múltiplas áreas, desde a análise de mercado até à gestão de preços e escolha de localização.

Contudo, a disponibilidade dos dados por si só não é suficiente para quem não domina os processos estatísticos e tecnológicos necessários ao seu processamento e interpretação. Portanto, a seguir, serão analisadas as técnicas e a abrangência geográfica dos estudos, de modo a destacar a obtenção de informação útil para a tomada de decisões de negócio.

2.4.2. Abrangência geográfica

No que diz respeito à abrangência geográfica da literatura revista, verifica-se que os estudos analisam diferentes áreas do globo, com critérios específicos para cada caso.

Num estudo sobre a seleção da localização ideal para um restaurante, os investigadores extraíram 1.094.717 avaliações de clientes a partir da plataforma Yelp.com, relativas a 5.220 restaurantes localizados na cidade de Nova Iorque (Wang et al., 2016). Neste mesmo estudo, foi também utilizada a plataforma Foursquare.com, com foco na mesma área geográfica.

A literatura no âmbito da utilização de dados e processos de aprendizagem automática demonstra que foram extraídos dados de várias cidades, como Dhaka, no Bangladeche (Ahmed et al., 2021), Bangalore, na Índia (Sushmitha, 2020), Singapura e nos distritos de Harbin, na China (Wang & Yan, 2017).

Em Portugal, um grupo de investigadores da Universidade da Madeira abordou a adequação de modelos de processamento de linguagem natural para a análise de sentimentos em comentários em língua portuguesa (Branco et al., 2024).

Desta forma, constata-se que, a nível global, incluindo Portugal, investigadores têm estudado a aplicação de diferentes técnicas para melhorar a análise do desempenho de restaurantes e da concorrência, com o objetivo de facilitar decisões de negócios e investimentos em novos estabelecimentos.

Seguidamente, serão discutidas as técnicas utilizadas para a extração, pré-processamento e processamento de dados nestas investigações, de modo a proporcionar uma melhor compreensão do trabalho desenvolvido nesta área.

2.4.3. Técnicas utilizadas

Tendo em consideração que o processo que conduz aos resultados gerados pela aprendizagem automática e pelo processamento de linguagem natural começa com a extração de dados, geralmente a partir de contextos online, a sua preparação para a introdução como *inputs* no sistema é estatisticamente relevante para a obtenção de resultados mais precisos.

De acordo com a literatura analisada, os conjuntos de dados obtidos foram submetidos a um pré-processamento, com o objetivo de remover entradas incompletas ou ausentes, de modo a melhorar a qualidade e consistência do conjunto de dados (*dataset*).

Com o mesmo objetivo, investigadores optaram pela normalização dos dados. Este processo visa padronizar a escala dos diferentes atributos (*features*) selecionados para escalas semelhantes, de forma a reduzir distorções ou enviesamentos nos resultados dos algoritmos aplicados (Ahmed et al., 2021).

Neste contexto, os investigadores indicam que, uma vez que os sistemas de aprendizagem automática trabalham exclusivamente com números, foi necessária a transformação de dados não numéricos em numéricos, recorrendo ao pacote Sklearn⁵ da linguagem Python.

O resultado final consistiu na adaptação dos atributos selecionados para uma escala comum, delimitada por valores mínimos e máximos partilhados.

Considerando que a literatura revista utiliza diferentes algoritmos, cujos resultados são avaliados com o objetivo de maximizar a precisão, apresenta-se a tabela 1, que sintetiza os algoritmos utilizados pelos investigadores em alguns dos artigos analisados, relativamente aos diferentes objetos de estudo.

Como se pode observar, o conjunto de opções disponíveis para o processamento de dados, tanto de restaurantes como dos respetivos comentários, recorre a diferentes modelos conforme cada caso específico.

Em particular, no estudo conduzido pelos investigadores da Universidade da Madeira, foi utilizado um modelo de aprendizagem automática não supervisionado, o BERT, com o intuito de avaliar a sua adequação à análise de comentários em português (Branco et al., 2024). Esta investigação justifica-se pelo facto de a língua portuguesa apresentar uma crescente quantidade de conteúdo disponível no contexto online.

Os modelos de aprendizagem automática, os processadores de linguagem natural e os modelos de linguagem natural revelam-se mais eficazes à medida que aumentam a disponibilidade e a qualidade dos dados que processam.


⁵ O Scikit-learn (sklearn) é uma biblioteca de código aberto em Python que oferece ferramentas simples e eficientes para análise de dados e aprendizagem de máquina, incluindo classificação, regressão e clustering.

No ambiente online, uma grande parte do conteúdo encontra-se em inglês, o que leva à inferência de que os resultados do processamento de dados nesta língua tendem a ser mais precisos.

Tabela 1.
Resumo de técnicas utilizadas pelos investigadores.

Exemplo	Artigo	Técnicas utilizadas
a)	Anmoldeep, <i>et al.</i> , 2020. Geographical location recommendation system for restaurants in Bengaluru.	Support Vector Machine (SVM); Decision Tree; Random Forest.
b)	Shihab & Oishi, 2018. A machine learning approach to suggest ideal geographical location for new restaurant establishment.	Support Vector Machine (SVM); Decision Tree; Logistic Regression; Decision Tree with Presort;
c)	Lin, J., <i>et al.</i> , 2016. Where is the goldmine: Finding promising business locations through Facebook's location-based services.	Deep Neural Networks (DNN); Support Vector Regression (SVR) - Linear; Support Vector Regression (SVR) - RBF; Gradient Boosting Machines (GBM).
d)	Wang, F., <i>et al.</i> , 2016. Where to Place Your Next Restaurant: Optimal Restaurant Location Using Yelp.	Ridge regression; Support vector regression (SVR); Gradient Boosted Regression Trees (GBRT).
e)	Priya, J. (2020). Predicting restaurant rating using machine learning and comparison of regression models.	Linear Regression; Random forest regression algorithm; Ridge regression; Lasso Regression; KNN Regression; Support Vector Regression; Elastic Net Regression; Bayesian Regression.
f)	Branco <i>et al.</i> (2024). Sentiment Analysis in Portuguese Restaurant Reviews: Application of Transformer Models in Edge Computing	BERT - Bidirectional Encoder Representations from Transformers; RoBERTa.

Figura 7.
Línguas mais utilizadas para conteúdo online em 2024.



(Statista, 2024)

Por esta razão, os investigadores da Universidade da Madeira procuraram avaliar a precisão dos modelos de linguagem natural utilizando a língua portuguesa. Os modelos de aprendizagem automática e processamento de linguagem natural dependem de grandes volumes de dados para atingir eficácia. A língua, nesse sentido, torna-se um elemento crucial, pois quanto maior for a quantidade de dados disponíveis para o treino do modelo, melhor será o desempenho final.

Neste trabalho, será realizada uma análise de sentimentos dos comentários recebidos na plataforma DIG-IN, como forma de agregar valor ao sistema de recomendação e decisão proposto.

Na literatura consultada, não foi identificada a utilização de LLMs como técnica de análise nos estudos revistos. Tal pode dever-se ao facto de esses modelos terem sido disponibilizados ao público apenas recentemente. Deste modo, esta será a técnica escolhida para o processamento de comentários e respectiva análise de sentimentos, visto que existe espaço na discussão para a sua introdução (Törnberg, 2023).

2.5. Análise de sentimentos

Em consonância com o aumento da popularidade das redes sociais, é comum que restaurantes mantenham perfis em plataformas como TripAdvisor, Google, Zomato (atualmente DIG-IN), entre outras.

Estes perfis são criados com o objetivo de "digitalizar" o cartão de visita do restaurante, criando um novo canal de aquisição de clientes e permitindo a publicação pública de classificações e comentários que os clientes fazem sobre o serviço. Tanto as classificações como os comentários servem como ferramentas de posicionamento do restaurante, fornecendo informações valiosas para outros clientes que procuram detalhes sobre um estabelecimento específico.

Este fenómeno de partilha de experiências dos clientes é conhecido como "*electronic word-of-mouth*" (eWOM), ou boca-a-boca eletrónico (Camilo, 2021). Restaurantes que valorizam as opiniões dos seus clientes podem utilizar essas avaliações para melhorar o seu serviço e reforçar a sua posição competitiva em relação aos concorrentes (Kim et al., 2022).


Geralmente, as contribuições de um utilizador dividem-se em dois aspetos: o primeiro refere-se à classificação objetiva da experiência, normalmente feita numa escala de Likert de 1 a 5, onde 1 corresponde a "completamente insatisfeito" e 5 a "completamente satisfeito" (Joshi et al., 2015). O segundo aspecto consiste num comentário escrito em que o cliente descreve a sua experiência relativamente ao serviço e à refeição, conferindo à avaliação uma dimensão subjetiva.

Na primeira parte da classificação, o valor é quantificável e pode ser calculado numa média, sendo de fácil compreensão tanto para a equipa gestora do restaurante como para outros clientes que procuram informações sobre o estabelecimento. Na segunda parte, os comentários escritos pelos consumidores podem incluir expressões que revelam sentimentos, figuras de estilo, sarcasmo ou ironia, o que exige um processo de interpretação mais complexo em comparação com a análise da classificação numérica. Por exemplo, ao analisar as classificações de clientes no TripAdvisor sobre um restaurante, localizado na Praia da Rocha, em Portimão, observa-se que os comentários escritos contêm tanto menções positivas como negativas a diferentes aspetos do serviço.

Figura 8.

Amostra de 4 comentários recolhidos da plataforma TripAdvisor, sobre um restaurante na Praia da Rocha, em Portimão, em 15 de Janeiro de 2024.

Comentário a)


 Utilizador
Peterborough • 6 contributos 👍 0 ...

●●●○○

Decent
09/2023 • Friends

Food was okay. Lovely location on the beach front. Service a little slow. 40 euros for 2 salads and 2 drinks. Charged for bread & butter, which was fine as we ate it, but also charged for sardine pate that we didn't touch (came in a packet so didn't go to waste).

Comentário b)


 Utilizador
1 contributo 👍 1 ...

●●●○○

Great if you just want drinks.
10/2022 • Couples

Drinks were great! Service mediocre. Hake and chip were delish. Hamburger on the plate was edible. Was given the wrong time for the start of lunch so ended up waiting an extra 1/2 hour.

Comentário c)

 Utilizador
1 contributo 👍 0 ...

●●●○○

Almoço
09/2022 • Family

A comida muito boa, tem uma vista espetacular sobre o mar, muito limpo, mas o serviço extremamente lento, não se pode ter pressa.

Comentário d)



Utilizador

Melgaço • 10 contributos



Almoço na praia

07/2020 • Family

Comemos uma cataplana de tamboril e camarão. A comida estava deliciosa. Foi pena termos de esperar tanto tempo com as crianças. Fui encomendar, propus pagar antecipadamente para garantir a encomenda e não esperar na mesa com as crianças. Disseram que não era necessário, mas na verdade esperamos cerca de meia hora pela comida...

À data da recolha dos dados, o restaurante ocupava a 21^a posição entre 79 concorrentes da área, com uma classificação de 4 em 5 estrelas, baseada num total de 456 avaliações. De facto, uma classificação de 4 estrelas pode ser interpretada como "Bom", dado que corresponde a uma taxa de satisfação geral de 80,0%.

No entanto, ao examinar alguns dos comentários feitos pelos visitantes com maior detalhe, identificam-se razões que impedem uma classificação superior, como, por exemplo, o tempo de espera, conforme demonstrado nas amostras da Figura 8.

É importante considerar que este restaurante possui múltiplos perfis online em diferentes plataformas. Uma análise detalhada de cada avaliação seria um processo bastante moroso e difícil de realizar manualmente. Tomando como exemplo os perfis do restaurante nas plataformas TripAdvisor, Google (*Business Profile*) e Facebook, verifica-se que, à data da análise, o restaurante apresenta classificações gerais consistentes: 4 estrelas no TripAdvisor e Google, e 4,4 estrelas no Facebook, num total máximo de 5 estrelas, com um total acumulado de 1.285 comentários.

Dada a quantidade de comentários, torna-se evidente que a análise individual de cada um é impraticável, especialmente num contexto de restauração, onde a equipa está essencialmente focada nas operações diárias. No entanto, a tecnologia, particularmente através da aprendizagem de máquina (*machine learning*) e do processamento de linguagem natural, permite processar rapidamente o texto de todos os comentários, classificando de forma mais eficiente e consistente o sentimento expressado.

Segundo Hua et al. (2023, p.2), numa análise sistemática dos processos de análise de sentimento, "A Análise de Sentimentos é uma tarefa central do processamento de linguagem natural que visa identificar a orientação afetiva ou

sentimental de um dado corpo de texto.”. Esta técnica permite identificar e classificar os sentimentos expressos no texto, determinando se são positivos, neutros ou negativos.

Por outras palavras, esta classificação permite analisar todos os comentários e compreender os sentimentos subjacentes, extraindo conclusões que antes seriam difíceis de obter. No entanto, a análise de sentimento, em termos gerais, limita-se a classificar o comentário como um todo, sendo positivo, neutro ou negativo.

Ao examinar-se os comentários com mais detalhe, observa-se que muitos contêm apontamentos positivos e negativos dentro do mesmo texto. No exemplo apresentado na Figura 8, o comentário a) menciona a comida, a localização e o serviço. Cada um desses aspetos é classificado de forma diferente: a comida é considerada "okay", a localização é descrita como "lovely", e o serviço é apontado como sendo "um pouco lento". Neste caso, a mera classificação do comentário como positivo, neutro ou negativo não é suficiente para uma análise mais profunda, dado o carácter multifacetado dos sentimentos expressos.

Portanto, torna-se necessário aplicar metodologias mais avançadas que permitam identificar, com maior precisão, os sentimentos específicos expressos em diferentes dimensões de um mesmo comentário.

2.5.1. O método ABSA (*Aspect-Based Sentiment Analysis*)

O método ABSA (*Aspect-Based Sentiment Analysis*) é uma técnica que permite direcionar a análise de sentimentos para diferentes aspetos específicos, em vez de atribuir uma classificação geral a todo o comentário (Ahmed et al., 2023). Este método oferece a capacidade de capturar a granularidade presente nas frases, possibilitando uma análise mais detalhada do que uma simples categorização global (Hua et al., 2024).

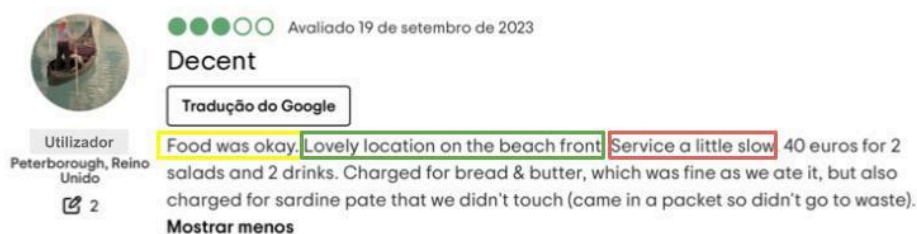
Através desta técnica, torna-se possível identificar os diferentes aspetos mencionados num comentário e classificá-los individualmente, focando-se na polaridade do sentimento associado a cada um desses aspetos. Em essência, o ABSA permite que, ao analisar-se um grande volume de dados, se obtenha uma informação mais segmentada e detalhada, uma vez que os comentários são

decompostos em aspetos específicos, seguidos de uma análise isolada da polaridade (positiva, neutra ou negativa) refletida em cada um desses aspetos.

Esta abordagem não só facilita a compreensão de como diferentes elementos do serviço ou produto são percebidos pelos consumidores, mas também possibilita uma visão mais clara e precisa sobre o que precisa de ser melhorado ou mantido, ao contrário das análises mais generalistas que podem omitir nuances importantes.

Figura 9.

No comentário a), a amarelo destaca-se um aspecto neutro, a verde um positivo e a vermelho um negativo.




Retomando o comentário identificado na Figura 9, verifica-se que os sentimentos expressos pelo cliente, ao descrever a sua experiência, são variados e não seguem uma linha única de polaridade.

Inicialmente, o cliente faz referência a três aspetos distintos: comida, localização e rapidez do serviço. Ao mencionar cada um desses aspetos, a linguagem utilizada atribui polaridades de sentimento diferentes a cada um. Por exemplo, a comida é descrita como "okay", indicando um sentimento neutro, a localização é caracterizada como "lovely", o que sugere um sentimento positivo, enquanto o serviço é descrito como "um pouco lento", refletindo um sentimento negativo.

Este exemplo ilustra a complexidade de classificar a experiência do cliente de forma linear ou através de uma simples categorização geral, sublinhando a necessidade de uma análise mais detalhada, como a oferecida pelo método ABSA, que permite identificar e classificar a polaridade de cada aspeto individualmente.

Figura 10.

Amostra do comentário a). Na primeira linha do comentário, destacam-se três aspectos diferentes, cada um com uma polaridade de sentimento.



No exemplo do comentário analisado, observa-se que, na primeira linha, o cliente faz referência à comida de forma neutra, à localização de forma positiva e ao tempo de serviço de forma negativa. Em suma, embora a classificação geral tenha sido de 3 em 5 estrelas/pontos, uma análise mais detalhada revela que, dentro da mesma avaliação, coexistem elementos positivos, neutros e negativos. Esta abordagem permite também identificar quais os aspetos em questão e a polaridade de sentimento associada a cada um.

É neste contexto que o método ABSA se destaca, ao permitir uma análise mais fina e detalhada dos sentimentos relacionados com cada aspeto específico. Como vimos neste exemplo, o cliente expressou diferentes opiniões sobre a comida, a localização e o serviço, fornecendo um feedback distinto para cada um (Hua et al., 2023).

Em linha com esta metodologia, e conforme referido anteriormente, serão utilizados modelos LLMs para realizar esta análise, justificada pela sua recente introdução no mercado e pela sua aplicabilidade (Simmering e Huoviala, 2023).

Por conseguinte, dado que estes modelos, ao contrário das técnicas tradicionais, interagem com os seres humanos através da interpretação textual, torna-se necessário definir um referencial que estabeleça as dimensões e os critérios a serem identificados e classificados nos comentários processados. Este referencial garantirá que os modelos LLMs possam reconhecer e classificar corretamente os diferentes aspetos e as polaridades dos sentimentos neles contidos.

2.6. Definição de um referencial para avaliar a experiência num restaurante

Numa plataforma digital de restaurantes, é comum que os clientes, após efetuarem uma reserva e consumirem os produtos de um restaurante, deixem críticas e comentários sobre a sua perceção geral do serviço diretamente na plataforma. Esses comentários desempenham um papel importante na formação da reputação do estabelecimento e influenciam as decisões de outros potenciais clientes.

Figura 11.

Exemplo sobre os critérios de avaliação específicos da plataforma TripAdvisor.com, sobre um restaurante na Praia da Rocha, em Portimão.



Como ilustrado no exemplo da figura 11, sempre que um cliente classifica um restaurante numa plataforma, a avaliação é frequentemente dividida em diferentes categorias ou atributos. Cada uma dessas categorias pode incluir aspetos como comida, serviço, valor e ambiente. A classificação final atribuída a um restaurante corresponde geralmente à média das pontuações dadas a cada um desses atributos.

Quando a média de uma classificação é inferior a 5 pontos, isso indica que algum aspeto da experiência não atendeu às expectativas do cliente, sugerindo que este não ficou completamente satisfeito. A satisfação do consumidor refere-se a "um

julgamento de que uma característica de um produto ou serviço, ou o próprio produto ou serviço, proporcionou (ou está a proporcionar) um nível agradável de satisfação no consumo, incluindo os níveis de satisfação insuficiente ou excessiva." (Oliver, 1997, como citado em Uslu e Eren, 2020, p.65).

Deste modo, a atribuição de uma pontuação individual a cada atributo facilita a identificação, por parte do gestor, de áreas específicas de insatisfação que podem estar a influenciar negativamente a perceção geral da experiência no restaurante. Compreender o conceito de satisfação do consumidor e os fatores que a influenciam torna-se essencial para uma análise mais aprofundada da experiência. Ao identificar aspetos ou sub-aspetos específicos relacionados com a satisfação, é possível realizar uma avaliação mais detalhada do grau de satisfação do cliente, permitindo uma intervenção direcionada e eficaz.

2.6.1. Medindo a satisfação do consumidor na restauração.

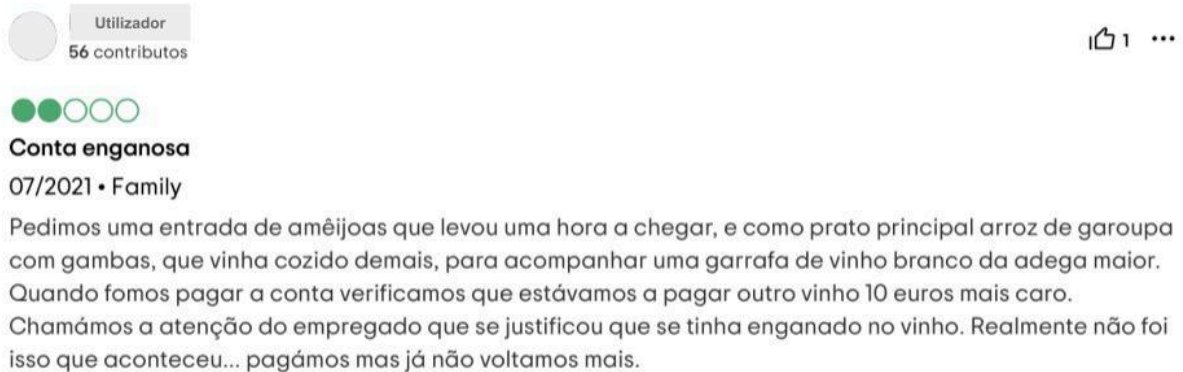
Embora pareça uma tarefa simples, a medição da satisfação do consumidor revela-se mais complexa do que aparenta. Na comunidade científica, há um debate extenso sobre quais os critérios mais adequados para determinar se um cliente está ou não satisfeito.

Os textos dos comentários de clientes variam significativamente, o que torna difícil estabelecer uma padronização. Embora muitos comentários mencionem aspetos frequentemente discutidos, como o serviço ou o sabor da comida, também existem aspetos menos referidos, como a limpeza do espaço ou o ambiente.

Por exemplo, no comentário da figura 12, o cliente faz referência à qualidade da comida, nomeadamente à sua confecção. No entanto, o foco principal do comentário recai sobre um erro na conta, que aparentemente gerou desconfiança no cliente. Este exemplo ilustra como a satisfação do cliente pode ser influenciada por uma variedade de fatores, nem sempre diretamente relacionados com os aspetos mais comuns da experiência gastronómica. Assim, a medição da satisfação precisa de considerar tanto os aspetos frequentes como os mais pontuais, de forma a obter uma visão completa da experiência do cliente.

Figura 12.

Exemplo de comentário de cliente na TripAdvisor.com, sobre um restaurante na Praia da Rocha, em Portimão.



Utilizador
56 contributos

1 1 ...

●●○○○○

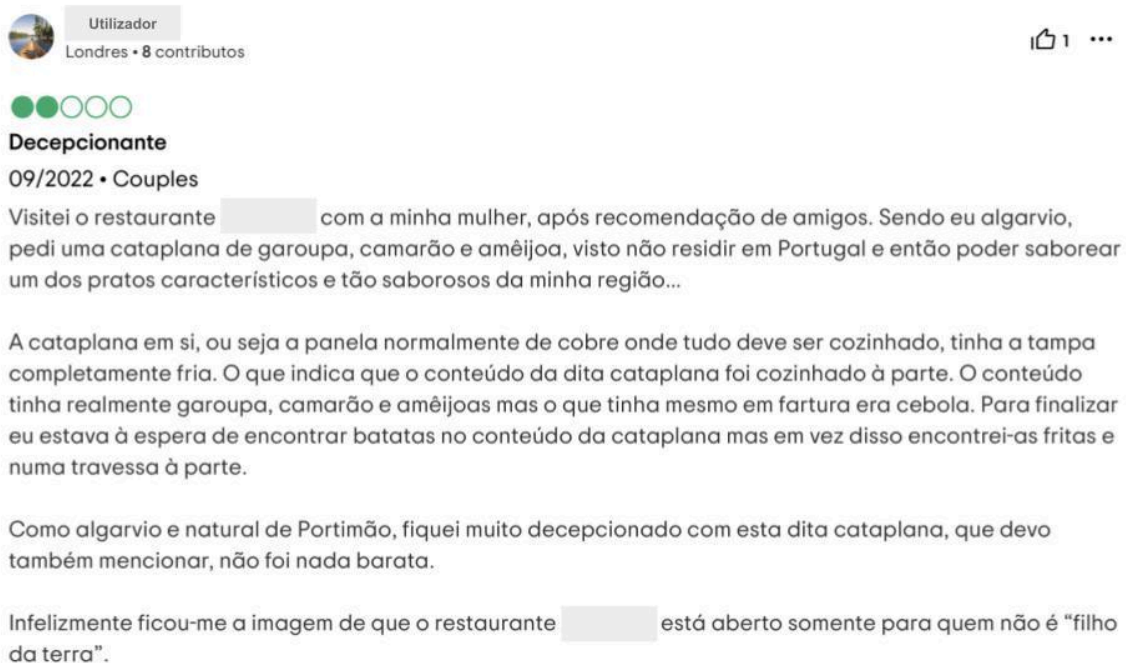
Conta enganosa
07/2021 • Family

Pedimos uma entrada de amêijoas que levou uma hora a chegar, e como prato principal arroz de garoupa com gambas, que vinha cozido demais, para acompanhar uma garrafa de vinho branco da adega maior. Quando fomos pagar a conta verificamos que estávamos a pagar outro vinho 10 euros mais caro. Chamámos a atenção do empregado que se justificou que se tinha enganado no vinho. Realmente não foi isso que aconteceu... pagámos mas já não voltamos mais.

No caso da figura 13, o comentário concentra-se inteiramente na crítica à qualidade da comida, com particular enfoque num prato específico. Não há qualquer referência a outros aspetos da experiência, como o serviço, a limpeza ou o ambiente.

Figura 13.

Exemplo de comentário de cliente na TripAdvisor.com, sobre um restaurante na Praia da Rocha, em Portimão.



Utilizador
Londres • 8 contributos

1 1 ...

●●○○○○

Decepcionante
09/2022 • Couples

Visitei o restaurante [redacted] com a minha mulher, após recomendação de amigos. Sendo eu algarvio, pedi uma cataplana de garoupa, camarão e amêijoas, visto não residir em Portugal e então poder saborear um dos pratos característicos e tão saborosos da minha região...

A cataplana em si, ou seja a panela normalmente de cobre onde tudo deve ser cozinhado, tinha a tampa completamente fria. O que indica que o conteúdo da dita cataplana foi cozinhado à parte. O conteúdo tinha realmente garoupa, camarão e amêijoas mas o que tinha mesmo em fartura era cebola. Para finalizar eu estava à espera de encontrar batatas no conteúdo da cataplana mas em vez disso encontrei-as fritas e numa travessa à parte.

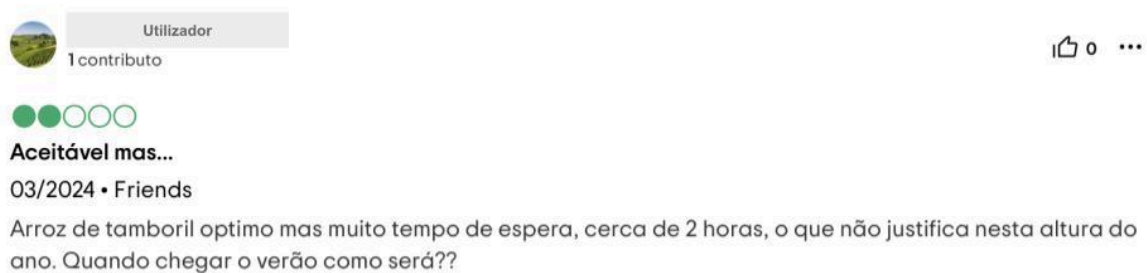
Como algarvio e natural de Portimão, fiquei muito decepcionado com esta dita cataplana, que devo também mencionar, não foi nada barata.

Infelizmente ficou-me a imagem de que o restaurante [redacted] está aberto somente para quem não é "filho da terra".

No exemplo da figura 14, o comentário também faz referência à qualidade da comida, que, como se tem observado, é um elemento frequentemente mencionado nos comentários. No entanto, o foco principal deste comentário recai sobre o tempo de espera, destacando-o como o fator que mais influenciou a percepção da experiência do cliente.

Figura 14.

Exemplo de comentário de cliente na TripAdvisor.com, sobre um restaurante na Praia da Rocha, em Portimão.



Embora cada comentário seja único, parece haver dimensões de análise que são recorrentes de comentário para comentário, como a qualidade da comida, o serviço ou o tempo de espera. No entanto, também existem comentários que abordam aspetos menos frequentes, como a limpeza ou a atmosfera. Por esta razão, torna-se relevante desenvolver e aplicar um modelo que, de forma abrangente, permita avaliar as críticas, considerando a diversidade de aspetos que podem ser alvo de análise.

Dada essa complexidade, surge a necessidade de estabilizar um método consistente para medir a satisfação do consumidor, de modo a garantir que todos os aspetos, frequentes ou não, sejam devidamente contemplados. Em resposta a esta necessidade, realiza-se uma análise dos modelos mais citados e consensualmente aceites na comunidade científica, com o objetivo de identificar aqueles que melhor captam a diversidade de fatores que influenciam a satisfação do cliente.

2.6.2. Analisando a evolução de modelos conceituais para aferir a satisfação do cliente.

O debate inicial sobre os critérios e dimensões relevantes para medir a satisfação do cliente levou à criação do modelo GAP, em 1985, sendo um modelo que identifica lacunas entre as expectativas dos clientes e o serviço prestado. O modelo identifica cinco lacunas principais que podem ocorrer em diferentes etapas da prestação de serviços, com o objetivo de melhorar a qualidade e a satisfação do cliente ao reduzir essas discrepâncias. (Parasuraman et al., 1985). São essas cinco lacunas:

- **Lacuna 1: Conhecimento** – Diferença entre as expectativas dos clientes e a percepção que a gestão tem dessas expectativas;
- **Lacuna 2: Política** – Discrepância entre a percepção da gestão sobre as expectativas dos clientes e a tradução dessa percepção em especificações de qualidade de serviço;
- **Lacuna 3: Entrega** – Diferença entre as especificações de qualidade do serviço e o serviço efetivamente entregue, também conhecido como SLA (Service Level Agreement);
- **Lacuna 4: Comunicação** – Diferença entre o serviço entregue e o que é comunicado aos clientes;
- **Lacuna 5: Percepção** – Discrepância entre o serviço esperado e o serviço percebido, influenciada pelas outras quatro lacunas.

Tabela 2.

Lacunas-chave identificadas no modelo GAP, com exemplos de casos que remetem para cada lacuna.

Lacuna	Exemplo de caso
Lacuna 1: Conhecimento	Um restaurante de alta gama acredita que os clientes valorizam principalmente o ambiente, mas estes estão mais interessados na qualidade dos pratos.
Lacuna 2: Política	Um hotel define que todos os pedidos dos hóspedes devem ser atendidos em menos de 10 minutos, mas essa política não é devidamente comunicada à equipa.
Lacuna 3: Entrega	Um restaurante promete pratos com ingredientes frescos, mas usa ingredientes de qualidade inferior devido a falhas no fornecimento ou custos.
Lacuna 4: Comunicação	Um hotel anuncia que todos os quartos têm vista para o mar, mas alguns quartos só têm uma vista parcial para o mar.
Lacuna 5: Percepção	Um hotel é promovido como um estabelecimento de luxo com serviço de quarto 24 horas, mas este serviço só está disponível em horários limitados.

Posteriormente, em 1988, o mesmo grupo de investigadores propôs o modelo SERVQUAL (Parasuraman et al., 1988), que identificou cinco dimensões-chave para avaliar a qualidade do serviço em qualquer indústria:

- **Tangibilidade** – Instalações físicas, equipamentos e aparência do pessoal;
- **Confiabilidade** – Capacidade de executar o serviço prometido de forma precisa;
- **Responsividade** – Capacidade de ajudar os clientes e fornecer um serviço rápido;
- **Garantia** – Conhecimento e cortesia dos funcionários, bem como a sua capacidade de transmitir confiança e segurança;
- **Empatia** – Atenção personalizada e cuidado prestado aos clientes.

Tabela 3.

Dimensões identificadas pelo modelo SERVQUAL e exemplos de casos que remetem para esta dimensão.

Dimensão	Exemplo de caso
Tangibilidade	A aparência física de um hotel, incluindo a limpeza dos quartos, a qualidade das instalações e o uniforme dos empregados.
Confiabilidade	Um restaurante que promete que os pedidos serão entregues à mesa em menos de 30 minutos e cumpre consistentemente essa promessa.
Responsividade	A rapidez e a eficácia com que o pessoal de um hotel responde a pedidos especiais ou reclamações dos hóspedes.
Garantia	A capacidade dos funcionários de um restaurante de responder com conhecimento a perguntas sobre ingredientes de pratos para clientes com alergias alimentares.
Empatia	O cuidado e atenção personalizada que o pessoal de um hotel oferece aos hóspedes, como lembrar-se dos nomes dos hóspedes ou dos seus pedidos habituais.

(Parasuraman et al., 1988, p.21)

Embora o SERVQUAL tenha sido desenvolvido sem uma indústria específica em mente, investigadores do setor da restauração adaptaram-no, criando o DINESERV (Stevens et al., 1995). O DINESERV mantém as mesmas dimensões básicas, mas adapta as descrições e expectativas para refletir melhor as especificidades da indústria da restauração, incorporando 5 dimensões com 29 itens de avaliação, distribuídos da seguinte forma:

- **Tangibilidade** – 10 itens;
- **Confiabilidade** – 5 itens;
- **Responsividade** – 3 itens;
- **Garantia** – 6 itens;
- **Empatia** – 5 itens.

Cada item no DINESERV inclui uma descrição detalhada, estabelecendo o critério específico a ser considerado para avaliação.

Assim, o DINESERV (Stevens et al., 1995) revela-se um modelo pertinente para a análise deste trabalho, pois oferece um conjunto de dimensões e critérios diretamente aplicáveis à indústria da restauração e às expectativas dos clientes. No contexto dos comentários dos clientes, é essencial reconhecer que os textos refletem diferentes aspetos do serviço, que variam de pessoa para pessoa.

O modelo DINESERV divide-se nas seguintes cinco dimensões:

- **Tangibilidade** – Refere-se às instalações físicas, equipamentos, aparência e apresentação do pessoal, bem como à qualidade, manutenção e funcionalidade das instalações e equipamentos;
- **Confiabilidade** – Relaciona-se com a capacidade de cumprir com o prometido, incluindo a precisão na entrega de pedidos, consistência nos pratos e cumprimento dos tempos de espera anunciados;
- **Responsividade** – Diz respeito à capacidade da equipa em auxiliar os clientes e fornecer um serviço célere;
- **Segurança** – Refere-se ao conhecimento e à cortesia dos funcionários, bem como à capacidade de transmitir confiança e segurança ao cliente;
- **Empatia** – Envolve a atenção e o cuidado personalizado prestados aos clientes.

Este modelo permite uma avaliação abrangente e segmentada da experiência do cliente, ajustando-se às particularidades da restauração e proporcionando uma análise mais detalhada dos comentários deixados pelos clientes.

Tabela 4.

Dimensões identificadas pelo modelo DINESERV e exemplos de casos que remetem para esta dimensão.

Dimensão	Exemplo de caso
Tangibilidade	A limpeza e organização visual de um restaurante, incluindo a apresentação dos pratos e a aparência dos funcionários.
Confiabilidade	Um restaurante que serve os pratos conforme descritos no menu e de forma consistente, e entrega os pedidos sem falhas.
Responsividade	A rapidez com que o pessoal do restaurante atende os pedidos dos clientes, como a rapidez em reabastecer bebidas ou trazer itens adicionais.
Segurança	A competência e cortesia dos funcionários do restaurante em assegurar aos clientes que suas restrições dietéticas são respeitadas e compreendidas.
Empatia	A atenção que os empregados dão aos clientes, de forma individual, reconhecendo os clientes que são frequentes e as suas preferências.

(Stevens et al., 1995, p.57)

2.6.3. DINESERV - Um referencial multidimensional para a análise de sentimentos.

Tendo em conta o exposto, verifica-se que a aplicação das dimensões do modelo DINESERV é de grande relevância para a análise de sentimento a ser realizada nesta dissertação. A divisão proposta pelo modelo permite uma análise mais detalhada e específica das experiências dos clientes, categorizando-as de forma a compreender melhor os diferentes aspetos do serviço que influenciam a sua satisfação.

Dessa forma, foi organizada, de acordo com o que foi descrito por Stevens et al. (1995), uma tabela que detalha os itens específicos associados a cada uma das cinco dimensões do modelo DINESERV. Esta tabela apresenta a correspondência de cada item com a respetiva dimensão, facilitando a identificação dos critérios que serão utilizados na análise de sentimento.

Tabela 5.

As 5 dimensões do modelo DINESERV, dimensões da análise e respectivos 29 critérios de avaliação.

Dimensão	Descrição do item / Critério de avaliação	Item
Tangibilidade	O restaurante tem um exterior atrativo	1.1
	O restaurante tem uma sala de refeições atrativa	1.2
	A equipa do restaurante é asseada e devidamente fardada	1.3
	O restaurante tem uma decoração adequada ao seu preço	1.4
	O restaurante tem um menu fácil de se entender	1.5
	O restaurante tem um menu que reflete a sua imagem	1.6
	O restaurante tem uma sala de refeições confortável e de fácil circulação	1.7
	O restaurante tem as casas de banho limpas	1.8
	A sala de refeições do restaurante é limpa	1.9
	O restaurante tem cadeiras confortáveis na sua sala de refeições	1.10
Confiabilidade	O restaurante serve os pratos no tempo prometido	2.1
	O restaurante corrige rapidamente qualquer erro cometido	2.2
	O restaurante é confiável e consistente	2.3
	O restaurante apresenta uma conta precisa com o custo da refeição	2.4
	O restaurante serve a refeição tal como como foi pedida	2.5
Responsividade	Durante a refeição, existem funcionários suficientes para ajudarem	3.1
	O restaurante tem um serviço rápido	3.2
	O restaurante faz esforços para atender a pedidos especiais	3.3
Segurança	O restaurante tem funcionários que conseguem responder às dúvidas dos seus clientes	4.1
	O restaurante faz com que o cliente se sinta confortável e confiante a lidar com a equipa	4.2

	O restaurante tem uma equipa que é capaz de dar informações precisas sobre os itens do menu, ingredientes e métodos de confeção	4.3
	O serviço do restaurante faz com que o cliente se sinta seguro	4.4
	O restaurante tem uma equipa que parece ser bem treinada e experiente	4.5
	A gerência do restaurante parece dar à sua equipa o apoio suficiente para que esta consiga executar as suas tarefas de forma adequada	4.6
Empatia	O restaurante tem uma equipa de funcionários sensíveis a desejos e necessidades dos clientes	5.1
	A equipa do restaurante faz com que os clientes se sintam especiais	5.2
	A equipa do restaurante antecipa desejos e necessidades dos clientes	5.3
	O restaurante tem uma equipa de funcionários solidários e que transmitem um ambiente reconfortante, no caso de algo correr mal.	5.4
	A equipa do restaurante parece ser sensível aos interesses dos clientes	5.5

Embora o modelo DINESERV seja bastante detalhado, com os seus 29 critérios distribuídos pelas cinco dimensões, é importante reconhecer que este foi originalmente concebido para recolher informação através de questionários. No entanto, o método que será aplicado nesta dissertação, com recurso a LLMs (Large Language Models), requer uma adaptação dos critérios. A necessidade de simplificação surge para evitar redundâncias e garantir que a análise de sentimento seja eficiente e objetiva.

Por exemplo, na dimensão tangibilidade, há uma sobreposição de critérios que avaliam essencialmente a mesma perceção sobre o ambiente do restaurante. Critérios como “O restaurante tem uma sala de refeições atrativa” (item 1.2), “O restaurante tem uma sala de refeições confortável e de fácil circulação” (item 1.7), “A sala de refeições do restaurante é limpa” (item 1.9) e “O restaurante tem cadeiras confortáveis na sua sala de refeições” (item 1.10) abordam aspetos semelhantes relativos ao espaço físico. Nos comentários online, esses aspectos são frequentemente reduzidos a observações mais gerais e menos detalhadas.

Assim, embora todos esses critérios sejam importantes no contexto de um questionário aplicado diretamente aos clientes, verificamos que os comentários em

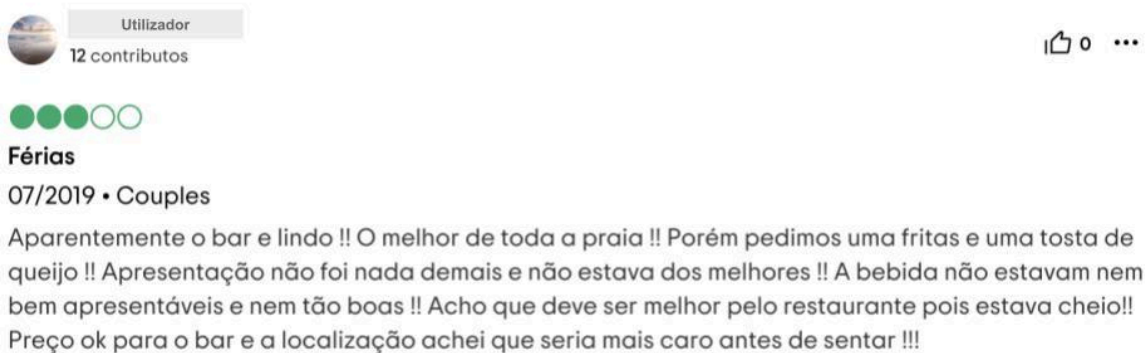
plataformas digitais tendem a ser mais concisos. Muitas vezes, os clientes fazem menções mais genéricas sobre o ambiente, conforto e limpeza, sem a necessidade de segmentar cada um desses aspetos de forma individual.

Portanto, para a análise de sentimento que será realizada com LLMs, é necessário consolidar os critérios em categorias mais abrangentes, captando o essencial sem perder o significado, mas garantindo que a análise seja direta e não redundante.

Figura 15.

Exemplos de comentários de clientes na TripAdvisor.com, sobre um restaurante na Praia da Rocha, em Portimão.

a)



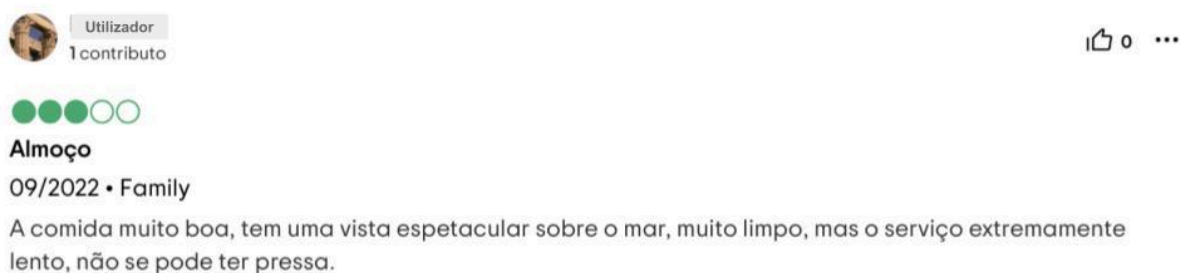
Utilizador
12 contributos

3/5

Férias
07/2019 • Couples

Aparentemente o bar é lindo !! O melhor de toda a praia !! Porém pedimos uma fritas e uma tosta de queijo !! Apresentação não foi nada demais e não estava dos melhores !! A bebida não estavam nem bem apresentáveis e nem tão boas !! Acho que deve ser melhor pelo restaurante pois estava cheio!! Preço ok para o bar e a localização achei que seria mais caro antes de sentar !!!

b)



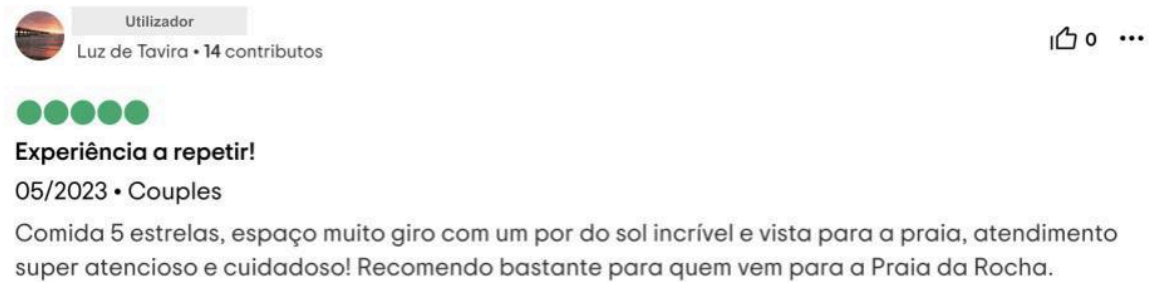
Utilizador
1 contributo

3/5

Almoço
09/2022 • Family

A comida muito boa, tem uma vista espetacular sobre o mar, muito limpo, mas o serviço extremamente lento, não se pode ter pressa.

c)



Nos exemplos apresentados, verificamos que os comentários não têm o nível de detalhe esperado pelo modelo DINESERV. As observações resumem diversos critérios em expressões curtas, como “Aparentemente o bar é lindo(...)” (Figura 15, a), “(...), muito limpo, (...)” (Figura 15, b), e “(...), espaço muito giro (...)” (Figura 15, c).

Além disso, analisando o conjunto de dados da plataforma DIG-IN (ex-Zomato), verifica-se que, das 1.043.806 entradas, 474.470 contêm comentários escritos, com uma média de 196 caracteres, ou cerca de 60 palavras por comentário (por exemplo, o comentário da figura 15, a), tem 67 palavras).

Assim, pode-se inferir que o nível de detalhe exigido pelo DINESERV não se verifica nos comentários online, já que os clientes tendem a expressar opiniões de forma simplificada, focando-se mais nas 5 dimensões gerais do modelo e não nos 29 itens específicos.

2.6.4. Adaptando o referencial DINESERV

No sentido de reduzir os 29 itens propostos pelo modelo DINESERV a um conjunto que corresponda a avaliações mais sucintas, procedeu-se a uma análise detalhada dos itens e dimensões, sintetizando aquilo que cada uma pretende captar. A partir da interpretação dos itens e da consulta à literatura, reformularam-se os critérios de avaliação, tendo em conta a forma mais concisa com que os clientes tendem a expressar as suas opiniões.

Dimensão Tangibilidade:

Propõe-se que os critérios relacionados com esta dimensão se concentrem na aparência geral das instalações e equipa, incluindo:

- Aparência física das instalações e equipamentos;
- Uniformes e aparência da equipa;
- Apresentação do menu.

Estes critérios captam a percepção geral sobre a atmosfera de um restaurante, que, segundo (Haghighi, 2012), tem um impacto significativo na satisfação do cliente.

Dimensão Confiabilidade:

No caso da confiabilidade, a proposta inclui critérios que avaliam a capacidade de o restaurante cumprir o que promete, como:

- Tempos de confeção e atendimento;
- Precisão dos pedidos e faturação;
- Consistência dos pratos, sabor e serviço.

Esta dimensão reflete a confiança que os clientes depositam no restaurante para entregar um serviço consistente e de qualidade, o que é crucial para gerar satisfação e lealdade (Alves, 2017).

Dimensão Responsividade:

Para a responsividade, que avalia a prontidão do serviço, os critérios são:

- Disponibilidade dos funcionários;
- Serviço rápido;
- Atendimento a pedidos especiais.

A responsividade está também associada à sensibilidade dos funcionários em relação às necessidades dos clientes, sendo um fator determinante na qualidade do atendimento personalizado (Silva et al., 2009).

Dimensão Segurança:

A segurança do cliente no serviço prestado é fundamental, e os novos critérios propostos são:

- Informações precisas e transparentes;
- Experiência e treino da equipa;

- Facilidade de interação com os funcionários.

A segurança engloba a confiança do cliente na competência da equipa, especialmente no que diz respeito a informações do menu e à capacidade de prestar um serviço confiável (Alhelalat et al., 2017).

Dimensão Empatia:

Finalmente, para a dimensão empatia, os critérios reformulados são:

- Sensibilidade às necessidades dos clientes;
- Capacidade de antecipação a necessidades;
- Suporte no caso de problemas.

A empatia, tal como a segurança, envolve aspetos comportamentais e relacionais da equipa, com foco na atenção personalizada e na capacidade de criar uma experiência positiva e satisfatória para o cliente. A empatia é um elemento essencial para a satisfação do consumidor em serviços de restauração, onde o atendimento pessoal é um fator chave.

Essas reformulações permitem capturar de forma mais concisa a essência das dimensões do DINESERV, adaptando-as ao formato de comentários curtos e diretos que os clientes tendem a fornecer nas plataformas online.

Por fim, obtemos a seguinte tabela com os novos critérios definidos a partir do modelo DINESERV, sintetizando os 29 itens em critérios mais concisos e adequados à análise de avaliações sucintas:

Tabela 6.

Resumo dos 15 novos critérios de avaliação, derivados do modelo DINESERV.

Dimensão	Novos Critérios
Tangibilidade	Aparência física das instalações e equipamentos; Uniformes e aparência da equipa; Apresentação do menu.
Confiabilidade	Tempos de confeção e atendimento; Precisão dos pedidos e faturação; Consistência dos pratos, sabor e serviço.
Responsividade	Disponibilidade dos funcionários; Serviço rápido; Atendimento a pedidos especiais.
Segurança	Informações precisas e transparentes; Experiência e treino da equipa; Facilidade de interação com os funcionários.
Empatia	Sensibilidade às necessidades dos clientes; Capacidade de antecipação a necessidades; Suporte no caso de problemas.

Em conclusão, a adaptação do modelo DINESERV aos comentários sucintos e diretos frequentemente encontrados em plataformas online exigiu uma simplificação dos seus 29 itens originais. Ao reestruturar e consolidar os critérios de avaliação, foi possível capturar a essência de cada dimensão — tangibilidade, confiabilidade, responsividade, segurança e empatia — sem perder a profundidade necessária para compreender a satisfação do cliente. Esta reformulação permite que a análise, suportada por modelos LLM, seja mais precisa e eficiente, refletindo as percepções dos clientes de forma mais ajustada à realidade das plataformas digitais de avaliação.

Assim, o conjunto de novos critérios propostos fornece uma base sólida para a análise de sentimento que será conduzida no próximo capítulo, permitindo avaliar de forma estruturada e abrangente os aspetos fundamentais da experiência do cliente no contexto da restauração.

3. Metodologia

Como mencionado ao longo deste trabalho, propõe-se a implementação de um sistema de recomendação de restaurantes na Área Metropolitana de Lisboa, que inclui uma análise detalhada da concorrência, baseada nos dados fornecidos pela plataforma DIG-IN. O sistema utilizará detalhes sobre os restaurantes, como localização, tipo de cozinha e preço médio, e combinará esses fatores com uma análise de sentimento dos comentários dos clientes, oferecendo aos investidores uma ferramenta robusta para avaliar o potencial de determinadas localizações para novos negócios de restauração.

De acordo com Bressler, (2012), a identificação e desenvolvimento de vantagens competitivas são cruciais para a entrada no mercado de pequenos negócios. Este sistema responde a essa necessidade, oferecendo uma visão detalhada da concorrência e das suas classificações, bem como a análise dos comentários dos clientes. Assim, o investidor poderá entender melhor os pontos fortes e fracos dos concorrentes, com base em experiências reais dos consumidores, e não apenas nas suas percepções pessoais.

Por exemplo, ao considerar um restaurante específico como referência, o sistema não só fornece informações como localização e tipo de cozinha, mas também destaca os aspetos qualitativos, como o feedback dos clientes, obtido através da análise de sentimento. O investidor terá acesso a essa informação de forma centralizada e rápida, substituindo a necessidade de recolher feedback de forma manual e evitando potenciais vieses que poderiam surgir em entrevistas.

A principal vantagem da ferramenta reside na análise automatizada e profunda dos comentários dos clientes, permitindo ao investidor identificar oportunidades de melhoria e criar vantagens competitivas com base nas falhas dos concorrentes. Esta abordagem poderá facilitar o processo de tomada de decisão, uma vez que oferece uma visão clara e baseada em dados sobre a experiência dos consumidores.

No entanto, devido aos elevados custos associados ao processamento de texto com LLMs, o sistema apresentado nesta dissertação trabalhará sobre os dados e constituirá um protótipo de um sistema global. Embora limitado em termos de abrangência geográfica e concorrencial, reflete o potencial de uma solução

completa e eficaz para análise e recomendação de restaurantes, demonstrando as capacidades do sistema proposto. Para a concretização deste protótipo, será detalhado o processo de recolha de dados, pré-processamento e aplicação dos LLMs para a implementação deste protótipo, de acordo com as seguintes etapas:

1. Origem dos dados;
2. Caracterização dos dados;
3. Definição da amostra;
4. Personalização de uma instrução (*prompt*) para aferir a precisão do ChatGPT na análise;
5. Modelos para a análise de sentimento aos comentários;
6. Aferição da precisão dos modelos;
7. Aplicação do sistema de análise num protótipo de ferramenta de recomendação.

3.1. Origem dos dados

Os dados utilizados para a análise de sentimento e implementação do sistema de comparação da concorrência no setor da restauração foram fornecidos pela ZMTEUROPE, LDA, empresa que gere a plataforma digital de descoberta de restaurantes atualmente conhecida como DIG-IN. A recolha de dados para este estudo centrou-se em duas dimensões principais: os restaurantes da Área Metropolitana de Lisboa (AML) e as respetivas classificações feitas pelos utilizadores da plataforma.

Foi possível obter um conjunto de dados significativo através da plataforma DIG-IN (anteriormente Zomato), no âmbito da criação recente do seu laboratório de dados, o Datalab. A ZMTEUROPE, LDA é uma PME com ambições de consolidar a sua presença no mercado nacional de reservas online e de apoiar o desenvolvimento de soluções inovadoras no ecossistema de startups. A criação do Datalab é um exemplo deste esforço, oferecendo uma base de dados robusta para estudos como o presente.

Em 2021, a plataforma DIG-IN afirmava ter mais de 40 mil restaurantes, bares e cafés registados, com uma base de utilizadores que excedia 1 milhão. No

mesmo ano, em Portugal, existiam oficialmente 35.360 estabelecimentos de restauração registados com o CAE 561 - Restaurantes (inclui actividades de restauração em meios móveis). Embora o número de estabelecimentos da plataforma e os dados do INE, I.P. não coincidam totalmente, é importante considerar que nem todos os fechos de estabelecimentos são comunicados à plataforma e alguns registos podem corresponder a restaurantes inativos ou já encerrados.

Apesar dessas discrepâncias, a DIG-IN mantém uma penetração significativa no mercado nacional, tornando-a numa fonte valiosa de dados para este estudo. O *dataset* fornecido reflete essa importância, com informações sobre 15.892 restaurantes ativos na Área Metropolitana de Lisboa, 1.043.806 avaliações e 474.470 comentários escritos.

Dado o volume e a qualidade dos dados recebidos, a escolha desta plataforma como base de dados para o estudo revela-se particularmente relevante. Os dados serão posteriormente processados, utilizando o modelo de avaliação que se vai desenvolver nos próximos tópicos deste texto.

3.2. Caracterização dos dados

Embora os dados tenham sido recebidos em segmentos diferentes, estes são respeitantes às duas dimensões já mencionadas, restaurantes dentro da delimitação da AML e respectivas classificações e comentários.

Após o pré-processamento necessário, utilizando a técnicas de análise de dados com linguagem Python, para se delimitar corretamente a AML e corrigir erros nos dados, como valores nulos, resultaram dois *datasets* (conjuntos de dados):

- 15.892 restaurantes dentro da AML;
- 1.043.806 classificações atribuídas, tendo 474.470 dessas classificações comentários efectivamente escritos, e não somente a classificação.

Deste processamento, resultaram então estes dois conjuntos de dados (*datasets*) que irão, em conjunto, permitir a tarefa da ferramenta proposta neste

trabalho. No que concerne ao aspeto dos dados dos 15.892 restaurantes da AML, obteve-se o seguinte:

Tabela 7.

Exemplo do conjunto de dados (*dataset*) dos restaurantes pré-processados.

id	name	type	rating	price	status	updated_at	Outside seating	takeaway	delivery	Review_count
6	Miss Jappa	Japanese, Sushi	4.1	40	active	2024-02-19 09:00:08	1	1	1	1110
7	Dom Tacho	Portuguese	3.6	28	active	2024-01-05 17:50:08	1	1	1	574
8	DiGastro BAR	Tapas	4	40	active	2024-01-05 17:50:08	0	0	0	36
9	Rice Me	Mediterranean, Vegetarian	3.8	30	active	2024-01-05 17:50:08	1	1	1	616
11	Copélia	Portuguese	3.9	6	active	2024-02-19 09:00:08	0	1	0	25
12	Despensa N6	Crepes, Bakery & Pastry	3.9	8	active	2024-01-05 17:50:08	0	1	1	643
13	Chiveve	Portuguese, Vegetarian, Mozambican, African	3.9	30	active	2023-05-05 10:39:58	0	0	0	0

Cada restaurante é diferenciado por um 'restaurant_id' (id) único, que contém o nome, o tipo de cozinha, a sua pontuação geral na plataforma DIG-IN, a sua localização, por coordenadas, o seu preço médio para 2 pessoas, a disponibilidade de esplanada, serviços de *takeaway* e *delivery*, assim como a contagem de comentários na plataforma.

No que respeita aos dados que serão processados por LLMs, nomeadamente os comentários feitos pelos clientes, obteve-se o seguinte:

Tabela 8.

 Exemplo do conjunto de dados (*dataset*) das avaliações pré-processado.

id	User_id	Restaurant_id	general_rating	original_text
4272631	0	1	4	Mais uma gelataria com gelados fantásticos, a variedade de sabores é incrível, não só pela quantidade como pelos sabores em si. Os gelados são ótimos e muito em conta, 2€ e tal (não me recordo ao certo o preço) por uma bola que pode ter 2 sabores (...)
4272632	82612	1	4.5	Sempre fui cliente mais assídua da Artisani de Carcavelos, bem juntinho à praia e, por isso mesmo, propícia aos gelados! Mas com a abertura desta em Lisboa, passei a frequentar muito mais este espaço perto do Jardim da Estrela (...)
4272633	0	1	4.5	
4272634	36328	1	4.5	Tem gelados artesanais para todos os gostos, pois o leque de sabores é variadíssimo. Tem aqueles tradicionais e conhecidos por toda a gente como caramelo, chocolate e stracciatella, mais uns quantos bastante originais como o famoso tarte de limão, pastel de nata, salame de chocolate, vinho moscatel, entre outros (...)
4272635	12632	1	4	
4272636	9049	1	4.5	Ir comer um gelado a artisani e já um clássico, como e ir ao santini. No Entanto, tem saído novos sabores de gelados que nunca tinha tido a oportunidade de experimentar. Esses são por exemplo: sabor a salame de chocolate, ferrero roche ou pastel de nata. Provei os três. São incríveis!! O gelado de pastel de nata vale mesmo mesmo a pena.

3.3. Definição da amostra

No que respeita aos dados dos restaurantes, um critério diferenciador importante identificado foi o tipo de cozinha oferecido por cada estabelecimento. Este critério é um dos mais relevantes na distinção entre os restaurantes e tem um peso significativo na decisão do consumidor. Contudo, como a criação do perfil do restaurante na plataforma DIG-IN é feita diretamente pela gerência, a categorização dos tipos de cozinha é deixada ao seu critério.


Esta flexibilidade na definição das categorias levou a alguma entropia durante a análise e segmentação, uma vez que, em muitos casos, as categorias estavam

misturadas e apresentadas de forma confusa, dificultando tanto a interpretação dos dados como, potencialmente, a escolha dos clientes.

Um exemplo claro desta situação é o restaurante com o id 4419, "African Kitchen - Restaurante Continental", que foi classificado como servindo as cozinhas "Portuguese, African, Italian, Brazilian". Embora este caso seja específico, situações semelhantes ocorreram em diversas instâncias, refletindo a falta de clareza na categorização.


Dado este cenário, o pré-processamento de dados focou-se em identificar os tipos de cozinha mais frequentes no conjunto de dados. Este esforço permitiu organizar e segmentar os restaurantes de forma mais eficiente, resultando na identificação das dez categorias principais, conforme ilustrado na figura 16. Estas categorias refletem os tipos de cozinha mais comuns e relevantes para a análise, facilitando uma segmentação mais clara e compreensível para o estudo.

Figura 16.
Os 10 tipos de cozinha mais frequentes no conjunto dos 15.892 restaurantes.




Dado que um restaurante pode ter vários tipos de cozinha associados, muitas vezes com combinações díspares, optou-se por restringir a pesquisa aos restaurantes que apresentam apenas um dos 10 tipos de cozinha mais frequentes. Esta delimitação permitiu uma análise mais clara e focada, cujos resultados estão representados na figura 17.

Figura 17.
 Restaurantes com um só tipo de cozinha, das top 10 categorias.




Após essa filtragem, analisaram-se as 1.043.806 classificações registadas nos dados, das quais 474.470 continham comentários escritos. O próximo passo foi delimitar o número total de comentários escritos para cada um dos tipos únicos de cozinha, com base no top 10 de categorias identificado anteriormente. Esta abordagem possibilitou uma visão mais precisa da distribuição e densidade de comentários por tipo de cozinha, permitindo uma análise detalhada da perceção do cliente para cada segmento específico.

Figura 18.
 Número de comentários escritos com um só tipo de cozinha associado, das top 10 categorias.



Com base nos resultados obtidos, optou-se por utilizar a categoria de restaurante Italiano ('Italian') para a amostra da ferramenta, dado que esta contém 4.464 comentários escritos provenientes de 115 restaurantes dentro da AML.

Figura 19.
 Média de comentários por restaurante da categoria.



A escolha da categoria “Italian” como foco da análise baseou-se em três fatores essenciais:

1. **Relação comentários/restaurante:** A categoria "Italian" apresenta uma boa relação de comentários por restaurante, com uma média de 38,82 comentários em 115 restaurantes, o que representa uma densidade significativa de opiniões por estabelecimento;
2. **Número de restaurantes:** Embora as categorias "Seafood", "Sushi", e "Japanese" também apresentem uma boa relação de comentários por restaurante, o número total de restaurantes em cada uma dessas categorias é inferior a 100, o que limita a representatividade da amostra;
3. **Custos de processamento:** A categoria "Burger", com uma média de 48,08 comentários para 333 restaurantes e um total de 16.012 comentários, teria sido uma boa opção. No entanto, os custos associados ao processamento de um número tão elevado de comentários levariam a restrições orçamentais. Diante disso, optou-se por uma categoria que oferecesse uma relação equilibrada entre número de comentários e viabilidade de processamento.

Assim, a categoria "Italian", com 115 restaurantes e um total de 4.464 comentários escritos, revelou-se a escolha ideal. Com uma média de 38,82 comentários por restaurante, o processamento completo dessa categoria é viável dentro dos limites orçamentais, permitindo uma análise integral dos dados sem a necessidade de reduzir a amostra.

Este protótipo, apesar de focado numa única categoria, expressa plenamente o potencial da ferramenta proposta. Ao refletir uma análise completa de todos os dados disponíveis na categoria "Italian", o protótipo demonstra como a ferramenta funcionaria com todas as categorias, evidenciando as suas capacidades de processamento e análise de sentimento.

3.4. Personalização de uma instrução (*prompt*) para aferir a precisão do *ChatGPT* na análise.

Um *prompt* é uma instrução em linguagem natural fornecida a um modelo de inteligência artificial para que este possa interpretar e realizar uma tarefa específica.

No contexto da utilização de LLMs, como o ChatGPT, o *prompt* atua como o guia que orienta o modelo a processar informações de acordo com os parâmetros definidos. Essencialmente, o *prompt* traduz a intenção humana em comandos que o modelo pode entender e executar, permitindo que a análise seja conduzida de forma precisa e eficiente. Ao definir um *prompt*, é importante incluir todos os critérios e regras que o modelo deve seguir para garantir que os resultados reflitam o que foi solicitado.

Com o modelo de avaliação proposto, é possível aplicar a metodologia desenvolvida para analisar comentários reais, verificando como o sentimento seria extraído em conformidade com os novos critérios para cada dimensão da análise.

Com base nisso, foi elaborado um *prompt* que incorpora todos os novos critérios definidos anteriormente, derivados do modelo DINESERV. Este *prompt* serve como a instrução que o software de inteligência artificial generativa, neste caso o ChatGPT, utiliza para avaliar os comentários:

“

Tu és um analista de sentimentos e avalias comentários de clientes de restaurantes, dando-lhes uma classificação de 1 a 5, em que 1 é (muito insatisfeito) e 5 (muito satisfeito).

Quero que analises o texto do comentário e verifiques correspondências com os critérios de cada uma das 5 dimensões.

As dimensões são:

Tangibilidade - que se refere às instalações físicas, equipamentos e aparência do pessoal, a qualidade e a manutenção das instalações, a modernidade e a funcionalidade dos equipamentos, assim como a apresentação dos funcionários e do menu;

Confiabilidade - que concerne à capacidade de executar o serviço prometido, incluindo a precisão da entrega de pedidos, a consistência e sabor dos pratos servidos em diferentes momentos e a capacidade de cumprir com os tempos de espera anunciados;

Responsividade - Esta dimensão é também associada ao termo Sensibilidade. Aqui, pretende-se verificar aspectos como o serviço é prestado por parte dos funcionários. Procura-se verificar se estes estão disponíveis e são sensíveis às necessidades dos clientes, prestando um serviço atencioso, rápido e também personalizado;

Segurança - A dimensão Segurança procura englobar os fatores que sejam relativos à forma como o cliente se sente num restaurante, nomeadamente se sente que o staff é capaz de prestar informações precisas sobre o menu, que é acessível e que demonstra experiência na operação;

Empatia - A dimensão Empatia demonstra critérios de avaliação similares, na sua essência, aos da dimensão Segurança. Embora de perspectivas diferentes, ambos abordam aspectos comportamentais da equipa, como a sua sensibilidade e capacidade de antecipação das necessidades dos clientes, assim como resolução de problemas.

Como tens de avaliar?

- 1) Só podes considerar aspectos relativos ao restaurante em avaliação;
- 2) Os comentários podem ter palavras como "extremamente", "muito" ou "muitíssimo", que sugerem uma polaridade de opinião forte em relação a algo. Isto quer dizer que a pessoa gostou muito ou pouco desse aspecto;
- 3) Caso o texto não obtenha correspondência com os critérios, não consideres esse critério na classificação média da dimensão correspondente;
- 4) Gera uma classificação, de 1 a 5, para cada dimensão avaliado;
- 5) No final, terá de resultar uma classificação para cada dimensão;
- 6) Apresenta também a classificação média geral, que corresponderá à média de todas as dimensões. Esse valor tem de ser arredondado;
- 7) Caso uma dimensão não obtenha um resultado, por falta de correspondência com o comentário, não a consideres na média final.

Faz uma tabela com as seguinte colunas:

- 1 para classificação pela máquina, 1 para a classificação geral;
- Tangibilidade;
- Confiabilidade;
- Responsividade;

- Segurança;
- Empatia.
- ”

Este *prompt* foi projetado para garantir que os critérios de avaliação e as dimensões de análise sejam aplicados de forma consistente, de acordo com os seguintes princípios:

1. **Foco nos aspectos relacionados com o restaurante:** A análise deve concentrar-se unicamente nos aspetos mencionados pelos clientes, como a qualidade do serviço, da comida, do ambiente, entre outros;
2. **Polaridade do discurso:** A identificação de sentimentos baseia-se na detecção de palavras que expressam fortes emoções ou julgamentos, como "extremamente" ou "muito", indicando a intensidade da satisfação ou insatisfação do cliente;
3. **Método de classificação:** A polaridade do comentário será classificada em termos de sentimento positivo, negativo ou neutro, conforme o tom geral do feedback. Isso será feito com base na análise da linguagem usada pelo cliente.

Além disso, para garantir a robustez da análise, foram estabelecidas contingências. Por exemplo, o modelo deve concentrar-se exclusivamente nos aspectos mencionados no comentário, evitando introduzir suposições sobre o restaurante ou o serviço que não estejam explícitas. Essa abordagem garante que a extração de sentimento seja precisa e esteja alinhada com os critérios previamente definidos.

Este processo, apoiado pelo *prompt* desenvolvido, assegura que a avaliação de cada comentário seja coerente e precisa, facilitando a análise do sentimento com base nos dados reais dos clientes e no modelo de avaliação ajustado ao DINESERV.

3.4.1. Comparação entre classificação geral feita pelos clientes vs. a classificação feita pela máquina.

Para uma primeira forma de se conferir a precisão deste *prompt* e o seu alinhamento com o resultado da avaliação humana, procedemos à análise dos 15 comentários (anexo 1) que encontravam na primeira página do Tripadvisor do restaurante em estudo. Aqui, o objetivo prendeu-se em compreender se a máquina interpreta o sentimento da mesma forma que o humano que o escreveu fez.

Comentários em análise:

Figura 20.

Amostra de 3 dos 15 comentários constantes na primeira página de comentários na plataforma TripAdvisor.com, de um restaurante na Praia da Rocha, em Portimão.

1)



Aceitável mas...

03/2024 • Friends

Arroz de tamboril optimo mas muito tempo de espera, cerca de 2 horas, o que não justifica nesta altura do ano. Quando chegar o verão como será??

2)



Má comida e serviço ainda pior.

08/2023 • Family

Muito má comida e péssimo serviço. A feijoada de buzinas que é especialidade vinha fria e teve que ir ao forno. Além disso não tinha sal. A sangria precisou de 3 Sprites (que foram cobradas sabendo os empregados que eram para meter na sangria) para ser bebível. Não fazem bife à Restaurante porque obviamente a carne vai direta do congelador para a fritura... esperamos com crianças mais de 2 horas pelo segundo presto. sopa de peixe com escamas!!! Inadmissível. Uma sopa de tomate que era uma sopa de ketchup. Fuja das gambas al ajillo. É tudo camarão congelado. As pataniscas todas queimadas e a açorda que acompanha tudo muito salgado. O gerente em negação não se importou muito e negou todas as reclamações. Não querem saber. Pelo menos em Agosto são mais uma armadilha para turistas.

3)



Mau demais

08/2023 • Family

A minha experiência neste restaurante não podia ter sido pior. Como não atendiam o telefone para fazer marcação, desloquei-me presencialmente e quando cheguei disseram que como não era cliente assíduo tinha de me habituar e esperar pelo menos 45min/1hora. Explicaram que os turnos mudavam e até me disseram a que horas o staff jantava, como se me interessasse. Basicamente argumentaram para eu não jantar lá. Foi o que fiz, nem cheguei a marcar, tive pena de não ficar com o nome do responsável pois foi a pessoa com quem falei, para o parabenizar, pois com um negócio a correr tão bem que não precisa de clientes, só merece mesmo os parabéns! Restauração algarvia no seu melhor!

Com a classificação atribuída pelos clientes em cada um dos 15 comentários como referência, foi então utilizada a versão 3.5 do ChatGPT, empregando o *prompt* previamente desenvolvido, para proceder à análise e classificação dos mesmos comentários.

Tabela 8.

Tabela das classificações feitas pelos clientes em comparação com as classificações dadas pela máquina.

Comentário	Classificação pelo humano	Classificação pela máquina
1)	2	2
2)	1	1
3)	1	1
4)	1	1
5)	5	5
6)	5	5
7)	2	2
8)	3	3
9)	5	5
10)	1	1
11)	1	1
12)	4	5
13)	3	3
14)	5	5
15)	2	2

Verificou-se que, em 14 dos 15 comentários analisados, o ChatGPT (versão 3.5) atribuiu a mesma classificação geral que os clientes, baseando-se apenas no texto dos comentários e sem acesso a mais informações sobre as avaliações. No único caso em que a máquina não coincidiu com a classificação do cliente (comentário 12), o texto do comentário também poderia gerar dúvidas a um analista humano.

No comentário 12, o cliente escreveu: “Um arroz maravilhoso, atendimento excelente e uma vista maravilhosa. Recomendo. Uma agradável surpresa à beira-mar.”, mas atribuiu uma classificação de 4 estrelas. Dado que o texto subentende uma satisfação total, com elogios à comida, atendimento e vista, um

analista humano poderia igualmente interpretar o comentário como sendo digno de 5 estrelas, dado o tom positivo e a recomendação expressa. No entanto, o utilizador optou por uma classificação ligeiramente inferior, talvez por algum fator não explicitado no comentário.

Este exemplo demonstra que, embora haja *nuances* que possam influenciar a classificação final, a máquina mostrou uma capacidade robusta de interpretação do texto e sentimento, que se aproxima bastante do julgamento humano em análises desse tipo.

Com base nessa confiança na capacidade do programa em substituir o humano para a análise de sentimento, passou-se para uma análise mais detalhada, focando cada uma das dimensões previamente definidas no modelo de avaliação.

3.4.2. Obtenção da classificação por dimensão do referencial

Com base no *prompt* utilizado, os resultados para cada uma das dimensões de análise foram obtidos e analisados. Verificou-se que, em muitos casos, algumas dimensões ficaram por classificar. Isto ocorre porque, naturalmente, os comentários dos clientes nem sempre abordam todos os aspetos da experiência do restaurante. Por exemplo, um cliente que destaca o serviço pode não mencionar a localização, o ambiente ou a decoração.

Tabela 9.

Tabela com as classificações dadas pela máquina, por dimensão do modelo de análise.

Comentário	Classificação	Classificação pela máquina	Tangibilidade	Confiabilidade	Responsividade	Segurança	Empatia
1)	2	2	-	2	2	-	-
2)	1	1	1	1	1	1	1
3)	1	1	-	1	1	-	1
4)	1	1	-	1	1	-	1
5)	5	5	5	5	5	5	5
6)	5	5	5	5	5	5	5
7)	2	2	2	2	-	-	2
8)	3	3	5	3	2	-	-
9)	5	5	5	5	5	-	5
10)	1	1	3	1	1	-	1
11)	1	1	2	1	1	-	1
12)	4	5	5	5	5	-	5
13)	3	3	4	2	2	-	3
14)	5	5	5	5	5	-	5
15)	2	2	2	2	1	2	1

Notou-se, em particular, que poucos comentários da amostra forneceram informações suficientes para classificar a dimensão Segurança, que está relacionada com o treino da equipa e a sua capacidade de fornecer informações precisas sobre o serviço e produtos. Esta lacuna depende, essencialmente, do conteúdo do comentário escrito pelo cliente, que pode omitir aspetos que não considerou relevantes na sua experiência.

Dado este cenário, o próximo passo será explorar um maior aperfeiçoamento do *prompt* utilizado para analisar os comentários, procurando identificar atributos específicos que possam distinguir de forma mais clara cada uma das dimensões de análise. Isso permitirá uma classificação mais completa e precisa, mesmo quando os comentários não mencionam explicitamente todos os aspetos esperados.

3.4.3. Estabelecer atributos para o referencial

De acordo com Stevens (Stevens et al., 1995), o modelo DINESERV tem como objetivo recolher informações específicas através de questionários aplicados pessoalmente e de imediato após a refeição, para captar todos os aspetos da experiência do cliente. No entanto, os comentários espontâneos gerados por clientes não seguem esse mesmo nível de detalhe. Observa-se que os clientes se concentram apenas em alguns aspetos da sua experiência, como nos seguintes exemplos:

1. **Comentário conciso:** *“Péssimo serviço. Tempo de espera quase 1h com a sala vazia. Demoraram 10 minutos após pedido, para dizer que não havia o que tinha sido pedido. Comida sofrível.”;*
2. **Comentário abrangente:** *“Somos clientes habituais deste restaurante há muitos anos e é, sem dúvida, um dos melhores que conhecemos, contudo tem falhas que prejudicam a sua boa imagem: 1. Fora do mês de Agosto é 5***** 2. Em Agosto é uma 'desgraça' porque: a) mantêm o mesmo pessoal e o restaurante, porque está sempre cheio, não consegue dar resposta. b) tempos de espera intermináveis. c) quem não reservar com antecedência não tem lugar... 3. O proprietário é extremamente simpático e disponível mas não consegue fazer milagres, talvez só limitando o número de clientes mas também entendo que têm que aproveitar o verão para facturar, ainda para mais depois do início desta pandemia. E aumentaram recentemente, de forma significativa, o número de mesas. 4. A qualidade da comida, seja peixe, seja carne, seja marisco, seja o que for, é irrepreensível. Apenas um senão, os menus infantis deixam muito a desejar e não dignificam o restaurante (hambúrguer congelado da IGLO!!!???). Daí a nossa classificação: Agosto 1*, fora de Agosto 5*****, na média são 3***.”.*

Nos dois exemplos, podemos sugerir os seguintes atributos de análise:

- Serviço;

- Comida;
- Tempos de espera;
- Atendimento.

Em ambos os casos, não houve menção a outros aspetos, como preço ou pedidos especiais. No entanto, esta pequena amostra não permite captar a variedade completa de atributos que os comentários podem conter.

Dada a incerteza sobre quais os melhores atributos para analisar comentários, foi necessário recorrer à literatura para identificar um conjunto mais abrangente de atributos que ajudem a interpretar os sentimentos expressos. A pesquisa de Choi et al., (2009), que entrevistou 290 consumidores na Flórida, EUA, revelou os 10 atributos mais relevantes na escolha de um restaurante. Essa pesquisa serviu de base para associar os atributos identificados às dimensões e critérios refinados do modelo DINESERV aplicados nesta pesquisa.

Tabela 10.

Os 10 atributos resultantes da pesquisa dos autores e correspondência com outras publicações.

Atributos	Johns & Howard	Kivela et al.	Cullen	Barta	Yuksel & Yuksel
Taste of the food	Yes	Yes	Yes	Yes	Yes
Food Portion	Yes	No	Yes	No	Yes
Service	Yes	Yes	Yes	No	Yes
Price	Yes	No	Yes	No	Yes
Ambience/atmosphere	Yes	No	Yes	Yes	Yes
Presentation of food	Yes	Yes	No	No	No
Nutritious food	Yes	No	No	No	Yes
Reputation of the restaurant	No	No	Yes	No	No
Cleanliness	Yes	Yes	Yes	No	Yes
Variety of healthy meals	No	No	No	No	Yes

(Choi et al., 2009, p.4)

Após testar a capacidade do ChatGPT (modelo 3.5) na análise de sentimentos, conforme demonstrado pela sua precisão na correspondência com a classificação humana, verificou-se que este modelo é suficientemente confiável para interpretar comentários e mapear as informações de acordo com os critérios atribuídos. Neste contexto, estão reunidas as condições para que o modelo possa ser utilizado eficazmente para analisar e extrair sentimentos a partir de comentários, respeitando os atributos e dimensões previamente definidos.

3.4.4. Associação dos 10 atributos às dimensões

Uma vez estabelecidos os atributos de base, procedeu-se à associação desses atributos às dimensões previamente definidas, utilizando as capacidades do modelo de linguagem mencionado. Para isso, foi dado ao programa o seguinte *prompt*:

“

Tu és um analista de sentimento que lê comentários de restaurantes e classifica atributos com base na experiência do cliente, numa escala de 1 a 5, em que 1 é muito insatisfeito e 5 muito satisfeito.

A tua análise é feita com base em 5 dimensões:

- 1) Tangibilidade - que se refere às instalações físicas, equipamentos e aparência do pessoal, a qualidade e a manutenção das instalações, a modernidade e a funcionalidade dos equipamentos, assim como a apresentação dos funcionários e do menu;
- 2) Confiabilidade - que concerne à capacidade de executar o serviço prometido, incluindo a precisão da entrega de pedidos, a consistência e sabor dos pratos servidos em diferentes momentos e a capacidade de cumprir com os tempos de espera anunciados;
- 3) Responsividade - Esta dimensão é também associada ao termo Sensibilidade. Aqui, pretende-se verificar aspectos como o serviço é prestado por parte dos funcionários. Procura-se verificar se estes estão disponíveis e são sensíveis às necessidades dos clientes, prestando um serviço atencioso, rápido e também personalizado;

- 4) Segurança - A dimensão Segurança procura englobar os fatores que sejam relativos à forma como o cliente se sente num restaurante, nomeadamente se sente que o staff é capaz de prestar informações precisas sobre o menu, que é acessível e que demonstra experiência na operação;
- 5) Empatia - A dimensão Empatia demonstra critérios de avaliação similares, na sua essência, aos da dimensão Segurança. Embora de perspectivas diferentes, ambos abordam aspectos comportamentais da equipa, como a sua sensibilidade e capacidade de antecipação das necessidades dos clientes, assim como resolução de problemas.

Em baixo, estão atributos que tens de relacionar com as dimensões. Caso não tenhas uma relação que consideres muito forte, não atribuas e indica qual é:

1. Sabor da comida
2. Porção de comida
3. Serviço
4. Preço
5. Ambiente/atmosfera
6. Apresentação da comida
7. Comida nutritiva
8. Reputação do restaurante
9. Limpeza
10. Variedade de refeições saudáveis

Organiza uma tabela que tenha 1 coluna para a Dimensão, 1 que tenha os critérios de cada dimensão, chamada "Novos Critérios" e uma coluna para os atributos."

Resultado obtido:

Tabela 11.

Tabela com os atributos relacionados com as dimensões.

Dimensão	Novos Critérios	Atributos Associados
Tangibilidade	Instalações físicas, equipamentos, aparência do pessoal	5. Ambiente/atmosfera 9. Limpeza
Confiabilidade	Capacidade de executar o serviço prometido, precisão na entrega	1. Sabor da comida 2. Porção de comida
Responsividade	Disponibilidade e sensibilidade às necessidades dos clientes	3. Serviço
Segurança	Informações precisas sobre o menu, acessibilidade	7. Comida nutritiva
Empatia	Antecipação das necessidades dos clientes, resolução de problemas	6. Apresentação da comida

Como se pode verificar, os atributos 4. Preço, 8. Reputação do restaurante e 10. Variedade de refeições saudáveis não foram associados a nenhuma das dimensões estabelecidas. Isto pode ser explicado pelo facto de que, embora existam alguns atributos que são transversalmente aceites na literatura, as propostas feitas por diferentes investigadores variam entre si.

Por exemplo, a tabela 10 é o resultado de uma investigação que comparou e estabilizou os atributos mais relevantes na escolha de um restaurante. Dada a complexidade de definir um modelo universal, optou-se por prosseguir com os dez atributos propostos por Choi et al. (2009, p.4), mesmo que três deles não se alinhem diretamente com o modelo DINESERV.

A descrição dos atributos tem como objetivo clarificar o que cada um deles pretende captar na análise de sentimento dos comentários dos clientes. Estes atributos, propostos por Choi et al., abrangem os principais aspetos que influenciam a escolha de um restaurante, desde a qualidade da comida (avaliada pelo sabor, porção e apresentação dos pratos), até à experiência global do cliente (serviço, ambiente, preço e reputação). Além disso, incluem-se critérios mais específicos, como a nutrição e a variedade de refeições saudáveis, que refletem preocupações

com a saúde e opções alimentares equilibradas. A limpeza também é um fator crucial, assegurando a higiene e conforto do espaço. Estes atributos formam a base para uma análise detalhada e segmentada, facilitando a avaliação precisa da experiência de cada cliente.

Descrição dos atributos:

Tabela 12.

Tabela com o que cada atributo pretende capturar, de acordo com os autores.

Atributo	Descrição
1. Sabor da Comida	Avalia a qualidade do sabor dos alimentos, incluindo autenticidade e equilíbrio de ingredientes.
2. Porção de Comida	Refere-se à quantidade servida, considerando adequação ao preço e expectativas.
3. Serviço	Procura rapidez, eficiência, cordialidade e profissionalismo dos empregados.
4. Preço	Avalia a adequação dos preços à qualidade dos pratos e ao serviço.
5. Ambiente/Atmosfera	Considera a decoração, iluminação, música e a disposição do espaço.
6. Apresentação da Comida	Observa a preparação visual, cuidado e criatividade na apresentação dos pratos.
7. Comida Nutritiva	Analisa a qualidade nutritiva das opções alimentares, como o uso de ingredientes frescos e os métodos de preparação.
8. Reputação do Restaurante	Baseia-se em críticas, recomendações, prémios recebidos e conhecimento público do restaurante.
9. Limpeza	Avalia a higiene do restaurante, incluindo as áreas de refeição e de preparação de alimentos.
10. Variedade de Refeições Saudáveis	Mede a diversidade de opções saudáveis disponíveis no menu, assim como outras alternativas do menu.

(Choi et al., 2009, p.4)

Com estes atributos estabilizados, torna-se relevante estabelecer as palavras-chave que refletem os mesmos.

3.4.5. Estabelecer palavras-chave para os atributos do modelo

Como podemos constatar, dos dez atributos propostos por Choi et al (2009, p.4), apenas o 1. Sabor da comida é transversalmente aceite por todos os investigadores consultados no estudo. Dado que existe dificuldade em estabilizar os atributos considerados ideais, foi decidido aceitar esta proposta do autor para avançar com a análise.

Utilizando uma amostra de 1.000 comentários fornecidos pela DIG-IN, procedeu-se à contabilização da incidência de cada atributo nos textos. Esta amostra foi composta por comentários aleatórios retirados de um dataset maior, que inclui restaurantes com mais de 1.000 classificações. Com base nos dez atributos propostos, isolamos palavras-chave que pudessem identificar cada um dos atributos de forma precisa.

Para a obtenção das palavras-chave, foi utilizado o seguinte *prompt*:

“

Tu és um analista de sentimentos que lê comentários de restaurantes e classifica atributos com base na experiência do cliente.

Nesta tarefa, tens de te focar nos 10 atributos que estão em baixo e identificar, nos 1000 comentários que estão no ficheiro em anexo, as palavras-chave ideias para melhor capturar cada um dos atributos.

Os comentários estão escritos em português de Portugal, pelo que deves encontrar palavras-chave desse idioma.

1. Sabor da comida - Avalia a qualidade do sabor dos alimentos, incluindo autenticidade e equilíbrio de ingredientes.

2. Porção de comida - Refere-se à quantidade servida, considerando adequação ao preço e expectativas.

3. Serviço - Procura rapidez, eficiência, cordialidade e profissionalismo dos empregados.

4. Preço - Avalia a adequação dos preços à qualidade dos pratos e ao serviço.

5. Ambiente/atmosfera - Considera a decoração, iluminação, música e a disposição do espaço.

6. Apresentação da comida - Observa a preparação visual, cuidado e criatividade na apresentação dos pratos.

7. Comida nutritiva - Analisa a qualidade nutritiva das opções alimentares, como o uso de ingredientes frescos e os métodos de preparação.

8. Reputação do restaurante - Baseia-se em críticas, recomendações, prémios recebidos e conhecimento público do restaurante.

9. Limpeza - Avalia a higiene do restaurante, incluindo as áreas de refeição e de preparação de alimentos.

10. Variedade de refeições saudáveis - Mede a diversidade de opções saudáveis disponíveis no menu, assim como outras alternativas do menu.

Depois de descritas as palavras-chave para cada atributo, quero que contabilizes a incidência de cada atributo nos comentários.

Organiza uma tabela que tenha 1 coluna para os atributos, 1 coluna para as palavras-chave identificadas e 1 coluna para a quantidade de vezes que identificas os atributos nos comentários.

”

O resultado obtido foi o seguinte:

Tabela 13.

Tabela com as palavras-chave, por atributo, e respectiva contagem.

Atributo	Palavras-chave	Contagem
1. Sabor da comida	saboroso, delicioso, tempero, autêntico, gostoso, equilibrado	112
2. Porção de comida	porção, quantidade, suficiente, generoso, grande	119
3. Serviço	atendimento, rápido, eficiente, cordial, amigável, profissional	312
4. Preço	preço, custo, caro, barato, acessível	264
5. Ambiente/atmosfera	ambiente, atmosfera, aconchegante, decoração, iluminação, música	217
6. Apresentação da comida	apresentação, visual, montagem, criativo, decorado	45
7. Comida nutritiva	nutritivo, saudável, fresco, natural, ingredientes	98
8. Reputação do restaurante	famoso, recomendado, premiado, conhecido, reputação	19
9. Limpeza	limpo, higiénico, asseado, limpeza	7
10. Variedade de refeições saudáveis	variedade, opções saudáveis, menu saudável, alternativas	53

Ao observar os resultados, verificamos que algumas palavras-chave surgem com maior frequência do que outras. Este padrão reflete a tendência dos consumidores em focar o seu feedback em aspetos mais comuns, como comida, serviço e preço. A incidência de palavras associadas a atributos como Sabor da comida, Serviço, Preço e Ambiente/atmosfera é notavelmente maior, indicando a centralidade desses aspetos nas experiências dos clientes.

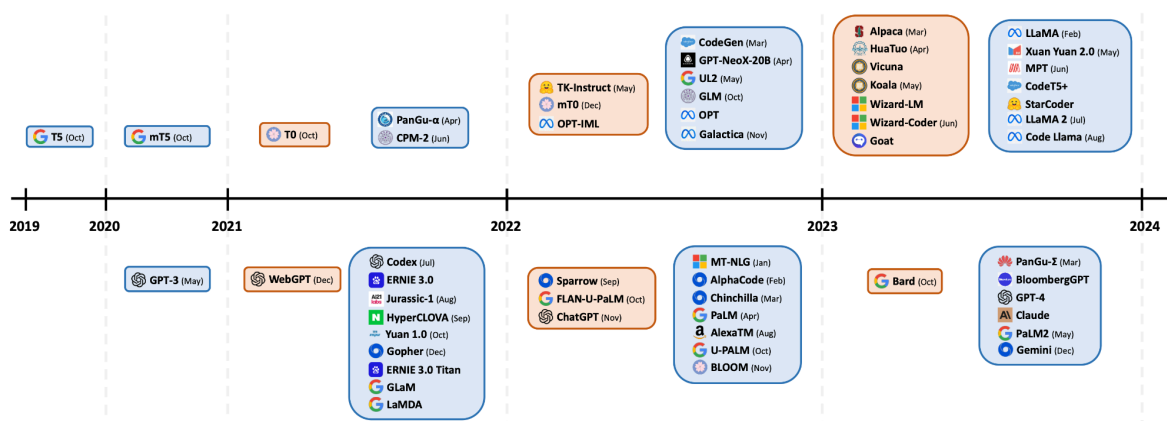
Por outro lado, os atributos Reputação do restaurante e Limpeza aparecem com muito menor frequência, sendo representados por um número mais reduzido de comentários. No entanto, dado que a amostra utilizada conta com apenas 1.000 comentários, decidiu-se manter todos os atributos propostos, de forma a assegurar uma análise abrangente.

A análise total abrange um conjunto de 474.470 comentários escritos, prontos para serem processados. Fazendo uma projeção proporcional, verificamos que o atributo com menor representatividade, Limpeza, corresponde a 0,7% da amostra. Mesmo assim, optou-se por manter todos os atributos, incluindo os menos representados, como a Reputação do restaurante, para garantir uma análise completa ao longo desta investigação.

3.5. Modelos para a análise de sentimento aos comentários

Atualmente, existe uma ampla disponibilidade de diferentes LLMs no mercado, cada um oferecendo diferentes níveis de performance e acessibilidade. Conforme proposto no início desta dissertação, a análise de sentimento será realizada utilizando os modelos da OpenAI, nomeadamente o ChatGPT.

Figura 21.
Cronologia de *Large Language Models* no mercado.



(Naveed et al., 2023, p.2)

Para o processamento dos dados, utilizou-se uma plataforma que facilita a integração de diferentes LLMs, a openrouter.ai, que oferece uma interface simplificada para selecionar e utilizar diversos modelos através de uma API de fácil integração. Este método permitiu o uso simultâneo de vários modelos, ajustando a escolha com base no desempenho e nos custos.

Após a avaliação dos diferentes modelos disponíveis, a escolha recaiu sobre os seguintes:

- **ChatGPT 3.5 Turbo** ("openai/gpt-3.5-turbo"): um modelo pago, selecionado pela sua eficiência e custo relativamente acessível;
- **ChatGPT 4o_2024-05-13** ("openai/gpt-4o-2024-05-13"): também um modelo pago, reconhecido pela sua alta precisão em tarefas complexas;
- **Mistral 7B Instruct (Free)** ("mistralai/mistral-7b-instruct"): um modelo gratuito que, nas amostras testadas, demonstrou boa performance comparável a modelos pagos, tornando-o uma alternativa viável para determinadas tarefas.

Com estas opções, foi possível equilibrar a relação entre custo e desempenho, assegurando que o processamento dos dados fosse eficiente, mantendo a qualidade da análise de sentimento realizada.

3.5.1. Aferindo-se a precisão dos modelos - Classificação geral pelo cliente vs. classificação geral pelos modelos

Após a seleção dos modelos, que irão processar os 4.464 comentários da categoria "Italian", atribuindo classificações aos dez atributos definidos (tabela 10), foi realizada uma análise preliminar para aferir a precisão dos modelos. Para isso, foram selecionados 20 comentários aleatórios do dataset previamente apresentado, sem que o modelo tivesse acesso à classificação dada pelo cliente.

A análise foi feita com base num *prompt* gerado a partir dos parâmetros estabelecidos até este ponto. Abaixo apresenta-se o *prompt* utilizado:

“

Tu és um avaliador de reviews de restaurantes.

Objetivo: Classificar a experiência em restaurantes com base em comentários escritos por utilizadores.

Atributos de Avaliação:

1. Sabor da Comida: Avalia a qualidade do sabor dos alimentos, incluindo autenticidade e equilíbrio de ingredientes;
2. Porção de Comida: Refere-se à quantidade servida, considerando adequação ao preço e expectativas;
3. Serviço: Procura rapidez, eficiência, cordialidade e profissionalismo dos empregados;
4. Preço: Avalia a adequação dos preços à qualidade dos pratos e ao serviço;
5. Ambiente/Atmosfera: Considera a decoração, iluminação, música e a disposição do espaço;
6. Apresentação da Comida: Observa a preparação visual, cuidado e criatividade na apresentação dos pratos;
7. Comida Nutritiva: Analisa a qualidade nutritiva das opções alimentares, como o uso de ingredientes frescos e os métodos de preparação;
8. Reputação do Restaurante: Baseia-se em críticas, recomendações, prémios recebidos e conhecimento público do restaurante;
9. Limpeza: Avalia a higiene do restaurante, incluindo as áreas de refeição e de preparação de alimentos;
10. Variedade de Refeições Saudáveis: Mede a diversidade de opções saudáveis disponíveis no menu, assim como outras alternativas do menu.

Lê cada review cuidadosamente e tem em consideração as palavras-chave referentes a cada atributo:

1. Sabor da comida: saboroso, delicioso, tempero, autêntico, gostoso, equilibrado;
2. Porção de comida: porção, quantidade, suficiente, generoso, grande;
3. Serviço: atendimento, rápido, eficiente, cordial, amigável, profissional;
4. Preço: preço, custo, caro, barato, acessível;
5. Ambiente/atmosfera: ambiente, atmosfera, aconchegante, decoração, iluminação, música;
6. Apresentação da comida: apresentação, visual, montagem, criativo, decorado;
7. Comida nutritiva: nutritivo, saudável, fresco, natural, ingredientes;

8. Reputação do restaurante: famoso, recomendado, premiado, conhecido, reputação;

9. Limpeza: limpo, higiénico, asseado, limpeza;

10. Variedade de refeições saudáveis: variedade, opções saudáveis, menu saudável, alternativas.

Instruções:

- Utiliza os adjetivos mencionados no comentário para ajudar a inferir o nível de satisfação em cada atributo;

- Atribui uma classificação de 1 a 5 para cada um dos critérios listados, baseando-se nas descrições fornecidas no comentário;

- Caso não identifiques palavras que permitam classificar um atributo, coloca N/A.

Formato de Saída Esperado:

Sabor da Comida: <classificação>

Porção de Comida: <classificação>

Serviço: <classificação>

Preço: <classificação>

Ambiente/Atmosfera: <classificação>

Apresentação da Comida: <classificação>

Comida Nutritiva: <classificação>

Reputação do Restaurante: <classificação>

Limpeza: <classificação>

Variedade de Refeições Saudáveis: <classificação>

”

Resultados obtidos com o modelo ChatGPT 3.5 Turbo

("openai/gpt-3.5-turbo"):

Tabela 14.

Tabela (parte 1) com as classificações dos atributos feitas pelo LLM *ChatGPT* 3.5 Turbo.

Comentário	1	2	3	4	5	6	7	8	9	10
Classificação pelo Cliente	3.0	1.0	2.0	2.5	2.5	3.0	4.5	4.5	3.5	2.0
Média dos Atributos (arredondada)	3.0	1.0	2.0	2.0	4.0	3.5	3.5	5.0	4.0	3.0
Sabor da Comida	4	N/A	N/A	3	3	3	5	5	4	4
Porção de Comida	N/A	N/A	N/A	2	4	2	N/A	N/A	N/A	N/A
Serviço	2	1	2	2	5	5	3	5	N/A	3
Preço	N/A	N/A	N/A	2	4	2	4	4	5	4
Ambiente/ Atmosfera	4	N/A	N/A	N/A	N/A	4	2	5	N/A	3
Apresentação da Comida	N/A	N/A	N/A	N/A	5	3	N/A	N/A	N/A	N/A
Comida Nutritiva	N/A	N/A	N/A	N/A	N/A	3	N/A	N/A	N/A	N/A
Reputação do Restaurante	N/A	1	2	2	4	5	3	5	4	3
Limpeza	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	2
Variedade de Refeições Saudáveis	N/A	N/A	N/A	N/A	N/A	N/A	4	N/A	N/A	N/A

Tabela 15.

 Tabela (parte 2) com as classificações dos atributos feitas pelo LLM *ChatGPT 3.5 Turbo*.

Comentário	11	12	13	14	15	16	17	18	19	20
Classificação pelo Cliente	5.0	3.0	3.5	3.5	3.0	3.5	4.0	4.5	3.5	4.0
Média dos Atributos (arredondada)	4.5	3.5	3.0	5.0	3.5	4.0	4.5	4.5	4.5	4.0
Sabor da Comida	4	4	2	N/A	4	N/A	5	4	4	4
Porção de Comida	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	5
Serviço	5	N/A	N/A	5	4	N/A	N/A	5	5	3
Preço	N/A	5	N/A	5	2	N/A	4	N/A	5	4
Ambiente/Atmosfera	5	N/A	4	N/A	2	4	5	N/A	4	5
Apresentação da Comida	N/A	2	3	N/A	N/A	N/A	N/A	N/A	N/A	N/A
Comida Nutritiva	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
Reputação do Restaurante	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
Limpeza	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
Variedade de Refeições Saudáveis	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A

Embora o objetivo desta análise preliminar não seja o de garantir que a máquina obtenha classificações idênticas às dos clientes, considera-se importante realizar testes para avaliar a capacidade dos modelos em gerar classificações coerentes. Na análise de 20 comentários aleatórios com o modelo *ChatGPT 3.5 Turbo*, foi identificado um caso em que a discrepância entre a classificação do cliente e a da máquina foi significativa. Trata-se do comentário 5, onde o cliente atribuiu uma classificação de 2.5, enquanto o modelo calculou uma média de 4.0 com base nos atributos avaliados.

Comentário 5

“Almoço de semana, ainda cedo. E ainda bem porque pelas 13h a casa já abarrotava pela sala grande até à esplanada. Optámos por 2 rodízios e um chá gelado, trazidos prontíssimo e com simpatia. Uma sopa de miso simplezinha e uma entrada dum rolo frito com queijo filadélfia, Seguiu-se o prato com 40 peças, bem apresentadas, bonitinhas e mais do que suficientes em quantidade. Tudo bem portanto, não fosse a epifania negativa - se é que tal coisa existe - que me aconteceu mesmo a meio da refeição: a de que detesto e jamais voltarei a comer sushi de fusão! Mesmo tendo tirado delicadamente, com os pauzinhos, todos os bocadinhos de morango e kiwi e queijo e maionese que consegui, tipo nojentinha, o sabor adocicado e gordurento que se sobrepõe a tudo estraga completamente o sushi, ao ponto de já não ser digno de tal nome. Isto sou eu, já se sabe. Mas quem gostar do género, terá aqui um almoço simpático e em conta.”

O comentário expressa uma mistura de sentimentos positivos e negativos:

- **Positivos:** A quantidade de comida foi considerada adequada, o serviço foi rápido e simpático, e o custo-benefício foi visto como positivo;
- **Negativos:** O sabor da comida, mais especificamente do sushi de fusão, foi descrito de forma muito negativa, com o cliente expressando uma forte aversão ao estilo de preparação.

A disparidade entre a classificação final da máquina e a do cliente pode ser explicada pela subjetividade da experiência gastronómica descrita. Embora o cliente tenha dado uma nota global negativa (2.5), o modelo de linguagem baseou-se na avaliação de atributos específicos, como a quantidade de comida e o serviço, que foram mencionados positivamente, resultando numa média mais elevada (4.0).

Agora, no que respeita aos resultados com o modelo ChatGPT 4o_2024-05-13

("openai/gpt-4o-2024-05-13"), obteve-se o seguinte:

Tabela 16.

Tabela (parte 1) com as classificações dos atributos feitas pelo LLM *ChatGPT* 4o_2024-05-13.

Comentário	1	2	3	4	5	6	7	8	9	10
Classificação pelo Cliente	3.0	1.0	2.0	2.5	2.5	3.0	4.5	4.5	3.5	2.0
Média dos Atributos (arredondada)	3.0	1.0	1.0	2.0	3.0	3.0	3.5	4.0	4.0	3.0
Sabor da Comida	4	N/A	1	3	2	4	5	4	5	4
Porção de Comida	N/A	N/A	N/A	2	4	2	4	N/A	N/A	4
Serviço	2	1	1	2	4	4	4	5	N/A	2
Preço	N/A	N/A	N/A	3	4	2	5	4	4	4
Ambiente/Atmosfera	4	N/A	N/A	N/A	3	3	2	5	N/A	4
Apresentação da Comida	N/A	N/A	N/A	2	4	2	4	N/A	N/A	N/A
Comida Nutritiva	N/A	N/A	N/A	N/A	N/A	N/A	N/A	4	N/A	N/A
Reputação do Restaurante	N/A	1	N/A	N/A	N/A	4	N/A	N/A	3	N/A
Limpeza	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	2
Variedade de Refeições Saudáveis	N/A	N/A	N/A	N/A	N/A	N/A	4	4	N/A	N/A

Tabela 17.

Tabela (parte 2) com as classificações dos atributos feitas pelo LLM *ChatGPT* 4o_2024-05-13.

Comentário	11	12	13	14	15	16	17	18	19	20
Classificação pelo Cliente	5.0	3.0	3.5	3.5	3.0	3.5	4.0	4.5	3.5	4.0
Média dos Atributos (arredondada)	5.0	3.0	3.0	4.5	2.5	3.5	4.5	5.0	4.0	3.5
Sabor da Comida	4	4	2	N/A	4	4	5	N/A	4	4
Porção de Comida	N/A	N/A	N/A	5	N/A	N/A	N/A	5	N/A	4
Serviço	5	N/A	N/A	4	4	N/A	N/A	N/A	4	3
Preço	N/A	4	N/A	N/A	1	N/A	3	N/A	4	4
Ambiente/Atmosfera	5	N/A	4	N/A	1	3	5	N/A	4	4
Apresentação da Comida	N/A	2	3	N/A	N/A	N/A	N/A	N/A	N/A	3
Comida Nutritiva	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
Reputação do Restaurante	N/A	N/A	N/A	N/A	N/A	N/A	4	N/A	4	N/A
Limpeza	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A
Variedade de Refeições Saudáveis	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	N/A	3

Os resultados obtidos com o modelo ChatGPT 4o_2024-05-13 não apresentaram discrepâncias relevantes. No geral, a máquina classificou os comentários de forma muito semelhante à dos clientes, demonstrando boa precisão.

Relativamente ao modelo Mistral 7B Instruct (Free)

("mistralai/mistral-7b-instruct:free"), obteve-se o seguinte:

Tabela 18.

Tabela (parte 1) com as classificações dos atributos feitas pelo LLM Mistral 7B Instruct (Free).

Comentário	1	2	3	4	5	6	7	8	9	10
Classificação pelo Cliente	3.0	1.0	2.0	2.5	2.5	3.0	4.5	4.5	3.5	2.0
Média dos Atributos (arredondada)	N/A	2.0	N/A	2.5	4.0	N/A	3.5	4.0	4.0	2.0
Sabor da Comida	N/A	3	N/A	3	2	N/A	5	4	5	N/A
Porção de Comida	N/A	2	N/A	2	5	N/A	3	4	5	2
Serviço	N/A	1	N/A	2	4	N/A	3	5	N/A	N/A
Preço	N/A	N/A	N/A	3	3	N/A	4	4	5	N/A
Ambiente/Atmosfera	N/A	N/A	N/A	4	4	N/A	2	5	3	N/A
Apresentação da Comida	N/A	N/A	N/A	2	4	N/A	4	4	5	N/A
Comida Nutritiva	N/A	N/A	N/A	3	N/A	N/A	4	3	3	N/A
Reputação do Restaurante	N/A	3	N/A	N/A	4	N/A	4	N/A	4	N/A
Limpeza	N/A	1	N/A	N/A	4	N/A	4	5	N/A	N/A
Variedade de Refeições Saudáveis	N/A	N/A	N/A	N/A	N/A	N/A	4	4	3	N/A

Tabela 19.

Tabela (parte 2) com as classificações dos atributos feitas pelo LLM Mistral 7B Instruct (Free).

Id do comentário	11	12	13	14	15	16	17	18	19	20
Classificação pelo Cliente	5.0	3.0	3.5	3.5	3.0	3.5	4.0	4.5	3.5	4.0
Média dos Atributos (arredondada)	4.5	4.0	2.5	N/A	3.0	N/A	N/A	4.0	4.0	4.0
Sabor da Comida	4	5	2	N/A	4	N/A	N/A	5	4	4
Porção de Comida	N/A	N/A	3	N/A	4	N/A	N/A	N/A	4	5
Serviço	5	5	N/A	N/A	4	N/A	N/A	5	5	3
Preço	N/A	4	N/A	N/A	2	N/A	N/A	4	4	4
Ambiente/Atmosfera	4	N/A	3	N/A	1	N/A	N/A	N/A	4	4
Apresentação da Comida	N/A	N/A	2	N/A	3	N/A	N/A	4	4	4
Comida Nutritiva	N/A	5	N/A	N/A	N/A	N/A	N/A	3	3	3
Reputação do Restaurante	N/A	3	N/A	N/A	3	N/A	N/A	5	4	N/A
Limpeza	4	4	N/A	N/A	N/A	N/A	N/A	5	4	4
Variedade de Refeições Saudáveis	N/A	2	N/A	N/A	N/A	N/A	N/A	N/A	3	4

Quanto ao modelo Mistral 7B Instruct (Free), verificou-se que este não foi capaz de classificar nenhum dos dez atributos em 6 dos 20 comentários, classificando assim 70,0% da amostra. Dois dos comentários com diferenças relevantes foram o 5, já transcrito anteriormente, e o 13.

Comentário 5

(Transcrito anteriormente na página 74)

O cliente deu uma classificação de 2.5, enquanto o modelo gerou uma média de 4.0. Embora a comida tenha sido avaliada negativamente, o modelo interpretou de forma positiva o serviço, preço e apresentação da comida, além de ter inferido positivamente sobre o ambiente e reputação, com base nas menções à sala cheia. A análise revela uma subjetividade que pode também ocorrer entre humanos.

Comentário 13

"O espaço está muito giro e é um sitio excelente para um jantar descontraido. A ideia da tábua, como base para servir a refeição, é engraçada mas muito pouco funcional. é muito estrateita, difícil pousar os talheres para um pausa e para comer. Em relação ao sabor dos hambúrgueres, confesso que esperava melhor. Achei-o um pouco sem sabor". Molhos a acompanhar as batatas bons ;)"

O cliente atribuiu uma classificação de 3.5, enquanto o modelo gerou uma média de 2.5. O modelo interpretou o sabor dos hambúrgueres como um 2, apesar de existirem elementos mencionados positivamente. A subjetividade da análise entre modelos e humanos é novamente evidente.

Apesar dessas diferenças, constatou-se que a média dos atributos classificados pelos modelos foi geralmente próxima da classificação geral atribuída pelos clientes, demonstrando a capacidade dos LLMs em alinhar suas avaliações com as percepções humanas.

3.5.2. Aferindo-se a concordância na classificação dos atributos, entre modelos


Partindo-se para a análise da classificação dos atributos, procedeu-se à avaliação da concordância entre os três modelos. Para isso, foram estabelecidas as seguintes condições para que haja concordância:

- **Polaridade negativa:** Classificações de 1 e 2 são consideradas como negativas;
- **Polaridade positiva:** Classificações de 3, 4 e 5 são consideradas como positivas;
- **Concordância de polaridade:** Os modelos concordam que o atributo é mencionado no texto e classificam-no com a mesma polaridade (positiva ou negativa);
- **Concordância de ausência:** Os modelos concordam que o atributo não é mencionado no texto e, portanto, não atribuem qualquer classificação ao atributo.

Este critério foi aplicado para verificar o alinhamento das análises entre os modelos e para garantir consistência nas avaliações dos atributos mencionados nos comentários.

Figura 22.

Taxa de concordância entre os modelos para cada atributo.



Na análise de 20 comentários (n=20), verificou-se concordância de 80,0% ou mais em cinco dos dez atributos: Sabor da comida, Serviço, Preço, Ambiente/atmosfera e Variedade de refeições saudáveis. Esta concordância reflete a prevalência das palavras-chave mencionadas anteriormente. Entre avaliadores humanos, a concordância pode variar entre 83,0% e 92,0%, de acordo com Carrasco e Dias, (2024). Por último, o atributo com menor concordância foi a Porção da comida (55,0%).

Estes resultados sugerem que, nos cinco atributos com alta concordância, os modelos identificam e classificam de forma semelhante aos clientes. Nos restantes, a menor concordância pode indicar fraca performance dos modelos ou necessidade de revisão das palavras-chave.

Para aprofundar a análise e comparar a concordância entre humano e máquina, procedeu-se à classificação de uma nova amostra aleatória de 100 comentários (n=100), analisados tanto por um avaliador humano quanto pelos três modelos. Esta comparação visa avaliar a concordância na identificação e classificação dos dez atributos, tomando o julgamento humano como referência.

3.5.3. Aferindo-se a concordância na classificação dos atributos, entre humano e modelos

A concordância é um fator importante para avaliar a capacidade dos modelos em realizar análises de sentimento de forma semelhante aos humanos. Essencialmente, esta concordância indica se a identificação e classificação dos atributos são consistentes entre o modelo e o humano, que aqui serve de referência.

O objetivo não é atingir uma concordância absoluta, já que, como observado, mesmo entre humanos esta raramente é perfeita. Em vez disso, pretende-se avaliar se o modelo e o humano concordam na forma de identificar e classificar cada atributo em cada comentário.

Para esta análise, foi utilizada uma amostra aleatória de 100 comentários (n=100), interpretada e classificada por um avaliador humano e pelos três modelos. As condições para haver concordância foram lembradas:

- Classificações de 1 e 2 indicam polaridade negativa;
- Classificações de 3, 4 e 5 indicam polaridade positiva;
- Concordância ocorre quando os modelos e o humano identificam o mesmo atributo e classificam com a mesma polaridade;
- Concordância também ocorre quando ambos concordam que o atributo não está presente no texto e não o classificam.

Conforme demonstrado na figura 22, os modelos alcançaram uma concordância geral de 72,0% entre si na identificação e classificação dos atributos. A mesma abordagem foi utilizada para comparar os resultados dos três modelos com o julgamento humano nesta nova amostra (n=100).

Para ilustrar, vejamos o exemplo 1:

Comentário da base de dados com o id 4089353

“Uma das coisas que mais gosto é de conhecer novos restaurantes, por isso quando recebi um convite para conhecer este restaurante, em que tudo é italiano e preparado por italianos, não pude recusar! Começando pela localização, encontra-se mesmo em frente às escadarias da Assembleia da República, tem um pequeno agradável pátio com algumas mesas e uma sala muito acolhedora, onde predomina a madeira, com um toque rústico q.b. Fomos muito bem recebidos pelo dono, Alessandro, e deixámos a seu cargo a escolha da ementa. Observando a ementa, pude verificar que os preços estão dentro do esperado num restaurante italiano, por exemplo: a massa mais cara (de trufas) custa 14€ e prato de carne mais caro (filet mignon para 2) custa 18€. Começámos pelas várias entradas: mozzarella de búfala e prosciutto de Parma, seguiu-se beringela alla parmegiana, coppa e uma tábua de enchidos de Parma, em quantidade mais que suficiente para ficarmos saciados! A beringela foi sem dúvida a melhor que já comi em restaurante, macia, cremosa, tempero e cozedura no ponto, os enchidos eram todos bastante diferente entre si, uns mais suaves e outros mais intensos, mas todos deliciosos! A ideia era que cada um pedisse um prato principal diferente e depois dividiríamos e desta forma experimentar vários pratos, deixámos novamente a escolha a cargo do Alessandro. Não existe carta fixa de vinhos, mas o que existem são italianos e podem deixar a escolha a cargo do empregado, não se vão arrepender. Começamos pela massa fresca com trufas, deste caso uns raviolis recheados com ricotta e trufas, cada garfada um verdadeiro deleite; chega depois um risotto com pêra, noz e queijo taleggio, um dos melhores risottos que já comi, com textura e equilíbrio de sabores perfeito; segue-se o tagliatelle com salsicha de Abruzzo e cogumelos, massa gulosa, que facilmente se tornaria um prato habitual se fosse cliente regular; e por fim, um clássico massa alla matriciana, um prato mais apimentado, com sabor característico, talvez por já estar a abarrotar foi o que menos gostei. Só tínhamos intenção de provar o tiramisu e a panna cotta, mas fomos novamente surpreendidos com várias sobremesas! Primeiro, o clássico tiramisu, tão suave e delicado; depois 2 panna cottas, morando e

chocolate, consistência e sabor perfeito, doce q.b. sem exageros, um copo" de massa folhada com frutos vermelhos"

Atributos identificados e classificados na análise do comentário pelo humano e pelo modelo *ChatGPT 3.5 Turbo*:

Tabela 20.

Exemplo 1 de um teste de concordância entre o humano e o modelo.

Atributos	Humano	Modelo	Concordam?
Sabor da comida	5	5	Sim
Porção da comida	5	5	Sim
Serviço	5	5	Sim
Preço	4	4	Sim
Ambiente/atmosfera	5	5	Sim
Apresentação da comida	5	5	Sim
Comida nutritiva	5	4	Sim
Reputação do restaurante	N/A	5	Não
Limpeza	N/A	5	Não
Variedade de refeições saudáveis	4	4	Sim
Média dos atributos	5.0	4.5	

No Exemplo 1, a concordância entre humano e modelo foi de 8 em 10, ou seja, 80,0% de concordância. O modelo e o humano identificaram os mesmos atributos e classificaram-nos com a mesma polaridade em 8 dos 10 atributos avaliados.

- Exemplo 2:

Comentário da base de dados com o id 3985785

“Bom mas bom! Piadinas fieis as q dsue come em Italia, com ingredients frescos e com qualidade, acompanhados de um serviço simpatico e educado!”

Atributos identificados e classificados na análise do comentário pelo humano e pelo modelo *ChatGPT 3.5 Turbo*:

Tabela 20.

Exemplo 2 de um teste de concordância entre o humano e o modelo.

Atributos	Humano	Modelo	Concordam?
Sabor da comida	5	4	Sim
Porção da comida	N/A	N/A	Sim
Serviço	5	2	Não
Preço	N/A	N/A	Sim
Ambiente/atmosfera	N/A	N/A	Sim
Apresentação da comida	N/A	N/A	Sim
Comida nutritiva	5	N/A	Não
Reputação do restaurante	N/A	N/A	Sim
Limpeza	N/A	N/A	Sim
Variedade de refeições saudáveis	N/A	N/A	Sim
Média dos atributos	5.0	3.0	

No Exemplo 2, a concordância também foi de 8 em 10, ou seja, 80,0%. Contudo, aqui houve uma discordância significativa no caso do serviço, em que o humano atribuiu uma nota positiva (5), enquanto o modelo classificou negativamente (2), demonstrando uma diferença na interpretação do sentimento relativo a esse atributo.

Resultados gerais obtidos na amostra de 100 comentários:

Tabela 23.

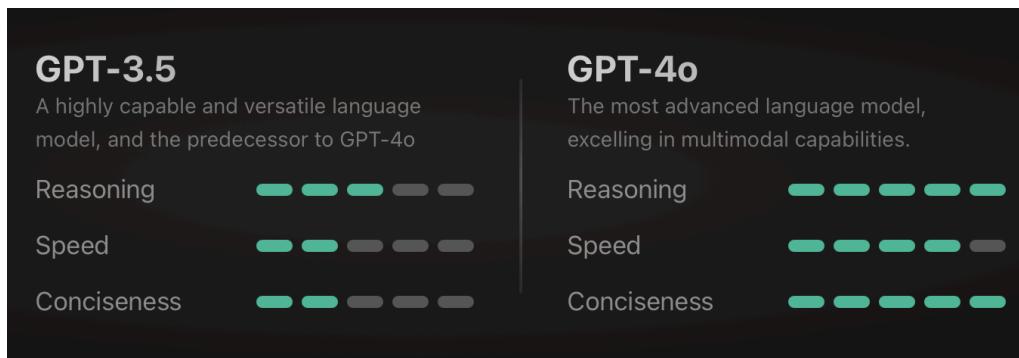
Resultados da taxa de concordância entre os 3 modelos em estudo.

Modelo LLM	Taxa de concordância com o humano
ChatGPT 3.5 Turbo	64,4 %
ChatGPT 4o_2024-05-13	81,6 %
Mistral 7B Instruct Free	60,6 %

Os resultados indicam que o modelo ChatGPT 4o_2024-05-13 teve a maior taxa de concordância com o avaliador humano, com 81,6%, um desempenho bastante próximo da taxa de concordância observada entre humanos (Carrasco & Dias, 2024). O modelo GPT 4o também demonstrou ser o mais avançado entre os três, como corroborado por comparações publicadas pela própria OpenAI, que destacam sua superior performance em relação à versão anterior.

É expectável que o modelo GPT-4o tenha um desempenho superior em relação ao GPT-3.5, principalmente em termos de capacidade de raciocínio, velocidade, e concisão.

Figura 23.
Comparativo entre modelos, pela empresa OpenAI⁶.



Com base nestes dados, conclui-se que os modelos são adequados para a tarefa de análise de sentimento, dada a concordância expressiva nas avaliações.

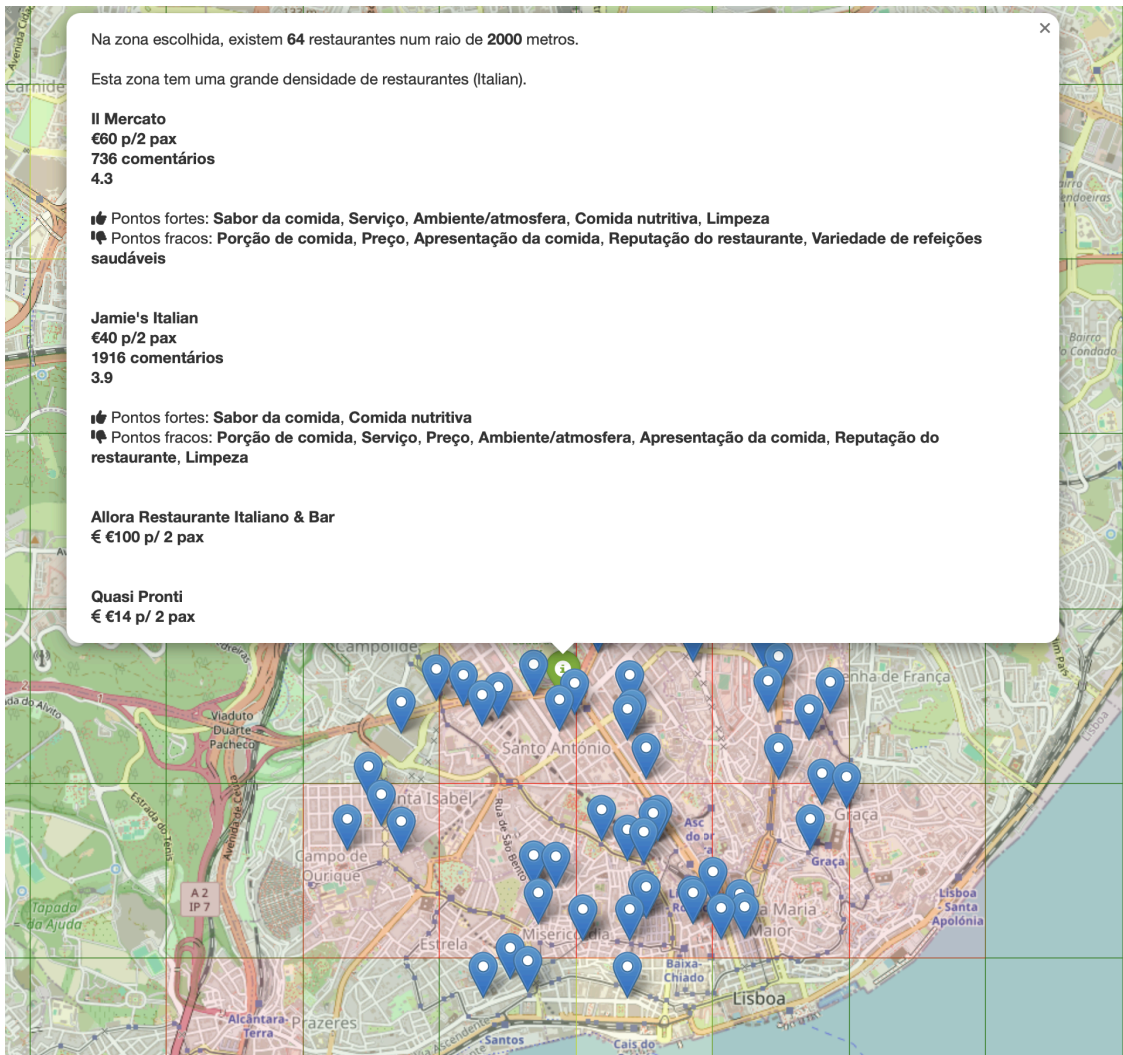
Contudo, o *prompt* utilizado ainda pode ser melhorado para otimizar os resultados, cujas taxas de concordância podem ser incrementadas com ajustes na precisão das instruções fornecidas. Essa melhoria, embora fora do escopo desta dissertação, representa uma oportunidade para futuros trabalhos na área, visando aumentar a robustez e confiança dos sistemas de recomendação baseados em análise de sentimento.

3.6. Aplicação do sistema de análise num protótipo de ferramenta de recomendação

A partir dos dados recolhidos, pré-processados e processados, foi possível desenvolver um protótipo de uma ferramenta prática e interativa voltada para investidores no setor da restauração. Esta ferramenta visa ajudar na análise detalhada de uma localização específica para apoiar na tomada de decisão. Para o protótipo, foram processados os 4.464 comentários escritos da categoria selecionada, utilizando o modelo GPT 3.5 Turbo.

⁶ Disponível no link: <https://chatbotapp.ai/landing-gpt4o>

Figura 24.
 Ferramenta em funcionamento - Localização escolhida na área da rotunda Marquês de Pombal (38.725033, -9.151035).



O protótipo foi dividido em duas partes principais:

1. Mapa interativo:

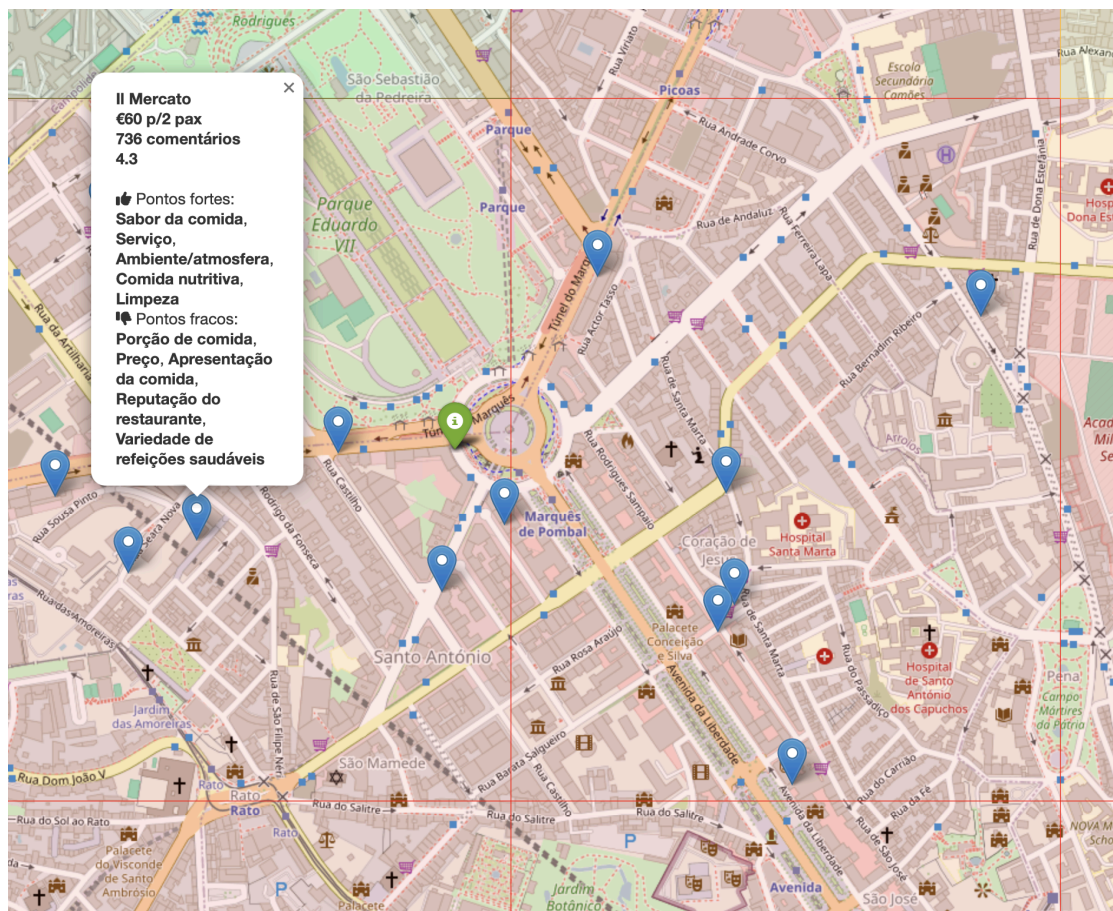
O investidor pode visualizar rapidamente três aspetos-chave para a tomada de decisão:

- **Grelha de cores:** Entre as cores vermelho e verde, estas simbolizam a saturação das zonas, como se pode verificar na figura 17.1;
- **Localização dos restaurantes da categoria 'Italian':** clicando nos pins, o investidor pode obter informações detalhadas sobre cada restaurante;

- **Nuvem de concorrência:** apresenta os dados dos restaurantes concorrentes de forma clara e fácil de interpretar. A ferramenta também delimita a verde as áreas com menos concorrentes da categoria, recomendando-as como zonas de oportunidade.

Figura 25.

Ferramenta em funcionamento - Auscultação de um restaurante específico.



2. Desempenho dos restaurantes:

A segunda parte da ferramenta exibe gráficos radar, facilitando a compreensão visual do desempenho dos restaurantes. Os gráficos refletem o resultado da análise de sentimento feita com os modelos de linguagem natural aos comentários dos clientes. Com essa informação, o investidor pode não apenas visualizar a concorrência em termos de localização, preços e classificações, mas também entender as percepções dos clientes sobre cada concorrente.

Figura 26.
Ferramenta em funcionamento - Gráficos radar por restaurante.



O processo atual de análise de investimento normalmente já inclui a procura por concorrentes, preços e classificações. No entanto, esta ferramenta centraliza todas essas informações num único local, utilizando os dados da plataforma DIG-IN para simplificar a busca. O maior valor da ferramenta, contudo, reside na análise de sentimento dos comentários, uma tarefa difícil e demorada para qualquer investidor realizar manualmente.

A inteligência artificial permite interpretar os comentários de maneira detalhada e eficiente, fornecendo informações que ajudam o investidor a identificar falhas ou oportunidades na oferta dos concorrentes. Assim, a ferramenta oferece uma vantagem competitiva ao ajudar o investidor a conhecer a fundo a concorrência e a ajustar a sua oferta de forma estratégica.

4. Discussão dos resultados

Para a implementação do sistema, validação dos dados e prototipagem da ferramenta descritos no capítulo anterior, foi utilizado um conjunto de softwares baseados em tecnologia de nuvem. A Python foi a linguagem de programação utilizada para o pré-processamento dos dados, assim como para o desenvolvimento do código necessário à comunicação com as APIs e para o processamento dos comentários pelos modelos de linguagem natural.

O desenvolvimento do código foi feito no *Google Colaboratory*, um editor de código que permite a escrita e execução diretamente no navegador, eliminando a necessidade de instalação de *software* local. Todo o processamento é realizado nos servidores da Google.

Para a interação com os modelos de linguagem natural (LLMs), utilizou-se a plataforma *openrouter.ai*, que oferece uma interface simplificada para selecionar e utilizar diversos modelos através de uma API de fácil integração. Isso facilitou a escolha e o processamento dos comentários com diferentes modelos disponíveis na plataforma.

4.1. Análise da concordância dos modelos

Na análise realizada com a amostra de 20 comentários ($n=20$), os modelos de linguagem natural demonstraram uma boa capacidade de classificar os comentários de maneira consistente com as classificações atribuídas pelos clientes. Este resultado reflete a capacidade dos modelos de interpretar o conteúdo dos comentários e atribuir classificações alinhadas com as expectativas dos clientes, garantindo uma análise coerente. Além disso, observou-se uma concordância igual ou superior a 80,0% em cinco dos dez atributos analisados. Esta concordância sugere que os modelos conseguem identificar e classificar os atributos principais de forma confiável, semelhante à performance de diferentes avaliadores humanos.

A figura 15 ilustra as taxas de concordância entre os modelos para cada um dos atributos avaliados. A boa performance dos modelos pode ser atribuída, em parte, à prevalência das palavras-chave que aparecem com frequência nos comentários e que se associam diretamente a cada atributo.

A análise foi expandida com uma amostra maior, composta por 100 comentários (n=100). Os resultados mostraram que o modelo GPT 4o_2024-05-13 alcançou uma taxa de concordância de 81,6%, o que é significativamente superior em comparação aos outros modelos, que apresentaram taxas de concordância de 64,4% para o GPT 3.5 Turbo e 60,6% para o Mistral 7B Instruct Free.

O desempenho superior do GPT 4o_2024-05-13 está em linha com o que é relatado na literatura e pela empresa OpenAI, que destaca a evolução deste modelo em relação ao seu predecessor, o GPT 3.5. A alta taxa de concordância deste modelo é um indicativo de que ele é mais eficaz na interpretação de texto e na atribuição de classificações de atributos, sendo capaz de replicar o processo de análise de sentimento de forma muito semelhante à de um avaliador humano.


Estes resultados são particularmente significativos para o estudo, pois asseguram que os modelos podem ser usados de forma confiável para identificar e classificar os atributos definidos, fornecendo uma análise de sentimento robusta e precisa. Ao identificar com clareza os sentimentos expressos nos comentários dos clientes, o modelo permite que a análise de concorrência e as decisões de investimento possam ser feitas com base em dados consistentes e confiáveis.

4.2. Processamento de todos os comentários da categoria 'Italian'

A análise dos 4.464 comentários da categoria 'Italian', correspondente a 115 restaurantes, foi realizada com o modelo GPT 3.5 Turbo. A figura 18 mostra o resultado final das divergências entre as classificações feitas pelos clientes e pelo modelo.

Figura 27.

Diferenças das classificações gerais feitas pelos clientes e o modelo GPT 3.5 Turbo.



Verifica-se que 16,04% dessas classificações tiveram uma diferença igual ou superior a 1.0 numa escala Likert de 1 a 5, o que significa que a classificação da grande maioria dos comentários, 83,96%, teve uma diferença igual ou inferior a 1.0.

Estes dados demonstram que, no geral, o modelo GPT 3.5 Turbo é bastante competente na classificação, obtendo uma elevada taxa de concordância com as classificações gerais dos clientes. Mesmo sem dados específicos sobre a concordância em nível de atributos, este resultado sugere que o modelo é eficaz ao replicar as avaliações gerais. Além disso, é importante lembrar que mesmo entre avaliadores humanos, a classificação exata de determinados aspectos do serviço pode variar ligeiramente, reforçando a consistência do modelo em contextos de avaliação subjetiva.

4.3. Relevância da ferramenta prototipada para o investidor

A dissertação desenvolveu um sistema de recomendação de restaurantes para empresários na Área Metropolitana de Lisboa, com o objetivo de apoiar na decisão de investimento. Após a conclusão do processo descrito no capítulo anterior, foi possível aplicar os dados processados na criação de um protótipo

interativo que oferece ao investidor uma análise detalhada de uma determinada localização e categoria de restaurante.

A ferramenta, de utilização intuitiva e visual, permite ao investidor compreender de forma rápida e clara o panorama da concorrência em uma área específica. Num único local, o investidor tem acesso direto aos concorrentes da categoria escolhida e pode identificar, por meio da análise de sentimento dos comentários, os pontos fortes e fracos de cada um. Mais do que obter dados básicos sobre a concorrência, como localização e preços, a ferramenta oferece *insights* sobre as percepções dos clientes em relação à oferta existente, o que é um diferencial fundamental.

Esta abordagem permite ao investidor identificar oportunidades de mercado e delinear vantagens competitivas, ajustando a sua oferta de forma estratégica com base nas falhas ou insuficiências dos concorrentes. Além disso, a ferramenta facilita a comunicação eficaz do novo restaurante, pois o investidor já conhece os aspetos valorizados pelos clientes.

Desta forma, a ferramenta pode posicionar-se como um recurso relevante na tomada de decisão de investimento, oferecendo uma visão aprofundada e holística do mercado em torno da localização selecionada, contribuindo para uma análise mais informada e precisa no setor da restauração.

5. Conclusão

Esta dissertação teve como objetivo criar um sistema de recomendação de restaurantes, para investidores, na Área Metropolitana de Lisboa (AML), utilizando técnicas de análise de dados e processamento de linguagem natural. O resultado final foi um protótipo de ferramenta de análise da concorrência, pensado para apoiar a tomada de decisão e identificar vantagens competitivas no setor da restauração.

O setor da restauração é altamente competitivo, com uma elevada taxa de mortalidade empresarial e constante renovação de novos estabelecimentos. Neste contexto, a ferramenta proposta oferece suporte estratégico, sendo especialmente útil para investidores sem equipas dedicadas à análise da concorrência.

A ferramenta organiza os dados relevantes num mapa de fácil interpretação e realiza uma análise de sentimentos baseada em comentários de consumidores, algo impraticável de ser feito manualmente, dada a grande quantidade de avaliações online.

Os dados fornecidos pela plataforma DIG-IN foram essenciais para o desenvolvimento do sistema. Estes dados foram pré-processados, resultando em dois conjuntos de dados principais que alimentaram o protótipo: um relativo aos restaurantes "Italian" na AML, com detalhes sobre os seus serviços, e outro contendo avaliações e comentários dos clientes.

Com o uso da plataforma openrouter.ai, foi possível integrar modelos de linguagem natural (LLMs) para processar os comentários com *prompts* baseados na literatura sobre a satisfação do cliente. Os LLMs identificaram e classificaram os atributos definidos, automatizando o processo de forma eficiente.

Os testes de concordância entre os modelos e um avaliador humano confirmaram a precisão da classificação dos comentários e atributos. As taxas de concordância variaram entre 60,6% e 81,6%, reforçando a confiança na capacidade dos modelos em replicar o julgamento humano.

Após esta validação, os comentários foram processados e integrados no protótipo. A ferramenta apresentou uma visão sobre a viabilidade de um local, destacando a concorrência na área escolhida, que inclui uma grelha de cores que mostra a saturação de restaurantes na categoria "Italian", facilitando a análise da concorrência.

Além disso, a ferramenta oferece gráficos de radar que mostram o desempenho dos concorrentes nos dez atributos definidos. Esta visualização permite ao investidor identificar rapidamente os pontos fortes e fracos de cada concorrente, facilitando uma tomada de decisão mais informada e subsequente criação de vantagens competitivas para o seu estabelecimento.

Em resumo, este trabalho contribui para o avanço nas áreas de Análise de Dados, Business Intelligence e Processamento de Linguagem Natural.

O protótipo desenvolvido tem o potencial de melhorar a qualidade das decisões de investimento no setor da restauração, ajudando a evitar a saturação de determinados tipos de restaurantes e promovendo a longevidade e o sucesso dos estabelecimentos.

Contudo, e embora o processo de criação tenha sido globalmente atingido com sucesso, como demonstrado, existem aspetos que agora se consideram relevantes para melhorar o desempenho da ferramenta, sendo, neste sentido, sugeridos os seguintes pontos de melhoria:

1. Aumento das fontes de dados para uma análise mais abrangente:

- Expandir a recolha de dados de restaurantes e comentários para incluir outras plataformas além da DIG-IN;
- Pré-processar e compilar os dados num conjunto mais amplo, integrando informações de várias plataformas;
- Ampliar o escopo da análise para englobar todos os tipos de cozinha e localizações.

2. Ajuste dos atributos ao mercado e às tendências descritivas dos clientes:

- Aprofundar a investigação para identificar quais atributos são mais valorizados pelos clientes no contexto online;
- Comparar os resultados com os atributos inicialmente definidos e ajustar a seleção de acordo com as novas descobertas;
- Incluir a possibilidade de comparar a evolução das classificações dos atributos ao longo do tempo, revelando tendências.

3. Determinação das palavras-chave mais relevantes para os atributos:

- Analisar a frequência de ocorrência de cada palavra-chave nos comentários analisados, bem como em outras bases de dados;
- Estabelecer um critério para excluir palavras-chave menos relevantes, por exemplo, removendo aquelas com menos de 5,0% de incidência.

4. Aperfeiçoamento da análise dos comentários ao captar nuances linguísticas:

- Treinar os modelos com exemplos de nuances linguísticas, como sarcasmo e ironia, para melhorar a interpretação dos comentários;
- Desenvolver uma escala de polaridade para sentimentos associados às palavras-chave. Por exemplo, diferenciar entre “gostámos” e “gostámos muito” para ajustar as classificações de forma mais precisa.

5. Otimização das instruções (*prompts*) para economizar recursos computacionais:

- Aplicar as lições aprendidas no desenvolvimento de prompts mais concisos, sem comprometer a qualidade da análise;
- Criar frases-chave que encapsulam instruções complexas, de modo a reduzir o consumo de tokens e os custos de computação.
- Testar o uso de modelos mais recentes e de código aberto (opensource) para reduzir os custos computacionais, mantendo a qualidade do processamento.

Estas sugestões visam tornar o sistema mais eficiente e robusto, garantindo uma análise mais detalhada e acessível, com maior precisão e menor custo.

Referências bibliográficas

- Ahmed, K., Nadeem, M., Zheng, Z., Li, D., Ullah, I., Assam, M., Ghadi, Y., & Mohamed, H. (2023). Breaking down linguistic complexities: A structured approach to aspectbased sentiment analysis. *Journal of King Saud University – Computer and Information Sciences*, 35, 1319–1578.
<https://doi.org/10.1016/j.jksuci.2023.101651>
- Ahmed, T., Akhter, L., Talukder, F., Al-Monsur, H., Rahman, H., & Sattar, A. (2021). *Restaurant Recommendation System in Dhaka City using Machine Learning Approach*. 21, 59–63. <https://doi.org/10.1109/SMART52563.2021.9676197>
- Alhelalat, J., Habiballah, M., & Twaissi, N. (2017). The impact of personal and functional aspects of restaurant employee service behaviour on customer satisfaction. *International Journal of Hospitality Management*, 66, 46–53.
<https://doi.org/10.1016/j.ijhm.2017.07.001>
- Alojamento, Restauração e Similares (Secção I)—CAE 561—Restaurantes (inclui actividades de restauração em meios móveis)* (Síntese Estatística Setorial). (2023). Instituto Nacional de Estatística.
<https://www.gee.gov.pt/pt/lista-publicacoes/estatisticas-setoriais/i-alojamento-r-estauracao-e-similares/56-restauracao-e-similares/2359-561-restaurantes-inclui-actividades-de-restauracao-em-meios-moveis/file>
- Alves, C. (2017). Estou Satisfeito: Um Estudo sobre a Lealdade do Consumidor em Restaurantes Empregando a Escala Dineserv. *Revista Brasileira de Marketing*, 16(3), 334–350. <https://doi.org/10.5585/remark.v16i3.3389>

Amaral, F., Tiago, T., & Tiago, F. (2014). User-generated content: Tourists' profiles on TripAdvisor. *International Journal of Strategic Innovative Marketing*.

<https://doi.org/10.15556/IJSIM.01.03.002>

Anmoldeep, A., Spoorthy, D., Jayanth, G., Jnanashree, A., & Sushmitha, S. (2020). Geographical location recommendation system for restaurants in Bengaluru. *Journal of Emerging Technologies and Innovative Research*, 7(6), 2111-2114.

<https://www.jetir.org/papers/JETIR2006306.pdf>

Asani, E., Vahdat-Nejad, H., & Sadri, J. (2021). Restaurant recommender system based on sentiment analysis. *Machine Learning with Applications*, 6.

<https://doi.org/10.1016/j.mlwa.2021.100114>

Branco, A., Parada, D., Silva, M., Mendonça, F., Mostafa, S., & Dias, F. (2024). Sentiment Analysis in Portuguese Restaurant Reviews: Application of Transformer Models in Edge Computing. *Electronics*, 13(3), 589.

<https://doi.org/10.3390/electronics13030589>

Bressler, M. (2012). How small businesses master the art of competition through superior competitive advantage. *Journal of Management & Marketing Research*, 11, 30–41.

Camilo, J. (2021). *Análise de sentimentos: Relação da experiência do consumidor com base nos problemas evidenciados nas online reviews* [Dissertação de mestrado, Universidade do Porto]. Repositório Aberto da Universidade do Porto. <https://hdl.handle.net/10216/134916>

Carrasco, P., & Dias, S. (2024). Enhancing Restaurant Management through Aspect-Based Sentiment Analysis and NLP Techniques. *Procedia Computer Science*, 237 (2024), 129–137. <https://doi.org/10.1016/j.procs.2024.05.088>

Choi, J., Lee, J., & Zhao, J. (2009). A Comparison of the Restaurant Selection

Preferences between Residents and Visitors of South Florida. *International CHRIE Conference-Refereed Track, Paper 14.*

<https://scholarworks.umass.edu/refereed/Sessions/Friday/14/>

Chui, M., Yee, L., Hall, B., Singla, A., & Sukharevsky, A. (2023). *The state of AI in 2023: Generative AI's breakout year.*

<https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai-in-2023-generative-ais-breakout-year>

Colson, E. (2019). What AI-Driven Decision Making Looks Like. *Harvard Business Review*. <https://hbr.org/2019/07/what-ai-driven-decision-making-looks-like>

Hua, Y., Denny, P., Taskova, K., & Wicker, J. (2023). *A Systematic Review of Aspect-based Sentiment Analysis (ABSA): Domains, Methods, and Trends* (arXiv:2311.10777). arXiv. <https://doi.org/10.48550/arXiv.2311.10777>

Huang, J., Gu, S., Hou, L., Wu, Y., Wang, X., Yu, H., & Han, J. (2022). *Large Language Models Can Self-Improve* (arXiv:2210.11610). arXiv.

<https://doi.org/10.48550/arXiv.2210.11610>

Jim, J., Talukder, M., Malakar, P., Kabir, M., Nur, K., & Mridha, M. (2024). Recent advancements and challenges of NLP-based sentiment analysis: A state-of-the-art review. *Natural Language Processing Journal*, 6, 100059.

<https://doi.org/10.1016/j.nlp.2024.100059>

Joshi, A., Kale, S., Chandel, S., & Pal, D. (2015). Likert Scale: Explored and Explained. *British Journal of Applied Science & Technology*, 7(4), 396–403.

<https://doi.org/10.9734/BJAST/2015/14975>

Kim, J., Lee, M., Kwon, W., Park, H., & Back, K. (2022). Why am I satisfied? See my reviews – Price and location matter in the restaurant industry. *International Journal of Hospitality Management*, 101, 103111.

<https://doi.org/10.1016/j.ijhm.2021.103111>

Kozyrkov, C. (2018). What Great Data Analysts Do—And Why Every Organization Needs Them. *Harvard Business Review*.

<https://hbr.org/2018/12/what-great-data-analysts-do-and-why-every-organization-needs-them>

Lin, J., Oentaryo, R., Lim, E., Vu, C., Vu, A., & Kwee, A. (2016). *Where is the Goldmine? Finding Promising Business Locations through Facebook Data Analytics*. 93–102. [https://doi.org/DOI: 10.1145/2914586.2914588](https://doi.org/DOI:10.1145/2914586.2914588)

Haghighi, M. (2012). Evaluation of factors affecting customer loyalty in the restaurant industry. *AFRICAN JOURNAL OF BUSINESS MANAGEMENT*, 6(14).
<https://doi.org/10.5897/AJBM11.2765>

Muller, A., & Guido, S. (2016). *Introduction to Machine Learning with Python* (1^a). O'Reilly Media, Inc.

Nadkarni, P., Ohno-Machado, L., & Chapman, W. (2011). Natural language processing: An introduction. *Journal of the American Medical Informatics Association*, 18(5), 544–551. <https://doi.org/10.1136/amiajnl-2011-000464>

Naveed, H., Khan, A., Qiu, S., Saqib, M., Anwar, S., Usman, M., Barnes, N., & Mian, A. (2023). *A Comprehensive Overview of Large Language Models*.

Oliveira, A. (2019). *Inteligência artificial*. Fundação Francisco Manuel dos Santos. 1^a edição. ISBN 978-989-8943-30-9..

Parasuraman, A., Zeithaml, V., & Berry, L. (1988). SERVQUAL: A multiple-Item Scale for measuring consumer perceptions of service quality. *Journal of retailing*.

Rodrigues, O., & Rodrigues, K. (2023). A inteligência artificial na educação: Os desafios do ChatGPT. *Texto Livre*, 16, e 45997.

<https://doi.org/10.1590/1983-3652.2023.45997>

Santos, A. (2023). Desafios e Oportunidades da Inteligência Artificial na Educação e na Formação. *RE@D - Revista de Educação a Distância e Elearning*, 6(2),

Artigo 2. <https://doi.org/10.34627/redvol6iss2e202311>

Santos, A. (2023). O que é, em que consiste o Chat GPT? *RE@D - Revista de Educação a Distância e Elearning*, 6(2).

<https://doi.org/10.34627/redvol6iss2e202311>

Schwab, K. (2017). *A Quarta Revolução Industrial*. LEVOIR, Marketing e Conteúdos Multimédia, S.A.

Shihab, I., & Oishi, M. (2018). A Machine Learning Approach to Suggest Ideal Geographical Location for New Restaurant Establishment. *IEEE Region 10 Humanitarian Technology Conference (R10-HTC)*, Malambe, Sri Lanka.

<https://doi.org/10.1109/R10-HTC.2018.8629845>

Siegel, E. (2018). 3 Common Mistakes That Can Derail Your Team's Predictive Analytics Efforts. *Harvard Business Review*.

<https://hbr.org/2018/10/3-common-mistakes-that-can-derail-your-teams-predictive-analytics-efforts>

Silva, L., Medeiros, C., & Costa, B. (2009). Qualidade dos Serviços Turísticos no Setor de Restaurantes: Uma Aplicação do Modelo SERVPERF. *Revista Hospitalidade*, 115–139.

Simmering, P., & Huoviala, P. (2023). *Large language models for aspect-based sentiment analysis*. *arXiv*. <http://arxiv.org/abs/2310.18025>

Statista. (2024). Most used languages among software developers globally 2024. Statista.

<https://www.statista.com/statistics/793628/worldwide-developer-survey-most-u>

sed-languages/

Statista. (2022). Python use cases 2022. Statista.

<https://www.statista.com/statistics/1338409/python-use-cases/>

Statista. (2024). Number of monthly active Facebook users worldwide as of 4th quarter 2023. Statista.

<https://www.statista.com/statistics/264810/number-of-monthly-active-facebook-users-worldwide/>

Statista. (2024). Languages most frequently used for web content as of January 2024, by share of websites. Statista.

<https://www.statista.com/statistics/262946/most-common-languages-on-the-internet/>

Stevens, P., Knutson, B., & Patton, M. (1995). Dineserv: A tool for measuring service quality in restaurants. *The Cornell Hotel and Restaurant Administration Quarterly*, 36(2), 5–60. [https://doi.org/10.1016/0010-8804\(95\)93844-K](https://doi.org/10.1016/0010-8804(95)93844-K)

Sushmitha, S. (2020). Geographical Location Recommendation System for Restaurants in Bengaluru. *JETIR*, 7(6), 2111–2114.

Törnberg, P. (2023). *How to use LLMs for Text Analysis* (arXiv:2307.13106). arXiv. <http://arxiv.org/abs/2307.13106>

Uslu, A., & Eren, R. (2020). Critical Review of Service Quality Scales with a Focus on Customer Satisfaction and Loyalty in Restaurants. *DETUROPE - The Central European Journal of Tourism and Regional Development*, 12(1), 64–84. <https://doi.org/10.32725/det.2020.004>

Wang, F., Chen, L., & Pan, W. (2016). Where to Place Your Next Restaurant?: Optimal Restaurant Placement via Leveraging User-Generated Reviews. *Proceedings of the 25th ACM International on Conference on Information and*

Knowledge Management, 2371–2376.

<https://doi.org/10.1145/2983323.2983696>

Wang, J., & Yan, X. (2017). How location matters in restaurant success?

Pacific Asia Conference on Information Systems (PACIS), Langkawi,

Malaysia. <https://aisel.aisnet.org/pacis2017/237/>

Anexos

Anexo 1

Restante amostra dos 15 comentários feitos na plataforma Tripadvisor.com, a um restaurante na Praia da Rocha, em Portimão.

4)



Recusa de atendimento

07/2023 • Family

Estive hoje, em pleno Agosto, para almoçar às 14h, foi-me dito que mesmo que houvessem mesas vazias, já não podiam atender. Perguntei ao funcionário, o porquê visto ter acabado de se sentar uma mesa à frente para almoçar. A resposta foi que como eram clientes habituais tinham direito a almoçar. Respondemos que os clientes só se tornam habituais, se vocês permitirem e aqui não voltamos mais. Gostaria que todos tivessem isto em consideração, sendo que uma das pessoas que se tinha acabado de sentar e conseguiu almoçar, tratava-se de um cantor conhecido. Com isto quero dizer, que somos discriminados no Algarve não só por sermos portugueses, como também por não sermos clientes habituais.

5)



Atendimento excepcional

06/2023 • Family

Recomendo tanto ao nível da qualidade como de atendimento e simpatia o melhor de todos. Parabéns pelo vosso atendimento qualidade variedade de ementas... o cuidado com tudo faz deste restaurante um serviço de excelência

6)



Experiência a repetir!

05/2023 • Couples

Comida 5 estrelas, espaço muito giro com um por do sol incrível e vista para a praia, atendimento super atencioso e cuidadoso! Recomendo bastante para quem vem para a Praia da Rocha.

7)



Decepcionante

09/2022 • Couples

Visitei o restaurante [redacted] com a minha mulher, após recomendação de amigos. Sendo eu algarvio, pedi uma cataplana de garoupa, camarão e amêijoas, visto não residir em Portugal e então poder saborear um dos pratos característicos e tão saborosos da minha região...

A cataplana em si, ou seja a panela normalmente de cobre onde tudo deve ser cozinhado, tinha a tampa completamente fria. O que indica que o conteúdo da dita cataplana foi cozinhado à parte. O conteúdo tinha realmente garoupa, camarão e amêijoas mas o que tinha mesmo em fatura era cebola. Para finalizar eu estava à espera de encontrar batatas no conteúdo da cataplana mas em vez disso encontrei-as fritas e numa travessa à parte.

Como algarvio e natural de Portimão, fiquei muito decepcionado com esta dita cataplana, que devo também mencionar, não foi nada barata.

Infelizmente ficou-me a imagem de que o restaurante [redacted] está aberto somente para quem não é "filho da terra".

8)



Almoço

09/2022 • Family

A comida muito boa, tem uma vista espetacular sobre o mar, muito limpo, mas o serviço extremamente lento, não se pode ter pressa.

9)



Excelente, como sempre

07/2022 • Family

Um dos melhores restaurantes na Praia da Rocha. Mantém a mesma qualidade, ano após ano. Nunca desilude. Bom atendimento, boa comida, bom ambiente.

10)



Péssimo

06/2022 • Friends

Tempos e tempos á espera dos pratos escolhidos Comida nada de especial Cerveja e coca cola dentro do normal 😞 Funcionários excessivos na sala para os pratos que iam saindo a um ritmo muitíssimo lento Conclusão: A não voltar

11)



Miss

06/2022 • Couples

Péssimo serviço. Tempo de espera quase 1h com a sala vazia. Demoraram 10 minutos após pedido, para dizer que não havia o que tinha sido pedido. Comida sofrível

12)



Refeição muito agradável, recomendado

05/2022 • Family

Um arroz maravilhoso, atendimento excelente c uma vista maravilhosa. Recomendo. Uma agradável surpresa á beira mar.

13)



O melhor restaurante da Praia da Rocha, MAS...

08/2021 • None

Somos clientes habituais deste restaurante há muitos anos e é, sem dúvida, um dos melhores que conhecemos, contudo tem falhas que prejudicam a sua boa imagem:

1. Fora do mês de Agosto é 5*****

2. Em Agosto é uma 'desgraça' porque:

a) mantém o mesmo pessoal e o restaurante, porque está sempre cheio, não consegue dar resposta.

b) tempos de espera intermináveis.

c) quem não reservar com antecedência não tem lugar...

3. O proprietário é extremamente simpático e disponível mas não consegue fazer milagres, talvez só limitando o número de clientes mas também entendo que têm que aproveitar o verão para facturarem, ainda para mais depois do início desta pandemia. E aumentaram recentemente, de forma significativa, o número de mesas.

4. A qualidade da comida, seja peixe, seja carne, seja marisco, seja o que for, é irrepreensível.

Apenas um senão, os menus infantis deixam muito a desejar e não dignificam o restaurante (hambúrguer congelado da IGLO!!!???)

Daí a nossa classificação: Agosto 1*, fora de Agosto 5***** , na média são 3***

14)



Excelência em restauração à beira-mar

08/2021 • None

Menu variado; Géneros que se salientaram pela sua fresquidão; Boa confecção; Excelente serviço; Preços aceitáveis; Avaliação final; Muito Bom e, Recomenda-se!

15)



Conta enganosa

07/2021 • Family

Pedimos uma entrada de amêijoas que levou uma hora a chegar, e como prato principal arroz de garoupa com gambas, que vinha cozido demais, para acompanhar uma garrafa de vinho branco da adega maior. Quando fomos pagar a conta verificamos que estávamos a pagar outro vinho 10 euros mais caro. Chamámos a atenção do empregado que se justificou que se tinha enganado no vinho. Realmente não foi isso que aconteceu... pagámos mas já não voltamos mais.