



INTELIGÊNCIA ARTIFICIAL E SEGMENTAÇÃO ESTRATÉGICA DE FRANQUIAS: ANALISANDO MODELOS DE NEGÓCIOS NO BRASIL COM K-MEANS

Wendel Marcos dos Santos; unip.wendel@gmail.com; PPGA UNIP

Pedro Lucas de Resende Melo; pedro.melo@docente.unip.br; PPGA UNIP

Modalidade: Artigo Teórico-Empírico

Área Temática: Redes.

Resumo

Contexto: O setor de franquias tem se consolidado como uma alternativa estratégica de investimento, proporcionando escalabilidade e redução de riscos para empreendedores. No entanto, nem todas as franquias geram o mesmo nível de valor para franqueadores e franqueados, sendo essencial compreender os fatores que impactam seu desempenho. Este estudo investiga como diferentes modelos de franquias criam valor, analisando aspectos financeiros, operacionais e estruturais.

Métodos: Utilizou-se uma abordagem quantitativa baseada em análise de clusterização K-Means para segmentar franquias em grupos distintos. O número ideal de clusters foi determinado pelo Método do Cotovelo (Elbow Method). Foram analisadas variáveis como taxa de franquia, prazo médio de retorno, suporte ao franqueado e satisfação da rede, permitindo identificar padrões de investimento e retorno no setor.

Resultados: A análise revelou quatro perfis distintos de franquias: (1) Premium, caracterizadas por alto investimento e suporte robusto; (2) Baixo Custo e Rápido Retorno, que oferecem acessibilidade, mas podem ter maior volatilidade; (3) Estruturadas de Médio Porte, que equilibram custo, suporte e estabilidade; e (4) Emergentes e Experimentais, que possuem alto potencial de crescimento, mas riscos elevados. A segmentação evidenciou que a criação de valor não depende apenas do investimento inicial, mas também do suporte da franqueadora e da estrutura da rede.

Conclusão: A clusterização demonstrou ser uma ferramenta eficiente para segmentar franquias e compreender seus diferentes modelos de criação de valor. Os achados auxiliam franqueadores e investidores na tomada de decisão, destacando a importância de suporte estruturado e inovação para a sustentabilidade do setor. Estudos futuros podem explorar o impacto de fatores tecnológicos e regionais na performance das franquias.

Palavras-chave: Franquias; Criação de valor; Clusterização; K-Means; Investimento.

1. Introdução

O setor de franquias tem se consolidado como um dos mais dinâmicos e estratégicos no cenário empresarial global. Esse modelo de negócios permite a replicação de operações bem-sucedidas, reduzindo riscos para novos empreendedores ao oferecer suporte contínuo, reconhecimento de marca e processos padronizados (Alon, Apriliyanti & Parodi, 2020; Dant & Grünhagen, 2014). A escalabilidade e a flexibilidade do franchising fazem dele um motor essencial para o desenvolvimento econômico e a geração de empregos (Varotto & Aureliano-

Silva, 2017).

No Brasil, esse mercado tem demonstrado um crescimento expressivo. Segundo a Associação Brasileira de Franchising (ABF, 2024), o setor registrou um faturamento de R\$ 273,1 bilhões, um aumento de 13,5% em relação ao ano anterior. Esse avanço reflete a crescente adesão ao modelo de franquias por empreendedores que buscam segurança e previsibilidade em um ambiente econômico muitas vezes instável (De Faria Olivo et al., 2020).

Entretanto, apesar do crescimento e da consolidação do franchising, nem todas as franquias geram o mesmo nível de valor para franqueadores e franqueados (Hua et al., 2017; De Faria Olivo et al., 2020). Algumas exigem altos investimentos e apresentam retorno financeiro mais demorado, enquanto outras possuem operações mais enxutas e rápido retorno, mas podem enfrentar desafios estruturais (Frazer et al., 2020). A questão central que se impõe, portanto, é: Como a segmentação de franquias por meio da clusterização pode revelar padrões estruturais que influenciam o retorno financeiro, a satisfação do franqueado e a sustentabilidade do modelo de negócio?

A decisão de investir em uma franquia envolve múltiplas variáveis, incluindo custo inicial, royalties, taxa de retorno, suporte oferecido, qualidade da rede e satisfação do franqueado (De Faria Olivo et al., 2020; Frazer et al., 2020; Melo et al., 2022). Muitos investidores assumem que franquias de maior valor agregado — isto é, aquelas com taxas de franquia e royalties elevados — proporcionam mais segurança e um retorno financeiro mais garantido (Lucia-Palacios et al., 2014; Hua et al., 2017; Lucia-Palacios et al., 2014). No entanto, a relação entre nível de investimento e retorno real é um tema ainda pouco explorado de maneira empírica (Lawrence, Zhang, Hsu, & Zheng, 2021; Sun & Lee, 2023)

Diante desse cenário, este estudo busca preencher essa lacuna ao investigar como diferentes tipos de franquias criam valor para franqueados e clientes. Para isso, utiliza-se a técnica de aprendizado de máquina não supervisionado K-Means, um dos métodos mais amplamente aplicados para a clusterização de dados em diversas áreas, incluindo análise de negócios e segmentação de mercado (Sinaga & Yang, 2020; Antonio et al., 2021). O K-Means agrupa elementos com características semelhantes em clusters distintos, permitindo a identificação de padrões estruturais que influenciam o desempenho das franquias (Gustriansyah, Suhandi & Antony, 2020).

Além disso, este estudo tem como relevância gerencial o suporte às decisões estratégicas, ajudando investidores a escolherem franquias mais alinhadas com seus objetivos financeiros e operacionais (Smith & Colgate, 2007; Keiningham et al., 2020). Assim, busca-se contribuir não apenas para a literatura acadêmica sobre franchising, mas também para a tomada de decisão baseada em evidências no setor (Matarazzo et al., 2021).

O objetivo central deste estudo é analisar como diferentes modelos de franquias geram valor para franqueados e clientes, considerando fatores como investimento inicial, prazo de retorno, suporte ao franqueado e satisfação geral. Especificamente, este trabalho busca: i) Identificar padrões e agrupamentos de franquias, utilizando análise de clusterização baseada em variáveis financeiras, operacionais e estruturais (Maciejewski & Krowicki, 2022); ii) Investigar a relação entre investimento e retorno, analisando se franquias de maior custo inicial são, de fato, mais rentáveis a longo prazo (Toscher, 2021); iii) Determinar os fatores mais influentes na criação de valor, como suporte da rede, inovação, qualidade da gestão e satisfação do franqueado (Zhang & Zheng, 2021); iv) Fornecer recomendações estratégicas para investidores e franqueadores, auxiliando na tomada de decisão e no planejamento de expansão (Gillis, Combs & Yin, 2020).

Espera-se que os resultados deste estudo contribuam para uma melhor compreensão

dos mecanismos de criação de valor no setor de franquias, fornecendo uma base empírica para decisões mais assertivas tanto na escolha de franquias quanto na formulação de estratégias de gestão e crescimento (Keiningham et al., 2020; Toscher, 2021; Zhang & Zheng, 2021). Além utilização de algoritmos de **aprendizado de máquina**, como o K-Means, representa uma estratégia metodológica robusta para a extração de padrões estruturais em contextos organizacionais complexos, como o das redes de franquias, permitindo análises orientadas por dados e com maior potencial explicativo (Sinaga & Yang, 2020; Umargono, Suseno & Gunawan, 2020; Antonio et al., 2021; Ong et al., 2023).

2. Fundamentação Teórica

A fundamentação teórica deste estudo explora os principais conceitos relacionados à criação de valor no setor de franquias, considerando abordagens estratégicas, inovação e o impacto das redes organizacionais. Além disso, discute-se a aplicação de técnicas de Inteligência Artificial, como a clusterização, para segmentação e análise do desempenho das franquias no mercado brasileiro.

2.1. Criação de Valor

A criação de valor é um dos pilares centrais da administração estratégica e da economia, ocorrendo quando uma empresa consegue oferecer produtos ou serviços que atendem às necessidades do cliente de forma mais eficiente ou inovadora do que seus concorrentes (Smith & Colgate, 2007; Keiningham et al., 2020; Zhang & Zheng, 2021). A criação de valor dentro de uma organização não se restringe apenas à eficiência operacional e aos ganhos financeiros, mas envolve uma rede complexa de interações que geram vantagem competitiva. Gillis, Combs e Yin (2020) destacam que cada atividade realizada dentro de uma empresa pode contribuir para a agregação de valor, tornando-se essencial para sua diferenciação no mercado.

No entanto, a criação de valor vai além da perspectiva tradicional centrada na empresa. Estudos recentes apontam para a cocriação de valor, um conceito que enfatiza a participação ativa dos clientes no desenvolvimento e aprimoramento de produtos e serviços. Nesse sentido, Vargo e Lusch (2017) argumentam que o valor é gerado em colaboração entre empresa e consumidor, transformando o cliente em um agente essencial na construção da proposta de valor (Toscher, 2021; Yen, Teng & Tzeng, 2020). No setor de franquias, isso é ainda mais evidente, pois os franqueados desempenham um papel fundamental na entrega da proposta de valor ao consumidor final (Ghantous & Alnawas, 2021). Dessa forma, o Quadro 1 apresenta o modelo tripartite da criação de valor no contexto das franquias, destacando as dimensões organizacional, operacional e de mercado.

Quadro 1 - Modelo Tripartite da Criação de Valor para Franquias

Dimensão do Valor	Descrição
Valor para a Empresa	Refere-se à capacidade da organização de capturar valor financeiro por meio de estratégias de diferenciação e eficiência operacional.
Valor para o Franqueado	Envolve a percepção de suporte, lucratividade e retorno sobre o investimento, influenciando a decisão de adesão e permanência na rede de franquias.
Valor para o Consumidor	Representa a percepção do cliente sobre a qualidade, experiência e confiabilidade da marca franqueada.

Fontes: Ortega et al. (2016); An & Han (2020); Becker & Jaakkola (2020); Matarazzo et al. (2021); Maciejewski & Krowicki (2022); Melo, Carneiro-da-Cunha & Telles (2022).

2.2. O Mercado de Franquias e seus Modelos de Negócio

O mercado de franquias tem se consolidado como um dos principais motores de crescimento econômico global, oferecendo um modelo de expansão empresarial baseado na replicação de um formato de negócio bem-sucedido (Dant & Grünhagen, 2014; Lucia-Palacios et al., 2014; Hajdini et al., 2017). As franquias podem ser classificadas em diferentes modelos de acordo com sua estrutura e investimento inicial, nas quais se destacam as seguintes categorias (Quadro 2). Diversos autores abordam os principais modelos adotados no mercado brasileiro, permitindo uma categorização alinhada às práticas do setor.

As **franquias tradicionais**, caracterizadas por operações robustas, suporte contínuo e estrutura consolidada, são discutidas por autores como Frazer et al. (2020), Gillis, Combs & Yin (2020), Melo, Carneiro-da-Cunha & Telles (2022), Jell-Ojobor, Alon & Windsperger (2022) e Sashi & Brynildsen (2022).

As **microfranquias** e com investimento reduzido e menor complexidade administrativa, são abordadas por Ortega et al. (2016), Melo et al. (2018), Santiago et al. (2020) e Melo et al. (2022). Já as **franquias home-based**, operadas a partir da residência do franqueado, têm destaque nos estudos de Hua et al. (2017), Oh, Yoo & Lee (2019), Keiningham et al. (2020), Labrecque, Swani & Stephen (2020) e Matarazzo et al. (2021).

Por fim, as **franquias de conversão**, que integram negócios independentes à estrutura da franqueadora, são abordadas por Maciejewski & Krowicki (2022) e Burston Webster, Imam & White (2021), destacando os desafios e benefícios dessa modalidade no contexto da expansão de redes.

Quadro 2 - Modelos de Franquias e suas Características

Tipo de Franquia	Descrição
Franquias Tradicionais	Modelo robusto, com alto investimento inicial, suporte contínuo e estrutura consolidada. Exemplos incluem redes de alimentação, varejo e serviços especializados.
Microfranquias e Home-Based	Investimento inicial reduzido (limite de R\$ 135 mil). Modelo enxuto, com menor complexidade administrativa, voltado para pequenos empreendedores. Permite que o franqueado opere de casa, reduzindo custos com espaço físico. Crescimento impulsionado pela digitalização e pela busca por opções de trabalho mais flexíveis.
Franquias de Conversão	Transformação de um negócio independente em unidade franqueada, agregando à marca consolidada da franqueadora as operações já existentes do empreendedor.

Fontes: Ortega et al. (2016); Hua et al. (2017); Melo et al. (2018); Oh, Yoo & Lee (2019); Santiago et al. (2020); Frazer et al. (2020); Gillis, Combs & Yin (2020); Keiningham et al. (2020); Labrecque, Swani & Stephen (2020); Matarazzo et al. (2021); Burston Webster, Imam & White (2021); Jell-Ojobor, Alon & Windsperger (2022); Maciejewski & Krowicki (2022); Melo, Carneiro-da-Cunha & Telles (2022); Sashi & Brynildsen (2022).

Dessa forma, a estrutura do mercado de franquias reflete a necessidade de adaptação constante às mudanças no comportamento do consumidor e à evolução tecnológica (Keiningham et al., 2020; Matarazzo et al., 2021; Burston Webster, Imam & White, 2021). Empresas que investem na digitalização de processos e na personalização da experiência do cliente fortalecem seu posicionamento competitivo e aumentam seu potencial de criação de valor (Shaykhzade & Alvandi, 2020; Zhang & Zheng, 2021; Liu, Shin & Burns, 2021).

2.3. Clusterização e a Análise de Franquias

A clusterização é uma técnica de aprendizado de máquina não supervisionado utilizada para agrupar elementos com características semelhantes dentro de um conjunto de dados (Nielsen, 2022; Naeem, Anam & Ahmed, 2023). No contexto de franquias, essa abordagem permite a identificação de padrões e perfis de negócio, auxiliando na segmentação do mercado e na tomada de decisões estratégicas (Xu & Wunsch, 2009; Dant & Grünhagen, 2014). Segundo Jain (2010), a clusterização é amplamente aplicada em diversos setores para classificar clientes, otimizar cadeias de suprimentos e prever tendências de mercado (Sinaga & Yang, 2020).

A segmentação de franquias por meio da clusterização possibilita a categorização das redes com base em variáveis como investimento inicial, taxa de retorno, suporte ao franqueado e satisfação geral (Alon, Apriliyanti & Parodi, 2020; De Faria Olivo et al., 2020). Isso permite compreender quais modelos de franquias compartilham características similares e quais apresentam desempenhos distintos (Varotto & Aureliano-Silva, 2017; Melo et al., 2018). Dessa forma, a clusterização é especialmente útil quando há um grande volume de dados complexos, tornando a análise tradicional limitada (Dalmaijer, Nord & Astle, 2022).

Entre os algoritmos de clusterização mais utilizados na literatura, destaca-se o K-Means, que agrupa elementos em K grupos distintos, minimizando a variabilidade interna de cada grupo (Gustriansyah, Suhandi & Antony, 2020; Antonio et al., 2021). O algoritmo parte da escolha inicial de K centros (centroids) e ajusta suas posições iterativamente, buscando maximizar a homogeneidade dentro dos clusters e a heterogeneidade entre eles (MacQueen, 1967; Umargono, Suseno & Gunawan, 2020; Sari, Al-Khowarizmi & Batubara, 2021). No setor de franquias, a aplicação desse método pode revelar agrupamentos de franquias com retorno financeiro mais rápido, franquias com maior suporte ao franqueado e franquias premium, que exigem alto investimento (Ortega et al., 2016; Ghantous & Alnawas, 2021).

Estudos recentes mostram que a clusterização pode ser uma ferramenta poderosa para análise de desempenho em redes de franquias (Ong et al., 2023; Khetarpaul et al., 2024). Além disso, ao se aplicar técnicas de agrupamento, é possível identificar padrões ocultos nos dados, permitindo decisões estratégicas mais embasadas (Gustriansyah et al., 2020; Dalmaijer et al., 2022; Matarazzo et al., 2021).

Outro aspecto relevante é a interpretação dos clusters formados (Becker & Jaakkola, 2020; Keiningham et al., 2020). Após a segmentação, os grupos podem ser analisados para entender quais fatores contribuem para o sucesso ou para o insucesso de determinados modelos de franquia (Shaykhzade & Alvandi, 2020). Por exemplo, redes que possuem taxas de franquia elevadas, mas baixo suporte ao franqueado, podem formar clusters distintos daqueles que oferecem suporte sólido e retorno rápido, permitindo que investidores escolham melhor onde alocar seus recursos (Gillis, Combs & Yin, 2020; Melo, Carneiro-da-Cunha & Telles, 2022).

Dessa forma, a clusterização se apresenta como uma ferramenta de alto valor para classificação e análise de franquias, auxiliando tanto franqueadores quanto investidores a entenderem melhor as dinâmicas do setor (Font et al., 2021; Sashi & Brynildsen, 2022). No próximo capítulo, a aplicação prática da clusterização será detalhada na Metodologia, incluindo os critérios adotados para segmentação e os resultados obtidos na análise das franquias (Burston Webster, Imam & White, 2021).

2.4. Indicadores de Sucesso em Franquias

A mensuração do desempenho de uma franquia é essencial para avaliar sua viabilidade e capacidade de gerar valor para franqueados e consumidores (Smith & Colgate, 2007; Dant &

Grünhagen, 2014). Dessa forma, o sucesso de um negócio deve ser analisado por meio de indicadores financeiros e operacionais, que refletem a eficiência da gestão e a satisfação dos stakeholders envolvidos (Hajdini et al., 2017; Gilli, Combs & Yin, 2020). No contexto de franquias, esses indicadores fornecem uma visão detalhada sobre a sustentabilidade do modelo de negócio, sua atratividade para novos investidores e seu potencial de expansão (Varotto & Aureliano-Silva, 2017; Alon, Apriliyanti & Parodi, 2020).

Os principais indicadores de sucesso no setor de franquias incluem: **Prazo de retorno do investimento (Payback)**, mede a velocidade com que o franqueado recupera o capital investido na franquia (Ortega et al., 2016; Melo et al., 2018). Esse indicador é essencial para investidores que buscam rentabilidade em curto e médio prazo (Frazer et al., 2020; Hua et al., 2017). Franquias que apresentam retorno acelerado costumam atrair mais investidores, mas o risco de volatilidade no desempenho deve ser considerado (De Faria Olivo et al., 2020; Jell-Ojobor, Alon & Windsperger, 2022).

A satisfação do franqueado, indicador qualitativo que reflete a percepção dos franqueados em relação ao suporte da franqueadora, à lucratividade da operação e à eficiência dos processos (Lashley & Morrison, 2013; Pallant, Sands & Karpen, 2020). Segundo Lashley & Morrison (2013), franqueados satisfeitos tendem a ser mais engajados, mantendo padrões de qualidade elevados e contribuindo para a consolidação da marca no mercado (Melo, Carneiro-da-Cunha & Telles, 2022; Santiago et al., 2020). Pesquisas mostram que redes que oferecem treinamentos frequentes, inovação em produtos e suporte operacional eficiente apresentam maiores taxas de retenção de franqueados (Maciejewski & Krowicki, 2022; Keiningham et al., 2020).

O desempenho da rede que avalia a consistência operacional da franquia e sua capacidade de manter um padrão de qualidade entre todas as unidades (Hajdini et al., 2017; Burston Webster, Imam & White, 2021). Um alto desempenho da rede está associado a fatores como eficiência nos processos, treinamento contínuo, padronização do atendimento e inovação constante (Becker & Jaakkola, 2020; Kleinaltenkamp et al., 2022). Segundo um estudo de Alonso & Kraus (2021), franquias que conseguem manter um nível uniforme de qualidade entre suas unidades tendem a ter um crescimento mais estável e previsível, reduzindo a taxa de encerramento de operações (Toscher, 2021; Lang, Xia & Liu, 2020).

Além desses indicadores principais, outros fatores podem influenciar o sucesso de uma franquia, tais como: **a) Faturamento médio das unidades**, que representa o potencial de receita de cada franqueado (Oh, Yoo & Lee, 2019; Ghantous & Alnawas, 2021); **b) A taxa de crescimento da rede**, capaz de medir a capacidade da franquia de atrair novos investidores e expandir suas operações (Shaykhzade & Alvandi, 2020; Maciejewski & Krowicki, 2022); **c) a reputação da marca** no mercado, que influencia a confiança do consumidor e a competitividade do negócio (An & Han, 2020; Font et al., 2021).

A combinação desses indicadores com técnicas de análise estatística e aprendizado de máquina, como a clusterização K-Means, possibilita uma visão mais aprofundada sobre o desempenho das franquias e sua capacidade de geração de valor (Dalmaijer et al., 2022; Khetarpaul, Sharma, Mishra, Sud, Soni & Agarwal, 2024). Essa abordagem permite categorizar redes em grupos distintos, identificando quais fatores têm maior impacto na satisfação dos franqueados e na lucratividade do modelo de negócio (Sinaga & Yang, 2020; Umargono, Suseno & Gunawan, 2020).

Dessa forma, compreender os indicadores de sucesso é essencial para franqueadores que desejam fortalecer suas redes, investidores que buscam oportunidades mais seguras e empreendedores que avaliam o custo-benefício de ingressar em uma franquia (Gustriansyah, Suhandi & Antony, 2020; Matarazzo et al., 2021).

3. Metodologia

Este estudo caracteriza-se como uma pesquisa quantitativa e exploratória, voltada para a análise de padrões e agrupamentos no setor de franquias por meio de técnicas de aprendizado de máquina (Sari et al., 2021; Ong et al., 2023). A abordagem quantitativa justifica-se pela utilização de dados numéricos e métricas financeiras, permitindo mensurar o desempenho das franquias com base em indicadores objetivos (Gillis, Combs & Yin, 2020; Matarazzo et al., 2021).

O caráter exploratório da pesquisa deve-se ao objetivo de identificar padrões ocultos nos dados, sem hipóteses pré-definidas sobre a relação entre os fatores analisados (Hair et al., 2010; Sinaga & Yang, 2020; Dalmaijer, Nord & Astle, 2022). A técnica de clusterização utilizada permite classificar as franquias em diferentes grupos, oferecendo uma visão segmentada do mercado e possibilitando inferências sobre os modelos de negócio mais eficientes (Gustriansyah, Suhandi & Antony, 2020; Umargono, Suseno & Gunawan, 2020; Antonio et al., 2021).

Dessa forma, a pesquisa busca fornecer análises estratégicas para franqueadores e investidores, possibilitando uma compreensão mais profunda sobre como diferentes variáveis impactam a criação de valor no setor de franquias (Melo, Carneiro-da-Cunha & Telles, 2022; Matarazzo et al., 2021; Toscher, 2021).

3.1. Origem das Variáveis Seleccionadas para a Clusterização

As variáveis utilizadas neste estudo foram extraídas da publicação "1000 Franquias e o Ranking das 405 melhores redes do país" (2024), da revista Pequenas Empresas & Grandes Negócios (Editora Globo), tais dados foram auditados pelo Serasa Experian, garantindo a procedência das informações utilizadas. Esta publicação apresenta um levantamento detalhado do mercado de franquias brasileiro, classificando as redes com base em critérios financeiros, operacionais e estruturais. A seleção dessas variáveis foi realizada com o objetivo de identificar padrões na criação de valor e diferenciar os diferentes perfis de franquias. O Quadro 3 apresenta as categorias analisadas, suas respectivas variáveis e suas descrições:

Quadro 3 - Variáveis do Estudo

Categoria	Variável	Métrica	Descrição	Autores
Variáveis Financeiras	Taxa de Franquia	R\$	Representa o investimento inicial necessário para abrir uma unidade.	Ortega et al. (2016); Melo et al. (2018); De Faria Olivo et al. (2020); Frazer et al. (2020); Jell-Ojobor et al. (2022)
	Taxa de Royalties	% faturamento	Indica o custo contínuo que o franqueado deve pagar à franqueadora.	
	Taxa de Publicidade	% faturamento	Representa o valor destinado ao marketing coletivo da rede.	
	Prazo Médio de Retorno	meses	Mede quanto tempo leva para recuperar o investimento inicial.	
Variáveis Operacionais	Desempenho da Rede	0-10	Avalia a eficiência e estabilidade da franquia no mercado.	Ortega et al. (2016); Frazer et al. (2020); Matarazzo et al. (2021); Melo et al. (2022)
	Qualidade da Rede	0-10	Mede a uniformidade e confiabilidade da operação em todas as unidades.	
	Satisfação do Franqueado	0-10	Reflete a percepção dos franqueados sobre o suporte e lucratividade da rede.	
Variáveis Estruturais	Média de Funcionários por Unidade	unid	Indica o porte da operação e a complexidade do negócio.	Frazer et al. (2020); Santiago et al. (2020)
	Área Média da Unidade	m ²	Mede o tamanho médio das instalações da franquia.	

A escolha dessas variáveis se justifica pelo seu impacto direto na criação de valor no setor de franquias, permitindo identificar agrupamentos de redes que compartilham características semelhantes e compreender como diferentes fatores influenciam o desempenho financeiro e operacional das franquias no Brasil (Frazer et al., 2020; Matarazzo et al., 2021; Melo, Carneiro-da-Cunha & Telles, 2022).

3.2. Técnicas de Análise

O método de clusterização K-Means é amplamente reconhecido como uma técnica de aprendizado de máquina não supervisionado, pertencente ao campo da Inteligência Artificial (Sinaga & Yang, 2020). Essa abordagem tem sido utilizada em diversos estudos aplicados à análise de dados organizacionais e mercadológicos, dada sua capacidade de segmentar automaticamente grandes conjuntos de dados com base em características latentes (Gustriansyah, Suhandi & Antony, 2020). No presente estudo, a aplicação do K-Means permitiu categorizar as franquias brasileiras em grupos homogêneos, com base em variáveis financeiras, operacionais e estruturais, favorecendo a identificação de padrões estratégicos entre os modelos de negócio analisados (Antonio et al., 2021).

Além disso, sua escolha justifica-se por fatores como eficiência computacional, escalabilidade e facilidade de interpretação dos resultados (Dalmaijer, Nord & Astle, 2022). Tais atributos tornam o K-Means especialmente apropriado para contextos de tomada de decisão orientada por dados, como é o caso das redes de franquias, onde a compreensão de perfis distintos pode subsidiar estratégias de expansão, suporte e rentabilidade (Frazer et al., 2020; Melo, Carneiro-da-Cunha & Telles, 2022; Gillis, Combs & Yin, 2020), uma vez que a heterogeneidade entre unidades franqueadas exige abordagens analíticas capazes de captar nuances estruturais e operacionais, o que reforça a pertinência do uso de técnicas de clusterização em estudos voltados à gestão estratégica do franchising.

Portanto, a adoção dessa técnica neste estudo representa uma escolha metodológica robusta e alinhada às exigências contemporâneas de análise em ambientes organizacionais complexos e dinâmicos (Khetarpaul et al., 2024; Umargono, Suseno & Gunawan, 2020). Para a aplicação do K-Means, seguiram-se as seguintes etapas metodológicas (Quadro 4):

Quadro 4 – Etapas Metodológicas para Aplicação do K-Means na Segmentação de Franquias

Etapa	Descrição	Referências
Normalização dos Dados	Como as variáveis utilizadas possuem escalas diferentes, foi necessário padronizá-las para evitar distorções na análise. Para isso, utilizou-se a técnica de padronização estatística (z-score), que transforma os valores de cada variável em desvios-padrão em relação à média.	Gustriansyah, Suhandi & Antony (2020); Dalmaijer, Nord & Astle (2022)
Definição do Número de Clusters	A escolha do número ideal de clusters foi feita utilizando o método do cotovelo (Elbow Method), que avalia a variação da soma dos erros quadráticos dentro dos grupos em diferentes valores de K. O ponto de inflexão do gráfico gerado por esse método indica o número mais adequado de agrupamentos, proporcionando uma segmentação mais representativa dos dados.	Umargono, Suseno & Gunawan (2020); Sari, Al-Khowarizmi & Batubara (2021)
Execução do Algoritmo K-Means	Com base na quantidade de clusters definida, aplicou-se o algoritmo K-Means, que inicia com a seleção aleatória de K centros (centroids) e ajusta iterativamente suas posições, minimizando a variabilidade interna dentro dos grupos e maximizando a diferenciação entre eles.	Sinaga & Yang (2020); Antonio et al. (2021); Khetarpaul et al. (2024)
Análise e Interpretação dos Clusters	Após a segmentação, os grupos foram avaliados em relação às suas características médias, identificando-se os fatores que mais influenciam o desempenho das franquias em cada cluster. Essa etapa possibilita que franqueadores e investidores compreendam melhor as variações entre diferentes modelos de negócios e tomem decisões estratégicas mais informadas.	Ong et al. (2023); Dalmaijer, Nord & Astle (2022)

Fonte: Os Autores

3.3. Ferramentas Utilizadas

Para a análise dos dados e aplicação das técnicas de clusterização, foram utilizadas ferramentas estatísticas e de aprendizado de máquina amplamente reconhecidas na literatura acadêmica e na prática empresarial (Sinaga & Yang, 2020; Umargono, Suseno & Gunawan, 2020; Dalmaijer, Nord & Astle, 2022; Gustriansyah, Suhandi & Antony, 2020).

A análise e o processamento dos dados foram realizados por meio da linguagem Python, devido à sua robustez e extensa biblioteca de ferramentas para manipulação de dados e modelagem estatística (Gustriansyah, Suhandi & Antony, 2020; Sinaga & Yang, 2020). Para a clusterização, foram empregadas bibliotecas especializadas, como Pandas, para organização e tratamento dos dados (Dalmaijer, Nord & Astle, 2022); NumPy, para operações matemáticas e normalização (Antonio et al., 2021); Scikit-Learn, para implementação do algoritmo K-Means e definição do número ideal de clusters (Sari, Al-Khowarizmi & Batubara, 2021; Umargono, Suseno & Gunawan, 2020); e Matplotlib/Seaborn, para visualização e interpretação dos agrupamentos identificados (Ong et al., 2023; Khetarpaul et al., 2024).

Além do uso do Python, para organização e apresentação dos resultados, foram utilizadas ferramentas como Microsoft Excel, para conferência e estruturação dos dados, e Jupyter Notebook, para o desenvolvimento e documentação do código de análise. A combinação dessas ferramentas possibilitou uma análise estruturada e embasada, garantindo precisão estatística e interpretabilidade dos resultados. A utilização de bibliotecas específicas para aprendizado de máquina permitiu a segmentação das franquias de maneira eficiente, assegurando que os agrupamentos formados representassem padrões reais dentro do conjunto de dados analisado (Sinaga & Yang, 2020; Umargono, Suseno & Gunawan, 2020; Ong et al., 2023; Khetarpaul et al., 2024).


4. Resultados

A análise dos dados permitiu a identificação de padrões distintos no setor de franquias, evidenciando como diferentes variáveis influenciam a criação de valor para franqueados e clientes. Nesta seção, são apresentados os principais achados do estudo, a segmentação das franquias em clusters e a interpretação dos resultados à luz da literatura existente.

4.1. Definição do Número de Clusters

Para determinar o número ideal de clusters (Figura 1) na segmentação das franquias, foi utilizado o Método do Cotovelo (Elbow Method), uma abordagem amplamente reconhecida na literatura para identificar o ponto em que o acréscimo de clusters deixa de proporcionar uma redução significativa na inércia do modelo (Sinaga & Yang, 2020; Umargono, Suseno & Gunawan, 2020). Esse método avalia a variação da soma dos erros quadráticos dentro dos clusters em diferentes valores de K, permitindo uma escolha otimizada do número de agrupamentos (Gustriansyah, Suhandi & Antony, 2020; Dalmaijer, Nord & Astle, 2022).

Figura 1 - Elbow Method para Definição do Número de Clusters



Fonte: Os Autores

O gráfico apresentado na Figura 1 mostra a variação da soma dos erros quadráticos dentro dos clusters para diferentes valores de K. O ponto de inflexão da curva indica o número ideal de clusters, pois representa o momento em que adicionar novos grupos não resulta em uma melhora significativa na segmentação (Sari, Al-Khowarizmi & Batubara, 2021; Antonio et al., 2021). Esse critério é amplamente utilizado em estudos de clusterização para garantir que o agrupamento seja eficiente e interpretável sem criar subdivisões desnecessárias nos dados (Umargono, Suseno & Gunawan, 2020). Com base na análise do gráfico, foi identificado que quatro clusters representam a melhor segmentação para os dados analisados. Esse valor foi escolhido com base nos seguintes critérios (Quadro 5):

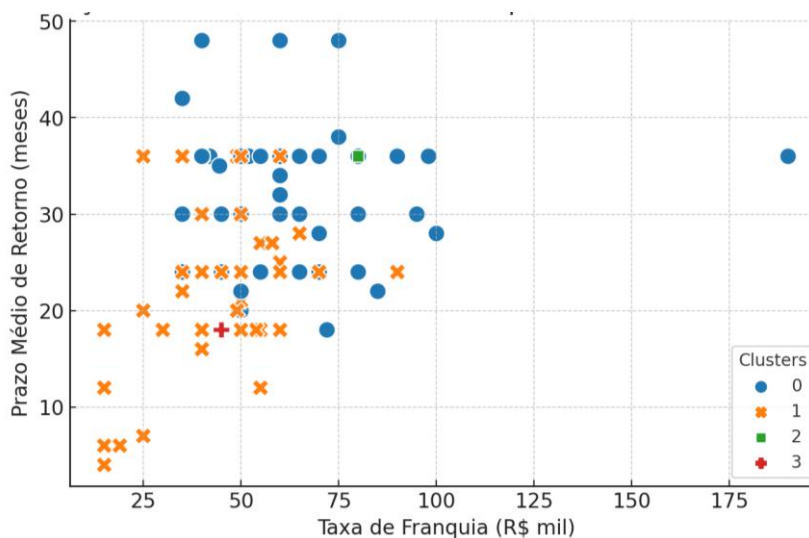
Quadro 4 - Critérios para a Definição do Número de Clusters (K=4)

Critério	Descrição	Referências
Redução significativa da inércia	A partir de K=4, a diminuição da inércia se torna marginal, indicando que a separação dos grupos é eficiente sem excessiva subdivisão.	Sinaga & Yang (2020); Gustriansyah, Suhandi & Antony (2020)
Coeficiente de Silhueta consistente	A avaliação do coeficiente de silhueta confirmou que a qualidade da segmentação é mais alta para K=4, garantindo que os clusters formados sejam bem diferenciados entre si.	Dalmajjer, Nord & Astle (2022); Sari, Al-Khowarizmi & Batubara (2021)
Interpretação dos clusters	A divisão em quatro grupos proporcionou um equilíbrio adequado entre granularidade e interpretabilidade dos dados, permitindo a distinção clara entre os diferentes perfis de franquias.	Antonio et al. (2021); Umargono, Suseno & Gunawan (2020)

Fonte: Os Autores

O gráfico de dispersão (Figura 2) apresenta a segmentação das franquias em clusters distintos, utilizando a Taxa de Franquia (R\$ mil) no eixo X e o Prazo Médio de Retorno (meses) no eixo Y. Esses eixos foram escolhidos por serem variáveis-chave na decisão de investimento em franquias, refletindo diretamente a relação entre o capital inicial exigido e o tempo necessário para recuperar o investimento.

Figura 2 - Visualização dos Clusters



Fonte: Os Autores

A segmentação das franquias revelou quatro perfis distintos, agrupados com base em características financeiras e operacionais. Cada cluster representa um conjunto de franquias com padrões semelhantes de investimento, prazo de retorno e estrutura de suporte, permitindo uma análise mais detalhada sobre como diferentes modelos de negócio criam valor.

O Quadro 6 descreve as principais características de cada cluster, destacando as diferenças entre franquias premium, de baixo custo e rápido retorno, estruturadas de médio porte e emergentes/experimentais. Essa categorização fornece uma visão estratégica para investidores e franqueadores, auxiliando na tomada de decisão e na formulação de estratégias de crescimento.

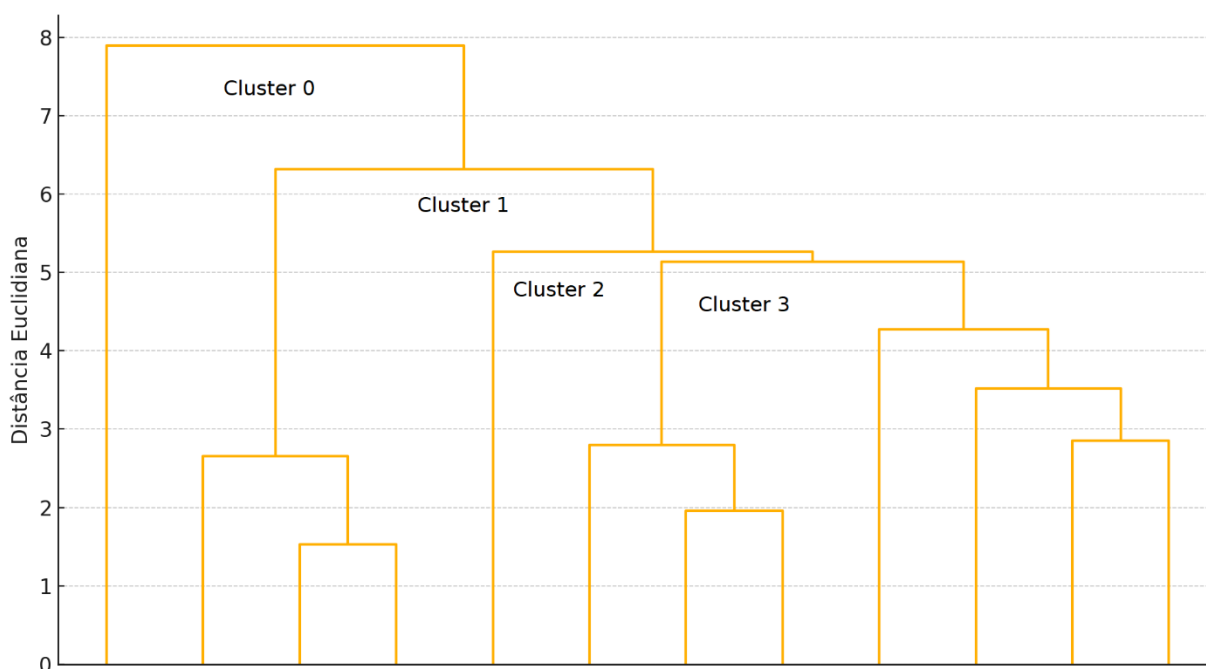
Quadro 5 - Segmentação de Franquias: Características e Perfis dos Clusters

Cluster	Características Principais
Cluster 0 - Franquias Premium	Alto investimento inicial, prazo de retorno mais longo, suporte robusto e maior satisfação dos franqueados.
Cluster 1 - Franquias de Baixo Custo e Rápido Retorno	Investimento reduzido, retorno acelerado, suporte moderado, maior heterogeneidade na satisfação do franqueado.
Cluster 2 - Franquias Estruturadas de Médio Porte	Investimento intermediário, equilíbrio entre suporte e retorno, maior estabilidade operacional.
Cluster 3 - Franquias Emergentes e Experimentais	Modelos novos ou menos consolidados, variabilidade no suporte e desempenho, risco maior para investidores.

Fonte: Os Autores

Como complemento à análise de segmentação realizada por meio do algoritmo K-Means — técnica de aprendizado de máquina não supervisionado que agrupa elementos com base na minimização da variabilidade interna dos clusters (Umargono, Suseno & Gunawan, 2020; Antonio et al., 2021;) — o dendrograma a seguir (Figura 3) apresenta a proximidade entre as franquias representativas de cada cluster.

Figura 3 - Dendrograma das Franquias Representativas por Cluster



Fonte: Os Autores

Embora o K-Means realize a alocação dos dados em grupos fixos com base em centroides (Khetarpaul et al., 2024), a análise hierárquica por dendrograma permite uma visualização contínua das relações de similaridade entre os elementos, proporcionando uma leitura mais aprofundada da estrutura dos agrupamentos (Sinaga & Yang, 2020; Dalmaijer, Nord & Astle, 2022;). Essa abordagem combinada permite fortalecer a interpretação dos padrões detectados, especialmente em contextos com múltiplas variáveis interdependentes, como no setor de franquias (Ong et al., 2023).

Discussão

A análise dos clusters revelou padrões distintos na criação de valor dentro do setor de franquias, destacando fatores determinantes para o desempenho e a atratividade de cada modelo. Nesta seção, os resultados são interpretados à luz da literatura, explorando as implicações estratégicas para franqueadores, franqueados e investidores.

4.2. Fatores mais determinantes para a separação dos clusters

A Taxa de Franquia e o Prazo Médio de Retorno foram variáveis fundamentais para a separação dos clusters, pois distinguem redes de alto investimento e retorno mais longo das franquias de baixo custo e retorno acelerado. Estudos anteriores destacam que a taxa de franquia reflete não apenas o custo inicial da adesão à rede, mas também a percepção de valor e a solidez do modelo de negócio (Dant & Grünhagen, 2014; De Faria Olivo et al., 2020).

Redes que cobram taxas elevadas tendem a oferecer suporte robusto e uma marca consolidada, justificando um prazo de retorno mais longo, enquanto franquias de menor custo podem atrair investidores iniciantes que buscam um retorno financeiro mais rápido (Melo,

Carneiro-da-Cunha & Borini, 2018). Além disso, pesquisas indicam que o prazo médio de retorno está diretamente relacionado à estrutura da franquia, à eficiência operacional e à competitividade da rede, sendo um fator crítico na decisão de novos franqueados (Hua et al., 2017; Jell-Ojobor, Alon & Windsperger, 2022).

A Satisfação do Franqueado emergiu como um fator determinante na formação dos clusters, pois redes que oferecem maior suporte e possuem uma estrutura consolidada apresentaram grupos mais homogêneos, enquanto franquias com suporte limitado demonstraram maior variabilidade interna. Estudos indicam que o suporte fornecido pela franqueadora – incluindo treinamento, assistência operacional e marketing – está diretamente relacionado ao nível de satisfação dos franqueados, impactando sua permanência na rede e seu desempenho financeiro (Ortega et al., 2016; Hua et al., 2017).

Além disso, pesquisas apontam que franqueados que percebem um suporte eficiente tendem a se engajar mais com a marca e a replicar melhores práticas, promovendo uma padronização da qualidade entre as unidades (Melo, Carneiro-da-Cunha & Telles, 2022; Gillis, Combs & Yin, 2020). A insatisfação, por outro lado, pode levar ao desengajamento e até ao desligamento da rede, tornando a estrutura de suporte um elemento crítico na criação de valor para os franqueados e na estabilidade do sistema de franchising (Jell-Ojobor, Alon & Windsperger, 2022; Sashi & Brynildsen, 2022).

O Desempenho e a Qualidade da Rede foram fatores adicionais para a segmentação das franquias, pois influenciaram diretamente a consistência operacional das redes analisadas. Estudos indicam que redes bem estabelecidas apresentam maior uniformidade nos processos e maior capacidade de padronização entre unidades, o que garante uma experiência mais previsível para os consumidores e reduz a taxa de fechamento de unidades (Ortega et al., 2016).

Além disso, a literatura sugere que a solidez das operações de uma franquia pode ser um diferencial competitivo, pois franqueadores que oferecem treinamentos contínuos e suporte eficiente tendem a criar redes mais resilientes e rentáveis (Toscher, 2021). Já franquias emergentes e experimentais, por outro lado, apresentam maior variabilidade na qualidade dos serviços prestados, o que pode impactar a percepção de valor da marca e a confiança dos investidores (Matarazzo et al., 2021). Dessa forma, a consolidação da rede e a uniformização da operação tornam-se fatores determinantes na diferenciação e no sucesso de um modelo de franquia. O impacto dessas variáveis indica que o mercado de franquias não se segmenta apenas pelo valor do investimento inicial, mas também pelo suporte oferecido, previsibilidade do retorno e qualidade percebida pelos franqueados (Jell-Ojobor, Alon & Windsperger, 2022).

Os achados deste estudo corroboram pesquisas anteriores sobre criação de valor no setor de franquias. Estudos indicam que a vantagem competitiva é sustentada quando uma empresa consegue oferecer valor superior ao cliente, seja por meio de diferenciação, inovação ou eficiência operacional, fatores que também são essenciais no franchising (Keiningham et al., 2020; Matarazzo et al., 2021).

A criação de valor pode ser analisada sob três perspectivas interligadas: o valor gerado para a empresa, para o franqueado e para o consumidor (Font et al., 2021). O valor para a empresa está diretamente associado à rentabilidade e vantagem competitiva da rede franqueadora, destacando-se a importância da padronização, eficiência operacional e inovação constante (Gilli, Combs & Yin, 2020; Ghantous & Alnawas, 2021). Já o valor para o franqueado envolve fatores como suporte, previsibilidade financeira e retorno sobre o investimento, sendo esses elementos essenciais para a atração e retenção de empreendedores no setor (Maciejewski & Krowicki, 2022; Melo et al., 2018). Por fim, o valor percebido pelo consumidor refere-se à qualidade dos produtos e serviços, à experiência do cliente e à confiança na marca, o que impacta diretamente a lealdade do consumidor e o desempenho geral da

franquia (Dolan et al., 2019; An & Han, 2020; Becker & Jaakkola, 2020).

Os diferentes clusters identificados neste estudo refletem essas três dimensões da criação de valor. Redes de franquias premium se destacam pela diferenciação e suporte contínuo, garantindo alta percepção de valor para franqueados e consumidores. Franquias de baixo custo, por outro lado, criam valor ao possibilitar um acesso mais democrático ao setor, embora enfrentem desafios em termos de padronização e previsibilidade financeira (Sashi & Brynildsen, 2022; Keiningham et al., 2020). Já as franquias estruturadas apresentam um equilíbrio estratégico entre custo, suporte e estabilidade operacional, enquanto as emergentes ainda precisam consolidar suas operações para garantir um crescimento sustentável (Pallant, Sands & Karpen, 2020; Burston Webster, Imam & White, 2021).

4.3. Clusters e os modelos de franquias analisados

A análise dos clusters demonstra que não há um modelo único de sucesso no franchising, visto que diferentes tipos de redes criam valor de maneiras variadas, dependendo do perfil do investidor e do mercado-alvo (Pallant, Sands & Karpen, 2020; Lang, Xia & Liu, 2020; Toscher, 2021). Enquanto algumas franquias se posicionam como oportunidades de investimento de alto valor agregado, outras apostam na acessibilidade e no rápido retorno financeiro como diferencial competitivo. A escolha do modelo mais adequado depende das expectativas dos investidores e das condições do mercado em que a franquia está inserida.

Um fator essencial identificado na análise é o suporte oferecido pela franqueadora, que influencia diretamente a satisfação do franqueado e sua permanência na rede (Shaykhzade & Alvandi, 2020; Toscher, 2021). Franquias que investem em padronização, suporte contínuo e capacitação de seus franqueados tendem a consolidar sua posição no mercado, garantindo maior previsibilidade de desempenho e minimizando riscos operacionais (Melo et al., 2022; Matarazzo et al., 2021). Além disso, a inovação nos processos e no modelo de negócios tem sido um diferencial importante para redes que buscam competitividade no longo prazo (Burston Webster, Imam & White, 2021; Keiningham et al., 2020).

Por outro lado, franquias emergentes podem representar tanto oportunidades quanto riscos elevados. Embora esses modelos de negócio tenham potencial de crescimento, eles também enfrentam desafios relacionados à falta de estrutura consolidada, variações na qualidade do suporte oferecido e incertezas quanto à fidelização dos consumidores (Melo, Carneiro-da-Cunha & Telles, 2022; Kleinaltenkamp et al., 2022). Dessa forma, a clusterização permite compreender melhor essas variações, fornecendo informações estratégicas para franqueadores que desejam otimizar suas estratégias e para investidores que buscam tomar decisões mais informadas (Alves, Rodrigues & Strehlau, 2023; Matarazzo et al., 2021).

A segmentação das franquias em clusters distintos reforça a importância de abordagens estratégicas diferenciadas para cada perfil de negócio. Franqueadoras podem utilizar essas análises para ajustar suas estratégias de expansão, aprimorar o suporte aos franqueados e identificar oportunidades de inovação. Investidores, por sua vez, podem utilizar essa pesquisa para escolher redes que melhor se alinhem com seus objetivos financeiros e operacionais (Antonio et al., 2021; Dalmaijer, Nord & Astle, 2022).

4.4. Recomendações

Diante da segmentação das franquias em quatro clusters distintos, torna-se essencial compreender como cada grupo pode otimizar sua criação de valor e maximizar seu desempenho

no mercado. Com base nos resultados obtidos, foram elaboradas recomendações estratégicas específicas para cada perfil de franquia, alinhando-as à literatura sobre criação de valor e gestão estratégica. O Quadro 7 a seguir apresenta essas recomendações, destacando as principais diretrizes para franqueadores e investidores que buscam aprimorar suas redes e tomar decisões mais informadas.

Quadro 6 - Recomendações para Diferentes Modelos de Franquias

Cluster	Recomendações Estratégicas
Cluster 0 - Franquias Premium	<ul style="list-style-type: none"> • Diferenciação pela marca: Investir no fortalecimento da marca para justificar o alto investimento inicial (Alon, Apriliyanti & Parodi, 2020; Keiningham et al., 2020; Jell-Ojobor, Alon & Windsperger, 2022) • Aprimoramento do suporte: Expandir capacitação para garantir a padronização e a qualidade (Frazer et al., 2020; Ghantous & Alnawas, 2021; Melo, Carneiro-da-Cunha & Telles, 2022). • Expansão internacional: Explorar mercados onde o reconhecimento da marca pode gerar vantagem competitiva (Ghantous & Alnawas, 2021; Jell-Ojobor, Alon & Windsperger, 2022)
Cluster 1 - Franquias de Baixo Custo e Rápido Retorno	<ul style="list-style-type: none"> • Manutenção da atratividade financeira: Criar pacotes acessíveis sem comprometer a rentabilidade (De Faria Olivo et al., 2020; Mainardes et al., 2019) • Garantia da qualidade operacional: Mesmo com baixo investimento, manter rigor na padronização Dant, Grünhagen & Windsperger (2011); Kleinaltenkamp et al. (2022); Ortega et al. (2016) • Expansão acelerada com cautela: Crescer rapidamente, mas garantindo sustentabilidade Toscher (2021); Hajdini et al. (2017)
Cluster 2 - Franquias Estruturadas de Médio Porte	<ul style="list-style-type: none"> • Aprimoramento da relação custo-benefício: Ajustar taxas e royalties para manter equilíbrio entre suporte e retorno Melo et al. (2018); Sashi & Brynildsen (2022) • Foco na inovação: Introduzir diferenciais competitivos sem elevar custos Matarazzo et al. (2021); Bezerra et al. (2021) • Expansão estruturada: Priorizar crescimento sustentável em regiões estratégicas Maciejewski & Krowicki (2022); Font et al. (2021)
Cluster 3 - Franquias Emergentes e Experimentais	<ul style="list-style-type: none"> • Validação do modelo de negócio: Realizar testes de mercado antes da ampla expansão Gillis, Combs & Yin (2020); Sari, Al-Khowarizmi & Batubara (2021) • Captação de investidores estratégicos: Criar incentivos para atrair franqueados dispostos a assumir riscos Pallant, Sands & Karpen (2020); Sinaga & Yang (2020) • Monitoramento rigoroso do desempenho: Estabelecer métricas para avaliar o sucesso da franquia (Keiningham et al., 2020; Kleinaltenkamp et al., 2022).

Fonte: Os Autores

5. Conclusão/Considerações finais

Este estudo teve como objetivo analisar como diferentes modelos de franquias geram valor para franqueados e clientes, considerando fatores como investimento inicial, prazo de retorno, suporte oferecido e satisfação geral. A aplicação da técnica de clusterização possibilitou a segmentação das franquias em quatro perfis distintos, permitindo uma visão mais detalhada sobre os padrões de investimento e retorno no setor (Porter, 1985; Lepak, Smith &

Taylor, 2007; Dant, Grünhagen & Windsperger, 2011).

As contribuições teóricas deste estudo residem na relação dos modelos de franquias e a criação de valor em redes de franquias, isto envolve a situação em que as franquias Premium criam valor por meio da diferenciação e do suporte robusto, justificando um investimento inicial elevado e um retorno financeiro de longo prazo (Frazer et al., 2020; Ghantous & Alnawas, 2021). Já as franquias de Baixo Custo e Rápido Retorno destacam-se pela acessibilidade do investimento e pela possibilidade de obtenção de lucros em menor tempo, ainda que possam apresentar maior volatilidade no desempenho (Gilli, Combs & Yin, 2020). As franquias Estruturadas de Médio Porte oferecem um equilíbrio entre custo, suporte e estabilidade, enquanto as Emergentes e Experimentais representam um alto potencial de crescimento, mas com riscos significativos devido à falta de consolidação no mercado (Mainardes et al., 2019; Matarazzo et al., 2021).

Os resultados deste artigo, geram contribuições teóricas relativos à discussão sobre a criação de valor no setor de franquias não depende exclusivamente do investimento inicial, mas de um conjunto de fatores estratégicos, como suporte ao franqueado, padronização dos processos e a solidez da marca (Hua et al., 2017; Melo, Carneiro-da-Cunha & Telles, 2022). Dessa forma, investidores devem avaliar não apenas os custos e prazos de retorno, mas também a capacidade da franqueadora de garantir um modelo de negócio sustentável e competitivo (Becker & Jaakkola, 2020; Melo et al., 2018; Shaykhzade & Alvandi, 2020).

Além disso, os achados deste estudo corroboram a literatura sobre criação de valor, que destaca a importância da diferenciação e da inovação para a sustentabilidade de redes franqueadas (Keiningham et al., 2020; Toscher, 2021; Sashi & Brynildsen, 2022). Modelos de negócios bem estruturados tendem a apresentar maior resiliência diante das oscilações do mercado e melhor adaptação às mudanças nas preferências dos consumidores (Pallant, Sands & Karpen, 2020; Burston Webster, Imam & White, 2021).

Dado o impacto econômico e estratégico do setor de franquias, pesquisas futuras podem explorar outros aspectos da criação de valor, incluindo a influência de fatores regionais, tecnológicos e comportamentais sobre o desempenho das redes (Lang, Xia & Liu, 2020; Maciejewski & Krowicki, 2022). O uso de outras técnicas de aprendizado de máquina, como modelos preditivos e redes neurais, também pode contribuir para uma análise ainda mais aprofundada dos padrões de sucesso das franquias (Sinaga & Yang, 2020; Umargono, Suseno & Gunawan, 2020).

Os resultados deste estudo oferecem contribuições gerenciais tanto para investidores quanto para franqueadores, auxiliando na tomada de decisão e na formulação de estratégias mais eficazes. A segmentação das franquias em clusters distintos permite uma melhor compreensão das oportunidades e desafios de cada modelo, promovendo uma abordagem mais analítica e estruturada para a expansão e o desenvolvimento do setor (Antonio et al., 2021; Dalmaier, Nord & Astle, 2022).

Referências

- Alon, I., Apriliyanti, I. D., & Parodi, M. C. H. (2020). A systematic review of international *Franchising*. *The Multinational Business Review*, 29(1), 43–69. <https://doi.org/10.1108/mbr-01-2020-0019>
- An, M., & Han, S. W. (2020). Effects of experiential motivation and customer engagement on customer value creation: Analysis of psychological process in the experience-based retail environment. *Journal of Business Research*, 120, 389–397. <https://doi.org/10.1016/j.jbusres.2020.02.044>

- Antonio, I. H. L., Augusto, Z. R. J., Miker, D. A., & Dayvis, Y. L., Junior. (2021). *Exploratory data analysis of community behavior towards the generation of solid waste using k-means and social indicators*. <https://hdl.handle.net/20.500.12867/4617>
- Becker, L. C. B., & Jaakkola, E. (2020). Customer experience: fundamental premises and implications for research. *Journal of the Academy of Marketing Science*, 48(4), 630–648. <https://doi.org/10.1007/s11747-019-00718-x>
- Burston Webster, G., Imam, T., & White, C. (2021). How Australian SMEs engage social media as digital touchpoints – a content analysis. *Small Enterprise Research*, 28(2), 170–189. <https://doi.org/10.1080/13215906.2021.1935309>
- Dalmajer, E. S., Nord, C. L., & Astle, D. E. (2022). Statistical power for cluster analysis. *BMC Bioinformatics*, 23(1). <https://doi.org/10.1186/s12859-022-04675-1>
- Chaudey, M., & Bouzid, S. (2021). Location of franchise networks in the United States. *Applied Spatial Analysis and Policy*, 14(4), 755–776. <https://doi.org/10.1007/s12061-021-09375-6>
- Dant, R. P., & Grünhagen, M. (2014). International *Franchising* Research: Some Thoughts on the What, Where, When, and How. *Journal of Marketing Channels*, 21(3), 124–132. <https://doi.org/10.1080/1046669x.2014.917012>
- De Faria Olivo, R. L., De Souza Nascimento, P. T., Sales, G. a. W., & Da Silva, F. L. (2020). The Brazilian *Franchising* Puzzle: What Explains Network Quality, Growth and Franchisees' Satisfaction. *Global Journal of Flexible Systems Management*, 21(S1), 79– 93. <https://doi.org/10.1007/s40171-020-00242-w>
- Editora Globo. (2024). 1000 Franquias e o Ranking das 405 melhores redes do país. *Pequenas Empresas & Grandes Negócios*.
- Font, X., English, R., Gkritzali, A., & Tian, W. (2021). Value co-creation in sustainable tourism: A *Service-Dominant Logic* approach. *Tourism Management*, 82, 104200. <https://doi.org/10.1016/j.tourman.2020.104200>
- Frazer, L., Merrilees, B., Nathan, G., & Thaichon, P. (2020). Creating Effective *Franchising* Relationships: Challenges of Managing Mature Franchisees. *Contributions to Management Science*, 135–148. https://doi.org/10.1007/978-3-030-35415-2_7
- Ghantous, N., & Alnawas, I. (2021). Zooming in on co-creation practices of international franchisors. *Industrial Marketing Management*, 92, 1–13. <https://doi.org/10.1016/j.indmarman.2020.10.014>
- Gillis, W. E., Combs, J. G., & Yin, X. (2020). Franchise management capabilities and franchisor performance under alternative franchise ownership strategies. *Journal of Business Venturing*, 35(1), 105899. <https://doi.org/10.1016/j.jbusvent.2018.09.004>
- Gustriansyah, R., Suhandi, N., & Antony, F. (2020). Clustering optimization in RFM analysis Based on k-Means. *Indonesian Journal of Electrical Engineering and Computer Science*, 18(1), 470. <https://doi.org/10.11591/ijeecs.v18.i1.pp470-477>
- Hajdini, I., Klapper, H., Rommer, P. S., & Windsperger, J. (2017). Control and Performance in *Franchising* Networks. *Contributions to Management Science*. https://doi.org/10.1007/978-3-319-57276-5_3

- Hua, N., O'Neill, J. W., Nusair, K., Singh, D., & DeFranco, A. (2017). Does paying higher franchise fees command higher RevPAR? *International Journal of Contemporary Hospitality Management*, 29(11), 2941–2961. <https://doi.org/10.1108/ijchm-02-2016-0060>
- Jain, R., Aagja, J. P., & Bagdare, S. (2017). Customer experience – a review and research agenda. *Journal of Service Theory and Practice*, 27(3), 642–662. <https://doi.org/10.1108/jstp-03-2015-0064>
- Jell-Ojobor, M., Alon, I., & Windsperger, J. (2022). The choice of master international *Franchising* – A modified transaction cost model. *International Business Review*, 31(2), 101942. <https://doi.org/10.1016/j.ibusrev.2021.101942>
- Keiningham, T. L., Aksoy, L., Bruce, H., Cadet, F., Clennell, N., Hodgkinson, I. J., & Kearney, T. (2020). Customer experience driven business model innovation. *Journal of Business Research*, 116, 431–440. <https://doi.org/10.1016/j.jbusres.2019.08.003>
- Kleinaltenkamp, M., Eggert, A., Kashyap, V., & Ulaga, W. (2022). Rethinking customer perceived value in business markets from an organizational perspective. *Journal of InterOrganizational Relationships*, 28(1–2), 1–18. <https://doi.org/10.1080/26943980.2022.2129545>
- Labrecque, L. I., Swani, K., & Stephen, A. T. (2020). The impact of pronoun choices on consumer engagement actions: Exploring top global brands' social media communications. *Psychology & Marketing*, 37(6), 796–814. <https://doi.org/10.1002/mar.21341>
- Lang, C., Xia, S., & Liu, C. (2020). Style and fit customization: a web content mining approach to evaluate online mass customization experiences. *Journal of Fashion Marketing and Management*, 25(2), 224–241. <https://doi.org/10.1108/jfmm-12-2019-0288>
- Liu, X., Shin, H., & Burns, A. C. (2021). Examining the impact of luxury brand's social media marketing on customer engagement: Using big data analytics and natural language processing. *Journal of Business Research*, 125, 815–826. <https://doi.org/10.1016/j.jbusres.2019.04.042>
- Lucia-Palacios, L., Bordonaba-Juste, V., Madanoglu, M., & Alon, I. (2014). *Franchising* and value signaling. *Journal of Services Marketing*, 28(2), 105–115. <https://doi.org/10.1108/jsm-09-2013-0253>
- Mainardes, E. W., Gomes, V. M., Marchiori, D. M., Correa, L. A., & Guss, V. (2019). Consequences of customer experience quality on franchises and non-franchises models. *International Journal of Retail & Distribution Management*, 47(3), 311–330. <https://doi.org/10.1108/ijrdm-09-2018-0211>
- Maciejewski, G., & Krowicki, P. (2022). Brand as a Customer Value Driver: Relationships with Customer Engagement. *Marketing of Scientific and Research Organisations*, 43(1), 53–74. <https://doi.org/10.2478/minib-2022-0003>
- Matarazzo, M., Penco, L., Profumo, G., & Quaglia, R. (2021). Digital transformation and customer value creation in Made in Italy SMEs: A dynamic capabilities perspective. *Journal of Business Research*, 123, 642–656. <https://doi.org/10.1016/j.jbusres.2020.10.033>
- Melo, P. L. D. R., Carneiro-da-Cunha, J. A., & Borini, F. M. (2018). Brazilian micro*Franchising* chains: entrepreneurs' backgrounds and perceptions of brands and support. *International Journal of Management and Enterprise Development*, 17(1), 53. <https://doi.org/10.1504/ijmed.2018.088332>

- Melo, P.L.D.R., Carneiro-da-Cunha, J.A. and Telles, R. (2022). Franchisor support and brand value empowerment of micro-franchisees: a Brazilian market perspective. *Journal of Entrepreneurship in Emerging Economies*, Vol. 14 No. 4, pp. 616- 642. <https://doi.org/10.1108/JEEE-09-2020-0324>
- Naeem, S., Ali, A., Anam, S., & Ahmed, M. M. (2023). An Unsupervised Machine Learning Algorithms: Comprehensive Review. *International Journal of Computing and Digital Systems*, 13(1), 911–921. <https://doi.org/10.12785/ijcds/130172>
- Nielsen, S. (2022), Management accounting and the concepts of exploratory data analysis and unsupervised machine learning: a literature study and future directions, *Journal of Accounting & Organizational Change*, Vol. 18 No. 5, pp. 811-853. <https://doi.org/10.1108/JAOC-08-2020-0107>
- Oh, D., Yoo, M. J., & Lee, Y. (2019). A holistic view of the service experience at coffee franchises: A cross-cultural study. *International Journal of Hospitality Management*, 82, 68–81. <https://doi.org/10.1016/j.ijhm.2019.03.022>
- Ortega, R.P., Melo, P. L. R., Boaventura, J. M.G., & Mascena, K.M.C (2016). Attendance of franchisee stakeholder’s interests and its relationship to financial performance in franchise networks. *Rev. Adm. UFSM, Santa Maria*, v. 9, Ed. Especial Engema, p. 25- 39. <https://doi.org/10.5902/1983465922118>
- Pallant, J. L., Sands, S., & Karpen, I. O. (2020). Product customization: A profile of consumer demand. *Journal of Retailing and Consumer Services*, 54, 102030. <https://doi.org/10.1016/j.jretconser.2019.102030>
- Santiago, M. C., Lanfranchi, A. G., Melo, P.L.D.R, Da Cunha, J. C., & Telles, R. (2020). Socioeconomic determinants of support and brand value perception: a survey of microfranchisees. *International Journal of Services and Operations Management*, 35(3), 269. <https://doi.org/10.1504/ijksom.2020.105371>
- Sari, I. P., Al-Khowarizmi, A., & Batubara, I. H. (2021). Cluster Analysis Using K-Means Algorithm and Fuzzy C- Means Clustering For Grouping Students’ Abilities In Online Learning Process. *Journal of Computer Science, Information Technology and Telecommunication Engineering*, 2(1), 139–144. <https://doi.org/10.30596/jcositte.v2i1.6504>
- Sashi, C., & Brynildsen, G. (2022). Franchise network relationships and word of mouth communication in social media networks. *Industrial Marketing Management*, 102, 153– 163. <https://doi.org/10.1016/j.indmarman.2022.01.011>
- Shaykhzade, F., & Alvandi, M. (2020). Investigating the effects of interaction satisfaction and interaction immersion in social media on customer value creation. *International Journal of Internet Marketing and Advertising*, 14(3), 258. <https://doi.org/10.1504/ijima.2020.108717>
- Sinaga, K. P., & Yang, M. (2020). Unsupervised K-Means clustering algorithm. *IEEE Access*, 8, 80716–80727. <https://doi.org/10.1109/access.2020.2988796>
- Smith, J. B., & Colgate, M. (2007). Customer Value Creation: A Practical Framework. *Journal of Marketing Theory and Practice*, 15(1), 7–23. <https://doi.org/10.2753/mtp1069-6679150101>
- Toscher, B. (2021). Resource integration, value Co-Creation, and *Service-Dominant Logic* in music marketing: the case of the TikTok platform. *International Journal of Music Business Research*, 10(1), 33–50. <https://doi.org/10.2478/ijmbr-2021-0002>



Umargono, E., Suseno, J. E., & Gunawan, S. K. V. (2020). K-Means Clustering Optimization Using the Elbow Method and Early Centroid Determination Based on Mean and Median Formula. *Intelligent Automation & Soft Computing*.
<https://doi.org/10.2991/assehr.k.201010.019>

Varotto, L. F., & Aureliano-Silva, L. (2017). Evolution in *Franchising*: Trends and new perspectives. *Internext*, 12(3), 31. <https://doi.org/10.18568/1980-4865.12331-42>

Yen, C., Teng, H., & Tzeng, J. (2020). Innovativeness and customer value co-creation behaviors: Mediating role of customer engagement. *International Journal of Hospitality Management*, 88, 102514. <https://doi.org/10.1016/j.ijhm.2020.102514>

Zhang, C., & Zheng, X. (2020). Customization strategies between online and offline retailers. *Omega*, 100, 102230. <https://doi.org/10.1016/j.omega.2020.102230>

Apêndice 1 – Procedimento Computacional: Segmentação de Franquias com Algoritmos de Aprendizado de Máquina

```
# Importação das bibliotecas
```

```
import pandas as pd
```

```
import numpy as np
```

```
from sklearn.preprocessing import StandardScaler
```

```
from sklearn.cluster import KMeans
```

```
from scipy.cluster.hierarchy import dendrogram, linkage
```

```
import matplotlib.pyplot as plt
```

```
import seaborn as sns
```

```
# Leitura do dataset
```

```
df = pd.read_excel("dados_franquias.xlsx")
```

```
# Seleção das variáveis para clusterização
```

```
variaveis = [
```

```
    "TAXA DE FRANQUIA",
```

```
    "PRAZO MÉDIO DE RETORNO",
```

```
    "DESEMPENHO DA REDE",
```

```
    "QUALIDADE DA REDE",
```



"SATISFAÇÃO DO FRANQUEADO",

"MÉDIA DE FUNCIONÁRIOS",

"ÁREA MÉDIA",

"TAXA DE ROYALTIES",

"TAXA DE PUBLICIDADE"

]

```
dados = df[variaveis].dropna()
```

```
# Normalização dos dados (z-score)
```

```
scaler = StandardScaler()
```

```
dados_padronizados = scaler.fit_transform(dados)
```

```
# Etapa do Método do Cotovelo
```

```
inercia = []
```

```
K_range = range(1, 11)
```

```
for k in K_range:
```

```
    modelo = KMeans(n_clusters=k, random_state=42)
```

```
    modelo.fit(dados_padronizados)
```

```
    inercia.append(modelo.inertia_)
```

```
# Plot do gráfico do cotovelo
```

```
plt.figure(figsize=(8, 5))
```

```
plt.plot(K_range, inercia, marker='o')
```

```
plt.xlabel("Número de Clusters (K)")
```

```
plt.ylabel("Soma dos Erros Quadráticos Internos (Inércia)")
```

```
plt.title("Método do Cotovelo para Determinação de K")
```

```
plt.grid(True)
```

```
plt.tight_layout()

plt.show()

# Aplicação do K-Means com o K ideal (neste caso, 4)
kmeans = KMeans(n_clusters=4, random_state=42)
clusters = kmeans.fit_predict(dados_padronizados)

# Inserção dos clusters no dataframe
df_clusters = df.copy()
df_clusters["CLUSTER"] = clusters

# Análise hierárquica e visualização via dendrograma
linkage_matrix = linkage(dados_padronizados, method='ward')

plt.figure(figsize=(14, 6))

dendrogram(
    linkage_matrix,
    no_labels=True,
    color_threshold=None
)

plt.title("Dendrograma das Franquias por Similaridade")
plt.ylabel("Distância Euclidiana")

plt.tight_layout()

plt.show()
```