

**UNIVERSIDADE FEDERAL DE MINAS GERAIS**  
**Escola de Enfermagem – Departamento de Nutrição**  
**Programa de Pós-graduação em Nutrição e Saúde**

Michele Bittencourt Rodrigues

**APLICANDO TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE  
MÁQUINA PARA O MONITORAMENTO AUTOMÁTICO DE PUBLICIDADES DE  
ALIMENTOS NO BRASIL**

Belo Horizonte

2023

Michele Bittencourt Rodrigues

**APLICANDO TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA PARA O MONITORAMENTO AUTOMÁTICO DE PUBLICIDADES DE ALIMENTOS NO BRASIL**

Dissertação apresentada à Pós-Graduação em Nutrição e Saúde da Universidade Federal de Minas Gerais, como requisito parcial para obtenção do título de Mestre em Nutrição e Saúde.

**Área de concentração:** Nutrição e Saúde

**Orientadora:** Profa. Dra. Paula Martins Horta

**Coorientadora:** Profa. Dra. Sandra Eliza Fontes de Avila

**Linha de Pesquisa:** Nutrição e Saúde Pública

Belo Horizonte  
2023

R696a Rodrigues, Michele Bittencourt.  
Aplicando técnicas de inteligência artificial e aprendizado de máquina para o monitoramento automático de publicidades de alimentos no Brasil [manuscrito]. / Michele Bittencourt Rodrigues. -- Belo Horizonte: 2023.  
84f.: il.  
Orientador (a): Paula Martins Horta.  
Coorientador (a): Sandra Eliza Fontes de Avila.  
Área de concentração: Nutrição e Saúde.  
Dissertação (mestrado): Universidade Federal de Minas Gerais, Escola de Enfermagem.

1. Publicidade de Alimentos. 2. Alimentos Industrializados. 3. Televisão. 4. Inteligência Artificial. 5. Aprendizado de Máquina. 6. Dissertação Acadêmica. I. Horta, Paula Martins. II. Avila, Sandra Eliza Fontes de. III. Universidade Federal de Minas Gerais, Escola de Enfermagem. IV. Título.

NLM: W 26.55.A7

Bibliotecário responsável: Fabian Rodrigo dos Santos CRB-6/2697



UNIVERSIDADE FEDERAL DE MINAS GERAIS

ESCOLA DE ENFERMAGEM  
CURSO DE PÓS-GRADUAÇÃO EM NUTRIÇÃO E SAÚDE

**ATA DE NÚMERO 92 (NOVENTA E DOIS) DA SESSÃO DE ARGUIÇÃO E DEFESA DA DISSERTAÇÃO APRESENTADA PELA CANDIDATA MICHELE BITTENCOURT RODRIGUES PARA OBTENÇÃO DO TÍTULO DE MESTRE EM NUTRIÇÃO E SAÚDE**

Aos 12 (doze) dias do mês de maio de dois mil e vinte e três, às 09:00 horas, realizou-se por videoconferência, a sessão pública para apresentação e defesa da dissertação "APLICANDO TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA PARA O MONITORAMENTO AUTOMÁTICO DE PUBLICIDADES DE ALIMENTOS NO BRASIL", da aluna **Michele Bittencourt Rodrigues**, candidata ao título de "Mestre em Nutrição e Saúde", linha de pesquisa "Nutrição e Saúde Pública". A Comissão Examinadora foi constituída pelas professoras doutoras Paula Martins Horta, Sandra Eliza Fontes de Avila, Ana Paula Bortoletto Martins e pelo Professor Rafael Moreira Claro, sob a presidência da primeira. Abrindo a sessão, a Senhora Presidente da Comissão, após dar conhecimento aos presentes do teor das Normas Regulamentares do Trabalho Final, passou a palavra à candidata para apresentação de seu trabalho. Seguiu-se a arguição pelos examinadores com a respectiva defesa da candidata. Logo após, a Comissão se reuniu sem a presença da candidata, para julgamento e expedição do seguinte resultado final:

APROVADO;

APROVADO COM AS MODIFICAÇÕES CONTIDAS NA FOLHA EM ANEXO;

REPROVADO.

O resultado final foi comunicado publicamente à candidata pela Senhora Presidente da Comissão. Nada mais havendo a tratar, eu, Mateus Gomes Pedrosa, Secretário do Colegiado de Pós-Graduação em Nutrição e Saúde da Escola de Enfermagem da Universidade Federal de Minas Gerais, lavrei a presente Ata, que depois de lida e aprovada será assinada por mim e pelos membros da Comissão Examinadora.

**Belo Horizonte, 12 de maio de 2023.**

Prof<sup>ª</sup>. Dr<sup>ª</sup> Paula Martins Horta  
Orientadora (UFMG)

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Sandra Eliza Fontes de Avila  
Membro Titular (UNICAMP)

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Ana Paula Bortoletto Martins  
Membro Titular (USP)

Prof. Dr. Rafael Moreira Claro  
Membro Titular (UFMG)

Mateus Gomes Pedrosa  
Secretário do Colegiado de Pós-Graduação



Documento assinado eletronicamente por **Paula Martins Horta, Professora do Magistério Superior**, em 15/05/2023, às 13:05, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Rafael Moreira Claro, Professor do Magistério Superior**, em 15/05/2023, às 13:52, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ana Paula Bortoletto Martins, Usuário Externo**, em 17/05/2023, às 16:05, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Sandra Eliza Fontes de Ávila, Usuária Externa**, em 21/06/2023, às 13:51, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Mateus Gomes Pedrosa, Assistente em Administração**, em 22/06/2023, às 09:51, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufmg.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **2303779** e o código CRC **33B0BE8A**.

*Ao meu amor e maior incentivador da  
realização desse sonho, Thiago.*

## AGRADECIMENTOS

Primeiramente, gostaria de agradecer a minha orientadora, Profa. Paula Horta, por todo o apoio, inspirações, oportunidades e ensinamentos ao longo do mestrado. Sua dedicação contribuiu para que todos os nossos trabalhos, incluindo essa dissertação, fossem concluídos com sucesso. Você é uma fonte de inspiração!

Também agradeço imensamente à Profa. Sandra Avila, minha coorientadora, e a Victória, minha parceira, por não medirem esforços para que nossas necessidades saíssem do mundo das ideias e virassem realidades. Sandra, um agradecimento muito especial pela sua forma carinhosa e acolhedora de coorientar! Vi, muito obrigada por sempre ser prestativa, doce e explicar tudo com a maior paciência.

Um agradecimento especial a Marina Santana que me auxiliou no início dessa jornada! Obrigada por ter me ajudado com os dados iniciais desse trabalho, sem sua ajuda para eu ter acesso a todos os vídeos e informações eu não teria conseguido!

Agradeço aos grupos de pesquisas GEPPAAS e GIN por terem me acolhido e compartilhado tanto conhecimento nos últimos anos. Agradeço também a cada uma das professoras e professores que foram responsáveis pelas disciplinas que cursei na UFMG e na UERJ, vocês foram essenciais para minha formação e exercem um papel extraordinário nesse mundo, obrigada por tanta dedicação e luta! Também não poderia deixar de agradecer ao Mateus Pedrosa, que sempre me ajudou e tornou cada questão administrativa mais simples.

Um agradecimento especial à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo investimento em pesquisa e pela bolsa de Mestrado.

Um agradecimento mais do que especial a toda minha família que tanto me apoiam. Obrigada por entenderem a minha ausência (mesmo que virtual) em diversos momentos. Em especial a Mamãe, Albanita e ao Papai, Edvaldo, obrigada por todo amor, incentivo e por nunca medirem esforços para me proporcionarem uma educação de qualidade. Vocês são minha essência! Dani, minha Tchuca e irmã mais linda, muito obrigada é pouco para expressar toda minha gratidão! Obrigada por me ouvir, me incentivar e estar sempre ao meu lado. Você é mais do que tudo para mim! Di e Guel, obrigada por serem minha fonte das melhores sensações do mundo, com vocês o mundo fica mais leve! Mesmo distantes vocês iluminam meus dias! Titia/Dindinha ama vocês infinitamente! Erik, obrigada pelo apoio e amor. Tia Edinea, obrigada por todo amor, suporte e incentivo de sempre! Vovô Rubens e Vovós, Maria e Vicentina, obrigada por continuarem (mesmo em outro plano) iluminando e

guiando meus caminhos, sinto vocês três o tempo todo comigo! À todas as minhas tias e tios, primas e primos, muito obrigada pelo amor, carinho e suporte.

À família Rocha Silva, muito obrigada por todo incentivo e amor. Um agradecimento especial à Fátima e ao João que sempre torcem por mim. Lucas, obrigada pelo carinho e por ter me ajudado na inscrição e matrícula do mestrado.

Ao meu amor, Thiago, a quem dedico essa dissertação, muito obrigada por todo o incentivo, suporte, companheirismo, dedicação e amor. Você foi minha estrutura quando eu não tive forças. O seu amor e apoio incondicional foram imprescindíveis nessa caminhada. Sem você nada disso teria sido possível! “*Amo-thi*”!

Às minhas amigas-irmãs Fran, Tati e Arara e ao amigo Tatá, obrigada pela amizade verdadeira, a torcida e todo o apoio emocional, vocês são meus potinhos de amor nesse mundo! Carol e Emerson, obrigada pela amizade! Bia e Juju, obrigada por trazer cores para os meus dias, a dinda ama muito vocês. Giselle, obrigada pelo suporte emocional, sem seus ensinamentos e escuta, provavelmente, eu surtaria nessa etapa final. A todos, amigos e colegas, que de alguma forma, direta e indiretamente, me ajudaram, muito obrigada!

Às amigas que o mestrado me deu de presente, Ju, Paloma e Mônica, muito obrigada por não soltarem a minha mão em momento algum! Ju, acredito que nossos destinos precisavam se cruzar. Sempre estivemos tão perto e, ao mesmo tempo, não nos conhecíamos. Mas de repente nossos mundos se alinharam e nos conectamos de uma forma incrível, que às vezes até me assusta. Obrigada por tudo e por tanto, se não fosse por você, eu jamais teria conseguido 0,1% de tudo que consegui nesse mestrado, muito obrigada! Paloma, obrigada por ser minha parceira, mesmo quando estávamos concorrendo às vagas na seleção. Jamais imaginei que um processo seletivo pudesse unir tanto as concorrentes. Que delícia foi ter uma parceira e amiga ao meu lado nessa etapa e em todas as outras ao longo dessa montanha-russa chamada Mestrado, obrigada por tudo!

Por último, simplesmente por serem meu alicerce, agradeço a Deus e aos meus guias espirituais, por ABSOLUTAMENTE tudo! Obrigada por me proporcionarem todas as oportunidades e vitórias, além de nunca me deixarem só, mesmo nos momentos mais difíceis.



## RESUMO

**Introdução:** A publicidade de alimentos tem sido reconhecida como um dos fatores que contribuem para a escolha de alimentos não saudáveis e, conseqüentemente, para o aumento da prevalência de obesidade e outras doenças crônicas relacionadas à alimentação. Diante disso, organismos de saúde apontam a relevância de se monitorar e restringir a publicidade de alimentos. O monitoramento da publicidade de alimentos é importante para avaliar a qualidade e a quantidade de anúncios de alimentos transmitidos para o público em geral, especialmente para crianças e jovens. No entanto, atualmente, os métodos utilizados para esse monitoramento são manuais e de alta complexidade de execução e custos, tornando a análise demorada e onerosa. Como consequência, as evidências produzidas são potencialmente limitadas em volume e qualidade, o que pode prejudicar a sua tradução em políticas públicas.

**Objetivo:** Desenvolver um método baseado em técnicas de inteligência artificial (IA) e aprendizado de máquina capaz de identificar e classificar automaticamente vídeos de publicidades de alimentos e não alimentos. **Métodos:** Estudo metodológico, que seguiu o protocolo desenvolvido pela rede INFORMAS (*International Network for Food and Obesity/non-communicable Diseases Research, Monitoring, and Action Support*) para a coleta de dados das publicidades de alimentos na televisão (TV). A seleção de dados envolveu as publicidades coletadas em 2018, 2019 e 2020, da programação de 3 canais abertos e 2 canais fechados da TV brasileira. O estudo foi realizado em 6 etapas de execução: coleta dos dados, seleção dos dados de treinamento; pré-processamento; divisão da base de dados inicial; treinamento e validação dos modelos computacionais, análise dos resultados. **Resultados:** A base de dados inicial foi criada a partir de 2.124 horas de gravação da programação televisiva brasileira e conteve 703 publicidades de alimentos e mais de 20.000 publicidades não alimentícias. Os resultados mostraram que a rede neural EfficientNet associada à estratégia Balanced batches alcançou uma precisão geral de 90,5% no banco de dados de teste, representando uma redução de 99,9% do tempo gasto na identificação e classificação das publicidades. **Conclusão:** A identificação e classificação automática de publicidades televisivas em alimentícias e não alimentícias através da tecnologia de IA e aprendizado de máquina representa uma abordagem promissora com enorme potencial para contribuir para a monitorização do ambiente alimentar. Essa descoberta tem importantes implicações práticas para pesquisadores, formuladores de políticas de saúde pública e órgãos reguladores não apenas no Brasil, mas também em outros países.

**Palavras-chave:** Publicidade de alimentos; Alimentos industrializados; Televisão; Inteligência artificial; Aprendizado de máquina; Saúde Pública.

## ABSTRACT

**Introduction:** Food advertising has been recognized as one factor contributing to the choice of unhealthy foods and, consequently, to the increase in the prevalence of obesity and other chronic diseases related to food. Health organizations emphasize the importance of monitoring and restricting food advertising. Monitoring food advertising is crucial to assess the quality and quantity of food advertisements (ads) that are broadcast to the public, especially to children and young people. However, currently, the methods used for this monitoring are manual and of high execution complexity and costs, making the analysis time-consuming and costly. Consequently, the evidence produced is potentially limited in volume and quality, which may impair its translation into public policy. **Objective:** To develop a method based on artificial intelligence (AI) and machine learning techniques capable of automatically identifying and classifying food and non-food ad videos. **Methods:** A methodological study, which followed the protocol developed by the INFORMAS network (*International Network for Food and Obesity/non-communicable Diseases Research, Monitoring and Action Support*) for collecting data from food ads on television (TV). Food advertising data were collected from the programming of three free-to-air channels and two pay-for-view TV channels in Brazil in 2018, 2019, and 2020. The study included six execution stages: data collection, selection of training data, preprocessing, division of the initial database, training, and validation of computational models, and analysis of results. **Results:** The initial database was created from 2,124 hours of recording of Brazilian television programming and contained 703 food ads and more than 20,000 non-food ads. The results showed that the EfficientNet neural network associated with the balanced batches strategy achieved an overall accuracy of 90.5% on the test database, which represents a reduction of 99.9% of the time spent on identifying and classifying ads. **Conclusion:** The automatic identification and classification of TV ads into food and non-food ads using AI technology represents a promising approach with enormous potential to contribute to monitoring the food environment. This finding has important practical implications for researchers, public health policymakers, and regulatory bodies, not only in Brazil but also in other countries.

**Keywords:** Food advertising; Processed foods; Television; Artificial intelligence; Machine learning; Public health.

## LISTA DE FIGURAS

<b>FIGURA 1.</b> Cronologia dos modelos teóricos propostos ao longo dos anos.....	17
<b>FIGURA 2.</b> Esquema dos conceitos bases apresentados.....	21
<b>FIGURA 3.</b> Etapas de execução do estudo.....	37
<b>FIGURA 4.</b> Fluxograma de auditoria para criação do banco de dados.....	40
<b>FIGURA 5.</b> Síntese da metodologia que compreende a etapa de seleção de dados de treinamento.....	42
<b>FIGURA 6.</b> Síntese da metodologia que compreende a divisão da base inicial dos dados.....	44
<b>FIGURA 7.</b> Síntese do treinamento e validação nas Bases 1 e 2.....	45
<b>FIGURA 8.</b> Exemplos das transformações da técnica “ <i>data augmentation</i> ” executadas em um <i>frame</i> de uma publicidade de alimento.....	48
<b>FIGURA 9.</b> Síntese da análise e validação dos dados.....	50
<b>FIGURE 1.</b> <i>Synthesis of the methodology that comprises the database preprocessing and split stage.....</i>	58
<b>FIGURE 2.</b> <i>Examples of data augmentation transformations performed in the food advertising frame.....</i>	60

## LISTA DE QUADROS E TABELAS

<b>QUADRO 1.</b> Quadro resumo das evidências de estudos que avaliaram o efeito da exposição à publicidade de alimentos na saúde da população.....	25
<b>QUADRO 2.</b> Quadro resumo dos estudos de monitoramento das publicidades de alimentos realizados no Brasil entre 2008 e 2014.....	30
<b>TABELA 1.</b> Detalhamento de cada rodada de coleta por canal.....	38
<b>TABELA 2.</b> Variáveis utilizadas para extração geral dos dados da publicidade televisiva de alimentos.....	41
<b>TABLE 1.</b> <i>Classification confusion matrix for each class in the training database using EfficientNet-B7 for classification of more than one frame per video associated with the Balanced Batches technique with merging weight 2.....</i>	63
<b>TABLE 2.</b> <i>Classification confusion matrix for each class in the validating database using EfficientNet-B7 for classification of more than one frame per video associated with the Balanced Batches technique with merging weight 2.....</i>	63
<b>TABLE 3.</b> <i>Classification confusion matrix for each class in the testing database using EfficientNet-B7 for classification of more than one frame per video associated with the Balanced Batches technique with merging weight 2.....</i>	63

## LISTA DE ABREVIATURAS E SIGLAS

Ads	<i>Advertisements</i>
AMA	<i>American Marketing Association</i>
AUP	Alimentos Ultraprocessados
CVD	Cardiovascular Diseases
DCNTs	Doenças Crônicas não Transmissíveis
FAO	<i>Food and Agriculture Organization of the United Nations</i>
FN	<i>False Negative</i>
FP	<i>False Positive</i>
HLPE	<i>High Level Panel of Experts</i>
IA	Inteligência Artificial
IBOPE	Instituto Brasileiro de Opinião Pública e Estatística
INFORMAS	<i>International Network for Food and Obesity/non-communicable Diseases Research, Monitoring and Action Support</i>
NCDs	<i>Non-communicable diseases</i>
OMS	Organização Mundial da Saúde
OPAS	Organização Pan-Americana da Saúde
PNAD	Pesquisa Nacional por Amostra de Domicílios
PNS	Pesquisa Nacional de Saúde
UNICAMP	Universidade Estadual de Campinas
UFMG	Universidade Federal de Minas Gerais
TN	<i>True Negative</i>
TP	<i>True Positive</i>
TV	Televisão e <i>Television</i>
WHO	<i>World Health Organization</i>

## SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>15</b>
1.1. Ambiente alimentar: uma cronologia dos modelos teóricos propostos.....	16
1.2. Marketing e publicidade de alimentos: conceitos, definições e mecanismos utilizados para influenciar o comportamento e as escolhas dos consumidores.....	20
1.3. A exposição à publicidade de alimentos e seus efeitos na saúde.....	24
1.4. A televisão como veículo de publicidades de alimentos.....	27
1.5. O monitoramento da publicidade televisiva.....	28
1.6. Monitoramento automático de publicidades televisivas de alimentos.....	33
<b>2. OBJETIVOS.....</b>	<b>36</b>
2.1. Objetivo geral.....	36
2.2. Objetivos específicos.....	36
<b>3. MÉTODOS.....</b>	<b>37</b>
3.1. Coleta de dados.....	37
3.1.1. Auditoria, codificação de dados e criação dos bancos de dados.....	38
3.2. Seleção dos dados.....	42
3.3. Pré-processamento de dados.....	42
3.4. Divisão da base de dados inicial.....	43
3.5. Treinamento e validação dos modelos computacionais.....	44
3.5.1. Visão geral.....	44
3.5.2. Abordagem para classificação.....	46
3.5.2.1. “Data augmentation”.....	47
3.5.2.2. “Balanced batches”.....	48
3.5.2.3. “Class weights”.....	49
3.5.3. Aplicações dos modelos.....	49
3.5.3.1. Modelo de treinamento.....	50
3.5.3.2. Modelo de validação.....	50
3.5.3.3. Modelo de teste.....	50
3.6. Análise estatística e análise de resultados algorítmicos.....	51
3.7. Aspectos éticos.....	52
<b>4. RESULTADOS E DISCUSSÃO.....</b>	<b>53</b>
<b>5. CONSIDERAÇÕES FINAIS.....</b>	<b>72</b>

<b>6. REFERÊNCIAS.....</b>	<b>74</b>
<b>7. ANEXOS.....</b>	<b>84</b>

## 1. INTRODUÇÃO

A prevalência de sobrepeso, obesidade e doenças crônicas não transmissíveis (DCNTs) tem aumentado de maneira epidêmica nas últimas décadas, e, atualmente, esses agravos representam um importante problema de saúde pública no mundo <sup>(1-5)</sup>. De acordo com a Organização Mundial da Saúde (OMS), o sobrepeso e a obesidade são os principais fatores de risco para as DCNTs. Segundo as últimas estimativas de 2016, a prevalência de obesidade em crianças e adolescentes de 5 a 18 anos em todo o mundo era de 6,8% <sup>(6,7)</sup>. Entre os adultos com 18 anos ou mais, 39% estavam acima do peso e 13% estavam obesos <sup>(6)</sup>. Além disso, em 2019, as DCNTs foram responsáveis por 74% (33,2 milhões) de mortes ocorridas no mundo <sup>(5,8)</sup>.

No Brasil, segundo a última Pesquisa Nacional de Saúde (PNS) de 2019, a proporção de pessoas com obesidade na população com 20 anos ou mais de idade passou de 12,2% para 25,9% entre 2003 e 2019, respectivamente <sup>(9)</sup>. Quanto ao sobrepeso, analisando pessoas na mesma faixa etária e no mesmo período, a proporção aumentou de 43,3% para 60,3% <sup>(9)</sup>. Além disso, a OMS estima que as DCNTs foram responsáveis por 74% de todas as mortes no país em 2016, com destaque para as doenças cardiovasculares, cânceres, doenças respiratórias e diabetes <sup>(5)</sup>.

Estudos já apontam que um dos principais impulsionadores da epidemia de sobrepeso, obesidade e DCNTs é a crescente redução da participação de alimentos in natura ou minimamente processados na dieta dos brasileiros, além do aumento do consumo de alimentos ultraprocessados (AUP) <sup>(10-13)</sup>. Enquanto os dois primeiros grupos de alimentos são fontes importantes de fibras alimentares, vitaminas e minerais, os AUP são considerados formulações industriais derivadas de alguns alimentos (ex.: óleos, gorduras, açúcares, amido e proteínas isoladas) que contêm pouco ou nenhum alimento integral, possuem baixo valor nutricional e são frequentemente adicionados de aromatizantes, corantes, emulsificantes e outros aditivos para fins alimentícios <sup>(14)</sup>.

Estudos de revisão sistemática e meta-análise mostram que vários níveis de participação de AUP na dieta têm sido diretamente associados ao aumento do risco de obesidade, diabetes tipo 2, doenças cardiovasculares, câncer, bem como mortalidade por todas as causas em qualquer faixa etária <sup>(15-18)</sup>. Além disso, um estudo indicou que o consumo de AUP foi responsável por aproximadamente 57.000 mortes prematuras na população de 30 a 69 anos no Brasil em 2019, o que equivale a 10,5% de todas as mortes evitáveis naquele



ano<sup>(19)</sup>. O estudo também apontou que a redução do consumo de AUP em 10% a 50% poderia prevenir aproximadamente 5.900 a 29.300 mortes por ano, respectivamente <sup>(19)</sup>.

Um dos mecanismos que explicam essas associações entre consumo de AUP e efeitos na saúde é a composição nutricional inadequada dos AUP que pode levar a desequilíbrios nutricionais e aumento do consumo de calorias <sup>(20)</sup>. Além disso, o consumo de AUP pode afetar negativamente a saúde metabólica e promover inflamação e estresse oxidativo <sup>(21)</sup>. A ingestão desses alimentos também pode ter um efeito negativo na microbiota intestinal, que está relacionada à saúde geral do organismo <sup>(22)</sup>.

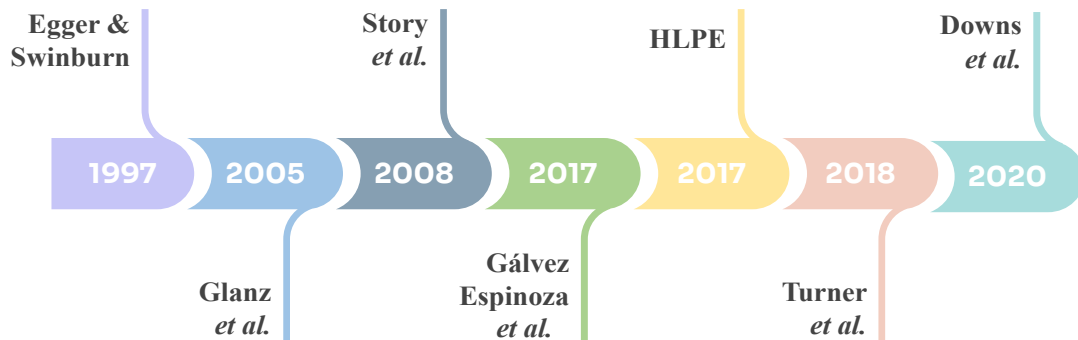
Dessa forma, a escolha alimentar possui um papel de destaque na saúde da população. No entanto, essa escolha é um processo complexo que envolve fatores socioculturais e psicológicos, além de determinantes ambientais, tais como normas sociais, interações familiares, políticas de preço, política alimentar e agrícola, disponibilidade e acessibilidade dos alimentos, mídias e tecnologias, comercialização de alimentos, entre outros <sup>(23)</sup>. Evidências destacam que atualmente os fatores ambientais têm atuado de forma a favorecer o consumo elevado de AUP, visto que as sociedades se tornaram mais urbanizadas, globalizadas e as pessoas passaram a ter menos tempo para produzir o seu próprio alimento <sup>(20,24–27)</sup>. Portanto, conhecer os fatores ambientais que estão associados aos hábitos alimentares não saudáveis é necessário para melhor subsidiar o desenvolvimento de políticas alimentares adaptadas às necessidades da população.

### **1.1. Ambiente alimentar: uma cronologia dos modelos teóricos propostos**

A discussão sobre a influência do ambiente sobre a pandemia global de obesidade iniciou em 1997 (Figura 1), quando Egger & Swinburn <sup>(28)</sup> apontaram que a obesidade deveria ser abordada não apenas como um distúrbio individual que requer tratamento, mas também considerando uma abordagem ecológica. Os autores argumentavam que as políticas públicas e as regulamentações governamentais eram ineficazes em lidar com o aumento das taxas de obesidade, visto que elas geralmente se concentravam em mudar o comportamento individual, em vez de mudar o ambiente que incentiva a promoção de hábitos não saudáveis <sup>(28)</sup>. Nesse sentido, eles sugeriram que era preciso mudar o ambiente para tornar as escolhas saudáveis mais fáceis, e sugeriram a adoção de algumas medidas como:

- Melhorar a disponibilidade e acessibilidade de alimentos saudáveis;
- Reduzir a exposição a alimentos altamente calóricos e pouco nutritivos;
- Promover a atividade física;
- Estabelecer regulamentações sobre a publicidade de alimentos para crianças.

**Figura 1.** Cronologia dos modelos teóricos propostos ao longo dos anos



**Fonte:** Elaborado para fins deste estudo.

A partir desse olhar, em 2005, os estudos sobre a influência dos fatores ambientais na alimentação se iniciaram e surgiram proposições de modelos conceituais para o que foi chamado ‘*ambiente alimentar*’<sup>(23,26,29)</sup>. O primeiro modelo foi proposto por Glanz *et al.* (2005)<sup>(23)</sup> e foi denominado *Model of Community Nutrition Environment* em inglês, que significa Modelo Comunitário de Ambiente de Nutrição (ou Nutricional) em tradução livre para o português. O modelo foi baseado em um modelo ecológico de comportamento de saúde que engloba componentes políticos, ambientais e individuais, além de condicionantes individuais de comportamentos e práticas alimentares. Ele apresenta quatro tipos de ambientes alimentares: *o comunitário, o organizacional, o do consumidor e o de informação*<sup>(23)</sup>.

O *ambiente alimentar comunitário* é medido pela distância, densidade e/ou variedade de tipos de estabelecimentos alimentares em uma área geográfica específica onde as pessoas vivem. O *ambiente alimentar organizacional* contempla as características dos locais onde as pessoas vivem (domicílios), trabalham (empresas, hospitais, etc.), estudam (escolas, universidades, etc.), entre outros. Já o *ambiente alimentar do consumidor* é caracterizado pelos aspectos de preço, promoções, informações nutricionais, variedade de opções e qualidade nutricional de alimentos em estabelecimentos comerciais, como restaurantes, bares, padarias. O *ambiente alimentar de informação* compreende a publicidade de alimentos e bebidas disseminada nos diversos espaços onde se inserem os indivíduos, tais como as mídias tradicionais (ex.: televisão (TV)), e as novas mídias (ex.: mídias sociais)<sup>(23)</sup>.

Em 2008, Story *et al.*<sup>(26)</sup> desenvolveram um novo modelo ecológico que se concentra na importância dos contextos ambientais e sociais no comportamento alimentar e propõe que a alimentação saudável é influenciada por quatro níveis: *individual, social, físico e macro ambiental*. O *nível individual* compreende questões cognitivas (ex.: atitudes, preferências, etc.), comportamentos individuais, estilo de vida, fatores biológicos (ex.: sexo e idade, etc.) e

aspectos demográficos (ex.: renda, raça/etnia, etc.). O *nível físico* compreende os locais nos quais as pessoas consomem suas refeições ou adquirem seus alimentos (residência, escola, local de trabalho, restaurantes, etc.). O *nível social* inclui as interações com a família, amigos, vizinhos e outros membros da comunidade. Já o *nível macro ambiental* envolve aspectos como produção e comercialização dos alimentos e marketing de alimentos <sup>(26)</sup>.

Mais recentemente, em 2017, Gálvez Espinoza *et al.* <sup>(30)</sup> propuseram um modelo conceitual de ambiente alimentar específico para o Chile. O modelo é composto por cinco tipos de ambientes alimentares: doméstico, via pública, institucional e organizacional, de restauração e de abastecimento. Cada um desses ambientes possui fatores e características que são capazes de influenciar escolhas alimentares saudáveis. Alguns desses fatores incluem a alta disponibilidade de alimentos não saudáveis, a distribuição desigual de estabelecimentos alimentares, os altos preços dos alimentos e a regulamentação limitada do marketing de alimentos. Sobre esse último fator, o modelo destaca a influência negativa da indústria que promove alimentos não saudáveis, especialmente para crianças e adolescentes em diversos meios de comunicação. Os autores sugerem políticas e intervenções para abordar essas restrições às publicidades de alimentos não saudáveis e promover comportamentos alimentares saudáveis <sup>(30)</sup>.

A partir deste ponto, outros autores ampliaram o estudo sobre a operacionalização e a mensuração do ambiente alimentar através de novas propostas de modelos teóricos. A *Food and Agriculture Organization of the United Nations* (FAO), em inglês, que significa Organização das Nações Unidas para a Alimentação e Agricultura na tradução livre para o português, através do Painel de especialistas de alto nível (em inglês: *High Level Panel of Experts* (HLPE)), publicou em 2017 um relatório que propõe um modelo conceitual para sistemas alimentares, definidos como a “*reunião de todos os elementos (ambiente, pessoas, insumos, processos, infraestruturas, instituições, etc.) e atividades relacionadas à produção, processamento, distribuição, preparação e consumo de alimentos, além dos resultados dessas atividades, como os impactos socioeconômicos e ambientais.*” <sup>(31)</sup>. Nesse modelo há:

- cinco categorias principais de impulsionadores das mudanças nos sistemas alimentares: (i) biofísicos e ambientais; (ii) inovação, tecnologia e infraestrutura; (iii) político e econômico; (iv) sociocultural; e (v) impulsionadores demográficos.
- três principais grupos de elementos que constituem os sistemas alimentares: (i) cadeias de abastecimento alimentar; (ii) ambientes alimentares e (iii) comportamento do consumidor.

Dessa forma, esses três grupos de elementos sofrem influências dos cinco principais impulsionadores, e são capazes de moldar as dimensões das escolhas alimentares (qualidade, quantidades, diversidades e segurança) e determinam os hábitos alimentares, a saúde, os resultados econômicos e sociais dos sistemas alimentares. Nesse sentido, o relatório também reforça o papel central do ambiente alimentar como facilitador para escolhas alimentares saudáveis e sustentáveis.

Em 2018, Turner *et al.*<sup>(29)</sup> conduziram uma revisão dos modelos anteriores de ambiente alimentar e sugeriram um novo modelo que fosse mais adequado para países de média e baixa renda. Esse modelo conceitual divide o ambiente alimentar em dois domínios: *externo e pessoal*. No *domínio externo*, são consideradas dimensões como disponibilidade e preços dos alimentos, características dos estabelecimentos e produtos, além do marketing e sua regulação, ou seja, aspectos que se referem às oportunidades e restrições do contexto. Já no *domínio pessoal*, são considerados um conjunto de dimensões individuais, como acessibilidade física, financeira, conveniência e preferências. Esses dois domínios se influenciam mutuamente e afetam a aquisição e o consumo de alimentos. Além disso, os autores destacam as diferenças nas dimensões no *domínio externo* entre países de alta renda e aqueles de média e baixa renda, como, por exemplo, na dimensão do marketing. Nos países de alta renda, os ambientes alimentares são regulamentados com leis mais rígidas e maior controle sobre as promoções e campanhas de marketing. No entanto, nos países de baixa e média renda os ambientes alimentares são menos regulamentados e conseqüentemente apresentam menor controle sobre as promoções e campanhas de marketing<sup>(29)</sup>.

Ademais, em 2020, Downs *et al.*<sup>(32)</sup> propuseram uma nova estrutura conceitual para definir e medir os ambientes alimentares em países de baixa, média e alta renda. Os autores propuseram um modelo mais abrangente e inclusivo que as abordagens anteriores. Segundo eles, o ambiente alimentar é a interface do consumidor com o sistema alimentar, e os principais elementos que o compõem são a disponibilidade, acessibilidade de compra, conveniência, qualidade e o marketing dos alimentos. Esse ambiente pode ser *natural ou construído*, conforme a influência pelo ambiente sociocultural e político e pelos ecossistemas no qual está inserido. Os *ambientes alimentares naturais* são classificados em *selvagens* (habitats naturais que produzem alimentos, como florestas, oceanos e rios) e *cultivados* (áreas de cultivo ou criação animal, incluindo campos e pastagens). Já os *ambientes alimentares construídos* incluem locais onde os alimentos são vendidos ou consumidos, como os

*mercados formais* (supermercados, lojas e restaurantes) e *informais* (vendedores ambulantes e barraquinhas de rua) <sup>(32)</sup>.

Diante da análise desses modelos teóricos descritos, podemos observar que todos os estudos destacam que existe uma influência dos fatores ambientais nas escolhas alimentares individuais, inclusive do marketing e da publicidade de alimentos. Nesse sentido, esse trabalho pretende explorar mais detalhadamente essa dimensão.

## **1.2. Marketing e publicidade de alimentos: conceitos, definições e mecanismos utilizados para influenciar o comportamento e as escolhas dos consumidores**

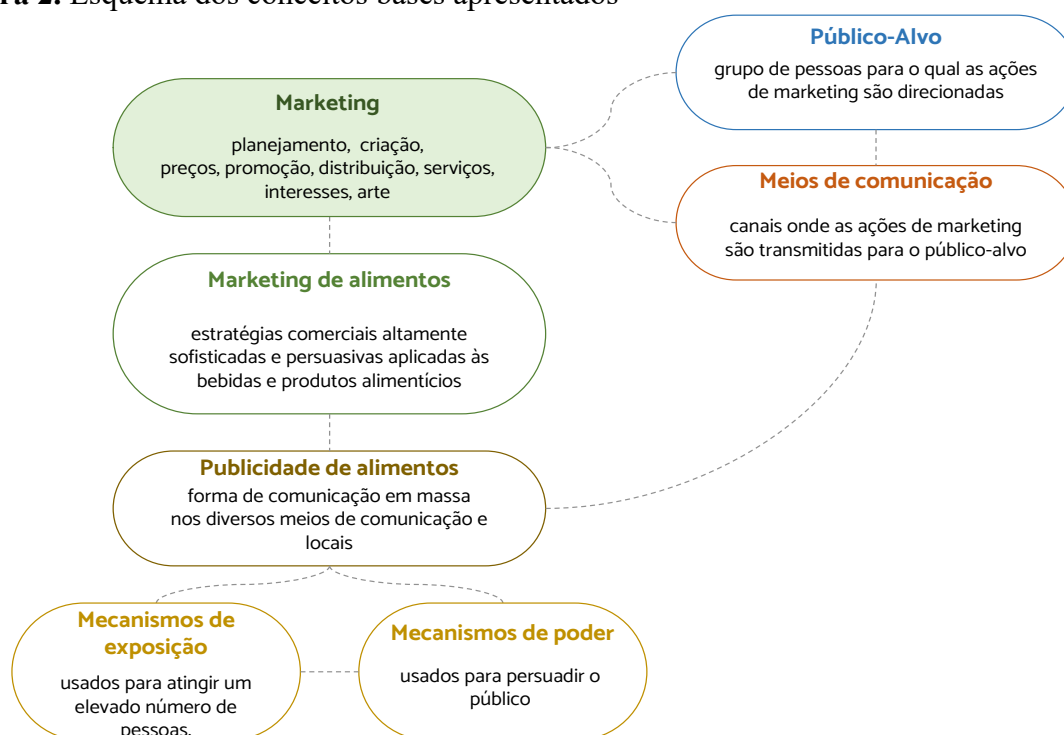
No cenário atual de expansão contínua da indústria alimentícia e do aumento da competição entre as marcas de alimentos, a utilização de ferramentas e mecanismos que contribuam para consolidar e impulsionar as empresas é essencial. Nesse sentido, o marketing e todos os seus componentes desempenham papéis fundamentais para essas empresas, principalmente, por ser um processo dinâmico que segue as tendências do mercado e a forma como a sociedade se organiza.

A *American Marketing Association* (AMA)<sup>(33)</sup> – em tradução livre para o português: Associação Americana de Marketing – define que o marketing envolve todo o processo de planejamento e execução dos produtos, desde a concepção, preço, promoção, distribuição e serviços para criar trocas que satisfaçam os objetivos individuais e organizacionais <sup>(33)</sup>. Um dos principais autores da área complementa essa definição afirmando que o marketing é a ciência e a arte de explorar, criar e entregar valor para satisfazer as necessidades de um público-alvo com lucro <sup>(34)</sup>. Portanto, quando se fala em marketing de alimentos, podemos defini-lo como um processo complexo que inclui uma série de componentes, como publicidade, promoção, definições de embalagens e rotulagens, estratégias de divulgações, vendas e precificação, que tem como objetivo atrair a atenção dos consumidores, gerar demandas de mercado e influenciar os hábitos de consumo <sup>(35-37)</sup>.

A publicidade de alimentos é um dos componentes do marketing de alimentos, e pode ser definida como uma forma de comunicação, com o principal objetivo de atrair e persuadir o consumidor a tomar uma ação, como a de comprar e/ou consumir o produto alimentício, ou bebida publicizado <sup>(38,39)</sup>. A publicidade de alimentos utiliza diversos meios de comunicação, como TV, rádio, jornais, revistas, internet, *outdoors*, entre outros para se comunicar com públicos específicos, denominados público-alvo da mensagem publicitária. Normalmente, este grupo apresenta características semelhantes (ex.: faixa etária, sexo biológico, etc.) e é

considerado mais propenso a comprar o produto ou serviço anunciado <sup>(38)</sup>. Visando persuadir o público-alvo, as mensagens publicitárias contêm mecanismos modernos de exposição e poder. Os mecanismos de exposição são usados para que uma publicidade possa atingir um elevado número de pessoas. Entretanto, os mecanismos de poder envolvem investimentos em design, conteúdo criativo, uso de promoções, brindes, colecionáveis, apelos publicitários, alegações de benefícios a partir do uso do produto, entre outros para persuadir o público-alvo <sup>(40)</sup> (Figura 2).

**Figura 2.** Esquema dos conceitos bases apresentados



**Fonte:** Elaborado para fins deste estudo.

Dessa forma, a publicidade de alimentos é projetada para aumentar o apelo de um produto, muitas vezes destacando sua conveniência, sabor, valor nutricional ou apelo social. Através da exposição repetida à publicidade de alimentos, as pessoas podem associar certos alimentos a sentimentos positivos e a hábitos alimentares específicos. Dessa forma, a influência da publicidade de alimentos no comportamento do consumidor pode ser explicada por algumas teorias da psicologia social, que abordam a forma como as pessoas percebem, interpretam e reagem à informação <sup>(41,42)</sup>.

Uma teoria relevante é a *Teoria da Aprendizagem Social*, que sugere que as pessoas aprendem através da observação e da imitação de comportamentos dos seus pares e/ou

pessoas que elas admiram <sup>(41)</sup>. Nesse sentido, as publicidades de alimentos que utilizam, por exemplo, de celebridades, personagens ou até mesmo situações socialmente desejáveis estão aplicando essa teoria para influenciar as pessoas a imitarem um determinado comportamento de consumo <sup>(41,43,44)</sup>.

Outra teoria que pode explicar os mecanismos de como a publicidade de alimentos pode influenciar as escolhas dos consumidores é a *Teoria da Persuasão* <sup>(45)</sup>. A persuasão é definida como comunicação planejada para influenciar os outros, modificando suas crenças, valores ou atitudes <sup>(45)</sup>. Dessa forma, a publicidade de alimentos utiliza várias técnicas de persuasão, como os gatilhos mentais, que são estímulos que ativam o comportamento ou pensamento automático do consumidor <sup>(34,46)</sup>. Alguns dos principais gatilhos mentais incluem, por exemplo: escassez, urgência, reciprocidade, prova social, autoridade, entre outros <sup>(46)</sup>.

Para entender a influência dos gatilhos mentais, é necessário primeiramente entender como se dá o processo de tomada de decisão <sup>(47,48)</sup>. Nesse sentido, é importante ressaltar que os consumidores não tomam decisões sem raciocínio. Diversos fatores influenciam essa decisão, tais como: (i) psicológicos, sociais e culturais; (ii) econômicos e de acessibilidade; (iii) familiares, entre outros <sup>(41,47,48)</sup>.

A tomada de decisão do consumidor no processo de compra passa por três estágios (*reconhecimento da necessidade, busca de informação e avaliação de alternativas*) até chegar na *decisão final* e o *comportamento pós-compra* <sup>(47)</sup>. Quando pensamos na compra de alimentos, todos esses estágios podem ser influenciados pela publicidade de alimentos. No primeiro estágio, *reconhecimento da necessidade*, o consumidor pode ser influenciado pela publicidade de alimentos que cria um desejo ou necessidade pelo produto anunciado. No segundo estágio, *a busca de informação*, a publicidade de alimentos pode fornecer informações que influenciam a percepção do consumidor sobre o produto, como sabor, valor nutricional, benefícios para a saúde, entre outros. No terceiro estágio, *avaliação de alternativas*, a publicidade de alimentos pode fornecer gatilhos mentais que influenciam a decisão de compra do consumidor. Por exemplo, o gatilho mental de escassez pode ser usado para criar uma sensação de urgência no consumidor, fazendo-o acreditar que o produto está em falta ou que a promoção é por tempo limitado, levando-o a tomar uma decisão de compra mais rápida. Já o gatilho mental de prova social pode ser utilizado para persuadir o consumidor, mostrando depoimentos de clientes satisfeitos ou avaliações positivas do produto, influenciando a decisão final do consumidor.

Além disso, teorias que abordam o tempo de decisão, como a *Teoria dos modelos de tomada de decisão dual*, têm revelado mecanismos que desencadeiam escolhas mais rápidas, muitas vezes potencializadas pelo efeito de persuasão <sup>(49,50)</sup>. Esses modelos sugerem que existem dois sistemas de processamento de informações envolvidos na tomada de decisão: um sistema rápido e intuitivo (Sistema 1) e um sistema lento e deliberativo (Sistema 2) <sup>(49,50)</sup>. O sistema rápido é responsável por decisões automáticas e impulsivas, enquanto o sistema lento é usado para decisões mais racionais e ponderadas <sup>(49,50)</sup>. A publicidade de alimentos, como vimos, utiliza estratégias persuasivas para influenciar as escolhas dos consumidores. Essas estratégias são frequentemente direcionadas ao Sistema 1. Através do uso de imagens atraentes, associações emocionais positivas e mensagens convincentes, a publicidade de alimentos busca ativar respostas automáticas e impulsivas nos consumidores. Essas estratégias são projetadas para influenciar a primeira impressão e gerar uma resposta rápida e intuitiva. Ao fazer isso, a publicidade pode ativar heurísticas cognitivas do Sistema 1, como a associação de um alimento com prazer, sabor ou status social. No entanto, o Sistema 2, também desempenha um papel importante na tomada de decisão <sup>(49,50)</sup>. Quando os consumidores são expostos a publicidades de alimentos, eles podem posteriormente engajar o Sistema 2 para uma avaliação mais cuidadosa das informações. O Sistema 2 pode levar em consideração fatores como informações nutricionais, custo-benefício, efeitos a longo prazo na saúde e preferências pessoais. A interação entre os sistemas de processamento pode ser influenciada por diversos fatores, como a exposição prévia à publicidade de alimentos, o contexto de consumo e a motivação dos consumidores. A repetição de anúncios, por exemplo, pode aumentar a familiaridade e a aceitação de determinados produtos alimentares, tornando-os mais propensos a serem selecionados de forma rápida e intuitiva.

Embora o processo de tomada de decisão possa levar tempo e envolver múltiplas etapas, é importante salientar que a publicidade de alimentos emprega teorias e mecanismos que visam acelerar esse processo, conferindo-lhe maior eficiência e, em muitos casos, caráter intuitivo. Esse impacto é particularmente relevante nos tempos atuais, em que a sociedade enfrenta crescentes restrições de tempo. Diante de ritmos de vida acelerados e pouco tempo para planejar e preparar alimentos saudáveis, os indivíduos frequentemente recorrem a decisões rápidas e automáticas no que diz respeito a escolhas alimentares. Nesse contexto, a publicidade de alimentos desempenha um papel crucial, ao utilizar estratégias persuasivas para influenciar tais decisões em momentos de escolha rápida, potencializando, assim, o efeito persuasivo. Consequentemente, a conjunção entre a pressão do tempo e a persuasão



publicitária pode exercer um impacto significativo nas escolhas alimentares dos indivíduos, moldando suas preferências e padrões de consumo.

### **1.3. A exposição à publicidade de alimentos e seus efeitos na saúde**

A publicidade de alimentos se encontra centrada principalmente em alimentos não saudáveis (ou seja: ricos em gorduras saturadas, sódio, açúcares adicionados e pobres em nutrientes protetores), a exemplo dos AUP<sup>(23,26,32,51-54)</sup>. Um relatório recentemente publicado pela OMS (2022)<sup>(36)</sup> apresentou os alimentos mais comumente anunciados em mensagens publicitárias televisivas, na sua grande maioria voltada para o público infantil. Segundo os resultados de estudos publicados entre 2009 e 2020, são eles: (i) produtos de confeitaria: doces, bolos e chocolates; (ii) *fast food*: hambúrgueres e pizzas; (iii) bebidas açucaradas: refrigerantes, sucos e outras bebidas; (iv) cereais matinais; e (vi) *snacks*: batatas fritas e biscoitos. Este documento também elucida que esses alimentos eram mais propensos a serem anunciados durante a programação infantil e nos horários em que as crianças provavelmente assistem à TV, como à tarde e nos finais de semana<sup>(36)</sup>.

As crianças são particularmente suscetíveis às mensagens persuasivas utilizadas nas publicidades de alimentos, pois estão em processo de desenvolvimento cognitivo, o que dificulta o reconhecimento da intenção de venda e persuasão nas publicidades<sup>(55)</sup>. Estudo apontou que crianças menores de 5 anos no estágio de *'pré-reconhecimento'* da defesa cognitiva são incapazes de diferenciar a publicidade televisiva dos programas televisivos, enquanto crianças até 10 anos ainda apresentam grandes dificuldades para descrever a intenção persuasiva das publicidades<sup>(56)</sup>. Devido a isso, a maioria dos estudos focam suas investigações dos efeitos da exposição à publicidade de alimentos na saúde e no comportamento de crianças.

No caso do impacto da exposição de adultos à publicidade de alimentos, as evidências são mais escassas, apesar de alguns estudos já apontarem um possível impacto no comportamento, nas atitudes e nas crenças individuais<sup>(57,58)</sup>. Além disso, indivíduos com menor nível de escolaridade e renda estão mais vulneráveis à publicidade de alimentos, especialmente aqueles que são considerados pouco saudáveis<sup>(59,60)</sup>. No intuito de demonstrar o que já está elucidado na literatura sobre os efeitos da exposição à publicidade de alimentos na saúde da população, o Quadro 1 apresenta um resumo dos estudos de revisões sistemática e meta-análise que investigaram esse tema.

**Quadro 1.** Quadro resumo das evidências de estudos que avaliaram o efeito da exposição à publicidade de alimentos na saúde da população.

<b>Autores</b>	<b>Ano</b>	<b>Desenho do estudo</b>	<b>Amostra</b>	<b>Público estudado</b>	<b>Meio de comunicação</b>	<b>Resultados</b>
Mills <i>et al.</i> <sup>(55)</sup>	2013	Revisão sistemática	9 Estudos experimentais	Adultos	TV	Os estudos não mostraram conclusivamente se a exposição à publicidade de alimentos afeta ou não o comportamento, as atitudes ou crenças relacionadas a alimentos em adultos, mas mostraram que o possível impacto varia de acordo com peso, gênero e comportamento alimentar.
Cairns <i>et al.</i> <sup>(59)</sup>	2013	Revisão sistemática	99 Estudo observacionais 16 Revisões sistemáticas	Crianças	TV	Os estudos mostraram que a exposição à publicidade de alimentos teve efeito direto no conhecimento, comportamento de compra, padrões de consumo e saúde de crianças. A preferência era modificada para alimentos com alto teor de gordura, sal ou açúcar.
Vukmirovic <i>et al.</i> <sup>(56)</sup>	2015	Revisão sistemática	7 Revisões sistemáticas 11 Estudos experimentais	Adultos	TV, <i>outdoors</i> e supermercados	A maioria dos dados revelou associação significativa entre a exposição à publicidade de alimentos ricos em açúcar e a escolha alimentar em adultos.
Sadeghirad <i>et al.</i> <sup>(60)</sup>	2016	Revisão sistemática e meta-análise	<i>Revisão sistemática:</i> 17 estudos experimentais <i>Meta-análise:</i> 9 estudos experimentais	Crianças	TV, jogos online, embalagens e anúncios em livros e revistas	As crianças expostas ao marketing de alimentos não saudáveis aumentaram, em média, 30,4kcal na ingestão alimentar. A exposição influenciou a preferência alimentar e as crianças expostas à publicidade de alimentos não saudáveis eram mais vulneráveis a escolher os alimentos anunciados.
Boyland <i>et al.</i> <sup>(50)</sup>	2016	Revisão sistemática e meta-análise	<i>Revisão sistemática:</i> 22 estudos experimentais <i>Meta-análise:</i> 18 estudos experimentais	Crianças e adultos	TV e internet	Os resultados mostraram que a exposição à publicidade de alimentos aumenta a ingestão de alimentos não saudáveis por crianças, mas não em adultos.
Prowse <sup>(61)</sup>	2017	Revisão sistemática	25 estudos experimentais e observacionais	Crianças	TV, internet, escolas e restaurantes	O marketing de alimentos não saudáveis influencia a ingestão de alimentos calóricos entre crianças. A publicidade de alimentos “divertida” nos locais em que crianças comem, compram ou aprendem, incentiva o consumo de alimentos não saudáveis.

**Fonte:** Elaborado para fins deste estudo com base nas seguintes referências: (52,57,58,61–66)

**Quadro 1.** Quadro resumo das evidências de estudos que avaliaram o efeito da exposição à publicidade de alimentos na saúde da população (continuação).

<b>Autores</b>	<b>Ano</b>	<b>Desenho do estudo</b>	<b>Amostra</b>	<b>Público estudado</b>	<b>Meio de comunicação</b>	<b>Resultados</b>
Russel <i>et al.</i> <sup>(62)</sup>	2019	Revisão sistemática e meta-análise	<i>Revisão sistemática:</i> 39 estudos experimentais e observacionais <i>Meta-análise:</i> 17 estudos experimentais e observacionais	Crianças e adolescentes	TV e jogos online	Crianças expostas à publicidade de alimentos consumiram 60kcal a mais do que as crianças expostas à publicidade não alimentar
Smith <i>et al.</i> <sup>(63)</sup>	2019	Revisão sistemática	71 estudos experimentais e observacionais	Crianças e adolescentes	TV, internet, jogos online, cartaz e embalagem	Os resultados do estudo encontraram um forte corpo de evidências de que a exposição ao marketing de alimentos afeta as atitudes, preferências e consumo de alimentos não saudáveis, especialmente em crianças, com consequências prejudiciais à saúde.
Packer <i>et al.</i> <sup>(64)</sup>	2022	Revisão sistemática e meta-análise	<i>Revisão sistemática:</i> 7 estudos experimentais <i>Meta-análise:</i> 3 estudos experimentais	Crianças	TV, internet, jogos online, cartaz e embalagem	Os resultados mostraram que a exposição à publicidade de alimentos com o endosso de celebridades ou influenciadores digitais resultou em uma ingestão calórica significativamente maior em crianças sob condições experimentais. No entanto, os autores encontraram evidências limitadas de que as celebridades ou os influenciadores afetam as intenções de compra.

**Fonte:** Elaborado para fins deste estudo com base nas seguintes referências: (52,57,58,61–66)

#### 1.4. A televisão como veículo de publicidades de alimentos

Apesar do crescimento do marketing digital <sup>(42)</sup>, a TV ainda continua sendo um dos principais meios para disseminação de informações e conteúdo publicitário <sup>(42,67,68)</sup>. No Brasil, a Pesquisa Nacional por Amostra de Domicílios (PNAD) de 2017 mostrou que de 69,3 milhões de domicílios no país, correspondendo a 97,2%, possuíam pelo menos um aparelho de TV <sup>(69)</sup>. Além disso, pesquisas de mercado indicam que a TV concentra atualmente 79% do tempo de consumo de tela da população brasileira <sup>(70)</sup>. Entre todas as mídias, a TV é o canal de comunicação mais utilizado pelas empresas para divulgação de seus produtos, representando 71% dos investimentos publicitários <sup>(71)</sup>. Inclusive, um estudo publicado em 2022 e que entrevistou 21.678 adultos em cinco países identificou a TV (44%) como o meio de comunicação que os participantes relatam estarem mais expostos à publicidade de alimentos <sup>(72)</sup>.

Assim, a TV é considerada um meio de comunicação estratégico para divulgação de produtos. Além disso, é importante destacar que a relação entre as indústrias televisiva, publicitária e alimentícia é de interdependência e de compartilhamento de interesses comuns <sup>(73)</sup>, o que é justificado pela busca constante por uma audiência qualificada, que gera lucro para os anunciantes e para os meios televisivos <sup>(73)</sup>.

Os investimentos publicitários na TV podem ocorrer de diversas formas, sendo que as principais são por meio de intervalos comerciais e de ações de *merchandising* editorial <sup>(73,74)</sup>. Os intervalos comerciais são espaços específicos na programação da TV destinados exclusivamente à veiculação de anúncios publicitários. Geralmente, eles ocorrem em momentos estratégicos da programação, como antes, durante ou após programas com maior audiência e o custo do anúncio varia de acordo com a duração do mesmo, a programação em que ele será exibido e a época do ano. Já as ações de *merchandising* editorial são inserções publicitárias dentro dos programas de TV, em que o produto ou serviço é apresentado de forma integrada ao conteúdo do programa. Essas inserções podem ser feitas por meio de citações, demonstrações ou outras formas de apresentação do produto, ou serviço. Além dessas formas de investimento publicitário, a TV também pode oferecer outras opções, como patrocínios de programas ou eventos, *product placement* (inserção de produtos em cenas de filmes ou séries), entre outros <sup>(73,74)</sup>.

Dentre essas duas formas de investimento publicitário, o poder da repetição das publicidades nos intervalos comerciais é uma forma eficaz de fixar a mensagem na mente dos telespectadores e despertar diversos gatilhos que criam uma associação entre a marca e o

produto na mente do público, o que pode levar a uma maior lembrança da marca e, conseqüentemente, a uma maior probabilidade de compra <sup>(73,74)</sup>. Além disso, a repetição também pode criar um senso de familiaridade com a marca, o que pode aumentar a confiança dos consumidores e a percepção de qualidade dos produtos publicizados <sup>(73,74)</sup>. Por esse motivo, identificar o conteúdo de publicidade de alimentos na TV por meio de um monitoramento adequado é fundamental para garantir a proteção dos consumidores e promover escolhas saudáveis em relação à alimentação.

### **1.5. O monitoramento da publicidade televisiva**

Estudos de monitoramento da publicidade televisiva de alimentos começaram a ser realizados no início da década de 90 na Austrália <sup>(75)</sup>. Desde as primeiras evidências acerca da influência da publicidade de alimentos sobre o consumo alimentar, vários estudos foram conduzidos em diferentes países para analisar a publicidade veiculada em meios de comunicação em massa, como a TV <sup>(76)</sup>. O monitoramento televisivo de publicidades de alimentos consiste, de forma geral, na gravação completa da programação de canais televisivos populares e em dias específicos. Após essa gravação é necessário a identificação dos momentos exatos em que as publicidades aparecem para criação do banco de dados. Com o banco de dados finalizado, um protocolo de coleta é definido e uma equipe de pesquisadores é treinada para classificar todas as publicidades veiculadas. Com esses dados anotados, um novo protocolo de coleta é definido no intuito de identificar a natureza, por exemplo, das estratégias de marketing presentes nas publicidades de alimentos.

Nesse sentido, um estudo realizado em 2010 envolvendo pesquisadores de quatro continentes (Oceania, Ásia, Europa Ocidental e América) identificou 68.462 (18%) publicidades televisivas de alimentos. Considerando todos os países envolvidos, 67% dos alimentos presentes nas publicidades eram considerados não saudáveis. Além disso, 23% das publicidades de alimentos continham as estratégias persuasivas de alegações de benefícios econômicos e 12% ofertas de prêmios <sup>(53)</sup>.

Após 2010, os estudos de monitoramento da publicidade televisiva de alimentos se tornaram mais frequentes e destacaram a elevada divulgação de alimentos considerados não saudáveis (ex.: AUP, lanches de *fast-food* e bebidas com alto teor de açúcar e sódio), em comparação à baixa participação de alimentos considerados saudáveis (ex.: alimentos *in natura* e minimamente processados) <sup>(61,76-84)</sup>. Esses estudos foram conduzidos em países dos cinco continentes:

- Ásia: Samoa Americana, China, Coréia do Sul, Fiji, Irã, Malásia, Nova Caledônia, Siri Lanka, Samoa, Tailândia e Tonga;
- África: África do Sul;
- América: Argentina, Canadá, Chile, Colômbia, Costa Rica, Estados Unidos da América, Guatemala e México;
- Europa: Alemanha, Espanha, Eslovênia e Reino Unido; e
- Oceania: Austrália e Nova Zelândia.

No Brasil, estudos prévios de monitoramento da publicidade de alimentos na TV também apontaram a elevada participação de alimentos não saudáveis e do uso de estratégias de marketing persuasivas e abusivas<sup>(85-87)</sup> (Quadro 2).

**Quadro 2.** Quadro resumo dos estudos de monitoramento das publicidades de alimentos realizados no Brasil entre 2008 e 2014.

Autores	Ano da coleta	Mês	Número de canais	Número de dias avaliados	Horário	Total de Publicidades avaliadas	Classificação das publicidades de alimentos	% de publicidade de alimentos	Características dos alimentos anunciados e estratégias de marketing
Henriques <i>et al.</i> , (2012) <sup>(83)</sup>	2008	Julho	2 canais abertos da televisão brasileira	8 dias (incluindo dias da semana e final de semana)	Horário da programação infantil, sendo Dias de semana: das 9h às 12h e das 16h às 18h Sábado: das 8h às 12h	1.018	De acordo com o regulamento proposto na Consulta Pública nº71/06	12,9% publicidade de alimentos dirigido ao público infantil	Publicidades de leite acidificado; restaurantes de <i>fast-food</i> , cereais matinais, chocolate, salgadinhos tipo <i>snack</i> , chiclete, creme de avelã e cacau, biscoitos recheados. Estratégias utilizadas: uso de celebridades e personagens infantis (69%); mensagens com apelos de benefício à saúde (50%) e oferta de brindes (46%)
Costa <i>et al.</i> , (2013) <sup>(84)</sup>	2009	Não informado	3 canais abertos da televisão brasileira	10 dias (incluindo dias da semana e final de semana)	Horário da programação infantil, sendo: Dias de semana: das 8h às 18h	1.369	De acordo com a versão do Guia Alimentar para a População Brasileira de 2008	13,8% publicidade de alimentos (excluindo bebidas alcólicas)	Publicidades de alimentos de “açúcares e balas” (48,1%); “óleos, gorduras e sementes oleaginosas” (29,1%); “leites e derivados” (16,4%); “cereais, tubérculos, raízes e derivados” (5,3%) e “vegetais e folhas” (1,1%). O estudo não identificou estratégias de marketing.
Maia <i>et al.</i> , (2017) <sup>(85)</sup>	2014	Janeiro	4 canais abertos da televisão brasileira	2 dias (incluindo dias da semana e final de semana)	Das 06h30 às 23h	2.754	De acordo com a versão do Guia Alimentar para a População Brasileira de 2014	10,2% para alimentos e bebidas e 0,9% para restaurantes	60,7% das publicidades de alimentos eram referentes a AUP, sobretudo de bebidas adoçadas (31,6%) e sorvetes, chocolates e outros doces (17%). Publicidades de bebidas alcoólicas representaram 31,9%. O estudo não identificou estratégias de marketing.

**Fonte:** Elaborado para fins deste estudo com base nas seguintes referências: (85–87).

No entanto, como é possível observar no quadro 2, a comparabilidade entre os resultados desses estudos <sup>(85-87)</sup> e de outros disponíveis na literatura é limitada pela falta de protocolos padronizados para coleta de dados e programação sistemática para realização do monitoramento. Isso significa que diferentes metodologias foram adotadas por esses autores, principalmente se tratando do número de dias analisados, horários das gravações, seleção dos canais e classificação das publicidades (Quadro 2).

Para sanar essa limitação vivenciada por pesquisadores brasileiros e de outros países, em 2017, a rede INFORMAS (*International Network for Food and Obesity/Non-communicable Disease Research, Monitoring and Action Support* – em tradução livre para o português: Rede Internacional para Pesquisa, Monitoramento e Suporte de Ação em Alimentação e Obesidade/Doenças Crônicas não Transmissíveis <sup>(88)</sup>) desenvolveu um protocolo com o objetivo de avaliar o poder e a exposição da promoção de produtos não saudáveis na TV por meio de uma abordagem que orienta a coleta sistemática de informações <sup>(40)</sup>. O protocolo contempla orientações sobre:

- como coletar e analisar os dados;
- quais canais devem ser estudados e em quais datas;
- variáveis a serem coletadas para construção do banco de dados, tais como nome do programa; horário da publicidade (início e término); momento da publicidade; e tipo de publicidade.
- variáveis a serem coletadas para as publicidades relacionadas a alimentos para construção do banco de dados: nome da marca ou empresa de alimentos; nome e descrição do produto; e categoria do alimento.
- variáveis de estratégias de marketing, classificadas em três grupos: *(i)* poder das estratégias de publicidade; *(ii)* uso da oferta de prêmios; e *(iii)* uso de alegações de benefícios da marca.

Com a utilização deste protocolo, Kelly *et al.* (2019) <sup>(79)</sup> descreveram e compararam a publicidade de alimentos em 22 países das regiões Ásia-Pacífico, África, América Central e do Sul, Europa e América do Norte. Entre outros achados, foi identificado que 22% de todos os anúncios televisivos eram de alimentos e bebidas, e que os alimentos e bebidas não saudáveis foram promovidos cerca de quatro vezes mais que os alimentos saudáveis. Além disso, a maior parte das estratégias de marketing se referiram aos caracteres promocionais e ofertas de prêmios nos alimentos anunciados <sup>(81)</sup>. Em 16 países, 30% dos anúncios continham



itens em promoção e, dentre esses, 73% eram de produtos que não poderiam ser anunciados na TV, de acordo com o perfil de nutrientes da OMS<sup>(89)</sup>.

No Brasil, um grupo de pesquisadores da rede INFORMAS também monitorou a publicidade de alimentos adotando essa metodologia em 432 horas de programação dos três principais canais da TV aberta brasileira em abril de 2018<sup>(90)</sup>. Este estudo identificou 7.991 publicidades veiculadas, sendo 14% (n=1.156 publicidades) relacionadas a alimentos. Desse total, 91% (n=780 publicidades) eram de AUP, principalmente refrigerantes, bebidas alcoólicas e refeições prontas. Além disso, outros estudos realizados a partir das análises dos mesmos dados identificaram que:

- (i) 80% dos alimentos anunciados não estavam em conformidade com o modelo de perfil nutricional sugerido pela Organização Pan-Americana da Saúde (OPAS)<sup>(91)</sup> e pela OMS<sup>(89,92)</sup>;
- (ii) 96% das publicidades apresentaram uma ou mais estratégias persuasivas de marketing<sup>(93)</sup>; e
- (iii) 10,1% das publicidades de AUP eram direcionados a crianças e 97,6% utilizavam técnicas que induziam os consumidores a fazerem escolhas prejudiciais à saúde e 57,7% utilizavam algum tipo de técnica abusiva dirigida a crianças e adolescentes<sup>(94)</sup>.

Apesar da proposta de um protocolo padronizado para monitorar a publicidade de alimentos na TV ter auxiliado pesquisas de monitoramento em todo o mundo, alguns desafios ainda permanecem, como a lentidão na realização dos estudos, o alto custo da coleta de dados e a propensão a erros decorrentes do trabalho manual<sup>(95)</sup>. Uma das principais dificuldades no monitoramento manual é identificar e diferenciar a publicidade alimentícia da não alimentícia devido ao grande volume de informações que devem ser processadas manualmente, o que demanda uma equipe grande e bem treinada. Conseqüentemente, as evidências produzidas são potencialmente limitadas em volume e qualidade, o que pode dificultar sua tradução em políticas públicas.

Para superar esses desafios, a utilização de técnicas computacionais pode ser de grande valor para identificar de maneira automática as publicidades de alimentos e as estratégias de marketing utilizadas na TV<sup>(95)</sup>. Tal abordagem tem o potencial de trazer grandes benefícios à saúde pública, permitindo a tomada de medidas mais assertivas e efetivas frente ao cenário da publicidade de alimentos.

## 1.6. Monitoramento automático de publicidades televisivas de alimentos

A computação pode oferecer caminhos para favorecer o monitoramento da publicidade televisiva de alimentos e algumas possibilidades que podem ser empregadas são a utilização da inteligência artificial (IA) e do aprendizado de máquina. A IA é o ramo da ciência da computação que busca desenvolver sistemas capazes de realizar tarefas que requerem inteligência humana, como aprender, raciocinar e se adaptar a novas situações <sup>(96,97)</sup>. Esses sistemas são criados a partir de algoritmos e modelos matemáticos que permitem a interpretação e análise de dados, possibilitando a tomada de decisões baseadas em informações precisas e em tempo real. Apesar de tantos exemplos atuais de aplicações da IA, como alto-falantes inteligentes e carros autônomos, entre outros, o reconhecimento da IA como área de pesquisa é recente (data de 1956) <sup>(97)</sup> e permaneceu, por mais de meio século, com limitado interesse prático. Com o surgimento do “*big data*” e as melhorias no campo da computação, a IA ganhou destaque em diversas áreas <sup>(97)</sup>. Já o aprendizado de máquina é a área da IA que se concentra no desenvolvimento de algoritmos capazes de aprender a partir de dados e experiências anteriores, sem serem explicitamente programados para isso <sup>(96,98)</sup>. Em vez de seguir regras pré-definidas, os algoritmos de aprendizado de máquina utilizam modelos algoritmos para realizar tarefas específicas de forma autônoma. Atualmente, com o desenvolvimento de áreas como aprendizado de máquina, IA e neurociências, o campo de reconhecimento automático de padrões está evoluindo rapidamente e auxiliando diversas áreas.

A indústria publicitária e a de alimentos têm utilizado cada vez mais técnicas computacionais, por exemplo IA, o aprendizado de máquina e outras tecnologias, para disseminar suas mensagens de marketing e ampliar seu mercado <sup>(96,99)</sup>. A IA tem sido muito utilizada para analisar dados de consumo e de demandas de mercado, gerando *insights* que permitam a criação de campanhas publicitárias mais eficientes e personalizadas <sup>(96,99)</sup>. Com essa tecnologia, é possível, por exemplo, segmentar o público-alvo de forma mais precisa, identificar padrões de comportamento dos consumidores, otimizar o processo de veiculação das campanhas e até mesmo criar conteúdos publicitários personalizados para cada usuário. Além disso, a IA também é utilizada para a análise de métricas e resultados, permitindo que as campanhas publicitárias sejam monitoradas em tempo real e ajustadas de acordo com o desempenho. Com essas ferramentas, as empresas podem aumentar o retorno do seu investimento e alcançar resultados mais efetivos <sup>(96,99)</sup>. Já o aprendizado de máquina é aplicado para aprimorar a eficácia e a eficiência das campanhas publicitárias, especialmente

no meio digital <sup>(98)</sup>. Por exemplo, através da análise dos históricos de navegação, é possível exibir anúncios mais relevantes para cada usuário, aumentando as chances de engajamento com a marca. As técnicas de aprendizado de máquina têm se mostrado cada vez mais úteis e relevantes para a publicidade, proporcionando uma experiência mais personalizada e efetiva para os consumidores <sup>(98)</sup>.

Na área da saúde, as técnicas de IA e aprendizado de máquina vêm sendo cada vez mais utilizadas para contribuir com a resolução de problemas, especialmente no monitoramento de vídeo e imagens. Essa abordagem envolve a análise de imagens de vídeo em tempo real para detectar e monitorar parâmetros específicos relacionados à saúde, tais como: a busca por diagnósticos <sup>(100,101)</sup>, reconhecimento de padrões <sup>(102)</sup>, processamentos de um grande volume de dados <sup>(103)</sup>, análise de exames de imagem <sup>(104)</sup> e auxílios à tomada de decisões para tratamentos <sup>(105)</sup>. Já no campo da saúde pública, o monitoramento de vídeo em imagem baseado em IA e aprendizado de máquina pode desempenhar um papel crucial no rastreamento e gerenciamento de doenças, por exemplo, infecciosas <sup>(106)</sup>. Um exemplo recente é a utilização de Algoritmos de IA treinados para analisar dados de vídeo de câmeras de vigilância em locais públicos para identificar pessoas que apresentavam sintomas de gripe que eram característicos da COVID-19 <sup>(107,108)</sup>. Dessa forma, ao detectar e isolar casos potenciais, esses sistemas ajudaram na prevenção da propagação do vírus nas comunidades <sup>(107,108)</sup>. Além disso, o monitoramento de vídeo com IA também foi usado para monitorar a adesão às diretrizes de saúde pública, como o uso de máscaras ou a manutenção do distanciamento social <sup>(108)</sup>. Nesse sentido, essas tecnologias podem ajudar as autoridades a identificar áreas onde falta conformidade, permitindo intervenções direcionadas para promover a saúde e a segurança pública.

Diante de tantas possibilidades, pesquisadores e estudiosos da área de monitoramento do ambiente alimentar também podem e devem se beneficiar do seu uso. Por meio do monitoramento automático de publicidades televisivas, os pesquisadores poderiam utilizar técnicas computacionais de reconhecimento de imagem para capturar e analisar, de forma rápida e precisa, a programação televisiva e identificar uma determinada publicidade. Dessa forma, esses dados poderiam ser usados para avaliar o impacto da publicidade de alimentos na saúde da população e identificar tendências e padrões de consumo de alimentos, permitindo assim um monitoramento contínuo, especialmente em países com menor renda disponível para pesquisa, além de auxiliar no desenvolvimento de políticas públicas mais efetivas para promover escolhas alimentares saudáveis.

Até onde sabemos, não existem muitos trabalhos voltados para o monitoramento automático de publicidades televisivas de alimentos, o que ressalta a proposta original deste estudo. As experiências já documentadas são restritas ao monitoramento de publicidade em mídia digital, devido ao crescimento desse meio (tanto no que está relacionado ao uso por parte da população quanto a sua popularidade) e a maior facilidade de criação de bases de dados para o monitoramento das publicidades nesse meio <sup>(109,110)</sup>. No entanto, estes trabalhos se resumem à publicação de ideias e não apresentaram, até o momento, nenhum resultado da sua eficácia. Apesar disso, pesquisadores e autoridades vêm exprimindo a necessidade de mais esforços para o desenvolvimento de outras ferramentas para uso em outros meios <sup>(36,95,111,112)</sup>. Portanto, é possível observar que apesar dos estudos para o monitoramento automático de publicidades alimentícias serem iniciais, nota-se uma demanda grande e urgente para os resultados de ferramentas eficazes, ágeis, robustas e capazes de otimizar o processo de monitoramento das publicidades de alimentos em diferentes meios de comunicação.

Diante do exposto, acreditamos que através de técnicas de IA e aprendizado de máquina, quando aplicadas no treinamento de algoritmos computacionais de reconhecimento de padrões, permitirão a identificação e a classificação das publicidades alimentícias televisivas no Brasil. Esse tipo de monitoramento tem o potencial de ajudar a promover a tradução dos resultados para políticas públicas que visem a promover um ambiente alimentar saudável e livre de publicidades de alimentos que estimulam o consumo prejudicial à saúde no Brasil.

## **2. OBJETIVOS**

### **2.1. Objetivo geral**

Desenvolver um método baseado em técnicas de IA e aprendizado de máquina capaz de identificar e classificar automaticamente vídeos de publicidades de alimentos e não alimentos.

### **2.2. Objetivos específicos**

- Criar uma base de dados com diferentes tipos de publicidades veiculadas na TV brasileira entre 2018 e 2020.
- Desenvolver um modelo algoritmo que facilite o processo de investigação e classificação de publicidades.
- Identificar e classificar automaticamente as publicidades veiculadas em publicidades alimentícias e não alimentícias.

### 3. MÉTODOS

Este é um estudo metodológico que seguiu as diretrizes do protocolo sobre o monitoramento do marketing de alimentos <sup>(40)</sup>, desenvolvido pela Rede INFORMAS <sup>(88)</sup> para realização das coletas das publicidades e para realização da primeira etapa do protocolo que consiste na identificação e classificação das publicidades televisivas. O estudo foi realizado pelo Departamento de Nutrição da Universidade Federal de Minas Gerais (UFMG), com a colaboração do Instituto de Computação da Universidade Estadual de Campinas (Unicamp). As seis etapas (Figura 3) de execução do estudo serão descritas nas subseções seguintes.

**Figura 3.** Etapas de execução do estudo



**Fonte:** Elaborado para fins deste estudo.

#### 3.1. Coleta de dados

Foram gravadas as transmissões televisivas de três canais da TV aberta brasileira em abril de 2018, maio de 2019 e junho de 2020. Além disso, a programação de 2 canais da TV fechada foi gravada em maio de 2019, setembro de 2019 e junho de 2020 (Tabela 1), estes últimos são canais direcionados ao público infantil. Foram selecionados os canais de maior audiência nacional, de acordo com os dados do Instituto Brasileiro de Opinião Pública e Estatística (IBOPE) <sup>(113)</sup>.

Para cada rodada de coleta de dados, a gravação foi realizada em formato digital por uma empresa especializada em serviço de *clipping* contratada especificamente para esse fim. Foram selecionados por sorteio aleatório oito dias não consecutivos, sendo quatro dias de fins de semana (sábado ou domingo) e quatro dias durante a semana (entre segunda-feira e sexta-feira). A gravação contemplou toda a programação dos canais das 06h às 24h, totalizando 18 horas diárias para cada canal e 2.124 horas nos três anos do estudo.

**Tabela 1.** Detalhamento de cada rodada de coleta de dados por canal

Canais	Anos de Coleta	Meses de coleta	Dias de coleta
Rede Globo	2018	Abril	Dias 05, 14, 15, 19, 22, 24, 25, 29
	2019	Maio	Dias 05, 07, 10, 11, 14, 18, 26, 27
	2020	Junho	Dias 04, 07, 09, 11, 13, 20, 24, 27
SBT	2018	Abril	Dias 05, 14, 15, 19, 22, 24, 25, 29
	2019	Maio	Dias 05, 07, 10, 11, 14, 18, 26, 27
	2020	Junho	Dias 04, 07, 09, 11, 13, 20, 24, 27
Rede Record	2018	Abril	Dias 05, 14, 15, 19, 22, 24, 25, 29
	2019	Maio	Dias 05, 08, 12, 14, 17, 21, 25, 28
	2020	Junho	Dias 04, 07, 09, 11, 13, 20, 24, 27
Discovery Kids*	2019	Maio	Dias 05, 07, 10, 11, 14, 18, 26, 27
	2019	Setembro	Dias 05, 08, 12, 14, 17, 21, 25, 28
	2020	Junho	Dias 04, 07, 09, 20, 24, 27
Cartoon	2019	Maio	Dias 05, 07, 10, 11, 14, 18, 26, 27
	2019	Setembro	Dias 05, 08, 12, 14, 17, 21, 25, 28
	2020	Junho	Dias 04, 07, 09, 11, 13, 20, 24, 27

\* Perda de dois dias (11,13) de gravação na coleta de junho de 2020 para o canal.

**Fonte:** Elaborado para fins deste estudo.

### 3.1.1. Auditoria, codificação de dados e criação dos bancos de dados

Após a conclusão das gravações pela empresa de *clipping*, o conteúdo foi auditado em cinco etapas para gerar a base completa dos dados de todas as publicidades veiculadas em cada rodada de coleta de dados (Figura 4).

- **Primeira etapa – Auditoria realizada pela empresa responsável por realizar as gravações:** a empresa identificou o número total de publicidades e codificou as publicidades de alimentos, bebidas e locais de venda destes produtos. As publicidades relacionadas a alimentos e bebidas foram individualmente identificadas. Veiculações repetidas de uma mesma publicidade foram identificadas de acordo com o código inicialmente utilizado para a publicidade (definido na primeira veiculação registrada, independente do canal). Alterações no conteúdo ou duração de uma publicidade foram suficientes para que lhe fosse atribuído um novo código de identificação, ainda que

essa se remetesse a uma campanha publicitária ou produto para os quais outras publicidades já haviam sido identificadas (por exemplo, publicidade de uma mesma marca de refrigerante com a mesma identidade visual, mas com durações distintas ou publicidades de uma mesma rede de *fast-food* anunciando sanduíches distintos que pertenciam a uma mesma série especial de produtos). Todas as demais publicidades (sem relação com alimentação) foram identificadas com um mesmo código.

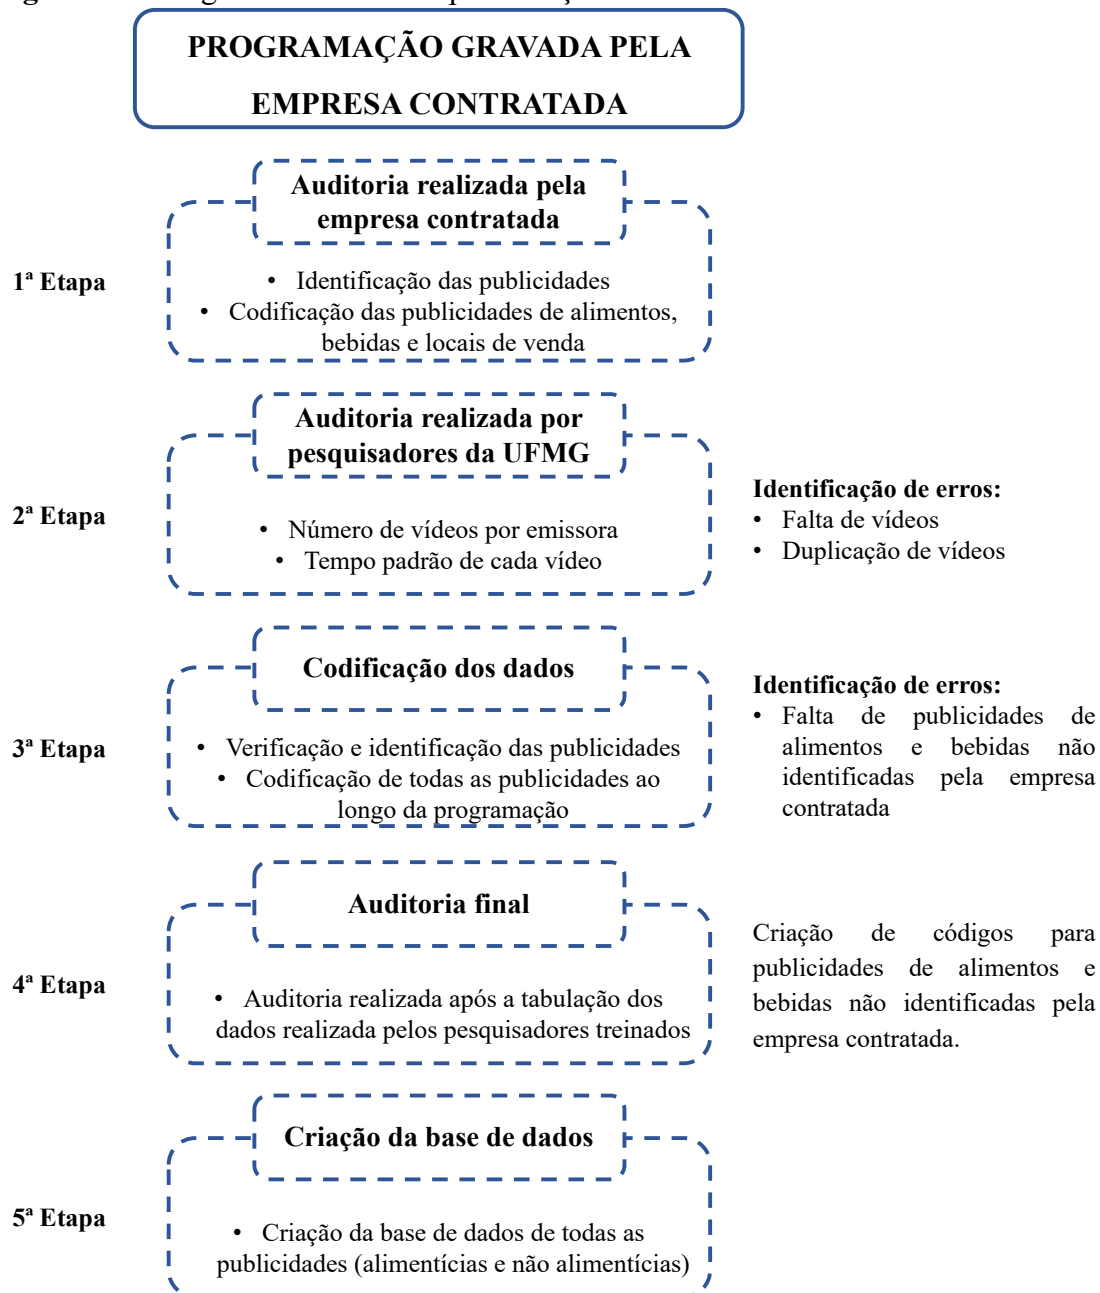
- ***Segunda etapa – Auditoria realizada por pesquisadores treinados:*** dois pesquisadores da UFMG foram treinados e realizaram a auditoria da gravação de maneira independente. Ambos os pesquisadores fizeram uma verificação geral do número e tempo dos vídeos gravados em cada emissora. A gravação ocorreu em vídeos de dez minutos durante o dia, ou seja, em uma hora de gravação existiam seis vídeos de dez minutos. Com essa auditoria foi possível identificar ausência de algum período de tempo de gravação ou até mesmo duplicação de vídeos.
- ***Terceira Etapa – Codificação dos dados:*** todas as publicidades foram tabuladas em um questionário eletrônico (Tabela 2), construído no Epi InfoTM, versão 7.2.2.6 (Anexo A). Para esta tabulação de dados, foram selecionados dez voluntários, que formaram cinco duplas, entre eles, alunos do curso de Nutrição e alunos do curso de Pós-graduação em Nutrição e Saúde da UFMG, devidamente treinados. Cada aluno ficou responsável pela extração de dados de oito dias de gravação, os dados foram duplamente tabulados para conferência.
- ***Quarta Etapa – Auditoria final:*** após o processo de tabulação dos dados, foi realizada uma auditoria abrangente por dois pesquisadores independentes para identificar eventuais divergências entre as duplas envolvidas na tabulação. A taxa de confiabilidade Inter codificador variou de 90,4% a 96%, indicando um alto nível de concordância entre os pesquisadores. Esse exame minucioso permitiu a identificação de anúncios adicionais de alimentos e bebidas que não foram inicialmente detectados na auditoria inicial.
- ***Quinta Etapa – Criação da base de dados de todas as publicidades:*** após essa auditoria final um banco de dados contendo todas as informações de todas as publicidades (alimentícias e não alimentícias) foi gerado.

Para todas as publicidades foram extraídas todas as variáveis contidas na Tabela 2 e todos os programas foram categorizados e classificados entre 14 tipos: documentário; esportes (programa específico ou um evento esportivo); filme (não específico para crianças); infantil



(ex. desenho, filme, série ou outro programa voltado para crianças); música ou vídeo musical; notícias, comentários, programas políticos; novela (não específica para crianças); programa de entrevistas; reality show; relacionado a saúde; religioso; série (não específica para crianças); e variedades de entretenimento. Dessa forma, uma planilha contendo todas as anotações detalhadas de todos os dados pertinentes a esses anúncios foi gerada. Esses dados foram indispensáveis para o treinamento do algoritmo e para a realização deste estudo.

**Figura 4.** Fluxograma de auditoria para criação do banco de dados



**Fonte:** Elaborado para fins deste estudo.

**Tabela 2.** Variáveis utilizadas para extração geral dos dados da publicidade televisiva de alimentos.

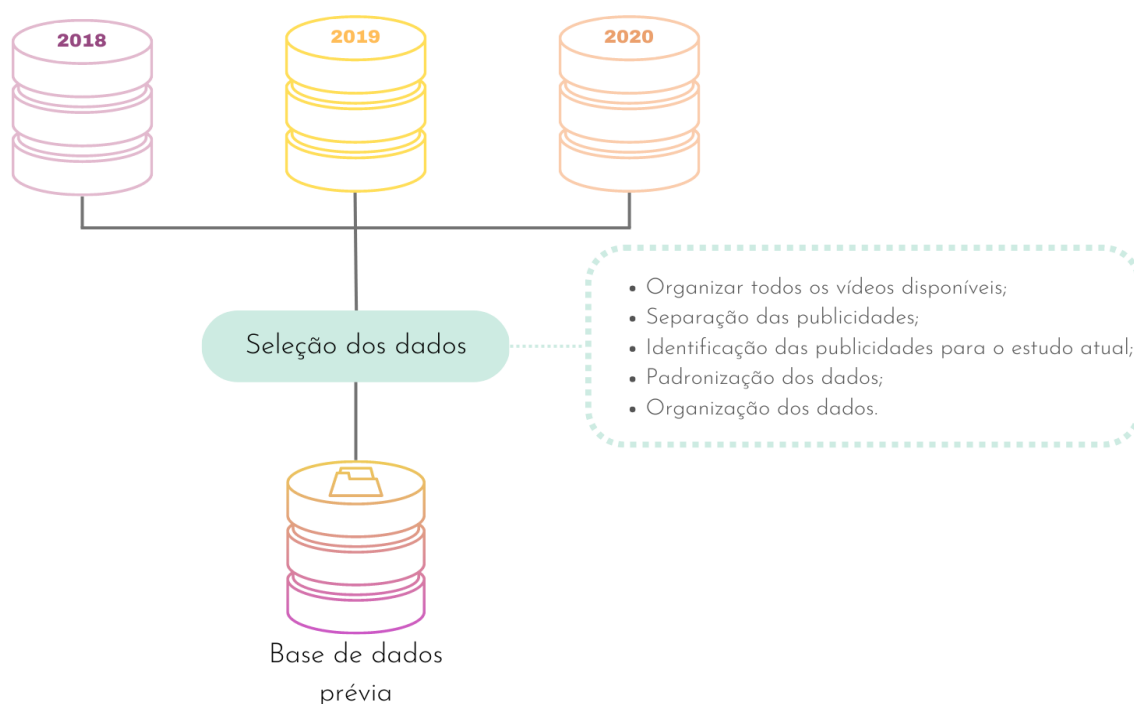
Variável	Descrição
Nome do canal	Opções dos canais avaliados
Data da gravação	Opções dos 8 dias gravados
Nome do programa	Nome do programa de acordo com a grade do canal
Horário da publicidade	Opções dos horários:
	06:00-06:59
	07:00-07:59
	08:00-08:59
	09:00-09:59
	10:00-10:59
	11:00-11:59
	12:00-12:59
	13:00-13:59
	14:00-14:59
	15:00-15:59
	16:00-16:59
	17:00-17:59
	18:00-18:59
19:00-19:59	
20:00-20:59	
21:00-21:59	
22:00-22:59	
23:00-23:59	
Horário de início da publicidade	No formato “HH:MM:SS” (hora, minuto, segundo)
Horário de término da publicidade	No formato “HH:MM:SS” (hora, minuto, segundo)
Momento da publicidade	Opções disponíveis:
	Intervalo de um programa específico Intervalo entre dois programas
Tipo de publicidade	Opções disponíveis:
	Alimento ou bebida – empresa/marca de alimentos
	Alimento ou bebida – não anunciado pela empresa/marca do produto
	Empresa/marca de alimentos sem anunciar um produto
	Revendedor de alimentos (supermercado e loja de conveniência) anunciando alimentos
	Revendedor de alimentos (supermercado e loja de conveniência) sem anunciar alimentos
	Revendedor de alimentos (restaurante/fast-food) anunciando alimentos
Revendedor de alimentos (restaurante/fast-food) sem anunciar alimentos	
Produto não alimentício	
Código da publicidade	Código de seis dígitos para cada publicidade copiada da grade de monitoramento. Para as publicidades não alimentícias foram adicionados o código “999999”

**Fonte:** Elaborado para fins deste estudo, a partir dos dados do protocolo de monitoramento da publicidade televisiva de alimentos<sup>(40)</sup> da rede INFORMAS (88).

### 3.2. Seleção dos dados

Foi realizada uma verificação de todos os dados disponíveis com o objetivo de: (i) Organizar todos os vídeos disponíveis; (ii) Separar as publicidades de alimentos; (ii) Identificar as publicidades para criação da base para o estudo atual; (iii) Padronizar os dados das três bases; e (iv) Organizar os dados. Essa verificação resultou em uma base única de dados do atual estudo. Visando tornar mais claro o delineamento da etapa de seleção de dados de treinamento, um fluxograma (Figura 5) é apresentado para sintetizar a metodologia adotada para a coleta de dados e seleção dos dados que constituíram a base única denominada “Base de dados prévia”.

**Figura 5.** Síntese da metodologia que compreende a etapa de seleção de dados de treinamento



**Fonte:** Elaborado para fins deste estudo.

### 3.3. Pré-processamento de dados

Para o processamento dos dados era necessário que todas as publicidades alimentícias e não alimentícias, que foram veiculadas durante os três anos de coleta, estivessem separadas em vídeos individuais. No entanto, seguindo o protocolo INFORMAS, somente os cortes das publicidades alimentícias estavam disponíveis. Sendo assim, todas as publicidades não alimentícias estavam misturadas com a programação completa e separados em vários vídeos de 10 minutos. Dessa forma, foi necessário automatizar o processo de corte desses vídeos

completos de cada canal, através dos registros de data e hora anotados pela equipe do Departamento de Nutrição da UFMG.

Para isso, a equipe do Instituto de Computação da Unicamp criou um código Python usando o *FFmpeg*<sup>1</sup>, uma solução completa de plataforma cruzada que contém uma coleção de bibliotecas de códigos, ferramentas e programas capaz de gravar, converter e cortar áudio e vídeo. Com esta etapa, foi identificada a presença de várias publicidades não alimentícias duplicadas nos vídeos recém-cortados, correspondendo a cerca de 80% dos vídeos coletados. As cópias consistiam em dois tipos: (i) duplicatas exatas dos vídeos e (ii) versões reduzidas de uma publicidade original. Para resolver esse problema, a equipe aplicou uma função de *average hash*, um algoritmo simples e eficiente para identificar duplicatas. É importante ressaltar que após essa etapa, foi possível criar a “base inicial de dados”, a primeira desse tipo no Brasil. Até o momento, a “base inicial de dados” contém 603 vídeos distintos de publicidades alimentícias e mais de 20.000 vídeos de publicidades não alimentícias. Seguindo as recomendações feitas no artigo *Datasheets for Datasets* <sup>(114)</sup>, nós disponibilizaremos a base de dados publicamente.

### 3.4. Divisão da base de dados inicial

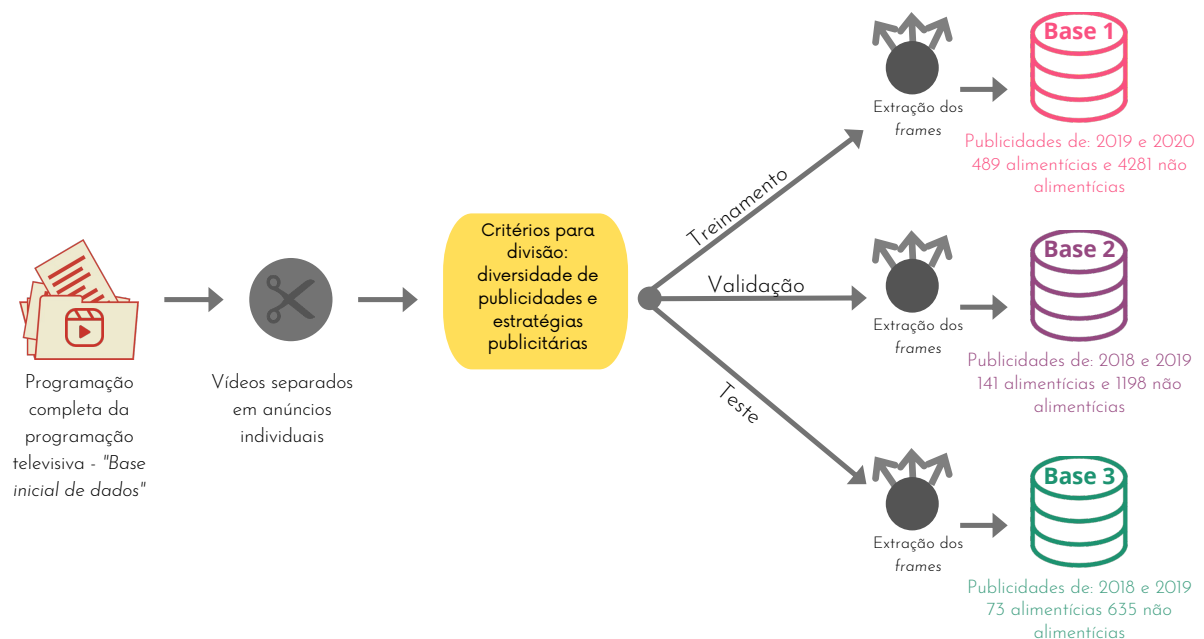
Após o pré-processamento dos dados, dividimos o banco de dados para treinar o modelo de aprendizado de máquina. Dividimos manualmente o “banco de dados inicial” em três bancos de dados: treino, validação e teste (Figura 6). A base de treino foi utilizada para o treinamento dos modelos, denominada Base 1. A base de validação, denominada Base 2, foi utilizada para ajustar os hiperparâmetros do modelo, avaliar e validar o seu desempenho. Por fim, a base de teste, denominada Base 3, foi utilizada para avaliar o desempenho final do modelo em dados novos (que nunca foram vistos). Optamos por uma divisão manual e minuciosa, visto que uma divisão aleatória não levaria alguns critérios que são importantes para o aprendizado do modelo como: representatividade de todas as empresas e tipos de publicidades, especialmente as publicidades alimentícias, em todas as três bases. Dessa forma, a divisão realizada foi: (i) para a Base 1, incluímos todas as publicidades de 2020 e as publicidades coletadas no segundo semestre de 2019, sendo: 489 vídeos de publicidades alimentícias e 4.281 vídeos de publicidades não alimentícias, totalizando: 4.770 vídeos publicitários; (ii) para a Base 2, incluímos as publicidades do primeiro semestre de 2019 e parte das publicidades de 2018, sendo: 141 vídeos de publicidades alimentícias e 1.198 vídeos

---

<sup>1</sup> <https://ffmpeg.org/>

de publicidades não alimentícias, totalizando: 1.339 vídeos publicitários; e (iii) para a Base 3, incluímos apenas publicidades de 2018, com exceção de alguns casos de canais infantis, que foram coletados a partir de 2019, sendo: 73 vídeos de publicidades alimentícias e 635 vídeos de publicidades não alimentícias, totalizando: 708 vídeos publicitários. Essa divisão foi realizada considerando a proporção recomendada de 75% para treinamento, 15% para validação e 10% para teste <sup>(115)</sup>. Em aprendizado de máquina, essa divisão de dados em subconjuntos é vital para evitar o *overfitting*, um problema comum no qual o modelo se torna muito especializado nos dados de treinamento, perdendo sua capacidade de generalizar para dados novos e não vistos <sup>(115)</sup>. Dividimos os dados de forma a alocar a maior parte deles para treinar o modelo, garantindo que a Base 2 e a Base 3 ainda representassem todo o banco de dados inicial. Além disso, aplicamos estratégias específicas durante o processo de treinamento do modelo devido aos dados desbalanceados, onde os anúncios não alimentícios eram a maioria. Essas estratégias serão discutidas mais adiante.

**Figura 6.** Síntese da metodologia que compreende a divisão da base inicial dos dados



**Fonte:** Elaborado para fins deste estudo.

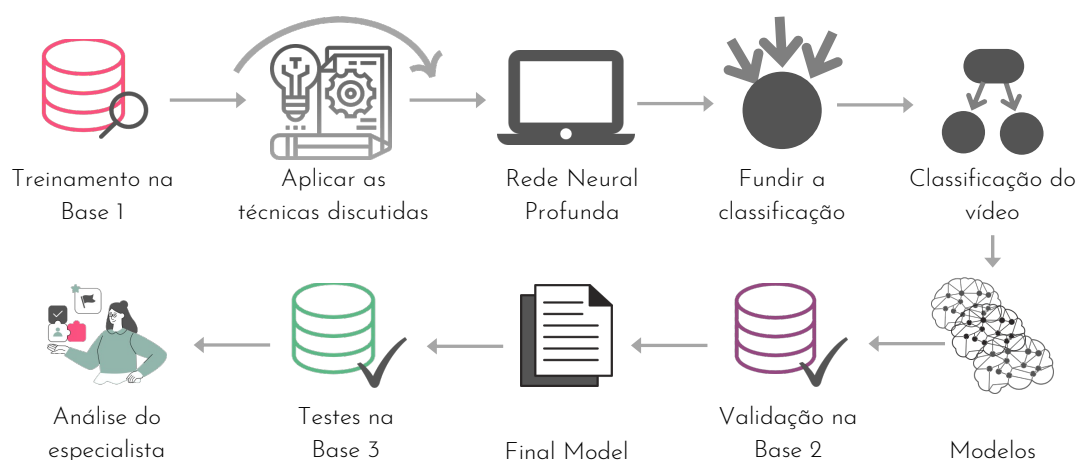
### 3.5. Treinamento e validação dos modelos computacionais

#### 3.5.1. Visão geral

Essa etapa foi executada pela equipe do Instituto de Computação da Unicamp e foi composta por duas sub etapas: (i) treinamento e (ii) validação. A equipe investigou técnicas de extração de características e classificação de imagens/vídeos, além de técnicas de

interpretabilidade de modelos. Estas podem ser uma ferramenta útil de depuração para encontrar fontes de erros preditivos dos modelos, principalmente para modelos caixas-pretas, como as redes neurais profundas<sup>(116)</sup>. Dessa forma, a rede neural profunda *EfficientNet*<sup>(117)</sup> foi utilizada como modelo, por ser o estado-da-arte para diversas tarefas, inclusive classificação de imagens/vídeos. Visto que a eficácia do modelo é altamente dependente da arquitetura base da rede, a *EfficientNet* oferece oito versões diferentes dessa arquitetura básica (*EfficientNet-B0* a *EfficientNet-B7*). Dessa forma, usamos a melhor arquitetura (*EfficientNet-B7*, que foi previamente treinado em um conjunto de dados *ImageNet*). Por exemplo, *EfficientNet-B0* tem 5,3 milhões de parâmetros, enquanto a *EfficientNet-B7* tem 66 milhões. Além disso, a *EfficientNet-B0* atinge 77,3% de precisão *top-1* no *ImageNet*, enquanto a *EfficientNet-B7* atinge 84,3%. Apesar da *EfficientNet-B7* vir com um custo computacional maior e um tempo de treinamento mais longo, ela consegue fornecer os melhores resultados possíveis para o nosso problema. Uma visão geral do fluxograma da abordagem proposta é ilustrada na Figura 7.

**Figura 7.** Síntese do treinamento e validação nas Bases 1 e 2.



**Fonte:** Elaborado para fins deste estudo.

Primeiramente, utilizando os dados da Base 1 (dados de treino), extraímos todos os *frames* dos vídeos (cada vídeo se refere a uma publicidade) e aplicamos algumas técnicas para mitigar o desequilíbrio de dados. Em seguida, os *frames* passaram pela rede neural profunda escolhida (a *EfficientNet*) gerando uma classificação para cada *frame*. Para obtenção de uma única classificação para a publicidade, o resultado obtido para cada *frame* de uma mesma publicidade passou por um processo de fusão por meio de um método de *pooling*. Esses processos resultaram em uma série de diferentes modelos treinados. Dessa forma,

determinamos os melhores modelos e estratégias aplicadas para serem validadas com as publicidades separadas na Base 2 (dados de validação). Essa última etapa serviu para indicar a necessidade de alguma adaptação nas técnicas aplicadas durante o treinamento. Após pequenas alterações necessárias, o melhor modelo obtido naquele momento foi selecionado para ser testado na Base 3 (dados de teste) e assim finalmente obtivemos os resultados que foram verificados e analisados por pesquisadores e especialistas na área de monitoramento de publicidades.

### 3.5.2. Abordagem para classificação

Usando a Base 1 (dados de treino), foi proposta uma abordagem para classificar imagens e vídeos de publicidades de alimentos. Primeiramente, uma pequena parte dos vídeos da Base 1 foi separada para validar inicialmente os resultados, a fim de reduzir o viés do modelo e selecionar os melhores modelos a serem validados. Para a divisão desses dados, foram realizadas duas separações: uma aleatória e a outra manual. A separação aleatória foi feita de forma automática, por meio de um sorteio randomizado, o que não considerava os anunciantes, mas sim a representatividade dos anos de coleta (2018, 2019 e 2020). A segunda, foi selecionada manualmente e teve como critério de separação a necessidade de garantir que o grupo de pré-validação de alimentos não apresentasse apenas publicidades de um único anunciante, ou seja, que representasse o conjunto de treinamento em sua totalidade e diversidade. Além disso, isso garantiu que, em ambos os casos, o grupo destinado a treinar o modelo tivesse a mesma porcentagem de anúncios de alimentos e não alimentos, ou seja, separamos os conjuntos de maneira equilibrada.

Como entrada para a rede neural profunda, os *frames* brutos das publicidades de alimentos foram usados em uma amostra de um *frame* por segundo (1 fps), enquanto para as publicidades não alimentícias foram coletados da seguinte forma, onde  $t$  é a duração da publicidade em segundos:

- $1/2$  *frames* por segundos, se  $t \leq 10$
- $1/4$  *frames* por segundos, se  $t \geq 11$  e  $t \leq 25$
- $1/6$  *frames* por segundos, se  $t \geq 26$  e  $t \leq 35$
- $t/15$  *frames* por segundos, se  $t \geq 36$  e  $t \leq 60$
- $t/30$  *frames* por segundos, se  $t \geq 61$  e  $t \leq 120$
- $t/45$  *frames* por segundos, se  $t \geq 121$

Esta decisão foi tomada para minimizar o desequilíbrio notado durante os testes anteriores. Todos os *frames* foram padronizados e centralizados conforme a métrica compatível com o tamanho da entrada do modelo escolhido: para *EfficientNet-B7*, a resolução varia de 224×224 a 600×600 pixels.

Dessa forma, cada *frame* extraído das publicidades foi classificado de forma independente. Para determinar a categoria da publicidade (alimentícia ou não alimentícia), empregamos uma abordagem de tomada de decisão. Usamos estratégias de média ponderada e simples para combinar as previsões de *frame* por vídeo em uma única previsão final por vídeo.

No entanto, no decorrer do estudo, foi observado que esse tipo de abordagem de retirar apenas os *frames* dos vídeos em diferentes taxas, dependendo da classe, não era suficiente para superar o desequilíbrio dos dados. Para solucionar o problema, aplicamos três estratégias diferentes a fim de encontrar o melhor resultado: “*Data augmentation*” (em português: aumento de dados), “*Balanced batches*” (em português: balanceamento de lotes) e “*Class weights*” (em português: pesos das classes). Ressalta-se que o código foi desenvolvido de maneira que é possível aplicar qualquer combinação dessas técnicas. No entanto, nem todas as combinações são necessariamente relevantes.

#### 3.5.2.1. “*Data augmentation*”

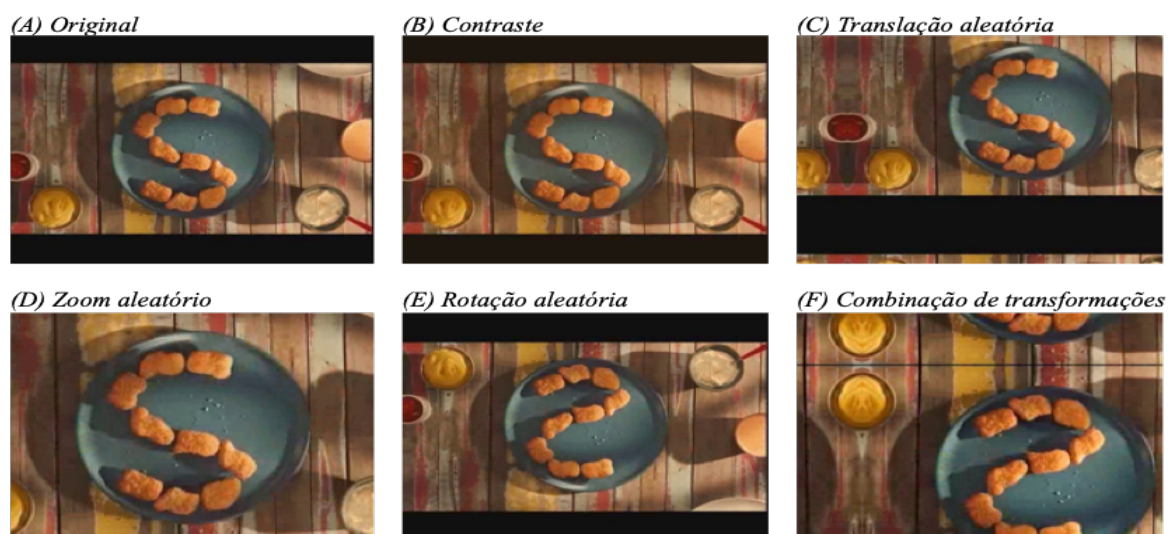
Técnica utilizada em aprendizado de máquina e outras áreas de análise de dados, que tem como objetivo aumentar artificialmente a quantidade de dados disponíveis para treinar um modelo ou algoritmo (118). Essa técnica consiste em criar novos exemplos de dados a partir dos dados originais, através da aplicação de transformações e alterações nos dados existentes, mantendo a informação original. Essas transformações podem incluir no caso de imagem, por exemplo, rotações, mudanças de escala, alterações de contraste e brilho, recortes e outras modificações que não afetam a informação fundamental dos dados.

O objetivo da técnica “*data augmentation*” é evitar o *overfitting*, que é o problema em que o modelo se ajusta excessivamente aos dados de treinamento e não generaliza bem para novos dados, melhorando a robustez e a capacidade de generalização do modelo. Além disso, a técnica “*data augmentation*” também pode ajudar a corrigir o desequilíbrio dos dados, gerando novos exemplos para as classes menos representativas. Neste estudo, aplicamos as seguintes transformações para os *frames* extraídos das publicidades de alimentos: rotação, translação, *zoom*, adição ou remoção de contraste e rotações no eixo vertical e/ou horizontal



(Figura 8). Para isso, utilizamos a *Biblioteca keras*<sup>2</sup>, que permite a aplicação de mais de uma transformação por imagem. Ao final desse processo, o desequilíbrio de classes é atenuado pela inserção de novos dados gerados aleatoriamente para a classe sub representada (publicidades de alimentos).

**Figura 8.** Exemplos das transformações da técnica “*data augmentation*” executadas em um *frame* de uma publicidade de alimento.



**Fonte:** Elaborado para fins deste estudo.

### 3.5.2.2. “*Balanced batches*”

Técnica utilizada no treinamento de modelos de aprendizado de máquina que visa equilibrar a distribuição de classes nos dados de treinamento. Dessa forma, no aprendizado de máquina, um *batch* é um conjunto de dados de entrada processados durante o treinamento. Quando os dados apresentam uma grande desigualdade na distribuição das classes, o modelo pode ter dificuldades para aprender a representação das classes menos frequentes e acabar por dar mais peso às classes mais comuns. Isso pode levar a resultados ruins na classificação das classes menos frequentes.

Os “*Balanced batches*” buscam corrigir essa desigualdade amostral, selecionando um número igual de exemplos de cada classe para compor cada *batch*. Dessa forma, o modelo é exposto a um conjunto equilibrado de exemplos de todas as classes durante o treinamento, o que ajuda a garantir que todas as classes sejam igualmente representadas e o modelo possa aprender a distinguir entre elas com mais precisão. Essa técnica é particularmente útil em

<sup>2</sup> <https://keras.io/api/models/sequential>

problemas de classificação binária ou multi-classe, onde a distribuição das classes é desigual. É importante notar que os “*Balanced batches*” não resolvem o problema da desigualdade nos dados de treinamento, mas ajudam a mitigar os efeitos da desigualdade na fase de treinamento do modelo. Neste estudo, utilizamos a biblioteca *imbalanced-learn Python*<sup>3</sup>, que cria um gerador de dados balanceados, repetindo amostras aleatórias do banco de dados caso não haja imagens suficientes para balancear as classes dentro do lote em questão.

### 3.5.2.3. “*Class weights*”

Técnica utilizada para lidar com conjuntos de dados desbalanceados em tarefas de classificação de aprendizado de máquina. Essa técnica atribui um peso diferente a cada classe durante o treinamento do modelo, com o objetivo de dar mais importância às classes minoritárias. Por exemplo, se em um conjunto de dados de publicidades, a classe “não alimentícia” tem 90% dos exemplos e a classe “alimentícia” tem apenas 10%, a técnica de “*class weights*” irá atribuir um peso maior à classe “alimentícia” durante o treinamento do modelo, para que ele dê mais importância a essa classe durante a aprendizagem. Essa técnica pode ser implementada de diversas formas, como atribuindo pesos inversamente proporcionais à frequência de cada classe ou utilizando técnicas mais avançadas, como o uso de redes neurais com pesos adaptativos. O objetivo é fazer com que o modelo seja capaz de aprender de forma equilibrada com todas as classes, mesmo que algumas delas sejam muito menos representadas nos dados. O uso da técnica “*class weights*” pode melhorar significativamente a capacidade do modelo de lidar com conjuntos de dados desbalanceados e evitar o viés em direção à classe majoritária. Neste estudo, utilizamos a biblioteca *Scikit-learn Python*<sup>4</sup>, que contém uma função que estima pesos de classes para bancos de dados desbalanceados.

### 3.5.3. *Aplicações dos modelos*

A seguir será detalhado como ocorreu as aplicações dos modelos de treinamento, validação e teste nas bases de dados para identificar e classificar tanto as publicidades alimentícias e não alimentícias.

---

<sup>3</sup> <https://imbalanced-learn.org/stable/references/generated/imblearn.keras.BalancedBatchGenerator.html>

<sup>4</sup> [https://scikit-learn.org/stable/modules/generated/sklearn.utils.class\\_weight.compute\\_class\\_weight.html](https://scikit-learn.org/stable/modules/generated/sklearn.utils.class_weight.compute_class_weight.html)

### 3.5.3.1. Modelo de treinamento

Treinamos todos os modelos na Base 1 para determinar qual técnica ou combinação de técnicas forneceria os melhores resultados. No total, realizamos oito experimentos, sete incluindo todas as combinações possíveis das técnicas discutidas anteriormente e um sem a aplicação de nenhuma. Replicamos cada experimento cinco vezes para avaliar a variabilidade, totalizando 40 modelos treinados.

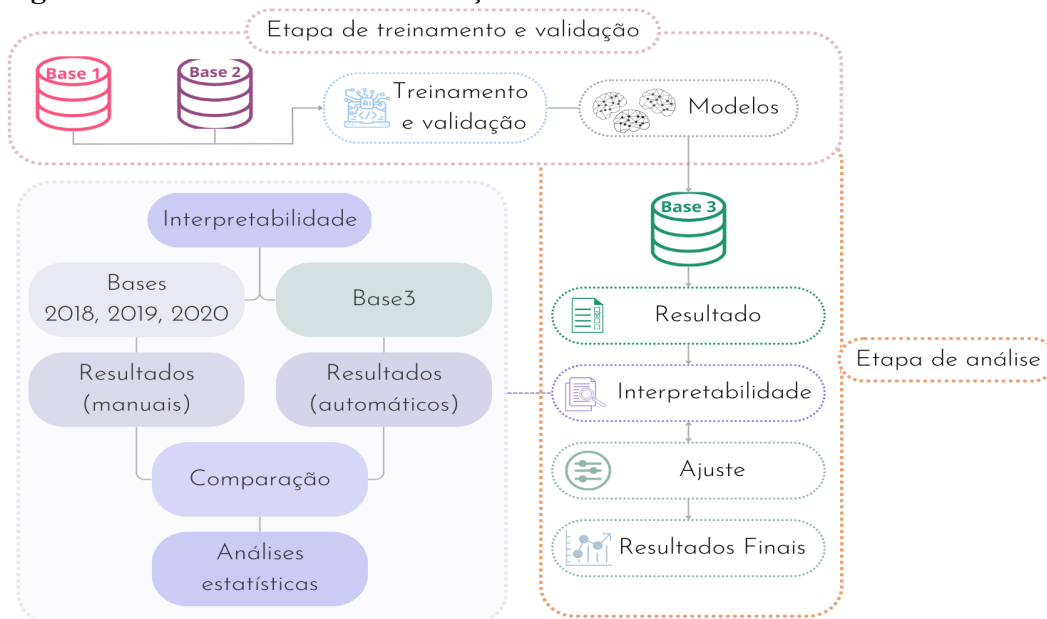
### 3.5.3.2. Modelo de validação

Validamos todos os modelos na Base 2 para certificar suas previsões. Para cada um dos 40 modelos, exploramos quatro métodos para mesclar a classificação dos *frames* em uma classificação de vídeo. Isso envolveu variar o peso atribuído aos *frames* classificados como parte de nossa classe de interesse (publicidades de alimentos) nos seguintes pesos: 1, 2, 3 e 4, resultando em 160 abordagens diferentes. Além disso, buscamos encontrar fontes de erros preditivos nos modelos, que serão discutidas posteriormente. As métricas usadas para avaliar os modelos foram precisão balanceada e matriz de confusão.

### 3.5.3.3. Modelo de teste

Após o treinamento e validação dos modelos utilizando as Bases 1 e 2, uma etapa de teste foi necessária para certificar a exatidão dos resultados fornecidos. Para isso, o modelo proposto foi aplicado na Base 3 (Figura 9), para verificar a generalização do modelo.

**Figura 9.** Síntese da análise e validação dos dados.



**Fonte:** Elaborado para fins deste estudo.

Dessa forma, testamos na Base 3 apenas o modelo de melhor desempenho com a melhor abordagem de mesclagem entre as 160 possibilidades. A etapa visou avaliar o desempenho do modelo em novos dados, ou seja, dados que o modelo ainda não havia tido contato, para ter uma ideia mais realista de como o modelo se comportaria fora de um ambiente controlado, classificando novas publicidades. Também procuramos encontrar as fontes de erros preditivos no modelo e, como no modelo de validação, as métricas usadas para avaliar os modelos foram acurácia balanceada e matriz de confusão. Os resultados obtidos foram analisados pela equipe do Departamento de Nutrição da UFMG com experiência em monitoramento de publicidade de alimentos. Visto que, diferentemente da análise humana, as decisões tomadas pelos modelos computacionais (baseados em redes neurais profundas) não podem ser interpretadas de forma racional e baseada nas evidências existentes (116) essa etapa de interpretabilidade se faz necessária.

### **3.6. Análise estatística e análise de resultados algorítmicos**

Os principais resultados dos modelos treinados foram retratados pelas matrizes de confusão de vídeo dos seguintes conjuntos. Uma matriz de confusão é uma tabela usada para avaliar o desempenho de um modelo de classificação. Normalmente, é usado em aprendizado de máquina e estatística para medir a acurácia geral das previsões de um modelo. A matriz compara a saída prevista de um modelo com a saída real e categoriza os resultados em quatro grupos: verdadeiro positivo (VP), verdadeiro negativo (VN), falso positivo (FP) e falso negativo (FN).

A previsão VP representa quando o modelo previu corretamente a classe positiva (ou seja, publicidades de alimentos) e o número de previsões VN representa quando o modelo previu corretamente a classe negativa (ou seja, publicidades não alimentícias). Além disso, a previsão FP representa quando o modelo previu uma classe positiva, mas foi realmente negativa, e a previsão FN representa quando o modelo previu uma classe negativa, mas foi realmente positiva. Assim, a porcentagem do número de FP, FN, VP e VN foram retratados em matrizes.

Para auxiliar na avaliação da precisão do modelo em prever a classificação de cada vídeo, utilizamos a saída do nível de confiança fornecida pelo algoritmo. O nível de confiança serve como um indicador da certeza ou da confiança do modelo em sua decisão de classificação, refletindo sua certeza na precisão da previsão. Sendo assim, ao categorizar um vídeo como alimento ou não alimento, o modelo forneceu um nível de confiança ao lado do

rótulo de cada vídeo previsto. Esse nível de confiança foi expresso em porcentagem, variando de 0% a 100%.

Para estabelecer um critério de confiabilidade das previsões do modelo, especialistas na área de monitoramento de publicidade de alimentos revisaram e analisaram todos os anúncios classificados erroneamente pelo algoritmo. Isso foi feito para verificar as possíveis inconsistências e erros preditivos. Também adotamos um limite (determinado empiricamente) de 65% onde o especialista revisou manualmente um vídeo com uma confiança inferior a essa taxa (de 50% a 65%). Ao incorporar a revisão de vídeos classificados corretamente, mas com menor nível de confiança, buscamos melhorar a interpretabilidade e a confiabilidade das previsões do modelo, permitindo uma avaliação mais detalhada de seu desempenho para garantir a qualidade da classificação, especificamente para anúncios de alimentos. Ambas as etapas foram realizadas para identificar os motivos que podem ter contribuído para a classificação incorreta.

### **3.7. Aspectos éticos**

O presente estudo não envolve coleta de dados ou qualquer experimento envolvendo seres humanos. Por este motivo, dispensa apreciação por Comitê de Ética em Pesquisa.

## 4. RESULTADOS E DISCUSSÃO

### **Revolutionizing food advertising monitoring: A machine learning-based method for automated classification of food and non-food videos**

#### **Abstract**

**Objective:** Food advertising is an important determinant to unhealthy eating. However, monitoring food advertising presents significant challenges, particularly in the initial step of analyzing an extensive number of advertisements (ads) to differentiate between food and non-food related content. This study aims to develop a machine learning-based method to identify and classify food and non-food ad videos automatically.

**Design:** Methodological study.

**Setting:** The collection of television (TV) ads data that followed the protocol developed by the INFORMAS network for monitoring food marketing on TV. From this data, we created a database and split it into three sub-databases (i.e., training, validation, and test) by extracting frames from ads. Subsequently, the training database was classified using the EfficientNet neural network. The best models and data-balancing strategies were investigated using the validation database. Finally, the test database was used to apply the best model and strategy, and results were verified with field experts.

**Participants:** The study used 2,124 hours of recorded Brazilian TV programming from 2018-2020, with 703 food ads and over 20,000 non-food ads.

**Results:** The results showed that the EfficientNet neural network associated with the balanced batches strategy achieved an overall accuracy of 90.5% on the test database, which represents a reduction of 99.9% of the time spent on identifying and classifying ads.

**Conclusions:** The method studied represents a promising approach for differentiating food and non-food related ads within monitoring food marketing, which has significant practical implications for researchers, public health policymakers, and regulatory bodies.

**Keywords:** Food advertising; Monitoring; Ultra-processed foods; Artificial intelligence; Machine learning.

## Introduction

Estimates from the World Health Organization (WHO) show that, in 2016, more than 1.9 billion adults were overweight, with more than 650 million obese <sup>(1)</sup>. Obesity is a chronic disease, in addition to being one of the main risk factors for several other non-communicable diseases (NCDs) - such as cardiovascular diseases (CVD), hypertension, stroke, certain types of cancer, and diabetes <sup>(2,3)</sup>, the leading cause of death worldwide <sup>(4)</sup>. Unhealthy diets are a major contributor to the epidemic of overweight and obesity <sup>(5)</sup> and thus have a central role in this scenario.

Unhealthy diets are promoted through food advertisements (ads) <sup>(2)</sup>, centered on products high in saturated fats, sodium, added sugars, and low in protective nutrients, such as fibers, vitamins, and minerals <sup>(2,6,7)</sup>. The advertising message has a high convincing power through persuasive marketing strategies such as ad repetition, product demonstration, peer popularity appeal, celebrity endorsement, and awards <sup>(8,9)</sup>. Consequently, exposure to food advertising can impact consumer behavior, stimulate the desire for the product and retain consumer loyalty <sup>(10-13)</sup>. These effects can be noted in different groups of individuals, although more emphasis has been put on children, an audience that lacks the cognitive skills to understand the persuasive intent of ads <sup>(12,14,15)</sup>. Therefore, restricting food advertising has been a global priority for health organizations that encourage civil society organizations, academic researchers, and governments to monitor and address the problem <sup>(16-18)</sup>.

Currently, ads are disseminated through various media channels, including television, radios, and the Internet. Effectively monitoring these ads presents several challenges, including the analysis of extensive volumes of media content, resulting in sluggish data processing, high costs for data collection, slow study execution, and the potential for errors arising from manual work.

One of the primary difficulties in manual monitoring is identifying and differentiating food advertising from non-food advertising due to the high volume of information that must be processed manually, which demands a large and well-trained team. Consequently, the quantity and quality of evidence produced may be insufficient, impeding its translation into effective public policies. Experts emphasize the potential benefits of employing artificial intelligence (AI) in evaluating food marketing <sup>(19,20)</sup>. These advantages include scalability, reproducibility, consistency, and the capacity to capture marketing content embedded within audio, text, still images, videos, and even immersive experiences such as virtual reality <sup>(19)</sup>.

Moreover, researchers contend that AI is indispensable for the comprehensive and systematic examination and monitoring of food marketing practices. Consequently, the proposal for automated monitoring holds promises in supporting the implementation of comprehensive policies aimed at reducing children's exposure to unhealthy food marketing.

Researchers in Canada and Australia are developing AI systems to monitor food marketing targeted at children<sup>(21-23)</sup>. The Canadian AI system focuses on monitoring digital platforms<sup>(21,22)</sup>, while the Australian machine learning (ML) algorithms include both digital and non-digital contexts<sup>(23)</sup>. Although these studies are currently in the protocol phase, the outcomes of the AI-based system for automatic monitoring have not yet been published<sup>(21-23)</sup>. Therefore, the primary aim of this study was to develop a machine learning-based method that could automatically identify and classify food and non-food ad videos by investigating deep neural networks.

## **Methods**

### **Design and database**

This is a methodological study that followed the Food Promotion Module: Food Marketing – Television protocol<sup>(24)</sup>, which has been developed by the INFORMAS network (International Food and Obesity/Noncommunicable Diseases Research, Monitoring and Support Network)<sup>(25)</sup> for collecting TV ads. The primary objective of this protocol is to establish a standardized framework for collecting television data and systematic programming to evaluate the influence and prevalence of unhealthy food promotion on TV.

The database consisted of recorded TV broadcasts of three free-to-air channels in April 2018, May 2019, and June 2020 in Brazil. In addition, two pay-for-view channels were monitored in May 2019, September 2019, and June 2020. For each round of data collection, the TV channel programming was recorded in digital format, by a company specializing in clipping service, for eight non-consecutive days, randomly drawn, four of which were weekend days (Saturday or Sunday) and four weekdays (between Monday and Friday). The recording covered the entire programming of the channels from 6 am to 12 am, totaling 18 hours a day for each channel and 2,124 hours in the three years of the study (due to a recording failure, two days (36h) of a pay-for-view channel in June 2020 were lost).



## Data coding

After the recordings were completed, the content was audited in five steps:

(i) audit carried out by the company responsible for clipping service: the company identified the total number of ads and coded the ads for food, beverages, and food retail outlets. Ads related to food and beverages were individually identified.

(ii) audit performed by trained researchers: two trained researchers independently audited the recording. Both researchers did a general check on the number and timing of videos recorded. With this audit, it was possible to identify the absence of some period or even duplication of videos.

(iii) data tabulation: five pairs of ten trained volunteers independently performed the data tabulation. Subsequently, the obtained results underwent a thorough verification process to identify and eliminate any potential divergences. For all ads, the following information was extracted: the channel name; channel type (i.e., free-to-air or pay-for-view); date of recording (classified as a day of the week or weekend); program name; advertising time (start and end); and type of advertising: (a) food-related ads, (b) food or drink company or brand (no retailer) without food or drink product, (c) food or drink retailer (supermarket or convenience store) with/without food or drink product, (d) food or drink retailer (restaurant or takeaway or fast food) with/without food or drink product, and (e) non-food or drink product(s). All ads were tabulated in an electronic questionnaire built in *Epi InfoTM*, version 7.2.2.6.

(iv) final audit: following the data tabulation process, a comprehensive audit was conducted by two independent researchers to identify any divergences among the pairs involved in the tabulation. The inter-coder reliability rate ranged from 90.4% to 96%, indicating a high level of agreement between the researchers. This meticulous examination allowed for the identification of additional food and beverage ads that were not initially detected in the initial audit.

(v) database creation: after conducting the final audit, we created a database that contains information on all ads, including both food and non-food ads. Additionally, we generated a spreadsheet of highly detailed notes of all pertinent data on these ads, which proved indispensable for conducting this study.

## Data preprocessing

With the database created and all the annotations regarding the ads completed and audited, the next step was data preparation and preprocessing. As the non-food ads were

mixed with the programming and separated into several 10-minute videos, it was necessary to automate the process of cutting these videos from the full channel schedule, through the timestamps annotated. For that, a Python code was created using `ffmpeg`<sup>5</sup>, a complete cross-platform solution capable of recording, converting, and clipping stream audio and video.

Once this step was implemented, we observed a significant presence of duplicate non-food ads within the recently extracted videos, accounting for approximately 80% of the collected videos. Consequently, these duplicates were removed from the database.

We emphasize that this is the first database of this type, and we make it publicly available. For this, we will follow the recommendations made in the article *Datasheets for Datasets* <sup>(26)</sup>.

### Data splits

After data preprocessing, we split the database to train the ML model. We manually split the “initial database” into three databases, as shown in Figure 1: Base 1 for algorithm training, Base 2 for result validation, and Base 3 for final model testing. The division criteria were as follows:

(i) for Base 1, we included all videos from 2020 and videos collected in the second half of 2019, of which: 489 food videos and 4281 non-food videos, totaling: 4770 videos.

(ii) for Base 2, we included the videos from the first half of 2019 and part of the videos from 2018, of which: 141 food videos and 1198 non-food videos, totaling: 1339 videos.

(iii) for Base 3, we included only videos from 2018, except for a few cases of children's channels, which were collected from 2019, of which: 73 food videos and 635 non-food videos, totaling: 708 videos.

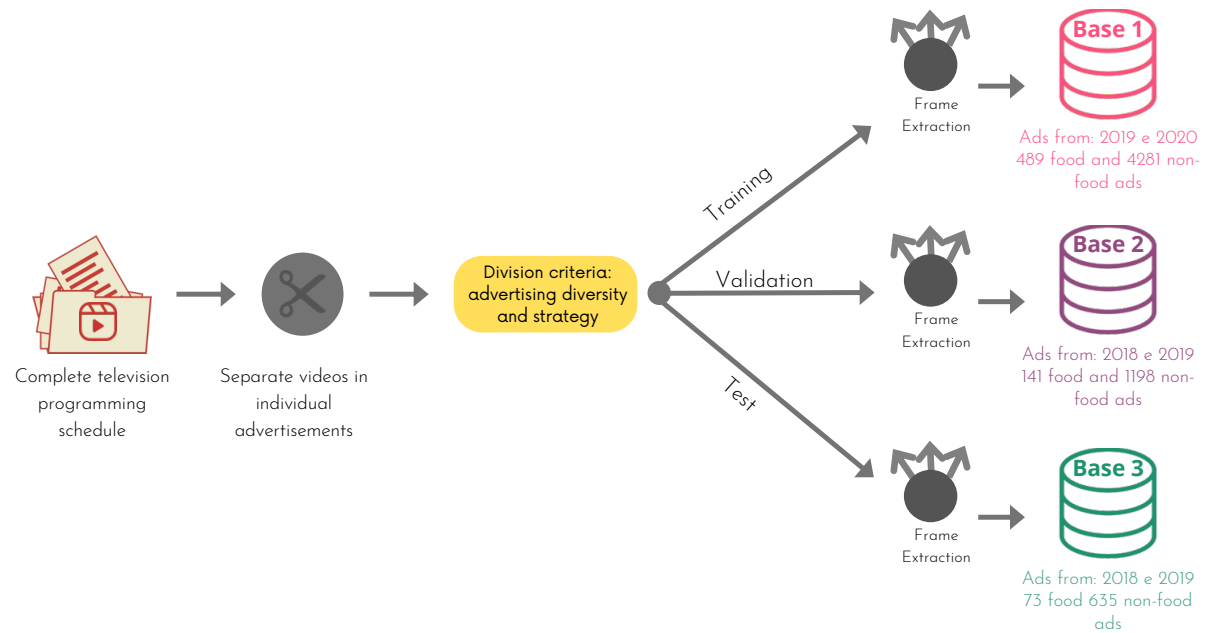
This division was carried out considering the recommended proportion of 75% for training, 15% for validation, and 10% for testing. In ML, data division into subsets is vital to avoid overfitting, a common problem where the model becomes too specialized in the training data, so it loses its ability to generalize to new, unseen data <sup>(27)</sup>.

We divided the data in a way that allocated most of it for training the model while ensuring that both Base 2 and Base 3 still represent the entire initial database. Also, we applied specific strategies during the model training process due to the imbalanced data, where non-food ads were the majority. These strategies will be discussed later.

---

<sup>5</sup> <https://ffmpeg.org/>

**Figure 1:** Synthesis of the methodology that comprises the database preprocessing and split stage.



### Machine learning-based method

First, we use the extracted frames from Base 1 (training data) and apply techniques such as data augmentation, balanced batches, or class weights to mitigate data imbalance. Then, the frames go through the selected deep neural network (the EfficientNet) to generate a classification for each frame. After that, a fusion process through an average pooling method is used to get a single classification for the video by combining the ratings of each frame from the same advertisement. These processes result in a series of different trained networks (models). We determined the best strategies by validating the videos separated in Base 2 (validation data). This step indicates that some adaptations may be necessary during the training stage. Once no further changes are necessary, we select the best model obtained so far to be tested on Base 3 (test data), leading to results that can be verified and analyzed by human experts in the field.

### Deep neural network: EfficientNet

Image recognition is a classic computational classification problem, and convolutional neural networks, specifically EfficientNets<sup>(28)</sup>, are the state of the art for this issue. The model's effectiveness is highly dependent on the base architecture of the network. EfficientNet offers eight versions of this base architecture (EfficientNet-B0 to EfficientNet-B7). For example, EfficientNet-B0 has 5.3 million parameters, while B7 has 66 million. Also, EfficientNet-B0 achieves 77.3% top-1 accuracy on ImageNet, while EfficientNet-B7 reaches

84.3%. We use the best one (EfficientNet-B7, pre-trained on ImageNet dataset), which provides the best possible outcomes for our problem.

### **Approach to classification**

Using Base 1, we propose classifying images and videos of food ads. As input to the neural network, for food ads videos, we used a frame sampling rate of one frame per second (1 fps), while for non-food ads videos, we selected the frame sampling rate as follows, where  $T$  is the duration of the video in seconds:

- 1/2 fps, if  $T < 10$
- 1/4 fps, if  $10 < T \leq 25$
- 1/6 fps, if  $25 < T \leq 35$
- $T/15$  fps, if  $35 < T \leq 60$
- $T/30$  fps if  $60 < T \leq 120$
- $T/45$  fps, if  $T > 120$

We opted for different frame sampling rates to mitigate the observed data imbalance during previous tests. All frames were standardized and centered according to the metric compatible with the input size of the chosen model: for EfficientNet-B7, the resolution varies from  $224 \times 224$  to  $600 \times 600$  pixels.

Each frame extracted from the ads was classified independently. To determine the video's category (food or non-food ads), we employed a decision-making approach. We used simple and weighted average strategies to combine the video frame predictions into a single final prediction per video. However, we realized that using different frame sampling rates was not enough to overcome the data imbalance. To overcome this problem, we applied three strategies – data augmentation, balanced batches, and class weights – to obtain the best result.

### **Data augmentation**

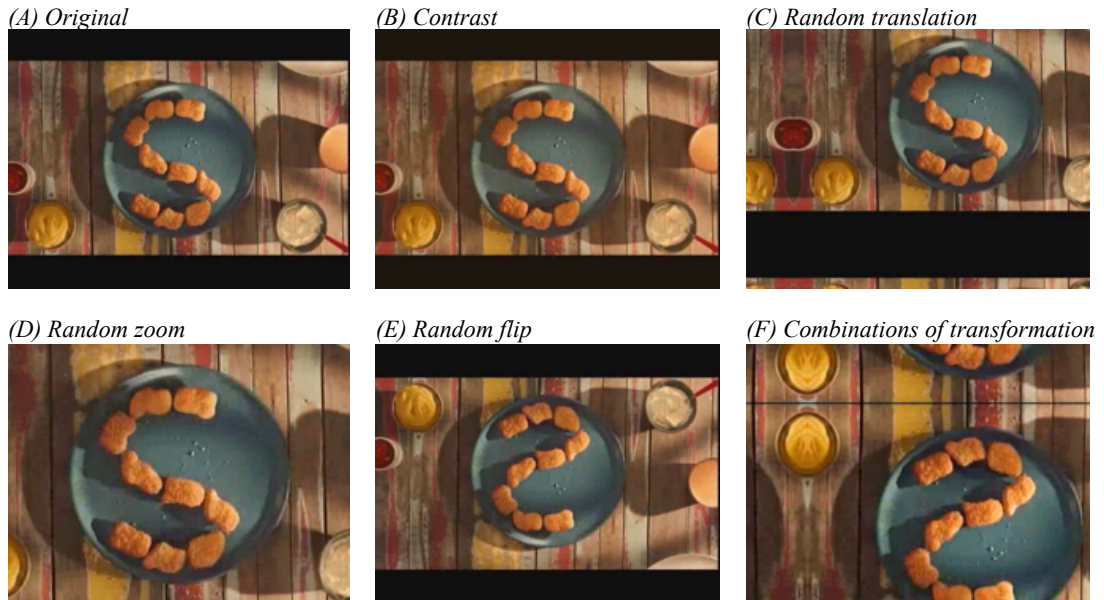
Data augmentation refers to a set of techniques used in ML to artificially increase the size of training data by applying transformations to the original data. We apply the following transformations for the frames extracted from the food advertising videos: rotation, translation, zoom, adding or removing contrast, and rotations in the vertical and/or horizontal axis (Figure 2). For that, we use the keras library <sup>6</sup>, which allows the application of more than

---

<sup>6</sup> <https://keras.io/api/models/sequential>

one transformation per image. At the end of this process, the class imbalance is attenuated by inserting new randomly generated data for the underrepresented class (food ads).

**Figure 2:** Examples of data augmentation transformations performed in the food advertising frame.



### Balanced batches

In ML, a batch is a set of input data processed during training. In balanced batches, the number of samples from each class in the dataset is roughly equal in each batch. Balancing the batches exposes the ML model to diverse examples from all classes in each training iteration, leading to better generalization performance and avoiding overfitting to any specific class.

We use the `imbalanced-learn`<sup>7</sup>, Python library, which creates a balanced data generator, repeating random samples from the database if there are not enough images to balance the classes within the batch in question.

### Class weights

Class weights are used to assign different weights to different classes during model training. The idea is to assign higher weights to the minority class (food ads) and lower weights to the majority class (non-food ads); thus, the model pays more attention to the

<sup>7</sup> <https://imbalanced-learn.org/stable/references/generated/imblearn.keras.BalancedBatchGenerator.html>

minority class and learns to predict it more accurately. The class weights are typically calculated as the inverse of the class frequency.

We use the Scikit-learn <sup>8</sup> Python library, which contains a function that estimates class weights for imbalanced databases.

We highlight the potential of utilizing all three techniques in conjunction.

### **Model training**

We train all the models in Base 1 to determine which technique or combination of techniques provides the best results. In total, we performed eight experiments, seven including all possible combinations of the previously discussed techniques and one without applying any. We replicated each experiment five times to evaluate the variability, totaling 40 trained models.

### **Model validation**

We validate all the models in Base 2 to certify their predictions. For each of the 40 models, we explored four methods to merge the frame rating into a video rating. This involved varying the weight assigned to the frames classified as part of our interest class (food ads) in the following weight values: 1, 2, 3, and 4, resulting in 160 different approaches. Also, we seek to find sources of predictive errors in the models, which will be discussed later. The metrics used to evaluate the models are balanced accuracy and confusion matrix.

### **Model testing**

Finally, we tested in Base 3 only the best-performing model with the best merging approach between the 160 possibilities. This step aims to evaluate its performance on data that the model has not yet had contact with, to get a more realistic idea of how this model would behave outside a controlled environment, classifying new ads. We also seek to find the sources of predictive errors in the model. The metrics used to evaluate the models are balanced accuracy and confusion matrix.

---

<sup>8</sup> [https://scikit-learn.org/stable/modules/generated/sklearn.utils.class\\_weight.compute\\_class\\_weight.html](https://scikit-learn.org/stable/modules/generated/sklearn.utils.class_weight.compute_class_weight.html)

### **Statistical analysis and analysis of algorithmic results**

The main results of the trained models were portrayed by the video confusion matrices of the following sets. A confusion matrix is a table used to evaluate the performance of a classification model. Typically, it is used in ML and statistics to measure the overall accuracy of a model's predictions. The matrix compares the predicted output of a model to the actual output and categorizes the results into four groups: true positive (TP), true negative (TN), false positive (FP), and false negative (FN).

The TP prediction represents when the model correctly predicted the positive class (i.e., food ads), and the number of TN predictions represents when the model correctly predicted the negative class (i.e., non-food ads). Also, the FP prediction represents when the model predicted a positive class, but it was negative, and the FN prediction represents when the model predicted a negative class, but it was positive. Thus, the percentage of the number of FP, FN, TP, and TN were portrayed in matrices.

To assess the model's accuracy in predicting each video, we utilized the confidence level output provided by the algorithm. The confidence level indicates the model's certainty or confidence in its classification decision, reflecting its belief in the accuracy of the prediction. Consequently, when categorizing a video as either food or non-food, the model provided a confidence level alongside the predicted class label. This confidence level was expressed as a percentage, ranging from 0% to 100%.

To establish a criterion for the reliability of the model's predictions, specialists in food advertising monitoring reviewed and analyzed all the ads that were misclassified by the algorithm. We also adopted a threshold (empirically determined) of 65% wherein the expert manually reviewed a video with a confidence lower than this rate (from 50% to 65%). By incorporating the review of videos correctly classified, but with a lower confidence level, we aimed to enhance the interpretability and reliability of the model's predictions, enabling a more nuanced assessment of its performance to ensure the quality of the classification, specifically for food ads.

Both steps were done to identify the reasons that may have contributed to the incorrect classification.

## Results

We report the result of the best model combined with the best classification merging approach. Each table represents the execution of this specific experiment on different bases. Tables 1, 2, and 3 show the confusion matrix of food/non-food classification using EfficientNet-B7 associated with the technique of Balanced Batches with merging weight 2 for the classification of more than one frame per video for Base 1, 2, and 3, respectively.

**Table 1:** Classification confusion matrix for each class in the training database using EfficientNet-B7 for classification of more than one frame per video associated with the Balanced Batches technique with merging weight 2.

Training at Base 1	Food	Non-food
<b>Food</b>	100% (498/498)	0% (0/498)
<b>Non-food</b>	0.4% (15/4281)	99.6% (4266/4281)

**Table 2:** Classification confusion matrix for each class in the validating database using EfficientNet-B7 for classification of more than one frame per video associated with the Balanced Batches technique with merging weight 2.

Validating at Base 2	Food	Non-food
<b>Food</b>	90.1% (127/141)	9.9% (14/141)
<b>Non-food</b>	9.6% (115/1198)	90.4% (1083/1198)

**Table 3:** Classification confusion matrix for each class in the testing database using EfficientNet-B7 for classification of more than one frame per video associated with the Balanced Batches technique with merging weight 2.

Testing at Base 3	Food	Non-food
<b>Food</b>	90.4% (66/73)	9.6% (7/73)
<b>Non-food</b>	9.3% (59/635)	90.7% (576/635)



When evaluating the algorithm's performance, we compared the overall accuracy of validating at Base 2 and testing at Base 3, which were 90.2% and 90.5%, respectively. The similarity between these results suggests that the algorithm performs consistently and effectively. Most promising, the slight differences observed between the results obtained from Base 2 and Base 3 highlight the importance of our careful data division approach. This approach ensured that the videos from the same round of data collection were not grouped in the same database, thus avoiding a negative impact on the model's performance when tested on new data. Additionally, to optimize the model's hyperparameters, the algorithm was validated multiple times on Base 2, which may lead to over-optimistic results. Nevertheless, the algorithm's effectiveness was demonstrated by its single execution in Base 3, indicating its accuracy, robustness, and reliability, thus enhancing its effectiveness in new data. To carry out the training, validation, and testing step, we utilized two distinct machine configurations: (i) a GPU RTX 2080 with 11 GB of memory and (ii) a Titan Xp with 12 GB of memory. Notably, during the testing step, the algorithm consistently delivered results within a 20-minute timeframe, regardless of the machine's specifications.

Upon analysis, specific patterns have been identified that contribute to the misclassification of ads by our algorithm across all three databases. Regarding non-food ads classified as food ads, we identified two main reasons for this misclassification. Firstly, some non-food companies featured food or scenes of people eating or drinking in their ads. Secondly, some non-food ads shared similar characteristics with food ads, such as the use of colors (e.g., red, and yellow) and the prices of products being advertised, like those featured in supermarket ads for food.

On the other hand, we also analyzed food ads that were classified as non-food ads and found several reasons behind this misclassification. Firstly, shorter ads lasting a maximum of 5 seconds, featured fewer frames of food, making it difficult for the algorithm to classify them. Secondly, some food company ads did not feature any food or scenes of people eating or drinking, like McDonald's ad for a contest for children to enter the field during the 2018 World Cup with the soccer player Neymar in a match for the Brazilian team. Thirdly, some beverage ads only showed the liquid being poured into a glass, without focusing on the packaging of the product. Lastly, ads for food supplements only showed a person ingesting a capsule at a particular time, which was insufficient for the algorithm to classify them as food ads.

## Discussion

From the analysis of 2,124 hours of recording of Brazilian TV programming, using the Food Promotion Module: Food Marketing – Television protocol <sup>(24)</sup>, we created an initial database containing 703 different food advertising videos and more than 20,000 non-food advertising videos. Using this initial database, the study assessed the effectiveness of an ML model based on EfficientNet combined with strategies to alleviate the data imbalance in identifying and ranking food/non-food video ads. This identification and classification represent a major step in systematically monitoring this type of ad. Our results showed that the algorithm achieved an overall accuracy of 90.5% in the test database, representing a great advance toward adopting an automatic monitoring approach.

The relevance of our study's approach to automating the monitoring process of food marketing can address the challenges posed by collecting and analyzing large volumes of data. Traditionally, studies have been limited to small samples due to the resource-intensive nature of the data collection and analysis process <sup>(20)</sup>. This limitation makes it difficult to monitor ads systematically across different media, time periods, and population groups, hindering the ability to compare findings across countries. An automated approach could simplify the process, reduce the time and resources required for monitoring, and facilitate comprehensive monitoring of food marketing.

For example, if a research team chooses to record 18 hours of TV programming during eight days of three free-to-air and two pay-for-view channels, as recommended in the Food Promotion Module: Food Marketing – Television protocol <sup>(24)</sup>, a total of 720 hours of programming must be recorded. The first task of this team is to be trained to identify and classify all instances of food and non-food ads and to watch the whole recorded content to separate these types of ads. Based on our experience, at least 10 researchers are necessary to carry out this step within two weeks. Assuming that one day of programming requires approximately 10 hours of work, the researchers would spend approximately 800 hours only on the first stage of monitoring to identify a mean of 1,460 unique ads. Using our test database, which contained 708 unique ads, we classified food and non-food ads in less than 20 minutes. Given this result, it would require approximately 42 minutes to analyze the sample of 1,460 unique ads. Therefore, using the algorithm reduces 99.9% of the time spent on the task, representing a significant financial resources savings achievement.

However, the method did not work with the same accuracy for all ads. Analysis of our test results revealed that the main classification error occurred in short ads of a maximum of five seconds and those with less prominent food and/or beverage features. Interestingly, these errors were also common in the manual collection, where researchers occasionally overlooked these brief ads with minimal food scenes, leading to the omission of notes. However, in the manual collection, with the data double-entered, these errors were captured during the audit. By adopting automatic monitoring, we could verify and address these issues through an analysis of the confidence levels provided by the algorithm for each video classification. In addition, these errors primarily occur in ads with lower persuasive impact, and such errors are to be expected. Advertisements with lower persuasive impact refer to promotional materials or campaigns that have a reduced ability to influence or persuade their target audience. These advertisements may fail to effectively communicate the intended message, generate desired emotional responses, or motivate viewers to take the desired action, such as making a purchase or changing their behavior. For example, in our study, these are short ads that do not exploit emotional appeals (e.g., ads that aim to tap into the viewers' emotions, evoking feelings such as joy, excitement, or empathy) or visual effects (e.g., presence of food, cartoon or company-owned characters, celebrities, aesthetically pleasing designs, the strategic use of color, among others). However, since our database is still relatively small, we can assume that in the future, the algorithm will probably be able to improve its performance through the capacity of a larger volume of information.

To the best of our knowledge, this is the first study to present results from automatic monitoring of food videos, highlighting the novelty of our study. In Canada, experiences documented in the literature show that studies focus on automatic monitoring advertising on digital media<sup>(21,22)</sup>. In these studies, the authors propose various steps for this approach, such as data collection, information extraction, marketing characteristics identification, and nutritional information extraction<sup>(21,22)</sup>. The aim is to develop an AI-based system to monitor the marketing of unhealthy foods/brands to children on websites, social media, and mobile gaming apps<sup>(21,22)</sup>, based on the CLICK monitoring structure proposed by WHO European Office for the Prevention and Control of Noncommunicable Diseases<sup>(18)</sup>. In Australia, researchers are also developing ML algorithms integrated into an image recognition system. This system autonomously detects and categorizes detrimental food, alcohol, and tobacco advertising, aiming to monitor children's exposure and engagement with such advertisements in both digital and non-digital contexts<sup>(23)</sup>. Despite the promising nature of these

interdisciplinary studies, they are currently in the protocol phase, and the results of the AI-based monitoring system have not been published yet <sup>(21–23)</sup>.

Additionally, Palmer et al. developed a deep learning workflow to automatically extract and classify outdoor advertising promoting unhealthy products <sup>(29)</sup>. Through a comprehensive dataset comprising 25,349 georeferenced images collected through cycling expeditions equipped with GoPro cameras, the researchers successfully applied automated techniques to identify and classify a total of 10,106 ads. Among these, 1,335 pertained to food, and 217 to alcohol, while the remaining 8,554 encompassed various other products. This study provides a compelling demonstration of the efficacy of an automated approach in accurately classifying street view images to discern and categorize unhealthy ads. Consequently, this technique offers a valuable means to identify geographic regions that would greatly benefit from more stringent advertising restriction policies to combat social inequalities. <sup>(29)</sup>.

When we broadened our search to the field of nutrition, we identified some initial studies that also used AI-based algorithms for food and non-food image classification through photos taken by the individuals themselves to facilitate the identification of food intake and use this information in dietary analysis. The results of these researches using AI-based techniques also proved to be promising <sup>(30,31)</sup> and illustrate the importance of incorporating new technologies to solve complex public health problems in an autonomous or semi-autonomous way.

Regarding our study's practical implications, they can be pointed out to researchers, public health policymakers, and regulatory bodies in Brazil and other countries. Although our methodology and results do not yet allow an assessment of the adequacy of advertising in Brazil, they can already help filter food advertising by reducing the number of ads that need to be analyzed individually. In future studies, researchers can move forward with identifying non-compliance with advertising regulations. Policymakers of other countries can also use this methodology as inspiration to propose a specific test for the reality of each country and help them in the proposal and approval of more specific policies to promote a healthy food environment.

Researchers can also be inspired by our experience to classify ads by food type and advance in recognizing the main patterns of persuasive strategies used in advertising through more effective and efficient models to address these issues. Based on our preliminary observations of the algorithm and data imbalance strategies employed, we believe that certain

marketing strategies can be easily identified through automated monitoring. For instance, adhering to the INFORMAS protocol, objective strategies such as the presence of cartoons or company-owned characters, licensed characters, celebrities, renowned sportspersons, and sports events can be efficiently detected utilizing a robust training database. From our current understanding, it is evident that these specific marketing techniques exhibit distinct features that lend themselves to automated identification. By leveraging a comprehensive and well-curated database, the training process can be optimized to recognize and classify such strategies accurately. These new models should be implemented and tested similarly to this study, using a training dataset (Base 1), a validation dataset (Base 2), and a testing dataset (Base 3). To improve the accuracy and robustness of the models, researchers could consider incorporating additional features such as nutritional content, product placement, and endorsement by celebrities or influencers. Moreover, future studies could: *(i)* explore the feasibility of automatic monitoring of food advertising on online platforms such as social media, YouTube, and streaming services; and *(ii)* incorporate advanced techniques such as natural language processing and sentiment analysis to broaden knowledge of the impact of food marketing.

By combining our current findings with future research, the application of ML techniques for automatically monitoring food ads can support researchers in extending systematic monitoring and facilitating comparability across studies. A database with different types of food ads shown on TV can be used in comparative studies between countries to identify common marketing patterns used by food companies in different cultural and regulatory contexts. In the medium and long term, the practical implications of advertising monitoring studies, especially those with a large volume of data, could contribute to a healthier food environment and result in lower rates of obesity by minimizing individual exposure to food advertising.

Despite the promising results of our study on food advertising monitoring, there are still areas where further progress is needed. Consequently, our future endeavors will focus on the following steps: *(i)* implement the tested algorithm in a new round of data collection to propose an enhanced monitoring approach; *(ii)* expand our existing database, particularly in terms of food ads, thereby enabling greater automation of the monitoring process; *(iii)* apply the algorithm to video datasets from other countries with similar food marketing contexts to evaluate its effectiveness, identify potential necessary adaptations, and facilitate cross-country comparisons and method harmonization for automated advertising monitoring in diverse

settings; and *(iv)* develop user-friendly software interface for the algorithm, streamlining its usability and ensuring efficient operation across a range of machine configurations adaptable to researchers' requirements.

Collaboration with researchers from various countries is instrumental in expanding the database and developing technologies that can accelerate the automatic tracking of ads across different media platforms and geographical locations. By combining efforts, we can advance the field and contribute to developing effective tools for comprehensive and efficient food advertising monitoring.

**Acknowledgments:** We wish to thank the team of research assistants at the Department of Nutrition at the Federal University of Minas Gerais for their time and valuable contribution in data collection.

**Funding:** This study received financial support from the Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) under process number 442789/2019-0 and the International Development Research Centre (projectID-108166). Authors were also supported by: *(i)* Rodrigues MB funded by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes) [financial code 001]; *(ii)* Ferreira VP funded by Becas Santander/Unicamp – HUB 2022; and *(iii)* Avila S. is partially funded by CNPq under process number 315231/2020-3, Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) under process numbers 2013/08293-7, 2020/09838-0, and Google Awards for Inclusion Research 2022.

**Conflict of interest:** None.

**Authorship:** Rodrigues MB: Conceptualization, Data curation, Formal analysis, Methodology, Writing – original draft; Ferreira VP: Conceptualization, Data curation, Formal analysis, Methodology, Writing – original draft; Claro RM: Data curation, Writing – review & editing; Martins APB: Data curation, Writing – review & editing; Avila S: Conceptualization, Formal analysis, Methodology, Project administration, Writing – review & editing; and Horta PM: Conceptualization, Data curation, Project administration, Writing – review & editing. All authors gave final approval of the version to be published.

**Ethical standard disclosure:** This study does not involve human participants.

## References

1. WHO - World Health Organization (2021) Obesity and overweight. <https://www.who.int/news-room/fact-sheets/detail/obesity-and-overweight> (accessed January 2023).
2. Jenkin G, Madhvani N, Signal L, et al. (2014) A systematic review of persuasive marketing techniques to promote food to children on television. *Obes. Rev.* **15**, 281–293. <https://doi.org/10.1111/obr.12141>
3. WHO - World Health Organization (2014) *Global status report on noncommunicable diseases 2014*. World Heal. Organ. Geneva, Switzerland. <https://apps.who.int/iris/handle/10665/148114> (accessed January 2023).
4. WHO - World Health Organization (2018) *Noncommunicable diseases country profiles 2018*. <https://apps.who.int/iris/handle/10665/274512> (accessed June 2023).
5. WHO - World Health Organization (2003) *Diet nutrition and the prevention of chronic diseases*. Geneva, Switzerland. <https://www.who.int/publications/i/item/924120916X> (accessed June 2023).
6. Leite FHM, Mais LA, Ricardo CZ, et al. (2020) Nutritional quality of foods and non-alcoholic beverages advertised on Brazilian free-to-air television: A cross-sectional study. *BMC Public Health* **20**, 385. <https://doi.org/10.1186/s12889-020-08527-6>
7. WHO - World Health Organization (2022) *Food marketing exposure and power and their associations with food-related attitudes, beliefs and behaviours: a narrative review*. <https://www.who.int/publications/i/item/9789240041783> (accessed June 2023).
8. Rozendaal E, Buijzen M & Valkenburg P (2011) Children's understanding of advertisers' persuasive tactics. *Int. J. Advert.* **30**, 329–350. <https://doi.org/10.2501/IJA-30-2-329-350>
9. Silva JM da, Rodrigues MB, Matos J de P, et al. (2021) Use of persuasive strategies in food advertising on television and on social media in Brazil. *Prev. Med. Reports* **24**, 101520. <https://doi.org/10.1016/j.pmedr.2021.101520>
10. Boyland EJ, Nolan S, Kelly B, et al. (2016) Advertising as a cue to consume: A systematic review and meta-analysis of the effects of acute exposure to unhealthy food and nonalcoholic beverage advertising on intake in children and adults. *Am. J. Clin. Nutr.* **103**, 519–533. <https://doi.org/10.3945/ajcn.115.120022>
11. Mills SDH, Tanner LM & Adams J (2013) Systematic literature review of the effects of food and drink advertising on food and drink-related behaviour, attitudes and beliefs in adult populations. *Obes. Rev.* **14**, 303–314. <https://doi.org/10.1111/obr.12012>
12. Prowse R (2017) Food marketing to children in Canada: A settings-based scoping review on exposure, power and impact. *Heal. Promot. Chronic Dis. Prev. Canada* **37**, 274–292. Public Health Agency of Canada. <https://doi.org/10.24095/hpcdp.37.9.03>
13. Russell SJ, Croker H & Viner RM (2019) The effect of screen advertising on children's dietary intake: A systematic review and meta-analysis. *Obes. Rev.* **20**, 554–568. <https://doi.org/10.1111/obr.12812>
14. Calvert SL (2008) Children as consumers: Advertising and marketing. *Futur. Child.* **18**, 205–234. <http://www.jstor.org/stable/20053125>
15. Cairns G, Angus K, Hastings G, et al. (2013) Systematic reviews of the evidence on the nature, extent and effects of food marketing to children. A retrospective summary. *Appetite* **62**, 209–215. <https://doi.org/10.1016/j.appet.2012.04.017>
16. WCRFI - World Cancer Research Fund International (2020) *Building momentum: lessons on implementing robust restrictions of food and non-alcoholic beverage marketing to children*. <https://www.wcrf.org/wp-content/uploads/2021/01/PPA->

- [Building-Momentum-3-WEB-3.pdf](#) (accessed June 2023).
17. WHO - World Health Organization (2010) *Set of Recommendations on the Marketing of Foods and Non-Alcoholic Beverages to Children*. Switzerland. <https://apps.who.int/iris/handle/10665/44416> (accessed June 2023).
  18. WHO - World Health Organization: Regional Office for Europe (2018) *Evaluating implementation of the WHO set of recommendations on the marketing of foods and non-alcoholic beverages to children: Progress, challenges and guidance for next steps in the WHO European Region*. Copenhagen, Denmark. <https://apps.who.int/iris/handle/10665/345153> (accessed June 2023).
  19. Olstad DL & Boyland E (2023) Towards effective restriction of unhealthy food marketing to children: unlocking the potential of artificial intelligence. *Int. J. Behav. Nutr. Phys. Act.* **20**, 1–4. <https://doi.org/10.1186/s12966-023-01458-6>
  20. Kelly B, Backholer K, Boyland E, et al. (2023) Contemporary Approaches for Monitoring Food Marketing to Children to Progress Policy Actions. *Curr. Nutr. Rep.* **12**, 14–25. <https://doi.org/10.1007/s13668-023-00450-7>
  21. Olstad DL, Raman M, Valderrama C, et al. (2022) Development of an Artificial Intelligence System to Monitor Digital Marketing of Unhealthy Food to Children: Research Protocol. *Curr. Dev. Nutr.* **6**, 1151. <https://doi.org/10.1093/cdn/nzac072.023>
  22. Olstad DL & Lee J (2020) Leveraging artificial intelligence to monitor unhealthy food and brand marketing to children on digital media. *Lancet Child Adolesc. Heal.*, 418–420. [https://doi.org/10.1016/S2352-4642\(20\)30101-2](https://doi.org/10.1016/S2352-4642(20)30101-2)
  23. Monitoring advertising to improve children’s health | Deakin. *Deakin Univ.* . <https://www.deakin.edu.au/research/impact-stories/monitoring-advertising-to-improve-childrens-health> (accessed June 2023).
  24. Kelly B (2017) *INFORMAS Protocol: Food Promotion Module: Food Marketing - Television Protocol*. The University of Auckland. <https://doi.org/10.17608/k6.auckland.5664706.v1>
  25. Swinburn B, Sacks G, Vandevijvere S, et al. (2013) INFORMAS (International Network for Food and Obesity/non-communicable diseases Research, Monitoring and Action Support): Overview and key principles. *Obes. Rev.* **14**, 1–12. <https://doi.org/10.1111/obr.12087>
  26. Gebru T, Morgenstern J, Vecchione B, et al. (2021) Datasheets for datasets. *Commun. ACM* **64** (12), 86–92. Association for Computing Machinery. <https://doi.org/10.1145/3458723>
  27. Géron A (2019) *Hands-On Machine Learning with Scikit-Learn, Keras & Tensor Flow*. Second, p. 510. United States of American: Jupyter.
  28. Tan M & Le Q V. (2019) EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. In *Int. Conf. Mach. Learn. ICML 2019*, vol. 97, pp. 6105–6114. Proceedings of Machine Learning Research, PMLR. <https://doi.org/10.48550/arXiv.1905.11946>
  29. Palmer G, Green M, Boyland E, et al. (2021) A deep learning approach to identify unhealthy advertisements in street view images. *Sci. Rep.* **11**, 4884. Nature Research.
  30. Jia W, Li Y, Qu R, et al. (2019) Automatic food detection in egocentric images using artificial intelligence technology. *Public Health Nutr.* **22**, 1168–1179. <https://doi.org/10.1038/s41598-021-84572-4>
  31. Singla A, Yuan L & Ebrahimi T (2016) Food/non-food image classification and food categorization using pre-trained GoogLeNet model. In *MADiMa 2016 - Proc. 2nd Int. Work. Multimed. Assist. Diet. Manag. co-located with ACM Multimed. 2016*, pp. 3–11. Association for Computing Machinery. <https://doi.org/10.1145/2986035.2986039>



## 5. CONSIDERAÇÕES FINAIS

O presente estudo, de forma original e inovadora, aplicou técnicas de IA e aprendizado de máquina para automatizar a primeira etapa prevista no protocolo de monitoramento do marketing televisivo de alimentos <sup>(40)</sup>, desenvolvido pela Rede INFORMAS <sup>(88)</sup>, que consiste na identificação e classificação das publicidades e que também pode ser a primeira etapa de qualquer monitoramento de marketing de alimentos por vídeo.

Diante disso, o estudo permitiu a criação da primeira base de dados brasileira com diferentes tipos de publicidades veiculadas na TV. Com a utilização da *EfficientNet* <sup>(117)</sup> combinada com estratégias para amenizar o desbalanceamento de dados, foi possível analisar um grande número de publicidades em um curto período de tempo e identificar se as publicidades eram alimentícias ou não. Isso representou uma redução de 99,6% do tempo gasto nessa etapa inicial, o que também representa uma conquista significativa em termos de economia de recursos financeiros.

Atualmente, apesar do baixo volume de evidências <sup>(95)</sup> sobre o monitoramento da publicidade televisiva de alimentos no Brasil <sup>(90,93,94)</sup>, os resultados mostram a baixa efetividade da regulação do Estado brasileiro no tema <sup>(93,94)</sup> e uma ineficiência da autorregulação <sup>(94,119)</sup>, destacando a necessidade de se avançar na agenda do cumprimento da restrição da publicidade, especialmente daquela direcionada às crianças, adolescentes e que promove alimentos não saudáveis. Nesse sentido, os resultados obtidos neste estudo possuem um grande potencial e se alinham com os interesses de organizações da sociedade civil, pesquisadores e governo, uma vez que classificar a publicidade de alimentos de forma precisa é fundamental para agilizar a segunda etapa do monitoramento de publicidades de alimentos, que identifica as estratégias persuasivas de marketing empregadas e a inadequação às normas regulatórias vigentes.

As implicações para o campo de pesquisa vão além do Brasil, pois a automação do monitoramento de publicidades alimentícias televisivas utilizando técnicas de IA e aprendizado de máquina pode ser aplicada em outros países que enfrentam desafios semelhantes em relação à classificação da publicidade de alimentos para a primeira etapa de monitoramento. Nossos achados, também podem auxiliar e inspirar pesquisadores a avançar em pesquisas de automação do reconhecimento dos principais padrões de estratégias persuasivas utilizadas na publicidade por meio de modelos mais eficazes e eficientes para abordar essas questões. Além disso, a criação de uma base de dados com diferentes tipos de

publicidades alimentícias veiculadas na TV pode ser utilizada em estudos comparativos entre diferentes países, permitindo a identificação de padrões comuns de estratégias persuasivas de marketing empregadas pelas empresas de alimentos em diferentes contextos culturais e regulatórios.

Em resumo, o presente estudo apresenta uma grande contribuição para o campo de estudo da saúde coletiva pelos seguintes pontos: *(i)* o estudo aplica de forma inédita a IA e o aprendizado de máquina no contexto do monitoramento da publicidade de alimentos no campo de conhecimento da saúde pública; *(ii)* utiliza tais técnicas como ferramenta para reduzir consideravelmente o esforço atualmente necessário para realizar a primeira etapa do monitoramento de publicidade de alimentos, permitindo maior efetividade, qualidade, padronização, agilidade e comparabilidade dos resultados encontrados; *(iii)* com a primeira etapa do monitoramento se tornando automática, será possível realizar monitoramentos periódicos e produzir evidências científicas mais robustas e em quantidade suficiente, para apoiar na formulação de políticas públicas específicas de restrição à publicidade de alimentos considerados nocivos à saúde no Brasil e também a nível global e *(iv)* além disso, o monitoramento automático poderá facilitar o processo de fiscalização. Ao combinar nossas descobertas atuais com pesquisas futuras, a aplicação da IA e de técnicas de aprendizado de máquina para monitorar automaticamente as publicidades de alimentos podem minimizar a exposição individual à publicidade de alimentos, especialmente as de alimentos não saudáveis.

## 6. REFERÊNCIAS

1. Brasil. Promoção da Saúde e da Alimentação Adequada e Saudável: Excesso de peso e obesidade [Internet]. Portal da Secretaria de Atenção Primária a Saúde. 2022 [cited 2023 Jan 28]. Available from: [https://aps.saude.gov.br/ape/promocao\\_saude/excesso](https://aps.saude.gov.br/ape/promocao_saude/excesso)
2. Ng M, Fleming T, Robinson M, Thomson B, Graetz N, Margono C, et al. Global, regional, and national prevalence of overweight and obesity in children and adults during 1980-2013: A systematic analysis for the Global Burden of Disease Study 2013. *Lancet* [Internet]. 2014 Aug 30 [cited 2023 Jan 28];384(9945):766–81. Available from: [https://doi.org/10.1016/S0140-6736\(14\)60460-8](https://doi.org/10.1016/S0140-6736(14)60460-8)
3. Noubiap JJ, Nansseu JR, Lontchi-Yimagou E, Nkeck JR, Nyaga UF, Ngouo AT, et al. Global, regional, and country estimates of metabolic syndrome burden in children and adolescents in 2020: a systematic review and modelling analysis. *Lancet Child Adolesc Heal* [Internet]. 2022 Mar 1 [cited 2023 Jan 28];6(3):158–70. Available from: [https://doi.org/10.1016/S2352-4642\(21\)00374-6](https://doi.org/10.1016/S2352-4642(21)00374-6)
4. Safiri S, Karamzad N, Kaufman JS, Nejadghaderi SA, Bragazzi NL, Sullman MJM, et al. Global, regional, and national burden of cancers attributable to excess body weight in 204 countries and territories, 1990 to 2019. *Obesity* [Internet]. 2022 Feb 1 [cited 2023 Jan 28];30(2):535–45. Available from: <https://doi.org/10.1002/oby.23355>
5. WHO - World Health Organization. Noncommunicable diseases country profiles 2018 [Internet]. 2018 [cited 2023 Jan 28]. Available from: <https://apps.who.int/iris/handle/10665/274512>
6. WHO - World Health Organization. Obesity and overweight [Internet]. 2021 [cited 2023 Jan 20]. Available from: <https://www.who.int/news-room/fact-sheets/detail/obesity-and-overweight>
7. WHO WHO. World health statistics 2022: monitoring health for the SDGs, sustainable development goals [Internet]. Geneva, Switzerland; 2022. Available from: <https://www.who.int/publications/i/item/9789240051157>
8. WHO WHO. Noncommunicable diseases [Internet]. 2022 [cited 2023 Jan 28]. Available from: <https://www.who.int/news-room/fact-sheets/detail/noncommunicable-diseases>
9. IBGE - Instituto Brasileiro de Geografia e Estatística. Pesquisa Nacional de saúde - 2019: atenção primária à saúde e informações antropométricas - Brasil [Internet]. Rio de Janeiro; 2020 [cited 2023 Jan 28]. Available from: <https://abeso.org.br/wp-content/uploads/2021/07/Pesquisa-Nacional-de-Saude-2019.pdf>
10. Bielemann RM, Santos Motta J V., Minten GC, Horta BL, Gigante DP. Consumption of ultra-processed foods and their impact on the diet of young adults. *Rev Saude Publica* [Internet]. 2015 [cited 2023 Mar 16];49:1–10. Available from: <https://doi.org/10.1590/S0034-8910.2015049005572>
11. Levy RB, Claro RM, Monteiro CA. Sugar and overall macronutrient profile in the Brazilian family diet (2002-2003). *Cad Saude Publica* [Internet]. 2010 Mar [cited 2021 Jan 16];26(3):472–80. Available from: <https://doi.org/10.1590/S0102-311X2010000300005>
12. Louzada ML da C, Martins APB, Canella DS, Baraldi LG, Levy RB, Claro RM, et al. Ultra-processed foods and the nutritional dietary profile in Brazil. *Rev Saude Publica* [Internet]. 2015 [cited 2023 Jan 16];49. Available from: <https://doi.org/10.1590/S0034-8910.2015049006132>
13. Monteiro CA, Cannon G, Lawrence M, Costa Louzada ML, Pereira Machado P. Ultra-processed foods, diet quality, and health using the NOVA classification system

- Prepared by [Internet]. FAO, editor. Rome; 2019. Available from: <http://www.fao.org/3/ca5644en/ca5644en.pdf>
14. Monteiro CA, Cannon G, Levy RB, Moubarac J-C, Louzada MLC, Rauber F, et al. Ultra-processed foods: what they are and how to identify them. *Public Health Nutr* [Internet]. 2019 Apr 12 [cited 2022 Dec 15];22(5):936–41. Available from: <https://doi.org/10.1017/S1368980018003762>
  15. Askari M, Heshmati J, Shahinfar H, Tripathi N, Daneshzad E. Ultra-processed food and the risk of overweight and obesity: a systematic review and meta-analysis of observational studies. *Int J Obes* [Internet]. 2020 Aug 14 [cited 2023 Jan 28];44(10):2080–91. Available from: <https://doi.org/10.1038/s41366-020-00650-z>
  16. Pagliai G, Dinu M, Madarena MP, Bonaccio M, Iacoviello L, Sofi F. Consumption of ultra-processed foods and health status: a systematic review and meta-analysis. *Br J Nutr* [Internet]. 2021 Feb 14 [cited 2023 Jan 28];125(3):308–18. Available from: <https://doi.org/10.1017/S0007114520002688>
  17. Lane MM, Davis JA, Beattie S, Gómez-Donoso C, Loughman A, O’Neil A, et al. Ultraprocessed food and chronic noncommunicable diseases: A systematic review and meta-analysis of 43 observational studies. *Obes Rev* [Internet]. 2021 Mar 1 [cited 2023 Jan 28];22(3):e13146. Available from: <https://doi.org/10.1111/obr.13146>
  18. Taneri PE, Wehrli F, Roa-Díaz ZM, Itodo OA, Salvador D, Raeisi-Dehkordi H, et al. Association Between Ultra-Processed Food Intake and All-Cause Mortality: A Systematic Review and Meta-Analysis. *Am J Epidemiol* [Internet]. 2022 Jun 27 [cited 2023 Jan 28];191(7):1323–35. Available from: <https://doi.org/10.1093/aje/kwac039>
  19. Nilson EAF, Ferrari G, Louzada MLC, Levy RB, Monteiro CA, Rezende LFM. Premature Deaths Attributable to the Consumption of Ultraprocessed Foods in Brazil. *Am J Prev Med* [Internet]. 2023 Jan 1 [cited 2023 Jan 28];64(1):129–36. Available from: <https://doi.org/10.1016/j.amepre.2022.08.013>
  20. Monteiro CA, Moubarac J-C, Cannon G, Ng SW, Popkin B. Ultra-processed products are becoming dominant in the global food system. *Obes Rev* [Internet]. 2013 Nov;14(S2):21–8. Available from: <https://doi.org/10.1111/obr.12107>
  21. De Deus Mendonça R, Souza Lopes AC, Pimenta AM, Gea A, Martinez-Gonzalez MA, Bes-Rastrollo M. Ultra-processed food consumption and the incidence of hypertension in a mediterranean cohort: The seguimiento universidad de Navarra project. *Am J Hypertens* [Internet]. 2017 Apr 1 [cited 2023 Feb 17];30(4):358–66. Available from: <https://doi.org/10.1093/ajh/hpw137>
  22. Zinöcker MK, Lindseth IA. The western diet–microbiome–host interaction and its role in metabolic disease. *Nutrients* [Internet]. 2018 Mar 17 [cited 2023 Feb 17];10(3):365. Available from: <https://doi.org/10.3390/nu10030365>
  23. Glanz K, Sallis JF, Saelens BE, Frank LD. Healthy Nutrition Environments: Concepts and Measures. *Am J Heal Promot* [Internet]. 2005 May 25;19(5):330–3. Available from: <https://doi.org/10.4278/0890-1171-19.5.330>
  24. Swinburn BA, Kraak VI, Allender S, Atkins VJ, Baker PI, Bogard JR, et al. The Global Syndemic of Obesity, Undernutrition, and Climate Change: The Lancet Commission report. *Lancet* [Internet]. 2019 Feb 23 [cited 2023 Jan 16];393(10173):791–846. Available from: [https://doi.org/10.1016/S0140-6736\(18\)32822-8](https://doi.org/10.1016/S0140-6736(18)32822-8)
  25. Monteiro CA, Levy RB, Claro RM, De Castro IRR, Cannon G. Increasing consumption of ultra-processed foods and likely impact on human health: Evidence from Brazil. *Public Health Nutr* [Internet]. 2010 Jan [cited 2023 Jan 28];14(1):5–13. Available from: <https://doi.org/10.1017/S1368980010003241>
  26. Story M, Kaphingst KM, Robinson-O’Brien R, Glanz K. Creating Healthy Food and

- Eating Environments: Policy and Environmental Approaches. *Annu Rev Public Health* [Internet]. 2008 Apr 1;29:253–72. Available from: <https://doi.org/10.1146/annurev.publhealth.29.020907.090926>
27. Moubarac JC, Batal M, Martins APB, Claro R, Levy RB, Cannon G, et al. Processed and ultra-processed food products: Consumption trends in Canada from 1938 to 2011. *Can J Diet Pract Res* [Internet]. 2014 [cited 2023 Jan 28];75(1):15–21. Available from: <https://doi.org/10.3148/75.1.2014.15>
  28. Egger G, Swinburn B. An “ecological” approach to the obesity pandemic. *BMJ* [Internet]. 1997 Aug 23;315:477–83. Available from: <https://doi.org/10.1136/bmj.315.7106.477>
  29. Turner C, Aggarwal A, Walls H, Herforth A, Drewnowski A, Coates J, et al. Concepts and critical perspectives for food environment research: A global framework with implications for action in low- and middle-income countries. *Glob Food Sec* [Internet]. 2018 Sep 1;18:93–101. Available from: <https://doi.org/10.1016/j.gfs.2018.08.003>
  30. Gálvez Espinoza P, Egaña D, Masferrer D, Cerda R. Proposal for a conceptual model for the study of food environments in Chile. *Rev Panam Salud Pública* [Internet]. 2017;41:e169. Available from: <https://doi.org/10.26633/RPSP.2017.169>
  31. HLPE HLP of E on FS. Nutrition and food systems: A report by the High Level Panel of Experts on Food Security and Nutrition of the Committee on World Food Security [Internet]. Rome; 2017. Available from: <https://www.fao.org/documents/card/en/c/I7846E>
  32. Downs SM, Ahmed S, Fanzo J, Herforth A. Food Environment Typology: Advancing an Expanded Definition, Framework, and Methodological Approach for Improved Characterization of Wild, Cultivated, and Built Food Environments toward Sustainable Diets. *Foods* [Internet]. 2020 Apr 22 [cited 2023 Mar 24];9(4):532. Available from: <https://doi.org/10.3390/foods9040532>
  33. AMA AM. What is marketing? [Internet]. American Marketing Association. 2017 [cited 2023 Mar 20]. Available from: <https://www.ama.org/the-definition-of-marketing-what-is-marketing/>
  34. Kotler P. *O Marketing sem Segredos*. Bookman; 2005. 160 p.
  35. Hawkes C. Uneven dietary development: Linking the policies and processes of globalization with the nutrition transition, obesity and diet-related chronic diseases. *Global Health* [Internet]. 2006 Mar 28 [cited 2023 Jan 28];2. Available from: <https://doi.org/10.1186/1744-8603-2-4>
  36. WHO - World Health Organization. Food marketing exposure and power and their associations with food-related attitudes, beliefs and behaviours: a narrative review [Internet]. 2022. Available from: <https://www.who.int/publications/i/item/9789240041783>
  37. Muc M, Tatlow-Golden MW. Protocols to monitor marketing of unhealthy foods to children: Comparison and evaluation of existing protocols, with stakeholder consultation Grant Agreement Number 951202 [Internet]. 2023 Sep [cited 2023 Jan 30]. Available from: <http://oro.open.ac.uk/86932/1/WP6.4-Food-Marketing-Monitoring-Global-Protocols-Review-Best-ReMaP.pdf>
  38. M.C. G. *Publicidade e Propaganda* [Internet]. Iesde. Curitiba: IESDE Brasil; 2009 [cited 2023 Jan 28]. 100 p. Available from: [https://books.google.dk/books?hl=pt-BR&lr=&id=mcjMntKor5gC&oi=fnd&pg=PA7&dq=Publicidade+x+propaganda&ots=9ZeoqljMU9&sig=Q0PWa7LzVKQPz5drVmw\\_Z114l1Q&redir\\_esc=y#v=onepage&q=Publicidade+x+propaganda&f=false](https://books.google.dk/books?hl=pt-BR&lr=&id=mcjMntKor5gC&oi=fnd&pg=PA7&dq=Publicidade+x+propaganda&ots=9ZeoqljMU9&sig=Q0PWa7LzVKQPz5drVmw_Z114l1Q&redir_esc=y#v=onepage&q=Publicidade+x+propaganda&f=false)
  39. Hawkes C. *Marketing Food to Children: The Global Regulatory Environment* [Internet]. World Health Organization. Geneva, Switzerland; 2004. Available from:

- <https://apps.who.int/iris/bitstream/handle/10665/42937/9241591579.pdf?sequence=1&isAllowed=y>
40. Kelly B. INFORMAS Protocol: Food Promotion Module: Food Marketing - Television Protocol [Internet]. The University of Auckland; 2017 [cited 2023 Apr 19]. Available from: <https://doi.org/10.17608/k6.auckland.5664706.v1>
  41. Chin JH, Mansori S. Social Marketing in Foods: A Review of Behavioural Change Models of Healthy Eating. *Ref Modul Food Sci* [Internet]. 2019 [cited 2023 Mar 24]; Available from: <https://doi.org/10.1016/B978-0-08-100596-5.22654-1>
  42. Kelly B, Vandevijvere S, Freeman B, Jenkin G. New Media but Same Old Tricks: Food Marketing to Children in the Digital Age. *Curr Obes Rep* [Internet]. 2015 Mar 10;4:37–45. Available from: <https://doi.org/10.1007/s13679-014-0128-5>
  43. Hebden L, King L, Kelly B. Art of persuasion: An analysis of techniques used to market foods to children. *J Paediatr Child Health* [Internet]. 2011 Nov 1 [cited 2023 Apr 15];47(11):776–82. Available from: <https://doi.org/10.1111/j.1440-1754.2011.02025.x>
  44. Kelly B, Hattersley L, King L, Flood V. Persuasive food marketing to children: use of cartoons and competitions in Australian commercial television advertisements. *Health Promot Int* [Internet]. 2008 Dec 1 [cited 2023 Mar 12];23(4):337–44. Available from: <https://doi.org/10.1093/heapro/dan023>
  45. Dainton M, Zelley ED. Explaining Theories of Persuasion. In: *Applying communication theory for professional life: A practical introduction* [Internet]. 3rd ed. Thousand Oaks, United States: SAGE Publications INC.; 2004. p. 103–31. Available from: [https://www.sagepub.com/sites/default/files/upm-binaries/4985\\_Dainton\\_Chapter\\_5.pdf](https://www.sagepub.com/sites/default/files/upm-binaries/4985_Dainton_Chapter_5.pdf)
  46. CIALDINI RB. *As armas da persuasão: Como influenciar e não se deixar influenciar*. 1st ed. Sextante; 2012.
  47. Santos S, Gonçalves HM. The consumer decision journey: A literature review of the foundational models and theories and a future perspective. *Technol Forecast Soc Change* [Internet]. 2021 Dec 1 [cited 2023 Mar 25];173:121117. Available from: <https://doi.org/10.1016/j.techfore.2021.121117>
  48. Kantar. Understand consumer decision-making during COVID-19 and beyond [Internet]. 2020 [cited 2023 Mar 25]. Available from: <https://www.kantar.com/inspiration/coronavirus/understand-consumer-decision-making-during-covid-19-and-beyond>
  49. Sierra JJ, Taute HA, Turri AM. Determinants of Intentions to Purchase Unhealthy Food and Beverage Options: A Dual-Process Theoretical Perspective. <http://dx.doi.org/10.1080/104544462014885862> [Internet]. 2015 Sep 3 [cited 2023 Jun 2];21(5):503–20. Available from: <https://doi.org/10.1080/10454446.2014.885862>
  50. Kahneman D, Frederick S. Representativeness Revisited: Attribute Substitution in Intuitive Judgment. *Heuristics and Biases* [Internet]. 2002 Jun 18 [cited 2023 Jun 2];49–81. Available from: <https://www.cambridge.org/core/books/heuristics-and-biases/representativeness-revisited-attribute-substitution-in-intuitive-judgment/AAB5D933A3F944CFB5CB02265D376C8F>
  51. Granheim SI, Løvhaug AL, Terragni L, Torheim LE, Thurston M. Mapping the digital food environment: A systematic scoping review. *Obes Rev* [Internet]. 2022 Sep 14 [cited 2023 Mar 15];23(1):e13356. Available from: <https://doi.org/10.1111/obr.13356>
  52. Boyland EJ, Nolan S, Kelly B, Tudur-Smith C, Jones A, Halford JCG, et al. Advertising as a cue to consume: A systematic review and meta-analysis of the effects of acute exposure to unhealthy food and nonalcoholic beverage advertising on intake in children and adults. *Am J Clin Nutr* [Internet]. 2016;103(2):519–33. Available from:

- <https://doi.org/10.3945/ajcn.115.120022%0A>
53. Kelly B, Halford JCG, Boyland EJ, Chapman K, Bautista-Castaño I, Berg C, et al. Television Food Advertising to Children: A Global Perspective. *Am J Public Health* [Internet]. 2010 Sep 1 [cited 2023 Mar 16];100(9):1730–6. Available from: <https://doi.org/10.2105/AJPH.2009.179267>
  54. WHO - World Health Organization: Regional Office for Europe. Tackling food marketing to children in a digital world: trans-disciplinary perspectives [Internet]. 5; 2016 [cited 2023 Mar 17]. Available from: <https://apps.who.int/iris/handle/10665/344003>
  55. Rozendaal E, Buijzen M, Valkenburg P. Children's understanding of advertisers' persuasive tactics. *Int J Advert* [Internet]. 2011 [cited 2023 Mar 27];30(2):329–50. Available from: <https://doi.org/10.2501/IJA-30-2-329-350>
  56. Carter OBJ, Patterson LJ, Donovan RJ, Ewing MT, Roberts CM. Children's understanding of the selling versus persuasive intent of junk food advertising: Implications for regulation. *Soc Sci Med* [Internet]. 2011 Mar;72(6):962–8. Available from: <https://www.sciencedirect.com/science/article/abs/pii/S027795361100061X?via%3Dihub>
  57. Mills SDH, Tanner LM, Adams J. Systematic literature review of the effects of food and drink advertising on food and drink-related behaviour, attitudes and beliefs in adult populations. *Obes Rev* [Internet]. 2013 Jan 9 [cited 2023 Mar 16];14(4):303–14. Available from: <http://doi.wiley.com/10.1111/obr.12012>
  58. Vukmirovic M. The effects of food advertising on food-related behaviours and perceptions in adults: A review. *Food Res Int* [Internet]. 2015 Sep 1;75:13–9. Available from: <https://doi.org/10.1016/j.foodres.2015.05.011>
  59. Grier SA, Kumanyika S. Targeted marketing and public health [Internet]. Vol. 31, *Annual Review of Public Health*. 2010 [cited 2023 Mar 27]. p. 349–69. Available from: <https://doi.org/10.1146/annurev.publhealth.012809.103607>
  60. Backholer K, Gupta A, Zorbas C, Bennett R, Huse O, Chung A, et al. Differential exposure to, and potential impact of, unhealthy advertising to children by socio-economic and ethnic groups: A systematic review of the evidence. *Obes Rev* [Internet]. 2021 Mar 1 [cited 2023 Mar 30];22(3):e13144. Available from: <https://doi.org/10.1111/obr.13144>
  61. Cairns G, Angus K, Hastings G, Caraher M. Systematic reviews of the evidence on the nature, extent and effects of food marketing to children. A retrospective summary. *Appetite* [Internet]. 2013;62:209–15. Available from: <https://doi.org/10.1016/j.appet.2012.04.017>
  62. Sadeghirad B, Duhaney T, Motaghipisheh S, Campbell NRC, Johnston BC. Influence of unhealthy food and beverage marketing on children's dietary intake and preference: a systematic review and meta-analysis of randomized trials. *Obes Rev* [Internet]. 2016 Oct 1 [cited 2023 Jan 16];17(10):945–59. Available from: <https://doi.org/10.1111/obr.12445>
  63. Prowse R. Food marketing to children in Canada: A settings-based scoping review on exposure, power and impact. *Heal Promot Chronic Dis Prev Canada* [Internet]. 2017 Sep 1 [cited 2023 Jan 16];37(9):274–92. Available from: <https://doi.org/10.24095/hpcdp.37.9.03>
  64. Russell SJ, Croker H, Viner RM. The effect of screen advertising on children's dietary intake: A systematic review and meta-analysis. *Obes Rev* [Internet]. 2019 Apr 1 [cited 2023 Jun 3];20(4):554–68. Available from: <http://doi.wiley.com/10.1111/obr.12812>
  65. Smith R, Kelly B, Yeatman H, Boyland E. Food Marketing Influences Children's

- Attitudes, Preferences and Consumption: A Systematic Critical Review. *Nutrients* [Internet]. 2019 Apr 18;11(4):875. Available from: <https://doi.org/10.3390/nu11040875>
66. Packer J, Russell SJ, Siovolgyi G, McLaren K, Stansfield C, Viner RM, et al. The Impact on Dietary Outcomes of Celebrities and Influencers in Marketing Unhealthy Foods to Children: A Systematic Review and Meta-Analysis. *Nutrients* [Internet]. 2022 Feb 1 [cited 2023 Jan 28];14(3):434. Available from: <https://doi.org/10.3390/nu14030434>
  67. Kantar. Power of Connection: how technology brands make TV work for them [Internet]. Kantar. 2020 [cited 2023 Apr 15]. Available from: <https://www.kantar.com/inspiration/advertising-media/power-of-connection-how-technology-brands-make-tv-work-for-them>
  68. Hotmart. What are means of communication and which ones you should use for advertising [Internet]. Hortmart. 2020 [cited 2023 Apr 22]. Available from: <https://hotmart.com/en/blog/means-of-communication>
  69. Brasil. Pesquisa Nacional por Amostra de Domicílios (PNAD): Acesso à Internet e à televisão e posse de telefone móvel celular para uso pessoal 2018 [Internet]. IBGE - Instituto Brasileiro de Geografia e Estatística. 2012 [cited 2023 Mar 19]. Available from: [https://biblioteca.ibge.gov.br/visualizacao/livros/liv101705\\_informativo.pdf](https://biblioteca.ibge.gov.br/visualizacao/livros/liv101705_informativo.pdf)
  70. Kantar Ibope Media. Inside Video 2022 revela preferências dos brasileiros no consumo de conteúdos em vídeo [Internet]. Kantar IBOPE Media. 2022 [cited 2022 May 27]. Available from: <https://www.kantaribopemedia.com/inside-video-2022/>
  71. Kantar. Retrospectiva & Perspectiva 2018 [Internet]. Brazil; 2018 [cited 2021 Jan 19]. Available from: <https://kantaribopemedia.com/retrospectiva-perspectivas-2018/>
  72. Nieto C, Jáuregui A, Contreras-Manzano A, Potvin Kent M, Sacks G, White CM, et al. Adults' Exposure to Unhealthy Food and Beverage Marketing: A Multi-Country Study in Australia, Canada, Mexico, the United Kingdom, and the United States. *J Nutr* [Internet]. 2022 Jun 13 [cited 2023 Jan 25];152(Supplement 1):25S-34S. Available from: <https://doi.org/10.1093/jn/nxab449>
  73. Ferreira RMC, Santana DO. Consumer Advertising: A Study of the Strategies Embedded in Rede Globo's Soap Operas per Time Slots. *Signo y Pensam* [Internet]. 2013 Jun [cited 2023 Mar 6];32(62):150–62. Available from: [http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S0120-48232013000100010](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-48232013000100010)
  74. Junior RT. Programação de TV: Conceitos, Estratégias, Táticas e Formatos [Internet]. 1st ed. Curitiba, Brasil: Appris; 2022. Available from: <https://books.google.dk/books?hl=pt-BR&lr=&id=bNibEAAAQBAJ&oi=fnd&pg=PT20&dq=Os+investimentos+publicitáris+na+TV+podem+ocorrer+de+diversas+formas,+sendo+que+as+principais+são+por+meio+de+intervalos+comerciais+e+de+ações+de+merchandising+editorial.+Os+int>
  75. Morton H. Television food advertising: a challenge for the new public health in Australia. *Community Health Stud* [Internet]. 2010 Feb 12 [cited 2023 Jan 29];14(2):153–61. Available from: <https://doi.org/10.1111/j.1753-6405.1990.tb00036.x>
  76. Jenkin G, Madhvani N, Signal L, Bowers S. A systematic review of persuasive marketing techniques to promote food to children on television. *Obes Rev* [Internet]. 2014;15(4):281–93. Available from: <https://doi.org/10.1111/obr.12141>
  77. Allemandi L, Castronuovo L, Tiscornia MV, Ponce M, Schoj V. Food advertising on Argentinean television: are ultra-processed foods in the lead? *Public Health Nutr* [Internet]. 2018 Jul 26 [cited 2022 Jul 20];21(1):238–46. Available from: <https://doi.org/10.1017/S1368980017001446>



78. Bassi S, Bahl D, Maity H, Dudeja S, Sethi V, Arora M. Content analysis of food advertisements on popular Indian television channels among children and youth: a cross-sectional study. *J Glob Heal Reports* [Internet]. 2021;5:e2021089. Available from: <https://doi.org/10.29392/001c.28355>
79. Boyland EJ, Harrold JA, Kirkham TC, Halford JCG. The extent of food advertising to children on UK television in 2008. *Int J Pediatr Obes* [Internet]. 2011 Oct [cited 2021 Aug 12];6(5–6):455–61. Available from: <https://pubmed.ncbi.nlm.nih.gov/21846176/>
80. Bragg MA, Miller AN, Roberto CA, Sam R, Sarda V, Harris JL, et al. Sports Sponsorships of Food and Nonalcoholic Beverages. *Pediatrics* [Internet]. 2018;141(4):e20172822. Available from: <https://doi.org/10.1542/peds.2017-2822>
81. Kelly B, Vandevijvere S, Ng SH, Adams J, Allemanni L, Bahena-Espina L, et al. Global benchmarking of children’s exposure to television advertising of unhealthy foods and beverages across 22 countries. *Obes Rev* [Internet]. 2019;20(S2):116–28. Available from: <https://doi.org/10.1111/obr.12840>
82. Prathapan S, Wijewardena K, Low WY. Content Analysis of Food and Beverages Advertisements Targeting Children and Adults on Television in Sri Lanka. *Asia Pac J Public Health* [Internet]. 2016 Jan 1 [cited 2022 Jul 20];28(1 Suppl):86S. Available from: <https://pubmed.ncbi.nlm.nih.gov/2785022/>
83. Rincón-Gallardo Patiño S, Tolentino-Mayo L, Flores Monterrubio EA, Harris JL, Vandevijvere S, Rivera JA, et al. Nutritional quality of foods and non-alcoholic beverages advertised on Mexican television according to three nutrient profile models. *BMC Public Health* [Internet]. 2016 Aug 5 [cited 2023 Mar 20];16:733. Available from: <https://doi.org/10.1186/s12889-016-3298-0>
84. Vandevijvere S, Soupen A, Swinburn B. Unhealthy food advertising directed to children on New Zealand television: extent, nature, impact and policy implications. *Public Health Nutr* [Internet]. 2017 Dec 1 [cited 2022 Jul 20];20(17):3029–40. Available from: <https://www.cambridge.org/core/journals/public-health-nutrition/article/unhealthy-food-advertising-directed-to-children-on-new-zealand-television-extent-nature-impact-and-policy-implications/DE1E6440757B1FBD25FE548A7B8EAAB8>
85. Henriques P, Sally EO, Burlandy L, Beiler RM. Regulation of publicity for children’s food as a strategy for promotion of health. *Ciência e Saúde Coletiva* [Internet]. 2012 Jan [cited 2023 Apr 15];17(2):481–90. Available from: <https://doi.org/10.1590/S1413-81232012000200021>
86. Costa SMM, Horta PM, dos Santos LC. Analysis of television food advertising on children’s programming on “free-to-air” broadcast stations in Brazil. *Rev Bras Epidemiol* [Internet]. 2013 Dec [cited 2023 Mar 15];16(4):976–83. Available from: <https://doi.org/10.1590/S1415-790X2013000400017>
87. Maia EG, Costa BV de L, Coelho F de S, Guimarães JS, Fortaleza RG, Claro RM. Analysis of TV food advertising in the context of recommendations by the Food Guide for the Brazilian Population. *Cad Saude Publica* [Internet]. 2017 [cited 2023 Mar 15];33(4):e00209115. Available from: <https://doi.org/10.1590/0102-311X00209115>
88. Swinburn B, Sacks G, Vandevijvere S, Kumanyika S, Lobstein T, Neal B, et al. INFORMAS (International Network for Food and Obesity/non-communicable diseases Research, Monitoring and Action Support): Overview and key principles. *Obes Rev* [Internet]. 2013 Oct;14(S1):1–12. Available from: <https://doi.org/10.1111/obr.12087>
89. WHO - World Health Organization: Regional Office for Europe. WHO Regional Office for Europe nutrient profile model [Internet]. WHO Regional Office for Europe. Copenhagen; 2015 [cited 2023 Jan 29]. Available from: <https://apps.who.int/iris/handle/10665/152779>

90. Guimarães JS, Mais LA, Leite FHM, Horta PM, Santana MO, Martins APB, et al. Ultra-processed food and beverage advertising on Brazilian television by International Network for Food and Obesity/Non-Communicable Diseases Research, Monitoring and Action Support benchmark. *Public Health Nutr* [Internet]. 2020 [cited 2023 Apr 15];23(15):2657–62. Available from: <https://doi.org/10.1017/S1368980020000518>
91. OPAS - Organização Pan-Americana da Saúde. Modelo de Perfil Nutricional da Organização Pan-Americana da Saúde [Internet]. Washington, DC; 2016. Available from: <https://iris.paho.org/handle/10665.2/18623>
92. Leite FHM, Mais LA, Ricardo CZ, Andrade GC, Guimarães JS, Claro RM, et al. Nutritional quality of foods and non-alcoholic beverages advertised on Brazilian free-to-air television: A cross-sectional study. *BMC Public Health* [Internet]. 2020 Mar 24 [cited 2023 Jan 29];20(385). Available from: <https://doi.org/10.1186/s12889-020-08527-6>
93. Santana MO, Guimarães JS, Leite FHM, Mais LA, Horta PM, Martins APB, et al. Analysing persuasive marketing of ultra-processed foods on Brazilian television. *Int J Public Health* [Internet]. 2020 Sep 1 [cited 2021 Jan 16];65:1067–77. Available from: <https://doi.org/10.1007/s00038-020-01456-6>
94. Guimarães JS, Mais LA, Leite FHM, Horta PM, Santana MO, Martins APB, et al. Abusive advertising of food and drink products on Brazilian television. *Health Promot Int* [Internet]. 2021 Jul 19 [cited 2023 Apr 9];37(2):daab025. Available from: <https://doi.org/10.1093/heapro/daab025>
95. Kelly B, Backholer K, Boyland E, Kent MP, Bragg MA, Karupaiah T, et al. Contemporary Approaches for Monitoring Food Marketing to Children to Progress Policy Actions. *Curr Nutr Rep* [Internet]. 2023 Mar 1 [cited 2023 Mar 30];12:14–25. Available from: <https://doi.org/10.1007/s13668-023-00450-7>
96. Haleem A, Javaid M, Asim Qadri M, Pratap Singh R, Suman R. Artificial intelligence (AI) applications for marketing: A literature-based study. *Int J Intell Networks* [Internet]. 2022 Jan 1 [cited 2023 Mar 6];3:119–32. Available from: <https://doi.org/10.1016/j.ijin.2022.08.005>
97. Haenlein M, Kaplan A. A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *Calif Manage Rev* [Internet]. 2019 Jul 17 [cited 2021 Mar 22];61(4). Available from: <https://doi.org/10.1177/0008125619864925>
98. Brei VA. Machine learning in marketing. *Found Trends Mark* [Internet]. 2020 Aug 31 [cited 2023 Mar 6];14(3):173–236. Available from: <http://dx.doi.org/10.1561/17000000065>
99. Chintalapati S, Pandey SK. Artificial intelligence in marketing: A systematic literature review. *Int J Mark Res* [Internet]. 2022 Jul 2 [cited 2023 Mar 6];64(1):38–68. Available from: <https://doi.org/10.1177/14707853211018428>
100. Jin P, Ji X, Kang W, Li Y, Liu H, Ma F, et al. Artificial intelligence in gastric cancer: a systematic review. *Journal of Cancer Research and Clinical Oncology* [Internet]. 2020 Sep 1 [cited 2021 Mar 22];2339–50. Available from: <https://link.springer.com/article/10.1007/s00432-020-03304-9>
101. Belić M, Bobić V, Badža M, Šolaja N, Đurić-Jovičić M, Kostić VS. Artificial intelligence for assisting diagnostics and assessment of Parkinson’s disease—A review [Internet]. Vol. 184, *Clinical Neurology and Neurosurgery*. Elsevier B.V.; 2019 [cited 2021 Mar 22]. p. 105442. Available from: <https://www.sciencedirect.com/science/article/abs/pii/S0303846719302380?via%3Dihub>
102. Valle E, Fornaciali M, Menegola A, Tavares J, Vasques Bittencourt F, Li LT, et al. Data, depth, and design: Learning reliable models for skin lesion analysis.

- Neurocomputing. 2020 Mar 28;383:303–13.
103. Ngiam KY, Khor IW. Big data and machine learning algorithms for health-care delivery. *Lancet Oncol* [Internet]. 2019 May 1 [cited 2021 Mar 22];20(5):e262–73. Available from: <http://www.thelancet.com/article/S1470204519301494/fulltext>
  104. Koenigkam Santos M, Raniery Ferreira Júnior J, Tadao Wada D, Priscilla Magalhães Tenório A, Henrique Nogueira Barbosa M, Mazzoncini De Azevedo Marques P. Artificial intelligence, machine learning, computer-aided diagnosis, and radiomics: Advances in imaging towards to precision medicine. *Radiol Bras* [Internet]. 2019 [cited 2021 Mar 22];52(6):387–96. Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7007049/>
  105. Contreras I, Vehi J. Artificial intelligence for diabetes management and decision support: Literature review [Internet]. Vol. 20, *Journal of Medical Internet Research*. JMIR Publications Inc.; 2018 [cited 2021 Mar 22]. p. e10775. Available from: <https://www.jmir.org/2018/5/e10775>
  106. Jiang F, Jiang Y, Zhi H, Dong Y, Li H, Ma S, et al. Artificial intelligence in healthcare: past, present and future. *Stroke Vasc Neurol* [Internet]. 2017 Dec 1 [cited 2023 Jun 2];2(4):230–43. Available from: <http://dx.doi.org/10.1136/svn-2017-000101>
  107. Piccialli F, di Cola VS, Giampaolo F, Cuomo S. The Role of Artificial Intelligence in Fighting the COVID-19 Pandemic. *Inf Syst Front* 2021 236 [Internet]. 2021 Apr 26 [cited 2023 Jun 2];23(6):1467–97. Available from: <https://doi.org/10.1007/s10796-021-10131-x>
  108. Chen J, Li K, Zhang Z, Li K, Yu PS. A Survey on Applications of Artificial Intelligence in Fighting Against COVID-19. *ACM Comput Surv* [Internet]. 2020 Jul 4 [cited 2023 Jun 2];54(8). Available from: <https://doi.org/10.48550/arXiv.2007.02202>
  109. Olstad DL, Lee J. Leveraging artificial intelligence to monitor unhealthy food and brand marketing to children on digital media [Internet]. Vol. 4, *The Lancet Child and Adolescent Health*. 2020 [cited 2023 Apr 18]. p. 418–20. Available from: [https://doi.org/10.1016/S2352-4642\(20\)30101-2](https://doi.org/10.1016/S2352-4642(20)30101-2)
  110. Olstad DL, Raman M, Valderrama C, Abad ZSH, Cheema AB, Ng S, et al. Development of an Artificial Intelligence System to Monitor Digital Marketing of Unhealthy Food to Children: Research Protocol. *Curr Dev Nutr* [Internet]. 2022 Jun 14 [cited 2023 Apr 18];6(Supl.1):1151. Available from: <https://doi.org/10.1093/cdn/nzac072.023>
  111. Kidd B, Mackay S, Swinburn B, Lutteroth C, Vandevijvere S. AdHealth: A feasibility study to measure digital food marketing to adolescents through Facebook. *Public Health Nutr* [Internet]. 2021 [cited 2023 Mar 19];24(2):215–22. Available from: <https://doi.org/10.1017/S1368980020001561>
  112. UNSCN. Nutrition 45: Nutrition in a Digital World. United Nations System Standing Committee on Nutrition [Internet]. 2020 Jul [cited 2023 Apr 17];1–148. Available from: <https://www.unscn.org/uploads/web/news/UNSCN-Nutrition-45-WEB.pdf>
  113. IBOPE - Instituto Brasileiro de Opinião Pública e Estatística. Audiência do Horário Nobre – 15 mercados – 26/03/2018 a 01/04/2018 2018 [Internet]. Instituto Brasileiro de Opinião Pública e Estatística. 2018 [cited 2020 Jan 23]. Available from: <https://www.kantaribopemedia.com/audiencia-dohorario-nobre-15-mercados-26032018>
  114. Gebu T, Morgenstern J, Vecchione B, Vaughan JW, Wallach H, Iii HD, et al. Datasheets for datasets. *Commun ACM* [Internet]. 2021 Dec 1 [cited 2023 Apr 18];64(12):86–92. Available from: <https://doi.org/10.1145/3458723>
  115. Géron A. Hands-On Machine Learning with Scikit-Learn, Keras & Tensor Flow. In: Tache N, editor. Second. United States of American: Jupyter; 2019. p. 510.
  116. Arrieta AB, Díaz-Rodríguez N, Del Ser J, Bennetot A, Tabik S, Barbado A, et al.

- Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Inf Fusion* [Internet]. 2020 Jun [cited 2023 Mar 29];58:82–115. Available from: <https://doi.org/10.1016/j.inffus.2019.12.012>
117. Tan M, Le Q V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. In: International Conference on Machine Learning, ICML 2019. *Proceedings of Machine Learning Research*, PMLR; 2019. p. 6105–14.
  118. Perez F, Vasconcelos C, Avila S, Valle E. Data augmentation for skin lesion analysis. In: OR 20 Context-Aware Operating Theaters, Computer Assisted Robotic Endoscopy, Clinical Image-Based Procedures, and Skin Image Analysis CARE CLIP OR 20 ISIC 2018 2018 2018 2018 Lecture Notes in Computer Science [Internet]. 2018 [cited 2023 Mar 6]. p. 303–11. Available from: [https://doi.org/10.1007/978-3-030-01201-4\\_33](https://doi.org/10.1007/978-3-030-01201-4_33)
  119. Matos J de P, Gondo M, Mota LSE, Horta PM. Food advertising aimed at children and adolescents in Brazil: a longitudinal analysis of denouncements in CONAR. *Cien Saude Colet* [Internet]. 2022;334. Available from: <http://cienciaesaudecoletiva.com.br/artigos/publicidade-de-alimentos-direcionada-a-crianca-e-ao-adolescente-no-brasil-analise-longitudinal-de-denuncias-no-conar/18590>

## 7. ANEXOS

### Anexo A

#### Questionário elaborado para a coleta de dados das publicidades – Coleta geral

##### Informação da publicidade

Nome do canal

Rede Globo

SBT

Rede Record

Cartoon

Discovery Kids

Data da gravação

04/06/2020

07/06/2020

09/06/2020

11/06/2020

13/06/2020

20/06/2020

24/06/2020

27/06/2020

Nome do programa

Horário da propaganda

Horário de início da propaganda

HH:MM:SS

Horário de término da propaganda

HH:MM:SS

Momento da propaganda

Tipo de propaganda

Código da propaganda