

UNIVERSIDADE DE SÃO PAULO
CENTRO DE ENERGIA NUCLEAR NA AGRICULTURA

YUNIEL TEJEDA MAZOLA

Rastreabilidade da carne bovina brasileira avaliada por técnicas
isotópicas e quimiométricas

Piracicaba
2022

YUNIEL TEJEDA MAZOLA

Rastreabilidade da carne bovina brasileira avaliada por técnicas isotópicas e quimiométricas

Tese apresentada ao Centro de Energia Nuclear na Agricultura da Universidade de São Paulo para obtenção do título de Doutor em Ciências

Área de Concentração: Energia Nuclear na Agricultura e no Ambiente

Orientadora: Prof^a. Dr^a Elisabete A. De Nadai Fernandes

Piracicaba
2022

AUTORIZO A DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Dados Internacionais de Catalogação na Publicação (CIP)

Técnica de Biblioteca - CENA/USP

Tejeda Mazola, Yuniel

Rastreabilidade da carne bovina brasileira avaliada por técnicas isotópicas e quimiométricas / Yuniel Tejeda Mazola; Elisabete A. De Nadai Fernandes. - - Piracicaba, 2022.

159 p.

Tese (Doutorado– Programa de Pós-Graduação em Ciências. Área de Concentração: Energia Nuclear na Agricultura e no Ambiente) – Centro de Energia Nuclear na Agricultura da Universidade de São Paulo, 2022.

1. Análise por ativação neutrônica. 2. Aprendizado de máquina. 3. Autenticidade da carne bovina. 4. Biomas brasileiros. 5. Perfil agrometalômico.
I. Título

CDU 637.5'62

Elaborada por:

Marília Ribeiro Garcia Henyei

CRB-8/3631

Resolução CFB Nº 184 de 29 de setembro de 2017

*Aos meus filhos, sirva de exemplo para sempre seguirem seus sonhos
A minha esposa, pelo amor incondicional e me encorajar cada dia a ser melhor
Aos meus avós, irmãos, pais, primos e tios por fazerem dos meus sonhos os seus
Obrigado pelo incansável apoio ao longo do período de elaboração deste trabalho*

Dedico

La presencia es mucho mas que estar aí

AGRADECIMENTOS

Gostaria de expressar minha mais sincera gratidão a todos aqueles que tornaram possível a minha meta de ser Doutor.

- Agradeço primeiramente à Prof^a. Elisabete A. De Nadai Fernandes, pela oportunidade de trabalhar no seu grupo de pesquisa, orientação, ensinamentos, apoio, incentivo, consideração e respeito
- Ao Laboratório de Radioisótopos – LRI, pelo suporte técnico-científico
- Ao Dr. Márcio Arruda Bacchi, por todo o suporte, disponibilidade, incentivo e amizade
- Ao Cláudio e Adriana, por todo o suporte, auxílio nas coletas, análises e amizade
- Ao Centro de Energia Nuclear na Agricultura (CENA) da Universidade de São Paulo (USP), pela grata estadia e experiência adquirida
- À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pelo financiamento de bolsa durante o Doutorado
- Aos meus colegas de laboratório, pela amizade, ajuda e convivência
- Ao pessoal da Secretaria de Pós-Graduação, por toda a disposição, auxílio e serviços prestados durante o Doutorado
- A minha família pelo apoio incondicional, aos que estão em Cuba que gostariam de compartilhar este momento mais de perto comigo, e minha esposa e filhos por me apoiarem e darem forças para continuar cada dia



“A vida não é fácil para nenhum de nós. Mas e daí? Nós devemos ter persistência e, acima de tudo, confiança em nós mesmos. Devemos acreditar que somos talentosos em alguma coisa, e que essa coisa, a qualquer custo, deve ser alcançada.”

Marie Curie

RESUMO

Tejeda Mazola, Y. **Rastreabilidade da carne bovina brasileira avaliada por técnicas isotópicas e quimiométricas**. 2022. 159 p. Tese (Doutorado em Ciências) – Centro de Energia Nuclear na Agricultura, Universidade de São Paulo, Piracicaba, 2022.

A crescente repercussão dos impactos ambientais causados pela pecuária bovina está influenciando grandemente a decisão do consumo de carne. A preocupação dos consumidores não se pauta apenas na qualidade do produto, mas, especialmente, com a origem geográfica, as condições de produção e os aspectos ambientais e humanos. A produção de carne bovina é fortemente criticada devido ao custo ambiental da atividade, associado a problemas de desmatamento, consumo de água, aquecimento global e mudanças climáticas. No entanto, os produtos alimentares de origem animal desempenham papel importante na segurança alimentar mundial. Aumentar a transparência da cadeia produtiva da carne bovina é essencial para melhorar a percepção do consumidor. Brasil é o maior exportador e o segundo maior produtor de carne bovina, com um rebanho de 196 milhões de animais distribuídos em uma vasta área de 163 milhões de hectares, compreendendo os biomas Amazônia, Caatinga, Cerrado, Mata Atlântica, Pampa e Pantanal. O país tem sido duramente criticado por algumas entidades internacionais que atribuem sua alta produção à expansão em áreas desmatadas ilegalmente. Nesse sentido, a caracterização do perfil agrometalômico da carne bovina permitirá obter modelos de aprendizado de máquina como instrumento de avaliação da autenticidade, contribuindo para a transparência do sistema produtivo. Amostras de carne bovina dos maiores exportadores mundiais - Brasil, dos biomas Amazônia, Caatinga, Cerrado, Pampa e Pantanal, Austrália, Argentina, Uruguai e Paraguai - foram selecionadas e submetidas à análise por ativação neutrônica para determinação do perfil agrometalômico. Cinco algoritmos de aprendizado de máquina - Classification and Regression Tree (CART), Multilayer Perceptron (MLP), Naïve Bayes (NB), Random Forest (RF) e Sequential Minimal Optimization (SMO) - foram utilizados para classificação. O modelo MLP apresentou o melhor desempenho de classificação, com acurácia de 100 %, 98 %, 98 %, 96 % e 82 %, respectivamente, para amostras procedentes do Paraguai, Uruguai, Austrália, Argentina e Brasil. Reduzindo o número de classes, a acurácia de classificação das amostras de carne bovina brasileira alcançou 94 % sem alterar o desempenho para outros países. As carnes dos biomas brasileiros foram discriminadas com aproximadamente 95 % de acurácia, comparando cada bioma com os demais. A melhor acurácia de classificação foi obtida para carne bovina dos biomas Amazônia (99 %) e Caatinga (99 %). O uso combinado de composição multielementar e aprendizado de máquina permitiu discriminar os países produtores de carne bovina, tornando-se uma ferramenta valiosa para rastreabilidade e transparência da origem geográfica.

Palavras-chave: Análise por ativação neutrônica. Aprendizado de máquina. Autenticidade da carne bovina. Biomas brasileiros. Perfil agrometalômico.

ABSTRACT

Tejeda Mazola, Y. **Traceability of Brazilian beef evaluated by isotopic and chemometric techniques**. 2022. 159 p. Thesis (Doctorate in Sciences) – Centro de Energia Nuclear na Agricultura, Universidade de São Paulo, Piracicaba, 2022.

The growing repercussion of the environmental impacts caused by cattle ranching is greatly influencing the decision to consume meat. Consumers' concern is not only based on the quality of the product, but especially with the geographical origin, production conditions and environmental and human aspects. Beef production is heavily criticized due to the environmental cost of the activity, associated with problems of deforestation, water consumption, global warming and climate change. However, food products of animal origin play an important role in global food security. Increasing the transparency of the beef supply chain is essential to improve consumer perception. Brazil is the largest exporter and second largest producer of beef, with a herd of 196 million animals distributed over a vast area of 163 million hectares, comprising the Amazon, Caatinga, Cerrado, Atlantic Forest, Pampa and Pantanal biomes. The country has been harshly criticized by some international entities that attribute its high production to expansion into illegally deforested areas. In this sense, the characterization of the agrometallomic profile of beef will make it possible to obtain machine learning models as an instrument for assessing authenticity, contributing to the transparency of the production system. Beef samples from the world's largest exporters - Brazil, from the Amazon, Caatinga, Cerrado, Pampa and Pantanal biomes, Australia, Argentina, Uruguay and Paraguay - were selected and subjected to neutron activation analysis to determine the agrometallomic profile. Five machine learning algorithms - Classification and Regression Tree (CART), Multilayer Perceptron (MLP), Naïve Bayes (NB), Random Forest (RF) and Sequential Minimal Optimization (SMO) - were used for classification. The MLP model presented the best classification performance, with accuracy of 100 %, 98 %, 98 %, 96 % and 82 %, respectively, for samples from Paraguay, Uruguay, Australia, Argentina and Brazil. Reducing the number of classes, the classification accuracy of Brazilian beef samples reached 94 % without changing the performance for other countries. Beef from Brazilian biomes was discriminated with approximately 95% accuracy, comparing each biome with the others. The best classification accuracy was obtained for beef from the Amazon (99 %) and Caatinga (99 %) biomes. The combined use of multi-element composition and machine learning allowed to discriminate between beef producing countries, making it a valuable tool for traceability and transparency of geographic origin.

Keywords: Neutron activation analysis. Machine learning. Beef authenticity. Brazilian biomes. Agrometallomic profile.

LISTA DE FIGURAS

Figura 1. Mapa da distribuição dos biomas no Brasil (a), distribuição do rebanho bovino no ano 2020 (b) e evolução do rebanho bovino no Brasil entre os anos 1975 e 2015 (c).....	28
Figura 2. Evolução da área de pastagem e da produtividade	29
Figura 3. Nível de desenvolvimento tecnológico e concentração de fazendas no bioma Amazônia	31
Figura 4. Evolução das exportações de carne bovina brasileira.....	33
Figura 5. Rastreabilidade da cadeia produtiva de carne bovina brasileira empregando o sistema Trase	34
Figura 6. Reação (n , γ) empregada na NAA	36
Figura 7. Conjunto de dados representados por círculos pretos e triângulos vermelhos e 5 hiperplanos para separação	42
Figura 8. Transformação de um conjunto de dados bidimensional contendo duas classes (círculos e sinal de mais) não linearmente separáveis para um conjunto bidimensional linearmente separável	43
Figura 9. Exemplo de um Multilayer Perceptron obtido para discriminação da origem geográfica de café Arábica de 15 países utilizando 11 parâmetros de qualidade	44
Figura 10. Estrutura gerada pelo modelo CART para discriminação da origem entomológica de dois méis brasileiros com base na fração de massa de prata.....	45
Figura 11. Locais de amostragem de carne bovina no Brasil.....	48
Figura 12. Locais de amostragem de carne bovina. EO: Estrela do Oeste (Frigoestrela); IT: Itápolis; NH: Nhandeara; PI: Piracanjuba; PL: Planura; PP: Ponta Porã; RN: Rondonópolis.....	49
Figura 13. Cortes de carne bovina selecionados	50
Figura 14. Distribuição geográfica das principais raças de gado de corte no Brasil.....	50
Figura 15. Identificação dos cortes de carne bovina dos animais após abate.....	52
Figura 16. Composição das rações para bovinos fornecidas aos animais da Beef Passion.....	54
Figura 17. Etapas de corte (A), liofilização (B) e moagem (C) das amostras de carne bovina.....	55
Figura 18. Etapas de pré-moagem (A), liofilização (B) e moagem (C) das amostras de ração para bovinos.	56
Figura 19. Cápsulas de polietileno contendo material a ser irradiado e monitores de fluxo de nêutrons de Ni-Cr.....	57
Figura 20. Sala de espectrometria gama do Laboratório de Radioisótopos	59
Figura 21. En score calculado para os materiais de referência certificados nos lotes de irradiação	64
Figura 22. Fração de massa dos elementos químicos (mg kg^{-1}) quantificados nas rações A ($n = 7$) e B ($n = 7$) com as facas M 20 e M 22.....	68
Figura 23. PCA e biplot da composição química da carne bovina de cinco países produtores	72
Figura 24. Dendrograma da composição multielementar da carne bovina de cinco países produtores	73
Figura 25. Acurácia, precisão, sensibilidade e especificidade para discriminar a carne bovina de cinco países produtores implementando os modelos de classificação CART, MLP, NB, RF e SMO	74
Figura 26. Acurácia de classificação para rastreabilidade da carne bovina de diferentes países utilizando a composição multielementar e o algoritmo MLP	76
Figura 27. PCA e biplot da composição multielementar da carne bovina dos biomas Amazônia, Cerrado, Caatinga, Pampa e Pantanal	79
Figura 28. Dendrograma da composição multielementar da carne bovina dos biomas Amazônia, Cerrado, Caatinga, Pampa e Pantanal	80
Figura 29. Importância relativa das variáveis para discriminar a carne bovina dos biomas brasileiros	80
Figura 30. Importância das variáveis para discriminar a carne bovina dos sete estados estudados. As barras verdes representam os elementos que apresentaram diferença estatisticamente significativa entre	

as classes ($p < 0,05$) e as azuis os elementos que não apresentaram diferença estatisticamente significativa entre as classes ($p > 0,05$)	84
Figura 31. Árvore de decisão obtida com as frações de massa (mg kg^{-1}) de Br, Co e Se implementando o modelo CART para discriminação da carne bovina dos biomas Amazônia (PA) e Caatinga (PE)....	89
Figura 32. Dispersão de Br e Se para discriminação de amostras de carne bovina procedentes do Pará	92
Figura 33. Distribuição das frações de massa dos elementos químicos determinados em amostras procedentes dos municípios Itápolis SP (IT, $n = 10$), Piracanjuba GO (PI, $n = 10$), Planura MG (PL, $n = 10$), Ponta Porã MS (PP, $n = 10$) e Rondonópolis MT (RM, $n = 10$).....	94
Figura 34. Importância das variáveis para discriminar a carne bovina procedente de cada cidade do bioma Cerrado. As barras verdes representam os elementos que apresentaram diferença estatisticamente significativa entre as classes ($p < 0,05$) e as azuis os elementos que não apresentaram diferença estatisticamente significativa entre as classes ($p > 0,05$).....	95
Figura 35. Importância relativa das variáveis (elementos químicos) para discriminar as classes (corte, grupo genético e sexo).....	99
Figura 36. Regra de decisão gerada pelo modelo CART empregando o subconjunto Chi#2 para discriminação dos cortes de carne bovina	103
Figura 37. Dendrograma obtido utilizando os subconjuntos Chi#1 e Chi#9 para discriminação dos cortes de carne bovina	104
Figura 38. Distância mínima significativa (MSD) em porcentagem referente à média da fração de massa dos elementos químicos para discriminação da carne bovina de regiões do Brasil, países produtores, corte, sexo e grupo genético dos animais e incerteza analítica média (U) em porcentagem referente à média das frações de massa dos elementos químicos.....	105
Figura 39. Diagrama representando as condições ambientais e de criação que influenciam o perfil agrometalômico e definem o terroir da carne bovina	107
Figura 40. Componentes Principais com Biplot para discriminar amostras procedentes da Beef Passion (BP), considerando 49 % das informações (PC1 32 % e PC2 17 %)	108
Figura 41. Regra de decisão gerada pelo modelo CART para discriminar a carne bovina proveniente da Beef Passion com base na fração de massa (mg/kg) de Br e Na	109
Figura 42. Importância relativa variável com base no valor de qui-quadrado, F-score e coeficiente de Cramer	112
Figura 43. Valores de acurácia obtidos pelos modelos de classificação usando diferentes subconjuntos de variáveis ordenadas pelo valor de qui-quadrado e F-score	114
Figura 44. Distribuição das frações de massa de Cs e Se e de Cs, Sc e Se, respectivamente, nas rações A e B.....	115

LISTA DE TABELAS

Tabela 1. Elementos químicos determinados por NAA e respectivos limites de detecção.....	38
Tabela 2. Origem das amostras de carne bovina.....	48
Tabela 3. Amostras de carne bovina analisadas procedentes da Beef Passion.....	53
Tabela 4. Características da jarra e bolas do moinho PM 400	55
Tabela 5. Tempo de meia-vida, energia dos raios gama, radionuclídeos interferentes e melhor contagem para detecção dos radionuclídeos	58
Tabela 6. Limites de detecção (LD) e desvio padrão (SD) obtidos para as os elementos químicos determinados em amostras de ração para bovinos.	65
Tabela 7. Limites de detecção e desvio padrão (SD) obtidos para os elementos químicos determinados em amostras de carne bovina.	66
Tabela 8. Valor mediano das frações de massa dos elementos químicos, desvio padrão robusto (RSD) e diferença estatisticamente significativa (SSD) usando o teste de Kruskal-Wallis	70
Tabela 9. Matriz de confusão obtida a partir dos modelos de classificação.....	75
Tabela 10. Matriz de confusão obtida a partir dos modelos de classificação MLP para diferenciar o país produtor.....	76
Tabela 11. Mediana das frações de massa dos elementos químicos e desvio padrão robusto (RSD) em mg/kg e diferença estatisticamente significativa (SSD) usando o teste de Kruskal-Wallis	78
Tabela 12. Acurácia geral obtida pelos modelos de classificação utilizando subconjuntos de variáveis avaliadas pelo qui-quadrado.....	81
Tabela 13. Matriz de confusão gerada pelos modelos de classificação CART, MLP e RF para discriminação da carne bovina dos biomas brasileiros	82
Tabela 14. Acurácia de classificação do Multilayer Perceptron (MLP), Random Forest (RF) e Classification and Regression Tree (CART) usando subconjuntos de variáveis baseados no valor de qui-quadrado	86
Tabela 15. Desempenho de classificação (Acurácia %) obtido implementando os modelos Multilayer Perceptron (MLP), Random Forest (RF) e Classification and Regression Tree (CART).	88
Tabela 16. Matrizes de confusão de maior acurácia geradas pelos modelos Multilayer Perceptron (MLP) e Random Forest (RF)	90
Tabela 17. Efeitos de interação entre sexo (S), grupo genético (GG) e corte (C) usando ANOVA fatorial	96
Tabela 18. Frações de massa médias de Br, Co, Cs, Fe, K, Na, Rb, Se e Zn, e diferenças estatisticamente significativas (SSD) empregando teste de comparação de Kruskal-Wallis com nível de significância de 0,05.....	97
Tabela 19. Acurácia de classificação dos modelos empregando os subconjuntos de variáveis organizados considerando o valor do qui-quadrado.....	100
Tabela 20. Matriz de confusão obtida implementando os modelos MLP, NB, RF e SMO para discriminação de cortes de carne bovina.....	101
Tabela 21. Desempenho de classificação dos modelos MLP, NB, RF e SMO para discriminação dos cortes de carne bovina picanha (A), contrafilé (B) e acém (C).....	102
Tabela 22. Matriz de confusão obtida implementando os modelos MLP, NB, RF e SMO para discriminar a carne bovina da <i>Beef Passion</i>	108
Tabela 23. Frações de massa dos elementos químicos determinados em ração para bovinos	110
Tabela 24. Distância mínima significativa (MSD) e incerteza analítica média (U) obtida nas rações para bovinos A (n = 14) e B (n = 14).	111
Tabela 25. Desempenho de classificação dos modelos RF, SMO, MLP, NB e CART para discriminação das rações para bovinos A e B.....	116

LISTA DE ABREVIATURAS E SIGLAS

ABIEC	Associação Brasileira das Indústrias Exportadoras de Carnes
ABPO	Associação Brasileira de Produtores Orgânicos
ANOVA	Análise de Variância
AR	Argentina
AU	Austrália
BR	Brasil
CART	Classification and Regression Tree
CDA	Análise Discriminante Canônica
ETR	Elementos Terras Raras
GAF	Global Agribusiness Forum
GO	Goiás
LDA	Análise Discriminante Linear
MG	Minas Gerais
MLP	Multilayer Perceptron
MS	Mato Grosso do Sul
MSD	Distância Mínima Significativa
NAA	Análise por Ativação Neutrônica
NB	Naïve Bayes
PA	Pará
PCA	Análise de Componentes Principais
PE	Pernambuco
PGAA	Prompt Gamma Rays
PY	Paraguai
RF	Random Forest
RS	Rio Grande do Sul
SP	São Paulo
SVM	Support Vector Machine
TEC	Tonelada Equivalente Carcaça
UA	Unidade de Animal
UY	Uruguai

SUMÁRIO

1 INTRODUÇÃO	23
2 REVISÃO	27
2.1 Características naturais do Brasil	27
2.2 Cadeia produtiva da carne bovina no Brasil	27
2.4 Análise de carne	34
2.3 Análise por ativação neutrônica	35
2.4 Inteligência artificial na agricultura	39
3 METODOLOGIA	47
3.1 Amostragem	47
3.1.1 Amostragem de carne bovina de diferentes países	47
3.1.2 Amostragem de carne bovina do bioma Cerrado	48
3.1.3 Influência do corte, raça e sexo	49
3.1.4 Beef Passion	50
3.1.5 Amostragem de carne bovina da Beef Passion	53
3.1.6 Amostragem de ração para bovinos da Beef Passion	53
3.2 Preparo de amostras	54
3.3 Análise por ativação neutrônica	56
3.4 Análises quimiométricas	59
4 RESULTADOS E DISCUSSÃO	63
4.1 Controle da qualidade analítica	63
4.2 Preparo de amostras	66
4.3 Rastreabilidade da carne bovina de diferentes países	69
4.4 Rastreabilidade da carne bovina de diferentes biomas do Brasil	77
4.5 Rastreabilidade da carne bovina do bioma Cerrado	92
4.6 Influência do corte, grupo genético e sexo	96
4.7 Análise da ração para bovinos da Beef Passion	109
5 CONCLUSÕES	117
REFERÊNCIAS	119
APÊNDICES	135
Apêndice A - Nível de desenvolvimento e cabeças de gado em diferentes biomas	137
Apêndice B - Dados referentes aos animais empregados na primeira etapa do estudo, WAG refere-se a ¼ Angus - ¼ Nelore - ½ - Wagyu e ANG a ½ Angus - ½ Nelore	139
Apêndice C - Variação das frações de massa dos elementos químicos nas rações A e B durante o período estudado	143

Apêndice D - Ce, Eu, La, Sc e Sm determinados em culturas orgânicas e matérias-primas fosfatadas.....	155
Apêndice E - Acurácia alcançada pelos modelos de classificação usando diferentes subconjuntos de variáveis ordenados de acordo com o valor de qui-quadrado	157
Apêndice F - Acurácia alcançada pelos modelos de classificação usando diferentes subconjuntos de variáveis ordenados de acordo com o valor de F-score.....	159

1 INTRODUÇÃO

A indústria global de carne bovina tornou-se um dos maiores negócios econômicos do mundo. A produção de carne bovina deverá aumentar nos próximos anos, consolidando Estados Unidos e Brasil como os principais países produtores. Os maiores exportadores mundiais são Brasil, Austrália, Estados Unidos e Índia [1]. Os produtores sul-americanos de carne bovina, Brasil, Argentina, Uruguai e Paraguai, estão fortalecendo a participação de mercado ao se tornarem concorrentes comerciais relevantes nos últimos anos [2].

O Brasil é um país com características naturais para desenvolver o agronegócio, considerando a extensão territorial de 8,5 milhões de km² que engloba importantes biomas como Amazônia, Caatinga, Cerrado, Mata Atlântica, Pantanal e Pampa. Em 2021, consolidou-se como uma potência agrícola, tornando-se maior exportador e segundo maior produtor de carne bovina do mundo [3], maior produtor de café, laranja e cana-de-açúcar [4], maior produtor de arroz fora da Ásia, maior produtor de soja [5], segundo maior produtor de tabaco, terceiro maior produtor de carne de frango [6], terceiro maior produtor de milho e quinto maior produtor de banana [4]. Brasil detém o maior rebanho bovino do mundo, com 196,468 milhões de animais, contemplando diversas raças e cruzamentos. A raça Nelore está presente em todo o território, dominando o rebanho bovino de corte há mais de um século e representando, ainda hoje, cerca de 75 %. O cruzamento Nelore – Angus, conhecido como cruzamento industrial, é um dos mais utilizados no Brasil, devido à maior tolerância às condições climáticas e a qualidade da carne (maciez e marmoreio). Mesmo com a predominância da raça Nelore no Brasil, apenas 39 % da inseminação de animais destinados à pecuária de corte é desta raça, ao passo que 49 % da inseminação artificial é feita com sêmen Angus proveniente dos EUA [7]. Destacam-se os estados de Mato Grosso (27,8 milhões), Minas Gerais (22,26 milhões), Goiás (19,71 milhões), Mato Grosso do Sul (22,02 milhões) e Pará (16,29 milhões), que concentram aproximadamente 55 % do rebanho bovino do país [3]. No bioma Amazônia, o crescimento do rebanho em 20 anos (1997 – 2017) chegou a índices elevados, como nos municípios de Nova Mamoré (1023 %), São Félix do Xingu (932 %), Novo Repartimento (732 %), Porto Velho (705 %), Cumarú do Norte (692 %), Pacajá (634%), Itupiranga (622 %), Novo Progresso (576 %), Marabá (494 %) e Altamira (465 %) [8]. Este crescimento da pecuária, especialmente no Pará e Rondônia, levou ao desmatamento irregular do bioma Amazônia, com extensiva mudança do uso da terra de floresta para pastagem [9-12].

Qualidade e sanidade da carne bovina são requisitos básicos essenciais para o consumo seguro desse importante alimento proteico. O consumidor tem buscado conhecer a origem geográfica, as condições de produção, os aspectos ambientais e humanos envolvidos no processo produtivo [13], assim como a qualidade nutricional e a sanidade dos alimentos. A preocupação com esses aspectos da carne bovina tem crescido na medida em que a demanda tem se expandido nos mercados nacional e internacional [13-19]. A tendência mundial das grandes redes varejistas é adquirir carne oriunda de sistemas sustentáveis de produção, com qualidade atestada por selos de origem. A certificação da qualidade dos alimentos (ISO 22.000 e GlobalGAP) é indispensável no processo de exportação para a superação de barreiras não tarifárias propiciando melhor resultado econômico para o país. Portanto, identificar, rastrear e certificar tornaram-se ferramentas utilizadas em todo o mundo [13, 14, 16, 20].

Sistemas eletrônicos de identificação animal (bolus intra-ruminal, brincos e bottons) têm sido implementados na União Europeia desde os anos 1990s [21] e no Brasil desde 2001 [22] com a criação do Sistema de Identificação e Certificação de Bovinos e Bubalinos (SISBOV). Essa rastreabilidade é, geralmente, perdida durante o processo de abate e mesmo durante a vida do animal [23]. A identificação do animal é simplesmente designativa e não acompanha o produto final que chega ao consumidor. Um exemplo disto foi exposto quando tentaram, sem sucesso, rastrear os atributos de carne bovina e salsichas de locais de varejo até os confinamentos de gado em Malawi [24].

Após os surtos epidêmicos do mal da vaca louca (encefalopatia espongiforme bovina - BSE), doença alcalina, chamada também cambaleio cego, ocasionada pelo teor elevado de selênio no solo [25], gripes aviária e suína que atingiram Europa, Estados Unidos e Japão, além da preocupação com a febre aftosa e infecções microbiológicas, os processos de rastreabilidade e certificação baseados em características intrínsecas dos produtos de origem animal mostraram-se como instrumentos de urgente utilização para garantia da sanidade e qualidade da proteína animal comercializada [16, 17]. Em 2017, a operação da Polícia Federal batizada como “Carne Fraca” trouxe ao conhecimento público processos não idôneos de fiscalização do Ministério de Agricultura, Pecuária e Abastecimento (MAPA), inspeção irregular dos procedimentos de abate de bovinos nos frigoríficos e, também, nos demais processos produtivos da carne comercializada no país, afetando a imagem internacional do setor do agronegócio brasileiro pela perda de credibilidade [26, 27].

Dortzbach et al. (2015) [28] durante estudo das áreas de pastagem do bioma Mata Atlântica demonstraram que pastagens com 50 anos de uso possuíam ainda 66 % de compostos orgânicos derivados da floresta (cobertura) original. Isótopos estáveis de carbono, nitrogênio, oxigênio, hidrogênio e enxofre têm sido empregados na determinação da origem geográfica da carne bovina [29, 30]. Estudos similares têm sido reportados usando a composição química para definir a origem geográfica da carne de carneiro proveniente de diferentes regiões da China [31] e classificação da carne bovina pelo modo de criação [32, 33]. Por outro lado, o emprego da análise por ativação neutrônica instrumental tem se mostrado promissor para discriminação da origem geográfica da carne bovina brasileira [34].

A carne bovina de diferentes regiões possui características intrínsecas próprias que permitem identificar, inequivocamente, a procedência do produto. O presente trabalho propôs estabelecer o perfil agrometalômico da carne bovina oriunda de importantes regiões e biomas do Brasil, assim como de alguns dos principais países produtores, para obter modelos baseados em algoritmos de aprendizado de máquina (ML) atuando como instrumento de garantia da autenticidade. Parâmetros como corte, sexo, grupo genético e dieta que podem influenciar o perfil agrometalômico da carne bovina e, conseqüentemente, interferir nos modelos de classificação foram investigados.

2 REVISÃO

2.1 Características naturais do Brasil

O Brasil possui extensão territorial de 8.5 milhões de km², dos quais o bioma Amazônia ocupa 49 %, contemplando a maior floresta tropical do mundo, equivalente a 1/3 das reservas de florestas tropicais úmidas. Este bioma tem concentrado o maior crescimento da atividade bovina nos últimos 20 anos [3, 35]. O bioma Caatinga ocupa uma área aproximada de 10 % do território nacional, caracterizado por regimes intermitentes de chuva e secas prolongadas, o que encarece a produção bovina, obrigando produtores a plantar forrageiras mais produtivas e armazenar para o período de seca. O bioma Cerrado abrange aproximadamente 24 % do território brasileiro e ocorre, principalmente, na região central do país, onde se concentra a maior produção de gado bovino (34 % da produção nacional). O clima é predominantemente seco, sendo identificados dentro do mesmo bioma as fisionomias: campo sujo, campo limpo, stricto sensu, lato sensu e cerradão [36, 37]. A Mata Atlântica ocupando aproximadamente 13 % do território brasileiro localizado no litoral, é um dos biomas mais modificados pela ação humana, restando só 27 % da floresta de cobertura original. O Pampa representa uma área aproximada de 2 % do território nacional. A atividade humana propiciou uniformização da cobertura vegetal majoritariamente usada como pastagem natural ou ocupada com atividades agrícolas, principalmente o cultivo de arroz. O Pantanal, que ocupa 2 % do território brasileiro, é o bioma mais conservado mantendo 87 % da cobertura original. É reconhecido como a maior planície de inundação contínua do Planeta Terra, o que constitui o principal fator para a sua formação e diferenciação em relação aos demais biomas. Nesse bioma, a criação de gado de corte existe há quase 300 anos, consistindo na principal atividade econômica da região [38, 39].

2.2 Cadeia produtiva da carne bovina no Brasil

Em 1980, o Brasil era um país importador de proteína animal, cuja produção de carne bovina era de cinco mil toneladas, suficiente para abastecer a cidade de São Paulo durante uma semana. Contudo, em 30 anos, passou a não só garantir carne bovina para o consumo nacional como a ser um dos maiores exportadores do mundo [3, 8, 19, 40, 41], destacando-se como potência do agronegócio mundial, especialmente quando se considera o baixo custo de produção no país [41, 42]. A principal característica da pecuária brasileira é a prática extensiva, ou seja, em pastagem, seja ela nativa ou plantada. Isso torna o sistema menos oneroso, sendo pouco dependente da disponibilidade dos grãos que compõem as rações animais ou da variação de preços. Não obstante, a taxa de suporte (número máximo de animais por hectare para um

determinado nível de desempenho num período de tempo, sem causar a deterioração do ecossistema) nas pastagens, de 1,2 UA/ha, é considerada baixa em relação à média de outros países em que a pecuária é praticada de forma intensiva [3, 43].

A Figura 1a mostra a distribuição dos diferentes biomas no Brasil [44], a Figura 1b mostra a distribuição do gado bovino brasileiro no ano de 2020 e a Figura 1c mostra a expansão da pecuária entre os anos de 1975 e 2015 no território brasileiro, concentrando-se especialmente nas regiões centro-oeste e norte do país, mas avançando sobre áreas de domínio de todos os biomas brasileiros ao longo do período [35]. Os diferentes biomas brasileiros têm características particulares de solos, umidade, regime de chuvas e composições florísticas, incluindo, espécies arbóreas e gramíneas [28, 38, 39, 45].

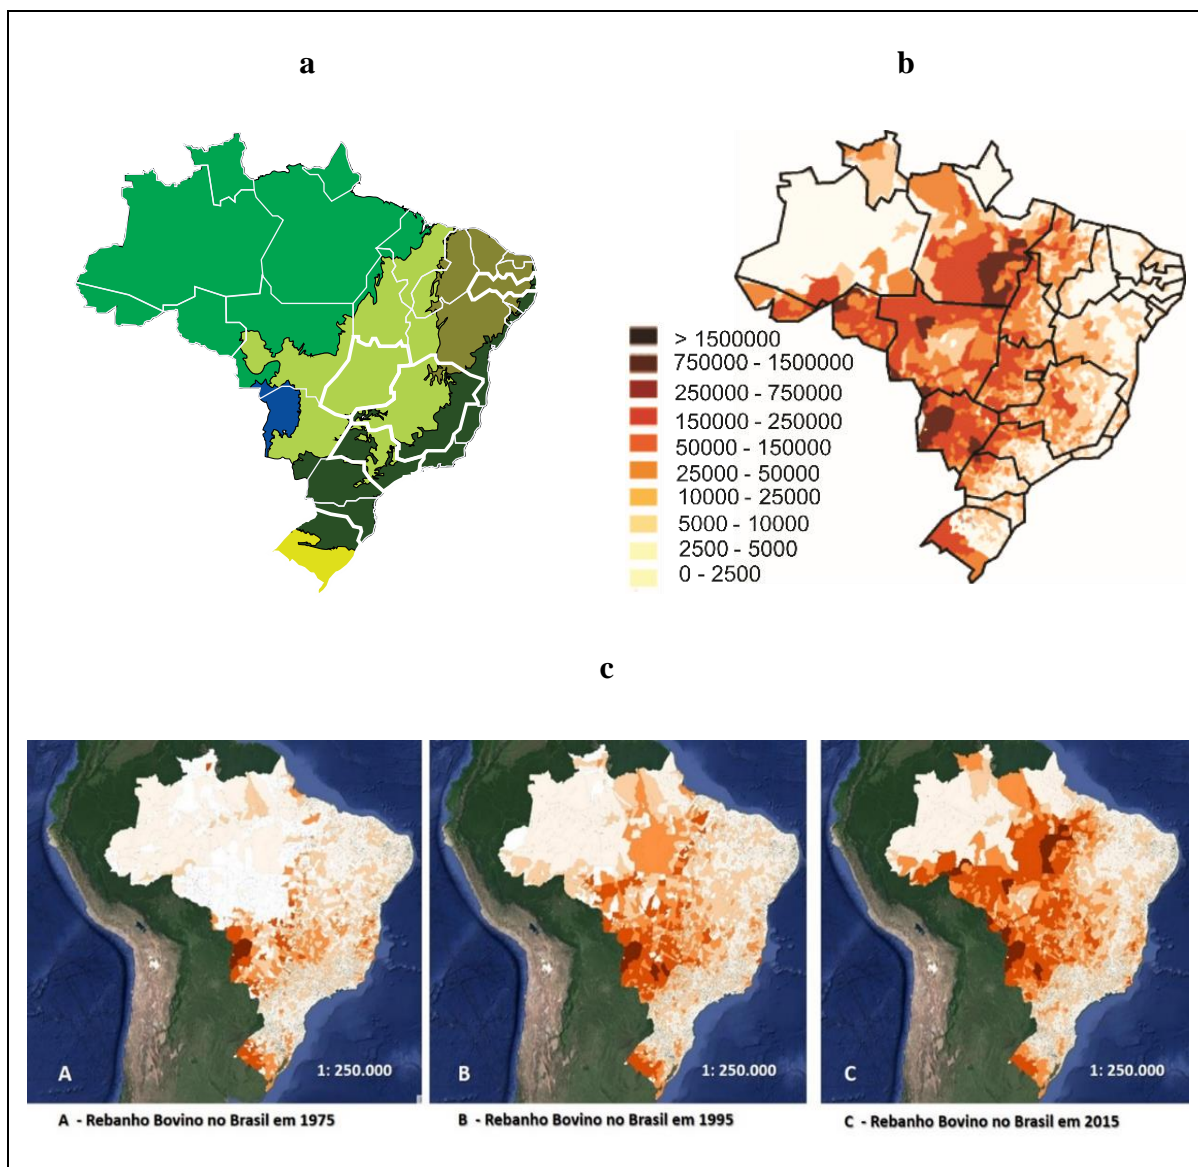


Figura 1. Mapa da distribuição dos biomas no Brasil (a), distribuição do rebanho bovino no ano 2020 (b) e evolução do rebanho bovino no Brasil entre os anos 1975 e 2015 (c)

A implementação de tecnologias na pecuária de corte tem melhorado a sustentabilidade da criação bovina no Brasil. Segundo ABIEC [3, 8], 19 % das áreas do país são destinadas a pastagens em condições de uso e 1 % corresponde a pastagens em estágio avançado de degradação. A Figura 2 mostra a evolução da área utilizada para pastagem com a produtividade [3, 8, 46]. A produção bovina cresceu ocupando menos área, diminuindo, assim, o custo ambiental desta atividade. A modificação no status produtor da pecuária bovina deve-se, em parte, ao estabelecimento de uma cadeia de carne sustentável no Brasil, utilizando genética superior, melhor manejo das pastagens, regras de nutrição e sanidade mais avançadas, tecnologias de campo e desenvolvimento de regras de bem-estar animal, que provocaram mudança progressiva na qualidade dos produtos e na forma de produção [7, 26, 47, 48].




Figura 2. Evolução da área de pastagem e da produtividade

A produção brasileira de carne bovina tem baixo custo, estimado em 60 % menor que na Austrália e 50 % menor que nos Estados Unidos. A idade média de abate é de 4 anos e a taxa de abate gira em torno de 21 %, contra 2 anos e 37 % nos Estados Unidos, o que significa que a indústria brasileira de carne bovina é menos eficiente [42].

Um trabalho da Embrapa de 2020 [48] mostrou a heterogeneidade do nível de desenvolvimento da criação de gado bovino no Brasil. Foram estudados 124 mil

estabelecimentos nos biomas Amazônia, Caatinga, Cerrado, Mata Atlântica, Pampa e Pantanal, abrangendo mais de 94 milhões de cabeças de gado distribuídas em aproximadamente 86 milhões de hectares de pastagens. Para estabelecer os níveis de desenvolvimento tecnológico das fazendas de criação de gado bovino nos diferentes biomas foram escolhidos parâmetros como:

- Atividade principal desenvolvida (percentual de fazendas com cria, percentual de fazendas com recria, percentual de fazendas com terminação, percentual de vacas relativo ao rebanho total e percentual de novilhos no rebanho).
- Nível tecnológico e intensificação (taxa de lotação (UA/ha), percentual de fazendas que utilizam fornecimento de ração, percentual de fazendas que utilizam adubação de pastagens, percentual de vacas inseminadas, percentual de bovinos em confinamento, percentual de fazendas que possuem animais rastreados e percentual de fazendas que utilizam serviços de consultoria).
- Uso e diversificação da terra (porcentagem de área de pastagem / área utilizada, porcentagem de área de pastagens naturais / área total de pastagens, porcentagem de área de pastagens semeadas degradadas / área total de pastagens, porcentagem de forragens para corte / área total de pastagens, percentual da área total de cultivos / área utilizada, percentual do total de cultivos permanentes / área total de cultivos, percentual de cultivos temporários / área total de cultivos, percentual de área de florestas plantadas / área total utilizada).
- Importância econômica da produção de carne bovina (porcentagem do valor bruto do produto proveniente da carne bovina).
- Tamanho da empresa (total de bovinos de corte por fazenda – UA / fazenda)

Foi observado que no bioma Amazônia, com maior crescimento do rebanho bovino nos últimos anos e participação importante nas exportações de carne bovina [3] o nível de desenvolvimento tecnológico para essa atividade é predominantemente baixo, com maior concentração das fazendas de criação na região sul (Figura 3) [48]. O Apêndice B mostra dados sobre número de cabeças de gado e nível de desenvolvimento técnico em diferentes biomas [3, 48].

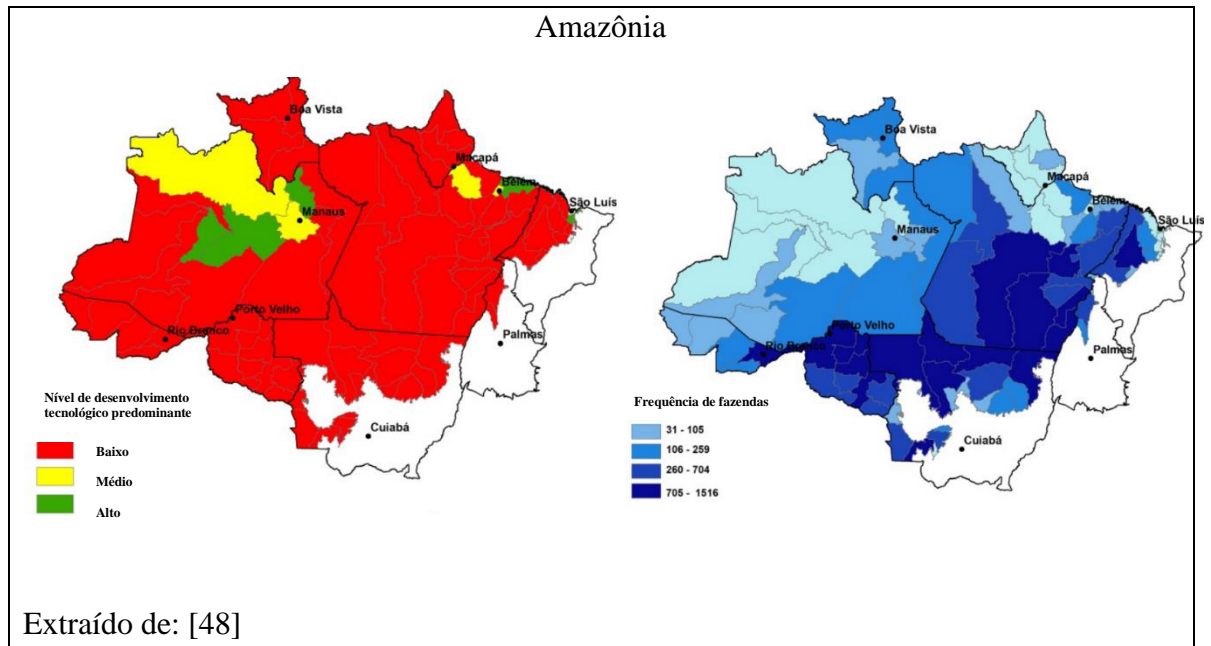


Figura 3. Nível de desenvolvimento tecnológico e concentração de fazendas no bioma Amazônia

No Brasil, a alimentação bovina é quase exclusivamente de grama e capim, passando os animais de 2 a 6 meses confinados para terminação, permitindo o ganho da gordura desejada. A terminação permite também que os animais se acostumem ao confinamento e permaneçam calmos até o abate, propiciando maior qualidade à carne [49]. Esta alimentação, baseada em pasto e produtos de origem vegetal, confere à carne brasileira um aspecto de produto orgânico, macia e com menor conteúdo de gordura, o que atrai a preferência dos consumidores europeus e do Oriente Médio. Este modo de criação tornou a carcaça bovina brasileira seja das mais leves do mundo, com peso médio de 248 kg [3, 42].

Há uma crescente demanda por carne de animais que se alimentam somente de insumos naturais, sendo o modo de criação implementado hoje no Brasil uma alternativa sustentável e competitiva. Assim, pecuaristas de todo o país estão estabelecendo selos que atestem a qualidade da carne produzida nos respectivos territórios. Em 2016, o estado de Mato Grosso lançou o selo “Carne de Mato Grosso” para atestar a qualidade da carne produzida na região. Nesse mesmo ano, a Korin lançou uma linha de carne bovina sustentável e uma de carne orgânica, atestando a carne produzida no Pantanal sul-mato-grossense [50], enquanto a Embrapa lançou a “Marca-Conceito Carne Carbono Neutro”, que visa atestar a carne produzida nos biomas Amazônia, Cerrado, Mata Atlântica, Caatinga, Pampa e Pantanal, utilizando uma integração sustentável de tipo silvipastoril, ou seja, pecuária-floresta [51]. A Associação Brasileira de Produtores Orgânicos (ABPO), através do Programa Pantanal Sustentável, certifica a carne de animais cuja alimentação básica e fundamental deve advir de

pastagem desse bioma [52]. Selos como “Rebanho Xingu” e “Alianza del Pastizal” atestam a qualidade da carne bovina produzida nos biomas Amazônia e Pampa, respectivamente. O selo “Brasil Agro: Food for Nature”, cuja criação foi anunciada pelo ministro da agricultura no Global Agribusiness Forum (GAF) em julho de 2018, tem como objetivo ser uma certificação sustentável para os produtos agrícolas brasileiros comercializados no exterior, cuja implementação permitirá ao consumidor saber mais informações sobre a origem e a rastreabilidade da mercadoria [53].

Os processos de rastreabilidade e certificação de carne bovina já estabelecidos no Brasil empregam técnicas de rastreamento físico tradicionais baseadas no uso de brincos e chips. Além disso, são avaliadas as características físico-químicas da carne [54-57], os teores de lipídeos [55, 58-60], a capacidade de retenção de água, cor, sabor e maciez [61, 62], o tipo de ração que alimentou o gado provedor dessa carne, o frigorífico onde ocorreu o abate ou corte e os procedimentos de embalagem, transporte e manejo na revenda [13, 14, 40]. Contudo, não há, por exemplo, um protocolo de identificação da composição multielementar das carnes, que permita estabelecer a assinatura química característica da região de origem do gado, inferindo-se informações sobre as doenças às quais esse rebanho estaria mais suscetível ou protegido, o que comeu, por onde foi, tipo de pastagem, água, ração e insumos utilizados na criação. Este tipo de rastreamento é fundamental para melhorar um aspecto decisivo na produção sustentável, ou seja, a garantia de origem.

Estas deficiências foram expostas e convertidas negativamente para a imagem e mercado externo da pecuária bovina brasileira, quando em 17 de março de 2017, a operação da Polícia Federal batizada como “Carne Fraca” trouxe ao conhecimento público os processos não idôneos de fiscalização do Ministério de Agricultura, Pecuária e Abastecimento (MAPA), inspeção irregular dos procedimentos de abate de bovinos nos frigoríficos e também nos demais processos produtivos da carne comercializada no país. Um importante veículo de imprensa do setor no Brasil, a revista Dinheiro Rural, publicou uma edição tratando da operação supracitada da Polícia Federal. Como consequência, dos quase 150 destinos para onde são enviadas as carnes brasileiras, países importantes como China, Chile, Catar e União Europeia manifestaram restrições ao produto brasileiro. As contas do setor baixaram abruptamente, a exportação que era de quase US\$ 63 milhões por semana passou a ser de US\$ 74 mil, gerando perdas ao redor US\$ 130 milhões para a agroindústria e quase R\$ 7 bilhões em valor de mercado para os frigoríficos investigados [26, 27]. A Figura 4 mostra as exportações e respectivo faturamento gerado nos últimos 25 anos [3, 8, 35, 46, 63].




Figura 4. Evolução das exportações de carne bovina brasileira

Apesar dos esforços do Governo Federal para controlar a situação, o reposicionamento da pecuária brasileira como líder no mercado exterior e a reconquista da credibilidade nos próximos anos exigirão total transparência e idoneidade dos processos de produção de carne no país. Para reverter o estrago, que na opinião de especialistas pode render perdas de US\$ 1,5 bilhão por ano, o Brasil tem que demonstrar, mais que nunca, para o mundo que a carne produzida é de qualidade, implementando e aprimorando metodologias de controle, rastreamento e fiscalização, empregando-se nestes processos tecnologias avançadas.

Nesse contexto, a iniciativa Transparency for Sustainable Economies (Trase) [64-66] tem mostrado resultados promissores para o rastreamento das exportações de carne bovina brasileira, permitindo identificar os municípios onde o gado é criado, as empresas responsáveis pelo abate e exportação, bem como os mercados internacionais aos quais são destinados esses produtos (Figura 5). Embora a iniciativa forneça resultados que possibilitem uma visão sem precedentes do comércio global de carne bovina com potencial para melhorar a transparência da cadeia de suprimentos, a base de dados atualmente disponíveis contém

informações até o ano de 2017. Esses dados são baseados em dados logísticos autodeclarados disponíveis publicamente e em dados oficiais de comércio global. Contudo, apesar de complexas análises e bancos de dados envolvidos no sistema TRASE, aproximadamente 10 % da carne bovina brasileira exportada não possuía identificação do bioma de origem.

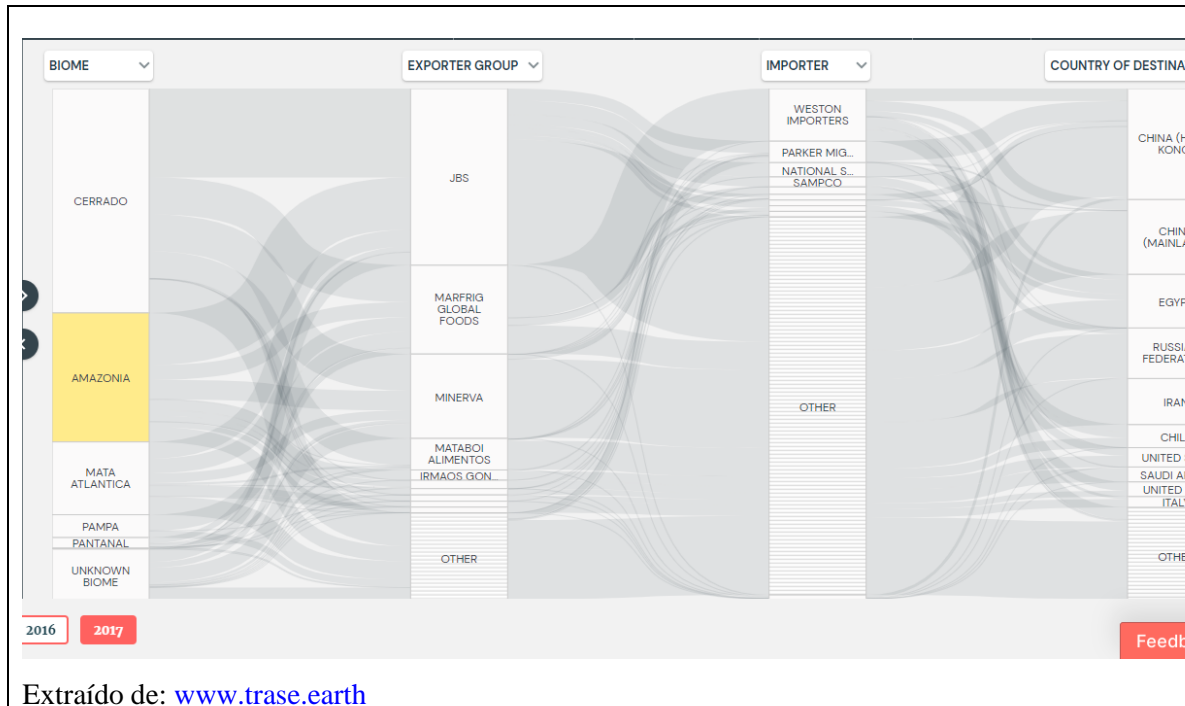


Figura 5. Rastreabilidade da cadeia produtiva de carne bovina brasileira empregando o sistema Trase

2.4 Análise de carne

A composição química da carne bovina representada por fatores como cinzas, proteína bruta, composição mineral, umidade, colesterol total e lipídios totais varia muito em função da idade, origem geográfica, sexo, genética e nutrição [67-70]. Técnicas analíticas diferentes, como ensaio de imunoabsorção enzimática, cromatografia gasosa-espectrometria de massas, cromatografia líquida de alta eficiência hifenada a espectrometria de massas, tem sido empregadas para discriminação da carne com base no sexo do animal, corte de carne, tipo de alimentação, raça, sistema de criação, origem geográfica, entre outras [71-73]. Análise multielementar e técnicas estatísticas como análise de variância (ANOVA), análise discriminante canônica (CDA), teste de comparação múltipla de Duncan, análise discriminante linear (LDA), análise de componentes principais (PCA) e teste de Tukey têm sido utilizados para avaliar a origem geográfica de carne [30, 73-77]. Estudos sobre a composição mineralógica de carnes têm sido relatados, empregando espectrometria de massas

com plasma indutivamente acoplado [77-79] e análise por ativação neutrônica instrumental [34]. Técnicas multielementares foram utilizadas para determinar origem geográfica da carne de carneiro [80] e de aves [81], bem como diferenciar sistemas de criação orgânico e convencional de carne de porco [82] e de frango [83]. Isótopos estáveis de carbono, nitrogênio, oxigênio, hidrogênio e enxofre permitiram a determinação da origem geográfica de carne bovina [30, 75, 77, 84].

Variações na composição química têm sido utilizadas como ferramenta para diferenciar a carne bovina, porém, a amostra é geralmente tratada como músculo bovino. Autores demonstram a possibilidade de diferenciar amostras de músculo bovino usando características químicas [85-87]. Considerando que, no Brasil, os três cortes primários de carne bovina são o dianteiro, o lateral e o traseiro, divididos em dez grandes seções denominadas cortes primários (lombo, peito, rocambole, torrão, pernil, lombo, costela e contrafilé), subdivididos em aproximadamente 77 cortes de varejo, com grande variação de nomes dependendo da região [88], é difícil escolher, após o abate, as características da carne que permitem uso da composição química do produto para melhorar a autenticidade.

2.3 Análise por ativação neutrônica

A análise por ativação neutrônica (NAA) é uma técnica analítica que foi descoberta por Hevesy e Levi em 1936. Apresenta alta sensibilidade e especificidade, correlacionando diretamente o sinal obtido com o elemento de interesse, e seletividade, permitindo medir o elemento desejado na presença de outros que emitem sinais da mesma natureza [89-91].

A técnica consiste na ativação nuclear dos elementos químicos presentes na amostra mediante irradiação com nêutrons térmicos (com energias inferiores a 0,5 eV que se encontram em equilíbrio térmico com átomos no moderador do reator) ou nêutrons rápidos (com energia cinética superior a 100 keV). Os nêutrons térmicos são os mais empregados em razão do grande fluxo produzido nos reatores nucleares e a alta seção de choque (definida como a probabilidade de acontecer uma reação nuclear) apresentada por muitos núclídeos estáveis [90]. A reação (n, γ) empregada na NAA acontece quando um nêutron interage com um elemento $({}^A_ZX)$ mediante uma colisão não elástica, formando um núcleo composto num estado altamente excitado $({}^{A+1}_ZX^*)$. O núcleo composto formado tem desexcitação geralmente instantânea a uma configuração mais estável através da emissão de um ou mais raios gama característicos (raios gama prontos). O produto desta desexcitação geralmente é um núcleo

radioativo que decai pela emissão de um ou mais raios gama característicos (raios gama retardados), mas com uma velocidade menor, de acordo com a meia-vida do radionuclídeo. A NAA pode se realizar medindo os raios gama prontos (prompt gamma rays, PGAA) durante a irradiação, ou medindo os raios gama retardados. O segundo modo de operação é o mais empregado, sendo que 70 % dos elementos têm núclídeos com propriedades apropriadas para serem determinados por NAA [92]. A PGAA é utilizada para determinação de elementos que decaem muito rapidamente, elementos que decaem para radioisótopos estáveis ou com intensidades fracas de decaimento de raios gama e elementos com elevada seção de choque para captura de nêutrons (B, Cd, Sm e Gd) [93, 94].

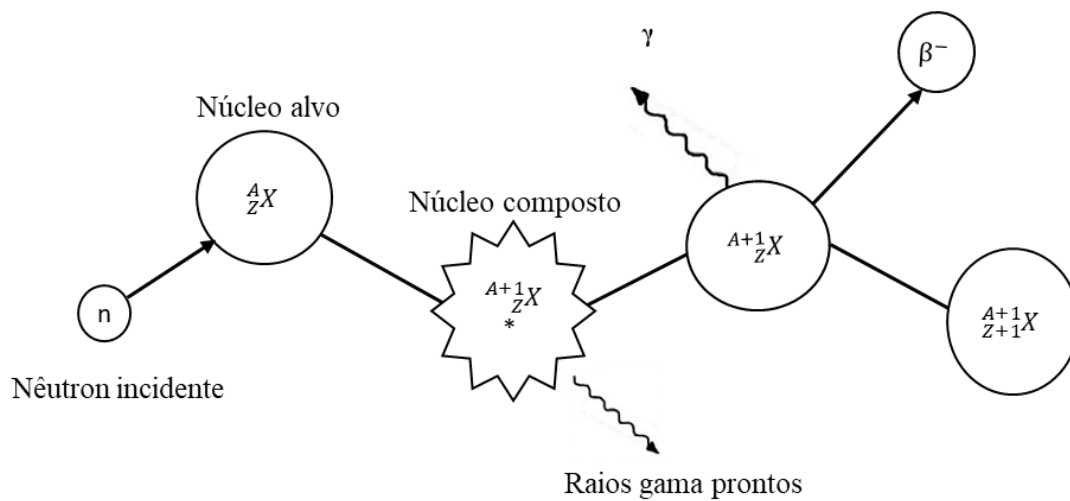



Figura 6. Reação (n , γ) empregada na NAA

Além da seção de choque, a abundância isotópica do nuclídeo a determinar e a vida-meia ($t_{1/2}$) do radioisótopo formado devem apresentar valores adequados para que a análise seja factível [89].



O rendimento da reação para formação do radioisótopo (${}^{A+1}_ZX$) do elemento a ser determinado (A_ZX) vai depender da seção de choque (σ) de A_ZX , do fluxo de nêutrons do reator nuclear (ϕ) e do número de átomos do nuclídeo alvo (N_1). Além disso, o nuclídeo ${}^{A+1}_ZX$, sendo radioativo, sofre decaimento. Este decaimento acontece numa taxa $\lambda_2 N_2$, sendo λ_2 a constante de decaimento do nuclídeo 2 ($\lambda_2 = \ln 2 / t_{1/2}$). Sendo assim, o crescimento de N_2 será dado pela Equação 1.

$$\frac{dN_2}{dt} = \sigma\phi N_1^0 - N_2\lambda_2 \quad (1)$$

A solução desta equação diferencial (equação de Leibnitz) é mostrada na Equação 2.

$$N_2(t_i) = \frac{\sigma\phi N_1^0}{\lambda_2} [1 - e^{-\lambda_2 t_i}] + N_2^0 e^{-\lambda_2 t_i} \quad (2)$$

Assumindo que no início da irradiação não havia átomos do nuclídeo N_2 , ou seja, quando $t_i = 0$ $N_2 = 0$, então o número de átomos N_2 formados após um tempo de irradiação t_i pode ser calculado tendo os valores de ϕ , λ_2 , σ e N_1^0 (Equação 3).

$$N_2(t_i) = \frac{\sigma\phi N_1^0}{\lambda_2} [1 - e^{-\lambda_2 t_2}] \quad (3)$$

Sabendo que a atividade medida experimentalmente (A) é proporcional a constante do decaimento radioativo (λ) e número de átomos (N) (Equação 4).

$$A = \lambda N \quad (4)$$

Então, a Equação 3 pode ser escrita como mostra a Equação 5:

$$A_2 = \sigma\phi N_2 [1 - e^{-\lambda_2 t_2}] \quad (5)$$

Sendo o interesse determinar a massa de cada elemento na amostra e não o número de átomos, empregando $N = \frac{N_{av} m I}{M}$, onde N_{av} o número de Avogadro ($6,02 \cdot 10^{23}$ atm/mol), M a massa molecular do elemento (g/mol), m a massa do composto (g) e I a abundância isotópica do nuclídeo, então a Equação 5 pode ser escrita como mostra a Equação 6:

$$A = \frac{I z \sigma \phi m N_{av}}{M} [1 - e^{-\lambda_2 t_2}] \quad (6)$$

Assumindo que sejam empregados os raios gama retardados, tem-se que considerar na equação o decaimento do radionuclídeo produto do tempo de esfriamento (tempo entre o fim da irradiação e a detecção, t') sendo que a equação para determinar de forma absoluta a quantidade (massa) do elemento de interesse presente na amostra seria conforme Equação 7:

$$A_2 = \frac{Iz\sigma\phi m_2 N_{av}}{M} \left[1 - e^{-\lambda_2 t_2} \right] e^{-\lambda_2 t'} \quad (7)$$

Empregando esta Equação é possível medir grande quantidade de elementos químicos sem a necessidade de separações radioquímicas. A Tabela 1 mostra elementos químicos que podem ser determinados por NAA e respectivos limites de detecção, considerando um fluxo de nêutrons de $1 \times 10^{13} \text{ n cm}^{-2} \text{ s}^{-1}$ e assumindo espectros livres de interferência [89, 91].

Tabela 1. Elementos químicos determinados por NAA e respectivos limites de detecção

Sensibilidade (picogramas)	Elementos
1	Dy, Eu
1 - 10	In, Lu, Mn
10 - 100	Au, Ho, Ir, Re, Sm, W
100 - 1000	Ag, Ar, As, Br, Cl, Co, Cs, Cu, Er, Ga, Hf, I, La, Sb, Sc, Se, Ta, Tb, Th, Tm, U, V, Yb
1000 - 10000	Al, Ba, Cd, Ce, Cr, Hg, Kr, Gd, Ge, Mo, Na, Nd, Ni, Os, Pd, Rb, Rh, Ru, Sr, Te, Zn, Zr
10000 - 100000	Bi, Ca, K, Mg, P, Pt, Si, Sn, Ti, Tl, Xe, Y
100000 - 1000000	F, Fe, Nb, Ne
1000000	Pb, S

Diferentes métodos de padronização têm sido desenvolvidos para quantificar a fração de massa de um elemento numa amostra. O método de análise absoluta é empregado para medir a fração de massa de um determinado elemento baseando-se nos parâmetros descritos na Equação 7. A exatidão das medições realizadas encontra-se limitada pela estabilidade dos parâmetros do reator e do sistema de detecção, podendo alcançar erro de até 30 %. Por outro lado, tem entre suas vantagens a possibilidade de quantificar praticamente qualquer elemento.

Outro método de padronização denominado análise por ativação comparativa é mais recomendado para determinação de elementos em baixos teores ($\mu\text{g/kg}$) [92]. Este método é, geralmente, considerado o mais exato para quantificar as frações de massa dos elementos e consiste na irradiação simultânea da amostra junto com padrões contendo quantidades conhecidas dos elementos a determinar. Após a irradiação, amostras e padrões são medidos no mesmo detector mantendo a mesma geometria. Desta forma, são evitadas incertezas nos parâmetros nucleares (fluxo de nêutrons) e do detector. A Equação 7 é simplificada a uma

relação de 3 (Equação 8), onde A_a é a atividade da amostra, A_p é a atividade do padrão, m_a é a massa da amostra, m_p é a massa do padrão, t_a é o tempo de esfriamento da amostra e t_p é o tempo de esfriamento do padrão [89].

$$m_a = \frac{A_a m_p}{A_p} e^{-\lambda(t_a - t_p)} \quad (8)$$

A principal desvantagem da análise comparativa é que requer a preparação de um grande número de padrões elementares.

Outro método de padronização surgiu como alternativa dos métodos absoluto e comparativo, o método k_0 , desenvolvido no Institute for Nuclear Sciences, em Gent, na Bélgica em 1975 [95]. De forma geral, o método k_0 consiste em parametrizar as variáveis nucleares que aparecem na expressão do método absoluto em uma única grandeza que, por sua vez, pode ser determinada com relativa facilidade. As variáveis nucleares são determinadas pela irradiação de monitores de fluxo e a fração de massa dos elementos é calculada em relação a um elemento, geralmente ouro, permitindo obter as frações de massa de vários elementos químicos empregando um único monitor, sem a necessidade do preparo de padrões individuais para cada elemento químico. A constante k_0 de um isótopo com referência ao padrão de ouro pode ser determinada conforme Equação 9 [95-98]:

$$k_{0,Au}(a) = \frac{M_{Au} * I_a * I_{\gamma a} * \sigma_a}{M_a * I_{Au} * I_{\gamma Au} * \sigma_{Au}} \quad (9)$$

Os valores de constante k_0 para a maioria dos elementos que podem ser determinados por NAA têm sido determinados experimentalmente e encontram-se disponíveis na literatura, dada sua grande utilidade [96, 97]. Além das constantes k_0 , para implementar a metodologia é necessária a caracterização das instalações de detecção e irradiação, razão entre os fluxos de nêutrons térmico e epitérmico e do parâmetro α relacionado com a distribuição de fluxo de nêutrons epitérmicos $1/E^{1+\alpha}$ [93, 99].

2.4 Inteligência artificial na agricultura

A Inteligência Artificial (IA), com as subáreas Machine Learning e Deep Learning, está revolucionando o agronegócio mundial, dada a capacidade de organizar grandes séries de dados e obter informações identificando padrões que passam despercebidos aos olhos humanos.

Diferentes governos têm implementado políticas públicas de desenvolvimento e de planejamento estratégico para avançar na implementação de tecnologias de IA. A China anunciou um plano nacional com investimento de US\$ 59 bilhões, pretendendo se tornar líder no setor até 2025. Na Europa Ocidental, o investimento em IA cresceu mais de 40 % em relação a 2017, enquanto na União Europeia €20 bilhões serão aplicados até 2025. No Brasil, o investimento reduzido tem causado significativo atraso [100]. Enquanto aqui ainda estão sendo testadas, outros países já estão com investimento maciço em empresas estruturadas de inteligência artificial.

O aprendizado de máquina é um método da matemática, ciência da computação e estatística que evoluiu a partir do estudo do reconhecimento de padrões e da teoria da aprendizagem computacional em inteligência artificial. A mineração de dados tem como objetivo descobrir informações (padrões) ocultas em grandes conjuntos de dados para fazer previsões precisas. Técnicas de mineração de dados têm sido utilizadas em estudos agrônômicos que influenciam a produção agrícola [101-104]. “Alice”, uma assistente virtual baseada na identificação de padrões a partir de redes neurais e deep learning, já está disponível para auxiliar o agricultor em tarefas de planejamento e análise para alcançar melhor desempenho na produção.

O Brasil, como plataforma do agronegócio mundial, apresenta potencial para implementação e desenvolvimento de técnicas de inteligência artificial aplicadas à agricultura, que resultem em melhorias na produção e assegurem a rastreabilidade dos alimentos. Os avanços no campo da pecuária e zootecnia de precisão geram acúmulo de grandes volumes de informação, que não têm sido explorados na máxima capacidade, sendo recomendado o uso de técnicas de mineração de dados que permitem otimizar a tomada de decisões [104, 105]. Nesse sentido, existem hoje no Brasil mais de 23 startups utilizando inteligência artificial na agricultura [106]. Entre as aplicações encontram-se o uso de satélite e aprendizado de máquina para monitorar a intensificação sustentável da agricultura [103, 107].

Avanços no controle da qualidade de alimentos utilizando técnicas quimiométricas têm sido foco de estudo de diversos autores nos últimos anos [108-112]. Algoritmos de classificação que implementam a aprendizagem supervisionada, como Random Forest, Sequential Minimal Optimization, Naïve Bayes, Multilayer Perceptron e Classification and Regression Tree, foram utilizados em estudos de autenticação de café orgânico [113], origem geográfica do café [114], diferenciação de cana-de-açúcar e sucos de produção orgânica ou convencional [115, 116],

origem geográfica de cerveja [117], arroz [118, 119], méis [120, 121], vinho [112], origem entomológica de méis [122], assim como para classificar os atributos da carne bovina com base em parâmetros de qualidade definidos pelo Departamento de Agricultura dos Estados Unidos (USDA), histórico de produção, tipo de raça e sensibilidade muscular [123]. Uma das principais observações nestes trabalhos é que os algoritmos de classificação permitem obter boa acurácia na discriminação entre as classes utilizando apenas um ou dois elementos químicos.

Naïve Bayes (NB) é um meio formal de análise de estratégias de decisão baseado no teorema de Bayes. Este teorema descreve a probabilidade de um evento, referindo-se ao conhecimento *a priori* (probabilidade prévia, calculada usando o conjunto de treinamento dividido pelo número total de instâncias no Naïve Bayes) que pode estar relacionado com o evento e mostra como alterar probabilidades *a priori* em vista de novas evidências para obter probabilidade *a posteriori*. A classificação é feita usando as probabilidades conhecidas de cada classe e as probabilidades conhecidas de cada atributo (variável de resposta). Sejam {C1, C2 e C3} as três classes (Ex. acém, contrafilé e picanha), que possuem probabilidades P(C1), P(C2) e P(C3), respectivamente, e as variáveis de resposta X1, X2, X3...Xn, que possuem valores k1, k2,..., kn, respectivamente, a probabilidade subsequente da classe Ci ocorrer para o exemplo especificado é dada por:

$$P(C_i) \times P(X_1 = k_1 \text{ and } X_2 = k_2 \dots \text{ and } X_n = k_n | C_i) \quad (10)$$

Como o modelo Naïve Bayes assume independência entre atributos, o valor desta expressão pode ser obtido através da expressão [114, 124]:

$$P(C_i) \times P(X_1 = k_1 | C_i) \times P(X_2 = k_2 | C_i) \times \dots \times P(X_n = k_n | C_i) \quad (11)$$

Sequential Minimal Optimization (SMO) implementa o algoritmo de Support Vector Machine (SVM). O objetivo do SVM é encontrar um hiperplano que desempenhe um papel como fronteira de decisão. A maior distância entre aquelas linhas paralelas que tocam os limites das classes é definida como o hiperplano da margem máxima. A Figura 7 mostra um exemplo de conjunto de dados linearmente separáveis e o conjunto de hiperplanos capazes de classificar corretamente entre as classes.




Figura 7. Conjunto de dados representados por círculos pretos e triângulos vermelhos e 5 hiperplanos para separação

Ao trabalhar com dados não linearmente separáveis, o SVM projeta os dados de seu espaço original para uma nova coordenada espacial, onde os dados são linearmente separáveis (Figura 8). Esse processo é feito aplicando uma função de transformação aos atributos do conjunto de dados. Uma alternativa para essa transformação é o uso de funções do núcleo, as chamadas funções kernel [116, 125, 126]. Este critério é usado para encontrar o hiperplano que fornece a separação mais robusta, obtendo a maior discriminação possível entre as classes. Um modelo de otimização quadrática é usado para encontrar um hiperplano. O principal parâmetro a ser ajustado pelo algoritmo no classificador SVM refere-se ao tipo de funções do kernel utilizadas. Embora o SMO seja uma das técnicas mais rápidas para aprender SVM, geralmente, é lento para convergir para uma solução, principalmente com dados ruidosos [127].

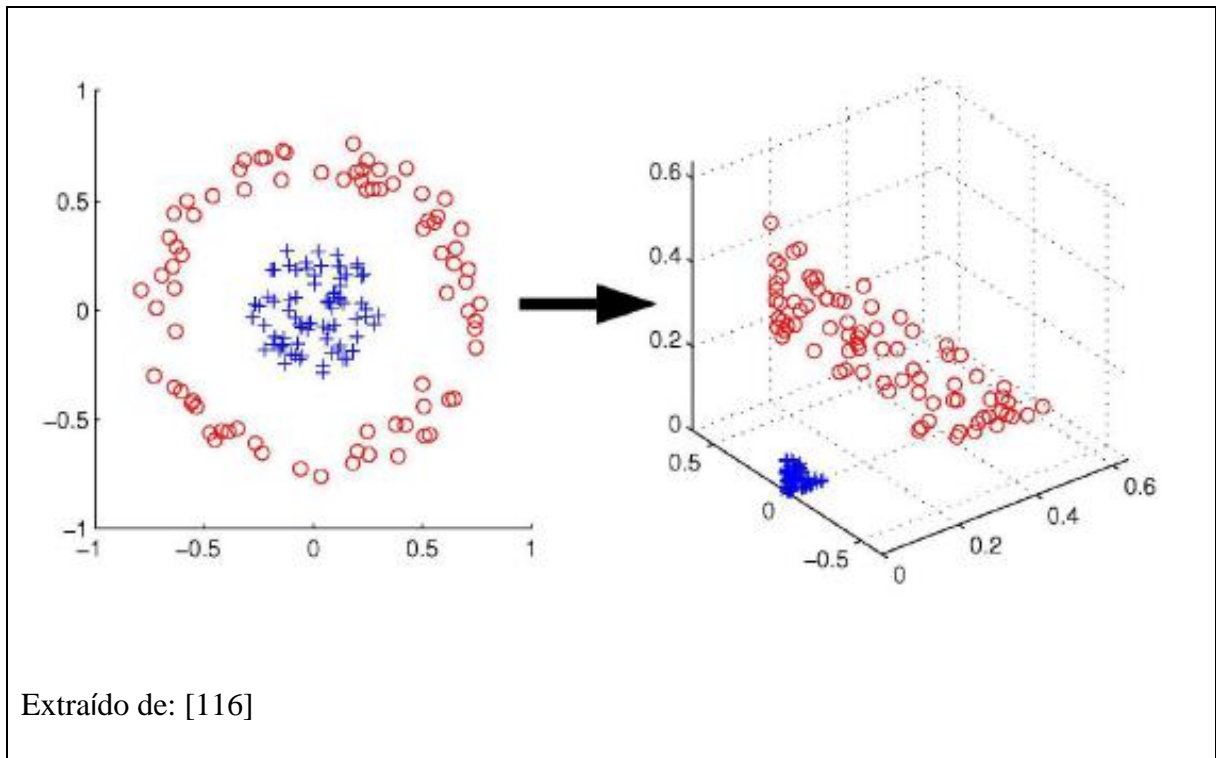


Figura 8. Transformação de um conjunto de dados bidimensional contendo duas classes (círculos e sinal de mais) não linearmente separáveis para um conjunto bidimensional linearmente separável

Artificial Neural Network é um modelo de classificação baseado na interconexão de nós, também chamados perceptrons. Eles foram inspirados no sistema cognitivo e nas funções neurológicas do cérebro humano, simulando o sistema de transmissão de impulsos nervosos por neurônios e seus ligamentos [128]. Um perceptron tem três elementos básicos, ou seja, conexões de entrada, combinador linear e função de ativação. As conexões de entrada são ponderadas por um peso sináptico. Cada nó X_i (composto por uma variável) é multiplicado pelo peso sináptico W_i (calculado pelo algoritmo) e, posteriormente, é conectado ao neurônio. A entrada tem um valor fixo diferente de zero. O combinador linear é responsável pela soma dos valores de entrada ($X_1*W_1 + X_2*W_2 + \dots + X_i*W_i$), gerando o potencial de ativação U . A função de ativação avalia o potencial de ativação U e através de uma função $f(u)$ calcula o sinal de saída do neurônio para identificar as classes.

O *Multilayer Perceptron* (MLP) é uma rede neural semelhante ao perceptron simples, mas esconde camadas entre as camadas de entrada e saída. Ele trabalha com a retropropagação de erros. Os erros de previsão obtidos durante a análise do conjunto de treinamento são propagados da camada de saída para as camadas anteriores. Este valor de erro é usado para ajustar os valores de peso em cada borda [129], podendo ser dividido o algoritmo de treinamento em diferentes etapas [116].

A Figura 9 mostra uma rede neural obtida para classificação da origem geográfica de café Arábica utilizando 11 atributos de entrada (*Acidity, Aftertaste, Aroma, Balance, Body, Cup Cleanliness (Clear Cup), Cupper Points, Flavor, Moisture, Sweetness e Total Cup Points*) de 15 países [114].

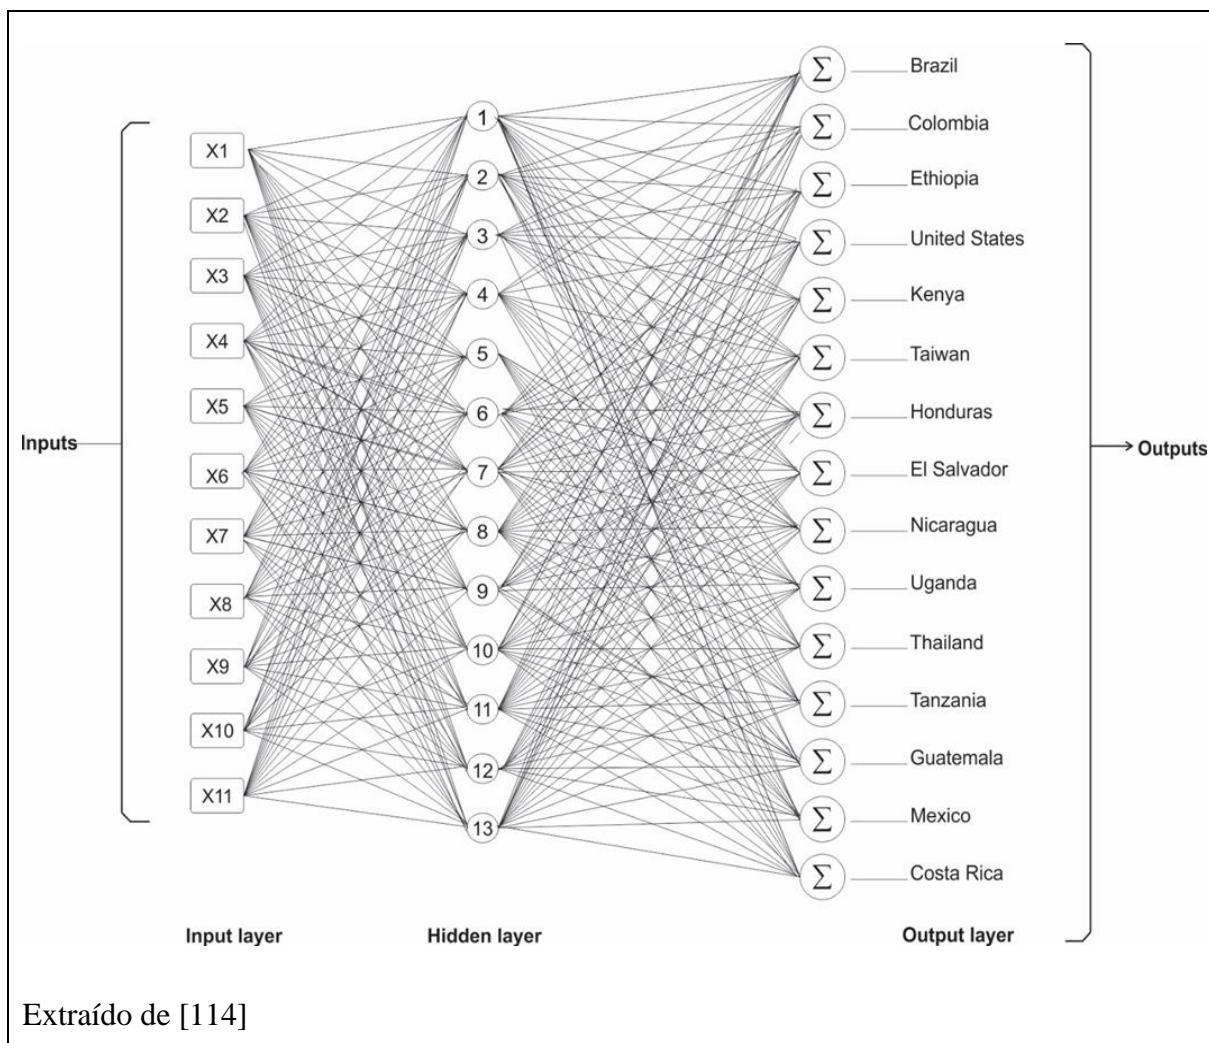


Figura 9. Exemplo de um Multilayer Perceptron obtido para discriminação da origem geográfica de café Arábica de 15 países utilizando 11 parâmetros de qualidade

Classification and Regression Tree (CART) refere-se a algoritmos de Árvore de Decisão (DT) que podem ser usados para classificação ou modelagem preditiva de regressão. Cada atributo do conjunto de dados de treinamento é analisado individualmente para construir regras de classificação [130]. A DT expressa as regras de classificação em uma estrutura em árvore. Cada nó da árvore corresponde a um atributo (Ex. elemento químico) e cada aresta que sai de um nó representa um valor ou intervalo de possíveis valores do atributo (Ex. fração de massa). A classificação de um exemplo desconhecido ocorre verificando os valores de suas frações de massa, começando pelo nó raiz e seguindo a aresta que representa o valor obtido. Esse processo iterativo gerará um caminho na árvore de decisão até que o rótulo da classe associada seja identificado com o rótulo da classe de treinamento. O algoritmo CART fornece uma base para algoritmos importantes, como árvores de decisão ensacadas, floresta aleatória e árvores de decisão impulsionadas.

A Figura 10 mostra um exemplo obtido para discriminação da origem entomológica de dois méis brasileiros, de abelhas *Apis* e *Jataí* com base na fração de massa de prata [122], gerada no Software WEKA (Waikato Environment for Knowledge Analysis) Version 3.8.5. Pode se observar como o nó representa a variável (elemento químico) utilizado como base para gerar a árvore de decisão, as arestas representam a decisão baseada no valor das frações de massa.




Figura 10. Estrutura gerada pelo modelo CART para discriminação da origem entomológica de dois méis brasileiros com base na fração de massa de prata

Para fração de massa de $Ag < 0,55$, as amostras serão classificadas com o rótulo de classe *Jataí*, e para fração de massa de prata $\geq 0,55$ serão classificadas com o rótulo de classe *Apis*. Os valores presentes entre () são o número de amostras utilizadas para treinamento e entre [] para teste do modelo obtido.

Random Forest (RF) adiciona uma camada adicional de aleatoriedade ao ensacamento e constrói várias árvores de decisão usando amostras de bootstrap dos dados de treinamento

originais. Este tipo de reamostragem altera a forma como a árvore é construída. Em uma floresta aleatória, cada nó é dividido usando o melhor entre um subconjunto de preditores (elementos químicos) escolhidos aleatoriamente naquele nó. Atinge altos níveis de precisão, geralmente muito superiores aos obtidos com uma única árvore de decisão [131]. O RF possui apenas dois parâmetros, o número de variáveis no subconjunto aleatório em cada nó e o número de árvores na floresta [132]. O conjunto de árvores é utilizado para classificação de um exemplo baseado na sua classificação mais frequente, sendo considerada cada árvore como um classificador individual.

A implementação de algoritmos de inteligência artificial para o processamento do perfil agrometalômico obtido por meio de técnicas isotópicas propiciaria à cadeia de produção bovina do Brasil contar com um modelo matemático, baseado em características intrínsecas da carne que permitam autenticar sua origem.

3 METODOLOGIA

3.1 Amostragem

A amostragem foi dividida em duas etapas, na primeira foram amostrados animais procedentes de diferentes biomas brasileiros. Na sequência, foram amostrados animais e os respectivos insumos utilizados na alimentação, procedentes de um produtor com sistema verticalmente integrado de produção que confere total rastreabilidade do processo produtivo. Esta etapa permitiu estabelecer bases sólidas técnico-científicas sobre a importância da escolha dos cortes de carne bovina que melhor refletem a assimilação dos elementos químicos provenientes da alimentação característica do modelo de criação e determinar a influência do sexo e cruzamento do animal na composição mineralógica da carne.

3.1.1 Amostragem de carne bovina de diferentes países

Foram selecionadas amostras de picanha bovina de cinco dos dez países que mais exportaram carne bovina em 2020 [1]: Brasil (1º; 2.539.000 toneladas; 23,50 % do mundo); Austrália (2º; 1.476.000 toneladas métricas; 13,66 % do mundo); Argentina (5º; 819 toneladas; 7,58 % do mundo); Uruguai (8º; 412 toneladas; 3,81 % do mundo) e Paraguai (9º; 371 toneladas; 3,41 % do mundo). No total, foram coletadas 62 amostras procedentes da Argentina, 51 amostras procedentes da Austrália, 175 amostras procedentes do Brasil, 56 amostras procedentes do Paraguai e 56 amostras procedentes do Uruguai. A maioria dos cortes bovinos foi obtida em casas de carnes e os cortes bovinos brasileiros foram retirados diretamente no frigorífico. As amostras de carne bovina brasileira foram coletadas dos biomas Amazônia (Pará, n = 25), Caatinga (Pernambuco, n = 25), Cerrado (Minas Gerais, n = 25, Goiás, n = 25 e São Paulo, n = 25), Pampa (Rio Grande do Sul, n = 25) e Pantanal (Mato Grosso do Sul, n = 25). A Tabela 2 mostra a origem das amostras coletadas.

Tabela 2. Origem das amostras de carne bovina

Origem	
Argentina	Arrebeef, Buenos Aires
Austrália	AMH, Queensland
Paraguai	FrigoChorti, Pozo Grande
Uruguai	SIRSIL, Montevideo
Brasil-GO (Bioma Cerrado)	Friboi, Mozarlândia
Brasil-SP (Bioma Cerrado)	Angelelli, Piracicaba
Brasil-MS (Bioma Pantanal)	Frigorífico Pantanal, Ladário
Brasil-PA (Bioma Amazônia)	Bertin S/A, Marabá
Brasil-MG (Bioma Cerrado)	Mataboi, Araguari
Brasil-RS (Bioma Pampa)	Mercosul Ltda, Alegrete
Brasil-PE (Bioma Caatinga)	Masterboi, Recife

A Figura 11 mostra os locais de onde procederam as amostras coletadas no Brasil e os biomas a que pertencem.

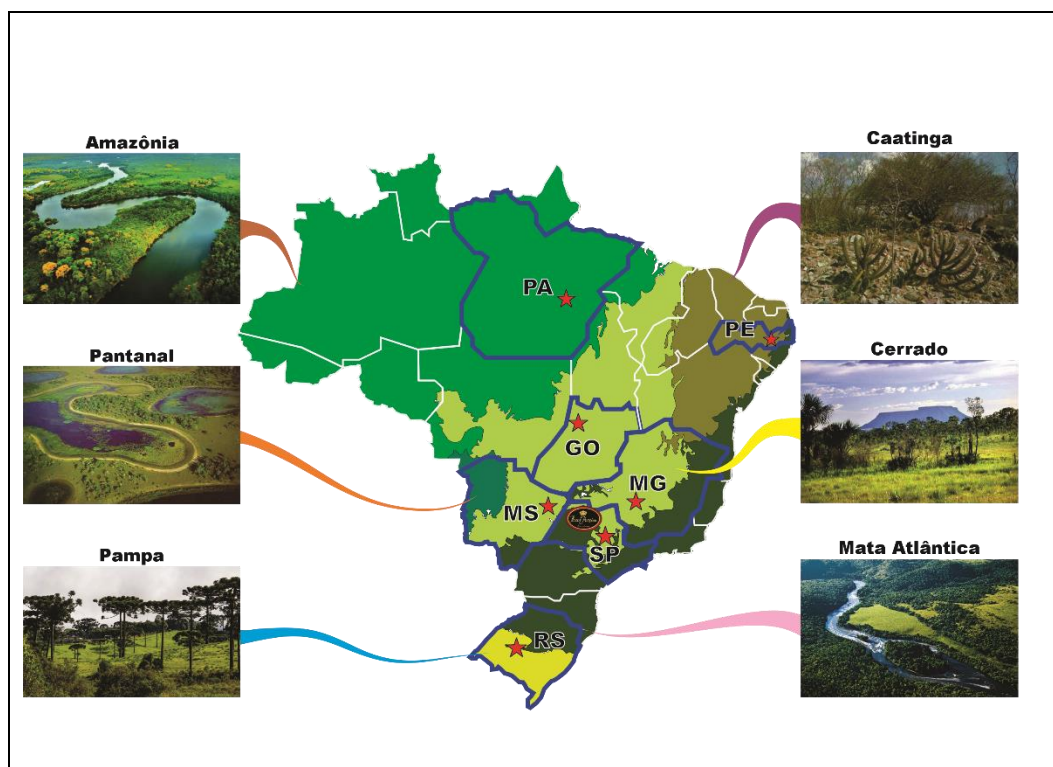


Figura 11. Locais de amostragem de carne bovina no Brasil

3.1.2 Amostragem de carne bovina do bioma Cerrado

Para melhor análise das características da carne bovina do bioma Cerrado, foi realizada uma parceria com a fazenda Turbilhão, localizada no município Estrela D'Oeste, SP, e encarregada de abastecer o Frigorífico Frigoestrela, no mesmo município. Os animais

finalizados na Fazenda Turbilhão são originários de diferentes regiões do país, sendo 100 % rastreados pelo SISBOV, um dos quesitos que certifica a propriedade para a comercialização na União Europeia. Foram coletadas 50 amostras de picanha, sendo 10 amostras de cada local estudado: Itápolis, SP (Cerrado); Piracanjuba, GO (Cerrado); Planura, MG (Cerrado); Ponta Porã, MS (Cerrado) e Rondonópolis, MT (Cerrado). A Figura 12 mostra os locais de procedência das amostras.




Figura 12. Locais de amostragem de carne bovina. EO: Estrela do Oeste (Frigoestrela); IT: Itápolis; NH: Nhandeara; PI: Piracanjuba; PL: Planura; PP: Ponta Porã; RN: Rondonópolis

3.1.3 Influência do corte, raça e sexo

Os cortes escolhidos para estudo foram acém (maçã do acém), contrafilé (Longissimus) e picanha (Gluteobíceps), representando assim os quartos dianteiro e traseiro do animal. O contrafilé (Longissimus) é um corte comumente utilizado para avaliar a composição de outros músculos [133-136], o acém é o maior corte do quarto dianteiro, podendo aumentar a representatividade, e a picanha por ser considerada um corte nobre de maior valor agregado. A Figura 13 mostra a distribuição no corpo do animal dos cortes de carne bovina estudados durante a primeira etapa do trabalho.

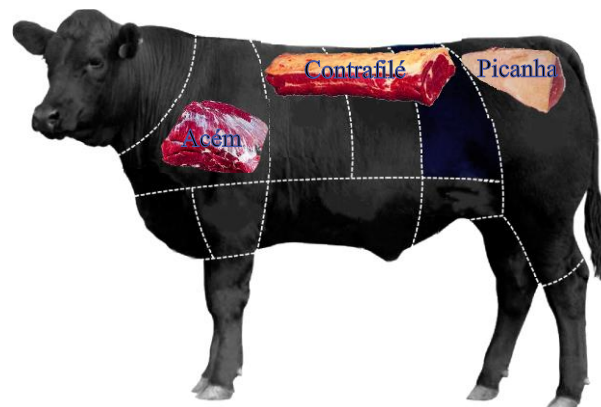


Figura 13. Cortes de carne bovina selecionados

Dada a grande diversidade de raças e cruzamentos genéticos que compõem o rebanho bovino brasileiro, conforme ilustra a Figura 14, os cortes foram escolhidos de gado que contenham na sua genética a raça Nelore (zebuíno) [42, 137, 138], Angus [7] e Wagyu, que vem ganhando destaque no rebanho bovino brasileiro pela qualidade da carne produzida [139, 140].

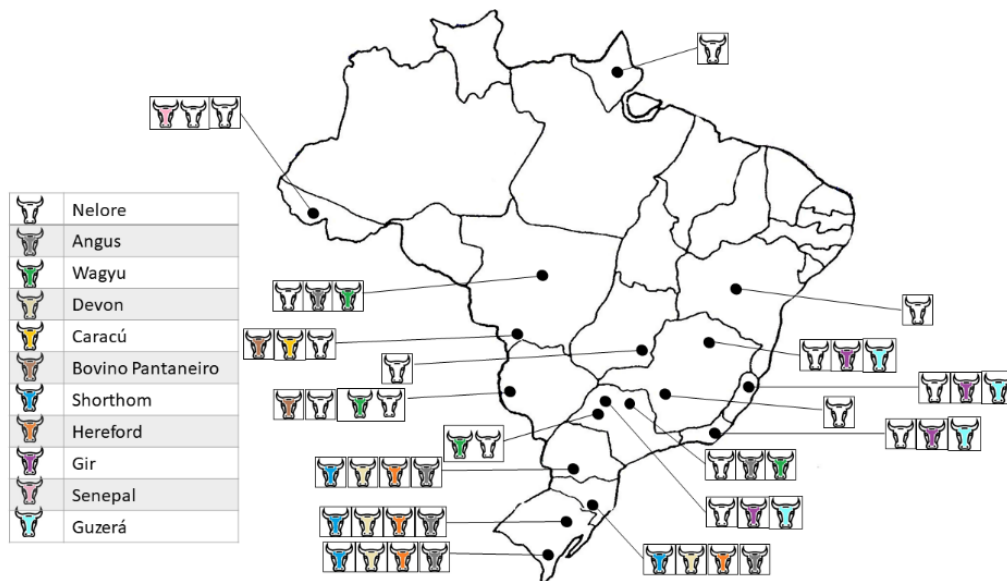


Figura 14. Distribuição geográfica das principais raças de gado de corte no Brasil.

3.1.4 Beef Passion

A *Beef Passion* é uma empresa produtora de carne bovina que opera em sistema de produção verticalizado, encarregada pelo processo produtivo, desde a inseminação, cria, recria, engorda, abate até comercialização, o que facilita a rastreabilidade do produto [141]. Além disso, este processo produtivo é considerado de excelência socioambiental e qualidade nutricional, certificado com o selo Rainforest Alliance. A empresa foi destaque em “Marca de

Carne” e campeã setorial no prêmio “As Melhores da Dinheiro Rural” de 2017, sendo catalogada como um terroir da carne bovina brasileira [142] e a primeira marca de carne brasileira certificada internacionalmente com critérios alternativos e humanizados, focada em recursos renováveis, bem-estar animal e responsabilidade socioambiental em todo o processo produtivo.

Na primeira etapa do processo produtivo, o cruzamento das raças é realizado nas fazendas de inseminação artificial e melhoramento genético “Rodansechis”, enquanto a cria dos animais é conduzida nas fazendas “Cantinho do Céu” situada na zona rural da cidade de Cassilândia e “Bom Sucesso” em Alcinópolis, Mato Grosso do Sul. O cruzamento acontece por meio de inseminação artificial das matrizes reprodutoras através do programa IATF (Inseminação Artificial em Tempo Fixo). O primeiro cruzamento é entre as raças Nelore e Angus australiano, conhecido no Brasil como cruzamento industrial, com o sêmen do Angus Australiano importado e inseminado nas vacas reprodutoras da raça Nelore. O animal resultante é $\frac{1}{2}$ Angus - $\frac{1}{2}$ Nelore, denominado “meio sangue Angus”. Os machos são castrados com seis meses de idade e desmamados entre o oitavo e o décimo mês para entrarem em regime de engorda a pasto. As fêmeas “meio sangue Angus” são avaliadas posteriormente em relação ao potencial reprodutivo e características da carcaça. As de melhor condição são utilizadas para reprodução, recebendo o sêmen da raça japonesa Wagyu, gerando os animais $\frac{1}{4}$ Angus - $\frac{1}{4}$ Nelore - $\frac{1}{2}$ - Wagyu, denominado “three cross”. As fêmeas com menor aptidão reprodutiva, juntamente com os machos, são encaminhadas para engorda a pasto. Para esta etapa, os animais são transportados para a fazenda “SPA bovino” da *Beef Passion* “Recanto Vó Cidinha”, situada na zona rural da cidade de Nhandeara, no estado de São Paulo. Os bezerros são mantidos em sistema de criação semi-intensivo em pastagem até atingirem entre 250 e 350 kg (meio-sangue Angus) e entre 350 e 420 kg (three cross). Essa etapa tem duração de 16 a 24 meses e, em seguida, os animais passam para o sistema intensivo de engorda em confinamento na própria fazenda. Esse confinamento se entende de 130 a 250 dias, durante os quais os animais ficam dispostos em piquetes cobertos, recebendo alimentação balanceada baseada em bagaço de cana-de-açúcar, grãos de milho moído, germe de milho, silagem de milho, farelo de amendoim, polpa cítrica, grãos de soja e Núcleo Mineral Nutron [143].

Para o abate, os animais são transportados para o Frigorífico “Olhos D’Água Indústria e Comércio de Carnes Ltda”, localizado a 200 km de Nhandeara, no município Ipuã, São Paulo. Os animais são abatidos conforme as normas de abate humanitário, seguindo processo rotineiro [144]. As carcaças são mantidas em câmara fria cerca de 48 h à temperatura de -2 °C para

resolução do *rigor mortis*, atingindo temperatura final para desossa em torno de 5 °C. O processo de abate e desossa é acompanhado pelo pessoal da própria *Beef Passion*. Os animais são marcados quando entram para abate e esta marca é mantida para avaliação do contrafilé (Figura 15), como uma das etapas de avaliação das meio-sangue Angus como mães, baseada, principalmente, no marmoreio e quantidade de gordura. No final do processo, são produzidos 62 tipos de cortes nobres. Os produtos são destinados a casas de carne da própria empresa e rede Oba Hortifruti, identificados com a marca *Beef Passion*, situadas nas cidades de São José do Rio Preto – SP, São Paulo – SP, Brasília – DF, Rio de Janeiro – RJ, Belo Horizonte – MG, Cuiabá – MT, Recife – PE, Belém – PA e Fortaleza – CE [143].



Figura 15. Identificação dos cortes de carne bovina dos animais após abate.

3.1.5 Amostragem de carne bovina da *Beef Passion*

Foram selecionados 78 animais dos cruzamentos $\frac{1}{2}$ Angus - $\frac{1}{2}$ Nelore e $\frac{1}{4}$ Angus - $\frac{1}{4}$ Nelore - $\frac{1}{2}$ Wagyu para o estudo. Durante o abate desses animais, foram amostrados cortes de acém, contrafilé e picanha diretamente no Frigorífico “Olhos D’Água”. Dados dos animais, como idade quando abatidos, pai, mãe, peso, tempo de confinamento e demais incidências durante a criação foram obtidos das planilhas de abate diretamente do produtor. O Apêndice A mostra os dados referentes a data da coleta, código do animal, cruzamento, sexo, data de entrada para engorda, data de nascimento, peso com que entrou no confinamento, peso para abate e dias no spa. A média do confinamento para engorda dos animais $\frac{1}{2}$ Angus - $\frac{1}{2}$ Nelore foi de 241 dias, com um peso de saída médio de 614 kg e com idade média de 2 anos. A média do confinamento para engorda dos animais $\frac{1}{4}$ Angus - $\frac{1}{4}$ Nelore - $\frac{1}{2}$ - Wagyu foi de 232 dias, com um peso de saída médio de 652 kg e com idade média de 3 anos. As amostras foram coletadas durante 4 campanhas de coleta, nos dias 08/11/2017, 22/11/2017, 29/11/2017 e 06/12/2017. Foram coletadas 196 amostras de carne bovina distribuídas conforme Tabela 3. O número de amostras de animais fêmeas do $\frac{1}{2}$ Angus - $\frac{1}{2}$ Nelore foi menor, devido ao próprio sistema de criação no qual elas são utilizadas como matriz para obter o $\frac{1}{4}$ Angus - $\frac{1}{4}$ Nelore - $\frac{1}{2}$ - Wagyu.

Tabela 3. Amostras de carne bovina analisadas procedentes da *Beef Passion*

	$\frac{1}{2}$ Angus $\frac{1}{2}$ Nelore	$\frac{1}{4}$ Angus - $\frac{1}{4}$ Nelore - $\frac{1}{2}$ - Wagyu
Macho	25	21
Fêmea	12	20
Acém	18	23
Contrafilé	38	40
Picanha	37	40

3.1.6 Amostragem de ração para bovinos da *Beef Passion*

Amostras do concentrado fornecido aos animais $\frac{1}{2}$ Angus - $\frac{1}{2}$ Nelore (ração A) e aos animais $\frac{1}{4}$ Angus - $\frac{1}{4}$ Nelore - $\frac{1}{2}$ - Wagyu (ração B) foram coletadas diretamente no local do

confinamento “Recanto Vó Cidinha” durante 15 dias consecutivos, de 14 a 27 de novembro de 2017. A Figura 16 mostra a composição das rações estudadas.

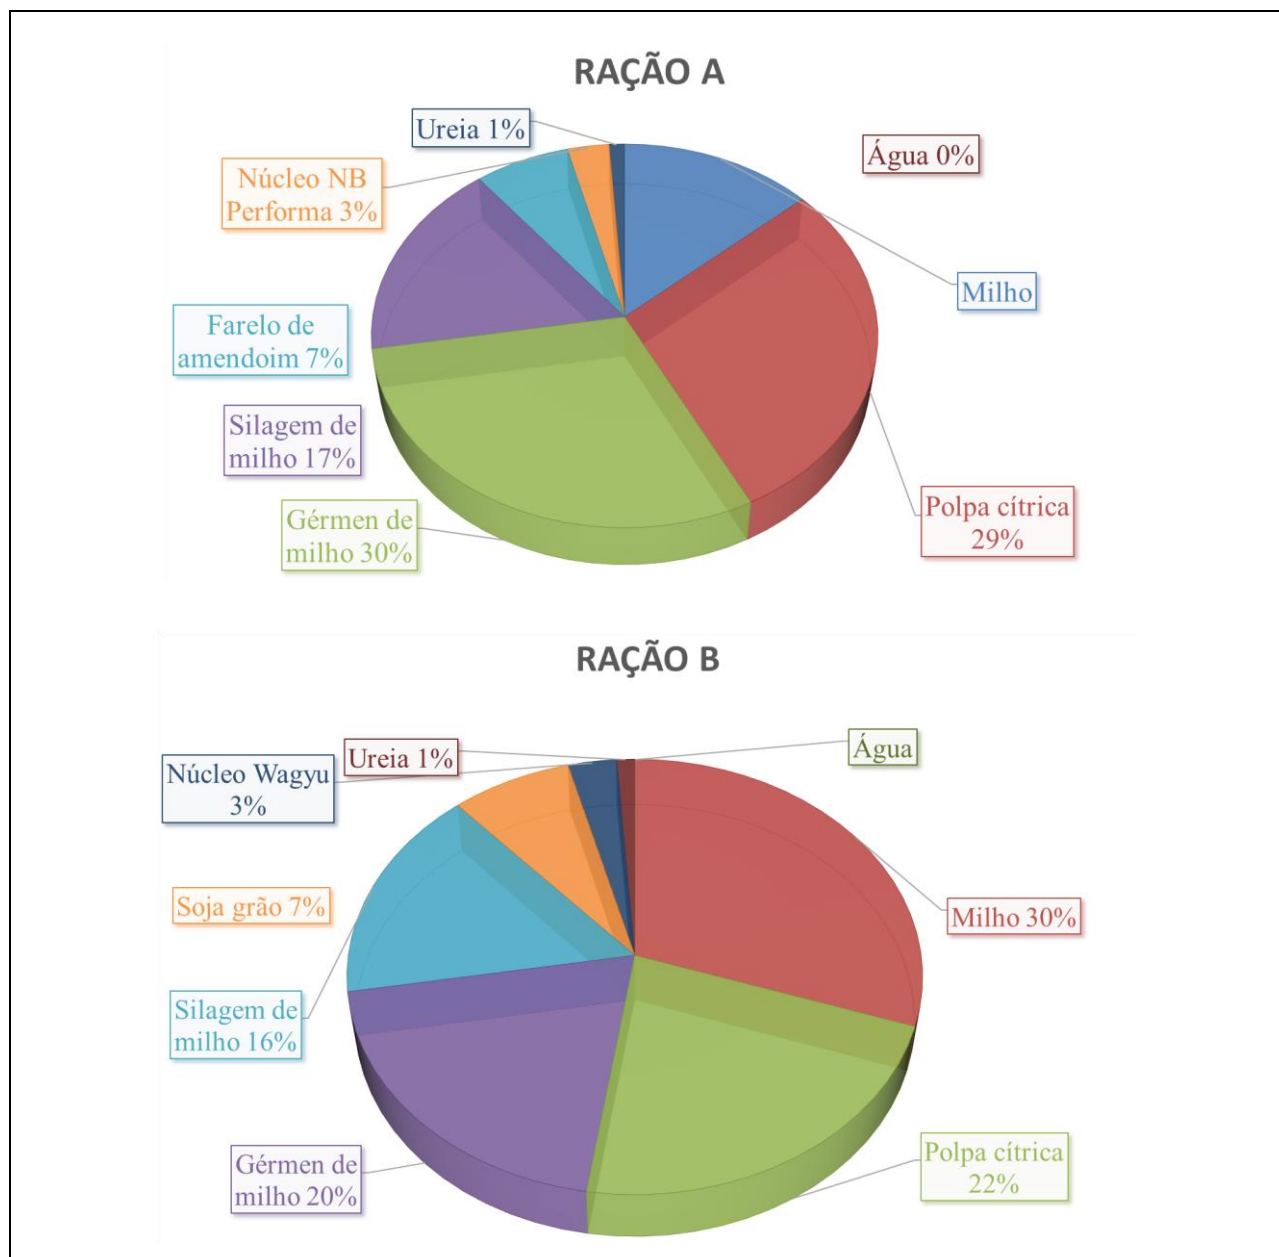


Figura 16. Composição das rações para bovinos fornecidas aos animais da *Beef Passion*

3.2 Preparo de amostras

Das amostras de contrafilé e picanha, foi retirada a capa de gordura de cobertura. Em seguida, uma porção de 300 g de carne bovina foi cortada em cubos empregando faca com lâminas de titânio, congelados e liofilizados durante 6 dias. Após a liofilização, a massa seca de cada amostra foi pesada obtendo-se o teor de umidade. Posteriormente, foram moídas em moinho de bolas Planetário PM 400 (Retsch) com jarra de moagem e bolas de óxido de alumínio sinterizado, com as características descritas na Tabela 4.

Tabela 4. Características da jarra e bolas do moinho PM 400

Jarra de moagem de óxido de alumínio sinterizado	
Designação	Al ₂ O ₃
Dureza	1750 HV
Densidade	3,9 g cm ⁻³
Composição	
Al ₂ O ₃	99,7 %
CaO	0,07 %
Fe ₂ O ₃	0,01 %
MgO	0,075 %
Na ₂ O	0,01 %
SiO ₂	0,075 %

O número de bolas variou entre 2, 4, 6 e 8 bolas e o tempo de moagem entre 1, 5, 10 e 20 min a 400 RPM em modo reverso (considerando metade do tempo de moagem em sentido horário e a outra metade em sentido anti-horário). Para escolher os melhores parâmetros de moagem, foi avaliado o grau de moagem obtido e a quantidade de háfnio (Hf) encontrada na amostra, elemento considerado como contaminante oriundo do material das bolas e das jarras de moagem. As melhores condições de moagem foram utilizar 4 bolas e 5 min de moagem.

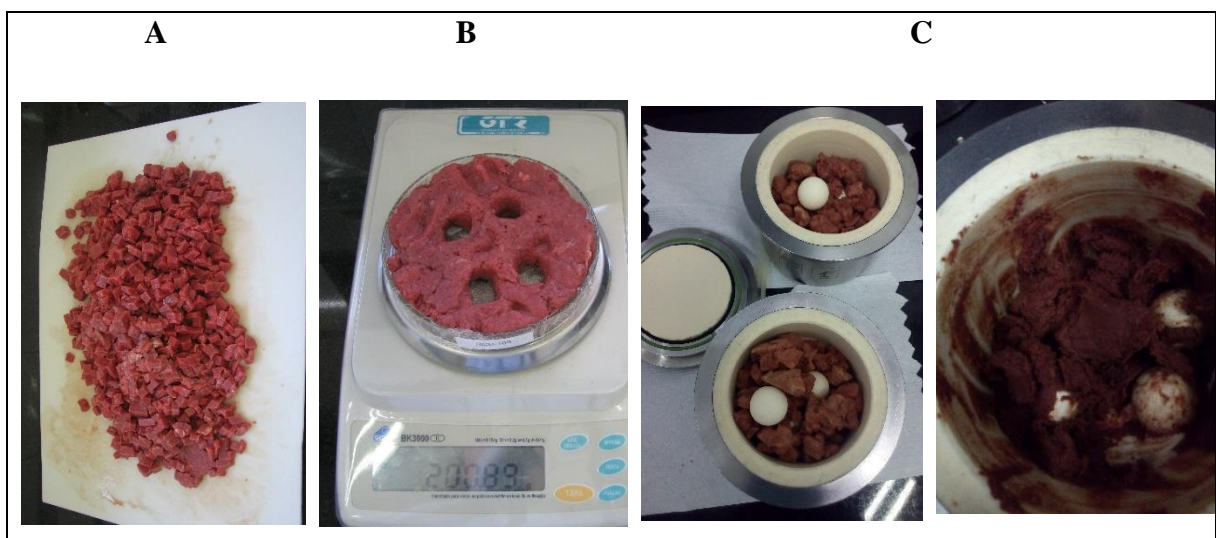


Figura 17. Etapas de corte (A), liofilização (B) e moagem (C) das amostras de carne bovina.

Para análise das amostras de ração para bovinos, foi realizada primeiramente uma pré-moagem com objetivo de diminuir o volume, empregando moinho de facas de titânio. As amostras foram congeladas e liofilizadas durante 3 dias. Após a liofilização, a massa seca obtida para cada amostra foi pesada e obtido o teor de umidade. Foi realizado um estudo preliminar no qual as amostras secas foram moídas empregando moinho Universal modelo IKA M 20 (faca

de aço inox) e M 22 (faca de carbeto de tungstênio) com sistema de circulação de água para esfriamento e câmara de aço inox. O uso da faca de carbeto de tungstênio foi escolhido e estabelecido como padrão para o processamento das amostras de ração.

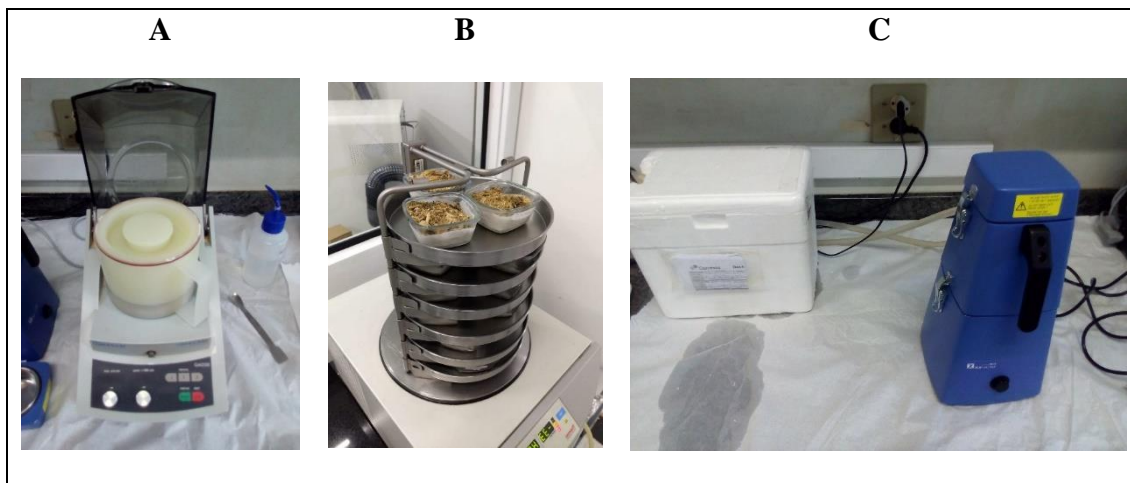


Figura 18. Etapas de pré-moagem (A), liofilização (B) e moagem (C) das amostras de ração para bovinos.

A umidade residual da ração e da carne bovina liofilizada foi determinada secando 1 g de amostra em estufa com circulação de ar durante 4 dias à temperatura de 105 °C [145]. Foi considerada a amostra seca após três medições com peso constante.

3.3 Análise por ativação neutrônica

Para controle da qualidade analítica foram utilizados os materiais de referência certificados, IAEA-336 Trace and Minor Elements in Lichen produzido pela Agência Internacional de Energia Atômica (IAEA); SRM 1515 Apple Leaves, SRM 1566b Oyster Tissue e SRM 1577c Bovine Liver, produzidos pelo National Institute of Standards and Technology (NIST). En Score foi calculado para validar os resultados analíticos. Foram considerados satisfatórios resultados com valor modular de En score menor do que 1 ($|En| < 1$) [146-148].

$$E_n = \frac{X_{lab} - X_{ref}}{\sqrt{(u_{lab})^2 + (u_{ref})^2}} \quad (12)$$

onde:

X_{lab} = valor obtido pelo laboratório

X_{ref} = valor de referência certificado

u_{lab} = incerteza expandida da análise com nível de confiança de 95 %

u_{ref} = incerteza expandida do material de referência certificado com nível de confiança de 95 %

Porções analíticas de 300 mg de amostra seca foram pesadas diretamente em cápsulas de polietileno de alta pureza fabricadas pela Posthumus Plastics, localizada em Beverwijk, Holanda. Foram empregadas para análise de carne bovina cápsulas do Tipo W (altura 1,2 cm) e para análise de ração para bovinos cápsulas Tipo T (altura 0,9 cm). O enchimento das cápsulas Tipo T foi de 100 % e das cápsulas Tipo W foi de 60 %, uma vez que o derretimento da gordura contida na carne bovina (marmoreio) durante a irradiação pode provocar vazamento. Após enchimento, as cápsulas foram lacradas empregando bastão de quartzo incandescente.

Para irradiação, as amostras foram divididas em lotes, contendo em cada um deles cápsulas vazias a serem utilizadas como branco analítico para determinação dos elementos químicos constituintes do polietileno e cápsulas com materiais de referência certificados empregados para garantia da qualidade analítica dos resultados. Fragmentos de aproximadamente 10 mg de uma liga Ni-Cr com composição química conhecida [149] foram colocados entre as cápsulas para medir o fluxo de nêutrons durante a irradiação. A irradiação foi realizada durante 4 h sob fluxo de nêutrons térmicos de $1 \times 10^{13} \text{ cm}^{-2} \text{ s}^{-1}$ no reator nuclear de pesquisa IEA-R1 do Instituto de Pesquisas Energéticas e Nucleares da Comissão Nacional de Energia Nuclear (IPEN/CNEN), localizado na cidade de São Paulo, SP.




Figura 19. Cápsulas de polietileno contendo material a ser irradiado e monitores de fluxo de nêutrons de Ni-Cr

Após irradiação, as amostras permaneceram no IPEN/CNEN durante um tempo de esfriamento de 48 a 72 h, sendo depois transportadas para o Laboratório de Radioisótopos, Piracicaba, SP. A atividade induzida nas amostras irradiadas foi medida por espectrometria gama de alta resolução empregando detectores de germânio hiperpuro (HPGe) de fabricação ORTEC, modelos GEM45190 e GEM50P4, com eficiências relativas no fotopico de 1332 keV de ^{60}Co de 45 % e 50 %, respectivamente. Para melhor detecção de raios gama de radionuclídeos com diferentes meias-vidas, foram realizadas quatro medições com tempos de decaimento aproximados de 3 dias (1^{ra} contagem), 7 dias (2^{da} contagem), 15 dias (3^{ra} contagem) e 30 dias (4^{ta} contagem). A altura (geometria) da medição foi ajustada, sendo o suficientemente

perto do detector de forma tal a não obter um tempo morto maior do que 10 %, empregando fontes de atividade conhecida de ^{137}Cs . Foram realizadas 3 medições para altura, sendo uma no início, outra na metade e outra no fim das contagens. A Tabela 5 mostra as energias gama de vários radionuclídeos comumente determinados por NAA [150].

Tabela 5. Tempo de meia-vida, energia dos raios gama, radionuclídeos interferentes e melhor contagem para detecção dos radionuclídeos

Radionuclídeo	$t_{1/2}$ (dias)	Contagem		Energia (keV)		Interferências
		Melhor	Outras	Principal	Outras	
^{42}K	0,515	1	2	1524,6		
^{24}Na	0,624	1	2	1368,6		
^{76}As	1,097	2	1	559,1	657,06	
^{282}Br	1,4708	2	1	554,3	619,1 – 698,4 – 776,5	
^{140}La	1,678	2	1	1596,5	328,8 – 487,0 – 815,8	
^{153}Sm	1,946	2	1	103,2		
^{115}Cd	2,228	2	1, 3	336,2	527,9	334,8 (^{59}Fe)
$^{239}\text{Np(U)}$	2,355	2	3	277,6	106,1 – 209,8 – 228,1	776,5 (^{82}Br)
^{122}Sb	2,7	2	3	564,1	692,8	
^{99}Mo	2,75	2	3	140,5	181,1 – 739,5 – 777,9	
^{175}Yb	4,19	2	3	396,3	113,8 – 282,5	
^{47}Ca	4,536	2	3	1297,1	159,4	
^{177}Lu	6,71	2	3	208,4	113,0	209,8 (^{239}Np)
^{147}Nd	10,98	3	4	531,0	319,4 – 439,9	
^{131}Ba	11,5	3	4	496,3	123,7 – 216,0 373,2	
^{86}Rb	18,66	3	4	1076,7		
$^{233}\text{Pa(Th)}$	27	4	3	312,0	300,1 – 340,5	312,6 (^{42}K)
^{51}Cr	27,7	4	3	320,1		319,4 (^{147}Nd)
^{169}Yb	32,02	4	3	177,2	130,5 – 197,9 – 307,7	
^{141}Ce	32,5	4	3	145,4		
^{181}Hf	42,39	4	3	482,0	132,9 – 345,8	
^{59}Fe	44,496	4	3	1099,3	192,4 – 1291,6	
^{203}Hg	46,612	4	3	279,2		
^{124}Sb	60,2	4	3	1691,0	602,7	
^{85}Sr	64,84	4	3	514,0		511 (aniquilação)
$^{58}\text{Co(Ni)}$	70,916	4	3	810,8		
^{160}Tb	72,1	4	3	879,4	298,6 – 965,1 – 1178	
^{56}Sc	83,82	4	3	889,3	1120,5	
^{182}Ta	114,43	4	3	1221,4	1189	
^{75}Se	119,77	4	3	264,6	136,0 – 279,5	264,1 (^{182}Ta)
^{65}Zn	244,1	4	3	1115,5		
^{134}Cs	753,14	4	3	795,8	569,3 – 604,7	
^{60}Co	1925,23	4	3	1332,5	1173,2	^{82}Br (pico soma)
^{152}Eu	4869	4	3	1408,1	121,8 – 344,3 – 778,9	

^{60}Co a 3^{ra} contagem se utiliza só se não for determinado bromo, pela interferência do pico soma

Após deconvolução dos espectros de radiação gama obtidos, a fração de massa dos elementos químicos e as respectivas incertezas foram calculadas usando o software Quantu [151] baseado no método k_0 [152, 153].



Figura 20. Sala de espectrometria gama do Laboratório de Radioisótopos

3.4 Análises quimiométricas

O software SAS OnDemand for Academics foi utilizado para realizar os testes estatísticos. Para implementação dos algoritmos de inteligência artificial, classificação e análise de dados, foi utilizado o software Weka (Waikato Environment for Knowledge Analysis) versão 3.8, um software de código aberto emitido sob a GNU General Public License [154, 155]. Detalhes matemáticos desses algoritmos têm sido relatados [156, 157]. Testes de Comparação de Wilcoxon-Mann-Whitney e teste de Kruskal-Wallis (RANOVA) foram implementados para comparação entre dois grupos/tratamentos e entre três ou mais grupos/tratamentos, respectivamente [158]. Foi utilizado o teste Wilks' Lambda nas análises de MANOVA [42, 159]. A medida de dispersão utilizada foi o desvio padrão robusto (RSD), calculado conforme a ISO 13528:2015 [147], onde X_i é o valor medido e X^* é o valor da mediana do conjunto de dados, segundo a Equação 13.

$$RSD = 1,483 * Mediana|X_i - X^*| \quad (13)$$

Para identificar os elementos químicos que apresentaram frações de massa com diferenças estatisticamente significativas entre as amostras de carne bovina e de ração, foi utilizado um nível de confiança de 95% ($p < 0,05$). Empregando-se o teste de ANOVA Fatorial quando mais do que um fator foi considerado (na carne bovina, por exemplo, os fatores raça,

sexo e corte), para avaliar e fazer inferências sobre os fatores ou interação entre fatores que influenciam as respostas [158].

A Análise de Componentes Principais (PCA) e Análise de Cluster foram implementadas como aprendizado de máquina não supervisionado com redução de dimensionalidade [160, 161].

A metodologia utilizada para análise de dados consiste nas seguintes etapas:

- I. Qui-quadrado, coeficiente de Cramer (V) e/ou F-score foram usados para avaliar a significância das variáveis individualmente.
- II. k subconjuntos de variáveis foram gerados, de acordo com a importância das variáveis.
- III. As amostras foram separadas em grupos de treinamento e de teste utilizando 10-fold cross-validation [115]. Cada algoritmo foi repetido 20 vezes, obtendo $(20 \times 10) = 200$ possibilidades de conjuntos de dados utilizados pelos modelos de classificação para cada subconjunto [119, 121, 162].

O coeficiente de Cramer e os testes F-score foram usados para a seleção das variáveis. Quanto maiores forem os valores atribuídos pelo F-score para cada variável, maior será sua capacidade discriminativa. Outro teste de independência de duas variáveis utilizadas é o Qui-quadrado (X^2), considerado uma distribuição não paramétrica dos dados. O X^2 foi usado para calcular o coeficiente de Cramer (V), um pós-teste do X^2 que fornece informações adicionais sobre a significância das variáveis. O coeficiente de Cramer foi calculado conforme Equação 14, onde k é o menor número de linhas ou o número de colunas e n é o número de observações. O valor de V varia de 0 (sem dependência entre as variáveis) a 1 (variáveis completamente dependentes) [162].

$$V = \sqrt{\frac{X^2}{n \cdot (k-1)}} \quad (14)$$

Acurácia, precisão, sensibilidade e especificidade dos métodos de classificação para cada classe foram calculadas usando as informações de verdadeiros positivos (TP), verdadeiros negativos (TN), falsos positivos (FP) e falsos negativos (FN) mostrados na matriz de confusão [111, 119, 162-164], conforme as Equações 15 a 18.

$$\text{Acurácia} = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (15)$$

$$\text{Precisão} = \frac{(TP)}{(TP+FP)} \quad (16)$$

$$\text{Sensibilidade} = \frac{(TP)}{(TP+FN)} \quad (17)$$

$$\text{Especificidade} = \frac{(TN)}{(TN+FP)} \quad (18)$$

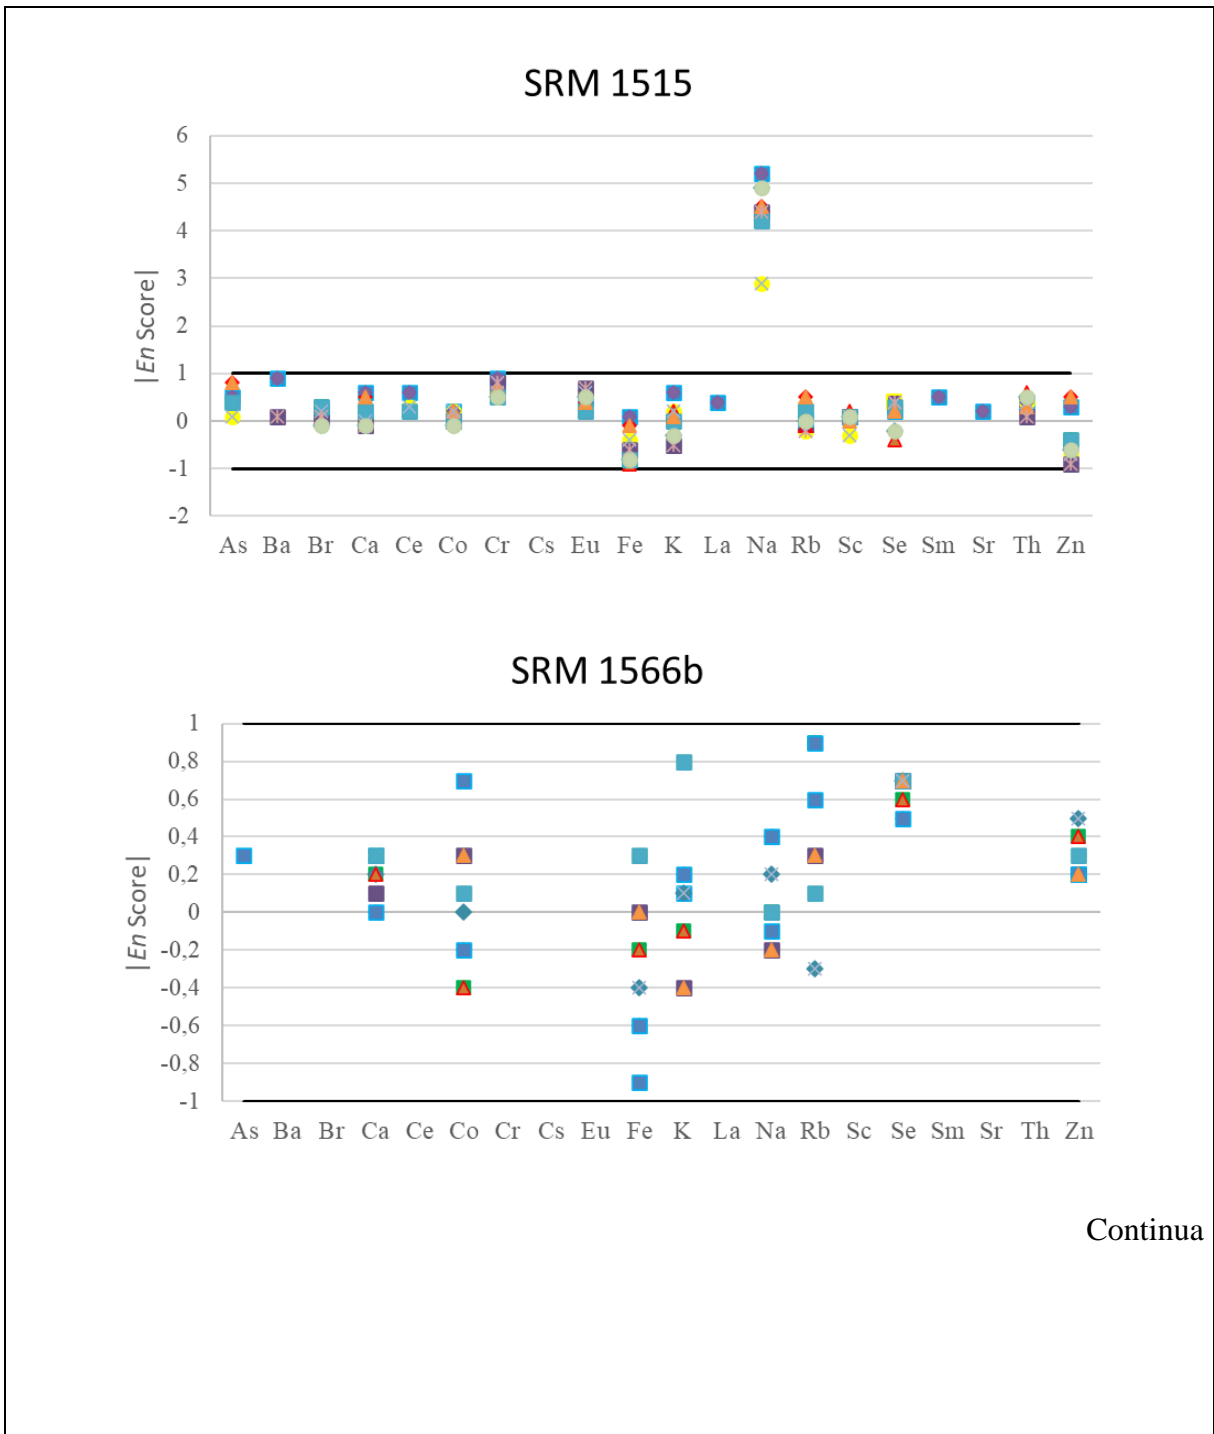
Para calcular a acurácia geral, o número de instâncias classificadas corretamente (CI) é dividido pelo total de instâncias (TI) (Equação 19).

$$\text{Acurácia (\%)} = \frac{(CI)}{(TI)} * 100 \quad (19)$$

4 RESULTADOS E DISCUSSÃO

4.1 Controle da qualidade analítica

A avaliação da qualidade analítica dos resultados obtidos foi realizada calculando os valores de En score dos materiais de referência certificados SRM 1515 Apple Leaves, SRM 1566b Oyster Tissue, SRM 1577c Bovine Liver e IAEA-336 Trace and Minor Elements in Lichen, conforme mostra a Figura 21.



Continua

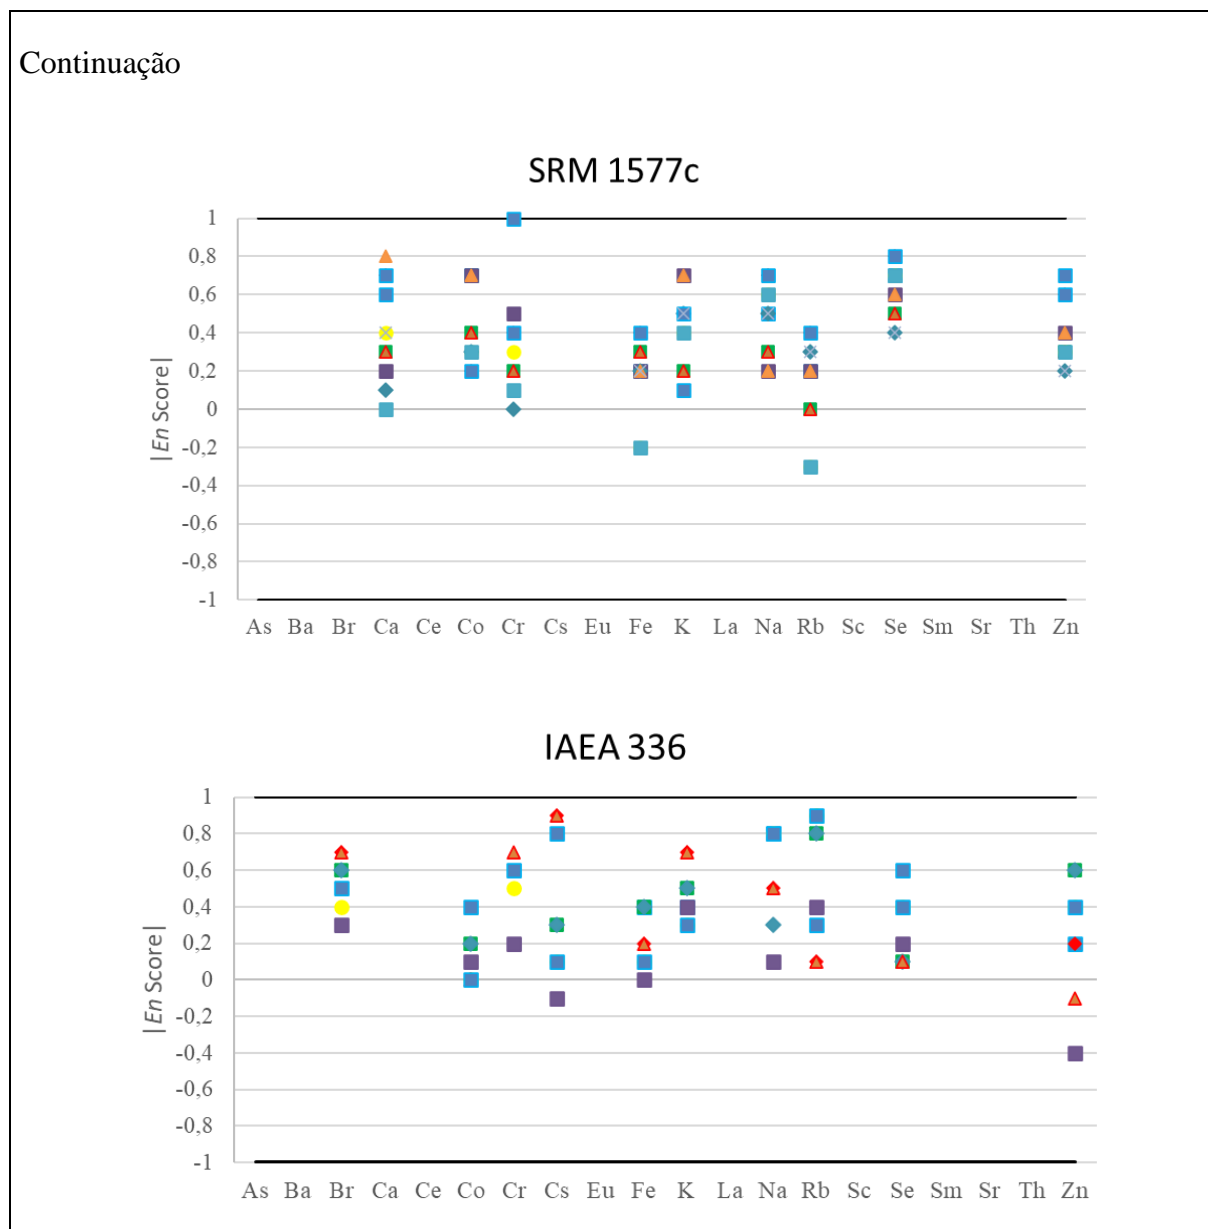


Figura 21. En score calculado para os materiais de referência certificados nos lotes de irradiação

Exceto para o sódio no SRM 1515, o restante dos elementos químicos apresentou $|\text{En score}| < 1$, garantindo a qualidade analítica dos resultados. A recuperação da fração de massa do Na no SRM 1515 foi amplamente discutida, sendo estabelecida a hipótese de possível migração do elemento das paredes dos frascos de vidro para o material [165]. Contudo, o valor certificado de sódio no SRM 1515 ($24,4 \pm 2,1 \text{ mg kg}^{-1}$) [166], aproximadamente três vezes acima do limite de quantificação obtido, é cerca de 500 vezes menor que a fração de massa quantificada nas amostras de carne e de ração. Os valores de sódio foram validados comparando os resultados obtidos com valores certificados no SRM 1577c ($2033 \pm 64 \text{ mg kg}^{-1}$) [167], SEM 1566b ($3297 \pm 53 \text{ mg kg}^{-1}$) [168] e IAEA 336 ($320 \pm 40 \text{ mg kg}^{-1}$) [169].

Os limites de detecção foram calculados para cada amostra empregando o software Quantu [151]. As Tabelas 6 e 7 mostram os limites de detecção e respectivos desvios-padrão para os elementos químicos determinados nas amostras de ração e carne, respectivamente.

Tabela 6. Limites de detecção (LD) e desvio padrão (SD) obtidos para as os elementos químicos determinados em amostras de ração para bovinos.

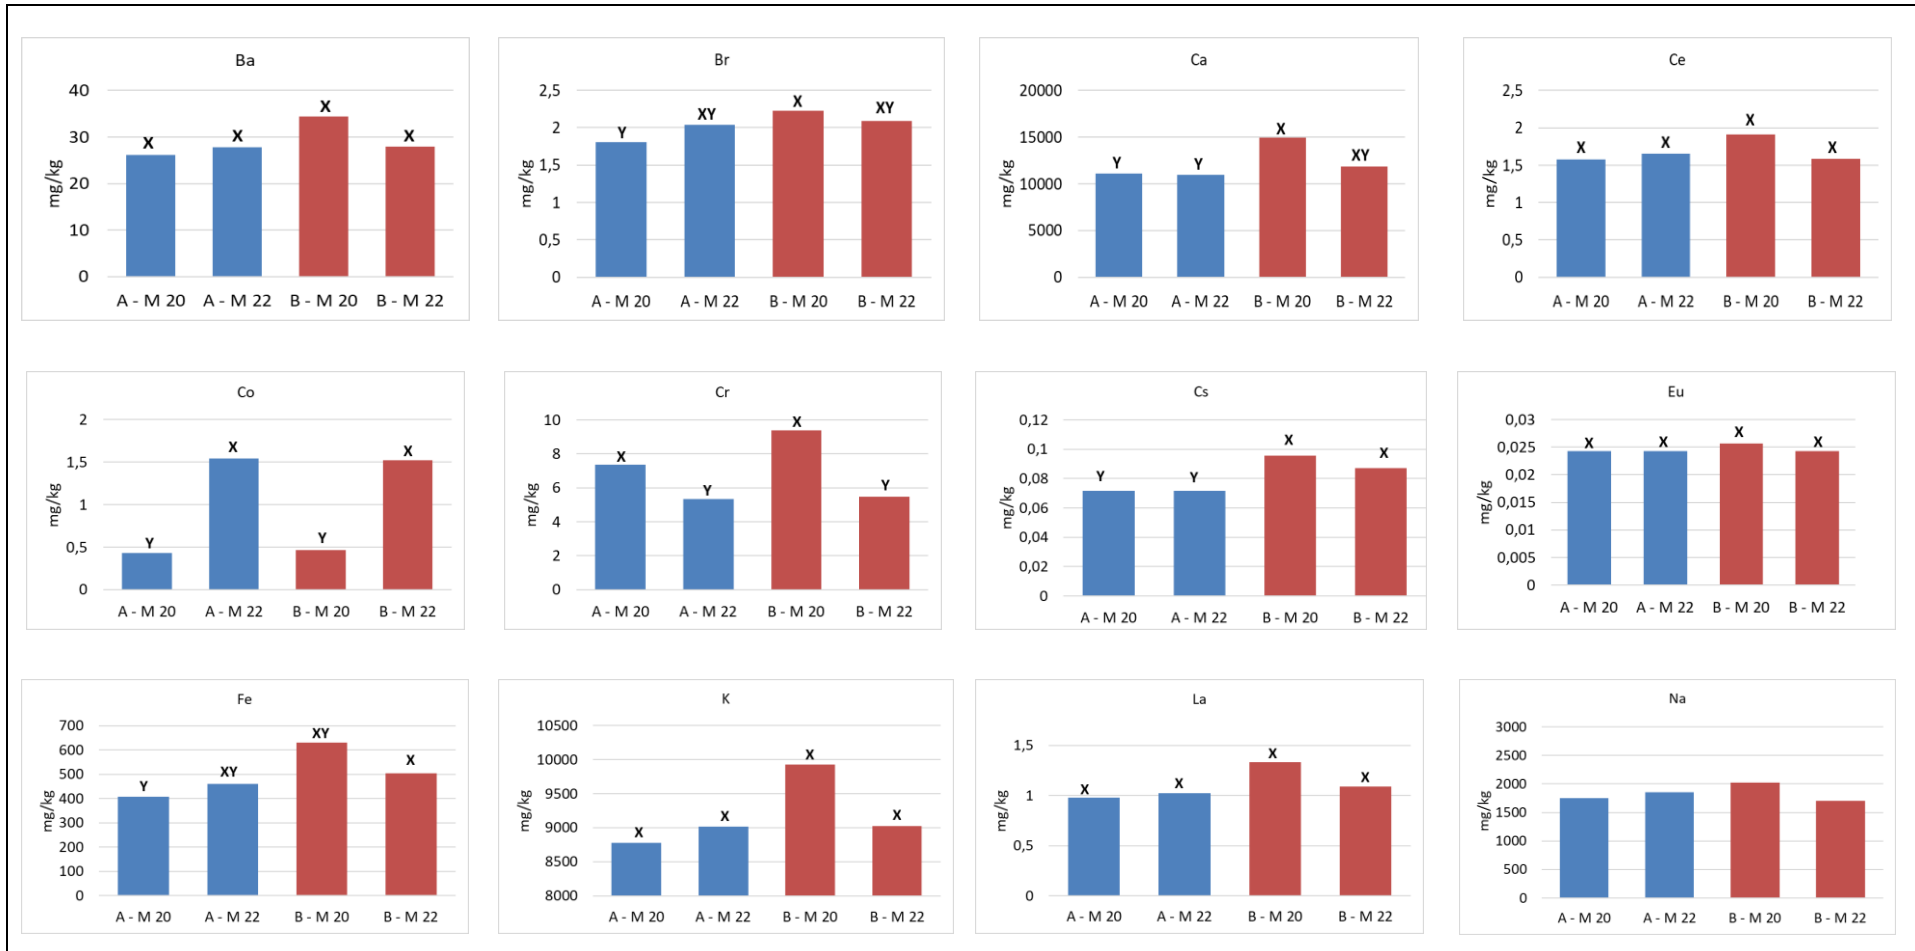
Elemento	Média do limite de detecção (mg kg⁻¹)	SD (mg kg⁻¹)
Ba	4,6	0,4
Br	0,11	0,01
Ca	297	26
Ce	0,118	0,009
Co	0,008	0,001
Cr	0,34	0,03
Cs	0,015	0,004
Eu	0,0021	0,0003
Fe	6,7	0,9
K	322	44
La	0,017	0,002
Na	2,9	0,3
Rb	0,5	0,1
Sc	0,0010	0,0001
Se	0,13	0,01
Sm	0,0056	0,0009
Sr	6,9	0,7
Th	0,015	0,001
W	0,25	0,06
Zn	0,49	0,06

Tabela 7. Limites de detecção e desvio padrão (SD) obtidos para os elementos químicos determinados em amostras de carne bovina.

Elemento	Média do limite de detecção (mg kg ⁻¹)	SD (mg kg ⁻¹)
Br	0,10	0,03
Co	0,004	0,001
Cs	0,010	0,002
Fe	3	1
K	300	100
Na	3	1
Rb	0,24	0,04
Se	0,13	0,03
Zn	0,17	0,03

4.2 Preparo de amostras

Foram obtidos teores de água (umidade) de 29 % e 32 % para as rações A e B, respectivamente. A umidade média residual das amostras de ração liofilizada foi de 5,2 %, com variação entre 4,5 % e 6,7 %. Foram determinados vinte elementos químicos nas rações A e B. A Figura 22 mostra os resultados obtidos empregando duas facas para moagem no moinho IKA, a M 20 (faca de aço inox) e a M 22 (faca de carbeto de tungstênio). Foram analisadas 7 amostras de cada ração com cada uma das facas: a – M 20 (n = 7); a – M 22 (n = 7); b – M 20 (n = 7) e b – M 22 (n = 7). As barras em azul representam as frações de massa da ração B e as barras em vermelho as da ração A. Foi utilizado o teste de comparação de Kruskal-Wallis para verificar se existem diferenças estatisticamente significativas ($p < 0,05$), sendo representados nos gráficos os grupos que não apresentaram diferenças estatisticamente significativas ($p > 0,05$) com a mesma letra.






Figura 22. Fração de massa dos elementos químicos (mg kg^{-1}) quantificados nas rações A ($n = 7$) e B ($n = 7$) com as facas M 20 e M 22

Se nenhuma influência da moagem fosse evidenciada, a fração de massa referente à mesma amostra (representada com a mesma cor) para cada elemento não apresentaria diferença estatisticamente significativa ($p > 0,05$). Foi encontrada diferença estatisticamente significativa ($p < 0,05$) entre as frações de massa de Co, Cr e W, sendo que para amostras moídas com a faca M 22 foram obtidas maiores frações de massa de Co e W, enquanto amostras moídas com a faca M 20 apresentaram maior fração de massa de Cr. Foi decidido trabalhar com a faca M 20, prestando especial atenção à contaminação da amostra com Cr.

Foram obtidos teores de água (umidade) de 65 %, 67 % e 69 % para os cortes de acém, contrafilé e picanha, respectivamente. A umidade média residual das amostras de carne bovina liofilizada foi de 6,4 %, variando entre 3 % e 7 %. Durante o estudo para determinar a contaminação por Hf nas amostras de carne bovina, resultante do procedimento de moagem, não foi possível realizar análises estatísticas, uma vez que a contaminação apresentou um comportamento aleatório, com grande variabilidade dentro do próprio tratamento. Foram estabelecidos como padrão para o preparo das amostras a utilização de 4 bolas e tempo de moagem de 5 min a 400 RPM em modo reverso (considerando metade do tempo de moagem em sentido horário e a outra metade em sentido anti-horário).

4.3 Rastreabilidade da carne bovina de diferentes países

Os elementos químicos Br, Co, Cs, Fe, K, Na, Rb, Se e Zn foram determinados por análise por ativação neutrônica e suas respectivas frações de massa calculadas pelo software Quantu [151]. O p-valor das frações de massa desses elementos determinados em picanha bovina procedente de Argentina (AR), Austrália (AU), Brasil (BR), Paraguai (PY) e Uruguai (UY) foi $< 0,001$, mostrando a alta significância estatística para discriminar a carne bovina dos países produtores. A Tabela 8 mostra as frações de massa medianas dos elementos químicos, desvio padrão robusto, intervalo interquartilico e resultado do teste de comparação múltipla de Kruskal-Wallis. Os países produtores de carne bovina marcados com a mesma letra não apresentam diferença estatisticamente significativa ($p > 0,05$) entre as frações de massa dos elementos químicos determinados.

Tabela 8. Valor mediano das frações de massa dos elementos químicos, desvio padrão robusto (RSD) e diferença estatisticamente significativa (SSD) usando o teste de Kruskal-Wallis

Analito		Argentina (n = 62)	Austrália (n = 51)	Brasil (n = 175)	Paraguai (n = 56)	Uruguai (n = 56)
Br	Mediana ± RSD (mg/kg)	16 ± 9	12 ± 5	4 ± 12	7 ± 1	42 ± 14
	SSD	Y	Y	W	Z	X
Co	Mediana ± RSD (mg/kg)	0,011 ± 0,004	0,015 ± 0,006	0,013 ± 0,031	0,009 ± 0,004	0,012 ± 0,003
	SSD	Y	X	XY	Z	Y
Cs	Mediana ± RSD (mg/kg)	0,02 ± 0,20	0,04 ± 0,07	0,15 ± 1,55	0,016 ± 0,003	0,06 ± 0,07
	SSD	Z	Y	X	Z	Y
Fe	Mediana ± RSD (mg/kg)	100 ± 17	105 ± 21	83 ± 21	91 ± 14	94 ± 16
	SSD	X	X	Y	Y	X
K	Mediana ± RSD (mg/kg)	13270 ± 2006	11489 ± 2186	12661 ± 2279	15725 ± 2395	11479 ± 1962
	SSD	Y	Z	Z	X	Z
Na	Mediana ± RSD (mg/kg)	2165 ± 356	1721 ± 288	2106 ± 473	2205 ± 355	2018 ± 330
	SSD	XY	Z	Y	X	Y
Rb	Mediana ± RSD (mg/kg)	12 ± 15	13 ± 7	34 ± 35	4,6 ± 0,9	25 ± 7
	SSD	Z	Z	X	W	Y
Se	Mediana ± RSD (mg/kg)	0,3 ± 0,1	0,7 ± 0,2	0,3 ± 0,3	0,24 ± 0,08	0,33 ± 0,14
	SSD	Y	X	Y	Z	Y
Zn	Mediana ± RSD (mg/kg)	184 ± 27	156 ± 30	164 ± 27	178 ± 30	178 ± 30
	SSD	XY	Y	Y	X	X

Paraguai apresentou a menor fração de massa de Co. Não foi encontrada diferença estatisticamente significativa ($p > 0,05$) entre as frações de massa de Co nas amostras de carne bovina originárias da Austrália e do Brasil, nem entre as amostras originárias do Brasil, Uruguai e Argentina. As amostras brasileiras apresentaram a maior fração de massa de Cs, sendo estatisticamente diferente ($p < 0,05$) das demais amostras. Não foi encontrada diferença estatisticamente significativa ($p > 0,05$) entre as frações de massa de Cs nas amostras de carne bovina da Austrália e do Uruguai, nem entre as da Argentina e do Paraguai. Não foi encontrada diferença estatisticamente significativa ($p > 0,05$) entre as frações de massa de Fe nas amostras de carne bovina da Argentina, Austrália e Uruguai, nem entre amostras do Brasil e Paraguai. As amostras do Paraguai apresentaram a maior fração de massa de K, sendo estatisticamente diferente ($p < 0,05$) das demais amostras. Não foi encontrada diferença estatisticamente significativa ($p > 0,05$) entre as frações de massa de K das amostras de carne bovina do Brasil, Austrália e Uruguai. Paraguai e Argentina apresentaram a maior fração de massa de Na, sem diferença estatisticamente significativa ($p > 0,05$) entre as amostras de carne bovina da

Austrália, Uruguai e Brasil. As maiores frações de massa de Rb e Se foram encontradas em amostras de carne bovina do Brasil e da Austrália, respectivamente.

A fração de massa de Zn teve a menor variação entre todas as amostras de carne bovina. Não foi encontrada diferença estatisticamente significativa ($p > 0,05$) entre as amostras do Paraguai, Uruguai e Argentina, nem entre as amostras da Argentina, Brasil e Austrália. A maior fração de massa de Br foi encontrada em amostras de carne bovina do Uruguai, sendo estatisticamente diferente de outros países. O aumento nas frações de massa de Br na carne bovina produzida próxima à linha costeira pode ser influenciado pela injeção de Br na atmosfera associada a aerossóis marinhos [170, 171]. As amostras de carne bovina brasileiras apresentam a menor fração de massa de Br, o que pode ser explicado pela enorme extensão territorial ocupada pela atividade pecuária e pela maior concentração de pecuária na região centro-oeste [3], com predominância de características continentais. O maior desvio padrão das frações de massa do Br foi obtido no Brasil. Outro aspecto que pode influenciar o aumento de Br em aerossóis e sua incorporação nos ciclos hidrológicos e na cadeia alimentar é a queima de biomassa [172] que afeta muito países como Austrália e Brasil. Considerando que a incerteza analítica foi inferior a 15 %, essa variação pode ser explicada pela grande variedade de condições ambientais para a pecuária no Brasil. De fato, seis (Br, Co, Cs, Fe, Na e Se) dos nove elementos químicos estudados apresentaram maior desvio padrão robusto das frações de massa, (284 %, 233 %, 1013 %, 25 %, 22 % e 98 %), respectivamente, em amostras de carne bovina do Brasil. De acordo com TRASE (*Transparency for Sustainable Economies*) [64-66], em 2017 foram rastreadas exportações de 2,1 milhões de toneladas de carne bovina brasileira, sendo 0,92 milhão de toneladas do bioma Cerrado, 0,53 milhão de toneladas do bioma Amazônia, 0,53 milhão de toneladas do bioma Mata Atlântica, 0,09 milhão de toneladas do bioma Pampa, 0,04 milhão de toneladas do bioma Pantanal e 0,22 milhão de toneladas de origem desconhecida. Esta rastreabilidade é baseada em dados logísticos autodeclarados e publicamente disponíveis e dados oficiais de comércio global, sendo assim uma declaração designativa. Apesar das complexas análises dos bancos de dados envolvidos no sistema TRASE, aproximadamente 10 % da carne bovina brasileira exportada não possuía identificação do bioma de origem [64]. As exportações totais dos biomas Cerrado e Amazônia (1,45 milhão de toneladas) foram superiores às exportações da Austrália (1,4 milhão de toneladas), Uruguai (0,40 milhão de toneladas), Paraguai (0,36 milhão de toneladas) e Argentina (0,28 milhão de toneladas), no mesmo ano [8]. A análise de componentes principais (PCA) considerando 82,7 % das informações, 53,3 % no

Componente Principal 1 (PC1) e 29,4 % no Componente Principal 2 (PC2), é apresentada na Figura 23.

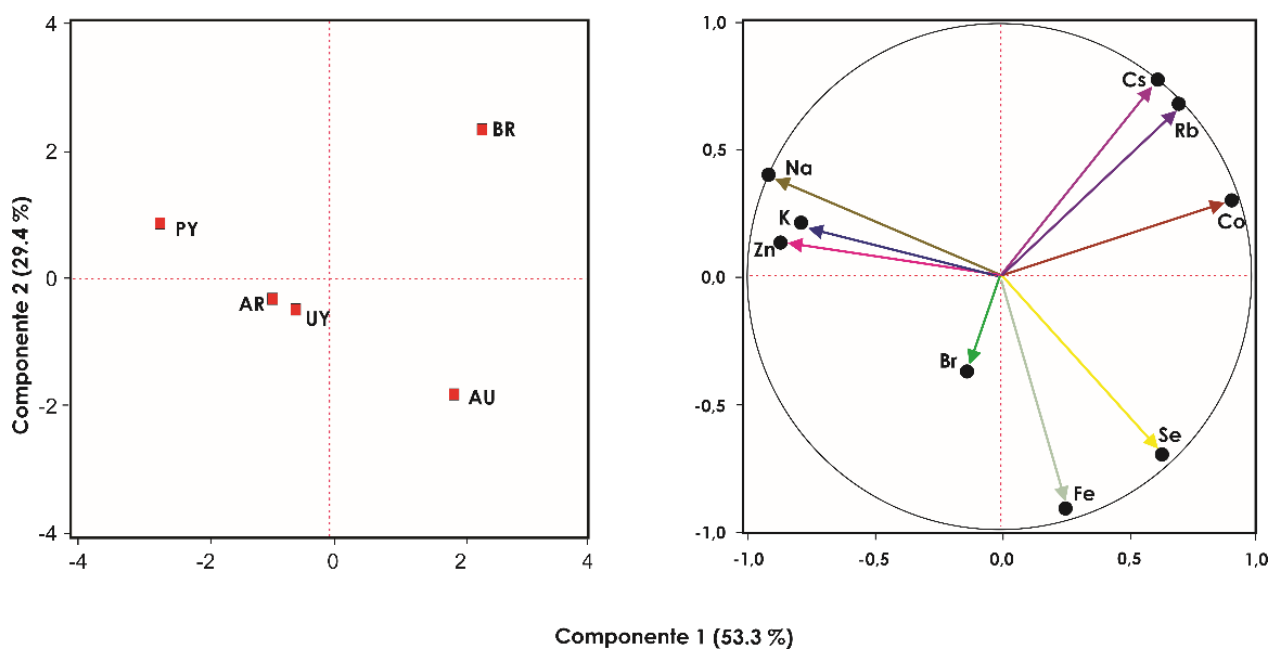


Figura 23. PCA e biplot da composição química da carne bovina de cinco países produtores

Foi observada a formação de quatro grupos, o primeiro com amostras de carne bovina do Brasil, o segundo com amostras de carne bovina da Austrália, o terceiro com amostras de carne bovina do Paraguai e o quarto com amostras de carne bovina da Argentina e Uruguai. As maiores distâncias foram observadas entre o primeiro, segundo e terceiro grupos e a menor distância entre o terceiro e o quarto grupos. A orientação e o comprimento dos vetores de cada variável (fração de massa do elemento químico) foram utilizados para discriminação exploratória dos países produtores de carne bovina. Brasil teve influência positiva de Co, Cs e Rb, influência negativa de Br e baixa influência de Fe, K, Na, Se e Zn. Austrália teve influência positiva de Fe e Se, influência negativa de K, Na e Zn, e baixa influência de Br, Co, Cs, e Rb. Paraguai teve influência positiva de Na, K e Zn, influência negativa de Fe e Se, e baixa influência de Br, Co, Cs e Rb. Argentina e Uruguai tiveram influência positiva de Br, influência negativa de Co, Cs e Rb, e baixa influência de Fe, K, Na, Se e Zn.

Foi realizada análise de cluster como outra análise exploratória e de aprendizado de máquina não supervisionado (Figura 24). Foi observada a formação de 3 grupos, o primeiro por Paraguai, o segundo por Brasil e Uruguai e o terceiro por Argentina e Austrália.

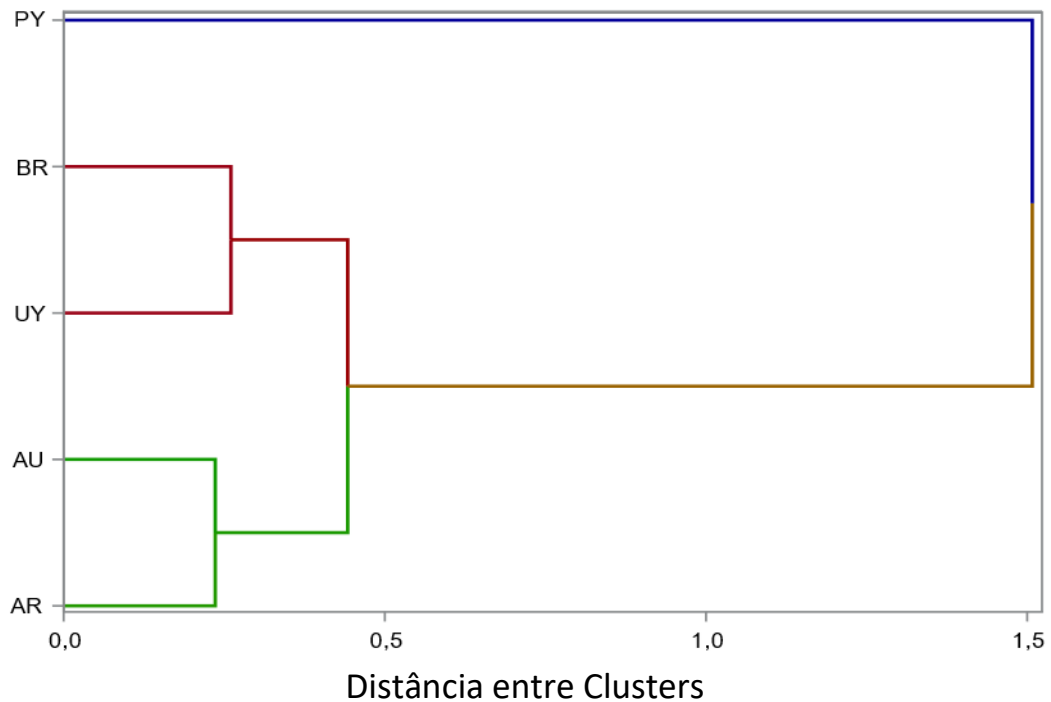


Figura 24. Dendrograma da composição multielementar da carne bovina de cinco países produtores

Mesmo com a formação de 4 grupos na análise de componentes principais (PCA) e três grupos na análise de cluster, a carne bovina dos 5 países apresentou diferenças altamente significativas quando comparadas dois a dois ($p < 0,0001$) utilizando contrastes multivariados NPMANOVA. Este resultado mostra a viabilidade do uso da composição química e abordagem quimiométrica para discriminar países produtores de carne bovina, como ferramenta para melhorar a transparência no comércio de carne bovina.

As amostras foram separadas em conjunto de treinamento (aproximadamente 60 % do conjunto de dados) e conjunto de teste (aproximadamente 40 % do conjunto de dados). Cinco algoritmos de aprendizado de máquina supervisionados foram usados para obter modelos que permitissem a classificação de carne bovina de diferentes países produtores com base nas frações de massa de Br, Co, Cs, Fe, K, Na, Rb, Se e Zn. A acurácia geral da classificação foi de 93 % (MLP), 88 % (RF), 85 % (CART), 80 % (NB) e 78 % (SMO). A Figura 25 mostra a acurácia, precisão, sensibilidade e especificidade desses algoritmos para cada grupo de amostras.

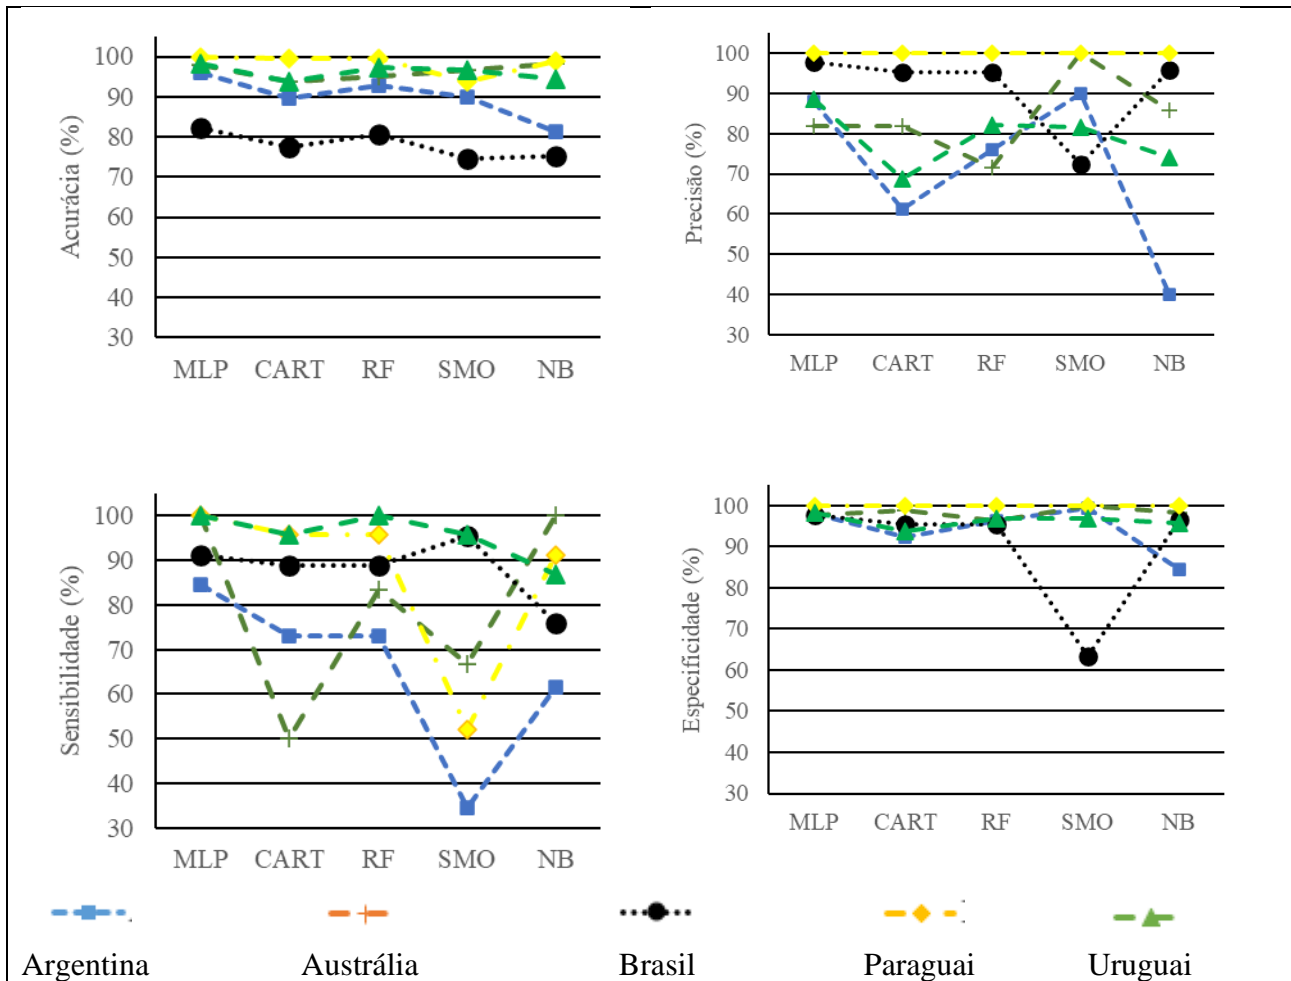


Figura 25. Acurácia, precisão, sensibilidade e especificidade para discriminar a carne bovina de cinco países produtores implementando os modelos de classificação CART, MLP, NB, RF e SMO

O melhor desempenho de classificação foi obtido pelo MLP para discriminar amostras do Paraguai (PY), com 100% de acurácia, precisão, sensibilidade e especificidade, sendo que as 23 amostras do grupo de teste foram classificadas corretamente. Os valores de acurácia de classificação obtidos para amostras do Uruguai (UY), Austrália (AU), Argentina (AR) e Brasil (BR) foram 98 %, 98 %, 96 % e 82 %, respectivamente. Sensibilidade de 100 % foi obtida para amostras da Austrália e Uruguai, sendo todas corretamente classificadas. Maior confusão foi observada entre amostras da Argentina, Brasil e Uruguai. Das 91 amostras de carne bovina produzidas no Brasil que compõem o grupo de teste, o modelo obtido implementando o MLP classificou 83 corretamente, 3 sendo classificadas como originárias da Argentina, 3 como originárias do Uruguai e 2 como de originárias da Austrália. Das 26 amostras do grupo de teste de carne bovina da Argentina, 22 foram classificadas corretamente e 4 incorretamente, sendo 2 originárias da Austrália e 2 do Brasil. A Tabela 9 mostra as matrizes de confusão obtidas para cada algoritmo de classificação implementado.

Tabela 9. Matriz de confusão obtida a partir dos modelos de classificação

MLP					
AR	AU	BR	PY	UY	<-- classificado como
22	2	2	0	0	AR
0	18	0	0	0	AU
3	2	83	0	3	BR
0	0	0	23	0	PY
0	0	0	0	23	UY

CART					
AR	AU	BR	PY	UY	<-- classificado como
19	1	3	0	3	AR
8	9	0	0	1	AU
4	0	81	0	6	BR
0	1	0	22	0	PY
0	0	1	0	22	UY

RF					
AR	AU	BR	PY	UY	<-- classificado como
19	5	2	0	0	AR
1	15	2	0	0	AU
4	1	81	0	5	BR
1	0	0	22	0	PY
0	0	0	0	23	UY

SMO					
AR	AU	BR	PY	UY	<-- classificado como
9	0	15	0	2	AR
0	12	6	0	0	AU
1	0	87	0	3	BR
0	0	11	12	0	PY
0	0	1	0	22	UY

NB					
AR	AU	BR	PY	UY	<-- classificado como
16	1	2	0	7	AR
0	18	0	0	0	AU
20	2	69	0	0	BR
2	0	0	21	0	PY
2	0	1	0	20	UY

O modelo CART classificou 4 amostras do Brasil como provenientes da Argentina e 6 como provenientes do Uruguai (Tabela 9). O modelo NB classificou 20 amostras do Brasil como provenientes da Argentina. O modelo RF classificou 4 amostras como procedentes da

Argentina e 5 como procedentes do Uruguai. O modelo SMO classificou 1 amostra como oriunda da Argentina e 3 como oriundas do Uruguai (Tabela 9). Isso pode ser explicado pela concentração da pecuária na região do bioma Pampa, compartilhada por Argentina, Brasil e Uruguai. A Figura 26 mostra um resumo dos resultados obtidos para rastreabilidade da carne bovina de diferentes países.

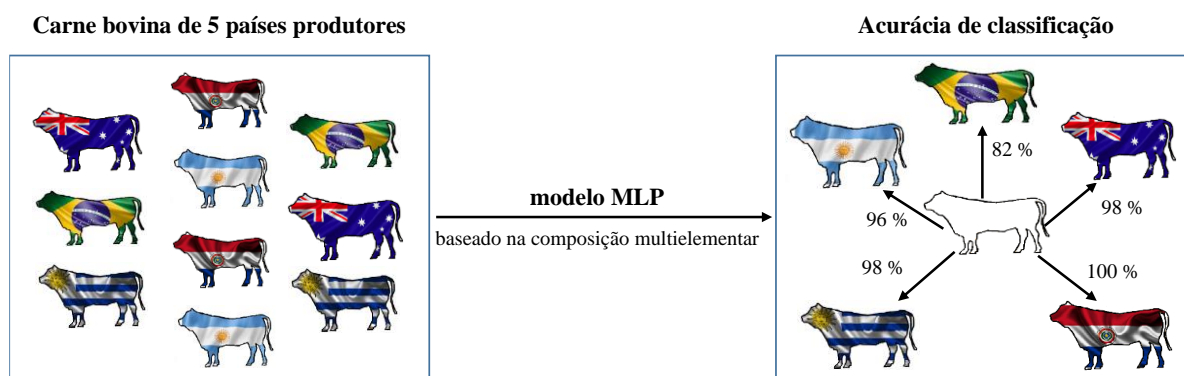


Figura 26. Acurácia de classificação para rastreabilidade da carne bovina de diferentes países utilizando a composição multielementar e o algoritmo MLP

Para diminuir a complexidade da função de ativação, o número de classes foi reduzido de 5 para 2, visando melhorar o desempenho da classificação [121]. Ao invés de usar um modelo para classificar entre as cinco origens geográficas da carne bovina, foram gerados cinco modelos MLP, um para cada país produtor de carne bovina. A Tabela 10 mostra a matriz de confusão obtida para os modelos MLP.

Tabela 10. Matriz de confusão obtida a partir dos modelos de classificação MLP para diferenciar o país produtor

Argentina (AR) ou Não Argentina (NAR)			Austrália (AU) ou Não Austrália (NAU)		
AR	NAR	<-- classificado como	AU	NAU	<-- classificado como
25	1	AR	25	1	AU
7	148	NAR	7	148	NAU
Brasil (BR) ou Não Brasil (NBR)			Paraguai (PY) ou Não Paraguai (NPY)		
BR	NBR	<-- classificado como	PY	NPY	<-- classificado como
83	8	BR	19	4	PY
2	88	NBR	0	158	NPY
Uruguai (UY) ou Não Uruguai (NUY)					
UY	NUY	<-- classificado como			
23	0	UY			
4	154	NUY			

A discriminação da carne bovina produzida na Argentina, Austrália, Brasil, Paraguai e Uruguai foi realizada com valores de acurácia de 96 %, 97 %, 94 %, 98 % e 98 %, respectivamente. A melhoria no desempenho da classificação foi obtida para a carne bovina brasileira, com acurácia aumentando de 82 % para 94 %. Para os demais países, não se obteve variação significativa no desempenho da classificação.

O aprendizado de máquina aplicado à composição multielementar da carne bovina produzida na Argentina, Austrália, Brasil, Paraguai e Uruguai permitiu discriminar sua origem geográfica. O melhor desempenho de classificação foi alcançado com a implementação de modelos MLP. A maior precisão foi obtida para a carne do Paraguai e a menor para a carne do Brasil, devido provavelmente à grande diversidade da pecuária brasileira [173].

4.4 Rastreabilidade da carne bovina de diferentes biomas do Brasil

Foram quantificadas as frações de massa dos elementos químicos Br, Co, Cs, Fe, K, Na, Rb, Se e Zn nas amostras de carne bovina utilizando análise por ativação neutrônica. A Tabela 11 mostra os valores medianos das frações de massa desses elementos, o desvio padrão robusto e o resultado do teste de comparações múltiplas de Kruskal-Wallis (nível de confiança de 95 %).

As maiores frações de massa de Br e Se foram encontradas nas amostras do bioma Amazônia (PA), sendo estatisticamente diferente ($p < 0,05$) dos demais biomas. As amostras do bioma Caatinga (PE) apresentaram as menores frações de massa de Co, sendo estatisticamente diferente ($p < 0,05$) dos demais biomas. Não houve diferenças significativas entre os biomas em relação às frações de massa de Cs, K, Na e Rb. O bioma Pampa (RS) apresentou a maior fração de massa de Fe e o bioma Pantanal (MS) a menor fração de massa de Zn, estatisticamente diferente dos demais biomas ($p < 0,05$). As amostras da Caatinga (PE) apresentaram as menores frações de massa de Co, Cs, Rb e Se. Os biomas Amazônia (PA), Caatinga (PE) e Pampa (RS), com maior interação com o ambiente costeiro, apresentaram maior fração de massa de Br na carne bovina, provavelmente influenciada por aerossóis salinos ricos em Br [171].

O desvio padrão robusto das frações de massa de Br, Cs, Rb e Se no bioma Amazônia (PA), Cs e Se no Pampa (RS) e Cerrado (SP), Cs no Pantanal (MS) e Se no Cerrado (MG) apresentou valores superiores a 50 %. Considerando que as incertezas analíticas médias para esses elementos não superaram 20 %, os altos valores de RSD indicam a dispersão das frações

de massa nestes locais. De forma geral, os elementos Cs e Se apresentaram as maiores dispersões.

Tabela 11. Mediana das frações de massa dos elementos químicos e desvio padrão robusto (RSD) em mg/kg e diferença estatisticamente significativa (SSD) usando o teste de Kruskal-Wallis

		GO n = 25	MG n = 25	MS n = 25	PA n = 25	PE n = 25	RS n = 25	SP n = 25
Br	Mediana	5	4	5	25	13	13	4
	RSD	1	2	2	13	4	6	2
	SSD	Z	Z	Z	X	Y	Y	Z
Co	Mediana	0,022	0,016	0,018	0,014	0,007	0,021	0,013
	RSD	0,007	0,006	0,006	0,006	0,001	0,009	0,005
	SSD	XY	XY	XY	Y	Z	X	XY
Cs	Mediana	0,21	0,15	0,6	0,13	0,08	2	0,16
	RSD	0,05	0,07	0,4	0,12	0,01	2	0,15
	SSD	Y	Y	XY	YZ	Z	X	Y
Fe	Mediana	77	84	91	92	89	104	89
	RSD	12	7	10	9	5	9	11
	SSD	Z	YZ	Y	Y	YZ	X	Y
K	Mediana	13973	13669	12717	12514	13499	12876	14261
	RSD	694	894	1238	1185	1524	1195	941
	SSD	X	XY	Z	Z	XYZ	YZ	X
Na	Mediana	2188	2148	2210	2177	2482	2271	2309
	RSD	198	106	299	358	100	219	169
	SSD	XY	Y	Y	XY	X	XY	XY
Rb	Mediana	32	54	50	49	28	60	45
	RSD	6	12	22	28	6	10	19
	SSD	YZ	X	XY	XYZ	Z	X	XY
Se	Mediana	0,3	0,3	0,3	0,8	0,13	0,2	0,2
	RSD	0,1	0,2	0,1	0,6	0,03	0,1	0,2
	SSD	Y	Y	Y	X	Z	YZ	Y
Zn	Mediana	166	168	144	183	195	177	180
	RSD	17	15	9	29	8	20	11
	SSD	X	X	Y	X	X	X	X

Os 5 biomas apresentaram diferenças estatisticamente significativas quando comparados dois a dois ($p < 0,0001$) usando contrastes multivariados NPMANOVA. Os três locais amostrados do Cerrado (Cerrado (GO), Cerrado (MG) e Cerrado (SP)) não diferiram ($p > 0,05$) entre si. Este resultado mostra a viabilidade da rastreabilidade química da carne bovina brasileira de acordo com o bioma de origem.

A Figura 27 apresenta o resultado de uma análise exploratória dos dados utilizando análise de componentes principais, considerando 67 % das informações (PC1 37,5 % e PC2 29,6 %). Pode-se observar similaridade entre as características das amostras de carne bovina do Cerrado (GO), Cerrado (MG) e Cerrado (SP), apresentando valor negativo de PC1 e PC2. Essas amostras tiveram distâncias menores com amostras do Pantanal (MS), que apresentaram valores de PC1 positivos e PC2 negativos. Os biomas Amazônia (PA) e Pampa (RS) apresentaram valores positivos tanto para PC1 quanto para PC2. O bioma Caatinga (PE) foi separado do restante, apresentando valor negativo de PC1 e valor positivo de PC2. A formação de quatro grupos foi observada de acordo com a composição multielementar da carne bovina: Amazônia e Pampa (grupo 1); Cerrado (GO), Cerrado (MG) e Cerrado (SP) (grupo 2); Pantanal (grupo 3) e Caatinga (grupo 4). As amostras da Caatinga foram as que mais se distinguiram dos demais biomas.

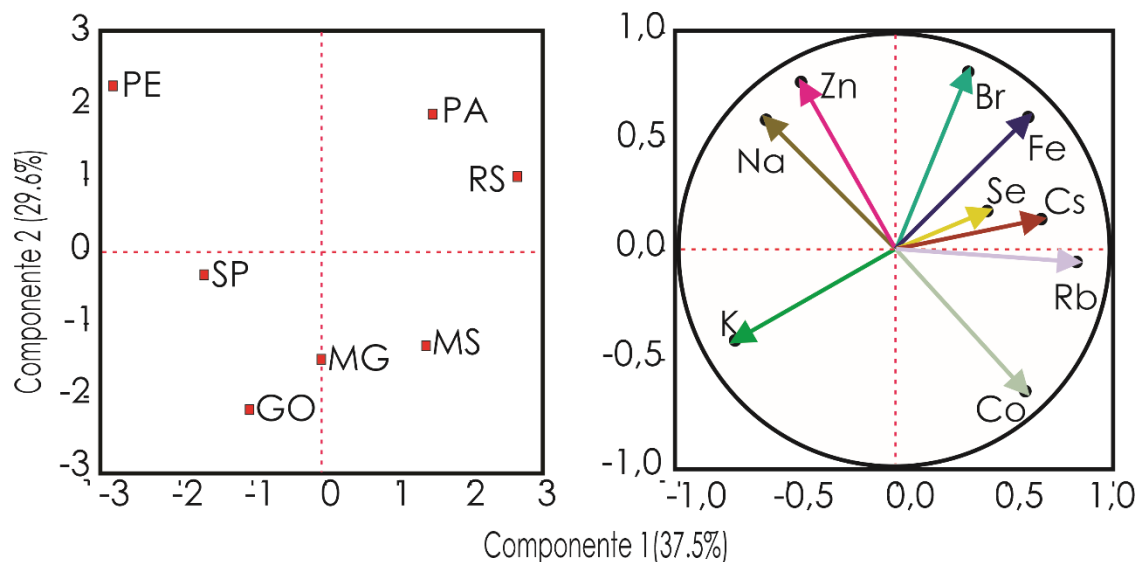


Figura 27. PCA e biplot da composição multielementar da carne bovina dos biomas Amazônia, Cerrado, Caatinga, Pampa e Pantanal

A orientação das variáveis e o comprimento dos vetores mostram uma contribuição positiva de Na e Zn e negativa de Co para identificar amostras da Caatinga, efeito contrário às amostras do Pantanal. Amostras da Amazônia e Pampa apresentam influência positiva de Br, Fe, Rb, Cs e Se, e influência negativa de K, ao contrário das amostras do Cerrado (GO), Cerrado (MG) e Cerrado (SP).

A Figura 28 mostra o dendrograma obtido pela análise de agrupamento, evidenciando as diferenças de composição elementar da carne bovina dos biomas. A menor distância foi obtida entre o Cerrado (SP) e o Cerrado (GO), que foram agrupados com o Cerrado (MG).

Pode-se observar a formação de quatro grandes grupos, o primeiro contendo as amostras do Cerrado (SP), Cerrado (GO) e Cerrado (MG), o segundo com as amostras dos biomas Amazônia (PA) e Pantanal (MS), o terceiro com amostras do Pampa (RS) e o quarto com amostras da Caatinga (PE).

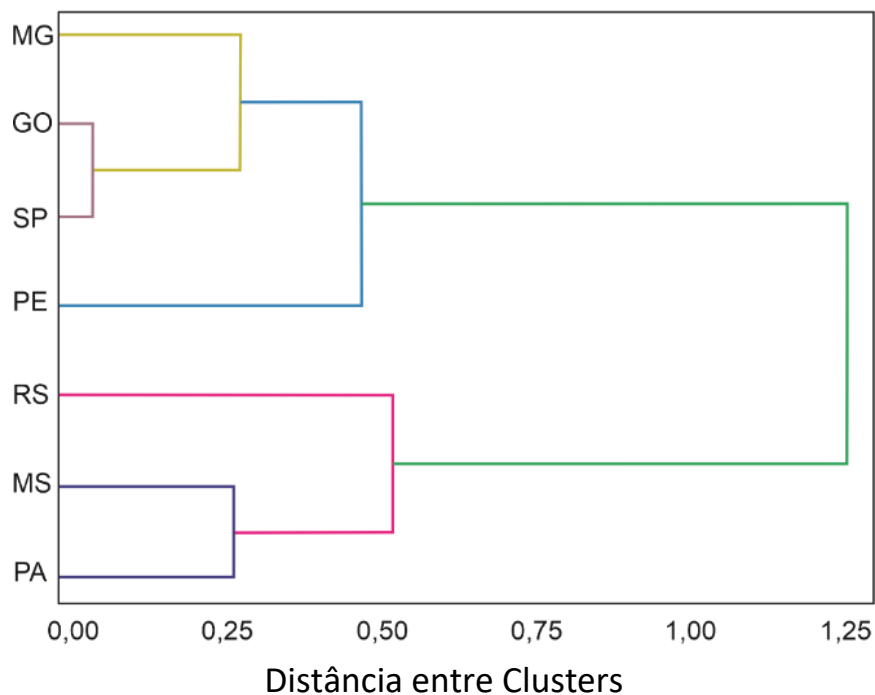


Figura 28. Dendrograma da composição multielementar da carne bovina dos biomas Amazônia, Cerrado, Caatinga, Pampa e Pantanal

Todos os elementos químicos apresentaram significância estatística ($p < 0,05$) para discriminar as amostras de carne bovina pela origem geográfica. Foi estabelecida a importância relativa das variáveis (elementos químicos) e ordenadas conforme a sua importância utilizando o valor de qui-quadrado (X^2), conforme Figura 29.

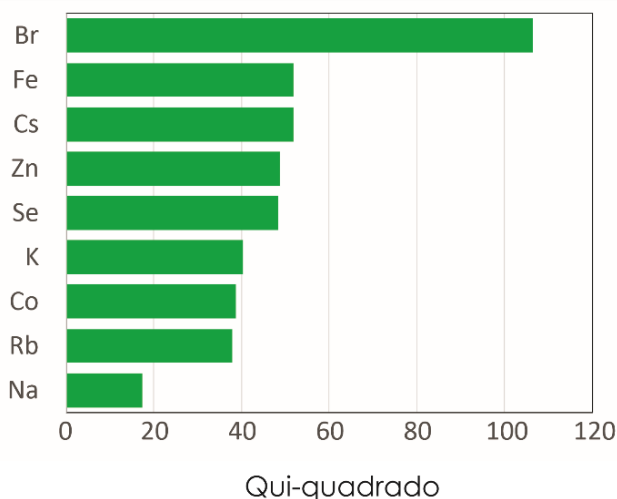


Figura 29. Importância relativa das variáveis para discriminar a carne bovina dos biomas brasileiros

A maior importância foi obtida para o elemento Br. Nove subconjuntos de variáveis foram gerados e depois usados para estabelecer os modelos de classificação. Partindo da informação obtida das análises exploratórias multivariadas, foram utilizados três algoritmos de classificação supervisionados (MLP, RF e CART), visando estabelecer modelos de classificação para as amostras procedentes de cada local analisado.

A Tabela 12 mostra os subconjuntos de variáveis criados juntamente com a acurácia geral obtida pelos modelos de classificação MLP, RF e CART. Aparecem ressaltadas em negrito as melhores acurácias de classificação obtidas para cada modelo.

Tabela 12. Acurácia geral obtida pelos modelos de classificação utilizando subconjuntos de variáveis avaliadas pelo qui-quadrado

Subconjuntos	Elementos químicos	Acurácia (%)		
		MLP	RF	CART
Chi#1	Br	36	38	44
Chi#2	Br, Fe	46	49	47
Chi#3	Br, Fe, Cs	42	53	51
Chi#4	Br, Fe, Cs, Zn	51	59	56
Chi#5	Br, Fe, Cs, Zn, Se	61	64	58
Chi#6	Br, Fe, Cs, Zn, Se, K	61	73	60
Chi#7	Br, Fe, Cs, Zn, Se, K, Co	60	75	58
Chi#8	Br, Fe, Cs, Zn, Se, K, Co, Rb	70	77	61
Chi#9	Br, Fe, Cs, Zn, Se, K, Co, Rb, Na	67	78	58

MLP - Multilayer Perceptron; RF - Random Forest; CART - Classification and Regression Tree

Com a inclusão de mais variáveis (elementos químicos) consideradas pelos algoritmos, o número de amostras classificadas corretamente por bioma aumentou, obtendo um valor máximo de acurácia geral de classificação de 78 % quando o algoritmo RF foi implementado.

A Tabela 13 mostra as respectivas matrizes de confusão geradas por cada algoritmo, considerando o subconjunto com maior acurácia de classificação, MLP (Chi#8), RF (Chi#9) e CART (Chi#8) da Tabela 12. A acurácia de classificação obtida implementando MLP, RF e CART foram, respectivamente, 97 %, 97 % e 95 % para Amazônia, 97 %, 97 % e 94 % para Caatinga e 91 %, 95 % e 91 % para Pampa. Os valores de acurácia das amostras dos três biomas foram superiores à acurácia geral obtida para cada modelo (Tabela 12).

Tabela 13. Matriz de confusão gerada pelos modelos de classificação CART, MLP e RF para discriminação da carne bovina dos biomas brasileiros

MLP							
GO	MG	MS	PA	PE	RS	SP	← classificado como
18	4	0	0	0	0	3	GO
3	16	2	0	0	1	3	MG
0	4	14	0	0	3	4	MS
0	0	0	23	0	2	0	PA
0	0	0	2	20	3	0	PE
0	0	3	1	0	20	1	RS
5	7	0	0	0	1	12	SP

RF							
GO	MG	MS	PA	PE	RS	SP	← classificado como
24	0	1	0	0	0	0	GO
3	14	3	0	0	1	4	MG
0	5	16	0	0	1	3	MS
0	0	0	24	0	1	0	PA
0	0	0	0	22	0	3	PE
0	2	1	0	0	22	0	RS
2	7	1	0	0	1	14	SP

CART							
GO	MG	MS	PA	PE	RS	SP	← classificado como
16	5	3	0	0	0	1	GO
2	8	3	0	0	0	12	MG
4	1	15	0	0	0	5	MS
0	0	0	22	0	3	0	PA
0	6	0	0	15	0	4	PE
0	1	1	5	0	14	4	RS
5	4	0	0	1	1	14	SP

De acordo com o algoritmo RF, não houve falso positivo para amostras do bioma Amazônia. Uma amostra da Amazônia foi classificada erroneamente como pertencente ao bioma Pampa. Para os algoritmos MLP e RF, não houve falso positivo para amostras do bioma Caatinga. Entre as amostras do bioma Cerrado, as correspondentes a Goiás foram as melhores classificadas implementando o MLP, sendo classificadas corretamente 18 e erroneamente 4

como pertencentes ao Cerrado (MG) e 3 como pertencentes ao Cerrado (SP). Três amostras do Cerrado (MG) e 5 do Cerrado (SP) foram classificadas como Cerrado (GO). Os menores acertos foram obtidos para Cerrado (MG) e Cerrado (SP), sendo corretamente classificadas 16 e 12 amostras, respectivamente. Considerando as 75 amostras destes três estados, implementando MLP (Chi#8), RF (Chi#9) e CART (Chi#8), foram classificadas corretamente 46 amostras (61 %), 52 amostras (69 %) e 38 amostras (51 %), respectivamente. Este resultado corrobora o observado na análise das Figura 27 e 28, em que foi observada menor distância entre os grupos de amostras procedentes destes 3 estados, que se encontram no bioma Cerrado [174].

O aumento do número de classes a serem classificadas, assim como de variáveis utilizadas, faz com que sejam necessários tamanhos amostrais maiores para poder obter coeficientes de generalização aceitáveis [126]. Quanto maior o número de classes, espera-se maior complexidade da função de ativação. Investigando a composição multielementar de méis brasileiros produzidos em quatro macrorregiões do Brasil para estabelecer modelos de classificação geográfica utilizando aprendizado de máquina foi obtida maior acurácia de classificação comparando cada região contra as demais (é ou não daquela região) do que comparando todas as regiões entre si [121]. Assim, aqui neste trabalho, uma abordagem similar poderia mostrar um incremento na acurácia de classificação. O número de classes (7 estados) foi reduzido para dois (cada estado contra os demais). Dessa forma, teria um modelo de classificação para carne bovina procedente de cada local estudado. Foi determinada a importância das variáveis utilizadas para a discriminação da carne bovina procedente de cada estado utilizando o valor de qui-quadrado (X^2), conforme Figura 30. As barras verdes representam os elementos que apresentaram diferença estatisticamente significativa ($p < 0,05$) entre amostra de cada estado comparada com os demais estados.

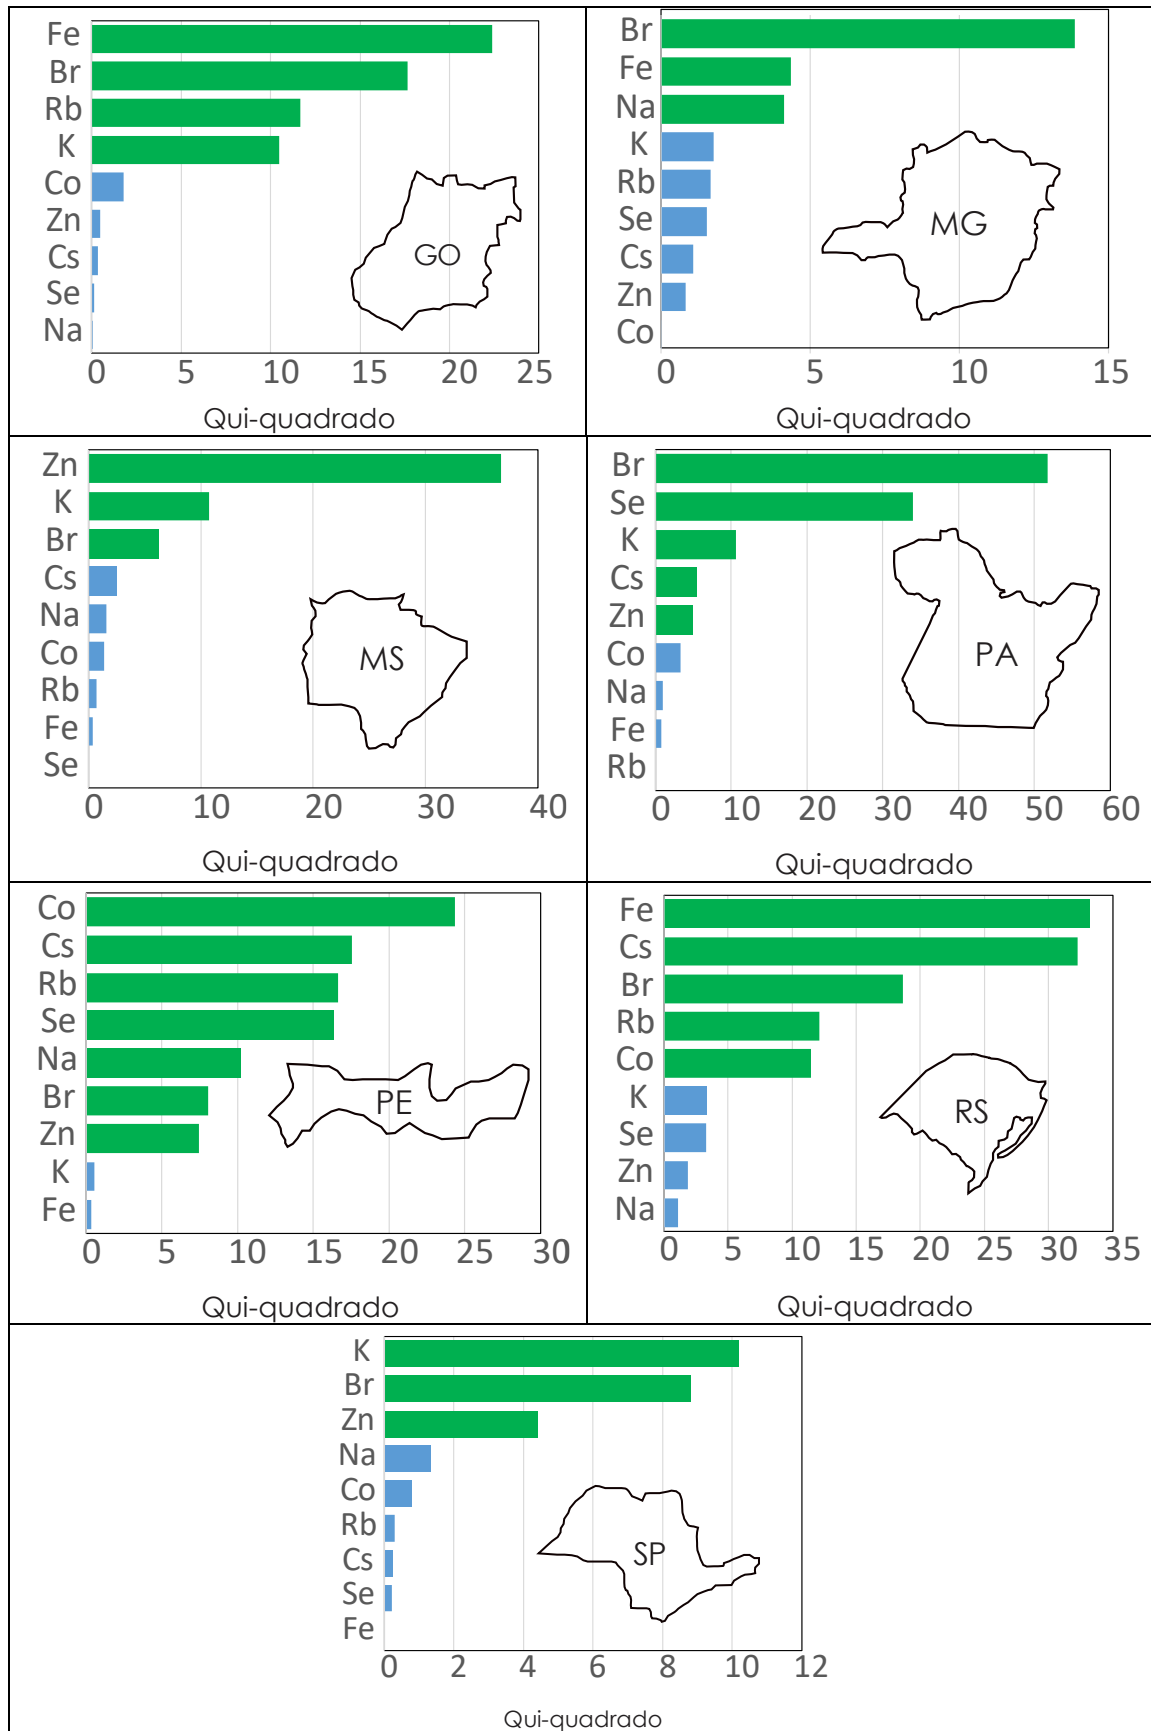


Figura 30. Importância das variáveis para discriminar a carne bovina dos sete estados estudados. As barras verdes representam os elementos que apresentaram diferença estatisticamente significativa entre as classes ($p < 0,05$) e as azuis os elementos que não apresentaram diferença estatisticamente significativa entre as classes ($p > 0,05$)

Quando feita a análise de comparação entre os 7 estados, foi observada diferença estatisticamente significativa ($p < 0,05$) para todos os elementos químicos. Com a diminuição do número de classes, foi possível avaliar quais os elementos que diferenciam a carne bovina de cada estado. As amostras procedentes de PA, MS, RS e PE apresentaram os maiores valores de qui quadrado (X^2), mostrando maior diferença na composição química da carne bovina destes estados quando comparada com os restantes. O maior número de elementos químicos que apresentaram diferença significativa na composição da carne foi obtido nas amostras procedentes de PE (Fe, Cs, Br, Rb e Co), PA (Br, Se, K, Cs e Zn) e RS (Fe, Cs, Br, Rb e Co).

Após organizar as variáveis em ordem decrescente de importância para discriminação da origem da carne bovina, foram gerados 9 subconjuntos de dados para cada local estudado. A Tabela 14 mostra os respectivos valores de acurácia obtidos por cada modelo em cada subconjunto gerado. Os números assinalados em negrito representam os melhores valores de acurácia de classificação obtidos empregando o menor número de elementos químicos para a discriminação. Utilizando esta estratégia de comparação de amostras de cada estado com as que não são do estado, foram obtidos modelos de classificação com, no mínimo, 20 pontos percentuais de acurácia a mais (Tabela 12). Este incremento pode ser justificado pelo efeito das variações da importância dos elementos químicos (Figuras 29 e 30). Como exemplo, na comparação entre os 7 estados, o Co foi colocado como sétimo na ordem de importância (Figura 29), porém, foi o mais importante elemento de discriminação de amostras da Caatinga (PE) (Figura 30).

Tabela 14. Acurácia de classificação do Multilayer Perceptron (MLP), Random Forest (RF) e Classification and Regression Tree (CART) usando subconjuntos de variáveis baseados no valor de qui-quadrado

GO ou NGO				MG ou NMG			
	Acurácia %				Acurácia %		
	MLP	RF	CART		MLP	RF	CART
Fe	86,9	81,2	86,9	Br	84,4	75,6	82,5
Fe, Br	87,5	85,6	86,3	Br, Fe	84,4	80,0	82,5
Fe, Br, Rb	85,0	89,4	87,5	Br, Fe, Na	81,9	83,8	85,0
Fe, Br, Rb, K	87,5	92,5	87,5	Br, Fe, Na, K	80,6	85,6	85,6
Fe, Br, Rb, K, Co	88,1	96,3	90,6	Br, Fe, Na, K, Rb	86,3	85,0	85,0
Fe, Br, Rb, K, Co, Zn	88,1	96,9	90,6	Br, Fe, Na, K, Rb, Se	83,8	85,6	84,4
Fe, Br, Rb, K, Co, Zn, Cs	89,4	96,9	91,9	Br, Fe, Na, K, Rb, Se, Cs	83,1	87,5	84,4
Fe, Br, Rb, K, Co, Zn, Cs, Se	91,3	97,5	91,9	Br, Fe, Na, K, Rb, Se, Cs, Zn	88,1	87,5	84,4
Fe, Br, Rb, K, Co, Zn, Cs, Se, Na	91,9	96,9	91,9	Br, Fe, Na, K, Rb, Se, Cs, Zn, Co	90,0	88,8	85,6
MS ou NMS				PA ou NPA			
	Acurácia %				Acurácia %		
	MLP	MLP	MLP		MLP	MLP	MLP
Zn	88,1	82,5	89,4	Br	89,4	88,1	87,5
Zn, K	86,9	85,0	89,4	Br, Se	95,6	94,4	94,4
Zn, K, Br	88,1	89,4	89,4	Br, Se, K	95,6	95,5	94,4
Zn, K, Br, Cs	88,8	89,4	89,4	Br, Se, K, Cs	96,3	96,9	93,8
Zn, K, Br, Cs, Na	90,0	90,0	90,0	Br, Se, K, Cs, Zn	99,4	95,6	93,8
Zn, K, Br, Cs, Na, Co	90,0	89,4	89,4	Br, Se, K, Cs, Zn, Co	99,4	96,9	93,8
Zn, K, Br, Cs, Na, Co, Rb	86,9	90,6	89,4	Br, Se, K, Cs, Zn, Co, Na	98,8	95,0	94,4
Zn, K, Br, Cs, Na, Co, Rb, Fe	89,4	91,3	89,4	Br, Se, K, Cs, Zn, Co, Na, Fe	97,5	96,3	94,4
Zn, K, Br, Cs, Na, Co, Rb, Fe, Se	86,9	91,9	89,4	Br, Se, K, Cs, Zn, Co, Na, Fe, Rb	97,5	96,9	94,4

Continua

Continuação							
PE or NPE				RS or NRS			
	Acurácia %				Acurácia %		
	MLP	MLP	MLP		MLP	MLP	MLP
Co	94,4	95,0	95,6	Fe	83,1	86,3	83,8
Co, Cs	94,4	96,9	95,6	Fe, Cs	85,0	89,4	86,3
Co, Cs, Rb	95,0	96,9	95,6	Fe, Cs, Br	91,3	90,0	88,8
Co, Cs, Rb, Se	96,3	96,9	95,6	Fe, Cs, Br, Rb	91,3	93,8	88,1
Co, Cs, Rb, Se, Na	96,9	97,5	95,6	Fe, Cs, Br, Rb, Co	93,8	93,1	88,1
Co, Cs, Rb, Se, Na, Br	98,8	97,5	95,6	Fe, Cs, Br, Rb, Co, K	89,4	91,9	88,1
Co, Cs, Rb, Se, Na, Br, Zn	96,9	98,1	95,6	Fe, Cs, Br, Rb, Co, K, Se	92,5	93,8	88,1
Co, Cs, Rb, Se, Na, Br, Zn, K	96,9	98,1	95,6	Fe, Cs, Br, Rb, Co, K, Se, Zn	92,5	94,4	88,1
Co, Cs, Rb, Se, Na, Br, Zn, K, Fe	96,3	98,1	95,6	Fe, Cs, Br, Rb, Co, K, Se, Zn, Na	90,0	93,8	88,1
SP ou NSP							
	Acurácia %						
	MLP	MLP	MLP				
K	83,1	70,0	83,1				
K, Br	81,9	87,5	85,0				
K, Br, Zn	81,9	86,9	83,1				
K, Br, Zn, Na	81,9	87,5	81,3				
K, Br, Zn, Na, Co	80,0	86,3	81,9				
K, Br, Zn, Na, Co, Rb	80,6	88,8	82,5				
K, Br, Zn, Na, Co, Rb, Cs	83,1	88,8	81,9				
K, Br, Zn, Na, Co, Rb, Cs, Se	79,4	89,4	83,1				
K, Br, Zn, Na, Co, Rb, Cs, Se, Fe	78,1	88,1	83,8				

A Tabela 15 mostra os melhores conjuntos de dados para discriminação da carne bovina e os respectivos valores de acurácia obtidos por cada modelo. Os números assinalados em negrito representam os melhores valores de acurácia de classificação obtidos empregando o menor número de elementos químicos para a discriminação.

Tabela 15. Desempenho de classificação (Acurácia %) obtido implementando os modelos Multilayer Perceptron (MLP), Random Forest (RF) e Classification and Regression Tree (CART).

	Acurácia (%)		
	MLP	RF	CART
Goiás	92 Fe, Br, Rb, K, Co, Zn, Cs, Se, Na	98 Fe, Br, Rb, K, Co, Zn, Cs, Se	92 Fe, Br, Rb, K, Co, Zn, Cs
Minas Gerais	90 Br, Fe, Na, K, Rb, Se, Cs, Zn, Co	89 Br, Fe, Na, K, Rb, Se, Cs, Zn, Co	86 Br, Fe, Na, K
Mato Grosso do Sul	90 Zn, K, Br, Cs, Na	92 Zn, K, Br, Cs, Na	90 Zn, K, Br, Cs, Na
Pará	99 Br, Se, K, Cs, Zn	97 Br, Se, K, Cs	94 Br, Se
Pernambuco	99 Co, Cs, Rb, Se, Na, Br	98 Co, Cs, Rb, Se, Na, Br, Zn	96 Co
Rio Grande do Sul	93 Fe, Cs, Br, Rb, Co	94 Fe, Cs, Br, Rb	89 Fe, Cs, Br
São Paulo	83 K	89 K, Br, Zn, Na, Co, Rb, Cs, Se	85 K, Br

O modelo CART utilizando somente as frações de massa de Co classificou corretamente 96 % das amostras da Caatinga (PE) e implementando o modelo MLP, considerando as frações de massa de Co, Cs, Rb, Se, Na e Br, a acurácia alcançou 99 %. Para classificação da carne proveniente da Amazônia (PA), implementando o MLP com as frações de massa de Br, Se, K, Cs e Zn foram classificadas corretamente 99 % das amostras. A Figura 31 mostra os modelos de árvore gerados pelo CART para discriminação das amostras de carne bovina procedentes da Caatinga (PE) e da Amazônia (PA), com acurácia de classificação de 95 % e 94 %, respectivamente.

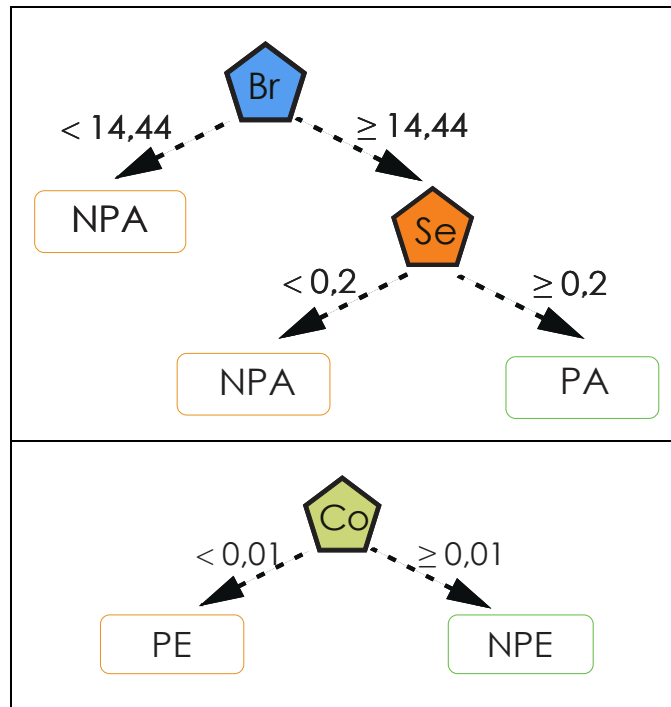


Figura 31. Árvore de decisão obtida com as frações de massa (mg kg^{-1}) de Br, Co e Se implementando o modelo CART para discriminação da carne bovina dos biomas Amazônia (PA) e Caatinga (PE)

Para obter o modelo de classificação gerado pelo CART para amostras de carne bovina do PA, foram utilizadas 104 amostras de NPA, das quais 2 foram classificadas incorretamente, e 14 amostras do PA, sendo que nenhuma foi classificada incorretamente. O modelo obtido foi testado utilizando 46 amostras de NPA e 11 amostras do PA, das quais 3 foram classificadas incorretamente. O modelo CART para discriminar amostras de carne bovina procedentes de PE foi treinado utilizando 104 amostras NPE (das quais 2 foram classificadas incorretamente) e 14 amostras de PE (das quais 3 foram classificadas incorretamente). O modelo foi testado utilizando 46 amostras de NPE e 11 amostras de PE, das quais 2 foram classificadas de forma incorreta.

Outras regiões com valores de acurácia acima de 94 % foram Cerrado (GO) implementando o RF com as frações de massa de Fe, Br, Rb, K, Co, Zn, Cs e Se (98 %) e Pampa (RS) com as frações de massa de Fe, Cs, Br e Rb (94 %). Menores valores de acurácia foram obtidos para amostras procedentes do Cerrado (MG) e Cerrado (SP). Ainda assim, os valores foram, no mínimo, 10 pontos percentuais superiores aos obtidos quando comparados todos os estados entre si. Novamente, foi observada sobreposição entre as características de amostras provenientes destes estados. Exceto para amostras do Cerrado (GO) e Cerrado (SP), foram obtidas maiores acurácias de classificação quando implementado o modelo gerado pelo MLP. A Tabela 16 mostra as matrizes de confusão de maior acurácia geradas pelos modelos

MLP e RF para classificação de amostras do Cerrado (GO), Cerrado (MG), Pantanal (MS), Amazônia (PA), Caatinga (PE), Pampa (RS) e Cerrado (SP).

Tabela 16. Matrizes de confusão de maior acurácia geradas pelos modelos Multilayer Perceptron (MLP) e Random Forest (RF)

Goiás					
MLP			RF		
NGO	GO	← classificado como	NGO	GO	← classificado como
142	8	NGO	149	1	NGO
6	19	GO	3	22	GO
Cs, Se, Na			Cs, Se		
Minas Gerais					
MLP			RF		
NMG	MG	← classificado como	NMG	MG	← classificado como
143	7	NMG	145	5	NMG
10	15	MG	15	10	MG
Br, Fe, Na, K, Rb, Se, Cs, Zn, Co			Br, Fe, Na, K, Rb, Se, Cs, Zn, Co		
Mato Grosso do Sul					
MLP			RF		
NMS	MS	← classificado como	NMS	MS	← classificado como
140	10	NMS	143	7	NMS
8	17	MS	10	15	MS
Zn, K, Br, Cs, Na			Zn, K, Br, Cs, Na		
Pará					
MLP			RF		
NPA	PA	← classificado como	NPA	PA	← classificado como
149	1	NPA	148	2	NPA
0	25	PA	3	22	PA
Br, Se, K, Cs, Zn			Br, Se, K, Cs		

Continua

Continuação								
Pernambuco								
MLP			RF					
NPE	PE	← classificado como	NPE	PE	← classificado como			
150	0	NPE	150	0	NPE			
2	23	PE	3	22	PE			
Co, Cs, Rb, Se, Na, Br			Co, Cs, Rb, Se, Na, Br, Zn					
Rio Grande do Sul								
MLP			RF					
NRS	RS	← classificado como	NRS	RS	← classificado como			
145	5	NRS	149	1	NRS			
5	20	RS	9	16	RS			
Fe, Cs, Br, Rb, Co			Fe, Cs, Br, Rb					
São Paulo								
MLP			RF					
NSP	SP	← classificado como	NRS	RS	← classificado como			
140	10	NSP	143	7	NSP			
20	5	SP	13	12	SP			
K			K, Br, Zn, Na, Co, Rb, Cs, Se					

Implementando o MLP, todas as amostras da Amazônia (PA) foram classificadas corretamente, com apenas uma amostra não-Amazônia (NPA) sendo classificada incorretamente como amostra da Amazônia (PA). No modelo RF, 5 amostras foram classificadas incorretamente, sendo 2 amostras de NPA classificadas como PA e 3 PA como NPA. Para os modelos MLP e RF, nenhuma amostra do NPE foi classificada como de PE, sendo classificadas incorretamente 2 amostras (MLP) e 3 amostras (RF). A pior classificação foi obtida pelo modelo MLP para discriminação da carne bovina procedente de SP, sendo que somente 5 das 25 amostras procedentes de SP foram corretamente classificadas.

A Figura 32 mostra a grande dispersão das frações de massa de Br e Se nas amostras de carne bovina procedentes do Pará, sendo maior que a dispersão das amostras dos restantes seis estados. Alguns estudos têm mostrado frações de massas elevadas de Se em alimentos, como a castanha do Brasil produzida no Pará [175]. Estas frações de massa apresentam variações ainda dentro do próprio bioma Amazônia, tanto no solo como nas castanhas [176, 177]. Por outro

lado, estudos apontam a influência do aerossol marinho e da queimada de biomassa no incremento das frações de massa de Br na forma de aerossol na Amazônia [171, 172, 178, 179].










Figura 32. Dispersão de Br e Se para discriminação de amostras de carne bovina procedentes do Pará

Em geral, foram obtidos modelos de classificação com desempenho acima de 90 % para discriminar amostras dos biomas Amazônia (PA), Caatinga (PE), Cerrado (GO), Cerrado (MG), Cerrado (SP), Pampa (RS) e Pantanal (MS) [180]. Esses modelos podem ser aprimorados considerando outros fatores além da origem geográfica que afetam a composição da carne bovina, como idade, sexo, genética e nutrição [69, 70].

4.5 Rastreabilidade da carne bovina do bioma Cerrado

Foram determinados os elementos Br, Co, Cs, Fe, K, Na, Rb, Se e Zn em amostras de carne bovina procedentes dos municípios Itápolis – SP (n = 10), Piracanjuba – GO (n = 10), Planura-MG (n = 10), Ponta Porã - MS (n = 10) e Rondonópolis – MT (n = 10), todos localizados no bioma Cerrado. A Figura 33 mostra o Diagrama de Caixas das frações de massa dos elementos químicos determinados.






Figura 33. Distribuição das frações de massa dos elementos químicos determinados em amostras procedentes dos municípios Itápolis SP (IT, n = 10), Piracanjuba GO (PI, n = 10), Planura MG (PL, n = 10), Ponta Porã MS (PP, n = 10) e Rondonópolis MT (RM, n = 10)

Mesmo tendo sido encontradas diferenças estatisticamente significativas ($p < 0,05$) entre as frações de massa dos elementos Br, Co, Cs, Na, Rb e Se (Figura 34), quando utilizadas para gerar os algoritmos CART, MLP, NB, RF e SMO, acurácias de classificação de 38 %, 60 %, 54 %, 58 % e 68 %, respectivamente, foram obtidas para discriminar a origem das amostras.




Figura 34. Importância das variáveis para discriminar a carne bovina procedente de cada cidade do bioma Cerrado. As barras verdes representam os elementos que apresentaram diferença estatisticamente significativa entre as classes ($p < 0,05$) e as azuis os elementos que não apresentaram diferença estatisticamente significativa entre as classes ($p > 0,05$)

As amostras analisadas encontram-se em regiões do bioma Cerrado, com mesmo nível de desenvolvimento tecnológico para a criação de gado de corte [48] e distribuição do uso da terra [181]. A similaridade no perfil agrometalômico das amostras de carne bovina procedentes das diferentes regiões do bioma Cerrado refletem as condições similares de criação do gado.

Foram utilizadas as amostras de carne bovina procedentes dos municípios de Itápolis - SP ($n = 10$), Piracanjuba - GO ($n = 10$), Planura - MG ($n = 10$), Ponta Porã - MS ($n = 10$) e Rondonópolis - MT ($n = 10$), juntamente com as amostras de Goiás ($n = 25$), Minas Gerais ($n = 25$) e São Paulo ($n = 25$), para obter o perfil agrometalômico das amostras de carne bovina procedentes do bioma Cerrado e gerar modelos de classificação. A melhor acurácia de classificação (95 %) foi obtida implementando o modelo MLP utilizando as frações de massa de Br, Cs, Fe, K, Na, Rb e Zn.

4.6 Influência do corte, grupo genético e sexo

Foi implementado o teste Fatorial ANOVA e não foi observada interação significativa ($p > 0,05$) entre corte, grupo genético e sexo (Tabela 17), permitindo analisar os fatores de forma independente.

Tabela 17. Efeitos de interação entre sexo (S), grupo genético (GG) e corte (C) usando ANOVA fatorial

Interações	<i>p</i> valor considerando a soma de quadrado tipo III								
	Br	Co	Cs	Fe	K	Na	Rb	Se	Zn
GG*S	0,8179	0,4438	0,9494	0,2005	0,6092	0,0939	0,8100	0,7097	0,8517
GG*C	0,3948	0,1383	0,9325	0,5860	0,6526	0,1504	0,8097	0,4197	0,7042
S*C	0,9868	0,5021	0,8917	0,1546	0,3187	0,5753	0,3848	0,8981	0,4119
GG*S*C	0,6551	0,0968	0,6167	0,4453	0,5656	0,1540	0,6356	0,9329	0,5045

GG– Grupo genético, S – Sexo, C - Corte

A Tabela 18 mostra as frações de massa de Br, Co, Cs, Fe, K, Na, Rb, Se e Zn, e as diferenças estatisticamente significativas empregando teste de comparação de Kruskal-Wallis com nível de significância de 0,05. Para todos os elementos químicos, as distâncias mínimas significativas (MSD) para comparação entre os cortes foram maiores do que as de grupo genético (Br: 7 %; Co: 31 %; Cs: 31 %; Fe: 16 %; K: 30 %; Na: 25 %; Rb: 24 %; Se: 33 % e Zn: 15 %) e sexo (Br: 6 %; Co: 33 %; Cs: 30 %; Fe: 16 %; K: 31 %; Na: 26 %; Rb: 33 %; Se: 3 % e Zn: 20 %). As diferenças da composição média entre os cortes (acém, contrafilé e picanha) foram maiores que as diferenças entre sexo (macho e fêmea) e grupo genético (½ Nelore - ½ Angus e ¼ Nelore - ¼ Angus - ½ Wagyu).

As frações de massa dos elementos químicos nas amostras de animais machos foram superiores às encontradas nas fêmeas. As frações de massa nas amostras procedentes de animais ½ Nelore - ½ Angus foram superiores às de ¼ Angus - ¼ Nelore - ½ Wagyu. Com exceção de K e Zn, os demais elementos químicos (Br, Co, Cs, Fe, Na, Se e Rb) apresentaram maiores frações de massa no corte de picanha. As maiores diferenças estatísticas entre os cortes foram observadas para fração de massa de Br e Fe ($p < 0,0001$). Todos os elementos químicos apresentaram diferenças estatisticamente significativas ($p < 0,05$) entre o corte de acém e o de contrafilé. Co, Na, Rb e Se não apresentam diferenças estatisticamente significativas entre o acém e a picanha, enquanto Cs, K, Rb e Zn não apresentam diferenças estatisticamente significativas ($p > 0,05$) entre o contrafilé e a picanha. É interessante notar que as maiores diferenças estatísticas foram observadas entre o acém (quarto dianteiro) e a picanha (quarto traseiro).

Tabela 18. Frações de massa médias de Br, Co, Cs, Fe, K, Na, Rb, Se e Zn, e diferenças estatisticamente significativas (SSD) empregando teste de comparação de Kruskal-Wallis com nível de significância de 0,05.

Analito		Corte			Grupo Genético		Sexo	
		Acém (n=41)	Contrafilé (n=78)	Picanha (n=77)	½ Angus x ½ Nelore (n=37)	¼ Angus x ¼ Nelore x ½ Wagyu (n=41)	Macho (n=46)	Fêmea (n=32)
Br	Média ± SD	1,6 ± 0,2	1,3 ± 0,1	1,9 ± 0,1	1,6 ± 0,3	1,5 ± 0,2	1,6 ± 0,2	1,5 ± 0,3
	SSD	Y	Z	X	X	X	X	X
	MSD	0,1464			0,1372		0,1377	
Co	Média ± SD	0,009 ± 0,005	0,008 ± 0,002	0,014 ± 0,007	0,011 ± 0,006	0,009 ± 0,003	0,011 ± 0,006	0,008 ± 0,003
	SSD	Y	Y	X	X	X	X	Y
	MSD	0,0039			0,0027		0,0026	
Cs	Média ± SD	0,11 ± 0,03	0,14 ± 0,03	0,15 ± 0,04	0,14 ± 0,04	0,12 ± 0,03	0,13 ± 0,04	0,12 ± 0,04
	SSD	Y	X	X	X	Y	X	Y
	MSD	0,0281			0,0193		0,0197	
Fe	Média ± SD	55 ± 11	47 ± 10	77 ± 15	61 ± 18	55 ± 14	60 ± 16	55 ± 15
	SSD	Y	Z	X	X	X	X	X
	MSD	10,168			8,4931		8,5536	
K	Média ± SD	8515 ± 1619	10296 ± 1976	10264 ± 1447	9890 ± 1709	9004 ± 1950	9797 ± 1676	8752 ± 2045
	SSD	Y	X	X	X	X	X	X
	MSD	1449,4			1010,6		999,29	
Na	Média ± SD	1261 ± 164	1227 ± 139	1533 ± 158	1377 ± 171	1254 ± 191	1359 ± 161	1228 ± 209
	SSD	Y	Y	X	X	Y	X	Y
	MSD	133,64			99,91		99,137	
Rb	Média ± SD	19 ± 4	22 ± 4	24 ± 5	22 ± 4	20 ± 5	22 ± 4	19 ± 5
	SSD	Y	XY	X	X	Y	X	X
	MSD	3,7154			2,8352		2,4939	
Se	Média ± SD	0,30 ± 0,05	0,33 ± 0,06	0,38 ± 0,06	0,35 ± 0,06	0,30 ± 0,06	0,34 ± 0,05	0,30 ± 0,07
	SSD	Y	Y	X	X	Y	X	Y
	MSD	0,0474			0,0319		0,0318	
Zn	Média ± SD	166 ± 29	118 ± 20	130 ± 14	144 ± 32	146 ± 34	154 ± 33	132 ± 28
	SSD	X	Y	Y	X	X	X	Y
	MSD	20,891			17,848		16,783	

O coeficiente de Cramer e o F-score foram calculados para obter a variável com maior poder discriminante (Figura 35). Essa é uma etapa crucial no processo de mineração de dados para identificar a variável mais importante a ser usada nos modelos de classificação [116]. As barras tracejadas mostram os elementos que apresentaram diferenças estatisticamente significativas ($p < 0,05$) e as barras pontilhadas os que não apresentam diferenças estatisticamente significativas ($p > 0,05$). Os mesmos elementos com diferenças estatisticamente significativas e de maior importância para classificação das classes sexo (Co, Cs, Na, Se e Zn) e grupo genético (Cs, Na, Se e Rb) foram obtidos implementando os métodos paramétricos (F-score) e não paramétricos (coeficiente de Cramer). Para discriminar entre os cortes de carne bovina, todos os elementos químicos apresentaram diferenças estatisticamente significativas para ambos os métodos. O coeficiente de Cramer varia de 0 (sem dependência entre os níveis dos fatores em estudo) a 1 (dependência total entre os níveis dos fatores em estudo), sendo 0,5 uma dependência considerável. Os cortes bovinos apresentaram dependência significativa das frações de massa de Br, Fe, Na e Zn, com coeficiente de Cramer superior a 0,5. As classes grupo genético e sexo não tiveram dependência significativa, considerando os valores do coeficiente de Cramer inferiores a 0,5.

Após calcular a importância relativa das variáveis usando o coeficiente de Cramer, 9 subconjuntos de variáveis foram gerados e, então, utilizados para estabelecer os modelos de classificação. A Tabela 19 mostra os subconjuntos de variáveis juntamente com a acurácia alcançada pelos modelos de classificação RF, SMO, NB, MLP e CART. A MANOVA foi usada para determinar os valores do F-score para os subconjuntos de dados gerados pela atribuição de seu poder discriminativo.

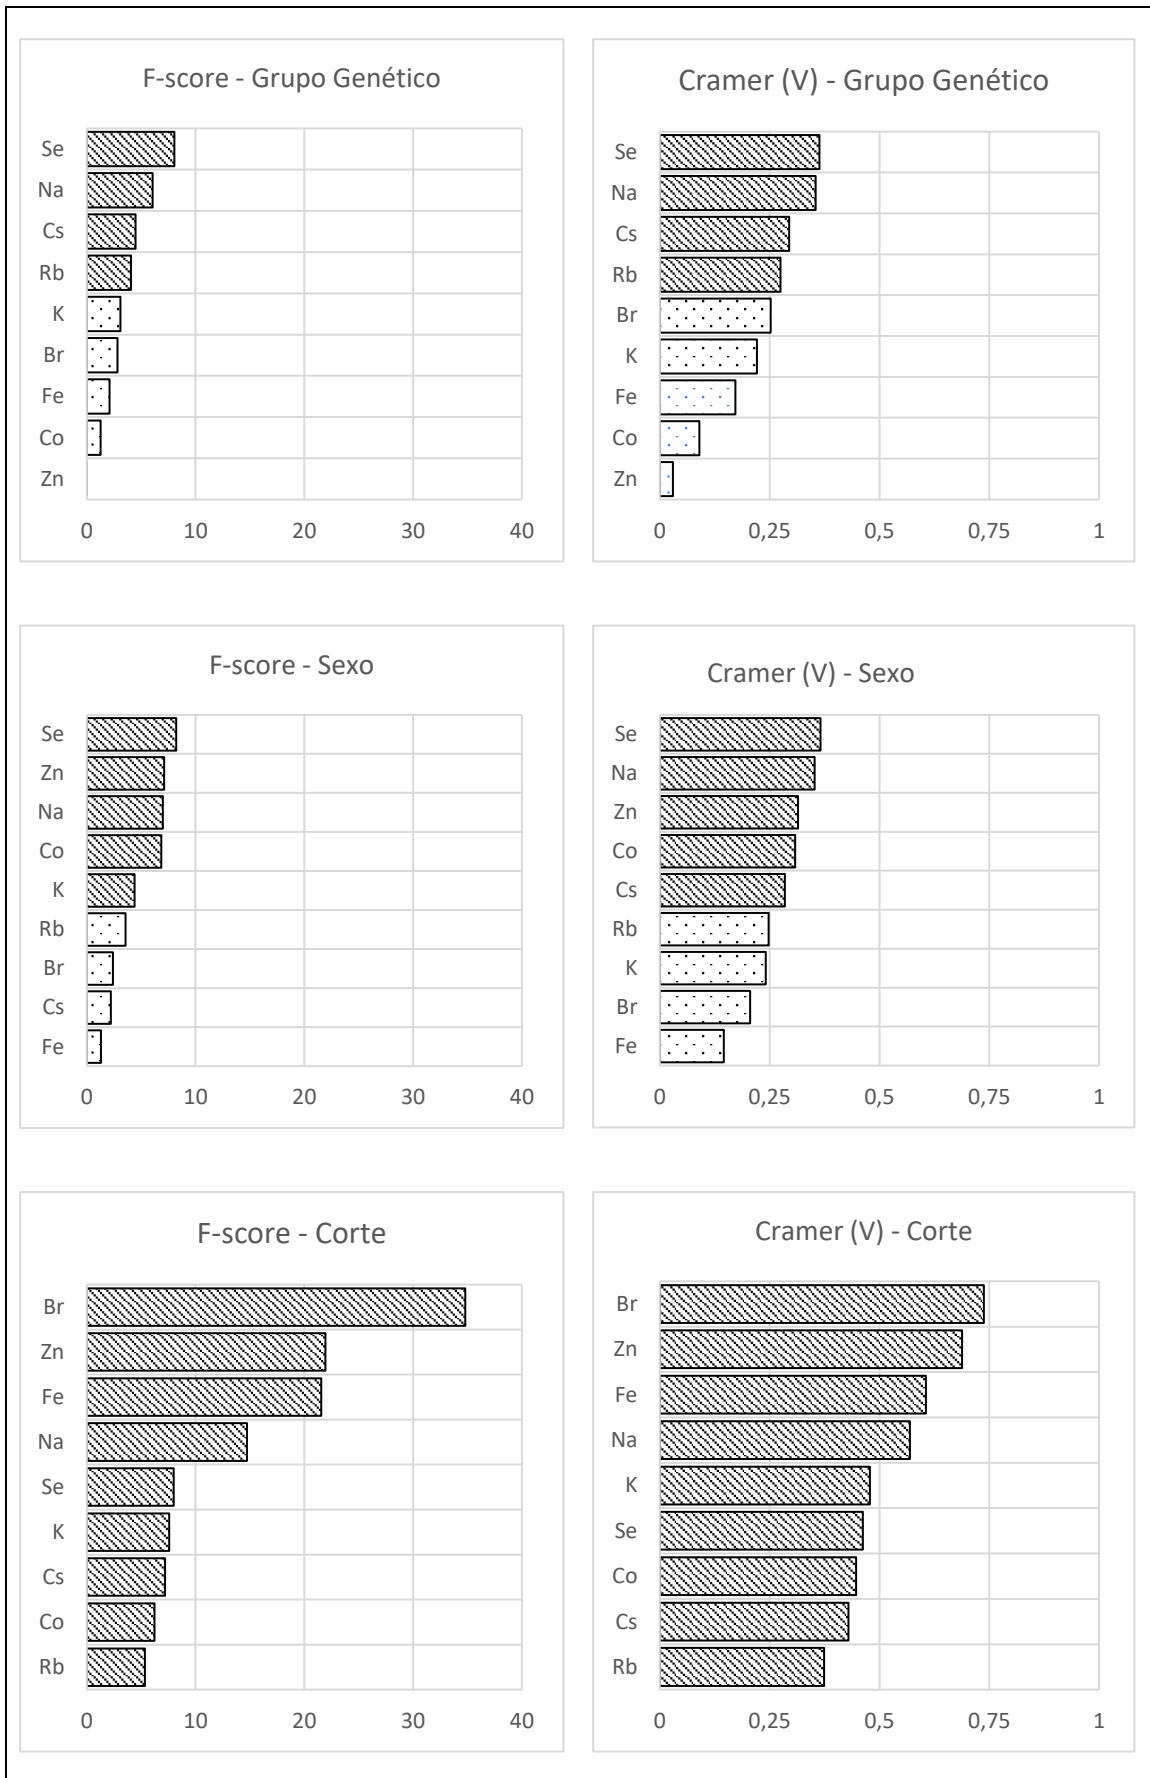


Figura 35. Importância relativa das variáveis (elementos químicos) para discriminar as classes (corte, grupo genético e sexo)

Tabela 19. Acurácia de classificação dos modelos empregando os subconjuntos de variáveis organizados considerando o valor do qui-quadrado

Subconjunto	Variáveis	Acurácia de classificação de corte (%)					MANOVA
		RF	SMO	MLP	NB	CART	F-score
Chi#1	Br	48	52	57	61	50	-
Chi#2	Br, Zn	77	63	80	77	70	36,39
Chi#3	Br, Zn, Fe	79	68	84	84	68	34,68
Chi#4	Br, Zn, Fe, Na	82	77	91	75	68	30,24
Chi#5	Br, Zn, Fe, Na, K	91	89	96	80	70	31,95
Chi#6	Br, Zn, Fe, Na, K, Se	89	95	96	86	70	27,69
Chi#7	Br, Zn, Fe, Na, K, Se, Co	89	95	91	82	70	23,92
Chi#8	Br, Zn, Fe, Na, K, Se, Co, Cs	91	91	95	82	70	22,84
Chi#9	Br, Zn, Fe, Na, K, Se, Co, Cs, Rb	88	91	95	85	70	20,06

Subconjunto	Variáveis	Acurácia de classificação de grupo genético (%)					MANOVA
		RF	SMO	MLP	NB	CART	F-score
Chi#1	Se	66	68	74	68	68	-
Chi#2	Se, Na	47	68	68	68	68	4,22
Chi#3	Se, Na, Cs	53	68	64	63	68	2,76
Chi#4	Se, Na, Cs, Rb	63	68	68	61	68	2,05
Chi#5	Se, Na, Cs, Rb, Br	63	63	63	68	68	1,62
Chi#6	Se, Na, Cs, Rb, Br, K	58	63	45	63	68	1,59
Chi#7	Se, Na, Cs, Rb, Br, K, Fe	58	63	45	63	68	1,50
Chi#8	Se, Na, Cs, Rb, Br, K, Fe, Co	57	58	55	63	68	1,34
Chi#9	Se, Na, Cs, Rb, Br, K, Fe, Co, Zn	59	63	54	63	68	1,23

Subconjunto	Variáveis	Acurácia de classificação de sexo (%)					MANOVA
		RF	SMO	MLP	NB	CART	F-score
Chi#1	Se	54	57	65	68	70	-
Chi#2	Se, Na	63	68	68	74	74	4,50
Chi#3	Se, Na, Zn	74	66	74	71	74	4,54
Chi#4	Se, Na, Zn, Co	74	70	59	79	74	3,70
Chi#5	Se, Na, Zn, Co, Cs	74	68	63	79	74	2,94
Chi#6	Se, Na, Zn, Co, Cs, Rb	61	68	73	68	59	2,40
Chi#7	Se, Na, Zn, Co, Cs, Rb, K	64	68	70	64	59	2,10
Chi#8	Se, Na, Zn, Co, Cs, Rb, K, Br	66	68	70	63	54	2,31
Chi#9	Se, Na, Zn, Co, Cs, Rb, K, Br, Fe	63	66	73	64	55	2,67

Os melhores valores de acurácia para diferenciar o grupo genético foram obtidos utilizando a fração de massa de Se: 74 % (MLP), 68 % (CART, NB e SMO) e 66 % (RF). Todos os modelos CART (Chi#1-Chi#9) e os modelos SMO (Chi#1-Chi#4) e NB (Chi#1, Chi#2 e Chi#5) tiveram o mesmo valor de acurácia (68 %). Para diferenciar o sexo, os melhores valores de acurácia foram 79 % implementando os modelos NB (Chi#4 e Chi#5), 74 % implementando os modelos CART (Chi#2- Chi#5), MLP (Chi#3) e RF (Chi#3 – Chi#5) e 70% usando o modelo SMO (Chi#4). Para discriminar o corte da carne bovina, os maiores valores de acurácia foram

obtidos tomando-se os subconjuntos Chi#5 e Chi#6 para implementar o método MLP (96 %), Chi#6 e Chi#7 para SMO (95 %), Chi#5 e Chi #8 para RF (91 %), Chi#6 para NB (86 %) e Chi#2, Chi#5- Chi#9 para CART (70 %). Esses valores de acurácia são 20 % superiores aos obtidos para a discriminação da carne bovina por grupo genético e sexo. Para os cortes bovinos, observou-se um aumento da acurácia com o aumento dos subconjuntos utilizados para a construção dos modelos. Isso pode ser atribuído ao fato que todos os elementos químicos determinados têm um potencial significativo para discriminar cortes bovinos (Figura 35). Para seis dos nove subconjuntos obtidos, o modelo CART apresentou desempenho de previsão igual com uma acurácia mínima de 50 % (Chi#1).

Para grupo genético e sexo, os valores de acurácia e F-score diminuíram ao incluir variáveis que possuem menor poder discriminativo. A acurácia da discriminação dos cortes aumentou do subconjunto Chi#1 para Chi#6 e depois diminuiu para Chi#9. O valor de F-score diminuiu do subconjunto Chi#1 para Chi#9. Diferenças no comportamento dos algoritmos de classificação e F-score para discriminação de corte estão relacionadas com a suposição de independência das variáveis (elementos químicos), o que não é válido para MANOVA. Apesar da suposição de independência, os modelos de classificação dão bons resultados para muitos conjuntos de dados de composição de alimentos [113, 118, 119, 121, 143, 173, 180]. Em geral, pode-se observar que os algoritmos de classificação implementados são menos sensíveis aos dados de ruído do que o MANOVA.

A Tabela 20 mostra a matriz de confusão obtida a partir dos modelos de classificação de cortes bovinos no subconjunto (Chi#5) com maior acurácia e considerando menor número de elementos químicos.

Tabela 20. Matriz de confusão obtida implementando os modelos MLP, NB, RF e SMO para discriminação de cortes de carne bovina.

RF ^a				MLP ^a			
A	B	C	← Classificado como	A	B	C	← Classificado como
77	0	0	A	77	0	0	A
0	63	15	B	0	71	7	B
0	3	38	C	0	0	41	C
SMO ^b				NB ^b			
A	B	C	← Classificado como	A	B	C	← Classificado como
71	3	3	A	75	0	2	A
0	75	3	B	0	60	18	B
0	0	41	C	0	8	33	C

^a: utilizando Br, Fe, K, Na, e Zn
^b: utilizando Br, Fe, K, Na, Se e Zn

A: Picanha; B: Contrafilé; C: Acém

Para a picanha, os modelos MLP e RF classificaram corretamente as 77 amostras, NB classificou corretamente 75 amostras e 2 como acém, e SMO classificou corretamente 71 amostras, 3 como acém e 3 como contrafilé. Para o contrafilé, MLP classificou corretamente 71 amostras, SMO classificou corretamente 75 amostras, NB e RF classificaram corretamente 60 e 63 amostras, respectivamente. A melhor classificação para o acém foi obtida pelo SMO e MLP, que classificaram corretamente as 41 amostras, enquanto RF classificou corretamente 38 amostras e NB classificou corretamente 33 amostras. Nenhuma amostra de acém ou contrafilé foi classificada como picanha por esses quatro algoritmos de classificação. De forma geral, foi observada maior confusão entre amostras de contrafilé e acém. A Tabela 21 mostra a performance de classificação dos modelos MLP, NB, RF e SMO para os conjuntos de dados que apresentaram maior acurácia geral.

Tabela 21. Desempenho de classificação dos modelos MLP, NB, RF e SMO para discriminação dos cortes de carne bovina picanha (A), contrafilé (B) e acém (C)

	RF	SMO	MLP	NB
	Br, Zn, Fe, Na, K	Br, Zn, Fe, Na, K, Se	Br, Zn, Fe, Na, K	Br, Zn, Fe, Na, K, Se
Acurácia A (%)	100	96	100	98
Acurácia B (%)	91	96	96	88
Acurácia C (%)	91	96	96	86
Precisão A (%)	100	100	100	100
Precisão B (%)	87	94	94	77
Precisão C (%)	90	94	97	86
Sensibilidade A (%)	100	82	100	91
Sensibilidade B (%)	81	94	94	81
Sensibilidade C (%)	93	100	97	86
Especificidade A (%)	100	96	100	100
Especificidade B (%)	95	98	98	90
Especificidade C (%)	89	93	96	85

Os modelos MLP e RF apresentaram melhor acurácia (100 %), precisão (100 %), sensibilidade (100 %) e especificidade (100 %) para classificação da picanha.

Para obter o modelo CART (Figura 36), 130 de 196 amostras foram usadas para treinar o algoritmo e 66 para testá-lo. Br e Zn foram usados para construir o modelo preditivo para classificar os cortes bovinos. De acordo com o modelo CART obtido para o subconjunto Chi#2, para fração de massa de Br $< 1,49$ mg/kg, as frações de massa de Zn definirão se é contrafilé ($< 156,7$ mg/kg) ou acém ($\geq 156,7$ mg/kg). Para fração de massa de Br $\geq 1,49$ mg/kg, as frações de massa de Zn definirão entre picanha (< 150 mg/kg) ou acém (≥ 150 mg/kg). Este modelo de classificação apresentou o melhor desempenho para o acém, classificando corretamente todas as amostras.

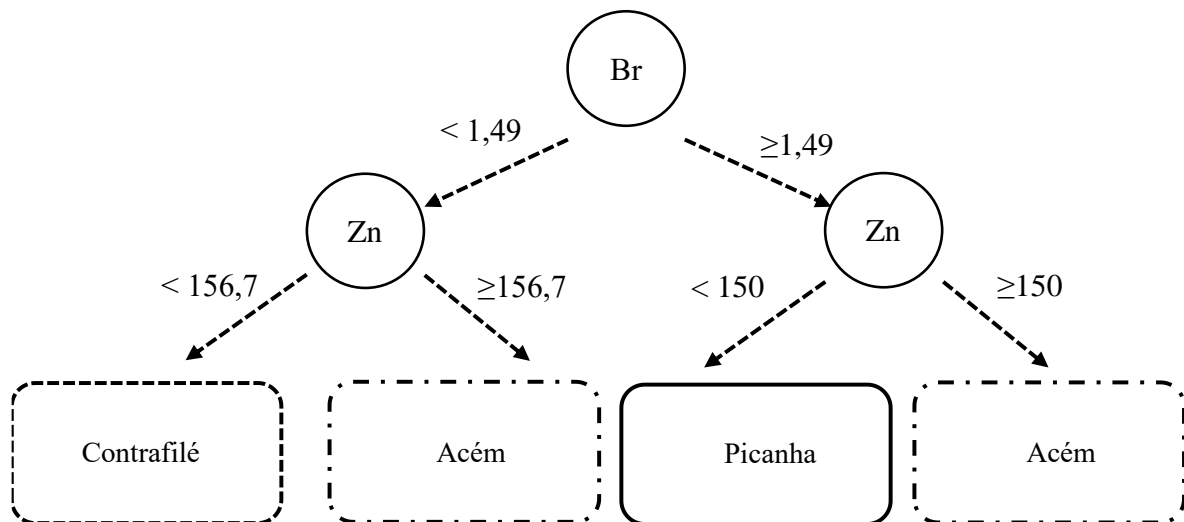



Figura 36. Regra de decisão gerada pelo modelo CART empregando o subconjunto Chi#2 para discriminação dos cortes de carne bovina

A Análise de Cluster da MANOVA foi construída com todas as variáveis (Chi#9) e com as variáveis F-score mais altas (Chi#2), obtendo-se o mesmo resultado (Figura 37). Os três cortes mostraram diferenças estatisticamente significativas ($p < 0,05$) entre si, porém, a distância euclidiana entre a picanha e o contrafilé implementando modelos multivariados é cinco vezes menor do que a distância euclidiana entre eles e o acém. Esses resultados mostram uma separação do quarto dianteiro do quarto traseiro.



Distância entre Clusters

Figura 37. Dendrograma obtido utilizando os subconjuntos Chi#1 e Chi#9 para discriminação dos cortes de carne bovina

Foi observada a viabilidade de combinar análise por ativação neutrônica e técnicas de mineração de dados para classificar carne bovina. Os elementos químicos que tiveram alta contribuição para a construção de modelos preditivos para autenticação de carne bovina foram Br, Fe, Na e Zn para corte, e Se e Na para sexo e grupo genético. Os modelos preditivos CART, MLP, NB, RF e SMO, baseados na composição mineral da carne bovina, permitiram discriminar corte com acurácia 20% superior aos obtidos para sexo e grupo genético. O MLP foi o modelo de classificação de escolha por apresentar melhor acurácia, precisão, sensibilidade e especificidade para autenticação de carne bovina.

A Figura 38 mostra as distâncias mínimas significativas (MSD) e a incerteza analítica média para cada elemento químico determinado em amostras de carne bovina para comparação por país de origem, região do Brasil, corte de carne bovina, sexo e grupo genético dos animais.




Figura 38. Distância mínima significativa (MSD) em porcentagem referente à média da fração de massa dos elementos químicos para discriminação da carne bovina de regiões do Brasil, países produtores, corte, sexo e grupo genético dos animais e incerteza analítica média (U) em porcentagem referente à média das frações de massa dos elementos químicos

Para utilizar a fração de massa obtida com objetivo de diferenciar entre várias classes, é necessário obter resultados com incerteza analítica menor que o MSD. Neste caso, todas as MSD foram superiores às incertezas analíticas médias, mostrando a viabilidade do uso da técnica de análise por ativação neutrônica para obter o perfil agrometalômico da carne bovina para discriminação entre país de origem, região do Brasil, corte de carne bovina, sexo e grupo genético dos animais. Considerando que quanto maior a MSD maior é a diferença entre os grupos de dados que estão sendo comparados [182], pode-se concluir que, exceto para K, Na e Zn, a diferença entre picanha bovina procedente de diferentes regiões do Brasil (Goiás, Minas Gerais, Mato Grosso do Sul, Pará, Pernambuco, Rio Grande do Sul e São Paulo) é maior que a diferença entre picanha bovina procedente de Argentina, Austrália, Brasil, Paraguai e Uruguai. Para todos os elementos químicos, os cortes apresentaram maior variação das frações de massa do que sexo e grupo genético, sendo obtido para eles maior MSD e maior coeficiente de Cramer.

Seria recomendado manter o mesmo corte para realização da discriminação da origem geográfica da carne bovina com base no perfil agrometalômico para evitar possíveis interações entre a origem geográfica e o corte estudado. É recomendado o uso do corte picanha, uma vez que os elementos químicos apresentaram maiores fração de massa. Do ponto de vista analítico, devido à menor quantidade de gordura intramuscular, o processamento de picanha propiciou amostras mais homogêneas, sendo obtido um sólido de consistência solta. Para acém e contrafilé, após liofilização e moagem, foram obtidas amostras na forma de aglomerados, provavelmente devido ao maior teor de gordura.

Tradicionalmente, o termo *terroir* refere-se a uma área geográfica e habilidade (*savoir-faire*) das pessoas que a exploram para conferir qualidades distintas aos produtos alimentares, comumente associadas à produção de vinho. No caso da carne bovina, o termo *terroir* está sendo utilizado para definir uma condição ambiental (clima, geografia, geologia e solo), características genéticas dos animais e sistema de criação (envolvendo aspectos nutricionais) que levam a produtos específicos que refletem a singularidade de onde se originam [183]. Por exemplo, nas montanhas mediterrâneas, a forma como as pastagens são geridas, as raças de animais e as interligações destes aspectos podem ser consideradas como uma adaptação de um sistema próprio de cultivo que faz um *terroir* dos seus produtos animais [183]. O Brasil contempla uma diversidade natural capaz de produzir carne bovina com características peculiares, surgindo termos como “Terroir Angus Beef” [47] e “Pampa: terroir de bovinos de corte” [184]. A carne bovina procedente da *Beef Passion* também é considerada um *terroir* da

carne dado o controle de cada etapa do sistema de produção verticalmente integrado [142]. A Figura 39 mostra o esquema da interação entre os termos de agrometaloma, uma interdisciplinaridade independente envolvendo um metaloma agrícola [185] e o *terroir* da carne bovina.



Figura 39. Diagrama representando as condições ambientais e de criação que influenciam o perfil agrometalômico e definem o *terroir* da carne bovina

Foi realizado um estudo para diferenciar os cortes de carne bovina da *Beef Passion* das amostras de picanha procedentes de Argentina, Austrália, Brasil, Paraguai e Uruguai.

A Figura 40 mostra o gráfico de análise de componentes principais com biplot para discriminar as amostras procedentes da Beef Passion (BP), considerando 49 % das informações (PC1 32 % e PC2 17 %).




Figura 40. Componentes Principais com Biplot para discriminar amostras procedentes da *Beef Passion* (BP), considerando 49 % das informações (PC1 32 % e PC2 17 %)

Para as amostras procedentes da *Beef Passion*, foram obtidas contribuições negativas dos elementos químicos Br, Fe, K, Na e Zn, apresentando vetores com direção e sentidos contrários à distribuição das amostras. Os elementos Co, Cs, Rb e Se apresentaram direção e sentido perpendiculares à distribuição das amostras da *Beef Passion*, não tendo contribuição significativa na discriminação. O gráfico de componentes principais mostrou a viabilidade de discriminar a carne bovina com base na origem geográfica.

Foram implementados os algoritmos de inteligência artificial CART, MLP, NB, RF e SMO, sendo obtidas acurácias de classificação de 98 %, 98 %, 100 %, 100 % e 98 %, respectivamente. A Tabela 22 mostra a matriz de confusão obtida para cada modelo implementado empregando todos os elementos químicos determinados.

Tabela 22. Matriz de confusão obtida implementando os modelos MLP, NB, RF e SMO para discriminar a carne bovina da *Beef Passion*

RF			NB		
BP	NBP	← Classificado como	BP	NBP	← Classificado como
194	2	BP	194	2	BP
0	450	NBP	0	450	NBP

MLP			SMO		
BP	NBP	← Classificado como	BP	NBP	← Classificado como
190	6	BP	188	8	BP
5	445	NBP	3	447	NBP

Para os modelos obtidos implementando RF e NB, nenhuma das 450 amostras não procedentes da *Beef Passion* (NBP) foi classificada como pertencente a este grupo (BP). O modelo de árvore obtido implementando CART mostra que menores frações de massa de Br e Na permitiram discriminar as amostras procedentes da *Beef Passion* (Figura 41).




Figura 41. Regra de decisão gerada pelo modelo CART para discriminar a carne bovina proveniente da *Beef Passion* com base na fração de massa (mg/kg) de Br e Na

Empregando o perfil agrometalômico e algoritmos de aprendizado de máquina foi possível autenticar com acurácia entre 98 % e 100 % a carne bovina produzida em um *terroir* da carne brasileiro.

4.7 Análise da ração para bovinos da *Beef Passion*

Foi estudada a composição multielementar das rações oferecidas aos bovinos de corte da *Beef Passion* com o objetivo de avaliar possíveis influências na composição da carne dos grupos genéticos $\frac{1}{2}$ Angus – $\frac{1}{2}$ Nelore e $\frac{1}{4}$ Angus – $\frac{1}{4}$ Nelore – $\frac{1}{2}$ Wagyu. A ração para bovinos de cada grupo genético foi definida para melhorar parâmetros como área do olho do lombo (AOL), espessura de gordura subcutânea (EGS), marmoreio (MAR) e relação altura : largura do contrafilé (RATIO) [143]. Vinte elementos químicos (Ba, Br, Ca, Ce, Co, Cr, Cs, Eu, Fe, Hf, K, La, Na, Rb, Sc, Se, Sm, Sr, Th e Zn) foram determinados por NAA nas duas rações A e B. A Tabela 23 mostra os valores mínimo, máximo, média e desvio padrão das frações de massa dos elementos químicos.

Tabela 23. Frações de massa dos elementos químicos determinados em ração para bovinos

Elementos	Ração A (n = 14)			Ração B (n = 14)		
	Mínimo (mg/kg)	Máximo (mg/kg)	Média ± SD (mg/kg)	Mínimo (mg/kg)	Máximo (mg/kg)	Média ± SD (mg/kg)
Ba	20	40	27 ± 5	21	44	31 ± 5
Br	1,6	2,2	1,9 ± 0,2	1,6	2,4	2,2 ± 0,2
Ca	9816	13853	11036 ± 1226	9981	16936	13381 ± 2060
Ce	1,1	2,0	1,6 ± 0,3	1,3	2,8	1,8 ± 0,4
Co	0,4	0,6	0,4 ± 0,2	0,3	0,6	0,5 ± 0,2
Cr	4	9	5 ± 3	4	7	5 ± 3
Cs	0,06	0,08	0,071 ± 0,006	0,07	0,12	0,09 ± 0,01
Eu	0,017	0,037	0,025 ± 0,005	0,021	0,04	0,027 ± 0,006
Fe	282	619	460 ± 244	427	617	503 ± 255
Hf	0,05	0,34	0,11 ± 0,07	0,06	0,20	0,11 ± 0,04
K	7354	10137	8897 ± 740	7951	10931	9474 ± 791
La	0,8	1,3	1,0 ± 0,1	0,9	1,6	1,2 ± 0,2
Na	1533	2465	1801 ± 235	1284	2618	1861 ± 374
Rb	9	15	13 ± 2	11	17	14 ± 1
Sc	0,11	0,19	0,13 ± 0,03	0,13	0,31	0,19 ± 0,04
Se	0,28	0,57	0,39 ± 0,06	0,18	0,38	0,28 ± 0,06
Sm	0,10	0,18	0,14 ± 0,02	0,12	0,23	0,16 ± 0,03
Sr	70	106	82 ± 11	68	124	96 ± 13
Th	0,07	0,20	0,12 ± 0,04	0,10	0,25	0,14 ± 0,04
Zn	73	116	88 ± 10	53	115	79 ± 15

O Apêndice C mostra a variação da fração de massa de cada elemento quantificado durante os dias monitorados. Os elementos terras raras (ETR) Ce, Eu, La, Sc e Sm podem ser derivados de rochas fosfatadas moídas incorporadas às ração como fontes de fósforo e cálcio [186-188]. Diferentes teores de ETR em amostras de alimentos produzidos em sistema orgânico e convencional foram relatados [113, 115, 162], bem como sua presença devido ao uso de fertilizantes fosfatados [115, 188-190] (Apêndice D).

Para todos os elementos químicos, os valores de MSD foram superiores à incerteza analítica média (U) (Tabela 24), permitindo a utilização dos resultados para discriminar ração para bovinos de corte pela composição química.

Tabela 24. Distância mínima significativa (MSD) e incerteza analítica média (U) obtida nas rações para bovinos A (n = 14) e B (n = 14).

Elementos		Ração A (mg/kg)	Ração B (mg/kg)	Elementos		Ração A (mg/kg)	Ração B (mg/kg)
Ba	U	1,7	1,8	K	U	247	279
	MSD	4,4			MSD	618	
Br	U	0,07	0,07	La	U	0,02	0,03
	MSD	0,16			MSD	0,13	
Ca	U	289	337	Na	U	53	51
	MSD	1367			MSD	252	
Ce	U	0,07	0,07	Rb	U	0,5	0,5
	MSD	0,28			MSD	1,2	
Co	U	0,03	0,03	Sc	U	0,003	0,005
	MSD	0,12			MSD	0,029	
Cr	U	0,3	0,3	Se	U	0,03	0,04
	MSD	1,9			MSD	0,05	
Cs	U	0,004	0,005	Sm	U	0,007	0,007
	MSD	0,008			MSD	0,022	
Eu	U	0,0008	0,0009	Sr	U	7	7
	MSD	0,0044			MSD	10	
Fe	U	10	13	Th	U	0,006	0,006
	MSD	115			MSD	0,029	
Hf	U	0,004	0,005	Zn	U	3	2
	MSD	0,050			MSD	10	

Técnicas de seleção de variáveis foram aplicadas para obter os elementos com maior poder discriminativo de acordo com o qui-quadrado e F-score. A Figura 42 mostra os valores de qui-quadrado, F-score e coeficiente de Cramer para cada elemento determinado. As barras vermelhas mostram os elementos que tiveram diferença significativa entre as duas rações estudadas, utilizando o teste de Wilcoxon (qui-quadrado) e teste de Duncan (F-score) com nível de confiança de 95%. Se, Sc, Ca, Cs, Br, La e Sr apresentaram diferenças estatisticamente significativas ($p < 0,05$) tanto para o teste de comparação paramétrico quanto para o não paramétrico Ce, Co, Cr, Eu, Fe, Hf, K, Na, Rb e Sm não apresentaram diferença estatisticamente significativa ($p \geq 0,05$) tanto para o teste de comparação paramétrico quanto para o não paramétrico. Os valores do qui-quadrado e do F-score obtidos para cada elemento mostraram a importância relativa para discriminar entre as rações para bovinos. Quanto maior o valor do qui-quadrado ou F-score, maior será seu poder discriminativo entre as classes. Para valores de coeficiente de Cramer maiores que 0,5, espera-se que a variável (elemento químico) apresente maior poder de discriminação entre as classes (ração A e B).




Figura 42. Importância relativa variável com base no valor de qui-quadrado, F-score e coeficiente de Cramer

Para construir os modelos preditivos, as variáveis (elementos químicos) foram ordenadas do maior ao menor poder discriminativo entre as rações. Dezesesseis subconjuntos foram gerados conforme mostrado no Apêndice E e no Apêndice F. Aumentar o número de elementos químicos menos importantes para discriminar a ração para bovinos permite avaliar o efeito dos dados de ruídos nos modelos. A relação entre o número de elementos contidos em cada subconjunto gerado e a acurácia obtida pelos modelos de classificação CART, MLP, NB, RF e SMO são observadas na Figura 43. A MANOVA foi usada para determinar os valores do F-score para os subconjuntos de dados. Todos os modelos de classificação apresentaram acurácia máxima ao considerar os três elementos químicos (Cs, Se e Sc) com maior poder discriminativo. Ao incluir elementos químicos com menor poder discriminativo, a acurácia da classificação diminuiu. O F-score da MANOVA tem um valor máximo para o subconjunto Chi#2 e após uma diminuição contínua até Chi#9, estabilizando de Chi#9 para Chi#17, quando foram incluídos elementos que não apresentaram diferenças estatisticamente significativas. Ajustando os valores F-score dos subconjuntos Chi#1 a Chi#9 para regressão linear obteve-se o valor de $R^2 = 0,96$ e coeficiente angular de -9 para os subconjuntos Chi#10 a Chi#17 obteve-se o valor de $R^2 = 0,76$ e coeficiente angular de -0,9. MANOVA perde poder discriminativo quando elementos químicos com pouco poder discriminativo são incluídos no modelo. Em contraste, os métodos de aprendizado de máquina mantêm a acurácia da previsão com a inclusão de elementos químicos que pouco contribuem para discriminação entre as classes.

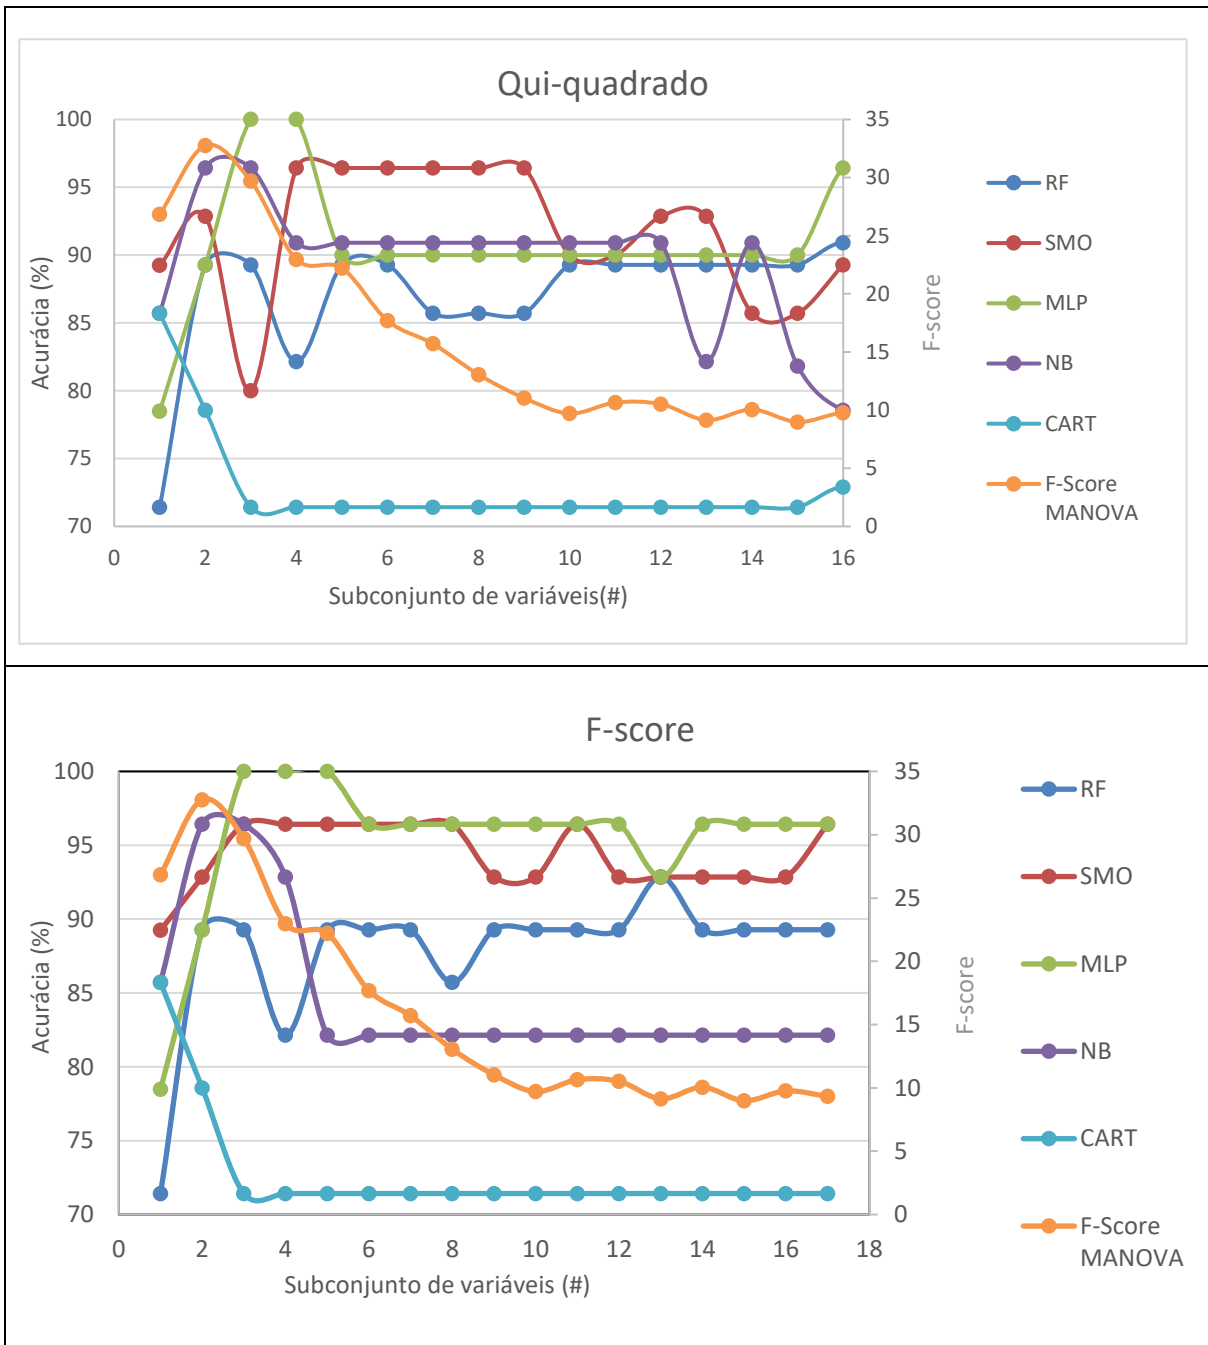


Figura 43. Valores de acurácia obtidos pelos modelos de classificação usando diferentes subconjuntos de variáveis ordenadas pelo valor de qui-quadrado e F-score

A Figura 44 mostram a distribuição das frações de massa de Cs e Se e de Cs, Sc e Se nas rações A e B. A linha azul representa o limite de decisão para discriminar as rações A e B, isto é, fração de massa de Cs = 0,08 mg/kg. As elipses azul e vermelha representam a distribuição do espaço onde se encontrariam 95 % dos dados referentes à fração de massa de Cs e Se das rações A e B, respectivamente.

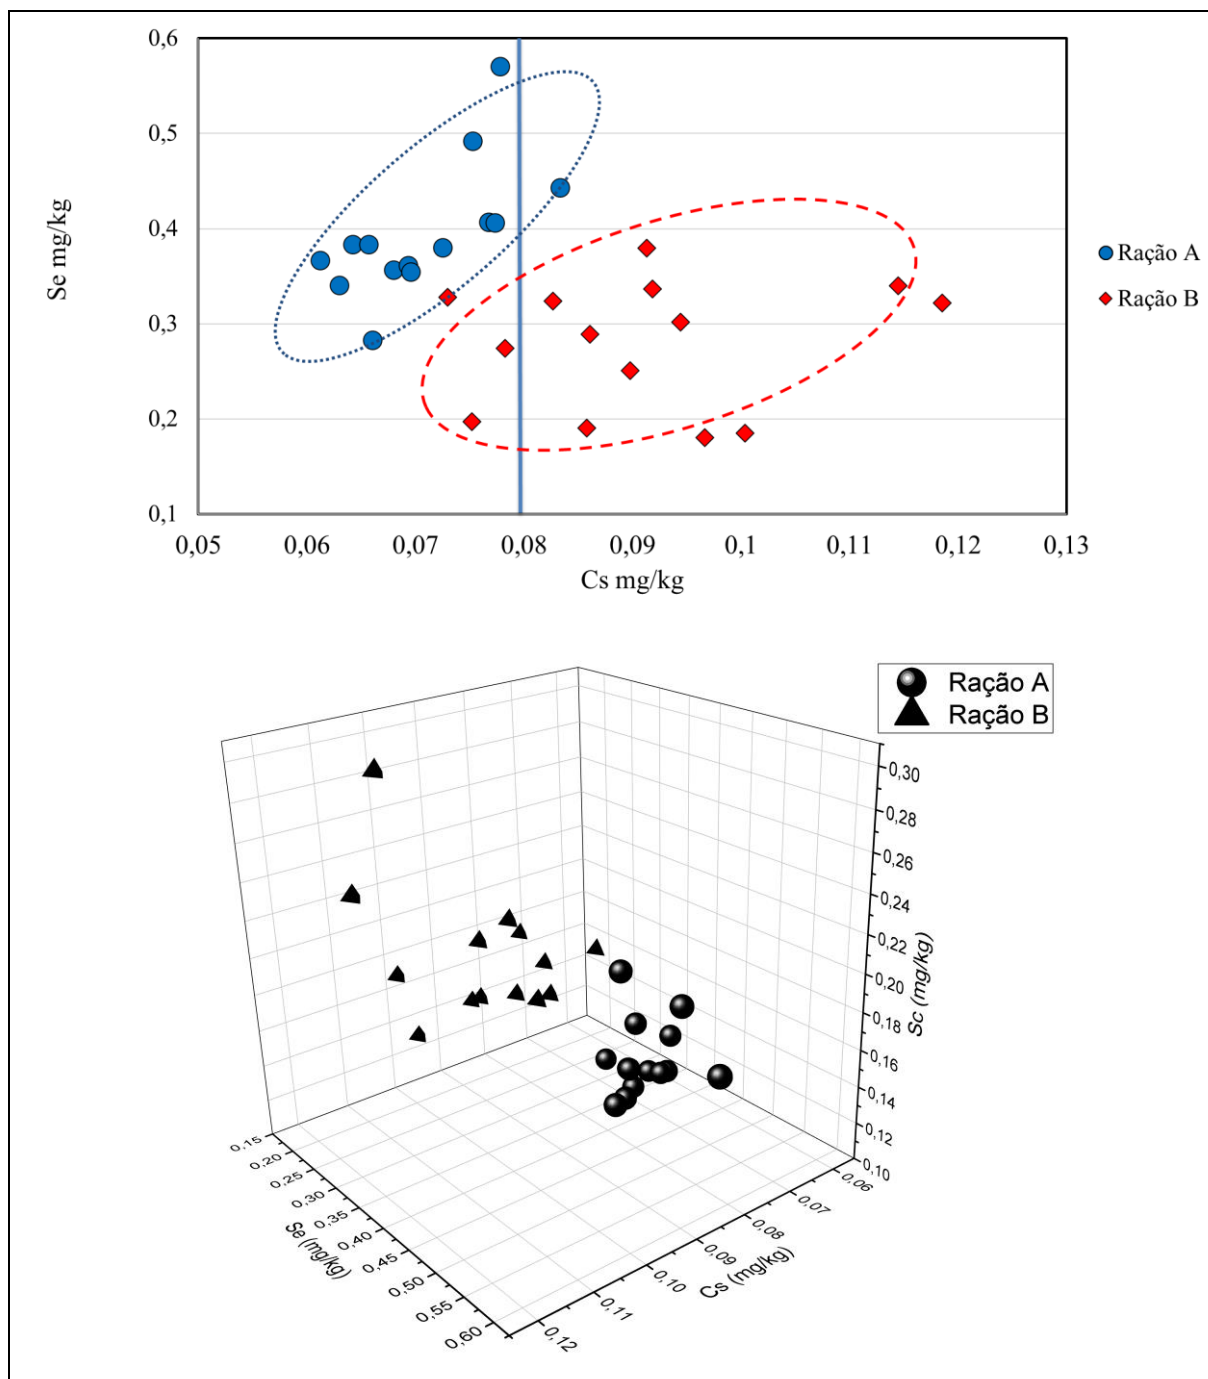


Figura 44. Distribuição das frações de massa de Cs e Se e de Cs, Sc e Se, respectivamente, nas rações A e B

A Tabela 25 mostra os maiores valores de acurácia, sensibilidade e especificidade obtidos para discriminar as rações de bovinos de corte implementando os modelos CART, RF, MLP, NB e SMO.

Tabela 25. Desempenho de classificação dos modelos RF, SMO, MLP, NB e CART para discriminação das rações para bovinos A e B

	RF	SMO	MLP	NB	CART
Subconjunto de variáveis	{Cs, Se, Sc}	{Cs, Se, Sc}	{Cs, Se, Sc}	{Cs, Se}	{Cs}
Acurácia (%)	89	100	100	96	86
Sensibilidade ração A (%)	93	100	100	100	93
Sensibilidade ração B (%)	86	100	100	93	79
Especificidade ração A (%)	86	100	100	93	79
Especificidade ração B (%)	93	100	100	100	93

Todos os modelos obtiveram maior desempenho preditivo ao utilizar Cs, Se e/ou Sc. SMO e MLP têm a maior acurácia (100 %), especificidade (100 %) e sensibilidade (100 %) considerando os elementos químicos Cs, Se e Sc. A fração de massa desses elementos permitiu a discriminação das classes. Os algoritmos de aprendizado de máquina estabeleceram uma série de funções para realizar modelos de classificação. Esses modelos são capazes de discriminar as rações bovinas sem erros. NB obteve a terceira melhor acurácia (96 %) considerando apenas as frações de massa de Cs e Se. Este modelo foi mais sensível para a ração A (100%) e específico para a ração B (100 %). Os modelos de árvore RF e CART apresentaram menor acurácia (89 % e 86 %, respectivamente), considerando Cs e Se (RF) e Cs (CART). Ambos os modelos apresentaram maior sensibilidade para a ração A (93 %) e especificidade para a ração B (93 %) [182].

Considerando que a ração B foi utilizada para a terminação de animais $\frac{1}{4}$ Angus – $\frac{1}{4}$ Nelore – $\frac{1}{2}$ Wagyu e tinha menor fração de massa de selênio na sua composição, esperava-se que a carne desses animais apresentasse menor teor de selênio. Porém, maior teor de selênio foi encontrado, o que pode ser explicado pelo teor de selênio orgânico no sal mineral componente da ração B (Núcleo Wagyu) e de selênio inorgânico (seleneto de sódio) no Núcleo NB Perform, utilizado na suplementação de animais $\frac{1}{2}$ Angus – $\frac{1}{2}$ Nelore, sendo que a via orgânica é mais eficiente para a absorção do elemento [25, 191].

5 CONCLUSÕES

Empregando análise por ativação neutrônica foram determinados elementos químicos Br, Co, Cs, Fe, K, Na, Rb, Se e Zn presentes na carne bovina procedente de diferentes regiões. Todas as distâncias mínimas significativas foram superiores às incertezas analíticas médias, mostrando a viabilidade do uso da técnica para obter o perfil agrometalômico da carne bovina para discriminação de país de origem, região do Brasil, corte de carne bovina, sexo e genética dos animais.

O maior desvio padrão robusto das frações de massa de Br, Co, Cs, Fe, Na e Se foi obtido para amostras procedentes do Brasil, mostrando como a grande variabilidade das condições ambientais da atividade pecuária influencia o perfil agrometalômico da carne bovina. O aprendizado de máquina aplicado à composição multielementar da carne bovina produzida na Argentina, Austrália, Brasil, Paraguai e Uruguai permitiu discriminar a origem geográfica. O melhor desempenho de classificação foi alcançado com a implementação de modelos baseados no algoritmo MLP. A maior acurácia de classificação foi obtida para a carne proveniente do Paraguai (100 %) e a menor para a carne do Brasil (82 %). A implementação de modelos de classificação dois a dois (cada país contra os demais países), melhorou a acurácia de classificação, especialmente para a carne do Brasil (94 %).

Quando gerados modelos de classificação baseados nos algoritmos CART, MLP e RF para discriminar a carne bovina procedente dos diferentes locais do Brasil, foram obtidos valores de acurácia de classificação, no mínimo, 20 pontos percentuais inferiores aos gerados para discriminar a carne proveniente de cada local. Foram obtidas as maiores acurácias de classificação utilizando modelo baseado no algoritmo MLP para carne procedente do bioma Amazônia (99 %), Caatinga (99 %), Pampa (94 %), Cerrado MG (90 %) e Pantanal (90 %), e utilizando modelo baseado no algoritmo RF para carne procedente do bioma Cerrado GO (98 %) e Cerrado SP (94 %). Foi observada maior dificuldade na separação de mostras procedentes do mesmo bioma, ou seja, Cerrado GO, Cerrado MG e Cerrado SP.

A distância mínima significativa e o coeficiente de Cramer mostraram que diferentes cortes apresentaram maior variação nas frações de massa do que os sexo e grupo genético. A diferença entre a composição multielementar de picanha bovina procedente de diferentes regiões do Brasil (Goiás, Minas Gerais, Mato Grosso do Sul, Pará, Pernambuco, Rio Grande do Sul e São Paulo) é maior que a diferença entre a composição multielementar de picanha bovina procedente de Argentina, Austrália, Brasil, Paraguai e Uruguai. Os modelos de

classificação CART, MLP, NB, RF e SMO baseados na composição multielementar da carne bovina permitiram discriminar cortes com acurácia 20 % superior à obtida para discriminar sexo e grupo genético.

Foram determinados os elementos químicos Ba, Br, Ca, Ce, Co, Cr, Cs, Eu, Fe, Hf, K, La, Na, Rb, Sc, Se, Sm, Sr, Th e Zn em diferentes rações utilizadas na alimentação de gado de corte empregando análise por ativação neutrônica. Foi demonstrada a viabilidade do uso de técnicas de mineração de dados aos elementos químicos presentes em ração para bovinos para discriminação. Modelos preditivos capazes de discriminar a ração para bovinos com base na composição química foram obtidos com acurácia de classificação de 86 %, 89 %, 100 %, 96 % e 100 %, respectivamente para CART, RF, MLP, NB e SMO. As redes neurais (MLP e SMO) tiveram a melhor acurácia, seguidas do modelo Bayesiano (NB) e dos modelos de árvore (CART e RF). Cs, Sc e Se foram as variáveis mais importantes para diferenciar as rações A e B. Não foi observada influência significativa da composição química das duas rações estudadas no perfil agrometalômico da carne dos animais que as consumiram. Foram obtidos modelos de classificação com base no perfil agrometalômico para discriminação da carne bovina oriunda de diferentes locais.

REFERÊNCIAS

1. USDA. FOREIGN AGRICULTURAL SERVICE. **Livestock and Poultry: World Markets and Trade.** Washington, DC, 2021. Disponível em: https://apps.fas.usda.gov/psdonline/circulars/livestock_poultry.pdf. Acesso em: 11 jul. 2022.
2. HYDE, M.; THORPE, S.; WARING, A.; MOIR, B.; GUNNING-TRANT, C. **South America: an emerging competitor for Australia's beef industry.** Research Report 16.14. Canberra, Australia: Department of Agriculture and Water Resources, Australian Bureau of Agricultural and Resource Economics and Sciences (ABARES), 2016. Disponível em: https://www.agriculture.gov.au/sites/default/files/sitecollectiondocuments/abares/publications/SouthAmericaBeef_v1.0.0.pdf
3. ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS EXPORTADORAS DE CARNE - ABIEC. **Perfil da pecuária no Brasil.** Brasília, DF, 2022. (Beef Report, 72). Disponível em: <http://abiec.com.br/publicacoes/beef-report-2022/>. Acesso em: 11 jul. 2022.
4. FAO. **FAOSTAT.** Crops Production Database. Rome, 2022. Disponível: <http://www.fao.org/faostat/en/#data/QC/visualize>. Acesso em: 11 jul. 2022.
5. EMBRAPA. **Soja em números** (safra 2020/21). Londrina: Embrapa Soja, 2022. Disponível em: <https://www.embrapa.br/en/soja/cultivos/soja1/dados-economicos>. Acesso em: 11 jul. 2022.
6. FAO. **FAOSTAT.** Livestock Processed Production Database. Rome, 2022. Disponível em: <http://www.fao.org/faostat/en/#data/QL/visualize>. Acesso em: 11 jul. 2022.
7. USDA. FOREIGN AGRICULTURAL SERVICE. **The Brazilian Bovine Genetics Market and US Exports, Service.** Washington, DC, 2021. Disponível em: https://usdabrazil.org.br/wp-content/uploads/2021/03/The-Brazilian-Bovine-Genetics-Market-and-US-Exports_Brasilia_Brazil_03-01-2021-1.pdf. Acesso em: 11 jul. 2022.
8. ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS EXPORTADORAS DE CARNE - ABIEC. **Perfil da pecuária no Brasil.** Relatório Anual. Disponível: https://edisciplinas.usp.br/pluginfile.php/4392168/mod_resource/content/1/Sum%C3%A1rio%20ABIEC%202017.pdf. Acesso em: 11 jul. 2022.
9. TYUKAVINA, A.; HANSEN, M.C.; POTAPOV, P.V.; STEHMAN, S.V.; SMITH-RODRIGUEZ, K.; OKPA, C.; AGUILAR, R. Types and rates of forest disturbance in Brazilian Legal Amazon, 2000-2013. **Science Advances**, v. 3, n. 4, e1601047, 2017.
10. RIVERO, S.; ALMEIDA, O.; ÁVILA, S.; OLIVEIRA, W. Pecuária e desmatamento: uma análise das principais causas diretas do desmatamento na Amazônia. **Nova Economia** [online], v. 19, n. 1, p. 41-66, 2009.
11. INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. **Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite.** São José dos Campos, 2022. Disponível: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>. [Acesso em: 29 jul. 2022.

12. LIMA FILHO, F.L.; BRAGANÇA, A.; ASSUNÇÃO, J.J. **A economia da pecuária na Amazônia: grilagem ou expansão da fronteira agropecuária?** Rio de Janeiro: Climate Policy Initiative, 2021. Disponível: <https://www.climatepolicyinitiative.org/pt-br/publication/a-economia-da-pecuaria-na-amazonia-grilagem-ou-expansao-da-fronteira-agropecuaria/>. Acesso em: 29 jul. 2022.
13. CONCHON, F.L.; LOPES, M.A. **Rastreabilidade e segurança alimentar**. Lavras: UFLA, 2012. 25 p. (Boletim Técnico, 91). Disponível em: http://www.cidasc.sc.gov.br/defesasanimariaanimal/files/2012/08/RASTREABILIDADE_fabricio.pdf.
14. FELÍCIO, P.E.D. Rastreabilidade aplicada à carne bovina. In: **Reunião Anual da Sociedade Brasileira de Zootecnia**, 38., 2001, Piracicaba. **Anais**. Piracicaba: FEALQ, 2001. p. 294-301. Disponível em: <http://sbz.org.br/new/pt/documentos--anais-das-reunioes>.
15. BAHAR, B.; MONAHAN, F.J.; MOLONEY, A.P.; O'KIELY, P.; SCRIMGEOUR, C.M.; SCHMIDT, O. Alteration of the carbon and nitrogen stable isotope composition of beef by substitution of grass silage with maize silage. **Rapid Communications in Mass Spectrometry**, v. 19, n. 14, p. 1937-1942, 2005.
16. SCHWÄGELE, F. Traceability from a European perspective. **Meat Science**, v. 71, n. 1, p. 164-173, 2005.
17. NAKASHITA, R.; SUZUKI, Y.; AKAMATSU, F.; IIZUMI, Y.; KORENAGA, T.; CHIKARAISHI, Y. Stable carbon, nitrogen, and oxygen isotope analysis as a potential tool for verifying geographical origin of beef. **Analytica Chimica Acta**, v. 617, n. 1, p. 148-152, 2008.
18. ARAUJO, P.C.D. **Isótopos estáveis na rastreabilidade de farinha de origem animal na alimentação de frangos de corte**. 2010. Dissertação (Mestrado em Zootecnia) - Faculdade de Medicina Veterinária e Zootecnia, Universidade Estadual Paulista Julio de Mesquita Filho, Botucatu. 2010.
19. SANTOS, C.D.C. **Impacto em características qualitativas de carne bovina in natura decorrente do manejo nutricional e de tecnologias pós-abate, e sua relação com grupo genético**. 2011. Tese (Doutorado em Ciências) - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba. 2011.
20. RESENDE, E.H.S.; LOPES, M.A. **Identificação, certificação e rastreabilidade na cadeia da carne bovina e bubalina no Brasil**. Lavras: UFLA, 2004. (Boletim Técnico, 58).
21. EUROPEAN COMMISSION. **Food Law General Requirements**. Brussels, 2022. Disponível em: https://food.ec.europa.eu/horizontal-topics/general-food-law/food-law-general-requirements_en
22. BRASIL. MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. Instrução Normativa nº 17, de 13 de julho de 2006. Estabelece a Norma Operacional do Serviço de Rastreabilidade da Cadeia Produtiva de Bovinos e Bubalinos (SISBOV), constante do Anexo I, aplicável a todas as fases da produção, transformação, distribuição e dos serviços agropecuários. Alterada pela Instrução Normativa MAPA - 14, de 24-05-2009. Alterada pela Instrução Normativa MAPA - 48, de 04-11-2009. **Diário Oficial da União**, Brasília,

14 jul. 2009. Disponível: <https://www.defesa.agricultura.sp.gov.br/legislacoes/instrucao-normativa-mapa-17-de-13-07-2006,842.html>.

23. NAZARENO, A.; RONCADA, L.; SILVA, I. Identificação eletrônica de animais: quais são as aplicabilidades desses métodos na produção de carne? **Journal of Animal Behaviour and Biometeorology**, v. 2, n. 4, p. 142-150, 2014.
24. KUMVENJI, D.C.E.; CHAMBA, M.V.M.; LUNGU, K. Effectiveness of food traceability system in the supply chain of local beef and beef sausages in Malawi: A food safety perspective. **Food Control**, v. 137, art. 108839, 2022.
25. REICH, H.J.; HONDAL, R.J. Why Nature Chose Selenium. **ACS Chemical Biology**, v.11, n. 4, p. 821-841, 2016.
26. ONDEI, V. Os 10 dias que avaliaram a carne. **Dinheiro Rural**, v. 13, n. 146, p. 20-25, 2017.
27. SILVA, J.G.; CARVALHO, L.V.; NUNES, L.V. A corrupção e seus efeitos no mercado de alimentos: O caso da operação “Carne Fraca”. **Economic Analysis of Law Review**, v. 12, n. 2, p. 3-23, 2021.
28. DORTZBACH, D.; PEREIRA, M.G.; BLAINSKI, É.; GONZÁLEZ, A.P. Estoque de C e abundância natural de ¹³C em razão da conversão de áreas de floresta em pastagem em bioma Mata Atlântica. **Revista Brasileira de Ciência do Solo**, v. 39, p. 1643-1660, 2015.
29. BONER, M.; FORSTEL, H. Stable isotope variation as a tool to trace the authenticity of beef. **Analytical and Bioanalytical Chemistry**, v. 378, n. 2, p. 301-310, 2004.
30. KELLY, S.D.; HEATON, K.; HOOGWERFF, J.; WOOLFE, M. Verifying the geographical origin of beef: The application of multi-element isotope and trace element analysis. **Food Chemistry**, v. 107, n. 1, p. 506-515, 2008.
31. WANG, Q.; LIU, H.; ZHAO, S.; QIE, M.; BAI, Y.; ZHANG, J.; GUO, J.; ZHAO, Y. Discrimination of mutton from different sources (regions, feeding patterns and species) by mineral elements in Inner Mongolia, China. **Meat Science**, v. 174, art. 108415, 2021.
32. LOGAN, B.G.; HOPKINS, D.L.; SCHMIDTKE, L.M.; MORRIS, S.; FOWLER, S.M. Classification of southern Australian grass- and grain-fed beef. **Food Analytical Methods**, v. 14, p. 1730-1743, 2021.
33. LOGAN, B.G.; HOPKINS, D.L.; SCHMIDTKE, L.M.; FOWLER, S.M. Authenticating common Australian beef production systems using Raman spectroscopy. **Food Control**, v. 121, art. 107652, 2021.
34. FERNANDES, E.A.N.; BACCHI, M.A.; SARRIÉS, G.A.; GONZAGA, C.L.; SARRIÉS, S.R.V.; FOGAÇA, A.A.; SILVA, G.A. Trace elements for tracking beef production in different biomes of Brazil. In: The Food Factor I Barcelona Conference, 2016, Barcelona. **Abstracts...** Barcelona, 2016.
35. ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS EXPORTADORAS DE CARNE - ABIEC. **Perfil da pecuária no Brasil**. Brasília, DF, 2020. (Beef Report, 50). Disponível: <http://abiec.com.br/publicacoes/beef-report-2020/>.

36. COUTINHO, L.M. O conceito de cerrado. **Revista Brasileira de Botânica**, v. 1, n. 1, p. 17-23, 1978.
37. BATALHA, M.A. O cerrado não é um bioma. **Biota Neotropica**, v. 11, n. 1, p. 1-4, 2011.
38. Instituto Brasileiro de Geografia e Estatística - IBGE. **Biomass e sistema costeiro-marinho do Brasil**. Rio de Janeiro, 2019. (Relatórios Metodológicos, 168).
39. GUEDES, L.P.; VALENTE, L.C.M. Cattle breeding in Brazilian biomes. In: Simpósio de Sustentabilidade e Ciência Animal, 2011.
40. SILVA, I.J.O.D. A rastreabilidade dos produtos agropecuários do Brasil destinados à exportação. In: NUPEA/ESALQ-USP. A Rastreabilidade de Produtores Agropecuários do Brasil - Curso de Rastreabilidade. Piracicaba, 2004.
41. DIAS-FILHO, M. **Diagnóstico das pastagens no Brasil**. Belém, PA: Embrapa Amazônia Oriental, 2014.
42. FERRAZ, J.B.S.; FELÍCIO, P.E.D. Production systems – An example from Brazil. **Meat Science**, v. 84, n. 2, p. 238-243, 2010.
43. Instituto Brasileiro de Geografia e Estatística - IBGE. **Tabulações especiais do Censo Agropecuário 2006**. Rio de Janeiro, 2015.
44. Instituto Brasileiro de Geografia e Estatística - IBGE. **Biomass do Brasil**. Rio de Janeiro, 2004. Disponível: https://geoftp.ibge.gov.br/informacoes_ambientais/estudos_ambientais/biomass/mapas/biomass_e_sistema_costeiro_marinho_250mil.pdf. Acesso em: 28 jul. 2022.
45. COUTINHO, L.M. O conceito de bioma. **Acta Botanica Brasilica**, v. 20, p. 13-23, 2006.
46. ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS EXPORTADORAS DE CARNE - ABIEC. **Perfil da pecuária no Brasil**. Brasília, DF, 2019. (Beef Report, 50). Disponível: <http://abiec.com.br/publicacoes/beef-report-2019/>.
47. RIBEIRO, S.D.D.A.; SICA, F.D.; CUNHA, R.R.C.D. **Angus Brazilian Gourmet**. Porto Alegre: Cartola Agência de Conteúdo, 2015. Disponível em: <https://carneanguscertificada.com.br/extranet/upload/Angus-2017.07.16-23.00.06.pdf>. Acesso em: 26 jul. 2022.
48. FASIABEN, M.D.C.R.; ALMEIDA, M.M.T.B.; MAIA, A.G.; OLIVEIRA, O.C.D.; COSTA, F.P.; BARIONI, L.G.; DIAS, F.R.T.; MOREIRA, J.M.M.Á.P.; SENA, A.L.D.S.; SANTOS, J.C.D.; LAMPERT, V.D.N.; OLIVEIRA, P.P.A.D.; ABREU, U.G.P.D.; GREGO, C.R. **Technological profile of beef cattle farms in Brazilian biomes**. Campinas: Embrapa Informática Agropecuária, 2020. Disponível: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1127930/1/Bol48-2020.pdf>.
49. RODRIGUES, T.P.; SILVA, T.J.P. Caracterização do processo de rigor mortis e qualidade da carne de animais abatidos no Brasil. **Arquivos de Pesquisa Animal**, v. 1, n. 1, p. 1-20, 2016.

50. SILVESTRE, F. **Carne Bovina Orgânica é Realidade**. Rio de Janeiro: OrganicsNet, 2016. Disponível em: <https://www.organicsnet.com.br/carne-bovina-organica-e-realidade/>. Acesso em: 14 jul. 2022.
51. EMBRAPA. **Marca-Conceito Carne Carbono Neutro. Campo Grande: Embrapa Gado de Corte**, 2016. Disponível: <https://www.embrapa.br/busca-de-solucoes-tecnologicas/-/produto-servico/3488/marca-conceito-carne-carbono-neutro>. Acesso em: 08 jan. 2019.
52. ABPO, **Memorial descritivo do protocolo carne sustentável da Associação Brasileira de Produtores Orgânicos**, 2017, Associação Brasileira de Produtores Orgânicos: Campo Grande – MS. p. 22. Acesso em: 14 jul. 2022.
53. ANBA. **Brasil lança selo de sustentabilidade agrícola**. 2018 ; Disponível: <https://anba.com.br/brasil-lanca-selo-de-sustentabilidade-agricola/> Acesso em: 09 jul. 2022.
54. BRIDI, A.M. "Padronização, rastreabilidade e certificação de animais e seus produtos." Disponível: www.uel.br/pessoal/ambриди/Carnesecarcacasarquivos/Padronizacao.pdf Universidade Estadual de Londrina, Londrina. 2006
55. PINHO, A.P.D.S. "Caracterização físico-química da carne bovina de marcas comercializadas no município de Porto Alegre." Doutorado em Zootecnia, Universidade Federal do Rio Grande do Sul, Porto Alegre (RS). 2009
56. FREITAS, A.K.D., RESTLE, J., MISSIO, R.L., PACHECO, P.S., PADUA, J.T., MIOTTO, F.R.C., GRECO, L.F., LAGE, M.E., NEIVA, J.N.M. "Carcass physical composition and physicochemical characteristics of meat from Nellore cattle." **Semina Ci. agr.**: p. 1007-1016, 2016.
57. ZIANI, K., KHODJA, F.I., KHALED, M.B. "Physicochemical quality assessment of Brazilian frozen beef imported into Algeria." **The North African Journal of Food and Nutrition Research** 2(3): p. 69-74, 2018.
58. MADRON, M., PETERSON, D., DWYER, D., CORL, B., BAUMGARD, L., BEERMANN, D., BAUMAN, D. "Effect of extruded full-fat soybeans on conjugated linoleic acid content of intramuscular, intermuscular, and subcutaneous fat in beef steers." **Journal of Animal Science** 80(4): p. 1135-1143, 2002.
59. INMETRO, Carnes Bovina e Suína. Teor de Gordura e Colesterol em Alimentos, 2017, Instituto Nacional de Metrologia, Qualidade e Tecnologia. Disponível: <http://www.inmetro.gov.br/consumidor/produtos/teorGordura.asp?iacao=imprimir> Acesso em: 16 jul. 2022.
60. ROSSATO, L.V., BRESSAN, M.C., RODRIGUES, É.C., GAMA, L.T.D., BESSA, R.J.B., ALVES, S.P.A. "Parâmetros físico-químicos e perfil de ácidos graxos da carne de bovinos Angus e Nelore terminados em pastagem." **Revista Brasileira de Zootecnia** 39: p. 1127-1134, 2010.
61. DOS SANTOS, M.F., DE CASTRO, L.M., MAGNABOSCO, C.D.U., LOPES, F.B., BRUNES, L. "Análise multivariada relacionando as características de maciez da carne, crescimento e

carcaça de bovinos da raça Nelore, variedade Mocho." **Embrapa Cerrados-Documentos** (INFOTECA-E), 2016.

62. MAIKO GIORGI PHILIPPE, F.M.M.C., GRACE ADELE GADOTTI, AMABILE CARINE PUEL, CARLOS EDUARDO NOGUEIRA MARTINS, FABIANA MOREIRA, JUAHIL MARTINS DE OLIVEIRA JÚNIOR, VANESSA PERIPOLLI. "Características da carcaça e da carne de bovinos de corte certificados / Carcass and meat traits of certified beef cattle." **Brazilian Journal of Development** 6(7): p. 52942 - 52951, 2020.
63. ABIEC, Beef Report. Perfil da pecuária no Brasil, 2021, ABIEC - Associação Brasileira das Indústrias Exportadoras de Carne. p. 60. Disponível: <http://abiec.com.br/publicacoes/beef-report-2021/> Acesso em: 11 jul. 2022.
64. TRASE. Transparency for Sustainable Economies. 2022; Disponível: https://trase.earth/flows?toolLayout=1&countries=27&commodities=46&selectedColumnsIds=0_7-1_22-2_9-3_16 Acesso em: 08 jul. 2022.
65. ZU ERMGASSEN, E.K.H.J., GODAR, J., LATHUILLIÈRE, M.J., LÖFGREN, P., GARDNER, T., VASCONCELOS, A., MEYFROIDT, P. "The origin, supply chain, and deforestation risk of Brazil's beef exports." **Proceedings of the National Academy of Sciences** 117(50): p. 31770-31779, 2020.
66. GARDNER, T.A., BENZIE, M., BÖRNER, J., DAWKINS, E., FICK, S., GARRETT, R., GODAR, J., GRIMARD, A., LAKE, S., LARSEN, R.K., MARDAS, N., MCDERMOTT, C.L., MEYFROIDT, P., OSBECK, M., PERSSON, M., SEMBRES, T., SUAVET, C., STRASSBURG, B., TREVISAN, A., WEST, C., WOLVEKAMP, P. "Transparency and sustainability in global commodity supply chains." **World Development** 121: p. 163-177, 2019.
67. AVILÉS, C., MARTÍNEZ, A., DOMENECH, V., PEÑA, F. "Effect of feeding system and breed on growth performance, and carcass and meat quality traits in two continental beef breeds." **Meat Science** 107: p. 94-103, 2015.
68. COLEMAN, L.W., HICKSON, R.E., SCHREURS, N.M., MARTIN, N.P., KENYON, P.R., LOPEZ-VILLALOBOS, N., MORRIS, S.T. "Carcass characteristics and meat quality of Hereford sired steers born to beef-cross-dairy and Angus breeding cows." **Meat Science** 121: p. 403-408, 2016.
69. IRSHAD, A., KANDEEPAN, G., KUMAR, S., ASHISH, K., VISHNURAJ, M., SHUKLA, V. "Factors influencing carcass composition of livestock: A review." **Journal of Animal Production Advances** 3(5): p. 177-186, 2012.
70. ROTTA, P.P., PRADO, R.M.D., PRADO, I.N.D., VALERO, M.V., VISENTAINE, J.V., SILVA, R.R. "The effects of genetic groups, nutrition, finishing systems and gender of Brazilian cattle on carcass characteristics and beef composition and appearance: a review." **Asian-Australasian Journal of Animal Sciences** 22(12): p. 1718-1734, 2009.
71. BALLIN, N.Z. "Authentication of meat and meat products." **Meat Science** 86(3): p. 577-587, 2010.
72. SENTANDREU, M.Á. SENTANDREU, E. "Authenticity of meat products: Tools against fraud." **Food Research International** 60: p. 19-29, 2014.

73. HASSOUN, A., MÅGE, I., SCHMIDT, W.F., TEMIZ, H.T., LI, L., KIM, H.Y., NILSEN, H., BIANCOLILLO, A., AÏT-KADDOUR, A., SIKORSKI, M., SIKORSKA, E., GRASSI, S., COZZOLINO, D. "Fraud in animal origin food products: advances in emerging spectroscopic detection methods over the past five years." **Foods** 9(8), 2020.
74. FRANKE, B.M., HALDIMANN, M., GREMAUD, G., BOSSET, J.-O., HADORN, R., KREUZER, M. "Element signature analysis: its validation as a tool for geographic authentication of the origin of dried beef and poultry meat." **European Food Research and Technology** 227(3): p. 701-708, 2008.
75. HORACEK, M. MIN, J.-S. "Discrimination of Korean beef from beef of other origin by stable isotope measurements." **Food Chemistry** 121(2): p. 517-520, 2010.
76. OSORIO, M.T., MOLONEY, A.P., SCHMIDT, O., MONAHAN, F.J. "Beef authentication and retrospective dietary verification using stable isotope ratio analysis of bovine muscle and tail hair." **Journal of Agricultural and Food Chemistry** 59(7): p. 3295-3305, 2011.
77. ZHAO, Y., ZHANG, B., CHEN, G., CHEN, A., YANG, S., YE, Z. "Tracing the geographic origin of beef in China on the basis of the combination of stable isotopes and multielement analysis." **Journal of Agricultural and Food Chemistry** 61(29): p. 7055-7060, 2013.
78. SAKAI, K. "Benefits of the Agilent 8900 ICP-QQQ with MS/MS operation for routine food analysis." **Application Note. Food Safety, Agriculture**, 2017.
79. ATIKUL ISLAM, M., YOUNG JEONG, J., KIM, E.J., KHAN, N., JAMILA, N., KIM, K.S. "Multielemental Characterization of Chicken Breasts from Conventional and Sustainable Farms by Inductively Coupled Plasma – Optical Emission Spectrometry (ICP-OES) and Inductively Coupled Plasma – Mass Spectrometry (ICP-MS)." **Analytical Letters**: p. 1-14, 2022.
80. SUN, S., GUO, B., WEI, Y., FAN, M. "Multi-element analysis for determining the geographical origin of mutton from different regions of China." **Food Chemistry** 124(3): p. 1151-1156, 2011.
81. KELLY, S.D., REES, G., CAIRNS, P., UECKERMANN, H., HOELZL, S., ROSSMANN, A., SCOTTER, M.J. "Verifying the geographical origin of poultry: The application of stable isotope and trace element (SITE) analysis." **Food Control** 67: p. 144-154, 2016.
82. ZHAO, Y., WANG, D., YANG, S. "Effect of organic and conventional rearing system on the mineral content of pork." **Meat Science** 118(Supplement C): p. 103-107, 2016.
83. LV, J. ZHAO, Y. "Combined stable isotopes and multi-element analysis to research the difference between organic and conventional chicken." **Food Analytical Methods** 10(2): p. 347-353, 2017.
84. PERINI, M., NFOR, M.B., CAMIN, F., PIANEZZE, S., PIASENTIER, E. "Using Bioelements Isotope Ratios and Fatty Acid Composition to Deduce Beef Origin and Zebu Feeding Regime in Cameroon." **Molecules** 26(8): p. 2155, 2021.
85. SAHAR, A. DUFOUR, É. "Classification and characterization of beef muscles using front-face fluorescence spectroscopy." **Meat Science** 100: p. 69-72, 2015.

86. AÏT-KADDOUR, A., LOUDIYI, M., FERLAY, A., GRUFFAT, D. "Performance of fluorescence spectroscopy for beef meat authentication: Effect of excitation mode and discriminant algorithms." **Meat Science** 137: p. 58-66, 2018.
87. CHO, S., CHOI, Y., SEOL, K.-H., KANG, S.M., VA, H.B., KIM, Y.-S., KIM, J.-H., SEONG, P.-N., MOON, S.-S., SEO, H.-W. "Comparison of chemical, mineral and vitamin composition of primal and retail cuts of 1+ grade hanwoo steer beef." **Journal of the Korean Society of Food Science and Nutrition** 50(4)2021.
88. DO PRADO, I.N., PASSETTI, R.A.C., RIVAROLI, D.C., ORNAGHI, M.G., DE SOUZA, K.A., CARVALHO, C.B., PEROTTO, D., MOLETTA, J.L. "Carcass composition and cuts of bulls and steers fed with three concentrate levels in the diets." **Asian-Australasian Journal of Animal Sciences** 28(9): p. 1309-1316, 2015.
89. BODE, P., HOFFMAN, E., LINDSTROM, R., PARRY, S., ROSENBERG, R. "Practical aspects of operating a neutron activation analysis laboratory." **IAEA Techdoc** 564, 1990.
90. GREENBERG, R.R., BODE, P., DE NADAI FERNANDES, E.A. "Neutron activation analysis: A primary method of measurement." **Spectrochimica Acta Part B: Atomic Spectroscopy** 66(3): p. 193-241, 2011.
91. GLASCOCK, M.D. "An overview of neutron activation analysis." Columbia, MO: University of Missouri Research Reactor (MURR), 2006.
92. CARDOSO, V. "Estudo das covariâncias envolvidas no método k_0 de análise por ativação neutrônica, Universidade de São Paulo, 2011
93. PUERTA, D.C., FIGUEIREDO, A.M.G., SEMMLER, R., JACIMOVIC, R. " k_0 -INAA of biological matrices at IPEN neutron activation analysis laboratory, Sao Paulo, using the k_0 _IAEA software." **Journal of Radioanalytical and Nuclear Chemistry** 300(2): p. 637-644, 2014.
94. ZAMBONI, C.B., Fundamentos da Física de Nêutrons. 1 ed. 2007: Editora Livraria da Física.
95. SIMONITS, A., DE CORTE, F., HOSTE, J. "Single-comparator methods in reactor neutron activation analysis." **Journal of Radioanalytical Chemistry** 24(1): p. 31, 1975.
96. DE CORTE, F. SIMONITS, A. " k_0 - Measurements and related nuclear data compilation for (n, γ) reactor neutron activation analysis: IIIb: tabulation." **Journal of Radioanalytical and Nuclear Chemistry** 133(1): p. 43-130, 1989.
97. KOLOTOV, V. DE CORTE, F. "Compilation of k_0 and related data for neutron-activation analysis (NAA) in the form of an electronic database." **Pure and Applied Chemistry** 76(10): p. 1921-1925, 2004.
98. DE CORTE, F., SIMONITS, A., DE WISPELAERE, A., HOSTE, J. "Accuracy and applicability of the k_0 -standardization method." **Journal of Radioanalytical and Nuclear Chemistry** 113(1): p. 145-161, 1987.

99. DE CORTE, F., MOENS, L., JOVANOVIĆ, S., SIMONITS, A., DE WISPELAERE, A. "Applicability of the $1/E^{1+\alpha}$ epithermal spectrum representation and the effective resonance energy $E^{-\tau}$ in NAA." **Journal of Radioanalytical and Nuclear Chemistry** 102(1): p. 37-57, 1986.
100. PORTAL, P.A.D. Crise no Brasil atrasou tecnologias como inteligência artificial. 2017 ; Disponível: <https://www.folhape.com.br/economia/economia/tecnologia/2017/10/05/NWS.44181,10.476,ECONOMIA,2373-CRISE-BRASIL-ATRASOU-TECNOLOGIAS-COMO-INTELIGENCIA-ARTIFICIAL.aspx> Acesso em: 30 jul. 2022.
101. MIRJANKAR, N. HIREMATH, S. "Application of data mining in agriculture field." **International Journal of Computer Engineering and Applications**, iCCSTAR-2016, Special Issue, 2016.
102. ABUZIR, Y. "Predict the main factors that affect the vegetable production in palestine using Weka data mining tool." **Palestinian Journal of Technology and Applied Sciences (PJTAS)**(1), 2017.
103. KAMILARIS, A. PRENAFETA-BOLDÚ, F.X. "Deep learning in agriculture: A survey." **Computers and Electronics in Agriculture** 147: p. 70-90, 2018.
104. KAMILARIS, A., KARTAKOULLIS, A., PRENAFETA-BOLDÚ, F.X. "A review on the practice of big data analysis in agriculture." **Computers and Electronics in Agriculture** 143: p. 23-37, 2017.
105. DRURY, B., VALVERDE-REBAZA, J., MOURA, M.-F., DE ANDRADE LOPES, A. "A survey of the applications of Bayesian networks in agriculture." **Engineering Applications of Artificial Intelligence** 65: p. 29-42, 2017.
106. TRACXN. AI in Agriculture Startups in Brazil. 2022 ; Disponível: <https://tracxn.com/explore/AI-in-Agriculture-Startups-in-Brazil> Acesso em: 25 jul. 2022.
107. GREGIO, F. Development and Innovation Environmental and land management. 2021; Disponível: <https://www.embrapa.br/en/busca-de-noticias/-/noticia/65083648/brazil-uses-satellite-and-machine-learning-to-monitor-agriculture--sustainable-intensification> Acesso em: 10 jul. 2022.
108. AZEVEDO, R.S.A., TEIXEIRA, B.S., SAUTHIER, M.C.D.S., SANTANA, M.V.A., DOS SANTOS, W.N.L., SANTANA, D.D.A. "Multivariate analysis of the composition of bioactive in tea of the species *Camellia sinensis*." **Food Chemistry** 273: p. 39-44, 2019.
109. DA SILVA SAUTHIER, M.C., DA SILVA, E.G.P., DA SILVA SANTOS, B.R., SILVA, E.F.R., DA CRUZ CALDAS, J., CAVALCANTE MINHO, L.A., DOS SANTOS, A.M.P., DOS SANTOS, W.N.L. "Screening of *Mangifera indica* L. functional content using PCA and neural networks (ANN)." **Food Chemistry** 273: p. 115-123, 2019.
110. VOICA, C., IORDACHE, A.M., IONETE, R.E. "Multielemental characterization of honey using inductively coupled plasma mass spectrometry fused with chemometrics." **Journal of Mass Spectrometry** 55(7): p. e4512, 2020.

111. DRIVELOS, S.A., HIGGINS, K., KALIVAS, J.H., HAROUTOUNIAN, S.A., GEORGIU, C.A. "Data fusion for food authentication. Combining rare earth elements and trace metals to discriminate "Fava Santorinis" from other yellow split peas using chemometric tools." **Food Chemistry** 165: p. 316-322, 2014.
112. KANG, X., ZHAO, Y., PENG, J., DING, H., TAN, Z., HAN, C., SHENG, X., LIU, X., ZHAI, Y. "Authentication of the Geographical Origin of Shandong Scallop *Chlamys farreri* Using Mineral Elements Combined with Multivariate Data Analysis and Machine Learning Algorithm." **Food Analytical Methods**, 2022.
113. BARBOSA, R.M., BATISTA, B.L., VARRIQUE, R.M., COELHO, V.A., CAMPIGLIA, A.D., BARBOSA, F. "The use of advanced chemometric techniques and trace element levels for controlling the authenticity of organic coffee." **Food Research International** 61: p. 246-251, 2014.
114. FERNANDES, E.A.D.N., SARRIES, G.A., MAZOLA, Y.T., LIMA, R.C., FURLAN, G.N., BACCHI, M.A. "Machine learning to support geographical origin traceability of *Coffea arabica*." **Advances in Artificial Intelligence and Machine Learning** 2(1): p. 273-287, 2022.
115. BARBOSA, R.M., BATISTA, B.L., BARIÃO, C.V., VARRIQUE, R.M., COELHO, V.A., CAMPIGLIA, A.D., BARBOSA, F. "A simple and practical control of the authenticity of organic sugarcane samples based on the use of machine-learning algorithms and trace elements determination by inductively coupled plasma mass spectrometry." **Food Chemistry** 184: p. 154-159, 2015.
116. MAIONE, C. "Mineração de dados para o reconhecimento da origem e do tipo de alimentos e outras substâncias com base em sua composição química". Mestrado em Computação, Universidade Federal de Goiás, Goiânia. 2016
117. ALCÁZAR, Á., JURADO, J.M., PALACIOS-MORILLO, A., DE PABLOS, F., MARTÍN, M.J. "Recognition of the geographical origin of beer based on support vector machines applied to chemical descriptors." **Food Control** 23(1): p. 258-262, 2012.
118. MAIONE, C., BATISTA, B.L., CAMPIGLIA, A.D., BARBOSA, F., BARBOSA, R.M. "Classification of geographic origin of rice by data mining and inductively coupled plasma mass spectrometry." **Computers and Electronics in Agriculture** 121: p. 101-107, 2016.
119. BARBOSA, R.M., DE PAULA, E.S., PAULELLI, A.C., MOORE, A.F., SOUZA, J.M.O., BATISTA, B.L., CAMPIGLIA, A.D., BARBOSA, F. "Recognition of organic rice samples based on trace elements and support vector machines." **Journal of Food Composition and Analysis** 45: p. 95-100, 2016.
120. FECHNER, D.C., HIDALGO, M.J., RUIZ DÍAZ, J.D., GIL, R.A., PELLERANO, R.G. "Geographical origin authentication of honey produced in Argentina." **Food Bioscience** 33: p. 100483, 2020.
121. BATISTA, B.L., DA SILVA, L.R.S., ROCHA, B.A., RODRIGUES, J.L., BERRETTA-SILVA, A.A., BONATES, T.O., GOMES, V.S.D., BARBOSA, R.M., BARBOSA, F. "Multi-element determination in Brazilian honey samples by inductively coupled plasma mass

- spectrometry and estimation of geographic origin with data mining techniques." **Food Research International** 49(1): p. 209-215, 2012.
122. LUCCAS, F.S., FERNANDES, E.A.D.N., MAZOLA, Y.T., BACCHI, M.A., SARRIÉS, G.A. "Optimization of sample preparation of Brazilian honeys for TQ-ICP-MS analysis." **Talanta Open** 5: p. 100117, 2022.
 123. GREDELL, D.A., SCHROEDER, A.R., BELK, K.E., BROECKLING, C.D., HEUBERGER, A.L., KIM, S.-Y., KING, D.A., SHACKELFORD, S.D., SHARP, J.L., WHEELER, T.L., WOERNER, D.R., PRENNI, J.E. "Comparison of machine learning algorithms for predictive modeling of beef attributes using rapid evaporative ionization mass spectrometry (REIMS) data." **Scientific Reports** 9(1): p. 5721, 2019.
 124. BRAMER, M., Principles of data mining. Vol. 180. 2016: Springer.
 125. XU, Y., ZOMER, S., BRERETON, R.G. "Support vector machines: a recent method for classification in chemometrics." **Critical Reviews in Analytical Chemistry** 36(3-4): p. 177-188, 2006.
 126. DE MELLO, R.F. PONTI, M.A., Machine Learning: A Practical Approach on the Statistical Learning Theory. 1 ed. 2018: Springer International Publishing.
 127. KEERTHI, S.S., SHEVADE, S.K., BHATTACHARYYA, C., MURTHY, K.R.K. "Improvements to Platt's SMO algorithm for SVM classifier design." **Neural Computation** 13(3): p. 637-649, 2001.
 128. TAN, P.-N., Introduction to data mining. 2005: Pearson Education India.
 129. GARDNER, M.W. DORLING, S.R. "Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences." **Atmospheric Environment** 32(14): p. 2627-2636, 1998.
 130. BEL, L., ALLARD, D., LAURENT, J.M., CHEDDADI, R., BAR-HEN, A. "CART algorithm for spatial data: Application to environmental and ecological data." **Computational Statistics & Data Analysis** 53(8): p. 3082-3093, 2009.
 131. BREIMAN, L. "Random Forests." **Machine Learning** 45(1): p. 5-32, 2001.
 132. LIAW, A. WIENER, M. "Classification and regression by Random Forest." **R news** 2(3): p. 18-22, 2002.
 133. BRACKEBUSCH, S.A., MCKEITH, F.K., CARR, T.R., MCLAREN, D.G. "Relationship between longissimus composition and the composition of other major muscles of the beef carcass." **Journal of Animal Science** 69(2): p. 631-640, 1991.
 134. EGELANDSDAL, B., WOLD, J.P., SPONNICH, A., NEEGÅRD, S., HILDRUM, K.I. "On attempts to measure the tenderness of Longissimus dorsi muscles using fluorescence emission spectra." **Meat Science** 60(2): p. 187-202, 2002.
 135. AÏT-KADDOUR, A., JACQUOT, S., MICOL, D., LISTRAT, A. "Discrimination of beef muscle based on visible-near infrared multi-spectral features: Textural and spectral analysis." **International Journal of Food Properties** 20(6): p. 1391-1403, 2017.

136. GREINER, S.P., ROUSE, G.H., WILSON, D.E., CUNDIFF, L.V., WHEELER, T.L. "The relationship between ultrasound measurements and carcass fat thickness and longissimus muscle area in beef cattle." **Journal of Animal Science** 81(3): p. 676-682, 2003.
137. BEEFPOINT, E. Nelore: conheça mais sobre a raça que representa 80% do gado de corte brasileiro. 2013; Disponível: <https://www.beefpoint.com.br/nelore-conheca-mais-sobre-a-raça-que-representa-80-do-gado-de-corte-brasileiro-projeto-racas/> Acesso em: 03 jul. 2022.
138. SANTOS, R.D., Zebu: a pecuária sustentável: edição comemorativa de 75 anos de registro genealógico e 80 da ABCZ. 2013, Uberaba, MG: Uberaba: Agropecuária Tropical.
139. WAGYU_INTERATIONAL. Wagyu around the World - Brazil. 2022; Disponível: http://www.wagyuinternational.com/global_Brazil.php Acesso em: 11 jul. 2022.
140. RIBEIRO, L.F.D. "Perspectivas da produção de carne bovina no Brasil—raças e seus cruzamentos". Trabalho de Conclusão de Curso (graduação), Universidade de Brasília, Brasília - DF. 2018
141. A.TERRY, S., A.BASARAB, J., LUOGUAN, L., A.MCALLISTER, T., FILIPPOMIGLIOR. "Strategies to improve the efficiency of beef cattle production." **Canadian Journal of Animal Science** 101(1): p. 1-19, 2021.
142. ONDEI, V. CAETANO, M. O terroir da carne. 2016; Disponível: <https://www.dinheirorural.com.br/o-terroir-da-carne/> Acesso em: 01 jul. 2022.
143. MENEZES, G.F. "Análise comparativa das características físico-químicas e da aceitação sensorial da carne de bovinos three cross (Wagyu, Angus e Nelore) alimentados com ração adicionada de grão de soja e ração tradicional". Estágio Supervisionado Graduação em Engenharia de Alimentos, Universidade Estadual Paulista "Júlio de Mesquita Filho", São José do Rio Preto - SP. 2013
144. RIISPOA, Regulamento da Inspeção Industrial e Sanitária dos produtos de Origem Animal, M.d. Agricultura., Editor 1980: Brasilia-DF. p. 166.
145. CELESTINO, S.M.C. "Princípios de secagem de alimentos." Embrapa Cerrados- Documentos (INFOTECA-E) **Documento** 276: p. 51, 2010.
146. KONIECZKA, P. NAMIESNIK, J., Quality assurance and quality control in the analytical chemical laboratory: a practical approach. 2016: CRC Press.
147. ISO, Statistical methods for use in proficiency testing by interlaboratory comparison, in ISO 13528, I. Standard, Editor 2015: Switzerland. p. 88.
148. SATHLER, M.M., DE SALLES, P.M.B., MENEZES, M.Â.D.B.C. "Trace elements detection in whole food samples by neutron activation analysis, k_0 -method." **Brazilian Journal of Radiation Sciences** 7(2A), 2019.
149. FRANÇA, E. J., FERNANDES, E.D.N., BACCHI, M. A. "Ni-Cr alloy as neutron flux monitor: composition and homogeneity assessment by NAA." **Journal of Radioanalytical and Nuclear Chemistry** 257(1): p. 113-115, 2003.

150. IAEA. Live Chart of Nuclides. 2022; Disponível: <https://www-nds.iaea.org/relnsd/vcharthtml/VChartHTML.html> Acesso em: 24 jul. 2022.
151. BACCHI, M.A. FERNANDES, E.A.N. "Quantu design and development of a software package dedicated to k_0 -standardized NAA " **Journal of Radioanalytical and Nuclear Chemistry** 257(3): p. 577-582, 2003.
152. BACCHI, M.A., FERNANDES, E.A.D., FRANÇA, E.J., BODE, P. "Quality assessment in a Brazilian laboratory performing k_0 -NAA." **Journal of Radioanalytical and Nuclear Chemistry** 257(3): p. 653-657, 2003.
153. BACCHI, M.A., FERNANDES, E.A.N., OLIVEIRA, H. "Brazilian experience on k_0 stardardized neutron activation analysis." **Journal of Radioanalytical and Nuclear Chemistry** 245: p. 217-222, 2000.
154. WITTEN, I.H., FRANK, E., HALL, M.A., PAL, C.J., Data Mining: Practical machine learning tools and techniques. Fourth Edition ed. 2016: Morgan Kaufmann.
155. HALL, M., FRANK, E., HOLMES, G., PFAHRINGER, B., REUTEMANN, P., WITTEN, I.H. "The WEKA data mining software: an update." **ACM SIGKDD Explorations Newsletter** 11(1): p. 10–18, 2009.
156. BISHOP, C., Pattern Recognition and Machine Learning (Information Science and Statistics), 1st edn. 2006. corr. 2nd printing edn. Springer, New York, ed. J.K.a.B.S. Michael Jordan. 2007.
157. GORUNESCU, F., Data Mining: Concepts, models and techniques. Vol. 12. 2011: Springer Science & Business Media.
158. GRANATO, D., DE ARAÚJO CALADO, V.M., JARVIS, B. "Observations on the use of statistical methods in Food Science and Technology." **Food Research International** 55: p. 137-149, 2014.
159. FERREIRA, S.L.C., SILVA JUNIOR, M.M., FELIX, C.S.A., DA SILVA, D.L.F., SANTOS, A.S., SANTOS NETO, J.H., DE SOUZA, C.T., CRUZ JUNIOR, R.A., SOUZA, A.S. "Multivariate optimization techniques in food analysis – A review." **Food Chemistry** 273: p. 3-8, 2019.
160. SILVA, T.L.G. "Método Estatístico de Análise de Cluster aplicado aos dados de uma Associação de Proteção Veicular." 2013.
161. MATERA, J.A., CRUZ, A.G., RAICES, R.S.L., SILVA, M.C., NOGUEIRA, L.C., QUITÉRIO, S.L., CAVALCANTI, R.N., FREIRAS, M.Q., CONTE JÚNIOR, C.A. "Discrimination of Brazilian artisanal and inspected pork sausages: Application of unsupervised, linear and non-linear supervised chemometric methods." **Food Research International** 64: p. 380-386, 2014.
162. MAIONE, C., DE PAULA, E.S., GALLIMBERTI, M., BATISTA, B.L., CAMPIGLIA, A.D., JR, F.B., BARBOSA, R.M. "Comparative study of data mining techniques for the authentication of organic grape juice based on ICP-MS analysis." **Expert Systems with Applications** 49: p. 60-73, 2016.

163. BISUTTI, V., MERLANTI, R., SERVA, L., LUCATELLO, L., MIRISOLA, M., BALZAN, S., TENTI, S., FONTANA, F., TREVISAN, G., MONTANUCCI, L., CONTIERO, B., SEGATO, S., CAPOLONGO, F. "Multivariate and machine learning approaches for honey botanical origin authentication using near infrared spectroscopy." *Journal of Near Infrared Spectroscopy* 27(1): p. 65-74, 2019.
164. TURRA, C., DIAS DE LIMA, M., FERNANDES, E.A.D.N., BACCHI, M.A., BARBOSA, F., BARBOSA, R. "Multielement determination in orange juice by ICP-MS associated with data mining for the classification of organic samples." *Information Processing in Agriculture* 4(3): p. 199-205, 2017.
165. BACCHI, M.A., FERNANDES, E.A.N., MAZOLA, Y.T., GONZAGA, C.L. "Stability of sodium mass fraction in agricultural certified reference materials." *Talanta Open* 5: p. 100097, 2022.
166. NIST, N.I.O.S.A.T., Certificate of Analysis Standard Reference Material 1515 Apple Leaves, 2019, U.S. Department of Commerce. p. 7.
167. NIST, Certificate of Analysis Standard Reference Material 1577c Bovine Liver, 2018, U.S. Department of Commerce: National Institute of Standards and Technology p. 6.
168. NIST, Certificate of Analysis Standard Reference Material 1566b Oyster Tissue, 2019, U.S. Department of Commerce: National Institute of Standards and Technology p. 6.
169. IAEA. "IAEA-336 Trace and minor elements in lichen " **Analytical Quality Control Services(Reference Sheet)**: p. 4, 1999.
170. SANDER, R., KEENE, W., PSZENNY, A., ARIMOTO, R., AYERS, G., BABOUKAS, E., CAINEY, J., CRUTZEN, P., DUCE, R., HÖNNINGER, G. "Inorganic bromine in the marine boundary layer: a critical review." *Atmospheric Chemistry and Physics* 3(5): p. 1301-1336, 2003.
171. ZHU, L., JACOB, D.J., EASTHAM, S.D., SULPRIZIO, M.P., WANG, X., SHERWEN, T., EVANS, M.J., CHEN, Q., ALEXANDER, B., KOENIG, T.K., VOLKAMER, R., HUEY, L.G., LE BRETON, M., BANNAN, T.J., PERCIVAL, C.J. "Effect of sea salt aerosol on tropospheric bromine chemistry." *Atmospheric Chemistry and Physics* 19(9): p. 6497-6507, 2019.
172. YAMASOE, M.A., ARTAXO, P., MIGUEL, A.H., ALLEN, A.G. "Chemical composition of aerosol particles from direct emissions of vegetation fires in the Amazon Basin: water-soluble species and trace elements." *Atmospheric Environment* 34(10): p. 1641-1653, 2000.
173. FERNANDES, E.A.D.N., MAZOLA, Y.T., SARRIÉS, G.A., BACCHI, M.A., BODE, P., GONZAGA, C.L., SARRIÉS, S.R. "Discriminating Beef Producing Countries by Multi-Element Analysis and Machine Learning." *Advances in Artificial Intelligence and Machine Learning* 1(1): p. 1, 2021.
174. BEUCHLE, R., GRECCHI, R.C., SHIMABUKURO, Y.E., SELIGER, R., EVA, H.D., SANO, E., ACHARD, F. "Land cover changes in the Brazilian Cerrado and Caatinga biomes from 1990 to 2010 based on a systematic remote sensing sampling approach." *Applied Geography* 58: p. 116-127, 2015.

175. DUMONT, E., DE PAUW, L., VANHAECKE, F., CORNELIS, R. "Speciation of Se in *Bertholletia excelsa* (Brazil nut): A hard nut to crack?" **Food Chemistry** 95(4): p. 684-692, 2006.
176. CHANG, J.C., GUTENMANN, W.H., REID, C.M., LISK, D.J. "Selenium content of Brazil nuts from two geographic locations in Brazil." **Chemosphere** 30(4): p. 801-802, 1995.
177. SILVA JUNIOR, E.C., WADT, L.H.O., SILVA, K.E., LIMA, R.M.B., BATISTA, K.D., GUEDES, M.C., CARVALHO, G.S., CARVALHO, T.S., REIS, A.R., LOPES, G., GUILHERME, L.R.G. "Natural variation of selenium in Brazil nuts and soils from the Amazon region." **Chemosphere** 188: p. 650-658, 2017.
178. TURN, S., JENKINS, B.M., CHOW, J., PRITCHETT, L., CAMPBELL, D., CAHILL, T., WHALEN, S. "Elemental characterization of particulate matter emitted from biomass burning: Wind tunnel derived source profiles for herbaceous and wood fuels." **Journal of Geophysical Research: Atmospheres** 102(D3): p. 3683-3699, 1997.
179. ARTAXO, P., FERNANDAS, E.T., MARTINS, J.V., YAMASOE, M.A., HOBBS, P.V., MAENHAUT, W., LONGO, K.M., CASTANHO, A. "Large-scale aerosol source apportionment in Amazonia." **Journal of Geophysical Research: Atmospheres** 103(D24): p. 31837-31847, 1998.
180. FERNANDES, E.A.D.N., SARRIÉS, G.A., BACCHI, M.A., MAZOLA, Y.T., GONZAGA, C.L., SARRIÉS, S.R.V. "Trace elements and machine learning for Brazilian beef traceability." **Food Chemistry** 333: p. 127462, 2020.
181. DE FARIA, A.S., DE ARAÚJO, F.M., FERREIRA, L.G., DE MOURA NOGUEIRA, S.H., Monitoramento do desmatamento no bioma Cerrado: Novas perspectivas de detecção, in Anais do XVIII Simpósio Brasileiro de Sensoriamento Remoto - SBSR2017, INPE. Disponível: <http://marte2.sid.inpe.br/col/sid.inpe.br/marte2/2017/10.27.14.08/doc/60128.pdf> Acesso em: 14 jul. 2022.
182. TEJEDA MAZOLA, Y., DE NADAI FERNANDES, E.A., SARRIÉS, G.A., BACCHI, M.A., GONZAGA, C.L. "Neutron activation analysis and data mining techniques to discriminate between beef cattle diets." **Journal of Radioanalytical and Nuclear Chemistry**, 322(3), 2019.
183. MARTIN, B., COPPA, M., VERDIER-METZ, I., MONTEL, M., JOY, M., CASASÚS, I., BLANCO, M. "The contribution of mountain pastures to the link to terroir in dairy and meat products." **Mountain Pastures and Livestock Farming Facing Uncertainty: Environmental, Technical and Socio-Economic Challenges**: p. 105-115, 2016.
184. FONTOURA, L.F.M. "Pampa: Terroir do gado bovino?" **Geosul** 34(71): p. 213-238, 2019.
185. LI, X., LIU, T., CHANG, C., LEI, Y., MAO, X. "Analytical Methodologies for Agrometallomics: A Critical Review." **Journal of Agricultural and Food Chemistry** 69(22): p. 6100-6118, 2021.
186. OTERO, N., VITORIA, L., SOLER, A., CANALS, A. "Fertilizer characterisation: major, trace and rare earth elements." **Applied Geochemistry** 20(8): p. 1473-1488, 2005.

187. ABDEL-HALEEM, A.S., SROOR, A., EL-BAHI, S.M., ZOHNY, E. "Heavy metals and rare earth elements in phosphate fertiliser components using instrumental neutron activation analysis." **Applied Radiation and Isotopes** 55(4): p. 569-573, 2001.
188. TURRA, C., DE NADAI FERNANDES, E.A., BACCHI, M.A., SARRIÉS, G.A., REYES, A.E.L. Uptake of rare earth elements by citrus plants from phosphate fertilizers. **Plant and Soil** 437(1): p. 291-299, 2019.
189. TURRA, C., DE NADAI FERNANDES, E.A., BACCHI, M.A., SARRIÉS, G.A., JÚNIOR, F.B., REYES, A.E.L. Rare earth elements in citrus production systems. **Journal of Plant Nutrition** 36(5): p. 762-771, 2013.
190. JOEBSTL, D., BANDONIENE, D., MEISEL, T., CHATZISTATHIS, S. Identification of the geographical origin of pumpkin seed oil by the use of rare earth elements and discriminant analysis. **Food Chemistry** 123(4): p. 1303-1309, 2010.
191. MEHDI, Y. DUFRASNE, I. Selenium in Cattle: A Review. **Molecules** 21(4): p. 545, 2016.

APÊNDICES

Apêndice A - Nível de desenvolvimento e cabeças de gado em diferentes biomas

No,	Município	Bioma Predominante	Cabeças de Gado	Nível Desenvolvimento
1	São Félix do Xingu - PA	Amazônia	2,154,474	Baixo
2	Porto Velho - RO	Amazônia	881,651	Baixo
3	Rio Branco - AC	Amazônia	513,734	Baixo
4	Vila Bela da Santíssima Trindade - MT	Amazônia - Pantanal	982,763	Baixo
5	Manaus - AM	Amazônia	3729	Médio
6	São Gabriel da Cachoeira - AM	Amazônia	-	Médio
7	Barcelos - AM	Amazônia	-	Médio
8	Belém - PA	Amazônia	-	Alto
9	Coari - AM	Amazônia	-	Alto
10	Manacapuru - AM	Amazônia	-	Alto
11	Ribas do Rio Pardo - MS	Cerrado	1,124,120	Médio
12	Santa Rita do Pardo - MS	Cerrado	548,327	Médio
13	Barretos - SP	Cerrado	43861	Alto
14	Juara - MT	Amazônia - Cerrado	956,052	Alto
15	Brasília - DF	Cerrado	84425	Alto
16	Nova Crixás - GO	Cerrado	737,141	Baixo
17	Imperatriz - MA	Cerrado	68967	Baixo
18	São Miguel do Araguaia - GO	Cerrado	563,721	Baixo
19	Santo Antônio do Leverger - MT	Cerrado	574,728	Baixo
20	Cáceres - MT	Pantanal	1,089,932	Médio
21	Corumbá - MS	Pantanal	1,782,064	Médio
22	Alegrete - RS	Pampa	635,355	Médio
23	Itamaraju - BA	Mata Atlântica	172,980	Médio

Apêndice B - Dados referentes aos animais empregados na primeira etapa do estudo, WAG refere-se a ¼ Angus - ¼ Nelore - ½ - Wagyu e ANG a ½ Angus - ½ Nelore


Data Coleta	Código Animal	Raça	Sexo	Entrada Curral	Data Nascimento	Peso Entrada (kg)	Peso Saída (kg)	Dias Spa	Data Saída	Picanha	Contrafilé	Acém
11/8/2017	103	WAG	M	1/18/2017	8/24/2014	300	755	291	11/5/2017	X	X	
11/8/2017	149	WAG	F	1/18/2017	9/20/2014	300	589	291	11/5/2017	X	X	
11/8/2017	483	WAG	M	1/18/2017	11/19/2014	318	740	291	11/5/2017	X	X	
11/8/2017	804	WAG	F	1/18/2017	11/15/2014	300	593	291	11/5/2017	X	X	
11/8/2017	319	WAG	F	7/1/2017	10/22/2014	425	606	128	11/6/2017	X	X	
11/8/2017	390	WAG	F	5/16/2017	10/30/2014	386	559	175	11/7/2017	X	X	
11/8/2017	0011	ANG	F	2/27/2017	7/22/2015	379	639	251	11/5/2017	X	X	
11/8/2017	0395	ANG	F	2/27/2017	10/26/2015	292	604	251	11/5/2017	X	X	
11/8/2017	0431	ANG	M	2/27/2017	11/1/2015	355	683	251	11/5/2017	X	X	
11/8/2017	0451	ANG	F	2/27/2017	11/1/2015	335	561	251	11/5/2017	X	X	
11/8/2017	0460	ANG	M	2/27/2017	11/5/2015	359	626	251	11/5/2017	X	X	
11/8/2017	3102	ANG	F	2/27/2017	8/8/2015	374	680	251	11/5/2017	X	X	
11/8/2017	3166	ANG	F	2/27/2017	10/23/2015	324	657	251	11/5/2017	X	X	
11/22/2017	177	WAG	M	3/14/2017	9/24/2014	522	726	247	11/16/2017	X	X	
11/22/2017	271	WAG	F	6/20/2017	10/13/2014	417	614	149	11/16/2017	X	X	
11/22/2017	378	WAG	F	6/20/2017	10/29/2014	300	616	149	11/16/2017	X	X	
11/22/2017	428	WAG	F	5/16/2017	11/4/2014	429	556	184	11/16/2017	X	X	
11/22/2017	444	WAG	M	1/18/2017	11/8/2014	470	643	302	11/16/2017	X	X	
11/22/2017	471	WAG	F	6/20/2017	11/16/2014	480	640	149	11/16/2017	X	X	
11/22/2017	493	WAG	F	1/18/2017	11/21/2014	358	706	302	11/16/2017	X	X	
11/22/2017	501	WAG	M	1/18/2017	11/23/2014	540	701	302	11/16/2017	X	X	
11/22/2017	529	WAG	F	5/23/2017	11/30/2014	453	644	177	11/16/2017	X	X	

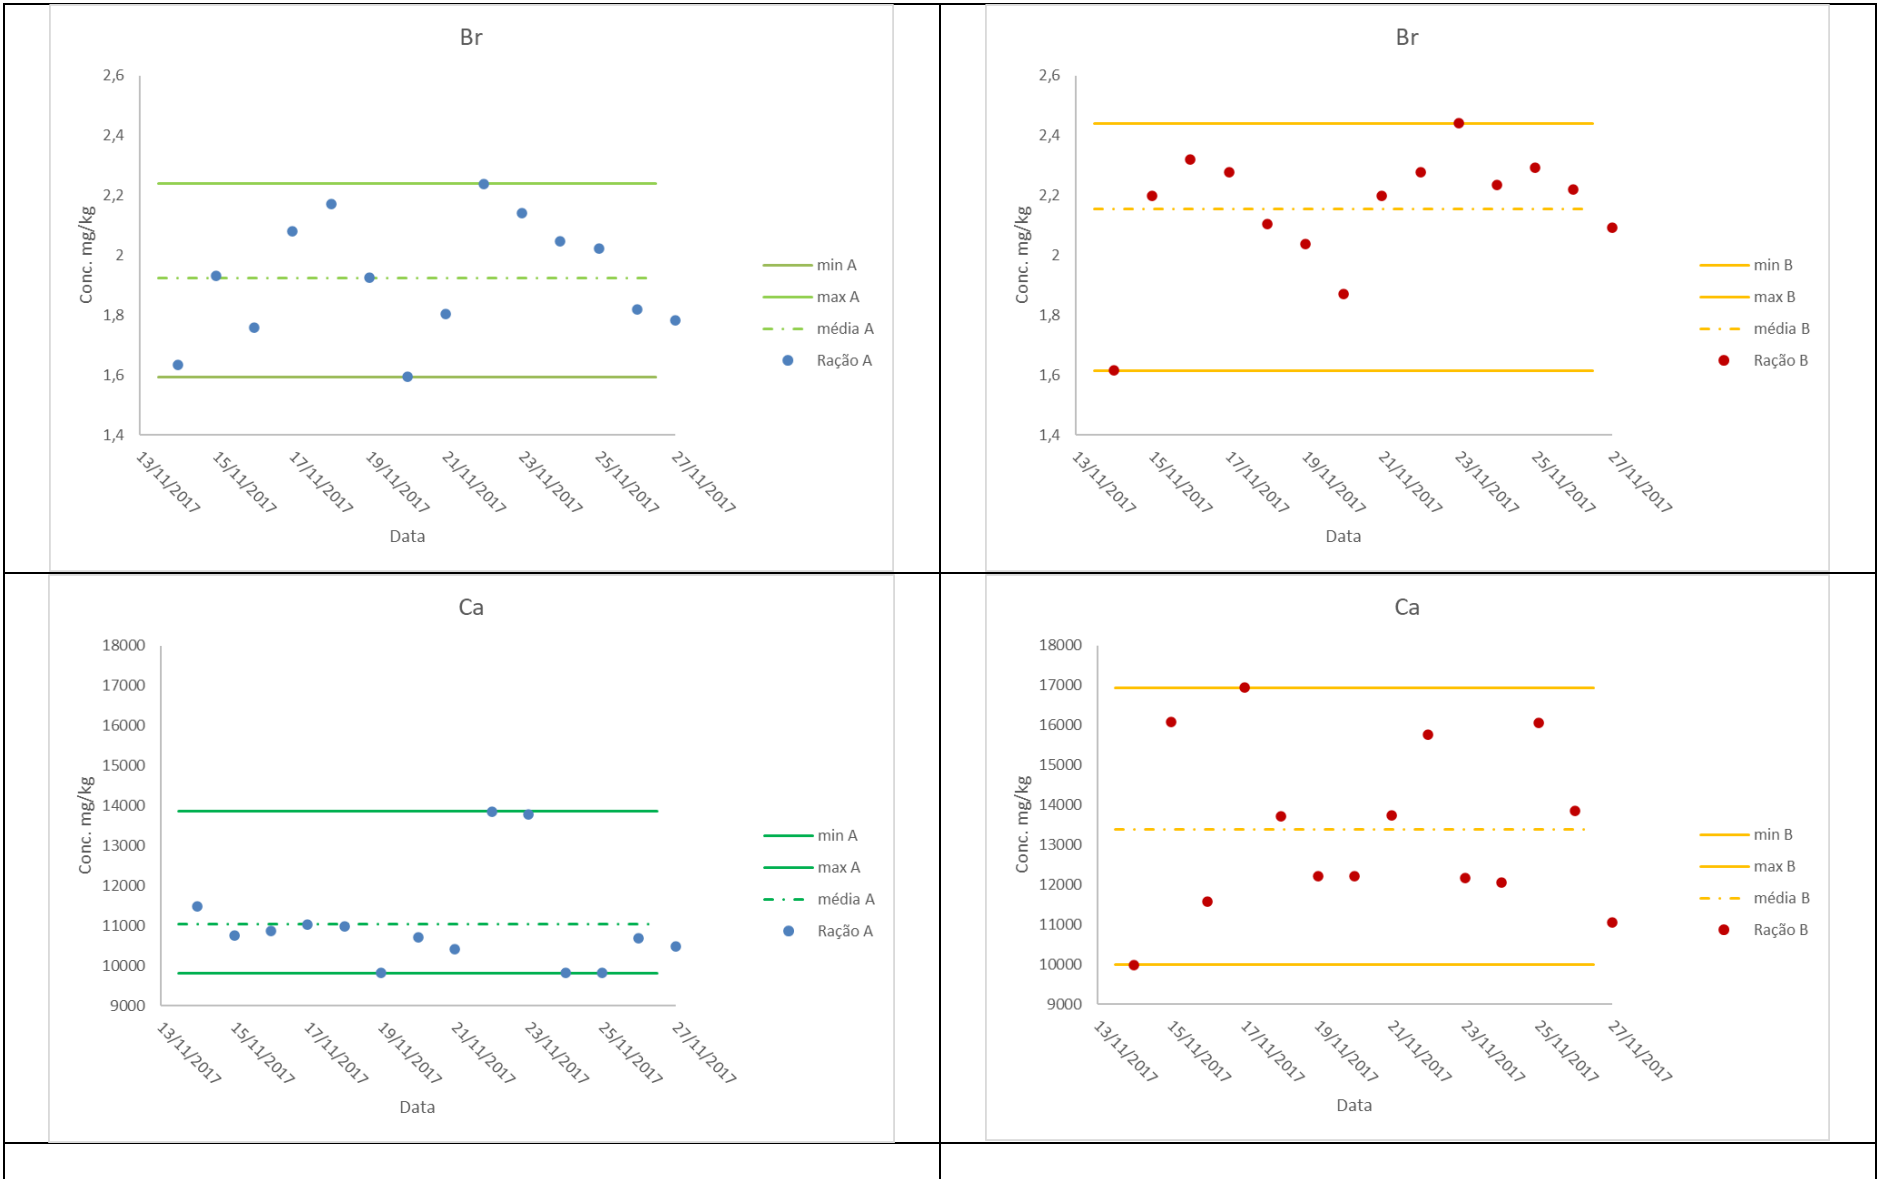
Data Coleta	Código Animal	Raça	Sexo	Entrada Curral	Data Nascimento	Peso Entrada (kg)	Peso Saída (kg)	Dias Spa	Data Saída	Picanha	Contrafilé	Acém
11/22/2017	616	WAG	F	6/20/2017	12/25/2014	460	636	149	11/16/2017	X	X	
11/22/2017	667	WAG	M	1/18/2017	1/10/2014	542	711	302	11/16/2017	X	X	
11/22/2017	284	ANG	M	2/27/2017	10/6/2015	310	656	263	11/17/2017	X	X	
11/22/2017	614	ANG	M	2/27/2017	12/27/2015	325	655	263	11/17/2017	X	X	
11/22/2017	1682	ANG	F	3/7/2017	11/20/2015	305	583	255	11/17/2017	X	X	
11/22/2017	3001	ANG	F	2/27/2017	2/28/2015	374	601	263	11/17/2017	X	X	
11/22/2017	3143	ANG	M	2/27/2017	10/1/2015	344	600	263	11/17/2017	X	X	
11/22/2017	3224	ANG	F	2/27/2017	11/21/2015	293	551	263	11/17/2017	X	X	
11/22/2017	3230	ANG	M	2/27/2017	11/21/2015	324	676	263	11/17/2017	X	X	
11/22/2017	3241	ANG	M	2/27/2017	11/26/2015	328	629	263	11/17/2017	X	X	
11/22/2017	3366	ANG	F	2/27/2017	1/18/2016	291	646	263	11/17/2017	X	X	
11/22/2017	7484	ANG	F	4/18/2017	15/06/2014	425	781	213	11/17/2017	X	X	
11/22/2017	80	ANG	M	7/2/2017	8/1/2016	320	545	138	11/17/2017	X	X	
11/29/2017	7	WAG	M	1/18/2017	7/21/2014	498	643	302	11/16/2017	X	X	X
11/29/2017	336	WAG	M	1/12/2017	10/24/2014	409	807	308	11/16/2017	X	X	X
11/29/2017	352	WAG	M	1/18/2017	10/27/2014	341	713	302	11/16/2017	X	X	X
11/29/2017	385	WAG	F	6/20/2017	10/29/2014	343	612	149	11/16/2017	X	X	X
11/29/2017	437	WAG	M	1/18/2017	11/6/2014	248	696	302	11/16/2017	X	X	X
11/29/2017	456	WAG	M	2/13/2017	11/12/2014	338	748	276	11/16/2017	X	X	X
11/29/2017	491	WAG	F	6/20/2017	11/21/2014	343	668	149	11/16/2017	X	X	X
11/29/2017	512	WAG	F	2/27/2017	11/19/2015	244	538	262	11/16/2017	X	X	X
11/29/2017	513	WAG	M	1/18/2017	11/26/2014	518	755	302	11/16/2017	X	X	X
11/29/2017	544	WAG	M	1/18/2017	12/2/2014	406	810	302	11/16/2017	X	X	X
11/29/2017	691	WAG	F	5/23/2017	2/20/2014	273	593	177	11/16/2017	X	X	X
11/29/2017	317	ANG	M	3/7/2017	10/14/2015	355	587	255	11/17/2017	X	X	X
11/29/2017	487	ANG	M	2/27/2017	11/9/2015	325	600	263	11/17/2017	X	X	X


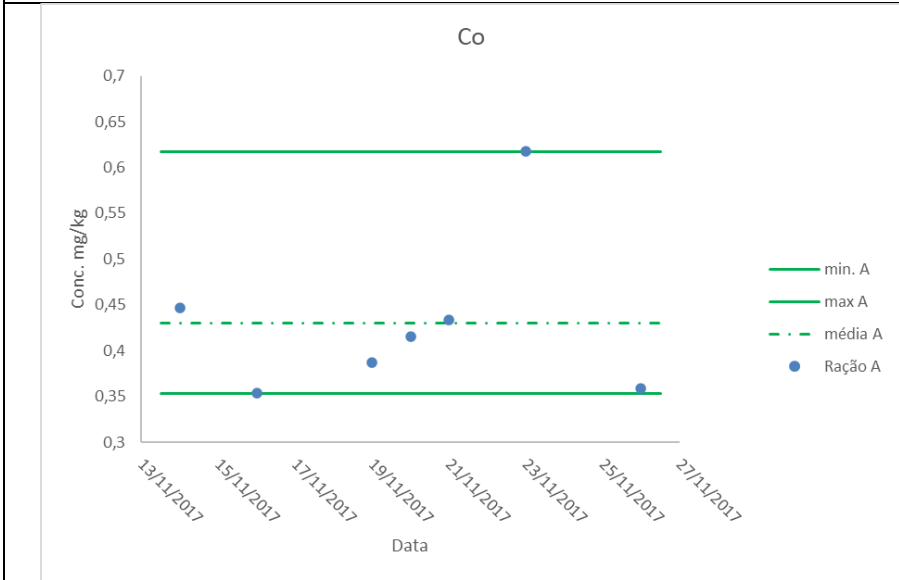


Data Coleta	Código Animal	Raça	Sexo	Entrada Curral	Data Nascimento	Peso Entrada (kg)	Peso Saída (kg)	Dias Spa	Data Saída	Picanha	Contrafilé	Acém
11/29/2017	546	ANG	M	2/27/2017	12/2/2015	297	620	263	11/17/2017	X	X	X
11/29/2017	556	ANG	M	2/27/2017	12/5/2015	269	566	263	11/17/2017	X	X	X
11/29/2017	2554	ANG	M	7/2/2017	11/25/2015	343	557	138	11/17/2017	X	X	
11/29/2017	3080	ANG	M	2/27/2017	7/7/2015	325	613	263	11/17/2017	X	X	X
11/29/2017	3221	ANG	M	2/27/2017	11/21/2015	315	608	263	11/17/2017		X	X
11/29/2017	3355	ANG	M	2/27/2017	1/18/2016	364	636	263	11/17/2017	X	X	X
11/29/2017	3362	ANG	M	2/27/2017	1/18/2016	281	660	263	11/17/2017	X	X	X
11/29/2017	141	ANG	M	3/7/2017	8/31/2015	325	622	255	11/17/2017	X	X	X
11/29/2017	3251	ANG	M	2/27/2017	11/26/2015	235	538	263	11/17/2017	X	X	X
12/6/2017	119	WAG	F	6/20/2017	9/11/2014	452	606	164	12/1/2017	X	X	X
12/6/2017	138	WAG	F	6/20/2017	9/17/2014	447	570	164	12/1/2017	X	X	X
12/6/2017	238	WAG	M	5/16/2017	10/6/2014	437	623	199	12/1/2017	X	X	X
12/6/2017	278	WAG	F	6/20/2017	10/14/2014	380	624	164	12/1/2017	X	X	X
12/6/2017	372	WAG	M	1/18/2017	10/29/2014	310	677	317	12/1/2017	X	X	X
12/6/2017	375	WAG	M	1/18/2017	10/29/2014	458	636	317	12/1/2017	X	X	X
12/6/2017	399	WAG	M	5/16/2017	10/30/2014	420	614	199	12/1/2017	X	X	X
12/6/2017	448	WAG	M	5/16/2017	11/9/2014	432	711	199	12/1/2017	X	X	X
12/6/2017	481	WAG	F	6/20/2017	11/19/2014	440	549	164	12/1/2017	X	X	X
12/6/2017	550	WAG	M	6/20/2017	12/3/2014	460	587	164	12/1/2017	X	X	X
12/6/2017	553	WAG	F	5/23/2017	12/4/2014	487	624	192	12/1/2017	X	X	X
12/6/2017	594	WAG	M	1/18/2017	12/18/2014	440	647	317	12/1/2017	X	X	X
12/6/2017	247	ANG	M	1/11/2017	9/27/2015	300	558	324	12/1/2017	X	X	X
12/6/2017	1855	ANG	F	6/29/2017	12/22/2015	328	496	155	12/1/2017	X	X	X
12/6/2017	2404	ANG	M	7/2/2017	10/6/2015	447	696	152	12/1/2017	X	X	X
12/6/2017	2444	ANG	M	6/22/2017	10/18/2015	319	500	162	12/1/2017	X	X	X
12/6/2017	2491	ANG	M	7/2/2017	10/28/2015	355	546	152	12/1/2017	X	X	X





Data Coleta	Código Animal	Raça	Sexo	Entrada Curral	Data Nascimento	Peso Entrada (kg)	Peso Saída (kg)	Dias Spa	Data Saída	Picanha	Contrafilé	Acém
12/6/2017	2776	ANG	M	6/22/2017	2/8/2016	375	608	162	12/1/2017	X	X	X
12/6/2017	3170	ANG	F	2/27/2017	10/23/2015	364	625	277	12/1/2017	X	X	X
12/6/2017	3218	ANG	M	2/27/2017	11/21/2015	365	651	277	12/1/2017	X	X	X
12/6/2017	3221	ANG	M	2/27/2017	11/21/2015	315	618	277	12/1/2017	X	X	X





Apêndice C - Variação das frações de massa dos elementos químicos nas rações A e B durante o período estudado













































Apêndice D - Ce, Eu, La, Sc e Sm determinados em culturas orgânicas e matérias-primas fosfatadas

ETR	Suco de laranja $\mu\text{g g}^{-1}$ [162]		Cana-de-açúcar $\mu\text{g g}^{-1}$ [115]		Café $\mu\text{g g}^{-1}$ [113]		Matérias-primas de fosfato mg kg^{-1} [187]		
	Orgânico (n = 19)	Convencional (n = 18)	Orgânico (n = 13)	Convencional (n = 9)	Orgânico (n = 20)	Convencional (n = 34)	Rocha de fosfato (n = 3)	Superfosfato (n = 3)	Calcário (n = 3)
Ce	2,3	1,6	6,1	10,4	23,8	115	3,48	8,55	10,40
Eu	0,45	0,21	0,16	0,50	6,8	6,4	0,37	0,33	0,22
La	2,1	1,2	2,7	5,4	13,9	35,1	-	18,1	19,54
Sc	-	-	-	-	-	-	1,02	3,95	0,26
Sm	0,42	0,2	0,75	1,8	11,4	12,2	-	-	1,67

Apêndice E - Acurácia alcançada pelos modelos de classificação usando diferentes subconjuntos de variáveis ordenados de acordo com o valor de qui-quadrado

Subconjunto	Variáveis	Acurácia (%)					MANOVA
		RF	SMO	MLP	NB	CART	F-score
Chi#1	Cs	71,42	89,25	78,48	85,71	85,71	26,83
Chi#2	Cs, Se	89,28	92,85	89,28	96,42	78,57	32,75
Chi#3	Cs, Se, Sc	89,28	80	100	96,42	71,42	29,69
Chi#4	Cs, Se, Sc, Ca	82,14	96,42	100	90,91	71,42	22,96
Chi#5	Cs, Se, Sc, Ca, Br	89,28	96,42	90,00	90,91	71,42	22,21
Chi#6	Cs, Se, Sc, Ca, Br, La	89,28	96,42	90,00	90,91	71,42	17,69
Chi#7	Cs, Se, Sc, Ca, Br, La, Sr	85,71	96,42	90,00	90,91	71,42	13,05
Chi#8	Cs, Se, Sc, Ca, Br, La, Sr, Th	85,71	96,42	90,00	90,91	71,42	11,04
Chi#9	Cs, Se, Sc, Ca, Br, La, Sr, Th, Zn	89,28	90,00	90,00	90,91	71,42	9,71
Chi#10	Cs, Se, Sc, Ca, Br, La, Sr, Th, Zn, Ba	89,28	90,00	90,00	90,91	71,42	10,65
Chi#11	Cs, Se, Sc, Ca, Br, La, Sr, Th, Zn, Ba, K	89,28	92,85	90,00	90,91	71,42	10,52
Chi#12	Cs, Se, Sc, Ca, Br, La, Sr, Th, Zn, Ba, K, Rb	89,28	92,85	90,00	82,14	71,42	9,14
Chi#13	Cs, Se, Sc, Ca, Br, La, Sr, Th, Zn, Ba, K, Rb, Sm	89,28	85,71	90,00	81,82	71,42	8,98
Chi#14	Cs, Se, Sc, Ca, Br, La, Sr, Th, Zn, Ba, K, Rb, Sm, Eu	90,91	89,28	96,42	78,57	72,89	9,76
Chi#15	Cs, Se, Sc, Ca, Br, La, Sr, Th, Zn, Ba, K, Rb, Sm, Eu, Na	89,28	92,85	96,42	78,57	71,42	9,34
Chi#16	Cs, Se, Sc, Ca, Br, La, Sr, Th, Zn, Ba, K, Rb, Sm, Eu, Na, Ce	89,28	92,85	96,42	78,57	71,42	7,94

Apêndice F - Acurácia alcançada pelos modelos de classificação usando diferentes subconjuntos de variáveis ordenados de acordo com o valor de F-score

Subconjunto	Variáveis	Acurácia (%)					MANOVA
		RF	SMO	MLP	NB	CART	F-score
FS#1	Cs	71,42	89,25	78,48	85,71	85,71	26,83
FS#2	Cs, Se	89,28	92,85	89,28	96,42	78,57	32,75
FS#3	Cs, Se, Sc	89,28	96,42	100	96,42	71,42	29,69
FS#4	Cs, Se, Sc, Ca	82,14	96,42	100	92,85	71,42	22,96
FS#5	Cs, Se, Sc, Ca, La	89,28	96,42	100	82,14	71,42	22,21
FS#6	Cs, Se, Sc, Ca, La, Br	89,28	96,42	96,42	82,14	71,42	17,67
FS#7	Cs, Se, Sc, Ca, La, Br, Sr	89,28	96,42	96,42	82,14	71,42	15,70
FS#9	Cs, Se, Sc, Ca, La, Br, Sr, Ba	89,28	92,85	96,42	82,14	71,42	11,04
FS#10	Cs, Se, Sc, Ca, La, Br, Sr, Ba, K	89,28	92,85	96,42	82,14	71,42	9,71
FS#11	Cs, Se, Sc, Ca, La, Br, Sr, Ba, K, Zn	89,28	96,42	96,42	82,14	71,42	10,65
FS#12	Cs, Se, Sc, Ca, La, Br, Sr, Ba, K, Zn, Th	89,28	92,85	96,42	82,14	71,42	10,52
FS#13	Cs, Se, Sc, Ca, La, Br, Sr, Ba, K, Zn, Th, Sm	92,85	92,85	92,85	82,14	71,42	9,14
FS#14	Cs, Se, Sc, Ca, La, Br, Sr, Ba, K, Zn, Th, Sm, Rb	89,28	92,85	96,42	82,14	71,42	10,05
FS#15	Cs, Se, Sc, Ca, La, Br, Sr, Ba, K, Zn, Th, Sm, Rb, Eu	89,28	92,85	96,42	82,14	71,42	8,98
FS#16	Cs, Se, Sc, Ca, La, Br, Sr, Ba, K, Zn, Th, Sm, Rb, Eu, Ce	89,28	92,85	96,42	82,14	71,42	9,76
FS#17	Cs, Se, Sc, Ca, La, Br, Sr, Ba, K, Zn, Th, Sm, Rb, Eu, Ce, Na	89,28	96,42	96,42	82,14	71,42	9,34