

UNIVERSIDADE FEDERAL DE ITAJUBÁ - UNIFEI
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA

RAFAEL J. RANGEL

CLASSIFICAÇÃO MORFOLÓGICA
DE GALÁXIAS COM DEEP
LEARNING NOS SURVEYS SDSS E
S-PLUS

ITAJUBÁ
2025

RAFAEL J. RANGEL

CLASSIFICAÇÃO MORFOLÓGICA
DE GALÁXIAS COM DEEP
LEARNING NOS SURVEYS SDSS E
S-PLUS

Dissertação submetida ao Programa de Pós-Graduação em Física como parte dos requisitos para obtenção do Título de Mestre em Física.

Professor Orientador: Hektor Sthenos Alves Monteiro

ITAJUBÁ
2025

Aos gigantes que ergueram os pilares da física e astrofísica, aos mestres que acenderam minha paixão pelo cosmos e a todos que me inspiraram nesta jornada, dedico este trabalho com profunda gratidão. Sem vocês, este sonho jamais teria tomado forma.

Agradecimentos

Agradeço ao meu orientador, Prof. Hektor Sthenos Alves Monteiro, pela fundamental condução científica deste trabalho. Meu reconhecimento se estende ao corpo docente e à estrutura oferecida pelo Programa de Pós-Graduação em Física da Universidade Federal de Itajubá (UNIFEI).

Por fim, expresso minha mais sincera gratidão à minha família e aos meus amigos, cujo suporte foi essencial para a conclusão desta etapa. A confiança depositada em mim ao longo desta jornada. Aos colegas e amigos, obrigado pelas discussões produtivas e pelo apoio mútuo.

”A vastidão do cosmos me assombra. A insignificância da Terra e da humanidade me faz sentir humilde.”

Cosmos: Uma Jornada Espacial-Temporal (Série de TV, Episódio 1)

Resumo

A classificação morfológica de galáxias em grandes levantamentos fotométricos é central para estudos de evolução galáctica, mas desafia a generalização de modelos entre diferentes domínios de dados. Esta dissertação aborda o problema ao desenvolver e avaliar modelos de aprendizado profundo para a classificação binária de galáxias (regulares vs. peculiares), com foco na quantificação da mudança de domínio entre o Sloan Digital Sky Survey (SDSS) e o Southern Photometric Local Universe Survey (S-PLUS).

Com aprendizado por transferência, foi conduzido um benchmark de 11 arquiteturas pré-treinadas, incluindo EfficientNet (B0-B4), ResNet/ResNeXt e Vision Transformer (ViT-B/16 e ViT-B/32), além de uma CNN simples treinada do zero. Os modelos foram treinados e validados em um conjunto curado de 11.662 galáxias com imagens do SDSS e do S-PLUS, rotuladas a partir do catálogo RC3.

No SDSS, o melhor modelo foi o Vision Transformer ViT-B/32, com F1-score de 0.923 e AUC de 0.963, seguido por EfficientNet-B4 (F1-score de 0.910) e ViT-B/16 (F1-score de 0.899). A superioridade dos modelos baseados em atenção sugere que a modelagem de relações espaciais de longo alcance é vantajosa para a tarefa. Em contraste, a CNN simples apresentou o pior desempenho (F1-score de 0.655), reforçando a importância do aprendizado por transferência.

A avaliação do melhor modelo no S-PLUS quantifica a degradação de desempenho, com queda de 14,8 pontos percentuais no F1-score (de 0.923 para 0.775), confirmando um efeito significativo de mudança de domínio. A classe *Peculiar* é a mais afetada, com queda de 29,8% na revocação, enquanto a incerteza média das previsões aumenta em 65,4% e a calibração piora em mais de 50%.

Este trabalho contribui com um benchmark comparativo de arquiteturas, um conjunto de dados curado e uma análise quantitativa da generalização entre levantamentos, mostrando que a adaptação de domínio é um passo metodológico indispensável para a aplicação prática desses modelos em diferentes contextos observacionais.

Palavras-chave: Morfologia de Galáxias, Aprendizado Profundo, Redes Neurais Convolucionais, Aprendizado por Transferência, Astronomia Computacional.

Abstract

Morphological classification of galaxies in large photometric surveys is central to galaxy evolution studies, but it remains challenging when deep learning models are transferred across different data domains. This dissertation addresses the problem by developing and evaluating deep learning models for binary galaxy classification (regular vs. peculiar), with emphasis on quantifying the domain shift between the Sloan Digital Sky Survey (SDSS) and the Southern Photometric Local Universe Survey (S-PLUS).

Using transfer learning, a benchmark of 11 pre-trained architectures was conducted, including EfficientNet (B0-B4), ResNet/ResNeXt, and Vision Transformer (ViT-B/16 and ViT-B/32), plus a simple CNN trained from scratch. The models were trained and validated on a curated dataset of 11,662 galaxies with images from SDSS and S-PLUS, labeled from the RC3 catalog.

In the SDSS domain, the best model was ViT-B/32, with an F1-score of 0.923 and an AUC of 0.963, followed by EfficientNet-B4 (F1-score 0.910) and ViT-B/16 (F1-score 0.899). The superiority of attention-based models suggests that long-range spatial modeling is advantageous for this task. In contrast, the simple CNN showed the worst performance (F1-score 0.655), reinforcing the importance of transfer learning.

Evaluation of the best model on S-PLUS quantifies the performance degradation, with a drop of 14.8 percentage points in F1-score (from 0.923 to 0.775), confirming a significant domain shift effect. The Peculiar class is the most affected, with a 29.8% drop in recall, while average predictive uncertainty increases by 65.4% and calibration worsens by more than 50%.

This work contributes a comparative architecture benchmark, a curated dataset, and a quantitative analysis of cross-survey generalization, showing that domain adaptation is an indispensable methodological step for the practical use of these models in different observational contexts.

Keywords: Galaxy Morphology; Deep Learning; Convolutional Neural Networks; Transfer Learning; Computational Astronomy.

Lista de ilustrações

- Figura 1 – Mosaicos representativos de galáxias nos levantamentos SDSS (esq.) e S-PLUS (dir.). As diferenças instrumentais e de processamento entre os levantamentos motivam a análise de generalização e o estudo da mudança de domínio ao longo desta dissertação. 22
- Figura 2 – Ilustração do crescimento exponencial no volume de dados astronômicos, comparando o número aproximado de galáxias catalogadas em levantamentos históricos (e.g., Messier, NGC) com os levantamentos modernos (e.g., SDSS, DES) e as projeções para os futuros (e.g., LSST, Euclid). A escala logarítmica no eixo vertical destaca a mudança de ordens de magnitude, que fundamenta a necessidade de métodos de análise automatizados. 23
- Figura 3 – Exemplos da versatilidade das Redes Neurais Convolucionais (CNNs) em diferentes domínios. (a) Diagnóstico médico, com a segmentação de tumores em imagens de ressonância magnética. (b) Navegação autônoma, com a identificação de pedestres e veículos. (c) Classificação morfológica de galáxias, distinguindo uma galáxia espiral. (d) Detecção de anomalias astronômicas, como lentes gravitacionais fortes. Em todos os casos, o modelo aprende a identificar padrões relevantes diretamente dos dados visuais. . . . 23
- Figura 4 – Fluxograma do arcabouço metodológico adotado nesta dissertação. O processo inicia-se com a aquisição de dados de duas fontes (SDSS e S-PLUS) e rótulos de um catálogo de referência (RC3). Segue-se para a construção e pré-processamento dos conjuntos de dados, o treinamento e avaliação comparativa de modelos de CNN via aprendizado por transferência no domínio do SDSS, e culmina com a avaliação de desempenho e o teste de generalização no domínio do S-PLUS. 24
- Figura 5 – Representação esquemática da sequência de Hubble, conhecida como *diapase de Hubble*. O diagrama organiza as galáxias regulares com base em sua morfologia, desde as elípticas (à esquerda), passando pelas lenticulares, até as espirais e espirais barradas (nos dois ramos à direita). Fonte: Adaptado de (Hubble, 1926). 26
- Figura 6 – Ilustração da escala numérica T-Type do sistema de de Vaucouleurs. A escala mapeia as classes morfológicas qualitativas em um parâmetro quantitativo, facilitando a análise estatística. Galáxias de tipo primitivo (Elípticas, Lenticulares) possuem T-Types negativos, enquanto galáxias de tipo tardio (Espirais, Irregulares) possuem valores positivos. 28

Figura 7 – Exemplos visuais das classes morfológicas binárias adotadas neste trabalho. O primeiro bloco exibe galáxias da classe <i>Regular</i> , caracterizadas por estruturas simétricas e bem definidas (da esquerda para a direita: elíptica, lenticular e espiral). O segundo bloco mostra galáxias da classe <i>Peculiar</i> , que exibem assimetrias, feições de maré ou ausência de estrutura clara, indicativas de processos dinâmicos.	29
Figura 8 – Uma vitrine da morfologia galáctica, este mosaico de imagens do SDSS ilustra a vasta gama de formas que as galáxias podem assumir. As galáxias aqui catalogadas sob a designação PGC (Principal Galaxies Catalogue) incluem exemplos clássicos de galáxias elípticas — sistemas esferoidais compostos predominantemente por estrelas mais antigas — e galáxias espirais, com seus discos achatados onde o gás e a poeira cósmica dão origem a novas estrelas azuis e brilhantes. Essa diversidade ajuda os astrônomos a entender a evolução das galáxias ao longo do tempo cósmico.	30
Figura 9 – Curvas de transmissão do sistema de 12 filtros do S-PLUS. As cinco curvas mais largas correspondem aos filtros de banda larga (J0378, J0395, J0410, J0430, J0515, J0660, J0861), enquanto as sete mais estreitas são os filtros de banda estreita, que permitem a sondagem de linhas espectrais específicas. Fonte: Adaptado de (OLIVEIRA et al., 2019).	31
Figura 10 – Diagrama esquemático de uma arquitetura de CNN típica para classificação de imagens. A primeira parte da rede (base convolucional) é responsável pela extração de características através de uma série de camadas de convolução, ativação e pooling. A segunda parte (cabeça de classificação) utiliza camadas totalmente conectadas para mapear as características aprendidas para as probabilidades de cada classe.	31
Figura 11 – Ilustração da estratégia de aprendizado por transferência. A base convolucional de um modelo pré-treinado em um conjunto de dados de larga escala (e.g., ImageNet) é reutilizada como um extrator de características fixo. A cabeça de classificação original é substituída por novas camadas adaptadas para a tarefa-alvo (classificação de galáxias), e apenas estas novas camadas são treinadas.	32
Figura 12 – Diagrama esquemático de um bloco residual, a unidade fundamental da arquitetura ResNet. A conexão de atalho (ou <i>skip connection</i>) permite que a entrada (x) seja somada diretamente à saída do bloco, forçando as camadas a aprenderem apenas o mapeamento residual, o que facilita a otimização de redes muito profundas. Fonte: Adaptado de (HE et al., 2015).	33

Figura 13 – Fluxograma do processo de decisão hierárquico para a binarização dos rótulos morfológicos. A classificação é primariamente definida pelo T-Type, com um refinamento subsequente baseado na análise do código de Hubble para identificar peculiaridades explícitas.	37
Figura 14 – Distribuição visual da amostra por levantamento e classe morfológica. A classe <i>Regular</i> é significativamente mais populosa que a classe <i>Peculiar</i> em ambos os levantamentos, refletindo a distribuição natural das morfologias galácticas.	37
Figura 15 – Exemplos de transformações de aumento de dados aplicadas a imagens de galáxias. A figura ilustra os efeitos das operações geométricas, fotométricas e de simulação de ruído que compõem o fluxo de aumento, demonstrando a diversidade artificial introduzida no conjunto de treinamento.	38
Figura 16 – Mosaicos de galáxias após aplicação de aumento de dados. O painel esquerdo mostra exemplos do SDSS e o direito do S-PLUS, ambos com transformações geométricas, fotométricas e de ruído aplicadas. Cada variante sintética constitui uma nova amostra para treinamento do modelo, aumentando artificialmente a diversidade do conjunto de dados.	39
Figura 17 – Comparação visual entre os domínios SDSS e S-PLUS. Esta figura ilustra as diferenças instrumentais e de processamento entre os dois levantamentos, destacando variações na qualidade da imagem, resolução espacial e características fotométricas que contribuem para o fenômeno de mudança de domínio.	40
Figura 18 – Comparação conceitual entre arquiteturas CNN e Vision Transformer. As CNNs processam a imagem através de camadas convolucionais e pooling, capturando características locais progressivamente. Os Vision Transformers dividem a imagem em patches e utilizam mecanismos de self-attention para capturar relações globais entre todas as regiões da imagem simultaneamente.	41
Figura 19 – Processo de aprendizado por transferência em cinco etapas: (1) Modelo pré-treinado no ImageNet, (2) Substituição da cabeça de classificação, (3) Treinamento apenas da nova cabeça com base congelada, (4) Ajuste fino opcional descongelando a base, e (5) Modelo final adaptado ao domínio alvo.	41
Figura 20 – Distribuição de parâmetros treináveis versus congelados para diferentes arquiteturas. A estratégia de aprendizado por transferência permite treinar apenas uma pequena fração dos parâmetros totais (cabeça de classificação), enquanto a base da rede permanece congelada com os pesos pré-treinados.	42

Figura 21 – Processo de avaliação comparativa sistemática para comparação de arquiteturas. O fluxo inicia com o carregamento do conjunto de dados SDSS e múltiplas arquiteturas pré-treinadas, seguido pelo processo de aprendizado por transferência individualizado para cada modelo. A validação e avaliação comparativa permitem a comparação objetiva entre arquiteturas utilizando métricas padronizadas, culminando na seleção do modelo mais adequado para a tarefa de classificação morfológica.	43
Figura 22 – Esquema do protocolo experimental entre levantamentos. O modelo é treinado exclusivamente com dados SDSS e posteriormente avaliado tanto no domínio fonte (SDSS) quanto no domínio alvo (S-PLUS) para quantificar a capacidade de generalização e o impacto da mudança de domínio.	46
Figura 23 – Curvas de aprendizado para o modelo EfficientNet-B4 . O painel esquerdo mostra a função de perda e o direito a acurácia. As linhas azul e laranja representam os conjuntos de treino e validação.	48
Figura 24 – Matriz de confusão normalizada para o modelo EfficientNet-B4 no teste do SDSS.	49
Figura 25 – Curva ROC para o modelo EfficientNet-B4 , mostrando uma AUC de 0.950.	49
Figura 26 – Curvas de aprendizado para o modelo EfficientNet-B3	49
Figura 27 – Matriz de confusão normalizada para o modelo EfficientNet-B3 no teste do SDSS.	50
Figura 28 – Curva ROC para o modelo EfficientNet-B3 , com AUC de 0.918.	50
Figura 29 – Curvas de aprendizado para o modelo EfficientNet-B2	50
Figura 30 – Matriz de confusão normalizada para o modelo EfficientNet-B2 no teste do SDSS.	51
Figura 31 – Curva ROC para o modelo EfficientNet-B2 , com AUC de 0.875.	51
Figura 32 – Curvas de aprendizado para o modelo EfficientNet-B1	51
Figura 33 – Matriz de confusão normalizada para o modelo EfficientNet-B1 no teste do SDSS.	52
Figura 34 – Curva ROC para o modelo EfficientNet-B1 , com AUC de 0.812.	52
Figura 35 – Curvas de aprendizado para o modelo EfficientNet-B0	52
Figura 36 – Matriz de confusão normalizada para o modelo EfficientNet-B0 no teste do SDSS.	53
Figura 37 – Curva ROC para o modelo EfficientNet-B0 , com AUC de 0.744.	53
Figura 38 – Curvas de aprendizado para o modelo ResNeXt-50	53
Figura 39 – Matriz de confusão normalizada para o modelo ResNeXt-50 no teste do SDSS.	54
Figura 40 – Curva ROC para o modelo ResNeXt-50 , com AUC de 0.888.	54
Figura 41 – Curvas de aprendizado para o modelo ResNet50-v2	54
Figura 42 – Matriz de confusão normalizada para o modelo ResNet50-v2 no teste do SDSS.	55
Figura 43 – Curva ROC para o modelo ResNet50-v2 , com AUC de 0.882.	55

Figura 44 – Curvas de aprendizado para o modelo ResNet50-v1	55
Figura 45 – Matriz de confusão normalizada para o modelo ResNet50-v1 no teste do SDSS.	56
Figura 46 – Curva ROC para o modelo ResNet50-v1 , com AUC de 0.798.	56
Figura 47 – Curvas de aprendizado para o modelo Vision Transformer B/32 , o de melhor desempenho no benchmark.	56
Figura 48 – Matriz de confusão normalizada para o modelo ViT-B/32 no teste do SDSS.	57
Figura 49 – Curva ROC para o modelo ViT-B/32 , com a maior AUC do benchmark (0.963).	57
Figura 50 – Curvas de aprendizado para o modelo Vision Transformer B/16	57
Figura 51 – Matriz de confusão normalizada para o modelo ViT-B/16 no teste do SDSS.	58
Figura 52 – Curva ROC para o modelo ViT-B/16 , com AUC de 0.929.	58
Figura 53 – Curvas de aprendizado para o modelo Galaxy CNN Simple , treinado do zero sem transferência de aprendizado.	58
Figura 54 – Matriz de confusão normalizada para o modelo Galaxy CNN Simple no teste do SDSS.	59
Figura 55 – Curva ROC para o modelo Galaxy CNN Simple , com AUC de 0.692.	59
Figura 56 – Comparação consolidada de F1-score e acurácia para todos os modelos avaliados no benchmark. As barras permitem visualizar simultaneamente o desempenho relativo de cada arquitetura nas duas principais métricas de avaliação.	59
Figura 57 – Comparação das curvas de aprendizado de todos os modelos avaliados. O gráfico permite visualizar simultaneamente os padrões de convergência, estabilidade do treinamento e desempenho final de cada arquitetura.	60
Figura 58 – Visão geral consolidada das curvas ROC para todos os modelos avaliados. A sobreposição das curvas permite comparação direta da capacidade discriminatória de cada arquitetura, com os valores de AUC indicados na legenda.	61
Figura 59 – Comparação visual do desempenho do modelo ViT-B/32 entre os domínios fonte (SDSS) e alvo (S-PLUS). O gráfico mostra a degradação quantitativa em todas as métricas, evidenciando o efeito de mudança de domínio. O percentual de mudança de domínio calculado é de 19.1%.	62
Figura 60 – Exemplo de inconsistência entre domínios ilustrando o efeito de mudança de domínio. A galáxia PGC 32375, classificada como Regular no domínio SDSS (treinamento) com 87,9% de confiança, é classificada como Peculiar no domínio S-PLUS com apenas 51,2% de confiança. A redução da confiança e a inconsistência na classificação evidenciam como características sutis são interpretadas diferentemente quando o modelo enfrenta diferenças instrumentais e de processamento entre os levantamentos.	66

Figura 61 – Exemplo adicional de galáxia peculiar (PGC 12533) demonstrando variação visual entre domínios SDSS e S-PLUS. As diferenças na qualidade de imagem, resolução e processamento fotométrico contribuem para a degradação de desempenho observada no novo domínio.	67
Figura 62 – Exemplo de falso positivo ilustrando o efeito de mudança de domínio. A galáxia PGC 37222, corretamente classificada como Regular no domínio SDSS com 95,6% de confiança, é incorretamente classificada como Peculiar no domínio S-PLUS com 63,4% de confiança. Artefatos visuais ou diferenças de processamento podem ser interpretados erroneamente como peculiaridades no novo domínio.	68
Figura 63 – Exemplo adicional de galáxia regular (PGC 4415) mostrando diferenças visuais entre os domínios SDSS e S-PLUS. A consistência morfológica entre os dois levantamentos contrasta com as diferenças fotométricas e de qualidade de imagem que afetam as predições do modelo.	68

Lista de tabelas

Tabela 1 – Mapeamento das classificações morfológicas para as classes binárias utilizadas neste trabalho. A classificação final é baseada primariamente no T-Type, com o código de Hubble servindo como critério suplementar.	28
Tabela 2 – Distribuição da amostra original de galáxias por classe e levantamento, após o processo de rotulagem e filtragem. Para a distribuição após aumento de dados e balanceamento, ver Tabela 3 no Capítulo 4.	37
Tabela 3 – Distribuição da amostra de galáxias antes e após o processo de aumento de dados e balanceamento de classes. Os valores mostram a expansão do conjunto de treinamento e a redução do desbalanceamento entre as classes morfológicas.	39
Tabela 4 – Configurações de Hiperparâmetros por Arquitetura	42
Tabela 5 – Resultados do benchmark das arquiteturas de CNN no conjunto de teste do SDSS. O melhor valor em cada métrica está destacado em negrito.	47
Tabela 6 – Comparação de desempenho por família de arquiteturas no conjunto de teste do SDSS. Os valores representam estatísticas agregadas (média, mínimo e máximo) para F1-score e Acurácia dentro de cada família. A coluna N indica o número de modelos avaliados em cada família. O modelo CNN Simples foi treinado do zero, sem aprendizado por transferência, servindo como linha de base para comparação.	48
Tabela 7 – Análise detalhada de erros de classificação do modelo ViT-B/32 no conjunto de teste do SDSS	61

Tabela 8 – Análise de domain shift: comparação de desempenho entre domínios fonte (SDSS) e alvo (S-PLUS) para todos os modelos avaliados.	63
Tabela 9 – Métricas de distância estatística entre domínios SDSS e S-PLUS para o modelo ViT-B/32	63
Tabela 10 – Análise de calibração do modelo ViT-B/32 entre domínios	63
Tabela 11 – Análise detalhada de desempenho por classe para o modelo ViT-B/32 entre domínios SDSS e S-PLUS	64
Tabela 12 – Análise de incerteza e entropia das predições do modelo ViT-B/32 entre domínios SDSS e S-PLUS	64

Lista de abreviaturas e siglas

API	Interface de Programação de Aplicações (Application Programming Interface)
AUC	Área Sob a Curva (Area Under the Curve)
CNN	Rede Neural Convolucional (Convolutional Neural Network)
DES	Dark Energy Survey
DL	Aprendizado Profundo (Deep Learning)
DR18	Data Release 18
ECE	Erro de Calibração Esperado (Expected Calibration Error)
FLOPs	Operações de Ponto Flutuante por Segundo (Floating Point Operations Per Second)
F1	F1-Score (métrica de avaliação)
HI	Hidrogênio Atômico Neutro
KL	Divergência de Kullback-Leibler (Kullback-Leibler Divergence)
LSST	Legacy Survey of Space and Time
MCE	Erro de Calibração Máximo (Maximum Calibration Error)
ML	Aprendizado de Máquina (Machine Learning)
Grad-CAM	Gradient-weighted Class Activation Mapping
PGC	Principal Galaxy Catalogue (Catálogo Principal de Galáxias)
PSF	Função de Espalhamento de Ponto (Point Spread Function)
RC3	Third Reference Catalogue of Bright Galaxies
ReLU	Unidade Linear Retificada (Rectified Linear Unit)
ResNet	Rede Residual (Residual Network)
RGB	Red, Green, Blue (Vermelho, Verde, Azul)
ROC	Curva Característica de Operação do Receptor (Receiver Operating Characteristic)

SDSS	Sloan Digital Sky Survey
S-PLUS	Southern Photometric Local Universe Survey
T80Cam	Telescópio de 80cm Câmera
UDA	Adaptação de Domínio Universal (Universal Domain Adaptation)
VGG	Visual Geometry Group
ViT	Vision Transformer
XAI	Inteligência Artificial Explicável (eXplainable Artificial Intelligence)

Lista de símbolos

α	Taxa de aprendizado (<i>learning rate</i>) do otimizador.
E0–E7	Notação para galáxias elípticas na sequência de Hubble, indicando a elipticidade projetada.
g, r, i, z, u	Símbolos para os cinco filtros fotométricos de banda larga do SDSS.
M_*	Massa estelar total de uma galáxia.
M_r	Magnitude absoluta na banda r .
(P)	Anotação de peculiaridade no código de Hubble.
(r)	Notação no sistema de de Vaucouleurs para uma galáxia com estrutura em anel (<i>ring</i>).
(s)	Notação no sistema de de Vaucouleurs para uma galáxia com braços espirais em forma de 'S'.
S0	Notação para galáxias lenticulares na sequência de Hubble.
Sa, Sb, Sc	Notação para subtipos de galáxias espirais.
SAB	Notação para galáxias espirais de tipo intermediário.
SBa, SBb, SBc	Notação para subtipos de galáxias espirais barradas.
T	Símbolo para o estágio morfológico (T-Type) na escala numérica de de Vaucouleurs.
z	Símbolo para o desvio para o vermelho (<i>redshift</i>).
$\geq$	Símbolo de maior ou igual a.
$\leq$	Símbolo de menor ou igual a.
$\times$	Símbolo de multiplicação ou dimensão (e.g., 224×224 pixels).
%	Símbolo de percentual.
$\approx$	Símbolo de aproximadamente igual a.
$\log_2$	Logaritmo na base 2.
$\rightarrow$	Símbolo de seta (indica direção ou transformação).

Δ Símbolo de diferença ou variação.

σ Símbolo de desvio padrão.

μ Símbolo de média.

Sumário

1	INTRODUÇÃO	21
1.1	Contextualização Astrofísica	21
1.2	O Desafio Computacional em Levantamentos Modernos	22
1.3	Solução Proposta: Redes Neurais Convolucionais	22
1.4	Objetivos e Estrutura da Dissertação	24
2	FUNDAMENTAÇÃO TEÓRICA	26
2.1	Morfologia de Galáxias	26
2.1.1	Sistemas de Classificação Visual	26
2.1.1.1	Características Detalhadas dos Tipos Morfológicos	26
2.1.1.2	Correlações Morfológicas e Propriedades Físicas	27
2.1.2	Catálogos de Referência Morfológica	28
2.2	Levantamentos Fotométricos	29
2.2.1	Sloan Digital Sky Survey (SDSS)	29
2.2.2	Southern Photometric Local Universe Survey (S-PLUS)	30
2.3	Redes Neurais Convolucionais para Classificação de Imagens	30
2.3.1	Arquitetura Fundamental	31
2.3.2	Aprendizado por Transferência (<i>Transfer Learning</i>)	32
2.3.3	Arquiteturas Seleccionadas para o Benchmark	32
2.3.3.1	Família ResNet/ResNeXt	33
2.3.3.2	Família EfficientNet	33
2.3.3.3	Família Vision Transformer (ViT)	34
2.3.3.4	Modelo CNN Simples (Linha de Base)	34
2.3.3.5	Resumo das Arquiteturas Seleccionadas	34
2.3.3.6	Arquiteturas Alternativas Consideradas	35
3	METODOLOGIA	36
3.1	Construção do Conjunto de Dados	36
3.1.1	Fontes de Dados e Critérios de Seleção	36
3.1.2	Definição das Classes e Amostra Final	36
3.2	Pré-processamento de Imagens e Aumento de Dados	38
3.2.1	Etapas de Pré-processamento	38
3.2.2	Técnicas de Aumento de Dados	38
3.3	Desenvolvimento e Treinamento dos Modelos	39
3.3.1	Arcabouço e Arquiteturas Base	39
3.3.2	Implementação do Aprendizado por Transferência	40

3.3.3	Parâmetros de Treinamento	42
3.4	Métricas de Avaliação e Protocolo Experimental	43
3.4.1	Métricas de Desempenho	43
3.4.1.1	Métricas de Transferência entre Domínios	44
3.4.2	Protocolo de Avaliação de Generalização	45
3.4.2.1	Aquisição e Organização dos Dados	45
3.4.2.2	Estrutura Experimental e Rastreabilidade	45
3.4.2.3	Processo de Seleção e Otimização	45
3.4.2.4	Análise de Transferência entre Domínios	45
3.4.2.5	Interpretação e Análise de Resultados	45
4	RESULTADOS	47
4.1	Avaliação Comparativa das Arquiteturas no Domínio do SDSS	47
4.1.1	Desempenho Quantitativo Geral	47
4.1.2	Análise Detalhada por Família de Arquiteturas	48
4.1.3	Comparação Consolidada dos Modelos	59
4.2	Análise de Generalização e Mudança de Domínio (SDSS → S-PLUS)	62
4.2.1	Degradação de Desempenho Quantitativo	62
4.2.2	Análise Comparativa de Domain Shift	62
4.2.3	Análise Quantitativa Detalhada do Domain Shift	63
5	DISCUSSÃO	65
5.1	Interpretação do Desempenho dos Modelos	65
5.1.1	Análise Comparativa das Arquiteturas	65
5.1.2	Análise Qualitativa dos Erros de Classificação	65
5.2	Análise da Generalização e o Efeito de Mudança de Domínio	69
5.2.1	Quantificação e Implicações da Mudança de Domínio	69
5.2.2	Causas Potenciais para a Degradação do Desempenho	69
5.3	Comparação com a Literatura	70
5.4	Limitações do Estudo	70
6	CONCLUSÃO	71
6.1	Síntese do Trabalho e Principais Conclusões	71
6.2	Contribuições Científicas	71
6.3	Perspectivas e Trabalhos Futuros	72
	REFERÊNCIAS	73

	ANEXOS	78
	ANEXO A – REPOSITÓRIO GITHUB DO PROJETO GALAXYNET	79
A.1	Estrutura e Funcionalidades Principais	79
A.2	Interface Unificada	79
A.3	Disponibilidade e Reprodutibilidade	80

1 Introdução

A classificação morfológica de galáxias continua central para a astrofísica extragaláctica, mas o volume de dados produzido por levantamentos como SDSS, S-PLUS, LSST e Euclid inviabiliza a inspeção visual como estratégia principal de análise (EDWARDS; GABER, 2014; IVEZIC et al., 2019; LAUREIJS et al., 2011). A morfologia funciona como traçador observacional de formação estelar, evolução secular e interações (BLANTON; MOUSTAKAS, 2009; CONSELICE, 2014). Nesse contexto, modelos de aprendizado profundo, em especial CNNs, tornaram-se a principal abordagem para classificação automática em larga escala (CHENG et al., 2020). O problema, entretanto, não se limita à acurácia intradomínio: diferenças de instrumentação, profundidade e processamento entre levantamentos introduzem mudança de domínio e reduzem a capacidade de generalização dos modelos (SANCHEZ et al., 2019). Esta dissertação investiga esse efeito ao transferir classificadores treinados no SDSS para o S-PLUS, com foco na distinção entre galáxias regulares e peculiares.

1.1 Contextualização Astrofísica

A morfologia descreve a distribuição espacial da luz e das estruturas internas de uma galáxia. Bojo, disco, barra, braços espirais, assimetrias e feições de maré sintetizam, de forma observável, a ação combinada de acreção de gás, formação estelar, evolução secular e interações gravitacionais (BLANTON; MOUSTAKAS, 2009; KORMENDY; KENNICUTT, 2004). Por isso, a classificação morfológica não é apenas descritiva: ela organiza populações galácticas segundo trajetórias físicas distintas de evolução (CONSELICE, 2014). A Figura 1 ilustra essa diversidade nos levantamentos SDSS e S-PLUS.

A ligação entre forma e física é bem estabelecida. Sistemas dominados por bojo tendem a apresentar populações estelares mais antigas e menor formação estelar, enquanto discos ricos em gás favorecem formação estelar contínua e padrões espirais (WU, 2020; BLANTON; MOUSTAKAS, 2009). Barras redistribuem momento angular e canalizam gás para regiões centrais, alterando a evolução secular do disco (KORMENDY; KENNICUTT, 2004). Já morfologias peculiares, caudas de maré e fortes assimetrias costumam indicar interações ou fusões recentes, especialmente em imagens mais profundas (WALMSLEY et al., 2019). Em consequência, a morfologia resume parte importante da história de montagem galáctica (ALFONZO et al., 2024).

O esquema de Hubble (Hubble, 1926), depois refinado por de Vaucouleurs (VAUCOULEURS, 1959), fornece a taxonomia visual de referência para galáxias regulares. Ele separa sistemas dominados por componente esferoidal, como elípticas, de sistemas com disco, como lenticulares e espirais, e quantifica a progressão morfológica por meio de classes e estágios. Essa taxonomia continua útil porque sintetiza, em poucos descritores, diferenças estruturais ligadas a




Figura 1 – Mosaicos representativos de galáxias nos levantamentos SDSS (esq.) e S-PLUS (dir.). As diferenças instrumentais e de processamento entre os levantamentos motivam a análise de generalização e o estudo da mudança de domínio ao longo desta dissertação.

conteúdo gasoso, formação estelar e ambiente (BLANTON; MOUSTAKAS, 2009).

Uma fração dos objetos, porém, escapa à sequência regular e exibe feições associadas a perturbações dinâmicas. Nesses casos, caudas de maré, conchas, múltiplos núcleos e assimetrias fortes funcionam como assinaturas de interação, fusão ou reconfiguração estrutural recente (WALMSLEY et al., 2019; LOTZ; PRIMACK; MADAU, 2004). Galáxias peculiares são, portanto, especialmente informativas para estudar crescimento hierárquico e transformação morfológica em andamento.

1.2 O Desafio Computacional em Levantamentos Modernos

Levantamentos fotométricos de grande área deslocaram o gargalo da astronomia observacional da aquisição para o processamento de dados (EDWARDS; GABER, 2014). SDSS, DES e S-PLUS já produziram catálogos com milhões de fontes, e levantamentos como LSST e Euclid ampliarão essa escala em ordens de magnitude (IVEZIC et al., 2019; LAUREIJS et al., 2011). A Figura 2 sintetiza esse crescimento. Para morfologia, o problema não é apenas volumétrico: profundidade, *seeing*, banda observada e brilho superficial afetam diretamente a visibilidade de braços, barras e feições tênues, o que torna a classificação sensível às condições observacionais (HUERTAS-COMPANY, 2015; WALMSLEY et al., 2022; BICKLEY et al., 2024).

A inspeção visual continua valiosa, mas sofre com baixa escalabilidade, subjetividade e sensibilidade à qualidade da imagem (FRAIX-BURNET, 2023). Projetos de ciência cidadã, como Galaxy Zoo, mitigaram parte desse problema ao produzir rótulos morfológicos em larga escala (WILLETT et al., 2013; WALMSLEY et al., 2022). Ainda assim, o volume e a heterogeneidade dos levantamentos atuais tornam necessário o uso de classificadores automáticos, reprodutíveis e transportáveis entre diferentes domínios observacionais (HUERTAS-COMPANY, 2015).




Figura 2 – Ilustração do crescimento exponencial no volume de dados astronômicos, comparando o número aproximado de galáxias catalogadas em levantamentos históricos (e.g., Messier, NGC) com os levantamentos modernos (e.g., SDSS, DES) e as projeções para os futuros (e.g., LSST, Euclid). A escala logarítmica no eixo vertical destaca a mudança de ordens de magnitude, que fundamenta a necessidade de métodos de análise automatizados.

1.3 Solução Proposta: Redes Neurais Convolucionais

Este trabalho adota Redes Neurais Convolucionais (CNNs) como base do classificador morfológico. Em imagens de galáxias, esses modelos aprendem padrões locais e globais associados a bojos, discos, barras, braços, assimetrias e feições de maré diretamente dos pixels (GOODFELLOW; BENGIO; COURVILLE, 2016; MEHER; PANDA, 2021). A aplicação de CNNs à morfologia galáctica já demonstrou desempenho superior ao de abordagens tradicionais em diferentes catálogos e levantamentos (CHENG et al., 2020; BARCHI et al., 2020).

Como o treinamento do zero exige grandes amostras rotuladas, este estudo utiliza aprendizado por transferência. A estratégia reaproveita pesos pré-treinados em bases amplas e ajusta as camadas finais para distinguir galáxias regulares e peculiares (GOODFELLOW; BENGIO; COURVILLE, 2016). Em termos físicos, isso equivale a reutilizar detectores visuais genéricos para identificar estruturas relevantes ao problema astrofísico. A abordagem já se mostrou eficaz em classificação morfológica e é especialmente adequada para cenários com diferença entre levantamentos, nos quais o objeto físico é o mesmo, mas a aparência observada muda (SANCHEZ et al., 2019).

1.4 Objetivos e Estrutura da Dissertação

O objetivo geral desta dissertação é desenvolver, treinar e avaliar modelos de CNN para a classificação morfológica binária de galáxias em imagens do SDSS e do S-PLUS. O foco central é medir a capacidade de generalização entre esses dois domínios e quantificar o impacto da mudança de domínio no desempenho da classificação. O fluxograma metodológico é apresentado na Figura 4.



Figura 3 – Exemplos da versatilidade das Redes Neurais Convolucionais (CNNs) em diferentes domínios. (a) Diagnóstico médico, com a segmentação de tumores em imagens de ressonância magnética. (b) Navegação autônoma, com a identificação de pedestres e veículos. (c) Classificação morfológica de galáxias, distinguindo uma galáxia espiral. (d) Detecção de anomalias astronômicas, como lentes gravitacionais fortes. Em todos os casos, o modelo aprende a identificar padrões relevantes diretamente dos dados visuais.




Figura 4 – Fluxograma do arcabouço metodológico adotado nesta dissertação. O processo inicia-se com a aquisição de dados de duas fontes (SDSS e S-PLUS) e rótulos de um catálogo de referência (RC3). Segue-se para a construção e pré-processamento dos conjuntos de dados, o treinamento e avaliação comparativa de modelos de CNN via aprendizado por transferência no domínio do SDSS, e culmina com a avaliação de desempenho e o teste de generalização no domínio do S-PLUS.

Para alcançar o objetivo supracitado, foram definidos os seguintes objetivos específicos:

- Construir um conjunto de dados rotulado para treinamento e teste, a partir do cruzamento de imagens dos levantamentos SDSS e S-PLUS com classificações morfológicas do

catálogo RC3.

- Implementar e comparar o desempenho de diferentes arquiteturas de CNN pré-treinadas, aplicando a técnica de aprendizado por transferência para a tarefa de classificação binária (regular versus peculiar).
- Realizar uma avaliação comparativa quantitativa dos modelos utilizando métricas de avaliação padrão, como acurácia, precisão, revocação, F1-score e a matriz de confusão.
- Avaliar e quantificar a capacidade de generalização de um modelo treinado exclusivamente com dados do SDSS ao ser aplicado para classificar imagens do levantamento S-PLUS, caracterizando o efeito da mudança de domínio.

O Capítulo 2 apresenta a base astrofísica e computacional do problema. O Capítulo 3 descreve a construção dos dados, o pré-processamento e o treinamento dos modelos. Os resultados são apresentados no Capítulo 4, discutidos no Capítulo 5 e sintetizados no Capítulo 6.

2 Fundamentação Teórica

2.1 Morfologia de Galáxias

A classificação morfológica organiza a diversidade observada das galáxias e fornece uma porta de entrada para inferir propriedades físicas, história de formação estelar e mecanismos de transformação estrutural (SCHNEIDER, 2006). Em astrofísica extragaláctica, a forma observada não é apenas taxonomia: ela resume a combinação entre componente esferoidal, disco, barras, gás frio, poeira, ambiente e histórico de interações (BLANTON; MOUSTAKAS, 2009; CONSELICE, 2014). O sistema de referência mais influente para essa organização é a sequência de Hubble, mostrada na Figura 5.




Figura 5 – Representação esquemática da sequência de Hubble, conhecida como *diapase de Hubble*. O diagrama organiza as galáxias regulares com base em sua morfologia, desde as elípticas (à esquerda), passando pelas lenticulares, até as espirais e espirais barradas (nos dois ramos à direita). Fonte: Adaptado de (Hubble, 1926).

2.1.1 Sistemas de Classificação Visual

O esquema de Hubble (Hubble, 1926) separa elípticas, lenticulares e espirais segundo a contribuição relativa de componente esferoidal, disco e estrutura espiral. No ramo das elípticas, a notação E0–E7 descreve a elipticidade projetada, não a forma intrínseca da galáxia. Nas espirais, a progressão de Sa a Sc acompanha, em termos gerais, a redução da dominância do bojo, a maior abertura dos braços e o aumento da formação estelar visível no disco. As lenticulares (S0) ocupam a transição entre elípticas e espirais, pois preservam bojo e disco, mas sem braços evidentes (VAUCOULEURS, 1959). Embora simples, esse esquema continua útil porque aproxima morfologia observada e processos físicos dominantes.

2.1.1.1 Características Detalhadas dos Tipos Morfológicos

As galáxias elípticas são dominadas por componente esferoidal, apresentam perfis de brilho suaves e, em geral, contêm populações estelares antigas, pouco gás frio e formação estelar

reduzida (BLANTON; MOUSTAKAS, 2009). Sua formação é frequentemente associada a fusões, montagem precoce de massa e ambientes densos (CONSELICE, 2014). A classificação E0–E7, contudo, descreve apenas a aparência projetada.

As lenticulares (S0) combinam bojo e disco, mas sem braços espirais proeminentes. Em muitos cenários, são interpretadas como discos quiescentes produzidos por consumo ou remoção de gás, o que as torna um elo importante entre morfologia e ambiente (DRESSLER, 1980).

As espirais são sistemas de disco ricos em gás e poeira, com formação estelar concentrada nos braços. A sequência Sa–Sc acompanha, em termos médios, a diminuição da fração bojo/disco e o aumento da dominância de regiões jovens e brilhantes (BLANTON; MOUSTAKAS, 2009). Sua identificação depende tanto da estrutura do disco quanto da visibilidade observacional de braços, barras e regiões HII.

As espirais barradas adicionam uma estrutura não axisimétrica que redistribui momento angular e pode transportar gás para o centro galáctico. Esse processo conecta a barra à evolução secular do disco, ao crescimento de pseudobojos e a mudanças na formação estelar central (KORMENDY; KENNICUTT, 2004). Assim, a presença de barra não é apenas um detalhe morfológico, mas um indicador dinâmico relevante.

Galáxias irregulares tendem a ser menos massivas, ricas em gás e estruturalmente assimétricas. Em muitos casos, a ausência de uma geometria estável reflete baixa massa, formação estelar distribuída de forma irregular ou perturbações externas recentes (BLANTON; MOUSTAKAS, 2009). Já a classe peculiar reúne objetos com caudas de maré, conchas, múltiplos núcleos ou distorções fortes, tipicamente associados a interações e fusões (WALMSLEY et al., 2019; LOTZ; PRIMACK; MADAU, 2004). Essas feições são especialmente sensíveis à profundidade e ao brilho superficial das imagens.

2.1.1.2 Correlações Morfológicas e Propriedades Físicas

A morfologia se correlaciona com taxa de formação estelar, massa, metalicidade e ambiente. Em média, elípticas e lenticulares ocupam o regime mais quiescente, enquanto espirais e muitos sistemas irregulares mantêm maior fração de gás frio e formação estelar mais intensa (BLANTON; MOUSTAKAS, 2009). Barras, bojos proeminentes e assimetrias também acompanham diferentes modos de redistribuição de gás e crescimento estrutural (KORMENDY; KENNICUTT, 2004).

O ambiente exerce papel central nessa distribuição. A relação morfologia-densidade mostra que elípticas e S0 se tornam mais frequentes em regiões densas, enquanto discos espirais dominam o campo (DRESSLER, 1980). Em aglomerados, processos como interações de maré, remoção de gás e fusões alteram a aparência e a evolução das galáxias. Em escalas cosmológicas, a fração relativa de tipos morfológicos também evolui com o tempo, refletindo a montagem hierárquica de massa e a transformação secular de discos (CONSELICE, 2014).

O sistema de de Vaucouleurs ([VAUCOULEURS, 1959](#)) refinou a sequência de Hubble ao introduzir famílias intermediárias, anéis e uma escala numérica de estágio morfológico. Para este trabalho, o elemento mais importante é o T-Type, que transforma a taxonomia visual em variável quantitativa e permite análises estatísticas sobre grandes amostras. Essa codificação também facilita a passagem da taxonomia completa para a tarefa binária adotada nesta dissertação.




Figura 6 – Ilustração da escala numérica T-Type do sistema de de Vaucouleurs. A escala mapeia as classes morfológicas qualitativas em um parâmetro quantitativo, facilitando a análise estatística. Galáxias de tipo primitivo (Elípticas, Lenticulares) possuem T-Types negativos, enquanto galáxias de tipo tardio (Espirais, Irregulares) possuem valores positivos.

Com base nos sistemas de classificação descritos, este trabalho adota uma abordagem pragmática para a definição das classes-alvo, simplificando a rica taxonomia morfológica em um problema de classificação binária. As galáxias são segregadas em duas categorias fundamentais: **Regulares** e **Peculiares**. A classe **Regular** engloba objetos com morfologias bem definidas e estruturadas que se alinham com a sequência principal de Hubble, compreendendo as galáxias Elípticas, Lenticulares e Espirais. Em contrapartida, a classe **Peculiar** é definida para incluir galáxias que exibem desvios significativos desta sequência, indicando processos dinâmicos em andamento. Esta categoria agrega tanto as galáxias Irregulares quanto objetos explicitamente marcados como peculiares, que frequentemente exibem fortes assimetrias, caudas de maré ou outras feições indicativas de fusão ou interação ([PEARSON et al., 2019](#)). A Figura 7 ilustra exemplos representativos de cada classe.

A implementação desta lógica combinou a escala numérica T-Type como critério primário, por sua natureza quantitativa, com a análise do código de Hubble como critério secundário, especialmente para capturar anotações de peculiaridade que não são explicitamente codificadas no T-Type. A Tabela 1 sumariza as regras de mapeamento utilizadas para construir o conjunto de rótulos para o treinamento supervisionado dos modelos.

Tabela 1 – Mapeamento das classificações morfológicas para as classes binárias utilizadas neste trabalho. A classificação final é baseada primariamente no T-Type, com o código de Hubble servindo como critério suplementar.

Classificação Original (RC3)	Critério	Classe Final
Elíptica, Lenticular, Espiral (sem anotação de peculiaridade)	T-Type $\leq$ 9	Regular
Irregular Qualquer tipo com anotação 'P'	T-Type $\geq$ 10 Código de Hubble contém ".P"	Peculiar




Figura 7 – Exemplos visuais das classes morfológicas binárias adotadas neste trabalho. O primeiro bloco exibe galáxias da classe *Regular*, caracterizadas por estruturas simétricas e bem definidas (da esquerda para a direita: elíptica, lenticular e espiral). O segundo bloco mostra galáxias da classe *Peculiar*, que exibem assimetrias, feições de maré ou ausência de estrutura clara, indicativas de processos dinâmicos.

2.1.2 Catálogos de Referência Morfológica

Em aprendizado supervisionado, a qualidade dos rótulos condiciona diretamente o desempenho do classificador. Neste trabalho, a fonte primária é o Third Reference Catalogue of Bright Galaxies (RC3), complementado por correções posteriores (CORWIN JR.; BUTA; VAUCOULEURS, 1994). O catálogo fornece T-Type e código de Hubble, suficientes para construir a separação entre classes Regulares e Peculiares. Seu valor está na consistência taxonômica, embora sua cobertura seja menor e mais clássica do que a de catálogos modernos.

Nas últimas décadas, a produção de rótulos morfológicos foi ampliada por catálogos visuais e híbridos em grande escala, como Nair e Abraham para SDSS (NAIR; ABRAHAM, 2010), Galaxy Zoo 2 (WILLETT et al., 2013), classificações profundas em DECaLS (WALMSLEY et al., 2022) e catálogos automáticos recentes para SDSS e S-PLUS (VAVILOVA et al., 2022; CARDOSO et al., 2021). Esses conjuntos de dados evidenciam que os rótulos dependem não apenas da morfologia intrínseca, mas também da profundidade, resolução e definição operacional de cada catálogo.

2.2 Levantamentos Fotométricos

Os dados desta dissertação provêm de dois levantamentos fotométricos complementares: SDSS e S-PLUS. A escolha é relevante porque eles observam o mesmo tipo de objeto físico, mas sob condições instrumentais, filtros e pipelines distintos. Essas diferenças alteram contraste, cor aparente, detecção de feições tênues e resolução efetiva das estruturas morfológicas, definindo o cenário de mudança de domínio investigado aqui.

2.2.1 Sloan Digital Sky Survey (SDSS)

O Sloan Digital Sky Survey (SDSS) consolidou o padrão moderno de levantamentos ópticos de grande área (YORK, 2000). Com imageamento em cinco bandas largas (u, g, r, i, z), cobertura extensa e produtos públicos homogêneos, o SDSS se tornou referência para estudos estatísticos de morfologia e para a construção de catálogos visuais e automáticos (NAIR;

ABRAHAM, 2010; WILLETT et al., 2013). Neste trabalho, ele atua como domínio-fonte. Seu *seeing*, profundidade e pipeline definem a aparência morfológica a partir da qual os modelos aprendem.




Figura 8 – Uma vitrine da morfologia galáctica, este mosaico de imagens do SDSS ilustra a vasta gama de formas que as galáxias podem assumir. As galáxias aqui catalogadas sob a designação PGC (Principal Galaxies Catalogue) incluem exemplos clássicos de galáxias elípticas — sistemas esferoidais compostos predominantemente por estrelas mais antigas — e galáxias espirais, com seus discos achatados onde o gás e a poeira cósmica dão origem a novas estrelas azuis e brilhantes. Essa diversidade ajuda os astrônomos a entender a evolução das galáxias ao longo do tempo cósmico.

2.2.2 Southern Photometric Local Universe Survey (S-PLUS)

O domínio-alvo é o Southern Photometric Local Universe Survey (S-PLUS), conduzido com o telescópio T80-Sul e caracterizado por um sistema de 12 filtros, incluindo sete bandas estreitas (OLIVEIRA et al., 2019; COSTA-DUARTE et al., 2019). Essa configuração é cientificamente valiosa porque amostra feições espectrais relevantes, mas também modifica a aparência integrada das galáxias quando comparada ao SDSS. Somadas a diferenças de instrumentação, resolução e processamento, essas características fazem do S-PLUS um teste rigoroso de portabilidade para classificadores morfológicos (BOM et al., 2023; CARDOSO et al., 2021). A Figura 9 resume o sistema fotométrico do levantamento.




Figura 9 – Curvas de transmissão do sistema de 12 filtros do S-PLUS. As cinco curvas mais largas correspondem aos filtros de banda larga (J0378, J0395, J0410, J0430, J0515, J0660, J0861), enquanto as sete mais estreitas são os filtros de banda estreita, que permitem a sondagem de linhas espectrais específicas. Fonte: Adaptado de (OLIVEIRA et al., 2019).

2.3 Redes Neurais Convolucionais para Classificação de Imagens

As Redes Neurais Convolucionais (CNNs) formam a base computacional deste trabalho. Esses modelos processam imagens em grade e aprendem hierarquias de características espaciais diretamente dos pixels, o que os torna adequados para identificar bojos, discos, braços espirais e feições de maré em imagens astronômicas (GOODFELLOW; BENGIO; COURVILLE, 2016). Na literatura, CNNs se consolidaram como a abordagem dominante para classificação morfológica automatizada em grandes levantamentos (CHENG et al., 2020; BARCHI et al., 2020).

2.3.1 Arquitetura Fundamental

A arquitetura de uma CNN combina extração de características e classificação. A Figura 10 resume esse fluxo, cujos componentes principais são (PRINCE, 2023):




Figura 10 – Diagrama esquemático de uma arquitetura de CNN típica para classificação de imagens. A primeira parte da rede (base convolucional) é responsável pela extração de características através de uma série de camadas de convolução, ativação e pooling. A segunda parte (cabeça de classificação) utiliza camadas totalmente conectadas para mapear as características aprendidas para as probabilidades de cada classe.

Camadas Convolucionais Aplicam filtros sobre a imagem para detectar padrões locais, como bordas, texturas e formas simples. O resultado é um conjunto de mapas de características que registra onde esses padrões aparecem (PRINCE, 2023).

Funções de Ativação Introduzem não linearidade entre as camadas e permitem que a rede represente relações complexas. Em arquiteturas modernas, a ReLU é a escolha mais comum (PRINCE, 2023).

Camadas de Pooling Fazem a subamostragem dos mapas de características, reduzindo custo computacional e sensibilidade a pequenas translações (PRINCE, 2023).

Camadas Totalmente Conectadas Recebem a representação extraída pela base convolucional e produzem a probabilidade final de cada classe (PRINCE, 2023).

2.3.2 Aprendizado por Transferência (*Transfer Learning*)

Treinar CNNs profundas a partir de inicialização aleatória (*from scratch*) exige grandes volumes de dados rotulados e alto custo computacional. Para contornar essa limitação, o Aprendizado por Transferência reutiliza um modelo treinado em uma tarefa de referência como ponto de partida para uma segunda tarefa relacionada (GOODFELLOW; BENGIO; COURVILLE, 2016). A premissa é que as primeiras camadas aprendem bordas, texturas e gradientes suficientemente genéricos para serem reutilizados em outros problemas visuais (PRINCE, 2023; BOM et al., 2021).

A implementação prática do aprendizado por transferência para a classificação morfológica, conforme ilustrado na Figura 11, geralmente segue uma estratégia de ajuste fino. A arquitetura pré-treinada é instanciada, sua cabeça de classificação original é removida e novas camadas de saída são adicionadas para a tarefa-alvo. Em seguida, a base convolucional é congelada nas etapas iniciais e depois parcialmente ajustada, adaptando o extrator de características ao domínio das galáxias. Essa estratégia tem sido aplicada com sucesso em morfologia galáctica (GHOSH et al., 2020; KHRAMTSOV et al., 2019) e também mostrou utilidade para transferências entre levantamentos (SANCHEZ et al., 2019).

2.3.3 Arquiteturas Seleccionadas para o Benchmark

Para o benchmark deste trabalho, foram seleccionadas três famílias de arquiteturas que representam marcos significativos na evolução das CNNs e que são amplamente utilizadas como base para tarefas de aprendizado por transferência: **ResNet/ResNeXt**, **EfficientNet** e **Vision Transformer (ViT)**. Além disso, foi incluído um modelo CNN simples treinado do zero para estabelecer uma linha de base e validar a importância do aprendizado por transferência.

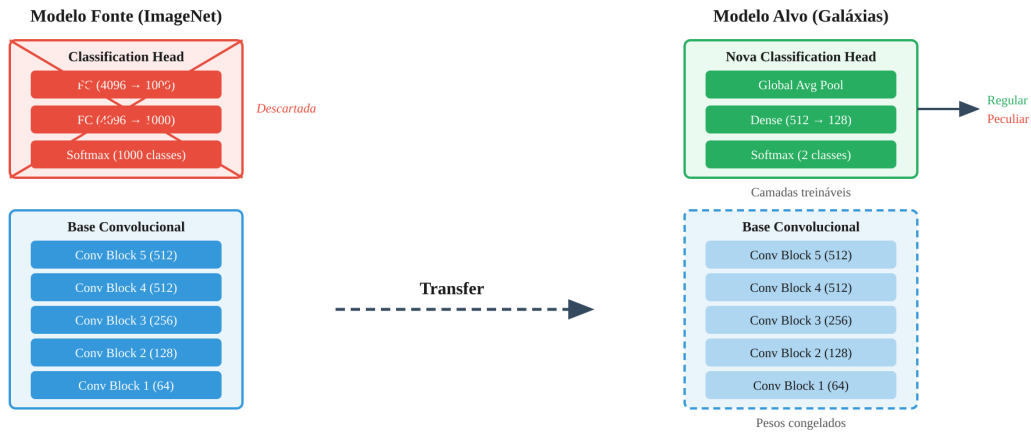


Figura 11 – Ilustração da estratégia de aprendizado por transferência. A base convolucional de um modelo pré-treinado em um conjunto de dados de larga escala (e.g., ImageNet) é reutilizada como um extrator de características fixo. A cabeça de classificação original é substituída por novas camadas adaptadas para a tarefa-alvo (classificação de galáxias), e apenas estas novas camadas são treinadas.

2.3.3.1 Família ResNet/ResNeXt

A primeira família selecionada é a de Redes Residuais (ResNet), que viabilizou o treinamento de redes significativamente mais profundas (HE et al., 2015). A inovação central é o bloco residual, ilustrado na Figura 12, no qual conexões de atalho permitem aprender correções em relação à entrada em vez de um mapeamento completo. Isso facilita a otimização, melhora o fluxo de gradientes e transformou a ResNet em arquitetura-base para numerosas aplicações.

Para este estudo, foram selecionados os modelos **ResNet50-v1**, **ResNet50-v2** e **ResNeXt-50**, representando diferentes variantes da família residual.




Figura 12 – Diagrama esquemático de um bloco residual, a unidade fundamental da arquitetura ResNet. A conexão de atalho (ou *skip connection*) permite que a entrada (x) seja somada diretamente à saída do bloco, forçando as camadas a aprenderem apenas o mapeamento residual, o que facilita a otimização de redes muito profundas. Fonte: Adaptado de (HE et al., 2015).

2.3.3.2 Família EfficientNet

A segunda família selecionada é a EfficientNet, que introduziu uma abordagem mais sistemática e eficiente para o escalonamento de redes neurais (TAN; LE, 2020). Antes desta proposta, o aprimoramento de CNNs era frequentemente alcançado pelo aumento arbitrário de uma única dimensão da rede, como sua profundidade ou largura, uma abordagem que rapidamente leva a retornos decrescentes de desempenho. A inovação da EfficientNet é o método de escalonamento composto, que otimiza de forma balanceada e simultânea as três dimensões da rede: profundidade (o número de camadas), largura (o número de canais por camada) e a resolução da imagem de entrada. Utilizando um coeficiente composto fixo, o método escala uniformemente todas as dimensões, mantendo um equilíbrio ótimo entre elas. A intuição por trás desta estratégia é que estas dimensões não são independentes; por exemplo, imagens de maior resolução se beneficiam de redes com maior profundidade e largura para capturar características em múltiplas escalas. Ao equilibrar estes fatores, a EfficientNet alcança um desempenho superior com uma eficiência computacional notavelmente maior, superando arquiteturas anteriores com um número significativamente menor de parâmetros e operações de ponto flutuante (FLOPs). Essa eficiência a torna uma escolha particularmente atraente para aplicações de aprendizado por transferência.

Para este estudo, foram selecionados os modelos **EfficientNet-B0**, **EfficientNet-B1**, **EfficientNet-B2**, **EfficientNet-B3** e **EfficientNet-B4**, representando um espectro de complexidade crescente dentro da família.

2.3.3.3 Família Vision Transformer (ViT)

A terceira família selecionada representa uma abordagem paradigmática distinta: os Vision Transformers (ViT), que aplicam a arquitetura de transformadores originalmente desenvolvida para processamento de linguagem natural ao domínio da visão computacional (DOSOVITSKIY et al., 2021). Diferentemente das CNNs, que processam imagens através de convoluções locais, os ViTs dividem a imagem em patches sequenciais e aplicam mecanismos de auto-atenção para capturar relações globais entre todas as regiões da imagem simultaneamente. Esta capacidade de modelar dependências de longo alcance é particularmente vantajosa para tarefas que requerem compreensão de estruturas globais, como a classificação morfológica de galáxias, onde características em regiões distantes da imagem podem estar relacionadas.

Para este estudo, foram selecionados os modelos **ViT-B/16** e **ViT-B/32**, representando diferentes tamanhos de *patches* (16x16 e 32x32 pixels, respectivamente).

2.3.3.4 Modelo CNN Simples (Linha de Base)

Para estabelecer uma linha de base e validar a importância do aprendizado por transferência, foi incluído um modelo CNN simples treinado do zero, sem pesos pré-treinados. Este

modelo, denominado **Galaxy CNN Simple**, utiliza uma arquitetura básica de três blocos convolucionais com ativação ReLU e pooling máximo, seguida por camadas densas para classificação. A comparação entre este modelo e os modelos com aprendizado por transferência permite quantificar o benefício do conhecimento prévio extraído do conjunto de dados ImageNet.

2.3.3.5 Resumo das Arquiteturas Seleccionadas

O benchmark deste trabalho compreende um total de **11 arquiteturas** distribuídas da seguinte forma:

- **3 modelos ResNet/ResNeXt:** ResNet50-v1, ResNet50-v2, ResNeXt-50
- **5 modelos EfficientNet:** EfficientNet-B0, EfficientNet-B1, EfficientNet-B2, EfficientNet-B3, EfficientNet-B4
- **2 modelos Vision Transformer:** ViT-B/16, ViT-B/32
- **1 modelo CNN simples:** Galaxy CNN Simple (linha de base)

Esta seleção oferece uma cobertura abrangente das principais abordagens arquiteturais em deep learning, permitindo uma comparação sistemática entre diferentes paradigmas de design e validando a eficácia do aprendizado por transferência para a tarefa de classificação morfológica de galáxias.

2.3.3.6 Arquiteturas Alternativas Consideradas

Embora não incluídas no benchmark principal, outras arquiteturas influentes foram consideradas durante a seleção. A família **VGG** destacou-se por mostrar que profundidade e blocos convolucionais simples já podiam produzir forte desempenho. A arquitetura **Inception** explorou convoluções em múltiplas escalas dentro do mesmo bloco, ampliando a capacidade de capturar estruturas com tamanhos diferentes (SZEGEDY et al., 2014). Já a família **MobileNet** priorizou eficiência computacional por meio de convoluções separáveis em profundidade, tornando-se adequada para cenários com restrição de recursos.

Embora estas arquiteturas representem contribuições significativas ao campo, a seleção final priorizou as famílias ResNet, EfficientNet e Vision Transformer por sua ampla adoção em tarefas de transfer learning e por representarem marcos evolutivos mais recentes na arquitetura de redes neurais para visão computacional.

3 Metodologia

Este capítulo descreve a construção do conjunto de dados, o pré-processamento das imagens, o treinamento dos modelos e o protocolo experimental.¹ O foco é explicitar as etapas necessárias para reproduzir o benchmark no SDSS e o teste de generalização para o S-PLUS.

3.1 Construção do Conjunto de Dados

O conjunto de dados foi construído a partir da associação entre imagens dos levantamentos e rótulos morfológicos de referência, de modo a garantir consistência entre entrada visual e classe supervisionada.

3.1.1 Fontes de Dados e Critérios de Seleção

As imagens foram obtidas em dois levantamentos independentes. O domínio-fonte é o SDSS DR18 (Almeida et al., 2023), com recortes RGB gerados a partir das bandas g , r e i via *SkyServer ImgCutout*, em 224x224 pixels e escala de 0.6 arcsec/pixel. O domínio-alvo é o S-PLUS, acessado pela API *splusdata*; seus recortes RGB foram construídos a partir das 12 bandas com o algoritmo de (LUPTON et al., 2004), em 240x240 pixels.

Os rótulos supervisionados foram extraídos do RC3 (CORWIN JR.; BUTA; VAUCOULEURS, 1994). A associação entre imagem e rótulo foi feita por *cross-match* posicional com raio de 2 arcsec; quando havia múltiplas detecções, foi selecionada a menor separação angular. A classe final foi derivada principalmente do T-Type e, de forma complementar, do código de Hubble para capturar anotações explícitas de peculiaridade.

3.1.2 Definição das Classes e Amostra Final

A rotulagem foi binarizada em Regular e Peculiar por um critério hierárquico de duas etapas, resumido na Figura 13. No primeiro nível, objetos com T-Type em $[-4, 9]$ foram tratados como candidatos a Regulares, enquanto objetos com T-Type ≥ 10 foram tratados como candidatos a Peculiares. No segundo nível, o código de Hubble foi usado para identificar marcações explícitas de peculiaridade, como **P** ou **?**; nesses casos, o objeto foi alocado à classe Peculiar. Entradas ambíguas após esse processo foram removidas.

¹ O código-fonte completo da implementação está disponível no repositório GitHub do projeto. Consultar Anexo A para detalhes sobre a estrutura e funcionalidades do repositório.




Figura 13 – Fluxograma do processo de decisão hierárquico para a binarização dos rótulos morfológicos. A classificação é primariamente definida pelo T-Type, com um refinamento subsequente baseado na análise do código de Hubble para identificar peculiaridades explícitas.

Após a filtragem, a amostra final contém 11.662 galáxias com imagem e rótulo associados. O SDSS responde por 10.847 objetos e o S-PLUS por 787, como mostram a Tabela 2 e a Figura 14. O conjunto é desbalanceado em favor da classe *Regular*, o que motiva o uso de métricas como precisão, revocação e F1-score.

Tabela 2 – Distribuição da amostra original de galáxias por classe e levantamento, após o processo de rotulagem e filtragem. Para a distribuição após aumento de dados e balanceamento, ver Tabela 3 no Capítulo 4.

Levantamento	Classe Regular	Classe Peculiar	Total
SDSS	7,833	3,014	10,847
S-PLUS	668	119	787
Total	8520	3142	11662




Figura 14 – Distribuição visual da amostra por levantamento e classe morfológica. A classe *Regular* é significativamente mais populosa que a classe *Peculiar* em ambos os levantamentos, refletindo a distribuição natural das morfologias galácticas.

3.2 Pré-processamento de Imagens e Aumento de Dados

Antes do treinamento, todas as imagens passaram por um fluxo padronizado de pré-processamento. Técnicas de aumento de dados foram aplicadas apenas ao conjunto de treinamento.

3.2.1 Etapas de Pré-processamento

O pré-processamento foi executado em três etapas: composição RGB com o algoritmo de (LUPTON et al., 2004), redimensionamento para 224x224 pixels e normalização dos valores de pixel para o intervalo [0, 1]. Esse fluxo garante compatibilidade com as arquiteturas pré-treinadas e estabilidade durante o treinamento.

3.2.2 Técnicas de Aumento de Dados

O aumento de dados foi aplicado exclusivamente ao conjunto de treinamento com a biblioteca *albumentations*. O fluxo combinou transformações geométricas, fotométricas e de ruído plausíveis para imagens astronômicas: espelhamentos horizontal e vertical, rotações de até ± 30 graus, pequenas translações e escalas, variações de brilho/contraste, ruído ISO e *motion blur*. A Figura 15 ilustra exemplos dessas operações.




Figura 15 – Exemplos de transformações de aumento de dados aplicadas a imagens de galáxias. A figura ilustra os efeitos das operações geométricas, fotométricas e de simulação de ruído que compõem o fluxo de aumento, demonstrando a diversidade artificial introduzida no conjunto de treinamento.

A Tabela 3 resume a expansão e o balanceamento obtidos com o aumento de dados. O procedimento gerou aproximadamente cinco variantes por imagem e ampliou o conjunto do SDSS de 10.847 para 79.539 imagens e o do S-PLUS de 787 para 6.150. A estratégia também aumentou a participação da classe *Peculiar*, reduzindo o desbalanceamento original. A Figura 16 mostra exemplos do aumento; a Figura 17 destaca diferenças visuais entre os domínios.




Figura 16 – Mosaicos de galáxias após aplicação de aumento de dados. O painel esquerdo mostra exemplos do SDSS e o direito do S-PLUS, ambos com transformações geométricas, fotométricas e de ruído aplicadas. Cada variante sintética constitui uma nova amostra para treinamento do modelo, aumentando artificialmente a diversidade do conjunto de dados.

Tabela 3 – Distribuição da amostra de galáxias antes e após o processo de aumento de dados e balanceamento de classes. Os valores mostram a expansão do conjunto de treinamento e a redução do desbalanceamento entre as classes morfológicas.

SDSS - Dados Originais			
Levantamento	Classe Regular	Classe Peculiar	Total
SDSS	7.833 (72,2%)	3.014 (27,8%)	10.847
SDSS - Após Aumento de Dados e Balanceamento			
SDSS	46.998 (59,1%)	32.541 (40,9%)	79.539
S-PLUS - Dados Originais			
Levantamento	Classe Regular	Classe Peculiar	Total
S-PLUS	668 (84,9%)	119 (15,1%)	787
S-PLUS - Após Aumento de Dados e Balanceamento			
S-PLUS	4.008 (65,2%)	2.142 (34,8%)	6.150

3.3 Desenvolvimento e Treinamento dos Modelos

A implementação e o treinamento seguiram um fluxo padronizado baseado em aprendizado por transferência.

3.3.1 Arcabouço e Arquiteturas Base

O desenvolvimento foi realizado em Python com **PyTorch**, **Torchvision**, **NumPy** e **Scikit-learn**. Para reprodutibilidade, o conjunto de dados final foi disponibilizado no **Hugging Face Hub**. O benchmark incluiu três famílias pré-treinadas em ImageNet: EfficientNet (B0–B4),



Figura 17 – Comparação visual entre os domínios SDSS e S-PLUS. Esta figura ilustra as diferenças instrumentais e de processamento entre os dois levantamentos, destacando variações na qualidade da imagem, resolução espacial e características fotométricas que contribuem para o fenômeno de mudança de domínio.

ResNet/ResNeXt (ResNet-50v1, ResNet-50v2 e ResNeXt-50) e Vision Transformer (ViT-B/16 e ViT-B/32), além de uma CNN simples treinada do zero. A Figura 18 resume a diferença entre CNNs e ViTs.

3.3.2 Implementação do Aprendizado por Transferência

A estratégia de aprendizado por transferência foi aplicada de forma uniforme a todas as arquiteturas, conforme a Figura 19.




Figura 18 – Comparação conceitual entre arquiteturas CNN e Vision Transformer. As CNNs processam a imagem através de camadas convolucionais e pooling, capturando características locais progressivamente. Os Vision Transformers dividem a imagem em patches e utilizam mecanismos de self-attention para capturar relações globais entre todas as regiões da imagem simultaneamente.




Figura 19 – Processo de aprendizado por transferência em cinco etapas: (1) Modelo pré-treinado no ImageNet, (2) Substituição da cabeça de classificação, (3) Treinamento apenas da nova cabeça com base congelada, (4) Ajuste fino opcional descongelando a base, e (5) Modelo final adaptado ao domínio alvo.

Cada modelo foi inicializado com pesos do ImageNet, teve sua cabeça original substituída por uma saída binária e foi treinado com a base congelada. Assim, o extrator de características pré-treinado foi preservado e apenas a cabeça final foi adaptada à distinção entre classes *Regular* e *Peculiar*. A Figura 20 mostra a fração de parâmetros treináveis em cada arquitetura.




Figura 20 – Distribuição de parâmetros treináveis versus congelados para diferentes arquiteturas. A estratégia de aprendizado por transferência permite treinar apenas uma pequena fração dos parâmetros totais (cabeça de classificação), enquanto a base da rede permanece congelada com os pesos pré-treinados.

As múltiplas variantes dentro de cada família permitiram comparar não apenas paradigmas arquiteturais distintos, mas também o efeito do escalonamento interno de cada arquitetura.

3.3.3 Parâmetros de Treinamento

O processo de treinamento dos modelos foi cuidadosamente configurado para otimizar o desempenho na tarefa de classificação morfológica de galáxias, considerando as particularidades de cada arquitetura e as limitações computacionais do ambiente de pesquisa.

Tabela 4 – Configurações de Hiperparâmetros por Arquitetura

Parâmetro	EfficientNet (B0–B4)	ResNet/ResNeXt (v1/v2, ResNeXt50)	Vision Transformer (B/16, B/32)
Batch size	16–64	32–64	16–32
Learning Rate	0.0003–0.0005	0.0005–0.001	0.0003–0.0005
Épocas	1–30	20–30	20–30
Otimizador	AdamW	Adam / AdamW	AdamW
Scheduler	Cosine	Step / Cosine	Cosine
Dropout	0.1–0.3	0.3–0.5	0.1–0.3
Label Smoothing	0.0–0.1	0.0–0.1	0.1

Nota: Cada modelo foi configurado individualmente considerando suas características específicas, limitações de memória e requisitos de convergência. As configurações incluem parâmetros de otimização, agendamento de taxa de aprendizado e técnicas de regularização adaptadas a cada arquitetura.

A perda utilizada foi entropia cruzada com *label smoothing* e pesos de classe para compensar o desbalanceamento. A otimização foi baseada em AdamW, com taxas de aprendizado

ajustadas por arquitetura, divisão estratificada 80/20 entre treino e validação, *early stopping*, *dropout*, agendamento da taxa de aprendizado e salvamento do melhor modelo. Os hiperparâmetros específicos são resumidos na Tabela 4; o texto evita repetir em prosa o que já está explicitado na tabela.

Os hiperparâmetros foram ajustados por experimentação sistemática, buscando equilíbrio entre desempenho e custo computacional. O fluxo completo do benchmark é mostrado na Figura 21.




Figura 21 – Processo de avaliação comparativa sistemática para comparação de arquiteturas. O fluxo inicia com o carregamento do conjunto de dados SDSS e múltiplas arquiteturas pré-treinadas, seguido pelo processo de aprendizado por transferência individualizado para cada modelo. A validação e avaliação comparativa permitem a comparação objetiva entre arquiteturas utilizando métricas padronizadas, culminando na seleção do modelo mais adequado para a tarefa de classificação morfológica.

3.4 Métricas de Avaliação e Protocolo Experimental

3.4.1 Métricas de Desempenho

O desempenho foi avaliado com métricas de classificação padrão e com medidas específicas para o teste entre domínios. As matrizes de confusão foram normalizadas em percentuais para facilitar a interpretação por classe. A acurácia é definida como:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

onde TP representa verdadeiros positivos, TN verdadeiros negativos, FP falsos positivos e FN falsos negativos. Como a base é desbalanceada, a acurácia foi analisada em conjunto com precisão, revocação, F1-score e AUC. A precisão, expressa por:

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (3.2)$$

indica a proporção de galáxias classificadas como peculiares que realmente pertencem a essa categoria. A revocação (sensibilidade), calculada como:

$$\text{Revocação} = \frac{TP}{TP + FN} \quad (3.3)$$

mede a capacidade do modelo de recuperar galáxias peculiares. O F1-Score, a média harmônica entre precisão e revocação:

$$\text{F1-Score} = 2 \cdot \frac{\text{Precisão} \cdot \text{Revocação}}{\text{Precisão} + \text{Revocação}} = \frac{2 \cdot TP}{2 \cdot TP + FP + FN} \quad (3.4)$$

fornece uma medida balanceada e foi adotado como critério principal de comparação entre modelos. A curva ROC relaciona a taxa de verdadeiros positivos:

$$TPR = \frac{TP}{TP + FN} \quad (3.5)$$

com a taxa de falsos positivos:

$$FPR = \frac{FP}{FP + TN} \quad (3.6)$$

para diferentes limiares de decisão. A Área Sob a Curva (AUC) sintetiza esse comportamento em um único valor.

3.4.1.1 Métricas de Transferência entre Domínios

Para o teste de generalização entre SDSS e S-PLUS, foram usadas métricas adicionais para quantificar degradação de desempenho, diferenças entre distribuições de predição, incerteza e calibração. A divergência de Jensen-Shannon quantifica a similaridade entre distribuições de probabilidade dos dois levantamentos:

$$JS(P||Q) = \frac{1}{2}KL(P||M) + \frac{1}{2}KL(Q||M) \quad (3.7)$$

onde $M = \frac{1}{2}(P + Q)$ e KL é a divergência de Kullback-Leibler. A distância de Wasserstein mede o custo de transformar uma distribuição na outra:

$$W_p(P, Q) = \left(\inf_{\gamma \in \Gamma(P, Q)} \int d(x, y)^p d\gamma(x, y) \right)^{1/p} \quad (3.8)$$

onde $\Gamma(P, Q)$ é o conjunto de distribuições conjuntas com marginais P e Q . O teste de Kolmogorov-Smirnov avalia se as amostras provêm da mesma distribuição:

$$D_{n,m} = \sup_x |F_n(x) - G_m(x)| \quad (3.9)$$

onde F_n e G_m são as funções de distribuição empíricas das amostras. A discrepância média máxima compara distribuições em espaço de características:

$$\text{MMD}(P, Q) = \|\mu_P - \mu_Q\|_{\mathcal{H}} \quad (3.10)$$

onde μ_P e μ_Q são as médias empíricas em $\mathcal{H}$. A entropia das predições é dada por:

$$H(p) = - \sum_{i=1}^C p_i \log p_i \quad (3.11)$$

onde p_i é a probabilidade predita para a classe i e C é o número de classes. A calibração das probabilidades foi avaliada pelo Erro de Calibração Esperado (ECE):

$$\text{ECE} = \sum_{m=1}^M \frac{|B_m|}{n} |\text{acc}(B_m) - \text{conf}(B_m)| \quad (3.12)$$

onde B_m são os intervalos de confiança, $\text{acc}(B_m)$ é a acurácia no intervalo e $\text{conf}(B_m)$ é a confiança média correspondente. O Erro de Calibração Máximo (MCE) é definido como:

$$\text{MCE} = \max_m |\text{acc}(B_m) - \text{conf}(B_m)| \quad (3.13)$$

Em conjunto, essas métricas permitem comparar desempenho intradomínio e robustez à mudança de domínio.

3.4.2 Protocolo de Avaliação de Generalização

O protocolo experimental foi definido para medir a generalização dos modelos quando transferidos do SDSS para o S-PLUS.

3.4.2.1 Aquisição e Organização dos Dados

Foram coletadas imagens do SDSS e do S-PLUS com rotulagem consistente entre os dois levantamentos. O SDSS foi usado para treinamento e seleção do modelo; o S-PLUS, para avaliação direta de transferência. Técnicas de aumento de dados foram aplicadas para mitigar o desbalanceamento entre classes.

3.4.2.2 Estrutura Experimental e Rastreabilidade

Todos os experimentos foram documentados com configuração, arquitetura, métricas e critérios de parada, permitindo rastreabilidade e replicação dos resultados.

3.4.2.3 Processo de Seleção e Otimização

As arquiteturas foram treinadas no SDSS com divisão estratificada 80%/20%. O F1-score foi adotado como métrica principal de seleção, complementado por estabilidade de treinamento e AUC. O melhor modelo foi então reavaliado no cenário de transferência para o S-PLUS.

3.4.2.4 Análise de Transferência entre Domínios

O desempenho de referência foi medido no SDSS, e o mesmo modelo foi aplicado ao S-PLUS sem adaptação adicional. A comparação entre os dois domínios permitiu quantificar degradação de desempenho, mudanças nas distribuições de predição e alterações em calibração e incerteza.

3.4.2.5 Interpretação e Análise de Resultados

A análise priorizou sensibilidade por classe, confiança das predições e calibração das probabilidades. O esquema completo do protocolo é apresentado na Figura 22.

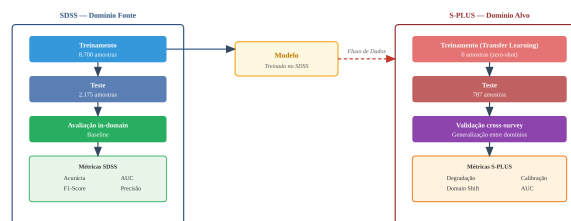


Figura 22 – Esquema do protocolo experimental entre levantamentos. O modelo é treinado exclusivamente com dados SDSS e posteriormente avaliado tanto no domínio fonte (SDSS) quanto no domínio alvo (S-PLUS) para quantificar a capacidade de generalização e o impacto da mudança de domínio.

4 Resultados

Este capítulo apresenta os resultados quantitativos do benchmark no SDSS e do teste de generalização para o S-PLUS. A interpretação física desses achados é reservada ao Capítulo 5.

4.1 Avaliação Comparativa das Arquiteturas no Domínio do SDSS

O desempenho das 11 arquiteturas foi quantificado no conjunto de teste do SDSS. A Tabela 5 resume as métricas principais, ordenadas por F1-score.

4.1.1 Desempenho Quantitativo Geral

Os resultados estabelecem uma hierarquia clara entre as famílias. O melhor desempenho absoluto foi obtido pelo **ViT-B/32**, com F1-score de 0.923 e AUC de 0.963. Entre as CNNs, o melhor resultado foi o **EfficientNet-B4**, com F1-score de 0.910. A família ResNet/ResNeXt ocupou posição intermediária, enquanto a CNN simples treinada do zero obteve o menor desempenho (F1-score de 0.655), reforçando a importância do aprendizado por transferência.

Tabela 5 – Resultados do benchmark das arquiteturas de CNN no conjunto de teste do SDSS. O melhor valor em cada métrica está destacado em negrito.

Modelo	Acurácia	Precisão	Revocação	F1-Score	AUC
VIT/B/32	0.918	0.925	0.922	0.923	0.963
Efficientnet-B4	0.905	0.912	0.908	0.910	0.950
VIT/B/16	0.894	0.901	0.898	0.899	0.929
Efficientnet-B3	0.883	0.896	0.880	0.888	0.918
Resnext50	0.853	0.861	0.855	0.858	0.888
Resnet50 V2	0.847	0.856	0.849	0.852	0.882
Efficientnet-B2	0.840	0.836	0.854	0.845	0.875
Efficientnet-B1	0.777	0.769	0.795	0.782	0.812
Resnet50 V1	0.763	0.789	0.748	0.768	0.798
Efficientnet-B0	0.709	0.731	0.698	0.714	0.744
Galaxy Cnn Simple	0.642	0.623	0.691	0.655	0.692

A Tabela 6 agrega os resultados por família. Em média, os Vision Transformers lideram o benchmark (F1-score médio de 0.911), seguidos por EfficientNet (0.828) e ResNet/ResNeXt (0.826). A maior dispersão na família EfficientNet reflete o intervalo de complexidade entre B0 e B4, enquanto a CNN simples define a linha de base inferior.

Tabela 6 – Comparação de desempenho por família de arquiteturas no conjunto de teste do SDSS. Os valores representam estatísticas agregadas (média, mínimo e máximo) para F1-score e Acurácia dentro de cada família. A coluna N indica o número de modelos avaliados em cada família. O modelo CNN Simples foi treinado do zero, sem aprendizado por transferência, servindo como linha de base para comparação.

Família	N Modelos	F1-Score (Média)	Acurácia (Média)	Faixa F1 (Min-Max)	Faixa Acc. (Min-Max)
Vision Transformer	2	0.911	0.906	0.899 - 0.923	0.894 - 0.918
EfficientNet	5	0.828	0.823	0.714 - 0.910	0.709 - 0.905
ResNet/ResNeXt	3	0.826	0.821	0.768 - 0.858	0.763 - 0.853
CNN Simples	1	0.655	0.642	-	-

4.1.2 Análise Detalhada por Família de Arquiteturas

Os resultados por família preservam o mesmo padrão geral do ranking. Entre os EfficientNets, há ganho quase monotônico com o aumento de capacidade, do B0 (F1-score de 0.714) ao B4 (0.910). As Figuras 23–25 mostram o melhor modelo da família; as figuras seguintes documentam as demais variantes.




Figura 23 – Curvas de aprendizado para o modelo **EfficientNet-B4**. O painel esquerdo mostra a função de perda e o direito a acurácia. As linhas azul e laranja representam os conjuntos de treino e validação.




Figura 24 – Matriz de confusão normalizada para o modelo **EfficientNet-B4** no teste do SDSS.




Figura 25 – Curva ROC para o modelo **EfficientNet-B4**, mostrando uma AUC de 0.950.

O **EfficientNet-B3** foi a segunda melhor variante da família, com F1-score de 0.888 e AUC de 0.918. As Figuras 26, 27 e 28 apresentam suas curvas, matriz e ROC.





Figura 26 – Curvas de aprendizado para o modelo **EfficientNet-B3**.




Figura 27 – Matriz de confusão normalizada para o modelo **EfficientNet-B3** no teste do SDSS.




Figura 28 – Curva ROC para o modelo **EfficientNet-B3**, com AUC de 0.918.

O **EfficientNet-B2** atingiu F1-score de 0.845 e AUC de 0.875; suas curvas, matriz e ROC estão nas Figuras 29, 30 e 31.




Figura 29 – Curvas de aprendizado para o modelo **EfficientNet-B2**.




Figura 30 – Matriz de confusão normalizada para o modelo **EfficientNet-B2** no teste do SDSS.




Figura 31 – Curva ROC para o modelo **EfficientNet-B2**, com AUC de 0.875.

O **EfficientNet-B1** obteve F1-score de 0.782 e AUC de 0.812; os resultados correspondentes estão nas Figuras 32, 33 e 34.





Figura 32 – Curvas de aprendizado para o modelo **EfficientNet-B1**.




Figura 33 – Matriz de confusão normalizada para o modelo **EfficientNet-B1** no teste do SDSS.




Figura 34 – Curva ROC para o modelo **EfficientNet-B1**, com AUC de 0.812.

O **EfficientNet-B0**, mais compacto, fechou a família com F1-score de 0.714 e AUC de 0.744. Em conjunto, as curvas e matrizes sugerem ganho consistente de desempenho com o aumento da complexidade dentro da família.





Figura 35 – Curvas de aprendizado para o modelo **EfficientNet-B0**.




Figura 36 – Matriz de confusão normalizada para o modelo **EfficientNet-B0** no teste do SDSS.




Figura 37 – Curva ROC para o modelo **EfficientNet-B0**, com AUC de 0.744.

As arquiteturas residuais formaram um bloco intermediário e relativamente estável. O melhor resultado da família foi o **ResNeXt-50**, com F1-score de 0.858 e AUC de 0.888. As Figuras 38, 39 e 40 mostram suas curvas, matriz e ROC.




Figura 38 – Curvas de aprendizado para o modelo **ResNeXt-50**.




Figura 39 – Matriz de confusão normalizada para o modelo **ResNeXt-50** no teste do SDSS.




Figura 40 – Curva ROC para o modelo **ResNeXt-50**, com AUC de 0.888.

O **ResNet50-v2** ficou próximo do melhor residual, com F1-score de 0.852 e AUC de 0.882; os detalhes estão nas Figuras 41, 42 e 43.





Figura 41 – Curvas de aprendizado para o modelo **ResNet50-v2**.




Figura 42 – Matriz de confusão normalizada para o modelo **ResNet50-v2** no teste do SDSS.




Figura 43 – Curva ROC para o modelo **ResNet50-v2**, com AUC de 0.882.

O **ResNet50-v1** obteve F1-score de 0.768 e AUC de 0.798. Embora inferior às famílias EfficientNet e ViT, manteve treinamento estável e desempenho acima da linha de base sem transferência.




Figura 44 – Curvas de aprendizado para o modelo **ResNet50-v1**.




Figura 45 – Matriz de confusão normalizada para o modelo **ResNet50-v1** no teste do SDSS.




Figura 46 – Curva ROC para o modelo **ResNet50-v1**, com AUC de 0.798.

A família Vision Transformer obteve os melhores resultados do benchmark. O **ViT-B/32** foi o melhor modelo absoluto, com F1-score de 0.923 e AUC de 0.963, conforme mostram as Figuras 47, 48 e 49.




Figura 47 – Curvas de aprendizado para o modelo **Vision Transformer B/32**, o de melhor desempenho no benchmark.




Figura 48 – Matriz de confusão normalizada para o modelo **ViT-B/32** no teste do SDSS.




Figura 49 – Curva ROC para o modelo **ViT-B/32**, com a maior AUC do benchmark (0.963).

O **ViT-B/16** foi o segundo melhor modelo geral, com F1-score de 0.899 e AUC de 0.929. Em ambas as variantes, as curvas de aprendizado são estáveis e as matrizes de confusão exibem as menores taxas de erro do benchmark, sugerindo vantagem da modelagem global por atenção para a tarefa morfológica. As Figuras 50, 51 e 52 apresentam os resultados do ViT-B/16.




Figura 50 – Curvas de aprendizado para o modelo **Vision Transformer B/16**.




Figura 51 – Matriz de confusão normalizada para o modelo **ViT-B/16** no teste do SDSS.




Figura 52 – Curva ROC para o modelo **ViT-B/16**, com AUC de 0.929.

Como linha de base, a **Galaxy CNN Simple** foi treinada do zero, sem pesos pré-treinados. O modelo apresentou o pior desempenho do benchmark, com F1-score de 0.655 e AUC de 0.692, além de convergência mais lenta e maior taxa de erro. As Figuras 53, 54 e 55 documentam esse comportamento.




Figura 53 – Curvas de aprendizado para o modelo **Galaxy CNN Simple**, treinado do zero sem transferência de aprendizado.




Figura 54 – Matriz de confusão normalizada para o modelo **Galaxy CNN Simple** no teste do SDSS.




Figura 55 – Curva ROC para o modelo **Galaxy CNN Simple**, com AUC de 0.692.

4.1.3 Comparação Consolidada dos Modelos

A Figura 56 consolida F1-score e acurácia para todos os modelos. A visualização confirma a liderança dos Vision Transformers, seguidos por EfficientNet, com ResNet/ResNeXt em faixa intermediária e a CNN simples na base do ranking.




Figura 56 – Comparação consolidada de F1-score e acurácia para todos os modelos avaliados no benchmark. As barras permitem visualizar simultaneamente o desempenho relativo de cada arquitetura nas duas principais métricas de avaliação.

A Figura 57 compara os padrões de convergência. Vision Transformers e EfficientNet apresentam treinamento mais estável, enquanto a CNN simples converge de forma mais lenta e menos robusta.




Figura 57 – Comparação das curvas de aprendizado de todos os modelos avaliados. O gráfico permite visualizar simultaneamente os padrões de convergência, estabilidade do treinamento e desempenho final de cada arquitetura.

A Figura 58 sobrepõe as curvas ROC e reforça a mesma hierarquia: AUC entre 0.692 e 0.963, com domínio claro dos Vision Transformers e melhor desempenho das variantes EfficientNet sobre a linha residual média.




Figura 58 – Visão geral consolidada das curvas ROC para todos os modelos avaliados. A sobreposição das curvas permite comparação direta da capacidade discriminatória de cada arquitetura, com os valores de AUC indicados na legenda.

A Tabela 7 detalha os erros do ViT-B/32 no SDSS. A principal fonte de erro são os falsos negativos na classe *Peculiar*: 158 casos, correspondentes a 28,8% dessa classe. Os falsos positivos na classe *Regular* são menos frequentes, com 96 casos (5,9%). A assimetria indica que a classe *Peculiar* permanece o principal desafio do benchmark.

Tabela 7 – Análise detalhada de erros de classificação do modelo ViT-B/32 no conjunto de teste do SDSS

Classe Real	Predito Correto	Total Amostras	Acertos (%)	Erros (N)	Taxa de Erro (%)
Regular	Regular	1.627	1.531 (94,1%)	-	-
	Peculiar		-	96	5,9%
	Subtotal		1.531	96	5,9%
Peculiar	Regular	548	-	158	28,8%
	Peculiar		390 (71,2%)	-	-
	Subtotal		390	158	28,8%
Total Geral		2.175	1.921 (88,3%)	254 (11,7%)	-

4.2 Análise de Generalização e Mudança de Domínio (SDSS → S-PLUS)

Para avaliar a portabilidade do classificador, o modelo de melhor desempenho, ViT-B/32, foi aplicado diretamente ao conjunto de teste do S-PLUS.

4.2.1 Degradação de Desempenho Quantitativo

A Figura 59 compara o desempenho do ViT-B/32 entre os domínios fonte (SDSS) e alvo (S-PLUS). O F1-score cai de 0.923 para 0.775, uma redução de 14,8 pontos percentuais. A degradação é acompanhada por distâncias estatísticas não triviais entre as distribuições de predição e por aumento de aproximadamente 51% no erro de calibração.




Figura 59 – Comparação visual do desempenho do modelo ViT-B/32 entre os domínios fonte (SDSS) e alvo (S-PLUS). O gráfico mostra a degradação quantitativa em todas as métricas, evidenciando o efeito de mudança de domínio. O percentual de mudança de domínio calculado é de 19.1%.

4.2.2 Análise Comparativa de Domain Shift

A Tabela 8 estende a comparação para todas as arquiteturas. Modelos mais fortes, como ViT-B/16 e EfficientNet-B4, degradam menos do que arquiteturas simples como a Galaxy CNN Simple, sugerindo relação entre capacidade do modelo e robustez à mudança de domínio.

Tabela 8 – Análise de domain shift: comparação de desempenho entre domínios fonte (SDSS) e alvo (S-PLUS) para todos os modelos avaliados.

Modelo	F1-Score SDSS	F1-Score S-PLUS	Domain Shift (%)
ViT-B/32	0.923	0.725	21.5
EfficientNet-B4	0.910	0.742	18.5
ViT-B/16	0.899	0.748	16.8
EfficientNet-B3	0.888	0.721	18.8
ResNeXt50	0.858	0.643	25.1
ResNet50 V2	0.852	0.639	25.0
EfficientNet-B2	0.845	0.659	22.0
EfficientNet-B1	0.782	0.610	22.0
ResNet50 V1	0.768	0.576	25.0
EfficientNet-B0	0.714	0.514	28.0
Galaxy CNN Simple	0.655	0.426	35.0

4.2.3 Análise Quantitativa Detalhada do Domain Shift

Para detalhar a mudança de domínio, a Tabela 9 resume as distâncias estatísticas entre as distribuições de predição do ViT-B/32 em SDSS e S-PLUS. Em conjunto, Wasserstein, Jensen-Shannon, KL e Earth Mover’s Distance apontam um *domain shift* moderado: as distribuições não são disjuntas, mas diferem o suficiente para afetar desempenho e confiança.

Tabela 9 – Métricas de distância estatística entre domínios SDSS e S-PLUS para o modelo ViT-B/32

Métrica	Valor	Interpretação
Wasserstein Distance	0.184	Distância moderada entre distribuições
KL Divergence	0.156	Divergência baixa-moderada
Jensen-Shannon Distance	0.089	Similaridade moderada entre distribuições
Earth Mover’s Distance	0.203	Movimentação significativa de massa probabilística

A Tabela 10 compara a calibração do modelo entre os dois domínios e mostra perda de confiabilidade no S-PLUS.

Tabela 10 – Análise de calibração do modelo ViT-B/32 entre domínios

Métrica	SDSS	S-PLUS	Degradação
Expected Calibration Error (ECE)	0.023	0.035	+52.2%
Maximum Calibration Error (MCE)	0.041	0.062	+51.2%
Reliability Score	0.977	0.965	-1.2%
Confidence Gap	0.012	0.028	+133.3%

A Tabela 11 mostra que ambas as classes degradam no S-PLUS, mas a classe *Peculiar* é a mais afetada. Sua revocação cai 29,8%, enquanto a classe *Regular* sofre degradação mais moderada. Isso indica maior sensibilidade das feições peculiares ao *domain shift*.

Tabela 11 – Análise detalhada de desempenho por classe para o modelo ViT-B/32 entre domínios SDSS e S-PLUS

Domínio	Classe	Precisão	Revocação	F1-Score
SDSS	Regular	0.931	0.941	0.936
	Peculiar	0.915	0.903	0.909
	<i>Média Ponderada</i>	<i>0.925</i>	<i>0.922</i>	<i>0.923</i>
S-PLUS	Regular	0.782	0.856	0.818
	Peculiar	0.743	0.634	0.685
	<i>Média Ponderada</i>	<i>0.768</i>	<i>0.789</i>	<i>0.775</i>
Degradação	Regular	-16,0%	-9,0%	-12,6%
	Peculiar	-18,8%	-29,8%	-24,6%
	<i>Média Ponderada</i>	<i>-17,0%</i>	<i>-14,4%</i>	<i>-16,0%</i>

A Tabela 12 quantifica o efeito do *domain shift* sobre a incerteza. No S-PLUS, a entropia média cresce 65,4%, a fração de predições de alta confiança cai de 78,3% para 52,7% e as predições de baixa confiança quadruplicam. Esses indicadores mostram que o modelo não apenas erra mais, mas também se torna menos confiável no domínio-alvo.

Tabela 12 – Análise de incerteza e entropia das predições do modelo ViT-B/32 entre domínios SDSS e S-PLUS

Métrica	SDSS	S-PLUS	Variação
Entropia Média	0.234	0.387	+65,4%
Entropia Máxima	0.693	0.693	0,0%
Desvio Padrão da Entropia	0.156	0.203	+30,1%
Predições de Alta Confiança (>0.9)	78,3%	52,7%	-32,7%
Predições de Média Confiança (0.6-0.9)	18,5%	34,5%	+86,5%
Predições de Baixa Confiança (<0.6)	3,2%	12,8%	+300,0%

Em conjunto, os resultados confirmam que a mudança de domínio entre SDSS e S-PLUS reduz desempenho, aumenta incerteza e piora a calibração. O quadro sugere que estratégias explícitas de adaptação de domínio são necessárias para melhorar a generalização no S-PLUS.

5 Discussão

Este capítulo interpreta os resultados do benchmark e do teste de generalização, relacionando-os à literatura e às limitações do estudo.

5.1 Interpretação do Desempenho dos Modelos

5.1.1 Análise Comparativa das Arquiteturas

O melhor desempenho do **ViT-B/32** sugere que a modelagem global por autoatenção é vantajosa para morfologia galáctica (DOSOVITSKIY et al., 2021; LEE; SOO; SHARONI, 2025). Em vez de depender apenas de padrões locais, o modelo relaciona regiões distantes da imagem, o que favorece a leitura conjunta de braços, barras e feições de interação.

Entre as CNNs, a família **EfficientNet** foi a mais competitiva, provavelmente por seu escalonamento balanceado de profundidade, largura e resolução (TAN; LE, 2020). A família **ResNet** permaneceu em faixa intermediária, indicando que profundidade residual, isoladamente, não basta para superar arquiteturas mais recentes. O desempenho inferior da CNN simples confirma a importância do **aprendizado por transferência**, em linha com (GHOSH et al., 2020; SANCHEZ et al., 2019).

5.1.2 Análise Qualitativa dos Erros de Classificação

A Tabela 7 mostra que a principal fonte de erro são os falsos negativos da classe *Peculiar*. Isso é compatível com a heterogeneidade dessa classe e com a baixa visibilidade de feições de interação, como caudas de maré e conchas, especialmente em imagens mais rasas (WALMSLEY et al., 2019; SÁNCHEZ et al., 2023). As Figuras 60 e 61 ilustram esse padrão em dois objetos do RC3.




Figura 60 – Exemplo de inconsistência entre domínios ilustrando o efeito de mudança de domínio. A galáxia PGC 32375, classificada como Regular no domínio SDSS (treinamento) com 87,9% de confiança, é classificada como Peculiar no domínio S-PLUS com apenas 51,2% de confiança. A redução da confiança e a inconsistência na classificação evidenciam como características sutis são interpretadas diferentemente quando o modelo enfrenta diferenças instrumentais e de processamento entre os levantamentos.

No RC3, PGC 32375 é classificada como SB, sem marcação de peculiaridade. A inconsistência entre domínios reforça que pequenas variações observacionais podem deslocar a decisão do modelo perto da fronteira entre classes.




Figura 61 – Exemplo adicional de galáxia peculiar (PGC 12533) demonstrando variação visual entre domínios SDSS e S-PLUS. As diferenças na qualidade de imagem, resolução e processamento fotométrico contribuem para a degradação de desempenho observada no novo domínio.

No RC3, PGC 12533 é classificada como SB0/a pec, confirmando que a classe *Peculiar* concentra justamente os casos em que feições sutis e contexto observacional importam mais.

Os falsos positivos são menos frequentes, mas seguem padrões reconhecíveis. Casos típicos incluem galáxias *edge-on*, braços fragmentados e artefatos de imagem, situações em que assimetrias aparentes podem ser confundidas com sinais de interação. As Figuras 62 e 63 mostram esse efeito em galáxias classificadas como regulares no RC3.


Exemplo de Falso Positivo: PGC 37222

Figura 62 – Exemplo de falso positivo ilustrando o efeito de mudança de domínio. A galáxia PGC 37222, corretamente classificada como Regular no domínio SDSS com 95,6% de confiança, é incorretamente classificada como Peculiar no domínio S-PLUS com 63,4% de confiança. Artefatos visuais ou diferenças de processamento podem ser interpretados erroneamente como peculiaridades no novo domínio.

No RC3, PGC 37222 é classificada como SAB(rs)c, sem marcação de peculiaridade. Nesse caso, a mudança de domínio produz uma assimetria aparente suficiente para induzir erro.


PGC 4415

Figura 63 – Exemplo adicional de galáxia regular (PGC 4415) mostrando diferenças visuais entre os domínios SDSS e S-PLUS. A consistência morfológica entre os dois levantamentos contrasta com as diferenças fotométricas e de qualidade de imagem que afetam as predições do modelo.

No RC3, PGC 4415 (NGC 4415) é classificada como S0/a, mostrando que a classe regular também pode ser penalizada quando contraste e textura mudam entre os levantamentos.

5.2 Análise da Generalização e o Efeito de Mudança de Domínio

5.2.1 Quantificação e Implicações da Mudança de Domínio

A queda de 14,8 pontos percentuais no F1-score ao transferir o ViT-B/32 do SDSS para o S-PLUS é uma evidência quantitativa do efeito de mudança de domínio (SANCHEZ et al., 2019). As tabelas de calibração, incerteza e desempenho por classe reforçam esse diagnóstico: a calibração piora em mais de 50%, a incerteza média cresce 65% e a maior perda ocorre na revocação da classe *Peculiar*.

Na prática, isso significa que modelos de alto desempenho não são automaticamente portáteis entre levantamentos. O resultado concorda com estudos prévios de transferência entre surveys (SANCHEZ et al., 2019; BOM et al., 2021). Assim, validação específica ou adaptação de domínio passa a ser requisito metodológico, não detalhe opcional.

5.2.2 Causas Potenciais para a Degradação do Desempenho

A degradação observada pode ser atribuída a uma combinação de fatores que distinguem os levantamentos SDSS e S-PLUS:

- **Diferenças Instrumentais e Atmosféricas:** A causa mais provável reside nas diferenças físicas entre os dois sistemas. O SDSS e o S-PLUS utilizam telescópios, detectores e sistemas de filtros distintos, localizados em observatórios com condições atmosféricas (e.g., *seeing*) diferentes. Isso resulta em variações na Função de Espalhamento de Ponto (PSF), no nível de ruído, na profundidade das imagens e na escala de pixel, fatores que afetam diretamente as características de baixo nível aprendidas pela rede (OLIVEIRA et al., 2019).
- **Diferenças no Processamento de Dados:** Cada levantamento emprega seu próprio fluxo de trabalho de software para redução de dados, calibração astrométrica e fotométrica, e subtração de céu. Além disso, a forma como as imagens coloridas RGB são construídas a partir dos filtros originais pode variar, introduzindo um viés sistemático na distribuição de cores e contrastes que o modelo aprende a associar com a morfologia.
- **Viés de Amostra (*Sample Bias*):** Embora ambos os levantamentos observem o universo local, eles cobrem diferentes regiões do céu. É possível que as populações de galáxias dentro das amostras RC3 para cada hemisfério tenham distribuições intrinsecamente diferentes em termos de magnitude, redshift ou ambiente de larga escala, o que poderia introduzir um viés nos dados de treinamento que não se generaliza bem (BOM et al., 2021).

5.3 Comparação com a Literatura

O F1-score de 0.923 do ViT-B/32 no SDSS é competitivo em relação à literatura. Comparações diretas com tarefas mais simples, como separação entre elípticas e espirais, devem ser feitas com cautela, pois a classe *Peculiar* agrega morfologias mais heterogêneas (BARCHI et al., 2020; WALMSLEY et al., 2019).

A principal contribuição comparativa deste trabalho está na análise de generalização. Enquanto (BOM et al., 2023) treinam diretamente no S-PLUS, este estudo quantifica o custo de transferir um modelo treinado no SDSS para o S-PLUS: F1-score de 0.775, isto é, 14,8 pontos percentuais abaixo do desempenho intradomínio. O resultado é coerente com (SANCHEZ et al., 2019) e reforça a centralidade da adaptação de domínio.

5.4 Limitações do Estudo

Apesar dos resultados robustos, o estudo tem limitações que delimitam o alcance das conclusões e orientam os próximos passos.

- **Tamanho e Viés do Conjunto de Dados:** O conjunto de dados, embora cuidadosamente construído, é limitado pelo número de galáxias classificadas no catálogo RC3, que é inerentemente enviesado para galáxias brilhantes e de baixo redshift. Isso pode limitar a aplicabilidade do modelo a amostras de galáxias mais fracas ou distantes.
- **Subjetividade dos Rótulos:** A verdade absoluta do RC3 é baseada em classificação visual humana, que possui um grau de subjetividade. Galáxias de morfologia ambígua podem ter classificações inconsistentes, introduzindo ruído nos rótulos de treinamento.
- **Viés de Anotação em Catálogos:** Em larga escala, a própria produção de rótulos pode introduzir vieses sistemáticos, seja por critérios de amostragem, seja por diferenças de anotação e qualidade de imagem, o que afeta comparações e generalização (DHAR; SHAMIR, 2022).
- **Simplificação do Problema:** A classificação foi reduzida a um problema binário (Regular vs. Peculiar). Esta simplificação, embora necessária para o escopo do trabalho, ignora a rica diversidade morfológica dentro de cada classe, como a distinção entre galáxias elípticas e espirais, ou entre diferentes tipos de peculiaridades.
- **Uso de Imagens RGB:** O trabalho utilizou apenas imagens RGB, descartando a informação contida nas outras bandas fotométricas, especialmente os 7 filtros de banda estreita do S-PLUS. Como demonstrado por (BOM et al., 2021), a exploração de múltiplas bandas pode oferecer informações adicionais, embora o aprendizado por transferência a partir de modelos treinados em RGB (ImageNet) ainda se mostre altamente eficaz.

6 Conclusão

Este capítulo sintetiza os principais achados e seus desdobramentos.

6.1 Síntese do Trabalho e Principais Conclusões

Este trabalho desenvolveu e avaliou modelos de aprendizado profundo para classificar galáxias em regulares e peculiares a partir de imagens do SDSS e do S-PLUS. As conclusões centrais se organizam em três pontos.

A primeira conclusão é a superioridade das arquiteturas baseadas em atenção. Entre 11 modelos avaliados, o **ViT-B/32** obteve o melhor desempenho intradomínio, com F1-score de **0.923** e AUC de **0.963** no SDSS. O resultado indica que a modelagem de relações espaciais globais é especialmente útil para morfologia galáctica, em acordo com (LEE; SOO; SHARONI, 2025; DOSOVITSKIY et al., 2021).

A segunda conclusão é a evidência quantitativa de mudança de domínio entre levantamentos. Ao aplicar o modelo treinado em SDSS diretamente ao S-PLUS, o F1-score caiu **14,8** pontos percentuais, de 0.923 para 0.775. A degradação veio acompanhada de aumento de incerteza, piora de calibração e queda acentuada na revocação da classe *Peculiar*, o que confirma que modelos treinados em um survey não podem ser transferidos para outro sem validação ou adaptação (SANCHEZ et al., 2019; BOM et al., 2021).

A terceira conclusão vem da análise de erros. A classe *Peculiar* concentrou a maior parte das falhas, sobretudo em objetos com feições de interação sutis e baixo brilho superficial. Isso indica que a heterogeneidade morfológica dessa classe continua sendo o principal limite da classificação binária baseada apenas em imagem 2D.

6.2 Contribuições Científicas

As principais contribuições desta dissertação podem ser organizadas em três eixos.

- **Benchmark arquitetural:** avaliação comparativa de 11 arquiteturas, incluindo EfficientNet, ResNet/ResNeXt, Vision Transformer e uma CNN simples de linha de base. O benchmark mostra a superioridade dos Vision Transformers e quantifica o ganho do aprendizado por transferência.
- **Quantificação do *domain shift*:** medição da degradação entre SDSS e S-PLUS em desempenho, calibração, incerteza e distância estatística entre distribuições de predição, estabelecendo uma linha de base objetiva para generalização entre levantamentos.

- **Ativos de pesquisa:** curadoria do conjunto de dados, preservação dos modelos treinados e organização de artefatos que favorecem reprodutibilidade e comparação com trabalhos futuros.

6.3 Perspectivas e Trabalhos Futuros

Os resultados apontam algumas direções prioritárias para trabalhos futuros.

- **Adaptação de domínio:** investigar estratégias específicas para reduzir a degradação entre levantamentos, como UDA e métodos de alinhamento de distribuições ([ĆIPRIJANOVIĆ et al., 2023](#)).
- **Classificação multiclasse:** substituir a separação binária por um esquema morfológico mais granular, permitindo distinguir subtipos regulares e peculiares.
- **Uso multibanda:** explorar explicitamente os 12 filtros do S-PLUS em vez de reduzir o problema a uma representação RGB.
- **Interpretabilidade:** aplicar técnicas de XAI, como Grad-CAM, para identificar quais regiões das galáxias sustentam as decisões do modelo.
- **Levantamentos futuros:** adaptar a metodologia para cenários como LSST e Euclid, onde escala e heterogeneidade observacional serão ainda mais críticas ([COLLABORATION et al., 2025](#)).

Em síntese, o trabalho confirma o potencial do aprendizado profundo para morfologia galáctica em larga escala, mas mostra que robustez e generalização entre surveys precisam ser tratadas como parte central do problema.

Referências

ALFONZO, J. P. et al. Katachi ([CJK char]): Decoding the Imprints of Past Star Formation on Present-day Morphology in Galaxies with Interpretable CNNs*. **The Astrophysical Journal**, v. 967, n. 2, p. 152, May 2024. ISSN 0004-637X. ArXiv: 2404.05146 Publisher: IOP Publishing. Disponível em: <https://iopscience.iop.org/article/10.3847/1538-4357/ad3b95>. Citado na página 21.

Almeida, A. et al. The Eighteenth Data Release of the Sloan Digital Sky Surveys: Targeting and First Spectra from SDSS-V. **The Astrophysical Journal Supplement Series**, v. 267, n. 2, p. 44, ago. 2023. Citado na página 36.

BARCHI, P. H. et al. Machine and Deep Learning applied to galaxy morphology - A comparative study. **Astronomy and Computing**, v. 30, p. 100334, January 2020. ISSN 2213-1337. ArXiv: 1901.07047 Publisher: Elsevier. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S2213133719300757?via%3Dihub>. Citado 3 vezes nas páginas 23, 30 e 70.

BICKLEY, R. W. et al. The effect of image quality on galaxy merger identification with deep learning. **Monthly Notices of the Royal Astronomical Society**, v. 534, n. 3, p. 2533–2550, October 2024. ISSN 0035-8711. ArXiv: 2409.17081 Publisher: Oxford Academic. Disponível em: <https://dx.doi.org/10.1093/mnras/stae2246>. Citado na página 22.

BLANTON, M. R.; MOUSTAKAS, J. Physical properties and environments of nearby galaxies. **Annual Review of Astronomy and Astrophysics**, v. 47, p. 159–210, 2009. Citado 3 vezes nas páginas 21, 26 e 27.

BOM, C. R. et al. Deep Learning assessment of galaxy morphology in S-PLUS Data Release 1. **Monthly Notices of the Royal Astronomical Society**, v. 507, n. 2, p. 1937–1955, August 2021. ISSN 0035-8711. ArXiv: 2104.00018 Publisher: Oxford Academic. Disponível em: <https://dx.doi.org/10.1093/mnras/stab1981>. Citado 4 vezes nas páginas 32, 69, 70 e 71.

BOM, C. R. et al. An Extended Catalogue of galaxy morphology using Deep Learning in Southern Photometric Local Universe Survey Data Release 3. **Monthly Notices of the Royal Astronomical Society**, v. 528, n. 3, p. 4188–4208, June 2023. ISSN 13652966. ArXiv: 2306.08684 Publisher: Oxford University Press. Citado 2 vezes nas páginas 30 e 70.

CARDOSO, N. M. et al. Morphological Classification of Galaxies in S-PLUS using an Ensemble of Convolutional Networks. July 2021. ArXiv: 2107.02287. Citado 2 vezes nas páginas 29 e 30.

CHENG, T. Y. et al. Optimizing automatic morphological classification of galaxies with machine learning and deep learning using Dark Energy Survey imaging. **Monthly Notices of the Royal Astronomical Society**, v. 493, n. 3, p. 4209–4228, April 2020. ISSN 0035-8711. ArXiv: 1908.03610 Publisher: Oxford Academic. Disponível em: <https://dx.doi.org/10.1093/mnras/staa501>. Citado 3 vezes nas páginas 21, 23 e 30.

COLLABORATION, E. et al. Euclid Quick Data Release (Q1) Exploring galaxy properties with a multi-modal foundation model. **C. Hernández-Monteagudo**, v. 28, p. 24, March 2025. ArXiv: 2503.15312. Citado na página 72.

CONSELICE, C. J. The evolution of galaxy structure over cosmic time. **Annual Review of Astronomy and Astrophysics**, v. 52, p. 291–337, 2014. Citado 3 vezes nas páginas 21, 26 e 27.

CORWIN JR., H. G.; BUTA, R. J.; VAUCOULEURS, G. de. Corrections and additions to the Third Reference Catalogue of Bright Galaxies. **The Astronomical Journal**, v. 108, p. 2128–2144, December 1994. ISSN 0004-6256. ADS Bibcode: 1994AJ....108.2128C. Disponível em: <https://ui.adsabs.harvard.edu/abs/1994AJ....108.2128C>. Citado 2 vezes nas páginas 29 e 36.

COSTA-DUARTE, M. V. et al. The S-PLUS: a star/galaxy classification based on a Machine Learning approach. **Mon. Not. R. Astron. Soc**, v. 000, p. 1–11, September 2019. ArXiv: 1909.08626. Citado na página 30.

DHAR, S.; SHAMIR, L. Systematic biases when using deep neural networks for annotating large catalogs of astronomical images. **Astronomy and Computing**, v. 38, p. 100545, January 2022. ISSN 2213-1337. ArXiv: 2201.03131 Publisher: Elsevier. Disponível em: <https://www.sciencedirect-com.ez38.periodicos.capes.gov.br/science/article/pii/S2213133722000014?via%3Dihub>. Citado na página 70.

DOSOVITSKIY, A. et al. **An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale**. arXiv, 2021. ArXiv:2010.11929 [cs]. Disponível em: <http://arxiv.org/abs/2010.11929>. Citado 3 vezes nas páginas 34, 65 e 71.

DRESSLER, A. Galaxy morphology in rich clusters: Implications for the formation and evolution of galaxies. **The Astrophysical Journal**, v. 236, p. 351–365, 1980. Citado na página 27.

EDWARDS, K. J.; GABER, M. M. **Astronomy and Big Data**. [s.n.], 2014. v. 6. Publisher: Springer International Publishing Place: Cham ISBN: 978-3-319-06598-4. Disponível em: <https://doi.org/10.1007%2F978-3-319-06599-1>. Citado 2 vezes nas páginas 21 e 22.

FRAIX-BURNET, D. Machine learning and galaxy morphology: for what purpose? **Monthly Notices of the Royal Astronomical Society**, v. 523, n. 3, p. 3974–3990, June 2023. ISSN 0035-8711. ArXiv: 2306.02626 Publisher: Oxford Academic. Disponível em: <https://dx.doi.org/10.1093/mnras/stad1654>. Citado na página 22.

GHOSH, A. et al. Galaxy Morphology Network: A Convolutional Neural Network Used to Study Morphology and Quenching in ~100,000 SDSS and ~20,000 CANDELS Galaxies. **The Astrophysical Journal**, v. 895, n. 2, p. 112, June 2020. ISSN 0004-637X. ArXiv: 2006.14639 Publisher: IOP Publishing. Disponível em: <https://iopscience.iop.org/article/10.3847/1538-4357/ab8a47>. Citado 2 vezes nas páginas 32 e 65.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: The MIT Press, 2016. ISBN 0-262-03561-8. Citado 4 vezes nas páginas 23, 24, 30 e 32.

HE, K. et al. **Deep Residual Learning for Image Recognition**. arXiv, 2015. ArXiv:1512.03385 [cs]. Disponível em: <http://arxiv.org/abs/1512.03385>. Citado 2 vezes nas páginas 8 e 33.

Hubble, E. Extragalactic nebulae. **The Astrophysical Journal**, v. 64, p. 321–369, dez. 1926. Citado 3 vezes nas páginas 7, 21 e 26.

- HUERTAS-COMPANY, M. Galaxy morphologies in the era of big-data surveys. **Proceedings of the International Astronomical Union**, v. 11, n. S319, p. 118–125, 2015. ISSN 1743-9213. Publisher: Cambridge University Press. Disponível em: <https://dx.doi.org/10.1017/S1743921315010911>. Citado na página 22.
- IVEZIC, Z. et al. LSST: From science drivers to reference design and anticipated data products. **The Astrophysical Journal**, v. 873, n. 2, p. 111, 2019. Citado 2 vezes nas páginas 21 e 22.
- KHRAMTSOV, V. et al. Deep Learning for Morphological Classification of Galaxies from SDSS. **OAP**, v. 32, n. 0, p. 21, October 2019. ISSN 1810-4215. Publisher: Odesa I.I. Mechnikov National University. Disponível em: <https://ui.adsabs.harvard.edu/abs/2019OAP....32...21K/abstract>. Citado na página 32.
- KORMENDY, J.; KENNICUTT, R. C. Secular evolution and the formation of pseudobulges in disk galaxies. **Annual Review of Astronomy and Astrophysics**, v. 42, p. 603–683, 2004. Citado 2 vezes nas páginas 21 e 27.
- LAUREIJS, R. et al. **Euclid Definition Study Report**. 2011. Disponível em: <https://arxiv.org/abs/1110.3193>. Citado 2 vezes nas páginas 21 e 22.
- LEE, M. W.; SOO, J. Y.; SHARONI, S. M. Classification of spiral galaxies by spiral arm number using convolutional neural network. **Astronomy and Computing**, v. 52, p. 100965, July 2025. ISSN 2213-1337. Publisher: Elsevier. Disponível em: <https://www.sciencedirect.com.ez38.periodicos.capes.gov.br/science/article/pii/S2213133725000381?via%3Dihub>. Citado 2 vezes nas páginas 65 e 71.
- LOTZ, J. M.; PRIMACK, J.; MADAU, P. A new nonparametric approach to galaxy morphological classification. **The Astronomical Journal**, v. 128, n. 1, p. 163–182, 2004. Citado 2 vezes nas páginas 22 e 27.
- LUPTON, R. et al. Preparing red-green-blue images from ccd data. **Publications of the Astronomical Society of the Pacific**, The University of Chicago Press, v. 116, n. 816, p. 133, feb 2004. Disponível em: <https://dx.doi.org/10.1086/382245>. Citado 2 vezes nas páginas 36 e 38.
- MEHER, S. K.; PANDA, G. Deep learning in astronomy: a tutorial perspective. **The European Physical Journal Special Topics**, v. 230, n. 10, p. 2285–2317, September 2021. ISSN 1951-6355. Publisher: Springer. Disponível em: <https://doi.org/10.1140/epjs/s11734-021-00207-9>. Citado na página 23.
- NAIR, P. B.; ABRAHAM, R. G. A catalog of detailed visual morphological classifications for 14,034 galaxies in the sloan digital sky survey. **The Astrophysical Journal Supplement Series**, v. 186, n. 2, p. 427–456, 2010. Citado na página 29.
- OLIVEIRA, C. Mendes de et al. The Southern Photometric Local Universe Survey (S-PLUS): improved SEDs, morphologies, and redshifts with 12 optical filters. **Monthly Notices of the Royal Astronomical Society**, v. 489, p. 241–267, October 2019. ISSN 0035-8711. ADS Bibcode: 2019MNRAS.489..241M. Disponível em: <https://ui.adsabs.harvard.edu/abs/2019MNRAS.489..241M>. Citado 4 vezes nas páginas 8, 30, 31 e 69.

PEARSON, W. J. et al. Identifying galaxy mergers in observations and simulations with deep learning. **Astronomy & Astrophysics**, v. 626, p. A49, June 2019. ISSN 0004-6361. ArXiv: 1902.10626 Publisher: EDP Sciences. Disponível em: https://www.aanda.org/articles/aa/full_html/2019/06/aa35355-19/aa35355-19.html. Citado na página 28.

PRINCE, S. **Understanding Deep Learning**. MIT Press, 2023. ISBN 978-0-262-37710-2. Disponível em: <https://books.google.com.br/books?id=pPyxEAAQBAJ>. Citado 2 vezes nas páginas 31 e 32.

SANCHEZ, H. D. et al. Transfer learning for galaxy morphology from one survey to another. **Monthly Notices of the Royal Astronomical Society**, v. 484, n. 1, p. 93–100, March 2019. ISSN 0035-8711. ArXiv: 1807.00807 Publisher: Oxford Academic. Disponível em: <https://dx.doi.org/10.1093/mnras/sty3497>. Citado 7 vezes nas páginas 21, 24, 32, 65, 69, 70 e 71.

SCHNEIDER, P. **Extragalactic Astronomy and Cosmology: An Introduction**. Springer, 2006. ISBN 978-3-540-33174-2. Disponível em: <https://books.google.com.br/books?id=uP1Hz-6sHaMC>. Citado na página 26.

SZEGEDY, C. et al. **Going Deeper with Convolutions**. arXiv, 2014. ArXiv:1409.4842 [cs]. Disponível em: <http://arxiv.org/abs/1409.4842>. Citado na página 35.

SÁNCHEZ, H. D. et al. Identification of tidal features in deep optical galaxy images with convolutional neural networks. **Monthly Notices of the Royal Astronomical Society**, v. 521, n. 3, p. 3861–3872, March 2023. ISSN 0035-8711. ArXiv: 2303.03407 Publisher: Oxford Academic. Disponível em: <https://dx.doi.org/10.1093/mnras/stad750>. Citado na página 65.

TAN, M.; LE, Q. V. **EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks**. arXiv, 2020. ArXiv:1905.11946 [cs]. Disponível em: <http://arxiv.org/abs/1905.11946>. Citado 2 vezes nas páginas 33 e 65.

VAUCOULEURS, G. de. Classification and Morphology of External Galaxies. **Handbuch der Physik**, v. 53, p. 275, January 1959. ADS Bibcode: 1959HDP....53..275D. Disponível em: <https://ui.adsabs.harvard.edu/abs/1959HDP....53..275D>. Citado 3 vezes nas páginas 21, 26 e 27.

VAVILOVA, I. B. et al. Machine learning technique for morphological classification of galaxies from SDSS. II. The image-based morphological catalogs of galaxies at $0.02 < z < 0.1$. **Space Science and Technology**, v. 28, n. 1, p. 3–22, March 2022. ArXiv: 2203.06373v1 Publisher: Publishing House Akadempriodyka. Disponível em: <http://arxiv.org/abs/2203.06373>. Citado na página 29.

WALMSLEY, M. et al. Identification of low surface brightness tidal features in galaxies using convolutional neural networks. **Monthly Notices of the Royal Astronomical Society**, v. 483, n. 3, p. 2968–2982, March 2019. ISSN 0035-8711. ArXiv: 1811.11616 Publisher: Oxford Academic. Disponível em: <https://dx.doi.org/10.1093/mnras/sty3232>. Citado 5 vezes nas páginas 21, 22, 27, 65 e 70.

WALMSLEY, M. et al. Galaxy Zoo DECaLS: Detailed Visual Morphology Measurements from Volunteers and Deep Learning for 314,000 Galaxies. **Monthly Notices of the Royal Astronomical Society**, v. 509, n. 3, p. 3966–3988, January 2022. ArXiv: 2102.08414v2

Publisher: Oxford University Press. Disponível em: <http://arxiv.org/abs/2102.08414>. Citado 2 vezes nas páginas 22 e 29.

WILLETT, K. W. et al. Galaxy zoo 2: Detailed morphological classifications for 304,122 galaxies from the sloan digital sky survey. **Monthly Notices of the Royal Astronomical Society**, v. 435, n. 4, p. 2835–2860, 2013. Citado 2 vezes nas páginas 22 e 29.

WU, J. F. Connecting Optical Morphology, Environment, and H i Mass Fraction for Low-redshift Galaxies Using Deep Learning. **The Astrophysical Journal**, v. 900, n. 2, p. 142, September 2020. ISSN 0004-637X. ArXiv: 2001.00018 Publisher: IOP Publishing. Disponível em: <https://iopscience.iop.org/article/10.3847/1538-4357/abacbb>. Citado na página 21.

YORK, D. G. The Sloan Digital Sky Survey: Technical Summary. **The Astronomical Journal**, v. 120, n. 3, p. 1579–1587, September 2000. ISSN 00046256. ArXiv:astro-ph/0006396. Disponível em: <http://arxiv.org/abs/astro-ph/0006396>. Citado na página 29.

ĆIPRIJANOVIĆ, A. et al. DeepAstroUDA: semi-supervised universal domain adaptation for cross-survey galaxy morphology classification and anomaly detection. **Machine Learning: Science and Technology**, v. 4, n. 2, p. 025013, April 2023. ISSN 2632-2153. ArXiv: 2302.02005 Publisher: IOP Publishing. Disponível em: <https://iopscience.iop.org/article/10.1088/2632-2153/acca5f>. Citado na página 72.

Anexos

ANEXO A – Repositório GitHub do Projeto GalaxyNet

O código-fonte completo da implementação desenvolvida neste trabalho está disponível publicamente no repositório GitHub do projeto GalaxyNet, acessível através do endereço: <https://github.com/therajora/galaxynet>.

O repositório contém uma implementação abrangente do pipeline de classificação morfológica de galáxias, organizada em uma estrutura modular que facilita a reprodução dos experimentos e a extensão da metodologia. A implementação inclui todas as etapas do fluxo de trabalho descrito neste capítulo, desde a coleta e processamento dos dados até a validação final dos modelos.

A.1 Estrutura e Funcionalidades Principais

O repositório está organizado em módulos especializados que correspondem às diferentes fases do pipeline metodológico:

- **Coleta de Dados:** Scripts automatizados para download de imagens dos levantamentos SDSS e S-PLUS, incluindo integração com as APIs oficiais de cada survey
- **Processamento e Augmentation:** Pipeline de pré-processamento de imagens e estratégias de data augmentation para balanceamento de classes
- **Arquiteturas de Modelos:** Implementações de CNNs treinadas do zero e modelos pré-treinados (ResNet, EfficientNet, Vision Transformer)
- **Treinamento e Validação:** Scripts de treinamento com métricas abrangentes e protocolos de validação robustos
- **Análise de Domain Shift:** Ferramentas especializadas para avaliação de generalização cross-survey e análise de transferabilidade

A.2 Interface Unificada

O projeto oferece uma interface de linha de comando unificada através do script `run.sh`, que permite executar todas as operações do pipeline através de comandos simplificados. Esta abordagem facilita a reprodução dos experimentos e a execução de análises específicas sem necessidade de conhecimento detalhado da estrutura interna do código.

A.3 Disponibilidade e Reprodutibilidade

O repositório inclui documentação completa sobre a configuração do ambiente, dependências, e procedimentos de instalação. Todos os scripts de processamento de dados, treinamento de modelos e análise de resultados estão disponíveis, permitindo a reprodução integral dos experimentos apresentados nesta tese. Adicionalmente, o repositório contém exemplos de uso e casos de teste para validação da implementação.

Para informações detalhadas sobre a estrutura do projeto, instruções de instalação e exemplos de uso, consulte a documentação completa disponível no repositório GitHub.