



UNIVERSIDADE FEDERAL DO RIO GRANDE - FURG
CENTRO DE CIÊNCIAS COMPUTACIONAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO
CURSO DE MESTRADO EM ENGENHARIA DE COMPUTAÇÃO

Dissertação de Mestrado

Arte e Transtornos Mentais: aplicação de aprendizado de máquina nas obras de Vincent Van Gogh

Fernando Brenner

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Computação da Universidade Federal do Rio Grande - FURG, como requisito parcial para a obtenção do grau de Mestre em Engenharia de Computação

Orientador: Prof.^a Dr.^a Diana Francisca Adamatti

Rio Grande, 2025

DISSERTAÇÃO DE MESTRADO

Arte e Transtornos Mentais: aplicação de aprendizado de máquina nas obras de Vincent Van Gogh

Fernando Brenner

Banca examinadora:

Documento assinado digitalmente
 **CÁTIA MARIA DOS SANTOS MACHADO**
Data: 30/04/2025 17:03:34-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Cátia Maria Machado

Documento assinado digitalmente
 **FRANCISCA FERREIRA MICHELON**
Data: 01/05/2025 14:51:58-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Francisca Ferreira Michelin

Documento assinado digitalmente
 **DIANA FRANCISCA ADAMATTI**
Data: 30/04/2025 16:41:38-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Diana Francisca Adamatti
Orientadora

Dados de catalogação na fonte:

colocar NOME DO BIBLIOTECÁRIO – CRB-colocar número do crb do bibliotecário
Biblioteca Central – FURG

A999a Brenner, Fernando

Arte e Transtornos Mentais: aplicação de aprendizado de máquina nas obras de Vincent Van Gogh / Fernando Brenner. – Rio Grande, 2025. – 94 f: gráf. – Dissertação (Mestrado) – Programa de Pós-Graduação em Computação. Universidade Federal do Rio Grande - FURG. Centro de Ciências Computacionais. Rio Grande, 2025. – Orientador Diana Francisca Adamatti.

1. Emoções. 2. Doenças Mentais. 3. Aprendizado de Máquina. 4. Van Gogh. I. Adamatti, Diana Francisca. II. Título.

CDD: 999.9

RESUMO

BRENNER, Fernando. **Arte e Transtornos Mentais: aplicação de aprendizado de máquina nas obras de Vincent Van Gogh**. 2025. 94 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Computação. Universidade Federal do Rio Grande - FURG, Rio Grande.

O presente estudo investiga a aplicação de técnicas de aprendizado de máquina na análise das obras do pintor Vincent Van Gogh, com o objetivo de identificar características visuais, documentais e temáticas que possam indicar possíveis transtornos mentais ao longo de diferentes períodos de sua vida. A pesquisa busca correlacionar variações na paleta de cores, técnicas de pinceladas, estrutura e composições das obras com registros históricos da vida do artista, especialmente aqueles que documentam suas condições mentais. A metodologia aplicada envolveu a coleta de um banco de dados de 2.026 imagens das obras de Van Gogh, categorizadas por período. Para análise do padrão de cores, utilizou-se o algoritmo *k-means* para identificar as paletas predominantes. As cartas escritas por Van Gogh foram analisadas com o algoritmo de processamento de linguagem natural *Transformers* para classificar o tom emocional. Padrões de pinceladas e texturas foram avaliados com a matriz de co-ocorrência em níveis de cinza, extraindo contraste, dissimilaridade, homogeneidade, energia e correlação e segundo momento angular. A composição e estrutura foram estudadas com o algoritmo de redes neurais convolucionais, treinado e validado para classificar as obras por cidade de produção. Os resultados sugerem uma mudança na paleta de cores, padrões estruturais das obras e mudanças nas condições emocionais de Van Gogh ao longo do período cronológico investigado. Observou-se uma transição de uma paleta de cores escuras para tons mais claros. Em relação aos padrões de pinceladas e textura, o contraste e a dissimilaridade tenderam a ser mais elevados. A homogeneidade tendeu a ser menor, indicando imagens menos uniformes. A energia permaneceu baixa, sugerindo texturas não muito repetitivas. A correlação foi consistentemente alta em todos os períodos. Na análise das direções das pinceladas, observou-se menor variação de intensidade nas direções horizontais e verticais ao analisar as características de contraste e dissimilaridade. A aplicação de uma rede neural convolucional demonstrou a complexidade em se estabelecer um padrão para as obras de Van Gogh. Os experimentos apresentaram desempenho baixo, com indícios de *overfitting* em muitos casos.

Palavras-chave: Emoções, Doenças Mentais, Aprendizado de Máquina, Van Gogh.

ABSTRACT

BRENNER, Fernando. **Art and Mental Disorders: Application of Machine Learning in the Works of Vincent van Gogh**. 2025. 94 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Computação. Universidade Federal do Rio Grande - FURG, Rio Grande.

This study investigates the application of machine learning techniques in the analysis of the works of the painter Vincent Van Gogh, with the aim of identifying visual, documentary, and thematic characteristics that may indicate possible mental disorders throughout different periods of his life. The research seeks to correlate variations in the color palette, brushstroke techniques, structure, and compositions of the works with historical records of the artist's life, especially those that document his mental conditions. The applied methodology involved the collection of a database of 2,026 images of Van Gogh's works, categorized by period. For the analysis of the color pattern, the k-means algorithm was used to identify the predominant palettes. The letters written by Van Gogh were analyzed with the Transformers natural language processing algorithm to classify the emotional tone. Brushstroke and texture patterns were evaluated with the gray-level co-occurrence matrix, extracting contrast, dissimilarity, homogeneity, energy, correlation, and second angular moment. The composition and structure were studied with the convolutional neural network algorithm, trained and validated to classify the works by city of production. The results suggest a change in the color palette, structural patterns of the works, and changes in Van Gogh's emotional conditions over the investigated chronological period. A transition from a dark color palette to lighter tones was observed. Regarding brushstroke and texture patterns, contrast and dissimilarity tended to be higher. Homogeneity tended to be lower, indicating less uniform images. Energy remained low, suggesting not very repetitive textures. Correlation was consistently high across all periods. In the analysis of brushstroke directions, less intensity variation was observed in the horizontal and vertical directions when analyzing the characteristics of contrast and dissimilarity. The application of a convolutional neural network demonstrated the complexity in establishing a pattern for Van Gogh's works. The experiments showed low performance, with indications of overfitting in many cases.

Keywords: Emotions, Mental Disorders, Machine Learning, Van Gogh.

LISTA DE FIGURAS

Figura 1	Auto retrato produzido por Van Gogh em 1889.	17
Figura 2	Etapas de funcionamento do algoritmo de redes neurais convolucionais.	27
Figura 3	Dispersão do sistema RGB nas obras de Van Gogh utilizando o algoritmo <i>k-means</i>	46
Figura 4	Distribuição das intensidades de cor nos canais vermelho, verde e azul para o <i>Cluster 0</i> - Intensidade de vermelho	47
Figura 5	Distribuição das intensidades de cor nos canais vermelho, verde e azul para o <i>Cluster 1</i> - Intensidade de Verde.	48
Figura 6	Distribuição das intensidades de cor nos canais vermelho, verde e azul para o <i>Cluster 1</i> - Intensidade de azul.	48
Figura 7	Distribuição das intensidades de cor nos canais vermelho, verde e azul nas obras de Van Gogh produzidas em Nuenen	49
Figura 8	Distribuição das intensidades de cor nos canais vermelho, verde e azul nas obras de Van Gogh produzidas em Paris	49
Figura 9	Distribuição das intensidades de cor nos canais vermelho, verde e azul nas obras de Van Gogh produzidas em Arles	50
Figura 10	Distribuição das intensidades de cor nos canais vermelho, verde e azul nas obras de Van Gogh produzidas em Saint-Rémy-de-Provence	50
Figura 11	Distribuição das intensidades de cor nos canais vermelho, verde e azul nas obras de Van Gogh produzidas em Auvers-sur-Oise	51
Figura 12	Distribuição das intensidades de cor nos canais vermelho, verde e azul de todas as obras de Van Gogh	52
Figura 13	Paletas de cores dominantes das obras de Van Gogh, segmentadas por cidade de produção: Nuenen, Paris, Arles, Saint-Rémy-de-Provence e Auvers-sur-Oise.	53
Figura 14	Funções de Distribuição Cumulativa das características de textura (a) Contraste, (b) Dissimilaridade, (c) Homogeneidade, (d) Energia, (e) Correlação e (f) ASM, obtidas pela análise GLCM das obras de Van Gogh produzidas em Nuenen, em função da probabilidade acumulada, para os ângulos 0°, 45°, 90° e 135°.	54
Figura 15	Funções de Distribuição Cumulativa das características de textura (a) Contraste, (b) Dissimilaridade, (c) Homogeneidade, (d) Energia, (e) Correlação e (f) ASM, obtidas pela análise GLCM das obras de Van Gogh produzidas em Paris, em função da probabilidade acumulada, para os ângulos 0°, 45°, 90° e 135°.	56

Figura 16	Funções de Distribuição Cumulativa das características de textura (a) Contraste, (b) Dissimilaridade, (c) Homogeneidade, (d) Energia, (e) Correlação e (f) ASM, obtidas pela análise GLCM das obras de Van Gogh produzidas em Arles, em função da probabilidade acumulada, para os ângulos 0°, 45°, 90° e 135°.	58
Figura 17	Funções de Distribuição Cumulativa das características de textura (a) Contraste, (b) Dissimilaridade, (c) Homogeneidade, (d) Energia, (e) Correlação e (f) ASM, obtidas pela análise GLCM das obras de Van Gogh produzidas em Saint-Rémy-Provence, em função da probabilidade acumulada, para os ângulos 0°, 45°, 90° e 135°.	59
Figura 18	Funções de Distribuição Cumulativa das características de textura (a) Contraste, (b) Dissimilaridade, (c) Homogeneidade, (d) Energia, (e) Correlação e (f) ASM, obtidas pela análise GLCM das obras de Van Gogh produzidas em Auvers sur Oise, em função da probabilidade acumulada, para os ângulos 0°, 45°, 90° e 135°.	61
Figura 19	Distribuição do tom emocional inferido das cartas de Van Gogh escritas durante suas estadias nas cidades de Nuenen, Paris, Arles, Saint-Rémy-de-Provence e Auvers-sur-Oise.	65
Figura 20	Resultados da acurácia de treinamento e validação ao longo das épocas para os Experimentos (a) 1, (b) 2, (c) 3 e (d) 4 da rede neural convolucional, utilizada para classificar as pinturas de Van Gogh de acordo com a cidade de produção.	69
Figura 21	Resultados do <i>loss</i> de treinamento e validação ao longo das épocas para os Experimentos (a) 1, (b) 2, (c) 3 e (d) 4 da rede neural convolucional, utilizada para classificar as pinturas de Van Gogh de acordo com a cidade de produção.	70
Figura 22	Resultados da precisão de treinamento e validação ao longo das épocas para os Experimentos (a) 1, (b) 2, (c) 3 e (d) 4 da rede neural convolucional, utilizada para classificar as pinturas de Van Gogh de acordo com a cidade de produção.	71
Figura 23	Resultados da <i>recall</i> de treinamento e validação ao longo das épocas para os Experimentos (a) 1, (b) 2, (c) 3 e (d) 4 da rede neural convolucional, utilizada para classificar as pinturas de Van Gogh de acordo com a cidade de produção.	73
Figura 24	Resultados da <i>F1-score</i> de treinamento e validação ao longo das épocas para os Experimentos (a) 1, (b) 2, (c) 3 e (d) 4 da rede neural convolucional, utilizada para classificar as pinturas de Van Gogh de acordo com a cidade de produção.	74
Figura 25	Matrizes de confusão dos resultados da classificação das obras de Van Gogh por cidade, utilizando uma rede neural convolucional nos Experimentos (a) 1, (b) 2, (c) 3 e (d) 4, mostrando o número de acertos e erros para cada cidade (Auvers sur Oise, Nuenen, Paris, Saint-Rémy-de-Provence, Arles).	75
Figura 26	Matrizes de confusão combinadas dos Experimentos (a) 1, (b) 2, (c) 3 e (d) 4, mostrando o desempenho da rede neural convolucional na classificação das obras de Van Gogh produzidas em Nuenen.	76

Figura 27	Matrizes de confusão combinadas dos Experimentos (a) 1, (b) 2, (c) 3 e (d) 4, mostrando o desempenho da rede neural convolucional na classificação das obras de Van Gogh produzidas em Paris.	77
Figura 28	Matrizes de confusão combinadas dos Experimentos (a) 1, (b) 2, (c) 3 e (d) 4, mostrando o desempenho da rede neural convolucional na classificação das obras de Van Gogh produzidas em Arles.	77
Figura 29	Matrizes de confusão combinadas dos Experimentos (a) 1, (b) 2, (c) 3 e (d) 4, mostrando o desempenho da rede neural convolucional na classificação das obras de Van Gogh produzidas em Saint-Rémy-de-Provence.	78
Figura 30	Matrizes de confusão combinadas dos Experimentos (a) 1, (b) 2, (c) 3 e (d) 4, mostrando o desempenho da rede neural convolucional na classificação das obras de Van Gogh produzidas em Auvers Sur Oise.	78

LISTA DE TABELAS

Tabela 1	Resumo das características de textura (Contraste, Dissimilaridade e Homogeneidade).	63
Tabela 2	Resumo das características de textura (Energia, Correlação e ASM). .	64
Tabela 3	: Possíveis Indicadores de Depressão nas Cartas de Van Gogh (por Período)	67

LISTA DE ABREVIATURAS E SIGLAS

ASM	Angular Second Moment
AUC	Area Under the Curve
BDI	Beck Depression Inventory
CDF	Cumulative Distribution Function
CID	Classificação Internacional de Doenças
CNN	Convolutional Neural Network
COVID	Coronavirus Disease
DSM	Diagnostic and Statistical Manual of Mental Disorders
GAD-7	Generalized Anxiety Disorder-7
GLCM	Gray Level Co-occurrence Matrix
MDD	Major Depressive Disorder
ML	Machine Learning
PNL	Processing Natural Language
PHQ-2	Patient Health Questionnaire-2
PO	Primeira Onda
ReLU	Rectified Linear Unit Layer
RGB	Red Green Blue
SMILE	Short Multidimensional Inventory Lifestyle Evaluation
SO	Segunda Onda
TDM	Transtorno Depressivo Maior

SUMÁRIO

1	Introdução	13
2	Vida e obra de Vincent Van Gogh	15
3	Conceitos	18
3.1	Emoção	18
3.2	Arte	20
3.2.1	Impressionismo	21
3.3	Transtorno mental	21
3.3.1	Histórico sobre transtorno mental	21
3.3.2	Critérios diagnósticos	22
3.4	Teorias psicológicas e arte	24
3.5	Padrão RGB	25
3.6	Aprendizado de máquina	26
3.6.1	Algoritmo de redes neurais convolucionais	26
3.6.2	Algoritmos de processamento de linguagem natural	30
3.6.3	Algoritmo <i>K-means</i>	30
3.6.4	Métricas de avaliação	31
3.6.5	Matriz de co-ocorrência de níveis de cinza	32
4	Trabalhos relacionados	34
4.1	Transtornos mentais e aprendizado de máquina	34
4.2	Arte e aprendizado de máquina	39
4.3	Cores e emoções	40
5	Metodologia	41
5.1	Coleta de dados	41
5.2	Pré-processamento de dados	42
5.3	Processamento de dados	42
5.4	Construção e validação do modelo de aprendizado de máquina	43
5.5	Análise dos resultados	45
6	Resultados	46
6.1	Análise de textura e padrões de pinceladas nas obras de Van Gogh	53
6.2	Análise das cartas escritas por Van Gogh	65
6.3	Análise estrutural nas obras de Van Gogh	68

7	Discussão	79
7.1	Nuenen	79
7.2	Paris	81
7.3	Arles	82
7.4	Saint-Rémy-Provence	84
7.5	Auvers-sur-Oise	85
7.6	Considerações acerca da Rede Neural Convolutacional	86
8	Conclusão	87
	Referências	89

ANEXOS

1 INTRODUÇÃO

Nos últimos anos, a integração de tecnologias avançadas no campo da saúde mental tem mostrado um potencial significativo para a análise e tratamento de transtornos mentais. Entre essas tecnologias, o aprendizado de máquina se destaca pela sua capacidade de processar grandes volumes de dados e identificar padrões complexos que seriam difíceis de detectar por métodos tradicionais [15].

Estudos recentes têm demonstrado a eficácia do aprendizado de máquina na predição de problemas de saúde mental. Por exemplo, um estudo utilizou dados de comportamento de saúde de estudantes universitários e diversos algoritmos de aprendizado de máquina e alcançou alta precisão na identificação de traços de bem-estar mental negativo, como depressão e ansiedade [59]. Outro estudo focou na predição de sintomas de saúde mental em adolescentes usando técnicas de aprendizado de máquina e destacou a importância de intervenções precoces para mitigar resultados negativos em longo prazo [73]. Além disso, uma revisão abrangente sobre abordagens de aprendizado de máquina para diagnóstico de saúde mental evidenciou o uso crescente de métodos de aprendizado de máquina e suas implicações para o futuro da psiquiatria, especialmente no diagnóstico e predição de condições como esquizofrenia, depressão, e transtorno bipolar [32].

Pesquisas que relacionam cores com estados mentais são cruciais, pois ajudam a entender como diferentes tonalidades podem refletir ou influenciar o estado emocional de um indivíduo. A pesquisa de [38] revela que cores como azul e verde são frequentemente associadas a sentimentos de calma e felicidade, enquanto vermelho e preto podem estar ligados a estados de raiva ou tristeza. Outro estudo demonstra que cores podem influenciar diretamente o humor e a percepção emocional das pessoas[31].

Este trabalho explora a aplicação de técnicas de aprendizado de máquina na análise das obras do pintor Vincent Van Gogh, com o objetivo de **identificar características visuais, documentais e temáticas que possam indicar possíveis transtornos mentais ao longo de diferentes períodos de sua vida**. Esta análise busca correlacionar variações na paleta de cores, técnicas de pinceladas, estrutura e composições das obras produzidas com os registros históricos da vida do artista, especialmente aqueles que documentam suas condições mentais como as cartas escritas por Van Gogh e registro biográficos.

Com foco neste objetivo, este documento está organizado da seguinte forma: no Capítulo 2 são relatados, brevemente, aspectos da vida e obra de Vicente Van Gogh. No Capítulo 3 são apresentados os principais conceitos pertinente a temática da pesquisa. No Capítulo 4 são discutidos alguns trabalhos relacionado aprendizado de máquina, transtornos mentais e arte. Já no Capítulo 5 são detalhados o objetivo e a metodologia aplicada e análise de dados, enquanto que no Capítulo 6 são apresentados os resultados. No Capítulo 7 são discutidos os resultados obtidos. Por fim, no Capítulo 8 são apresentadas as conclusões.

2 VIDA E OBRA DE VINCENT VAN GOGH

Vincent Willem Van Gogh 1, nascido em 30 de março de 1853, em Zundert, na Holanda, é uma das figuras mais influentes da história da arte ocidental. Sua vida, marcada por períodos de intensa criatividade e sofrimento emocional, teve um impacto considerável no mundo da arte [52]. Van Gogh nasceu em uma família de classe média. Desde cedo mostrou interesse pela arte, embora sua infância fosse caracterizada por uma personalidade introspectiva e melancólica. Aos 16 anos, foi trabalhar para a empresa de arte Goupil Cie. Esta atividade permitiu viajar e viver em cidades como Haia, Londres e Paris, onde teve seu primeiro contato com o universo da arte [52].

Em 1880, aos 27 anos, Vincent decidiu se dedicar inteiramente à arte. Mudou-se para Bruxelas, onde estudou brevemente na *Académie Royale des Beaux-Arts*. Seus primeiros trabalhos foram fortemente influenciados pelo realismo, retratando cenas da vida cotidiana e do campo. Em 1885, na cidade de Nuenen na Holanda, Van Gogh mergulhou na vida rural holandesa. Ele se dedicou a retratar os camponeses, os tecelões e a paisagem local, com cores escuras e terrosas e uma forte ênfase no realismo social. Obras como "Os Comedores de Batata" refletem essa fase, marcada pela preocupação com as condições de vida dos trabalhadores e uma paleta de cores mais sombria. A vida em Nuenen foi um período de aprendizado e experimentação para Van Gogh, onde ele desenvolveu suas habilidades e começou a definir seu estilo próprio. [52].

No final de 1885, Van Gogh se mudou para Antuérpia, onde descobriu a arte japonesa, que teve um impacto significativo em seu estilo. Em 1886, foi para Paris para morar com seu irmão mais novo, Theo Van Gogh, que era comerciante de arte. Nesse contexto, Van Gogh teve contato com o Impressionismo e o Neo-Impressionismo, o que revolucionou sua paleta de cores. As cores se tornaram mais vibrantes e luminosas, e as pinceladas, mais soltas e expressivas. Obras como "Autorretrato com Chapéu de Feltro Cinza" e os diversos estudos de flores demonstram essa mudança. A vida social agitada de Paris também o impactou, levando a temas como cafés, cabarés e a vida urbana [52].

A partir de 1888, Van Gogh deixou Paris e foi para Arles, no sul da França, em busca de uma nova luz e paisagens. Este período foi um dos mais produtivos de sua carreira, produzindo obras-primas como "Girassóis", e "Quarto em Arles". Nesse período, sua

pintura atingiu o ápice da expressividade, com cores vibrantes, pinceladas vigorosas e temas como naturezas-mortas, paisagens e retratos. Em Arles, ele também conviveu com o artista francês Paul Gauguin, o que gerou uma relação intensa e conflituosa, culminando no episódio da mutilação da orelha. Suas cartas ao irmão teu Theo revelam seu sofrimento e luta contra a doença mental [52].

Em 1889, Van Gogh internou-se voluntariamente no asilo de Saint-Paul-de-Mausole, em Saint-Rémy-de-Provence. A natureza ao redor do asilo, com ciprestes, oliveiras e campos de trigo, tornou-se tema recorrente em suas obras. Nesse local, ele continuou pintando, produzindo algumas de suas obras mais famosas, como "A Noite Estrelada" e "Campo de Trigo com Ciprestes". Suas obras dessa época são caracterizadas por movimentos espirais e um uso intenso de cor, transmitindo, dessa forma, intensidade emocional. Obras como "A Noite Estrelada" e "Campo de Trigo com Corvos" refletem a angústia e a busca por serenidade do artista nesse período. Isolamento, a introspecção e a relação com a natureza influenciaram suas pinturas em Saint-Rémy [52].

Nos últimos meses de vida em 1890, Van Gogh se mudou para Auvers-sur-Oise, buscando tratamento com o Dr. Gachet. Nesse local, ele pintou intensamente, retratando a paisagem local, a igreja de Auvers e o retrato do próprio Dr. Gachet. As cores se alternam entre tons vibrantes e melancólicos, e as pinceladas, ora vigorosas, ora mais suaves. Obras como "Campo de Trigo com Corvos" e "Retrato do Dr. Gachet" expressam a complexidade emocional e a luta do artista contra a doença [52].

Diagnosticado com epilepsia do lobo temporal, sua condição foi exacerbada pelo uso frequente de absinto, uma bebida alcoólica popular entre os artistas da época, conhecida por suas propriedades convulsivas. Este consumo aumentava os sintomas psiquiátricos marcados por alucinações, delírios e estados de agitação intensa. O tratamento era feito com brometo de potássio, que proporcionavam certo alívio, mas as dificuldades em manter a abstinência de substâncias como o absinto continuavam a comprometer sua saúde mental e física. Em 1890, ele se mudou para Auvers-sur-Oise, ainda na França. Nesse período, produziu mais de 70 pinturas. Em 27 de julho de 1890, Van Gogh atirou em si mesmo e morreu, aos 37 anos [52].

Van Gogh produziu aproximadamente 2100 obras, incluindo cerca de 860 pinturas a óleo, muitas das quais criadas nos últimos dois anos de sua vida. Embora tenha vendido apenas algumas pinturas durante sua vida, seu trabalho tem profunda e duradoura influência no expressionismo e na arte moderna. Suas cartas a Theo são uma fonte valiosa de informações sobre suas ideias e processos criativos. Hoje, suas obras são algumas das mais valiosas e reconhecidas do mundo, celebradas por sua cor vibrante e expressividade emocional [52].

Estudos recentes sugerem que ao longo do declínio de suas condições mentais, o artista começou a utilizar uma paleta de cores diferente. A análise realizada em três versões do obra "Quarto em Arles", pintada ao longo de dois anos, mostra que Van Gogh usou

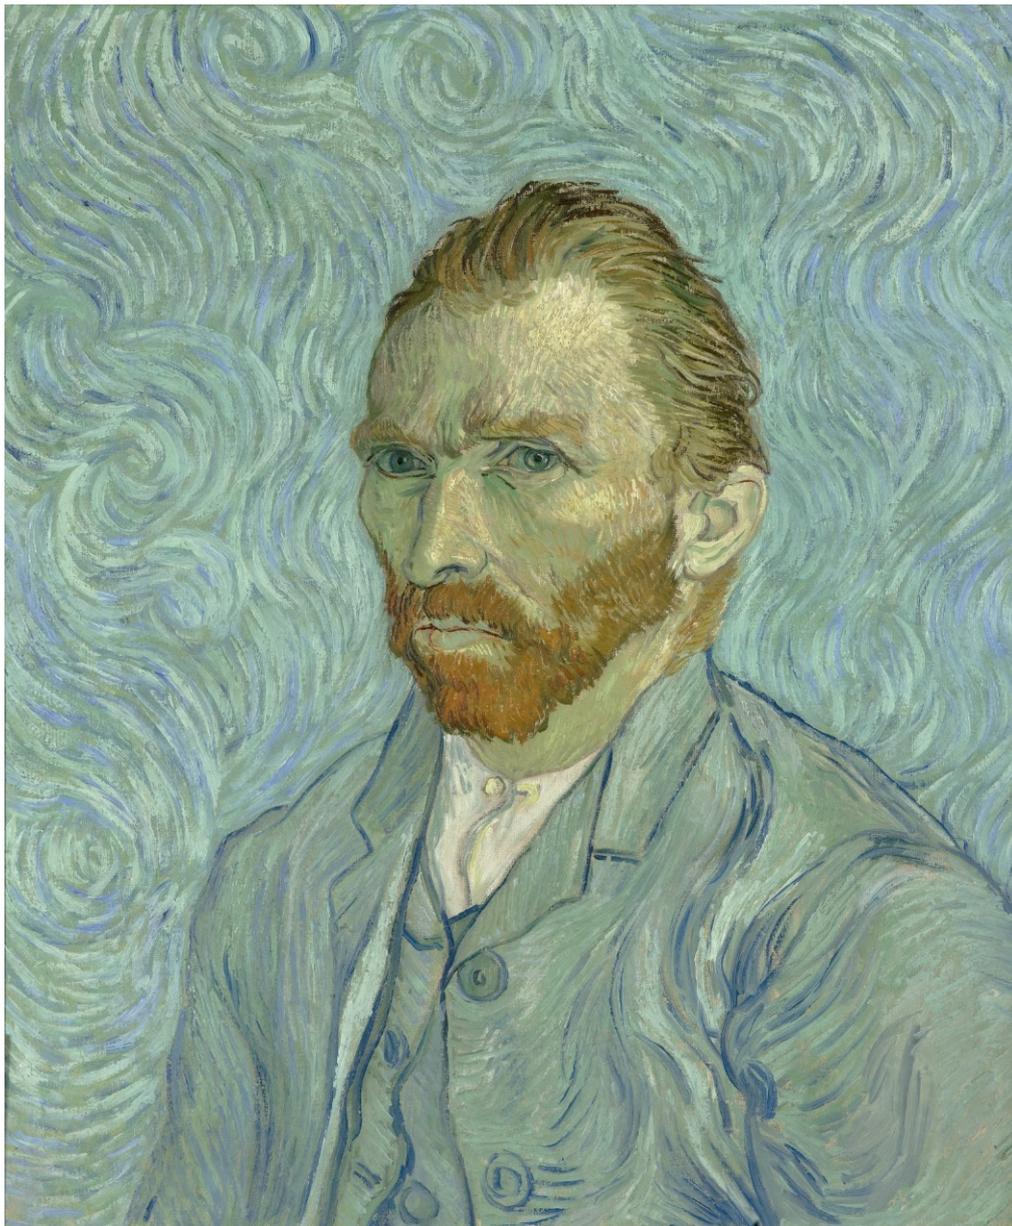


Figura 1: Auto retrato produzido por Van Gogh em 1889.

uma paleta progressivamente mais escura [52].

3 CONCEITOS

Este Capítulo propõe apresentar os conceitos importantes para o entendimento e realização do trabalho. Inicialmente, são apresentados os conceitos de emoção, arte e transtorno mental. Na sequência, são correlacionadas algumas teorias psicológicas e expressão artística. Por fim, é definido o conceito de aprendizado de máquina e apresentado o funcionamento dos algoritmos utilizados na pesquisa.

3.1 Emoção

O artigo de Izard, *The Many Meanings/Aspects of Emotion: Definitions, Functions, Activation, and Regulation*, aborda a complexidade do conceito de emoção. O autor destaca que, apesar da ampla aceitação da importância das emoções na ciência, não existe um consenso sobre uma definição unificada para emoção. O estudo envolveu a análise de respostas de cientistas proeminentes sobre a natureza das emoções. Eles concordaram em vários aspectos, como as funções de ativação e regulação das emoções, mas divergiram em outros. Izard sugere que emoções têm múltiplas interpretações e são integradas de formas variadas na cognição e na ação, enfatizando a necessidade de contextualizar e definir claramente o termo emoção em pesquisas futuras [33]. A autora afirma que embora haja uma ampla aceitação da importância do estudo das emoções, não existe um consenso a respeito da definição de emoção.

A Teoria James-Lange define que as emoções são o resultado direto de reações fisiológicas a estímulos proporcionados pelo ambiente externo. Em outras palavras, contrariando a crença comum de que as emoções provocam reações físicas, essa teoria sugere que é a percepção das mudanças corporais que constitui a emoção. Tal hipótese recebeu críticas e levou ao desenvolvimento de novas teorias sobre emoções, reconhecendo a complexa interação entre fisiologia, experiências e percepção [14].

O artigo *The Cannon–Bard Thalamic Theory of Emotions: A Brief Genealogy and Reappraisal* destaca a importância na transição da teoria de James-Lange para o estudo dos mecanismos cerebrais centrais das emoções. A teoria de Cannon-Bard criticou a teoria de James-Lange por sua ênfase nas respostas viscerais como a fonte das emoções. Em vez

disso, Cannon-Bard sugeriu que as emoções surgem diretamente no cérebro, especificamente no tálamo, e são simultâneas às reações físicas, não sendo causadas por elas. Este conceito marcou uma mudança significativa no entendimento das emoções, destacando o papel do cérebro na geração da experiência emocional [12].

Já a teoria de Schachter-Singer, também conhecida como Teoria de Dois Fatores, argumenta que a experiência emocional é o resultado de uma interação entre estados fisiológicos e a interpretação cognitiva desses estados. Essa teoria propõe que as emoções são formadas pela combinação da excitação fisiológica com a cognição ou avaliação do contexto em que ocorre essa excitação. Diferentemente de teorias anteriores, que sugeriam que as emoções eram diretamente derivadas de respostas fisiológicas, a teoria de Schachter-Singer enfatiza a importância da interpretação cognitiva na determinação da experiência emocional. Esta teoria foi um avanço significativo na psicologia emocional, destacando a complexidade da experiência emocional humana [64].

A teoria das emoções básicas de Ekman postula que existem algumas emoções fundamentais, inatas e universais que são experimentadas por todos os seres humanos, independentemente da cultura ou do contexto social. As emoções básicas identificadas incluem [20]:

- **Alegria:** Uma emoção positiva associada à satisfação, felicidade e contentamento;
- **Tristeza:** Uma emoção negativa que envolve sentimentos de perda, desamparo e desespero;
- **Raiva:** Uma resposta emocional a uma ameaça percebida, frustração ou injustiça;
- **Nojo:** Uma reação de aversão, muitas vezes relacionada à repulsa de algo considerado desagradável ou contaminado;
- **Medo:** Uma emoção de alarme e urgência em resposta a perigos percebidos ou ameaças;
- **Surpresa:** Uma reação breve e muitas vezes neutra a algo inesperado.

Ekman argumenta que essas emoções são expressas de maneira semelhante em culturas diferentes, sugerindo uma base biológica para elas. Além disso, ele estudou as expressões faciais das emoções, demonstrando que as expressões faciais associadas a essas emoções básicas são reconhecíveis por pessoas de diferentes culturas. Posteriormente, essa lista foi expandida para incluir outras emoções como desprezo e, em alguns de seus trabalhos posteriores, explorou a ideia de que outras emoções complexas podem ser combinações a partir dessas emoções básicas [19].

A teoria da construção da emoção de Barrett sugere que as emoções não são reações automáticas e universais a estímulos específicos, mas são experiências construídas pelo

cérebro. Nesse contexto, as emoções são o resultado da interpretação do cérebro para sinais sensoriais do corpo em combinação com o contexto, as experiências passadas e o conhecimento cultural. Barrett propõe que as emoções são construções sociais e psicológicas, não entidades biologicamente programadas. Nesta perspectiva, as emoções são vistas como fenômenos que emergem da interação de várias influências, incluindo estados físicos do corpo, experiências passadas, expectativas, e o ambiente. Em outras palavras, o que é sentido como uma emoção é o resultado do cérebro interpretando as sensações corporais com base no ambiente e aprendizado prévio. Essa abordagem destaca a variabilidade e a complexidade das emoções humanas e sugere que elas são mais personalizadas e contextualizadas do que as teorias anteriores sugeriam [7].

3.2 Arte

A arte pode ser entendida como uma forma de expressão humana que engloba uma ampla gama de atividades e criações que expressam ideias, emoções, visões de mundo ou beleza. Ela pode assumir muitas formas, como pintura, escultura, música, literatura, dança, teatro, fotografia, cinema ou arquitetura. As características fundamentais da arte incluem [16, 42]:

1. **Expressão criativa:** A arte é um meio para os indivíduos expressarem seus sentimentos, pensamentos e visões. Cada obra de arte é uma representação da visão de mundo do seu criador, seja ela uma expressão pessoal, uma representação social ou uma exploração de conceitos abstratos.
2. **Comunicação:** A arte serve como um poderoso meio de comunicação, capaz de transmitir ideias e emoções complexas que podem ser difíceis de expressar através da linguagem convencional. Ela pode provocar discussões, inspirar mudanças e influenciar a opinião pública.
3. **Estética:** A arte muitas vezes busca provocar uma resposta estética no observador, seja ela de admiração pela beleza, choque, reflexão ou contemplação. A estética pode variar grandemente de acordo com diferentes culturas e períodos históricos.
4. **Inovação e técnica:** A arte frequentemente envolve a exploração de novas ideias, técnicas e materiais. Os artistas podem experimentar com diferentes abordagens para criar obras que desafiam as convenções ou exploram novas fronteiras estéticas.
5. **Reflexo cultural e histórico:** A arte é um reflexo das sociedades e culturas em que é criada. Ela pode fornecer *insights* valiosos sobre as crenças, valores, e a história de diferentes povos e épocas.

3.2.1 Impressionismo

O Impressionismo foi um movimento artístico revolucionário que surgiu na França na segunda metade do século XIX, marcando uma ruptura com as convenções da pintura acadêmica da época. Os artistas impressionistas buscavam capturar a impressão visual imediata de um momento, priorizando a representação dos efeitos da luz e da cor sobre os objetos e paisagens. Em vez de linhas nítidas e contornos definidos, eles empregavam pinceladas visíveis, rápidas e fragmentadas, utilizando uma paleta de cores claras e vibrantes para transmitir a atmosfera e a sensação do instante observado, muitas vezes pintando ao ar livre para melhor registrar as nuances da luz natural e os aspectos da vida cotidiana [47].

Entre os principais expoentes do Impressionismo, destacam-se nomes como Claude Monet, pioneiro do movimento e famoso por suas séries de pinturas de nenúfares e da Catedral de Rouen; Pierre-Auguste Renoir, conhecido por suas cenas alegres da vida parisiense e retratos; Edgar Degas, que retratava com frequência bailarinas e cenas de bastidores; Berthe Morisot, uma das poucas mulheres a integrar o movimento, conhecida por suas pinturas delicadas de cenas domésticas e retratos; e Camille Pissarro, considerado o decano dos impressionistas e mestre na representação de paisagens rurais e urbanas. Outros artistas importantes incluem Alfred Sisley e Gustave Caillebotte, cada um contribuindo com sua perspectiva única para a estética impressionista [47].

3.3 Transtorno mental

Transtorno mental é definido como um padrão ou anomalia de pensamento, emoção ou comportamento que resulta em sofrimento pessoal, prejuízo no funcionamento social ou ocupacional, ou risco significativo de sofrimento. Esses transtornos podem variar amplamente em termos de severidade e sintomas, e podem incluir condições como depressão, ansiedade, transtornos de humor, esquizofrenia ou transtornos de personalidade. Eles são geralmente caracterizados por desvios das normas de desenvolvimento psicológico e social, impactando significativamente a qualidade de vida e a capacidade de atender às demandas do dia a dia. O diagnóstico e tratamento de transtornos mentais geralmente requerem uma abordagem multidisciplinar, envolvendo profissionais de saúde mental, como psiquiatras e psicólogos [2].

3.3.1 Histórico sobre transtorno mental

O primeiro relato escrito relacionado a transtorno mental, mais especificamente sobre depressão, apareceu em 2000 a.C. na antiga Mesopotâmia. Na sequência, por volta de 500 a.C., novos relatos foram identificados nas civilizações gregas, romanas, babilônicas, chinesas e egípcias. Nas culturas antigas, os transtornos mentais eram frequentemente relacionados como manifestações de forças sobrenaturais ou descontentamento dos deuses

[6] [27].

Durante a Idade Média, a interpretação dos transtornos mentais era muitas vezes influenciada por crenças religiosas. Indivíduos com transtornos mentais eram diagnosticados como possuídos por demônios, sendo submetidos a tratamentos de exorcismo [6] [27].

No período do renascimento e iluminismo ocorreram as primeiras manifestações científicas e humanitárias dos transtornos mentais. Philippe Pinel, na França, e William Tuke, na Inglaterra, foram pioneiros em tratar os indivíduos com doenças mentais com dignidade e respeito, promovendo um cuidado mais compreensivo [6] [27].

Durante o século XIX e início do século XX, iniciou a formação de uma abordagem mais clínica e patológica dos transtornos mentais. Abordagens psicodinâmicas introduzidas pela Psicanálise, através de Sigmund Freud, enfatizaram a importância dos processos mentais inconscientes. Emil Kraepelin desenvolveu um sistema inicial de classificação dos transtornos mentais, que influenciou as futuras classificações diagnósticas propostas por manuais [6].

Em meados do século XX, houveram avanços significativos na psicofarmacologia, com advento de antipsicóticos e antidepressivos, revolucionando o tratamento dos transtornos mentais. A desinstitucionalização também começou, com um movimento em direção ao tratamento de indivíduos com transtornos mentais em comunidades, em vez de instituições psiquiátricas tradicionais [6] [27].

No final do século XX, desenvolveram-se abordagens mais sofisticadas, com bases biológicas e ambientais dos transtornos mentais. A publicação do DSM (Manual Diagnóstico e Estatístico de Transtornos Mentais) e da CID (Classificação Internacional de Doenças) ajudou a padronizar o diagnóstico. Além disso, houve um crescente reconhecimento da importância da saúde mental e do estigma associado aos transtornos mentais, com mais ênfase na recuperação e no suporte comunitário [3, 6, 55].

3.3.2 Critérios diagnósticos

Os critérios diagnósticos para transtornos mentais são conjuntos padronizados de diretrizes usadas por profissionais de saúde mental para determinar se uma pessoa possui um transtorno psicológico específico [3]. Esses critérios são geralmente estabelecidos por manuais diagnósticos reconhecidos, como:

- **DSM (Manual Diagnóstico e Estatístico de Transtornos Mentais):** Publicado pela Associação Americana de Psiquiatria, o DSM é um dos manuais mais amplamente utilizados no mundo. Ele fornece descrições detalhadas, sintomas e outros critérios necessários para o diagnóstico de uma variedade de transtornos mentais [3].
- **CID (Classificação Internacional de Doenças):** Desenvolvida pela Organização Mundial da Saúde, a CID é outro sistema de classificação amplamente utilizado

que inclui capítulos específicos para transtornos mentais. A CID fornece códigos associados a cada transtorno, que são usados em contextos de saúde em todo o mundo [55].

Os critérios diagnósticos para transtornos mentais geralmente incluem:

- **Sintomas específicos:** Alguns transtornos incluem os seguintes sintomas:
 - Humor persistentemente triste, ansioso ou "vazio";
 - Perda de interesse ou prazer em atividades que antes eram prazerosas;
 - Fadiga ou perda de energia;
 - Dificuldade de concentração, indecisão;
 - Alterações no sono (insônia ou hipersonia);
 - Alterações no apetite ou peso;
 - Sentimentos de inutilidade ou culpa excessiva;
 - Pensamentos de morte ou suicídio.
 - Diminuição da necessidade de sono. Sentir-se descansado após apenas algumas horas de sono;
 - Mais loquaz do que o habitual ou pressão para continuar falando. Falar excessivamente, rapidamente e de forma difícil de interromper;
 - Fuga de ideias ou experiência subjetiva de que os pensamentos estão correndo. Uma torrente de pensamentos rápidos e em constante mudança, com dificuldade em se concentrar em um único tópico;
 - Distraibilidade. Atenção muito facilmente desviada por estímulos externos irrelevantes ou sem importância;
 - Aumento da atividade dirigida a objetivos (social, profissional, escolar ou sexualmente) ou agitação psicomotora. Envolvimento excessivo em atividades planejadas ou inquietação física e mental;
 - Envolvimento excessivo em atividades prazerosas que têm um alto potencial para consequências dolorosas. Por exemplo, gastos excessivos, indiscrições sexuais ou investimentos financeiros arriscados.
- **Duração:** Quanto tempo os sintomas devem estar presentes para que se qualifiquem para um diagnóstico. Por exemplo, quadros depressivos podem ser diagnosticados a partir de um humor deprimido persistente por mais de duas semanas.
- **Impacto funcional:** Avaliação de como os sintomas afetam a capacidade da pessoa de funcionar em diferentes áreas da vida, como trabalho, escola ou relacionamentos.

- **Exclusão de outras condições:** Verificação de que os sintomas não são melhor explicados por outra condição médica ou mental. Por exemplo, o transtorno depressivo pode fazer parte de um espectro mais amplo como em um quadro de transtorno bipolar.

3.4 Teorias psicológicas e arte

Existem diversas teorias psicológicas que relacionam-se com a arte. Algumas delas são:

- **Teoria psicanalítica de Freud**

A teoria psicanalítica clássica entende que a arte, da mesma forma que os sonhos, é uma via de acesso ao inconsciente. Dessa maneira, a capacidade artística é uma forma de expressão de conteúdo de desejos reprimidos no inconsciente [41].

A expressão artística também é entendida como resultado do uso de mecanismo de defesa psíquica denominado sublimação. Entende-se por sublimação o processo pelo qual impulsos ou desejos inaceitáveis são transformados em atividades socialmente aceitáveis ou mesmo admiráveis, como a arte. A capacidade simbólica presente em pinturas pode relevar *insights* sobre o estado psíquico do artista ou sobre temas universais do inconsciente humano. Ainda no contexto psicanalítico, a apreciação de uma obra de arte possibilita ao expectador identificar-se tanto com os conflitos emocionais expressos na obra como também com questões universais humanas [41].

- **Teoria da catarse de Aristóteles**

A teoria da catarse de Aristóteles afirma que a experiência de emoções dramáticas de medo e piedade através dos personagens da tragédia propicia ao telespectador uma capacidade de limpeza emocional. Essa experiência catártica proporciona o equilíbrio necessário para a saúde emocional de um indivíduo através da arte [11, 18].

- **Teoria analítica de Jung**

A teoria analítica de Jung vê a arte como uma manifestação do inconsciente coletivo e uma forma de acessar e integrar o *self*. Em outras palavras, a arte autêntica emerge a partir do processo de individuação, ou seja, o desenvolvimento integral da personalidade humana, revelando arquétipos e temas universais compartilhados por toda a humanidade [36].

- **Teoria humanista**

A teoria humanista propõe a arte como uma forma de autoexpressão e autodescoberta. Por meio da arte, os indivíduos podem explorar suas potencialidades e expressar aspectos de si mesmos que podem não ser facilmente comunicados por meio da linguagem verbal, enfatizando a aceitação e a validação das experiências e emoções individuais. O uso da arte como ferramenta de escuta pode criar um espaço onde as experiências internas são validadas e expressas [62].

3.5 Padrão RGB

O padrão RGB (*Red, Green, Blue*) é um modelo de cores aditivas utilizado para a representação e exibição de imagens em dispositivos eletrônicos como monitores, televisores e câmeras digitais. Este modelo é baseado na teoria da visão tricromática humana, que afirma que a percepção de cores é devida à combinação de três tipos de receptores sensíveis à luz (cones) no olho humano, que são mais sensíveis a comprimentos de onda correspondentes ao vermelho, verde e azul [26].

No modelo RGB, as cores são criadas pela combinação de diferentes intensidades de luz vermelha, verde e azul. Cada uma dessas cores primárias pode ter um valor que varia de 0 a 255, onde 0 representa a ausência de luz e 255 representa a intensidade máxima de luz. A combinação dessas três cores em diferentes intensidades pode produzir uma ampla gama de cores [10]. Onde:

- **Preto:** (0, 0, 0) - ausência de luz em todas as três cores.
- **Branco:** (255, 255, 255) - intensidade máxima de luz em todas as três cores.
- **Vermelho:** (255, 0, 0) - intensidade máxima de luz vermelha, sem luz verde ou azul.
- **Verde:** (0, 255, 0) - intensidade máxima de luz verde, sem luz vermelha ou azul.
- **Azul:** (0, 0, 255) - intensidade máxima de luz azul, sem luz vermelha ou verde.

O uso do padrão RGB é fundamental para muitas tecnologias digitais. Em monitores de computador e televisores, cada *pixel* é composto por *sub-pixels* vermelhos, verdes e azuis que variam em intensidade para criar a cor desejada. Este método é eficiente para dispositivos de exibição devido à capacidade dos sistemas eletrônicos de controlar precisamente a intensidade de luz emitida por cada *sub-pixel* [57].

Além disso, o modelo RGB é amplamente utilizado em *softwares* de edição de imagens, onde os valores de RGB podem ser ajustados para alterar a cor de uma imagem digital. O modelo também é essencial para a captura de imagens em câmeras digitais, onde os sensores de imagem detectam a luz nos espectros vermelho, verde e azul e convertem essas informações em dados digitais [17].

3.6 Aprendizado de máquina

Aprendizado de máquina (do inglês, *Machine Learning* - ML) é um subcampo da inteligência artificial que foca no desenvolvimento de algoritmos e técnicas que permitem aos computadores aprender e melhorar a partir da experiência. As principais características do aprendizado de máquina incluem [29]:

- **Aprendizado com dados:** Ao invés de ser explicitamente programado para realizar uma tarefa específica, algoritmos de aprendizado de máquina são treinados usando grandes conjuntos de dados. Por exemplo, para identificar objetos em imagens, um modelo de aprendizado de máquina seria treinado com milhares de imagens rotuladas.
- **Modelos preditivos:** Uma vez treinado com dados, o sistema pode fazer previsões ou tomar decisões com base em novos dados de entrada. Por exemplo, um modelo de aprendizado de máquina treinado em dados históricos de transações financeiras pode ser usado para detectar atividades fraudulentas.
- **Melhoria Contínua:** Um aspecto crucial é a capacidade de melhorar automaticamente com a experiência. Quanto mais dados o sistema processa, mais ele afina seu modelo para melhorar a precisão.
- **Tipos de Aprendizado:** As seguintes abordagens de aprendizado são utilizadas:
 - **Aprendizado supervisionado:** o modelo é treinado em um conjunto de dados rotulado e aprende a fazer previsões com base nessas etiquetas;
 - **Aprendizado Não supervisionado:** o modelo analisa e agrupa dados não rotulados com base em semelhanças ou padrões;
 - **Aprendizado por Reforço:** o modelo aprende a tomar decisões através de tentativa e erro, recebendo recompensas ou penalidades por suas ações.

3.6.1 Algoritmo de redes neurais convolucionais

O algoritmo de redes neurais convolucionais (do inglês, *Convolutional Neural Network* - CNN) é uma classe de redes neurais artificiais usadas em tarefas de reconhecimento de imagem e processamento de vídeo devido à sua capacidade de captar padrões espaciais e hierárquicos em dados visuais. O algoritmo CNN funciona com os componentes e estruturas apresentados pela Figura 2.

1. Camadas Convolucionais (*Convolutional Layers*):

- A camada convolucional é o núcleo de uma CNN. Ela aplica um conjunto de filtros (*kernels*) à entrada para criar mapas de características (*feature maps*).

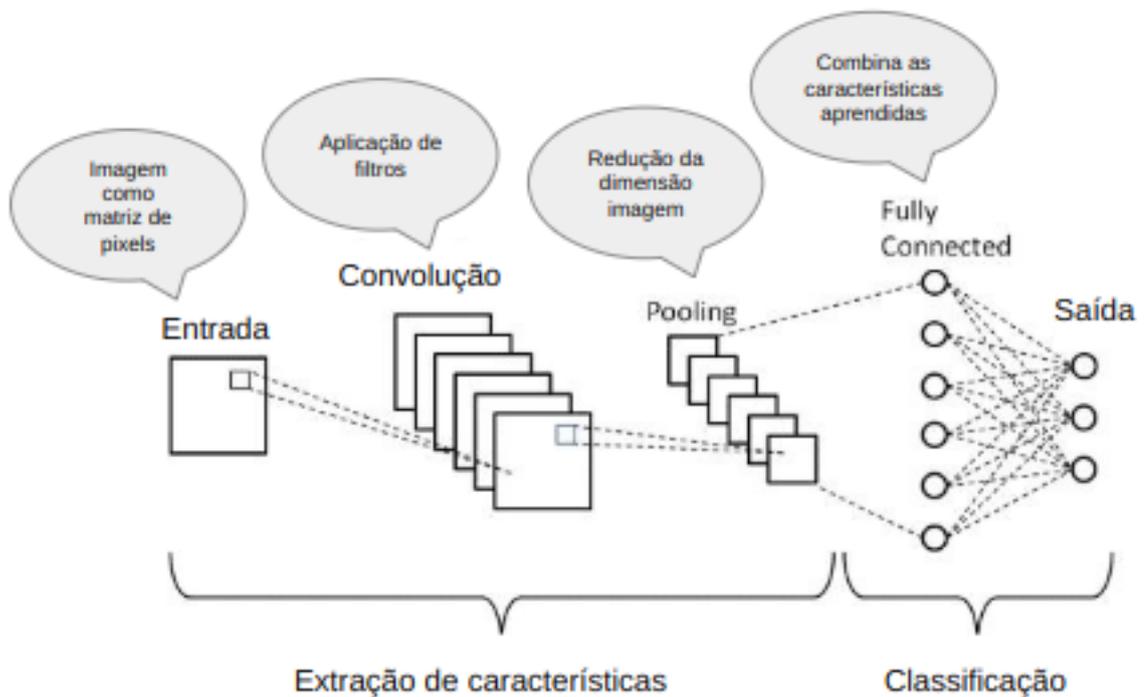


Figura 2: Etapas de funcionamento do algoritmo de redes neurais convolucionais.

Cada filtro é uma pequena matriz de pesos que percorre a entrada, realizando operações de convolução [45]. Dada uma imagem bidimensional de entrada, em cada camada, um conjunto de n filtros de convolução K_i , com $i = 1, 2, \dots, n$, podem ser aplicados, de modo a obter várias bandas B_i da imagem original.

- Dessa forma, a operação de convolução pode ser definida como

$$B_l(p) = \sum_{\forall w \in N(p)} I(w) \cdot K_l(w)$$

onde w corresponde a um *pixel* pertencente à vizinhança de p , isto é, $N(p)$. Com $I(w)$ correspondente ao valor da imagem na posição w e $K_l(w)$ corresponde ao valor na posição respectiva a w no *kernel* i .

2. Camada de ReLU (*Rectified Linear Unit Layer*):

- Após a convolução, é comum aplicar a função de ativação ReLU, que introduz não-linearidade no modelo:

$$B_l(p) = \max\{B_l(p); 0\}$$

- ReLU ajuda a rede a aprender características não-lineares complexas [53].

3. Camadas de Pooling (*Pooling Layers*):

- As camadas de *pooling* reduzem a dimensionalidade dos mapas de características, preservando as informações mais importantes. Em outras palavras, essas operações são realizadas a partir das várias bandas da imagem original a fim de se obter invariância translacional. Em geral, emprega-se operações de *pooling* máximo, onde o valor máximo em cada região da matriz de entrada é selecionado[9]. A operação de *pooling* é dado por

$$M_l(r) = \max_{\forall p \in \beta(r)} \{B_l(p)\}$$

onde $\beta(r)$ corresponde à região de *pooling* referente a r , na banda B_l . Mais operações similares podem ser agregadas. Os resultados, estruturas de dados geradas bandas, são passadas para camadas superiores da rede. Ao final, tem-se uma representação de alto nível dos dados originais, codificada em um vetor de características numérico.

4. Camadas totalmente conectada (*Fully Connected Layers*):

- Essas camadas conectam todos os neurônios de uma camada à camada seguinte. Elas são usadas nas partes finais da CNN, após as camadas convolucionais e de *pooling*, para tomar decisões com base nas características extraídas.
- A operação em uma camada totalmente conectada é:

$$f(x) = Wx + b$$

onde W é a matriz de pesos e b é o vetor de *bits* [45].

Já o funcionamento da CNN segue a seguinte ordem de execução:

1. Entrada:

- A CNN recebe uma imagem de entrada representada como uma matriz de pixels (por exemplo, uma imagem de 32x32 pixels com 3 canais de cor).

2. Processamento através de camadas convolucionais e ReLU:

- A entrada passa por uma série de camadas convolucionais, onde filtros específicos são aplicados para extrair características como bordas, texturas e padrões.
- Cada saída convolucionada é passada por uma camada ReLU para introduzir não-linearidade [53].

3. Redução de dimensionalidade com *Pooling*:

- As camadas de *pooling* reduzem a resolução espacial dos mapas de características, mantendo as informações mais importantes e reduzindo a quantidade de parâmetros [9].

4. Camadas *Fully Connected*:

- As características extraídas são achatadas em um vetor e passadas por várias camadas totalmente conectadas para realizar a classificação ou regressão final [45].

5. Saída:

- A camada final geralmente usa uma função de ativação como *softmax* para produzir uma distribuição de probabilidades sobre as classes possíveis no caso de uma tarefa de classificação:

$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$$

Para realizar o treinamento da CNN segue a seguinte ordem:

1. *Forward Pass*:

- Os dados de entrada passam através da rede, camada por camada, até a camada de saída.

2. Cálculo da função de custo:

- A função de custo (por exemplo, entropia cruzada para classificação) calcula o erro entre a saída prevista e o valor real [29].

3. *Backward pass* e atualização dos pesos:

- Usando *backpropagation*, os gradientes da função de custo em relação aos pesos da rede são calculados e os pesos são atualizados usando um otimizador como o gradiente descendente [63].

As aplicações de CNNs são diversas, onde pode-citar:

- **Reconhecimento de imagens:** Classificação de objetos em imagens, detecção de rostos, reconhecimento de dígitos escritos à mão [43].
- **Processamento de vídeo:** Reconhecimento de ações, análise de comportamento [37].
- **Visão computacional:** Segmentação de imagem, detecção de bordas, análise de imagens médicas [50].

3.6.2 Algoritmos de processamento de linguagem natural

Os algoritmos de Processamento de Linguagem Natural (do inglês, *Processing Natural Language* - PNL) capacitam computadores a compreenderem e processarem a linguagem humana, transformando texto e fala em dados utilizáveis. Eles operam através das etapas de tokenização, análise sintática e semântica. Tais técnicas permitem identificar padrões, sentimentos, intenções e entidades em textos, possibilitando aplicações como tradução automática, *chatbots*, análise de sentimentos em mídias sociais e sistemas de recomendação [71].

Nesse contexto, o *Transformer* é uma arquitetura de rede neural do campo da PNL e se tornou a base para muitos modelos de linguagem de última geração. Desenvolvido para lidar com tarefas de sequência para sequência, como tradução automática, o *Transformer* se destaca por sua capacidade de processar sequências de dados em paralelo. A principal inovação reside no seu mecanismo de atenção, especialmente a autoatenção, que permite ao modelo ponderar a importância de diferentes partes da sequência de entrada ao processar cada elemento, capturando dependências de longo alcance de forma mais eficaz [71].

O classificador de sentimentos do Transformers processa o texto inicial dividindo-o em *tokens* (palavras ou subpalavras), um passo essencial para a análise numérica. Em seguida, esses *tokens* são transformados em *embeddings*, que são representações vetoriais que capturam o significado das palavras. A arquitetura *Transformer*, central para o algoritmo, utiliza a autoatenção para aprender as relações entre as palavras dentro da mesma frase, permitindo que o modelo compreenda o contexto. Finalmente, a camada de classificação produz o sentimento predominante (positivo, negativo, etc.) e, por vezes, uma pontuação de confiança [71].

3.6.3 Algoritmo *K-means*

O *k-means* é um algoritmo de agrupamento usado em aprendizado não supervisionado para dividir um conjunto de dados em k *clusters*, onde a letra k é um número pré-definido de *clusters* [8]. Sua execução segue as seguintes etapas:

1. **Inicialização:** Seleciona k centróides iniciais, que podem ser escolhidos aleatoriamente ou de outras formas, como o método *k-means++*.
2. **Atribuição:** Cada ponto de dados é atribuído ao centróide mais próximo, formando k *clusters*. A distância entre um ponto de dados e um centróide é geralmente medida pela distância euclidiana.
3. **Atualização:** Recalcula a posição dos centróides como a média dos pontos de dados atribuídos a cada *cluster*.

4. **Repetição:** Os passos de atribuição e atualização são repetidos até que os centróides não mudem mais significativamente ou até que um número máximo de iterações seja alcançado.

Um exemplo de utilização pode ser um conjunto de dados com coordenadas (x, y) a ser agrupados em $k = 2$ *clusters*:

1. Inicializa dois centróides aleatoriamente.
2. Atribui cada ponto de dados ao centróide mais próximo.
3. Recalcula a posição dos dois centróides como a média dos pontos no *cluster*.
4. Repete os passos 2 e 3 até que os centróides se estabilizem.

Durante as etapas do algoritmo, são visualizadas informações diferentes:

1. **Inicialização:** Centróides em posições aleatórias.
2. **Iteração 1:** Atribuição dos pontos aos centróides e recálculo dos centróides.
3. **Iteração 2:** Nova atribuição dos pontos aos centróides recalculados e recálculo dos centróides novamente.
4. **Convergência:** Quando os centróides não mudam mais significativamente. ou as iterações 1 a N continuarão até atender este critério.

Pode-se citar algumas vantagens e desvantagens do uso do algoritmo *k-means*:

- **Vantagens:** Simplicidade e eficiência em termos computacionais e bom funcionamento com *clusters* de forma esférica e tamanho semelhante.
- **Desvantagens:** Requer a especificação do número de *clusters* *k a priori*, tem sensibilidade à escolha inicial dos centróides e não funciona bem com *clusters* de formas e densidades variadas.

O *k-means* é amplamente utilizado em análise de dados exploratória, segmentação de mercado, compressão de imagens, entre outros campos.

3.6.4 Métricas de avaliação

Métricas de avaliação são utilizadas para verificar a eficácia de um algoritmo de aprendizado de máquina ao aplicá-lo em um conjunto de dados. De maneira geral, são consideradas as seguintes métricas [25]:

- **Acurácia**

A acurácia é a proporção de previsões corretas feitas pelo modelo em relação ao total de previsões. Ela é calculada como:

$$Acurácia = \frac{\sum VerdadeirosPositivos + \sum VerdadeirosNegativos}{NúmeroamostrasTeste}$$

- **Precisão**

A precisão é a proporção de previsões positivas corretas em relação ao total de previsões positivas feitas pelo modelo. Ela é calculada como:

$$Precisão = \frac{\sum VerdadeirosPositivos}{\sum VerdadeirosPositivos + \sum FalsosPositivos}$$

- **Recall**

O *recall* (também conhecido como sensibilidade) é a proporção de previsões positivas corretas em relação ao total de instâncias reais positivas. Ele é calculado como:

$$Recall = \frac{\sum VerdadeirosPositivos}{\sum VerdadeirosPositivos + \sum FalsosNegativos}$$

- **F1-score**

O *F1-score* é a média harmônica entre a precisão e o *recall*. Ele é uma métrica útil quando há um desbalanceamento entre as classes e queremos um equilíbrio entre precisão e *recall*. Ele é calculado como:

$$F1 - score = 2 \times \frac{Precisão \times Recall}{Precisão + Recall}$$

- **Matriz de confusão**

A matriz de confusão é uma tabela que permite a visualização do desempenho de um algoritmo de classificação. Cada linha da matriz representa as instâncias reais de uma classe, enquanto cada coluna representa as instâncias previstas de uma classe. A matriz tem a seguinte forma para um problema binário:

	<i>PrevistoPositivo</i>	<i>PrevistoNegativo</i>
<i>RealPositivo</i>	<i>TP</i>	<i>FN</i>
<i>RealNegativo</i>	<i>FP</i>	<i>TN</i>

3.6.5 Matriz de co-ocorrência de níveis de cinza

A Matriz de Co-ocorrência de Níveis de Cinza (do inglês, *Gray Level Co-occurrence Matrix* - GLCM) é uma matriz que conta a frequência com que pares de *pixels* com

níveis de cinza específicos ocorrem em uma imagem, em uma dada relação espacial. Essa relação espacial é definida pela distância e ângulo [66]. A matriz GLCM tem dimensões iguais ao número de níveis de cinza na imagem. Por exemplo, se a imagem for em escala de cinza de 8 bits, a matriz terá 256×256 *pixels*. Cada elemento (i, j) da matriz armazena a contagem de quantas vezes um pixel com nível de cinza 'i' ocorre adjacente a um pixel com nível de cinza 'j', de acordo com a relação espacial definida. As principais características que podem ser observadas e calculadas a partir da GLCM incluem:

Contraste: Mede a diferença de intensidade entre um *pixel* e seu vizinho. Um alto contraste indica uma grande variação nos níveis de cinza localmente, sugerindo uma textura mais áspera ou com bordas bem definidas. Um baixo contraste indica pouca variação, sugerindo uma textura mais suave.

Dissimilaridade: Quantifica o grau de diferença nos níveis de cinza entre pares de pixels vizinhos em uma imagem. Ela indica o quão diferentes são os níveis de cinza dos pixels que ocorrem juntos dentro de uma janela de análise e para uma determinada relação espacial (distância e ângulo).

Homogeneidade: Mede a proximidade da distribuição dos elementos na GLCM à diagonal principal. Uma alta homogeneidade indica que a maioria dos pares de *pixels* vizinhos tem níveis de cinza semelhantes (os valores na GLCM estão concentrados perto da diagonal). Uma baixa homogeneidade sugere uma maior dispersão dos valores, indicando maior variação nos níveis de cinza entre vizinhos.

Energia: Mede a homogeneidade da imagem. Uma alta energia indica que a imagem tem uma textura muito regular ou uniforme, com poucas variações nos padrões de ocorrência. Uma baixa energia sugere uma textura mais complexa e menos uniforme.

Correlação: Mede o grau de dependência linear entre os valores de nível de cinza de *pixels* vizinhos. Uma alta correlação indica que os níveis de cinza de *pixels* vizinhos tendem a ser semelhantes. Uma baixa correlação sugere que não há uma relação linear forte entre os níveis de cinza vizinhos.

Segundo Momento Angular (do inglês, *Angular Second Moment - ASM*) também conhecido como Energia ou Uniformidade, quantifica a homogeneidade ou uniformidade da textura de uma imagem. Ele mede o grau em que pares de *pixels* vizinhos têm níveis de cinza semelhantes.

4 TRABALHOS RELACIONADOS

Este Capítulo apresenta três grupos de estudos: primeiro, os principais trabalhos relacionados a transtornos mentais e aprendizado de máquina, e em um segundo momento, trabalhos relacionados a aprendizado de máquina na análise de obras de arte. E finalmente, trabalhos que abordam cores e emoções.

4.1 Transtornos mentais e aprendizado de máquina

O estudo de [51] avaliou longitudinalmente as taxas de primeiro episódio de depressão maior durante a pandemia de COVID-19 em adultos italianos sem diagnóstico psiquiátrico anterior e criou um modelo preditivo de aprendizado de máquina para avaliar amostras independentes subsequentes. Um questionário online de autoavaliação foi lançado nos períodos de maio a junho, e de setembro a outubro de 2020. Diagnósticos provisórios de transtorno depressivo maior (TDM) foram determinados usando um algoritmo de diagnóstico com base nos critérios do DSM V do Questionário de Saúde do Paciente-9 para maximizar a especificidade. Foram utilizados os algoritmos de árvores de decisão impulsionadas por gradiente e a técnica de Explicações Aditivas de Shapley para estimar a contribuição preditiva de cada variável.

No total, participaram do estudo 3.532 participantes. A amostra final incluiu 633 participantes na pesquisa da primeira onda (PO) e 290 na segunda onda (SO). O TDM foi encontrado em 7,4% dos participantes da PO e 7,2% da SO. O ML final, treinado na PO, exibiu uma sensibilidade de 76,5% e uma especificidade de 77,8% quando testado na SO. Os principais fatores identificados foram baixa resiliência, ser estudante de graduação, estar estressado devido às condições relacionadas à pandemia e baixa satisfação com o sono habitual antes da pandemia e o apoio de familiares. O tabagismo atual e o uso de medicamentos para condições médicas também contribuíram, embora em menor grau. Nesse contexto, as taxas de primeiro episódio de depressão maior entre os italianos durante as fases iniciais da pandemia foram consideráveis. O ML exibiu um bom desempenho preditivo, sugerindo metas potenciais para intervenções preventivas da depressão durante crises de saúde pública. Apesar dos resultados promissores, os autores destacam como limitação

o tamanho restrito da amostra, avaliação por meio de autorelato do participantes e dados cobrindo somente o ano de 2020.

Ainda no contexto da pandemia de COVID-19, o trabalho de [65] teve como objetivo avaliar se os comportamentos de estilo de vida podem prever a presença de depressão e ansiedade na população geral brasileira, usando um modelo desenvolvido na Espanha. Uma pesquisa web foi realizada durante abril e maio de 2020 através da escala *Short Multidimensional Inventory Lifestyle Evaluation* (SMILE), cujo objetivo era avaliar os comportamentos de estilo de vida durante a pandemia de COVID-19. A depressão e a ansiedade foram examinadas usando o PHQ-2 (do inglês, *Patient Health Questionnaire-2*) e o GAD-7 (do inglês, *Generalized Anxiety Disorder-7*), respectivamente. *lastic net*, *random forest* e *gradient tree boosting* foram usados para desenvolver modelos preditivos. Cada técnica utilizou um subconjunto da amostra espanhola para treinar os modelos, que foram então testados internamente (em relação ao restante da amostra espanhola) e externamente (em relação à amostra brasileira completa), avaliando sua eficácia.

A amostra do estudo incluiu 22.562 indivíduos (19.069 do Brasil e 3.493 da Espanha). Os modelos desenvolvidos se saíram de maneira semelhante e foram igualmente eficazes na previsão da depressão e ansiedade em ambos os testes, com valores de acurácia no teste interno de 0,85 (depressão) e 0,86 (ansiedade) e valores de acurácia no teste externo de 0,85 (depressão) e 0,84 (ansiedade). O significado da vida foi o preditor mais forte da depressão, enquanto a qualidade do sono foi o preditor mais forte da ansiedade. De modo geral, comportamentos de estilo de vida específicos durante o início da epidemia de COVID-19 previram com sucesso a presença de depressão e ansiedade em uma grande amostra brasileira usando modelos de aprendizado de máquina desenvolvidos em uma amostra espanhola.

A pesquisa de [30] utilizou a rede social Twitter para coletar de dados e prever depressão e ideias suicidas em usuários árabes, tendo em vista a tendência das pessoas de tratar as redes sociais como seus diários pessoais, compartilhar seus pensamentos mais profundos e obter informações valiosas que podem ser usadas para identificar o estado psicológico dos usuários. Inicialmente, foi criado um o conjunto de dados AraDepSu, coletando tweets do Twitter e rotulando-os manualmente. Posteriormente, ampliou-se a diversidade dos tweets dos usuários, adicionando um rótulo neutro ("neutro"), de modo que o conjunto de dados inclui três classes ("deprimido", "suicida" e "neutro"). Em seguida, foi treinado o conjunto de dados AraDepSu em mais de 30 modelos baseados em Transformer. O resultado mostrou que o modelo com melhor desempenho é o MARBERT, com valores de precisão, precisão média macro, recall médio macro e pontuação F1 média macro de 91,20%, 88,74%, 88,50% e 88,75%, respectivamente.

Já [40] investigou modelos de aprendizado de máquina para prever o risco de depressão em estudantes universitários e identificar fatores familiares e individuais importantes. Identificou-se 171 estudantes universitários e familiares em risco de depressão.

A precisão da previsão de três modelos de aprendizado de máquina, regressão logística esparsa, máquina de vetores de suporte e floresta aleatória, foi comparada. Destes modelos, os três modelos de ML demonstraram excelentes capacidades de previsão. O modelo floresta aleatória apresentou o melhor desempenho. Ele revelou cinco fatores significativos responsáveis pela depressão: autopercepção da saúde mental dos estudantes universitários, neuroticismo, apego com evitação do medo, coesão familiar e depressão da mãe. Além disso, o modelo de regressão logística identificou cinco fatores responsáveis pela depressão: gravidade do câncer no pai, gravidade de doenças respiratórias na mãe, autopercepção da saúde mental dos estudantes universitários, conscienciosidade e neuroticismo.

A pesquisa de [46] desenvolveu modelos de previsão para a depressão entre adultos nos Estados Unidos com hipertensão, utilizando diversas abordagens de aprendizado de máquina. Além disso, foram analisados os mecanismos dos modelos desenvolvidos. Neste estudo foram incluídos 8.628 adultos com hipertensão (11,3% com depressão) provenientes da Pesquisa Nacional de Saúde e Exame Nutricional de 2011 a 2020. Selecionaram-se várias características significativas usando métodos de seleção de recursos para construir os modelos. O desequilíbrio de dados foi gerenciado com subamostragem aleatória. Seis métodos de classificação de ML diferentes foram implementados: rede neural artificial, floresta aleatória, *AdaBoost*, aumento de gradiente estocástico, *XGBoost* e máquina de vetores de suporte. O método de validação cruzada de 10 grupos foram utilizadas para previsões. O desempenho de cada modelo foi avaliado examinando a área sob a curva característica de operação do receptor, acurácia, precisão, sensibilidade, especificidade e pontuação F1. Para um algoritmo interpretável, usou-se a função de avaliação da importância da variável de Caret. De todos os modelos de classificação, a rede neural artificial treinada com características selecionadas ($n = 30$) alcançou o maior operação do receptor (0,813) e especificidade (0,780) na previsão da depressão. A máquina de vetores de suporte previu a depressão com a maior acurácia (0,771), precisão (0,969), sensibilidade (0,774) e pontuação F1-score (0,860). As características mais frequentes e importantes que contribuíram para os modelos incluíram a relação entre a renda familiar e a pobreza, nível de triglicérides, contagem de glóbulos brancos, idade, status de distúrbio do sono, presença de artrite, nível de hemoglobina, estado civil e nível de educação.

Em [49], foram utilizados métodos de aprendizado de máquina para detectar potenciais casos de depressão entre idosos. Foram selecionados 1.538 idosos do Estudo Longitudinal Chinês sobre Longevidade Saudável. Foram usados o modelo de Memória de Longo Prazo de Curto Prazo e seis modelos de aprendizado de máquina para prever diferentes fatores de risco para a depressão e os riscos de depressão na população idosa nos dois anos subsequentes a pesquisa. A curva de operação do receptor e a análise de curva de decisão foram usadas para avaliar a precisão de previsão do modelo de referência e dos

modelos de ML.

Os resultados mostraram valores da área sob a curva de operação do receptor da regressão logística com regularização Lasso (AUC = 0,629, valor $p = 0,020$) foram os mais altos entre os modelos de ML. Os resultados da análise de curva de decisão mostraram que o benefício líquido de seis modelos de ML foi semelhante (limiar: 0,00-0,10), o benefício líquido da regressão Lasso foi o maior (limiar: 0,10-0,17 e 0,22-0,25), e o benefício líquido do DNN foi o maior (limiar: 0,17-0,22 e 0,25-0,40). Em dois modelos de ML, as atividades de vida diária / atividades de vida diária instrumental, autoavaliação da saúde, estado civil, artrite e número de coabitantes foram os preditores mais importantes para idosos com depressão.

O estudo de [4] pesquisou a viabilidade de prever a depressão com base em comportamentos humanos quantificados a partir de conjuntos de dados de smartphones e identificar comportamentos que podem influenciar a depressão. Participaram 629 pessoas, em um estudo longitudinal exploratório com duração média de 22,1 dias, com avaliação de depressão de oito itens do *Patient Health Questionnaire* (PHQ-8) com faixa de 8 a 86 anos e desvio padrão de 17,90. Foram utilizados 22 marcadores de comportamento de regularidade, entropia e desvio padrão dos dados. Procurou-se explorar a relação entre as características comportamentais e a depressão usando correlação e modelos lineares mistos bivariados. Este estudo usou cinco algoritmos de aprendizado de máquina supervisionado com otimização de hiperparâmetros, validação cruzada aninhada e tratamento de dados desequilibrados para prever a depressão.

Dos 629 participantes, de pelo menos 56 países, 69 (10,97%) eram do sexo feminino, 546 (86,8%) eram do sexo masculino e 14 (2,2%) eram não-binários. A distribuição etária dos participantes é a seguinte: 11,6% tinham entre 18 e 24 anos, 32,4% tinham entre 25 e 34 anos, 24,8% tinham entre 35 e 44 anos, 26,4% tinham entre 45 e 64 anos e 4,8% tinham 65 anos ou mais. Das 1.374 avaliações PHQ-8, 1;143 (83,19%) foram classificadas como não deprimidas (pontuação PHQ-8 < 10), enquanto 231 (16,81%) foram classificadas como deprimidas (pontuação $PHQ - 8 \geq 10$), com base no ponto de corte do PHQ-8. Foi encontrada uma correlação de *Pearson* positiva significativa entre a entropia normalizada do status da tela e a depressão ($r=0,14$, $P<0,001$). O modelo linear misto bivariado demonstrou uma correlação intraclasse de 0,7584 e uma associação positiva significativa entre a entropia normalizada do status da tela e a depressão ($b=0,48$, $P=0,03$). Os melhores algoritmos de ML alcançaram as seguintes métricas: precisão, 85,55%-92,51%; *recall*, 92,19%-95,56%; *F1-score*, 88,73%-94,00%; área sob a curva da característica operacional do receptor, 94,69%-99,06%; Cohen k , 86,61%-92,90%; e acurácia, 96,44%-98,14%. A inclusão do grupo etário e do gênero como preditores melhorou o desempenho do ML. As características do status da tela e da conectividade à Internet foram as mais influentes na previsão da depressão.

Ainda no contexto de investigação de previsão de de depressão e ansiedade utilizando

métodos de aprendizagem de máquina, o artigo de [61] apresentou uma nova metodologia de diagnóstico, que testa rigorosamente as diferenças nos vieses cognitivos entre indivíduos ansiosos e deprimidos. Cento e vinte e cinco participantes foram divididos em quatro grupos com base nos níveis de seus sintomas de ansiedade e depressão. Um abrangente conjunto de testes comportamentais detectou e quantificou diversos vieses cognitivo-emocionais. Ferramentas avançadas de aprendizado de máquina, desenvolvidas por este estudo, analisaram esses resultados. Essas ferramentas detectam padrões exclusivos que caracterizam ansiedade versus depressão para prever a filiação a grupos. O modelo de previsão para diferenciar participantes sintomáticos (ou seja, com sintomas elevados de depressão, ansiedade ou ambos) em comparação com o grupo de controle não sintomático revelou uma precisão de previsão de 71,44% para o primeiro (sensibilidade) e 70,78% para o segundo (especificidade). Obteve-se uma precisão de previsão de 68,07% e 74,18% para um modelo de dois grupos com depressão/ansiedade elevada, respectivamente. A análise também revelou quais medidas comportamentais específicas contribuíram para a previsão, apontando para mecanismos cognitivos-chave na ansiedade versus depressão.

Já [60] avaliou o uso de algoritmos de aprendizado de máquina em 412 participantes com suas respectivas estatísticas de uso de seus dispositivos móveis. O Inventário de Depressão de Beck - 2ª edição (do inglês, *Beck Depression Inventory* - BDI-II) foi usado para medir a gravidade da depressão entre os participantes. Uma gama de algoritmos de classificação de aprendizado de máquina foi treinada para detectar participantes com sintomas de depressão (ou seja, pontuação do *BDI - II* ≥ 14). A importância relativa das variáveis individuais também foi quantificada. Verificou-se que os participantes com depressão tinham menos contatos salvos em seus dispositivos, passavam mais tempo em seus dispositivos móveis fazendo e recebendo menos chamadas e enviavam mais mensagens de texto do que os participantes sem depressão. O melhor modelo foi o random forest, que teve uma precisão equilibrada fora da amostra de 0,768. A precisão equilibrada aumentou para 0,811 quando a idade e o gênero dos participantes foram incluídos.

A pesquisa de [48] analisou a relação entre transtorno depressivo maior e biomarcadores microRNAs. Foram aplicados ML supervisionado e não supervisionado aos perfis de expressão de microRNAs no sangue de um conjunto de dados de casos-controles de depressão ($n = 168$) para distinguir entre (1) status de caso vs. controle; (2) níveis de gravidade da depressão definidos com base na Escala de Avaliação da Depressão de Montgomery-Asberg; e (3) respondedores a antidepressivos vs. não respondedores. Os casos de depressão puderam ser distinguíveis dos controles saudáveis com uma área sob a curva da característica operacional do receptor (do inglês, *Area Under the Curve* - AUC) de 0,97 nos dados de teste. Casos de alta gravidade vs. baixa gravidade eram distinguíveis com um AUC de 0,63. A clusterização não supervisionada dos pacientes, antes da análise de ML supervisionada de cada *cluster* para a gravidade de depressão, melhorou o desem-

penho dos classificadores (AUC de 0,70 para o *cluster* 1 e 0,76 para o *cluster* 2). Os respondedores a antidepressivos não puderam ser separados com sucesso dos não respondedores, mesmo após a estratificação de pacientes por clusterização não supervisionada. No entanto, o teste de permutação do principal microRNA, identificado pelo modelo de ML treinado para distinguir respondedores vs. não respondedores em cada um dos 2 *clusters*, mostrou uma associação com a resposta aos antidepressivos. Cada um desses marcadores de microRNA foi significativo apenas ao comparar respondedores vs. não respondedores do *cluster* correspondente, mas não ao usar o conjunto heterogêneo de pacientes não *clusterizados*.

4.2 Arte e aprendizado de máquina

O estudo de [68] propôs o uso de aprendizado de máquina para autenticar as obras de arte de Raffaello Sanzio da Urbino, mais conhecido como Rafael. Foi utilizada a rede neural profunda ResNet50 para extração de características e usou-se um classificador binário de máquina de vetores de suporte para dar suporte à autenticação. Algoritmos de detecção e análise de bordas, considerados cruciais para capturar a essência do estilo artístico de Rafael, incluindo as assinaturas de pinceladas, também foram integrados e são usados como ferramenta de autenticação. Os resultados demonstram uma precisão de 98% em tarefas de classificação baseadas em imagens durante a validação, usando um conjunto de teste de pinturas bem conhecidas e autênticas de Rafael.

No trabalho de [74] utilizou-se de metodologias de aprendizado de máquina para identificar precisamente os diversos elementos dentro de designs de arte gráfica. Essa abordagem propõe um modelo modificado de *Single Shot MultiBox Detector* para refinar o reconhecimento de elementos de design artístico. Aprimorou-se as características do modelo incorporando informações do mecanismo de atenção de longo alcance, aumentando assim a precisão da detecção de alvos. Também foi refinado o modelo de mecanismo de atenção *Feature Pyramid Transformer* para garantir que o mapa de características de saída esteja alinhado de forma eficaz com os requisitos de detecção de objetos. Os achados empíricos demonstram que essa abordagem modificada supera o algoritmo original *Single Shot MultiBox Detector* em todas as quatro métricas de avaliação, exibindo melhorias de 1,52%, 1,89%, 3,09% e 2,57%, respectivamente. Testes qualitativos ilustram ainda a precisão, robustez e universalidade do método proposto, especialmente em cenários caracterizados por elementos artísticos densos e categorias difíceis de distinguir dentro das composições artísticas.

O estudo [44] revisou vários métodos de aprendizado de máquina aplicados na detecção de falsificação de imagens, categorizando-os com base no tipo de falsificação detectada (*move-copy*, *splicing* e *DeepFake*) e sua capacidade de localizar áreas falsificadas. Os resultados dos métodos de aprendizado de máquina superaram os métodos tradi-

cionais em termos de precisão e eficácia na detecção de falsificações. As redes neurais convolucionais e redes adversariais generativas, mostraram-se particularmente eficazes para problemas de classificação, regressão e segmentação. Esses métodos não requerem a criação manual de recursos significativos, pois são capazes de extrair automaticamente características descritivas que capturam aspectos dos dados de entrada adequados para a tarefa em questão.

Os métodos analisados foram capazes de detectar diferentes tipos de falsificações, como *move-copy*, *splicing* e *DeepFakes*, com alta precisão. Além disso, alguns métodos foram capazes de distinguir entre regiões fonte e alvo nas falsificações de *move-copy*, fornecendo uma localização precisa das áreas manipuladas.

4.3 Cores e emoções

Alguns estudos revelam padrões universais de associações de cor e emoção, como o vermelho sendo associado a excitação ou raiva e o azul a tranquilidade. A cor rosa está associada ao amor e ao prazer, o amarelo à alegria e diversão. Por sua vez, o amarelo está associado à alegria e otimismo, enquanto o verde está ligado à natureza e renovação. No entanto, variações culturais influenciam essas associações. O branco pode representar pureza em algumas culturas e ao luto em outras. O vermelho é relacionado a alegria na China e ao medo na Nigéria. Os atributos da cor (matiz, saturação e luminosidade) estão relacionadas às dimensões de emoção (valência, excitação e dominância) [1, 5, 13, 21, 23, 22, 24, 28, 34, 35, 54, 67, 72].

Cores brilhantes e saturadas tendem a evocar emoções positivas e de alta excitação, enquanto cores escuras e menos saturadas são associadas a emoções negativas e de baixa excitação. A preferência por cores pode estar influenciada pelas emoções associadas a elas. A preferência pelo azul tende a associar a sentimentos de calma e segurança. As emoções podem explicar em parte as preferências de cores e as correspondências multimodais de cores, como a associação entre cores e música. O uso estratégico das cores em ambientes, como em decoração e design, pode impactar o bem-estar emocional. Ambientes com cores mais quentes e brilhantes podem melhorar o humor e aumentar a excitação, enquanto cores frias e suaves podem ajudar na redução do estresse e promoção do relaxamento [1, 5, 13, 21, 23, 22, 24, 28, 34, 35, 54, 67, 72].

5 METODOLOGIA

O presente trabalho tem como objetivo a aplicação de técnicas computacionais, em especial o aprendizado de máquina, na análise das obras de Vincent Van Gogh, com o objetivo de identificar possíveis correlações entre características visuais, documentais e os transtornos mentais que o artista enfrentou ao longo de sua vida. Nesse contexto, foram definidos alguns passos para execução.

5.1 Coleta de dados

Foi utilizado um banco de dados contendo **2.026** imagens de obras de Vincent Van Gogh, categorizados de acordo com os seguintes períodos de sua vida [39]:

- **Período em Nuenen (1881-1885);**
- **Período em Paris (1886-1888);**
- **Período em Arles (1888-1889);**
- **Período em Saint-Rémy-Provence (1889-1890);**
- **Período em Auvers-sur-Oise (1890).**

O banco de dados de imagens é composto por 1.024 imagens. Foram selecionadas obras distribuídas entre os cinco períodos da seguinte forma: 86 obras produzidas na cidade de Nuenen; 153 pinturas criadas no período de Paris; 189 obras pertencentes a Arles, 143 obras feitas em Saint-Rémy e, por fim, 79 produzidas na cidade de Auvers-sur-Oise. As imagens possuem tamanhos não uniformes, mas com resoluções compatíveis para realizar as investigações proposta por este trabalho.

O banco de dados das cartas escritas por Van Gogh contém 380 cartas traduzidas para o inglês, distribuídas entre os períodos da seguinte forma: 122 escritas em Nuenen; 45 no período de Paris; 147 pertencentes ao período de Arles; 50 pertencentes ao período de Saint-Rémy; e 16 produzidas na cidade de Auvers-sur-Oise [70].

5.2 Pré-processamento de dados

As imagens foram normalizadas e redimensionadas para um tamanho padrão para garantir uniformidade, facilitando o processamento e análise pelo modelo. Para a análise do padrão de cores, as imagens foram redimensionadas na proporção 200x200 *pixels*. Para a avaliação do padrão de pinceladas e texturas, as imagens foram padronizadas na proporção 600x400 *pixels*.

Em seguida, as imagens foram convertidas para uma escala de cores normalizada, onde os valores dos *pixels* foram ajustados para um intervalo comum (de 0 a 255). A normalização dos valores dos *pixels* ajuda a melhorar a estabilidade e o desempenho dos algoritmos de aprendizado de máquina. Por fim, foram usadas técnicas de equalização de histograma com o intuito de corrigir diferenças na iluminação das imagens, assegurando que todas as pinturas tenham uma distribuição de luminosidade mais uniforme.

As cartas foram filtradas, selecionando-se somente as cartas escritas por Van Gogh, que contabilizam a quantidade anteriormente citada. Na sequência, foram classificadas de acordo com o local de onde foram escritas e selecionadas somente as cartas correspondentes aos cinco períodos propostos por esse trabalho.

5.3 Processamento de dados

Para realizar a análise das obras produzidas por Van Gogh foram extraídas as seguintes características visuais das pinturas:

- **Padrão de cores:** O padrão de cores fornece uma representação da distribuição de cores em uma imagem. Eles permitem a análise da intensidade e variedade de cores usadas por Van Gogh em diferentes períodos, o que pode refletir no estado emocional e mental.
- **Textura:** A análise de textura será utilizada para identificar padrões de repetição e variação na superfície da pintura.
- **Padrões de pinceladas:** A análise dos padrões de pinceladas envolve a detecção de bordas e a segmentação das áreas de pinceladas. Pinceladas violentas e desordenadas podem ser indicativas de momentos de crise emocional, enquanto pinceladas suaves e controladas podem refletir períodos de calma.
- **Composição e estrutura:** A composição e a estrutura de uma pintura incluem a disposição dos elementos dentro da obra, o uso de simetria, equilíbrio e a organização geral. Análises de formas e *layouts* podem revelar como Van Gogh estruturava suas obras em diferentes fases de sua vida, possivelmente refletindo seu estado mental e capacidade de organização cognitiva.

5.4 Construção e validação do modelo de aprendizado de máquina

Inicialmente, para a avaliação do padrão de cores nas obras de Van Gogh, foi utilizado o algoritmo *k-means* para identificar as principais paletas de cores em cada pintura. Os centróides iniciais do algoritmo são definidos pelo método *k-means++* da biblioteca *scikit-learn* da linguagem de programação Python [56] [58]. Na sequência, com base no conjunto de paleta de cores coletadas no padrão RGB, foi aplicado novamente o algoritmo *k-means* para agrupar as cores semelhantes em três *clusters*. Por fim, foi avaliado o padrão de cores RGB, separadamente, de cada período proposto por essa pesquisa.

O estudo das cartas escritas por Van Gogh em busca de indícios que sentimentos de instabilidade emocional foi realizada de duas formas. Na primeira, foi aplicado o algoritmo de processamento de linguagem natural *Transformers* para classificar as cartas em uma escala entre -1 e 1 no qual, -1 corresponde a cartas com alto indício e instabilidade emocional e 1 para cartas com baixo indício. Na sequência, foi realizado uma estudo qualitativo da cartas com o objetivo de validar a análise proposta pela algoritmo de análise de sentimentos.

Os padrões de pinceladas e texturas foram avaliadas através da aplicação da matriz de co-ocorrência em níveis de cinza [69]. Foram extraídas de cada imagem o contraste, dissimilaridade, homogeneidade, energia e correlação. Considerou-se os ângulos 0° , 45° , 90° e 135° entre *pixels*. Os ângulos 0° e 90° representam as direções horizontal e vertical de pinceladas, respectivamente. Já os ângulos 45° e 135° se referem as pinceladas diagonais.

Para o estudo da composição e estrutura será utilizado o algoritmo de redes neurais convolucionais. Uma rede neural foi treinada com a base de dados usada nesse trabalho. Os dados foram divididos em conjuntos de treinamento e teste, utilizando uma proporção como 70% para treinamento e 30% para teste. Para avaliar o desempenho do modelo foram consideradas as métricas de acurácia, precisão, *recall*, *F1-score* e matriz de confusão. Por fim, a validação cruzada foi implementada para assegurar a robustez e a capacidade de generalização do modelo. Foram propostos 4 (quatro) experimentos variando alguns hiperparâmetros com a finalidade de otimizar o modelo treinado. A definição dos hiperparâmetros de cada experimento foi:

1. Experimento 1:

- **Configuração:**

- Taxa de aprendizado = 0.0001
- Regularização L2 = 0.001
- Taxa de *dropout* = 0.5

- **Justificativa:** Estabelece um ponto de referência com valores comumente utilizados para esses hiperparâmetros. A taxa de aprendizado moderada visa um

aprendizado estável, a regularização L2 busca prevenir *overfitting* e o *dropout* de 0.5 é um valor padrão frequentemente usado.

2. Experimento 2 (Taxa de Aprendizado Aumentada):

- **Configuração:**

- Taxa de aprendizado = 0.001 (10x maior que a linha de base)
- Regularização L2 = 0.001
- Taxa de *dropout* = 0.5

- **Justificativa:** Avalia o efeito de uma taxa de aprendizado mais alta. Espera-se um aprendizado potencialmente mais rápido, mas com maior risco de instabilidade e divergência. Este experimento testa a sensibilidade do modelo a este hiperparâmetro.

3. Experimento 3 (Sem Regularização L2):

- **Configuração:**

- Taxa de aprendizado = 0.0001
- Regularização L2 = 0.0 (removida)
- Taxa de *dropout* = 0.5

- **Justificativa:** Investiga o impacto da regularização L2. A ausência da penalidade sobre os pesos permite que o modelo se ajuste mais livremente aos dados de treinamento. Espera-se um melhor ajuste aos dados de treino, mas com um risco potencialmente maior de *overfitting*.

4. Experimento 4 (Dropout Reduzido):

- **Configuração:**

- Taxa de aprendizado = 0.0001
- Regularização L2 = 0.001
- Taxa de *dropout* = 0.2

- **Justificativa:** Testa o efeito de um *dropout* menor. Um *dropout* menor significa que mais neurônios permanecem ativos durante o treinamento. Isso pode permitir que o modelo aprenda representações mais complexas, mas também pode aumentar a susceptibilidade ao *overfitting*.

5.5 Análise dos resultados

Os resultados obtidos pelos modelos foram analisados, identificando padrões e características que possam estar associadas a possíveis transtornos mentais em cada período da vida de Van Gogh. As etapas do estudo foram aplicadas considerando todas as obras presentes na base de dados, bem como dividindo em períodos da vida do pintor conforme proposto nessa metodologia.

Os resultados de cada um período foram comparados com as demais períodos, bem como o conjunto total de imagens. Técnicas de visualização de dados foram utilizadas para interpretar e visualizar as características extraídas do modelo aplicado. Na sequência, os resultados foram relacionados com eventos conhecidos da vida de Van Gogh e possíveis estados mentais documentados. Também foi incluída uma análise do contexto histórico e pessoal de Van Gogh durante cada período.

6 RESULTADOS

Inicialmente, foi realizado o estudo do padrão de cores utilizado nas obras de Van Gogh considerando 685 imagens da base de dados, englobando todos os períodos de vida do pintor. Nesse contexto, foi usado o algoritmo *k-means* definido com três *clusters* para avaliar a predominância da paleta de cor em cada imagem. No total, foram coletados as cinco cores mais usadas em cada obra no formato RGB.

A Figura 3 mostra os resultados considerando a primeira cor predominante. As imagens foram agrupadas de acordo com a intensidades das cores vermelho, verde e azul. O eixo X representa a intensidade do vermelho, o eixo Y representa a intensidade do verde e o eixo Z representa a intensidade do azul.

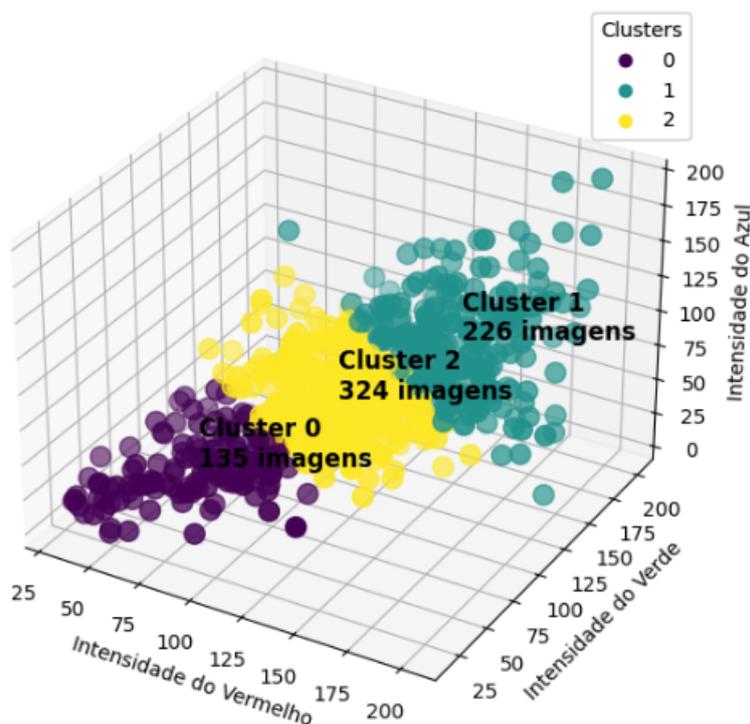


Figura 3: Dispersão do sistema RGB nas obras de Van Gogh utilizando o algoritmo *k-means*

Os dados foram distribuídos da seguinte forma: o *cluster 0*, com pontos roxo, possui

135 imagens; o *cluster 1*, com pontos verdes, contém 226 imagens; e, por fim, o *cluster 2*, com pontos amarelo, apresenta 324 imagens.

Observou-se que o *cluster 0* tem menor intensidade média de verde e azul, sugerindo, dessa forma, uma predominância de cores com tons mais quentes, compostos por vermelho e amarelo. Já o *cluster 1*, apesar de apresentar maior dispersão, mostra média mais alta na intensidade verde e azul sugerindo uma predominância de tons mais frios. Por fim, o *cluster 2* mostrou com imagens mais concentradas no que diz respeito a intensidade média do padrão RGB, permitindo inferir a presença de uma mistura mais equilibrada das cores.

Na Figura 4 são apresentados os histogramas de cada *cluster*. Para o *cluster 0*, os resultados mostraram que, em (a), as intensidades de vermelho variam principalmente entre 20 e 120. Há uma concentração significativa de intensidades ao redor de 60 a 80, indicando que essas intensidades são predominantes nas imagens pertencentes a esse grupo. Existem dois picos menores espalhados próximo a 120, sugerindo variação nas tonalidades de vermelho usadas nas imagens.

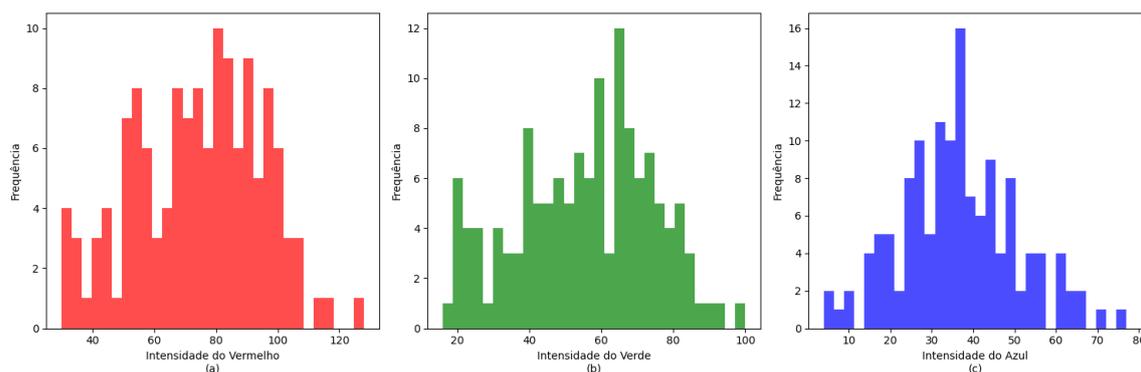


Figura 4: Distribuição das intensidades de cor nos canais vermelho, verde e azul para o *Cluster 0* - Intensidade de vermelho

Em (b) as intensidades de verde variam entre 10 e 100. A distribuição é relativamente uniforme com alguns picos, ao redor de 60. Tal achado permite inferir que a intensidade do verde é utilizada de maneira variada, mas com uma tendência em torno de intensidades médias. Para finalizar, em (c), o histograma de azul mostra uma variação de intensidades entre 10 e 80. Há uma concentração de intensidades entre 30 e 50, com um pico significativo próximo a 40. Isso indica uma predominância de tons de azul médio nas imagens no *cluster 0*.

A Figura 5 mostra os histogramas resultantes do *cluster 1*. Em (a), as intensidades de vermelho variam principalmente entre 80 e 200. Observou-se uma concentração significativa de intensidades ao redor de 140 a 170. Há um picos menor próximo a 80, sugerindo variação nas tonalidades de vermelho usadas nas imagens. Em (b), as intensidades de verde concentraram entre 120 e 200. A distribuição é relativamente uniforme com algumas variações expressivas, especialmente ao redor de 140 a 160. Isso sugere que

a intensidade do verde possui uma tendência em torno de intensidades médias. O histograma de azul, em (c), mostra uma variação de intensidades entre 25 e 200, sugerindo uma amplitude grande no uso da intensidade do azul. Há uma concentração de intensidades entre 75 e 125, com um pico significativo próximo a 100, indicando uma predominância de tons de azul médio.

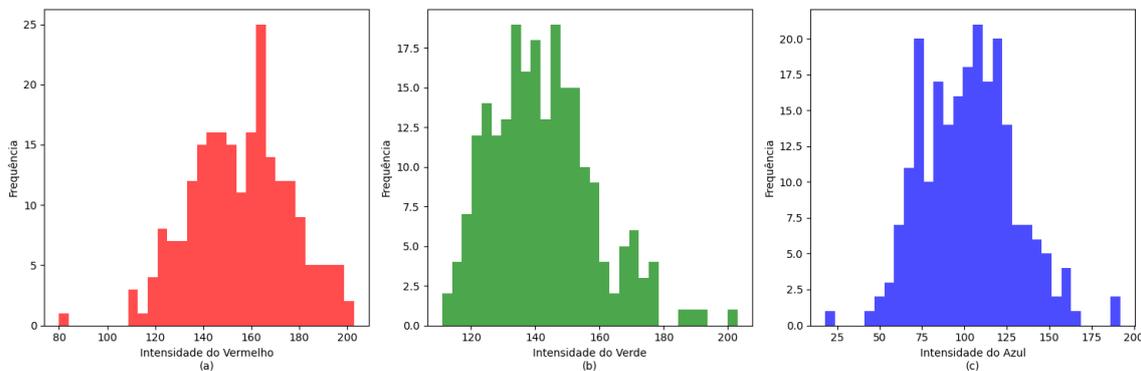


Figura 5: Distribuição das intensidades de cor nos canais vermelho, verde e azul para o *Cluster 1* - Intensidade de Verde.

A Figura 6 apresenta os resultados do *cluster 2*. De maneira geral, houve grande amplitude no uso das componentes de cores na escala RGB. O histograma da intensidade de vermelho, em (a), mostra que as intensidades de vermelho variaram principalmente entre 60 e 160. Há uma concentração significativa de intensidades ao redor de 100 a 120. Existe um pequeno pico, indicando variação nas tonalidades de vermelho usadas nas imagens.

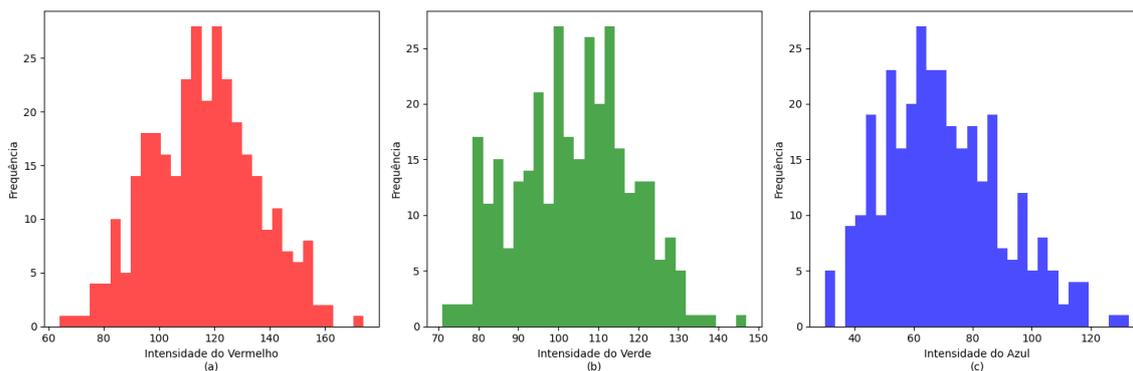


Figura 6: Distribuição das intensidades de cor nos canais vermelho, verde e azul para o *Cluster 1* - Intensidade de azul.

Em (b), no histograma da intensidade do verde, este variou entre 70 e 140. Ocorreu uma distribuição relativamente uniforme com alguns picos, especialmente ao redor de 100 a 120. Tais resultados permite inferir que a intensidade do verde foi utilizada de maneira variada, mas com uma tendência em torno de intensidades médias. Por fim, em (c), o histograma de azul mostra uma variação de intensidades entre 40 e 120. Há uma

concentração de intensidades médias entre 60 e 100, com um pico significativo próximo a 80.

A Figura 7 apresenta a análise das obras de Van Gogh produzidas da cidade de Nuenen. No geral, percebe-se o grande predomínio de intensidades mais baixas entre 0 e 100 em todas os canais de cores investigados. Percebe-se também que as três componentes apresentam poucos pontos na zona de intensidade mais clara próximas a 255. Essas características permitem inferir que o uso de tons mais escuros e quentes sugerindo uma sensação de energia, vibração e calor. A utilização de tonalidades baixas no azul pode criar contraste, gerando profundidade na imagem e realçando áreas de sombra.

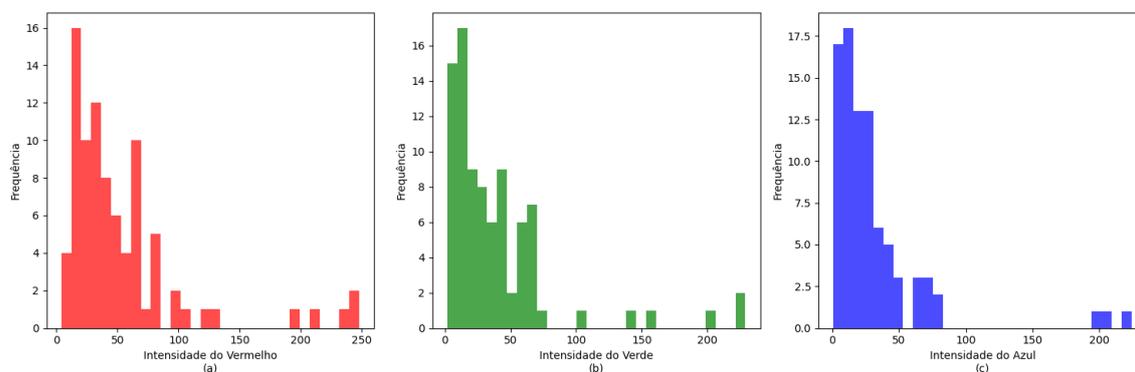


Figura 7: Distribuição das intensidades de cor nos canais vermelho, verde e azul nas obras de Van Gogh produzidas em Nuenen

A Figura 8 avalia a produção de Van Gogh na cidade de Paris. Mantém-se um cenário semelhante a produção de Nuenen no qual há predomínio de tons mais escuros com picos variando entre 0 e 50 nas três intensidades de cores analisadas. Nesse contexto geral, destaca-se ainda a presença de poucos pontos a tons claros próximos a 255. Os picos em baixas intensidades nos histogramas do vermelho e do verde sugerem que a imagem pode ser predominantemente composta por tons escuros, criando possivelmente uma atmosfera mais sombria, misteriosa ou noturna.

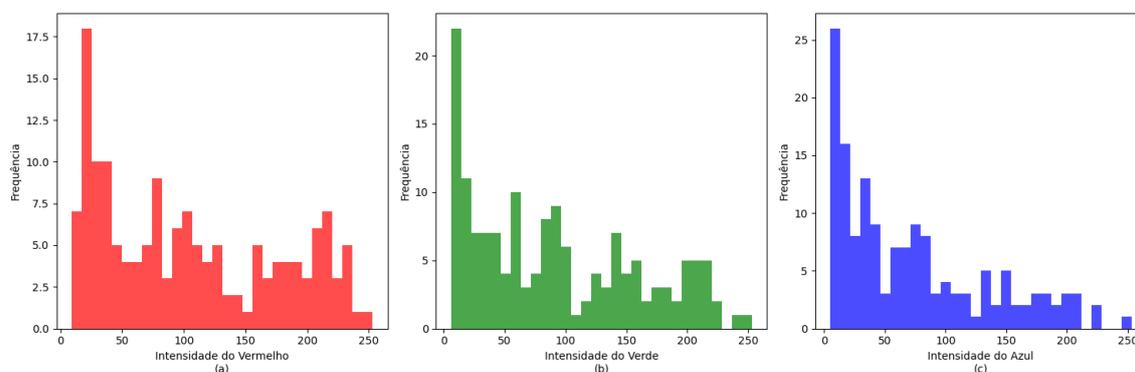


Figura 8: Distribuição das intensidades de cor nos canais vermelho, verde e azul nas obras de Van Gogh produzidas em Paris

A Figura 9 mostra o cenário das obras produzidas na cidade de Arles. No gráfico (a) observa-se um predomínio de tons claros da intensidade de vermelhos. A intensidade de verde, no gráfico (b) apresenta distribuição mais uniforme com picos em torno de tons médios. Por outro lado, no gráfico (c), a intensidade de azul concentra-se mais em uma zona de tons mais escuros. Tal cenário sugere que as imagens possam ter um contraste acentuado com áreas bem definidas.

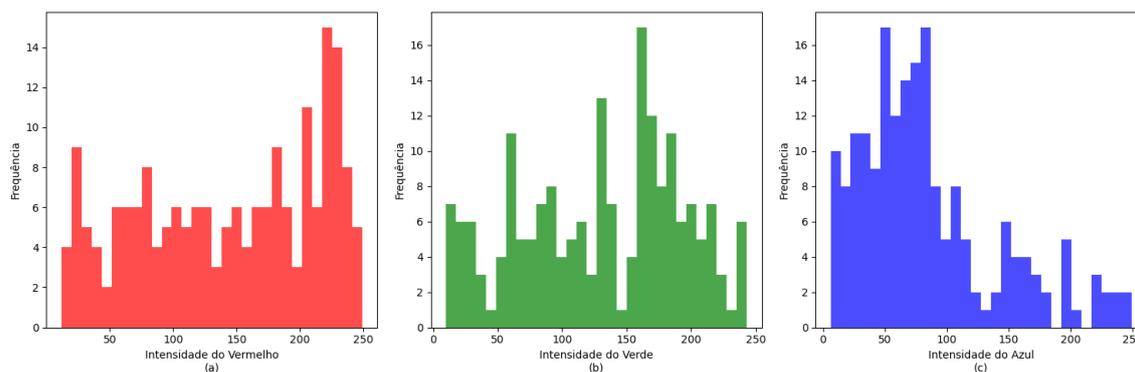


Figura 9: Distribuição das intensidades de cor nos canais vermelho, verde e azul nas obras de Van Gogh produzidas em Arles

A Figura 10 explicita o cenário das obras feitas na cidade de Saint-Rémy. No gráfico (a) observa-se uma distribuição mais uniforme da intensidade de vermelho com picos próximos a tons médios a 100. A intensidade de verde, no gráfico (b), apresenta distribuição semelhante ao vermelho com picos compreendidos entre 0 e 100. Por fim, no gráfico (c), a intensidade de azul concentra-se mais em uma zona de tons mais escuros. Esses resultados sugere que as imagens podem ter uma predominância de tons quentes. A presença de picos em altas intensidades de vermelho e a concentração de em baixas intensidades de azul apontam para um bom contraste na imagem, com áreas claras e escuras bem definidas.

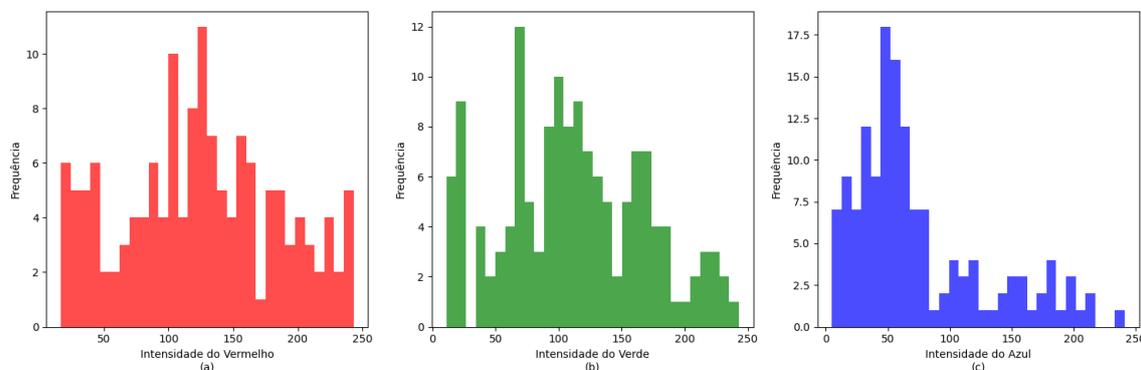


Figura 10: Distribuição das intensidades de cor nos canais vermelho, verde e azul nas obras de Van Gogh produzidas em Saint-Rémy-de-Provence

A Figura 11 representa o cenário das obras feitas na cidade de Auvers-sur-Oise. No

gráfico (a) observa-se uma comportamento mais uniforme da intensidade de vermelho com picos distribuídos ao longo da escala de cinza. No gráfico (b), a intensidade de verde possui picos próximos a 100. Para finalizar, no gráfico (c), a intensidade de azul concentra-se mais em uma zona de tons mais escuros. Esses dados sinalizam a tendência de as obras investigadas nesse período possuir tons mais vermelhos e verdes e baixa concentração da intensidade azul.

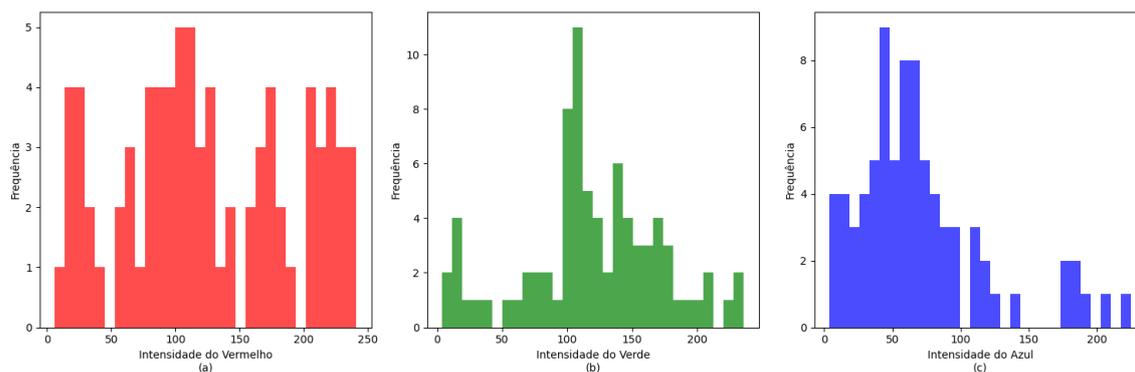


Figura 11: Distribuição das intensidades de cor nos canais vermelho, verde e azul nas obras de Van Gogh produzidas em Auvers-sur-Oise

A Figura 12 mostra a distribuição de cores englobando as obras de todos os períodos. De maneira geral, há predomínio de tonalidades mais claras que na produção de Van Gogh com base nas componentes analisadas. O gráfico traz os resultados do canal vermelho. Observa-se um pico localizado na faixa de intensidade alta, compreendido entre 200 e 250, sugerindo o uso frequente de vermelhos vibrantes e luminosos. Na sequência, uma concentração de intensidade média entre 100 e 150. Por fim, ocorre uma baixa nas intensidades compreendidas entre 0 e 50, evidenciando a pouca utilização de vermelhos escuros ou próximos ao preto.

No gráfico (b), é possível analisar as tonalidades da componente verde. Observa-se maior concentração de pontos entre 150 e 250 nas tonalidades mais claras. O intervalo entre 0 e 150 possui comportamento mais uniforme com leves picos próximo a 0 e 50. No entanto, de modo geral, há uma preferência de Van Gogh pelo uso de tons de verdes mais claros.

Por fim, o gráfico (c) explicita a distribuição da tonalidade azul. Observa-se dois picos mais acentuados entre 0 a 100, correspondendo a tonalidades mais escuras e entre 150 a 255 referindo-se a tons mais claros. Há uma leve vale entre 100 e 150 relacionado a intensidades médias. Com base nas três componentes é possível inferir que Van Gogh tinha preferência por cores mais claras nas tonalidades vermelha, verde e amarela.

A Figura 13 representa a paleta de cores dominantes de cada obra de Van Gogh analisada nesse estudo, segmentadas pelas cidades. É possível observar diferenças notáveis que corroboram, em grande medida, as mudanças de estilo do pintor ao longo de sua

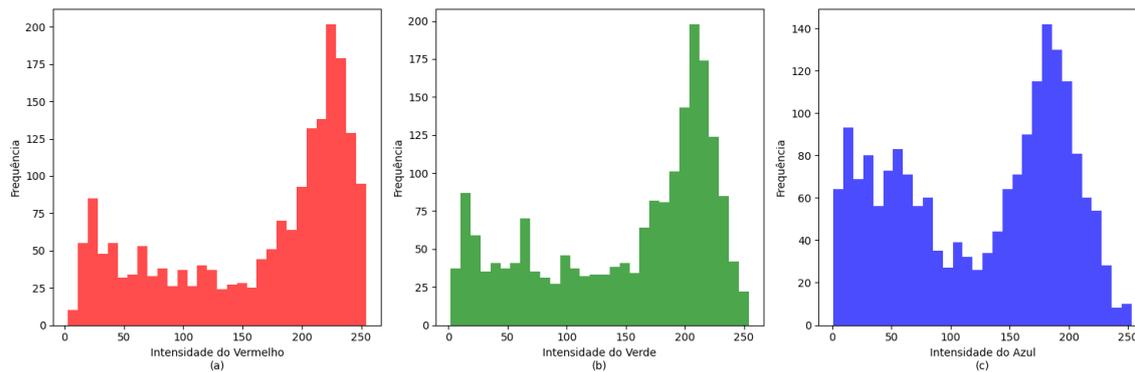


Figura 12: Distribuição das intensidades de cor nos canais vermelho, verde e azul de todas as obras de Van Gogh

trajetória artística.

A paleta de Nuenen, representando seu período inicial na Holanda, é caracterizada por uma predominância marcante de tons escuros e terrosos. Observa-se uma abundância de marrons, cinzas, pretos e verdes escuros, cores que refletem a temática central desse período: a vida camponesa e as paisagens rurais holandesas, retratadas com um realismo sombrio. A quase ausência de cores vivas e a presença de tons escuros criam uma atmosfera melancólica e austera, típica das primeiras obras do artista.

Em contraste, a paleta de Paris apresenta uma diversidade significativamente maior. Embora os tons escuros ainda estejam presentes, possivelmente representando uma transição gradual, surgem cores mais vibrantes, como azuis, vermelhos e amarelos, ainda que em tons mais fechados quando comparados a fases posteriores. Essa mudança reflete a influência do Impressionismo e do Pós-Impressionismo que Van Gogh encontrou na capital francesa, um período de experimentação e descoberta de novas técnicas e abordagens cromáticas.

Arles marca uma transformação radical na paleta de Van Gogh. A visualização demonstra um predomínio absoluto de cores quentes e intensas, com destaque para amarelos e laranjas vibrantes. Essa explosão de cores solares é diretamente relacionada à luz e à paisagem do sul da França, que fascinaram o artista. Azuis e verdes também aparecem, mas em menor proporção, complementando a paleta dominada pela luminosidade.

O período em Saint-Remy, marcado pela internação de Van Gogh em um asilo, revela uma paleta onde azuis e verdes ganham maior destaque em relação a Arles. Os amarelos, embora presentes, perdem a intensidade anterior, e tons de roxo e branco surgem, adicionando uma nova dimensão à sua paleta. Essa mudança pode ser interpretada como um reflexo tanto das paisagens da região de Saint-Remy, com seus campos de trigo e ciprestes, quanto do estado emocional conturbado do artista durante esse período.

Finalmente, Auvers-sur-Oise apresenta uma paleta que parece sintetizar elementos dos períodos anteriores. Os verdes e azuis mantêm uma presença forte, mas os amarelos

e laranjas retornam, embora de forma menos intensa do que em Arles. A paleta é, de modo geral, mais clara e suave do que a de Nuenen, mas menos explosiva do que a de Arles, sugerindo um retorno a uma certa serenidade, mas com a incorporação das lições cromáticas aprendidas ao longo de sua jornada.

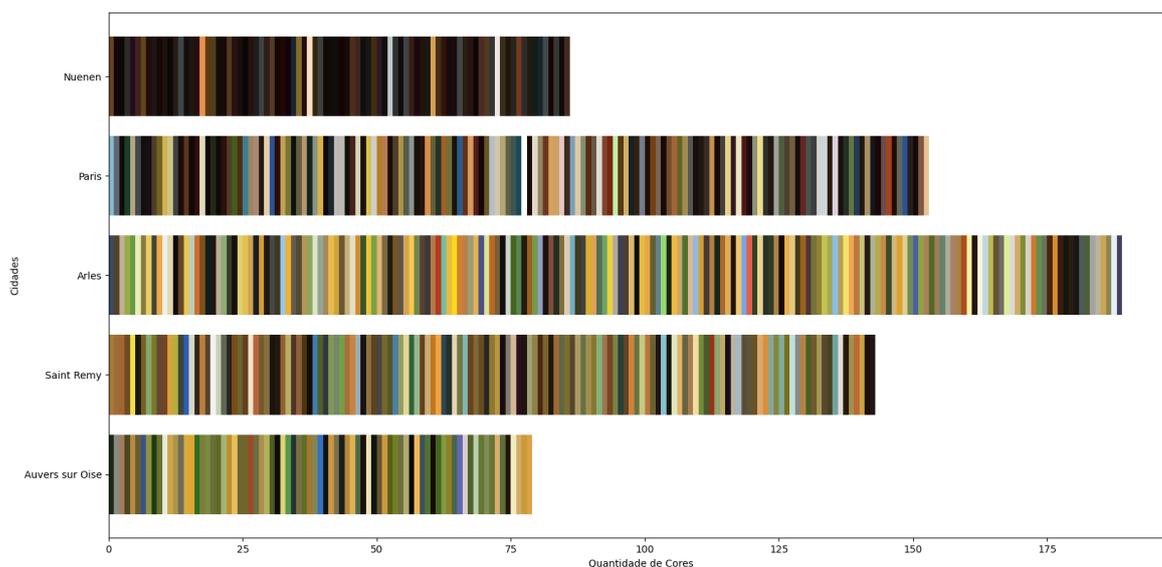


Figura 13: Paletas de cores dominantes das obras de Van Gogh, segmentadas por cidade de produção: Nuenen, Paris, Arles, Saint-Rémy-de-Provence e Auvers-sur-Oise.

6.1 Análise de textura e padrões de pinceladas nas obras de Van Gogh

A análise de textura e padrões de pinceladas foi realizada utilizando o algoritmo GLCM, extraindo as características contraste, dissimilaridade, homogeneidade, energia, correlação e ASM e considerando os ângulos 0° , 45° , 90° e 135° entre *pixels*. Os ângulos 0° e 90° representam as direções horizontal e vertical, respectivamente. Já os ângulos 45° e 135° se referem as diagonais. Todos os resultados são mostrados em gráficos de Função de Distribuição Cumulativa (do inglês, *Cumulative Flow Diagram - CDF*), onde o eixo y representa a probabilidade cumulativa da característica analisada nas obras de Van Gogh. O eixo x faz referência aos valores encontrados na investigação de cada característica.

A Figura 14 mostra os resultados da aplicação da técnica nas obras de Van Gogh produzido na cidade de Nuenen. Em (a) estão os achados do contraste. No geral, a variação do contraste se situa nos valores em torno de 250 a 1750, resultando num contraste relativamente alto. Isso sugere diferenças significativas de intensidade entre *pixels* vizinhos

nessas obras. O ângulo 45° possui contraste ligeiramente abaixo das demais curvas em até 90% das obras. A curva de 135° apresenta valores muito semelhantes ao ângulo 45° . Isso sugere que os valores de contraste tendem a ser maiores nessa direção. O ângulo 0° apresenta menor contraste em torno de 90% das imagens investigadas. Isso indica menor contraste no sentido horizontal. O ângulo de 90° se situa entre os demais ângulos em que o contraste se situa entre 250 e 500 em 90% das pinturas.

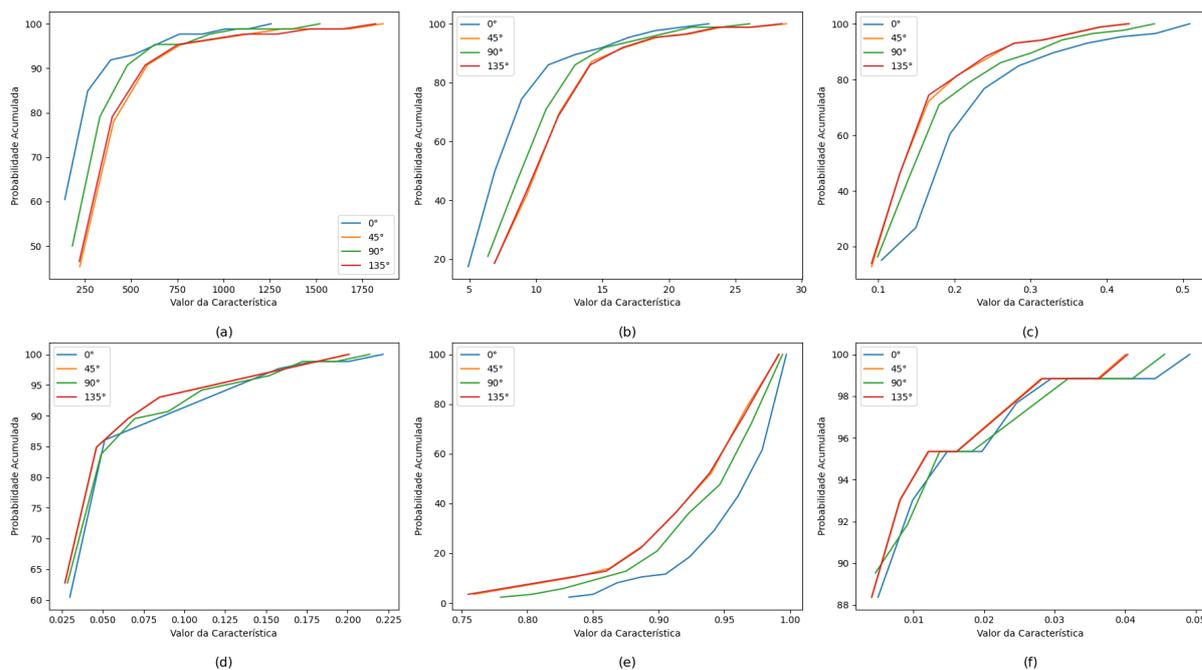


Figura 14: Funções de Distribuição Cumulativa das características de textura (a) Contraste, (b) Dissimilaridade, (c) Homogeneidade, (d) Energia, (e) Correlação e (f) ASM, obtidas pela análise GLCM das obras de Van Gogh produzidas em Nuenen, em função da probabilidade acumulada, para os ângulos 0° , 45° , 90° e 135° .

Em (b) estão representados os valores de dissimilaridade. As curvas atingem 50% de probabilidade acumulada em torno de 5-10, e 100% próximo a 25-30, indicando valores moderados de dissimilaridade. Isso sugere variações locais de intensidade, mas não tão extremas quanto o indicado pelo contraste. O ângulo de 0° mostra resultados de dissimilaridade mais baixo em aproximadamente 90% dos casos. Os valores de 45° e 135° são os mesmos em praticamente todos os casos. Por fim, o ângulo de 90° se encontra entre as demais curvas no qual a dissimilaridade varia entre 5 e 25. Os dados de similaridade reforça a interpretação do contraste, com maior variação local de intensidade na direção de 45° , provavelmente devido a pinceladas ou elementos diagonais.

A análise da homogeneidade, em (c), situa-se entre 0,1 e 0,2, em torno de 50% das curvas, e, no máximo 0,5, na totalidade dos casos. Tal achado sugere que as imagens geralmente não são muito homogêneas, o que é esperado em pinturas com pinceladas visíveis e variações de textura. Diferentemente do contraste e dissimilaridade, as curvas de 45° e 135° estão acima das outras, apresentando resultados muito próximos. Isso sugere

que os valores de homogeneidade tendem a ser menores nessas direções. A curva de 90° concentra-se entre as demais curvas no qual, em até 90% dos casos, mostra resultados acima de 0,3. No geral, as pinturas apresentam menor homogeneidade nas direções de 45° e 135°, o que é consistente com os resultados de contraste e dissimilaridade. As outras direções apresentam um comportamento mais misto, com variações menos previsíveis.

Em (d) estão os resultados da característica energia. Em torno de 90% dos casos, em todas as curvas, a energia concentra-se entre 0,05 e 0,1 e 100% próximo a 0,2. A baixa energia, em geral, indica a ausência de padrões fortemente repetitivos. A proximidade das curvas sugere que essa falta de uniformidade é relativamente consistente em todas as direções, embora com uma ligeira tendência a menor energia nas diagonais, isto é, menor energia nos ângulos de 45° e 135°.

A correlação em (e) mostra curvas, em 50% das obras, em torno de 0,9 e 100% próximo a 1,0. Isso indica uma forte correlação linear entre os *pixels* nas pinturas analisadas. As curvas de 45° e 135° estão acima das outras, indicando valores de correlação mais baixos nessas direções com uma amplitude entre 0,75 e 1. A curva em 0° apresenta os valores mais altos em todos os casos observados, variando entre 0,83 e 1. Por fim, o ângulo de 90° está presente entre as demais curvas, variando entre 0,75 e 1. Embora a textura visível e as variações de intensidade, há uma forte correlação linear entre *pixels* vizinhos, o que pode estar relacionado com o tipo da pincelada com tendência a seguir os contornos dos objetos e a criar transições graduais de tons. A maior correlação em 0° sugere uma estrutura mais linear nessa direção.

Para finalizar, em (f), o momento angular segundo, ASM, apresentam números praticamente iguais nas direções 45° e 135°, variando entre 0 e 0,04. As curvas dos ângulos 0° e 90° se intercalam ao longo da análise com resultados maiores, se comparado as demais direções. Em 100%, o valor máximo ASM gira em torno de 0,05. Tais achados reforçam a investigação de energia, com baixa uniformidade geral.

A Figura 15 representa os resultados encontrados na análise das obras produzidas em Paris. Em relação ao contraste, em (a), comparado com o gráfico de Nuenen, os valores de contraste em Paris são mais altos. As curvas atinge, em 50% dos casos, em torno de 500 nos ângulos 45° e 135° e abaixo de 500 na curvas 0° e 90°. O valor máximo encontrado gira em torno de 3000. Isso sugere que as pinturas de Paris apresentam, em geral, diferenças de intensidade mais acentuadas entre *pixels* vizinhos. A curva de 0° na horizontal está quase sempre acima das outras. Isso sugere uma tendência a valores de contraste mais baixos na direção horizontal. Por sua vez, as curvas de 45° e 135°, na diagonal, estão abaixo das curvas de 0° e 90°, indicando uma concentração de valores de contraste mais altos nessas direções. As pinturas de Paris provavelmente apresentam pinceladas ou elementos com variações de intensidade mais acentuadas nas diagonais.

Na sequência, em (b), os valores de dissimilaridade também são mais altos quando comparados aos obras de Nuenen. Em 50% das obras selecionadas, as curvas 45°, 90° e

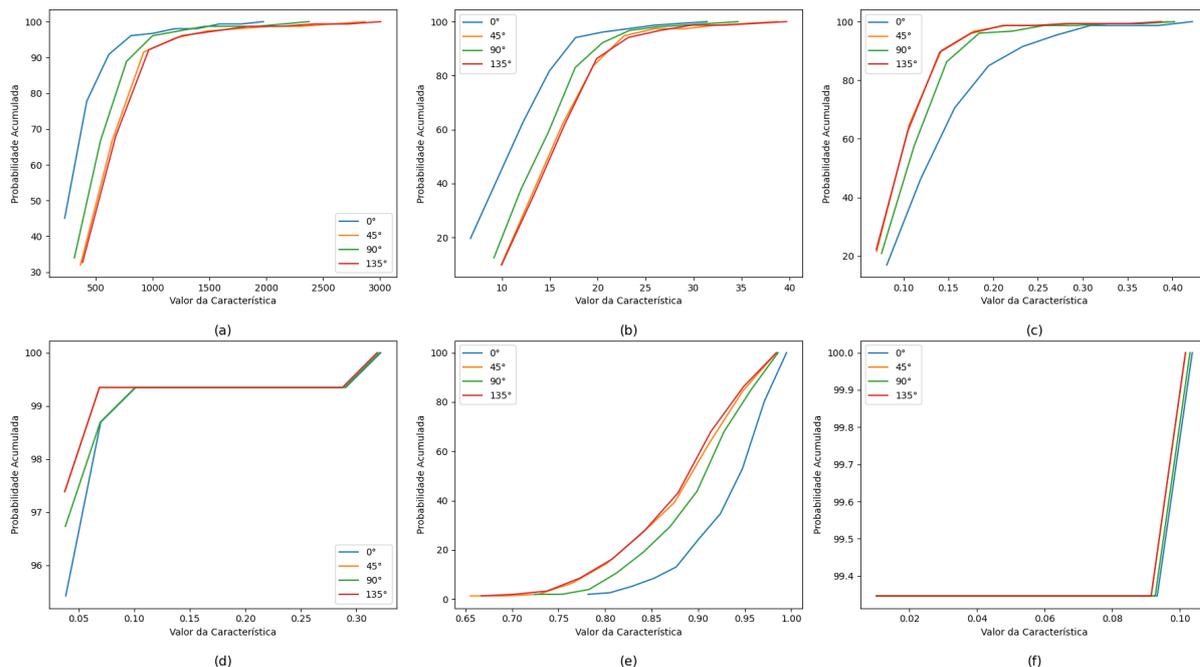


Figura 15: Funções de Distribuição Cumulativa das características de textura (a) Contraste, (b) Dissimilaridade, (c) Homogeneidade, (d) Energia, (e) Correlação e (f) ASM, obtidas pela análise GLCM das obras de Van Gogh produzidas em Paris, em função da probabilidade acumulada, para os ângulos 0° , 45° , 90° e 135° .

135° situam-se entre 10 e 15. O ângulo 0° apresenta menores valores nesse percentual. Em 100% dos casos, a dissimilaridade máxima gira entre 30 e 40. Essa indicação permite inferir variações locais de intensidade mais acentuadas nas pinturas de Paris. No geral, a curva 0° permanece acima das demais, indicando valores de dissimilaridade mais baixos na direção horizontal. Os demais ângulos estão relativamente próximos, sugerindo valores de dissimilaridade semelhantes. Em outras palavras, observa-se menor variação de intensidade na direção horizontal, provavelmente devido a pinceladas ou elementos horizontais mais marcantes. As outras direções apresentam variações mais uniformes entre si.

Os valores da homogeneidade em Paris são ligeiramente mais baixos dos valores encontrados em Nuenen. Os resultados são apresentados em (c). Em termos gerais, considerando 50% das imagens relacionadas, os resultados encontrados estão próximos a 0,1 nos ângulos 45° , 90° e 135° . Em 100% dos dados, o índice máximo encontrado está próximo de 0,4 em todas as direções. A curva de 0° está abaixo das outras, indicando que para um dado valor de homogeneidade, a probabilidade acumulada é maior em 0° . Isso sugere que os valores de homogeneidade tendem a ser maiores na direção horizontal. As demais curvas se cruzam e apresentam um comportamento misto, dificultando uma interpretação clara.

A energia representada em (d) é perceptivelmente mais alta em Paris do que nas obras de Nuenen. As curvas para os quatro ângulos estão muito próximas umas das outras,

com a curva de 0° ligeiramente abaixo das demais em parte do gráfico. A proximidade das curvas sugere que essa falta de uniformidade é relativamente consistente em todas as direções, embora com uma ligeira tendência a maior energia na direção horizontal.

A correlação é percebida com índices altos, mas um pouco mais baixa que as pinturas de Nuenen. Os resultados estão sinalizados em (e). Considerando 50% da amostra, os resultados apontam para números entre 0,85 e 0,95 em todas as direções. Por outro lado, em 100%, o valor máximo gira em torno de 1. Dessa forma, observa-se forte correlação linear entre *pixels* vizinhos, mas um pouco menor do que a observada em Nuenen. O ângulo 0° é acentuadamente mais alto do que as outras curvas com valores compreendidos entre 0,75 e 1. As demais direções mostram um comportamento misto. Mantém-se uma forte correlação linear entre *pixels* vizinhos, o que sugere uma tendência a seguir os contornos dos objetos e a criar transições graduais de tons. A maior correlação na direção horizontal pode estar relacionada a uma maior frequência de pinceladas horizontais ou à composição das obras desse período.

Para finalizar, o ASM, no gráfico (f), traz valores baixos, mas um pouco mais altos do que Nuenen. No geral, todas as curvas possuem comportamentos muito parecidos com resultados entre 0,08 e 0,1. Apesar dessas características, é possível observar o ângulo 0° ligeiramente abaixo das outras índices. Esses achados estão de acordo com a energia, apresentando baixa uniformidade geral e uma ligeira tendência a maior uniformidade na direção horizontal.

A Figura 16 representa os resultados encontrados nas obras produzidas na cidade de Arles. Os números de contraste em Arles são altos (conforme (a)), semelhantes aos observados em Paris e mais altos que em Nuenen. A curva atinge 50% dos *pixels* entre 250 e 750, considerando todas as curvas. Já em até 100% dos casos, os valores encontrados ficam compreendidos entre 2000 e 3500. Isso sugere que as pinturas de Arles continuam a apresentar diferenças significativas de intensidade entre *pixels* vizinhos. As curvas de 0° na horizontal e 90° na vertical estão acima das curvas de 45° e 135° nas diagonais, indicando um menor índice de contraste nessas direções. As curvas das diagonais, do ângulo 45° e 135° , estão relativamente próximas, indicando valores de contraste semelhantes entre essas direções. Isso sugere uma tendência a valores de contraste mais altos nas direções diagonais.

No estudo da dissimilaridade em Arles (b), observa-se resultados altos, semelhantes aos de Paris e mais altos que em Nuenen. Os ângulos atinge 50% dos *pixels* no intervalo de 10 a 20 e 100% no intervalo entre 35 a 40. Novamente, as curvas de 0° e 90° estão acima das curvas de 45° e 135° , sugerindo valores de dissimilaridade mais baixos nas direções horizontais e verticais. Por sua vez, as curvas das diagonais estão próximas, sugerindo valores de dissimilaridade semelhantes entre essas direções. Tais características reforçam a interpretação do contraste, com maior variação local de intensidade nas diagonais.

No que diz respeito a homogeneidade, mostrados em (c), os valores de homoge-

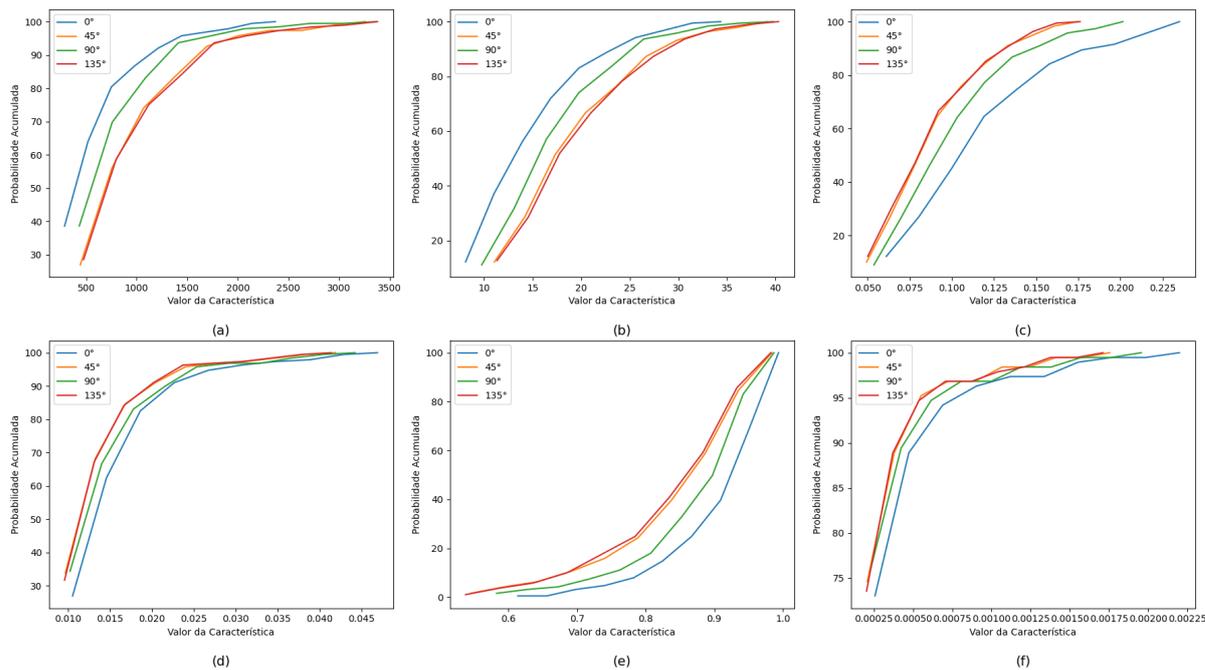


Figura 16: Funções de Distribuição Cumulativa das características de textura (a) Contraste, (b) Dissimilaridade, (c) Homogeneidade, (d) Energia, (e) Correlação e (f) ASM, obtidas pela análise GLCM das obras de Van Gogh produzidas em Arles, em função da probabilidade acumulada, para os ângulos 0° , 45° , 90° e 135° .

neidade em Arles são baixos, semelhantes aos de Paris e mais baixos que em Nuenen. Encontra-se uma variação entre 0,075 e 0,1 em até 50% dos *pixels* avaliados. Já em relação a até 100%, os valores giram em torno do intervalo entre 0,175 e 0,225. As curvas de 0° e 90° estão abaixo das curvas de 45° e 135° . Isso sugere que os valores de homogeneidade tendem a ser maiores nas direções horizontais e verticais. Os ângulos correspondentes as diagonais estão relativamente próximos.

Em relação a energia, em (d), os resultados obtidos são baixos, próximos as obras de Paris e Nuenen, permitindo supor o uso de texturas pouco uniformes e não repetitivas. A curva atinge até 50% de probabilidade acumulada entre 0,01 e 0,02 e 100% em torno de 0,045. Os ângulos de 0° e 90° estão abaixo das curvas de 45° e 135° , indicando uma tendência a valores de energia mais altos nessas direções. Por outro lado, as curvas das diagonais, 45° e 135° , apresentam comportamento muito parecido.

A correlação está representada no gráfico (e), apresentando resultados altos, semelhantes a Paris e Nuenen. As curvas atingem, em 50% dos *pixels* avaliados, a probabilidade acumulada em torno de 0,85 e 0,90 e 100% próximo a 1.0. Isso indica uma forte correlação linear entre *pixels* vizinhos. As análises verticais e horizontais do ângulo 0° e 90° estão abaixo das curvas diagonais de 45° e 135° , indicando uma correlação mais altas nas direções horizontais e verticais. Já as curvas das diagonais estão próximas com comportamento similar.

A avaliação do momento angular reforça a interpretação da energia no qual há uma

baixa uniformidade geral com uma pequena tendência a uniformidade nas direções horizontais e verticais. Nesse contexto, os ângulos atingem, em até 75% dos *pixels*, valores em torno de 0,00025 e 100% em torno de 0,002. De forma geral, os comportamentos das curvas de 0° e 90° estão abaixo das curvas de 45° e 135°, indicando uma tendência a valores de ASM mais altos nessas direções. Esses resultados podem ser conferidos no gráfico (f).

Na sequência, na Figura 17 está representado o estudo das características das obras de Van Gogh na cidade de Saint-Remy. A correlação, em (a), mostra que em até 50% dos *pixels* analisados possuem valores entre 500 e 1500, aproximadamente, e em torno de 3.000 a 4.000 em 100%. A produção de Van Gogh mantém valores altos de contraste, semelhantes a Arles e Paris e mais altos que Nuenen. As pinceladas nas diagonais, representadas pelos ângulos 45° e 135°, trazem um contraste mais alto, mantendo-se a tendência do pintor nos outros cenários estudados. As curvas na horizontal e vertical apresentam comportamentos de menor contraste.

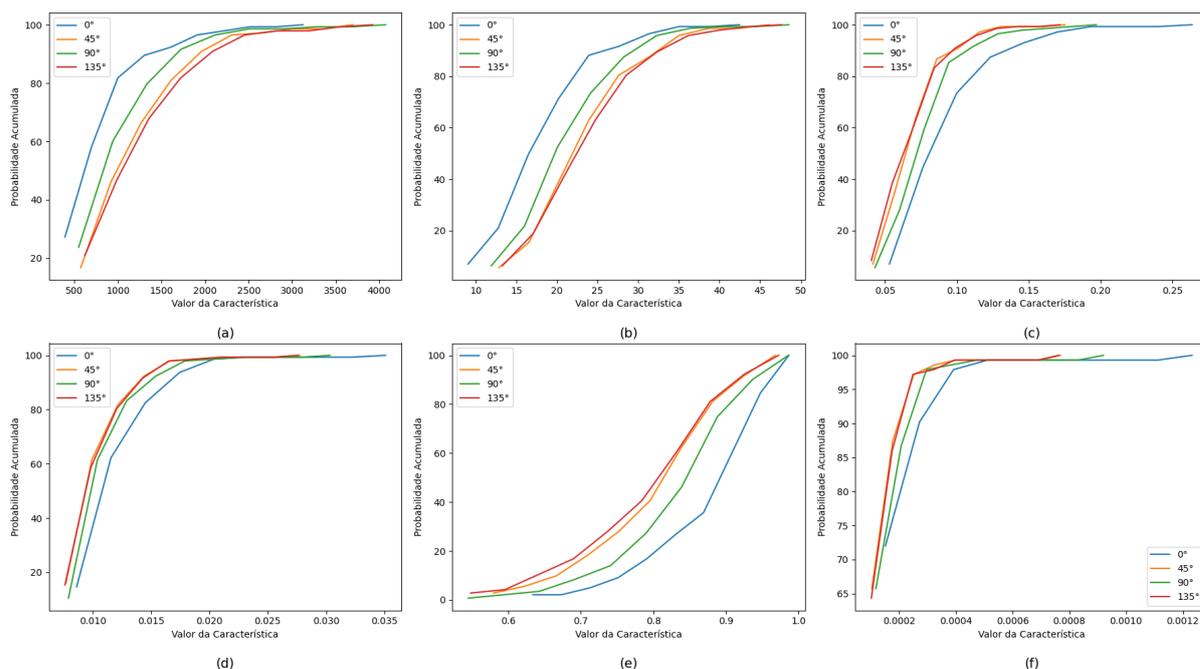


Figura 17: Funções de Distribuição Cumulativa das características de textura (a) Contraste, (b) Dissimilaridade, (c) Homogeneidade, (d) Energia, (e) Correlação e (f) ASM, obtidas pela análise GLCM das obras de Van Gogh produzidas em Saint-Rémy-Provence, em função da probabilidade acumulada, para os ângulos 0°, 45°, 90° e 135°.

A dissimilaridade em Saint-Rémy, em (b), mostram valores de até 25 para até 50% dos *pixels* investigados e entre 40 e 50 para a totalidade dos *pixels*. Similar ao contraste, a curva de 0° permanece *acima* das outras, indicando valores de dissimilaridade *mais baixos* na direção horizontal. Os ângulos 45° e 135° representando as diagonais apresentam comportamentos muito semelhantes. Por fim, pinceladas na vertical, simbolizada pelo ângulo de 90°, situa-se entre as demais curvas. Esses achados reforçam a interpretação

do contraste, com menor variação local de intensidade na direção horizontal.

O gráfico (c) mostra uma homogeneidade com valores baixos, similar aos dados de Arles e Paris e mais baixos que Nuenen. No geral, as curvas atingem resultados de até 0,1 em até 50% dos pontos avaliados. Homogeneidade no intervalo de 0,15 e 0,25 são encontrados em até 100% *pixels* em análise. As curvas de 0° e 90° estão abaixo das curvas de 45° e 135°. Estas, por sua vez, apresentam resultados muito semelhantes. Isso sugere que os valores de homogeneidade tendem a ser mais alto nas direções horizontais e verticais.

O gráfico (d) traz os resultados sobre a característica energia. Nesse quesito encontra-se valores baixo, semelhante as obras de outros períodos. As curvas atingem valores próximos a 0,01 em até 50% dos casos. Considerando a totalidade em 100% dos dados, os valores giram no intervalo de 0,225 e 0,035. Todas as curvas apresentam comportamento muito próximos no qual o ângulo 0° está ligeiramente abaixo das demais. Mais uma vez, destaca-se um padrão indicativo que a falta de uniformidade é ligeiramente maior na direção horizontal.

Em (e) está o gráfico correspondente a correlação. Em até 50% dos *pixels*, os valores achados giram em torno de 0,80 e 0,90 e, em até 100% dos casos, próximo a 1. Isso indica uma forte correlação linear entre *pixels* vizinhos. A curva de 0° está abaixo das outras, indicando valores de correlação mais altos na direção horizontal. Na sequência, vem a curva de 90° e, em seguida, os ângulos diagonais. Mais uma vez, os resultados apontam para uma forte correlação entre os *pixels* no sentido horizontal.

O momento angular mostra valores de no máximo 0,0002 em até 50% de *pixels* do contexto investigado. Considerando a totalidade dos casos, os índices variam entre 0,0007 e 0,0012. No geral, as curvas para os quatro ângulos estão relativamente próximas, embora a curva de 0° esteja ligeiramente abaixo em parte do gráfico. Esse cenário está de acordo com a energia tendo baixa uniformidade geral e uma ligeira tendência a maior variação na direção horizontal.

A Figura 18 apresenta os resultados de Auvers-sur-Oise. O contraste se apresenta alto comparável aos períodos de Paris, Arles e Saint-Remy. Os valores de todas as direções giram no intervalo entre 500 e 1.500 em 50% dos *pixels* e próximo a 3.500 em 100%. Isso indica que as pinturas desse período continuam a apresentar diferenças significativas de intensidade entre *pixels* vizinhos. A curva de 0° horizontal está acima das outras, indicando que o contraste tende a ser menor nessa direção. Os ângulos 45° e 135° apresentam praticamente o mesmo comportamento em até, aproximadamente, 60% sugerindo uma concentração de valores de contraste mais altos nessas direções diagonais. O ângulo de 90° apresenta comportamento semelhante a curva de 0°. Os resultados completos do contraste estão no gráfico (a).

Em (b) estão os resultados em relação a dissimilaridade. Os valores de dissimilaridade em Auvers-sur-Oise são altos, na mesma faixa dos observados em Paris, Arles e

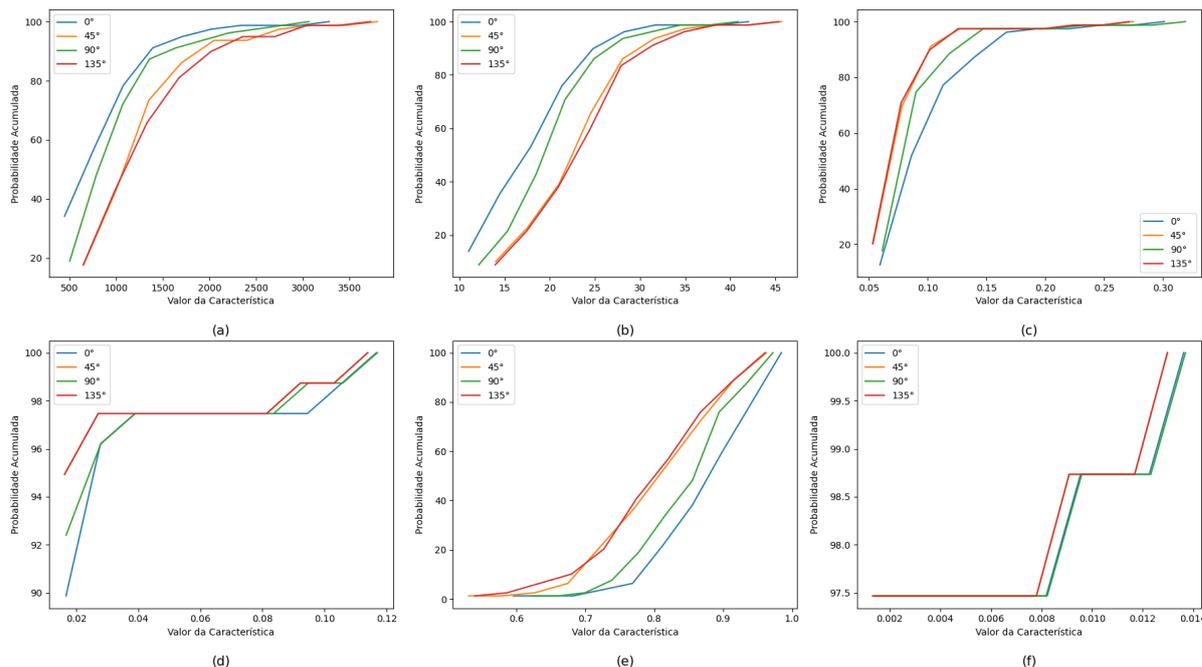


Figura 18: Funções de Distribuição Cumulativa das características de textura (a) Contraste, (b) Dissimilaridade, (c) Homogeneidade, (d) Energia, (e) Correlação e (f) ASM, obtidas pela análise GLCM das obras de Van Gogh produzidas em Auvers sur Oise, em função da probabilidade acumulada, para os ângulos 0° , 45° , 90° e 135° .

Saint-Remy. A curva atinge 50% de probabilidade acumulada em torno de 15 e 25 e 100% no intervalo de 40 e 45. Isso indica variações locais de intensidade acentuadas. A curva de 0° está acima das outras, indicando valores de dissimilaridade mais baixos na direção horizontal. As curvas correspondentes a diagonal apresentam comportamentos muito semelhantes, mostrando um padrão mais uniforme nesse sentido. Por fim, a curva de 90° situa-se levemente abaixo se comparada a direção horizontal, demonstrando comportamento similar.

Os resultados da homogeneidade estão representados no gráfico (c). De modo geral, a homogeneidade em Auvers-sur-Oise são baixos, mantendo a tendência dos períodos anteriores. A curva atinge 50% de probabilidade em torno 0,05 a 0,1 e 100% entre 0,25 e 0,30, aproximadamente. A curva de 0° está abaixo das outras, indicando que a homogeneidade é *maior* nessa direção. Nesse contexto, os valores de homogeneidade tendem a ser mais altos na direção horizontal. A análise dos ângulos diagonais 45° e 135° , apresentam comportamento praticamente igual em todos os pontos investigados. A direção vertical apresenta traços similares a curva de 0° , encontrando-se levemente acima desta. Dessa maneira, percebe-se maior homogeneidade na direção horizontal.

Os valores de energia são baixos (d), indicando texturas pouco uniformes e não repetitivas. A curva atinge 98% em até 0,04 e 100% em torno de 0,12. As curvas para os quatro ângulos estão muito próximas, embora a curva de 0° esteja ligeiramente abaixo em relação as demais direções. A baixa energia supõe a ausência de padrões fortemente repe-

titivos, A proximidade das curvas sugere que essa falta de uniformidade é relativamente consistente em todas as direções, com uma ligeira tendência a maior energia na direção horizontal.

No gráfico (e) estão os achados de correlação. A curva de 0° está abaixo das outras curvas na maior parte do gráfico com uma correlação maior na direção horizontal. As curvas diagonais 45° e 135° estão relativamente próximas com traçados semelhantes. Em até 50% dos *pixels*, os ângulos apresentam valores compreendidos entre 0,8 e 0,9 e valor 1 em até 100% dos casos.

Para finalizar, o momento angular está exposto no gráfico (f). Em aproximadamente 98% dos *pixels*, os valores encontrados são de, no máximo, 0,008 e 100% em torno de 0,014. As curvas para todas as direções estão relativamente próximas, embora a curva de 90° esteja ligeiramente abaixo em boa parte do gráfico. As Tabelas 1 e 2 resumem as informações sobre características de texturas nas obras analisadas.

Característica	Nuenen	Paris	Arles	Saint-Rémy-Provence	Auvers-sur-Oise
Contraste	Contraste relativamente alto, com as diagonais (45° e 135°) ligeiramente maior e a horizontal (0°) menor.	Contraste mais alto que em Nuenen, com a horizontal (0°) tendendo a ser menor e as diagonais (45° e 135°) maiores que a horizontal e a vertical.	Contraste alto, similar a Paris, com as direções horizontal e vertical (0° e 90°) apresentando menor contraste que as diagonais.	Contraste alto, similar a Arles e Paris, com as diagonais (45° e 135°) mostrando um contraste mais alto e as direções horizontal e vertical com menor contraste.	Contraste alto, comparável aos períodos anteriores, com a horizontal (0°) tendendo a ser menor e as diagonais (45° e 135°) mostrando valores de contraste mais altos.
Dissimilaridade	Dissimilaridade moderada, com a direção horizontal (0°) mostrando valores mais baixos e as diagonais (45° e 135°) valores praticamente iguais e mais altos.	Dissimilaridade mais alta que em Nuenen, com a direção horizontal (0°) permanecendo abaixo das demais, indicando valores mais baixos nessa direção.	Dissimilaridade alta, semelhante a Paris, com as direções horizontal e vertical (0° e 90°) apresentando valores mais baixos que as diagonais.	Dissimilaridade alta, com a direção horizontal (0°) mostrando valores mais baixos e as diagonais (45° e 135°) apresentando comportamentos semelhantes.	Dissimilaridade alta, similar aos outros períodos, com a direção horizontal (0°) mostrando valores mais baixos que as demais direções.
Homogeneidade	Homogeneidade geralmente não muito alta, com as diagonais (45° e 135°) apresentando valores menores que as outras direções.	Homogeneidade ligeiramente mais baixa que em Nuenen, com a direção horizontal (0°) mostrando valores maiores.	Homogeneidade baixa, semelhante a Paris, com as direções horizontal e vertical (0° e 90°) mostrando valores maiores que as diagonais.	Homogeneidade baixa, similar a Arles e Paris, com as direções horizontal e vertical (0° e 90°) mostrando valores mais altos que as diagonais.	Homogeneidade baixa, mantendo a tendência anterior, com a direção horizontal (0°) mostrando valores maiores que as outras direções.

Tabela 1: Resumo das características de textura (Contraste, Dissimilaridade e Homogeneidade).

Característica	Nuenen	Paris	Arles	Saint-Rémy-Provence	Auvers-sur-Oise
Energia	Valores de energia baixos, indicando texturas pouco uniformes, com uma ligeira tendência a menor energia na direção de 45°.	Energia mais alta que em Nuenen, com as curvas para os quatro ângulos muito próximas, embora a vertical (90°) seja ligeiramente maior.	Resultados de energia baixos, próximos aos de Paris e Nuenen, com as direções horizontal e vertical (0° e 90°) tendendo a valores mais altos.	Valores de energia baixos, semelhante aos de outros períodos, com todas as curvas apresentando comportamento muito próximo, embora a horizontal (0°) seja ligeiramente maior.	Valores de energia baixos, indicando texturas pouco uniformes, com as curvas para os quatro ângulos muito próximas, embora a horizontal (0°) seja ligeiramente maior.
Correlação	Forte correlação linear, com as diagonais (45° e 135°) mostrando valores mais baixos nessas direções.	Forte correlação linear, um pouco menor que em Nuenen, com a horizontal (0°) mais alta que as outras curvas.	Forte correlação linear, semelhante a Paris e Nuenen, com as direções horizontal e vertical (0° e 90°) mostrando uma correlação mais alta que as diagonais.	Forte correlação linear, com a horizontal (0°) mostrando valores de correlação mais altos que as outras direções.	Correlação alta, com a horizontal (0°) mostrando uma correlação maior que as outras curvas.
ASM	Momentos angulares baixos, com as direções diagonais (45° e 135°) apresentando valores menores que as direções horizontal e vertical.	Valores baixos, um pouco mais altos que em Nuenen, com a horizontal (0°) ligeiramente mais alto que as outras.	Avaliação do momento angular reforça a baixa uniformidade, com as direções horizontal e vertical (0° e 90°) mostrando valores mais altos.	Momentos angulares com valores baixos, com as curvas para os quatro ângulos relativamente próximas, embora a horizontal (0°) esteja ligeiramente mais alta.	Momento angular baixo, indicando baixa uniformidade, com as curvas para todas as direções relativamente próximas, embora a vertical (90°) esteja ligeiramente mais alta.

Tabela 2: Resumo das características de textura (Energia, Correlação e ASM).

6.2 Análise das cartas escritas por Van Gogh

A Figura 19 mostra os resultados após a aplicação do algoritmo de processamento de linguagem natural *Transformers* nas cartas escritas por Van Gogh. O eixo y contém as cinco cidades investigadas nesta pesquisa. O eixo x traz, em ordem cronológica, o período das cartas escritas por Van Gogh. O mapa de calor possui uma escala compreendida entre -1 e 1. Conteúdos das cartas considerados pelo algoritmo como mais negativos são representados por tonalidades da cor azul. Por outro lado, conteúdos entendidos como mais positivos são representados por tons de vermelho.

As cartas enviadas por Van Gogh quando estava na cidade de Nuenen apresentam um predomínio de tons de azul mais claros, o que pode assinalar um período de maior instabilidade emocional. A mudança para cidade de Paris entre 1886 e 1887 sugere o primeiro momento mais positivo. Na sequência, entre os anos de 1887 e 1888 na cidade Arles, percebe-se um período de maior estabilidade positiva. Esse mesmo cenário é observado Saint-Rémy com pequenas frações negativas. Auvers-sur-Oise manteve o predomínio em tons mais vermelhos, sugerindo um contexto mais positivo.

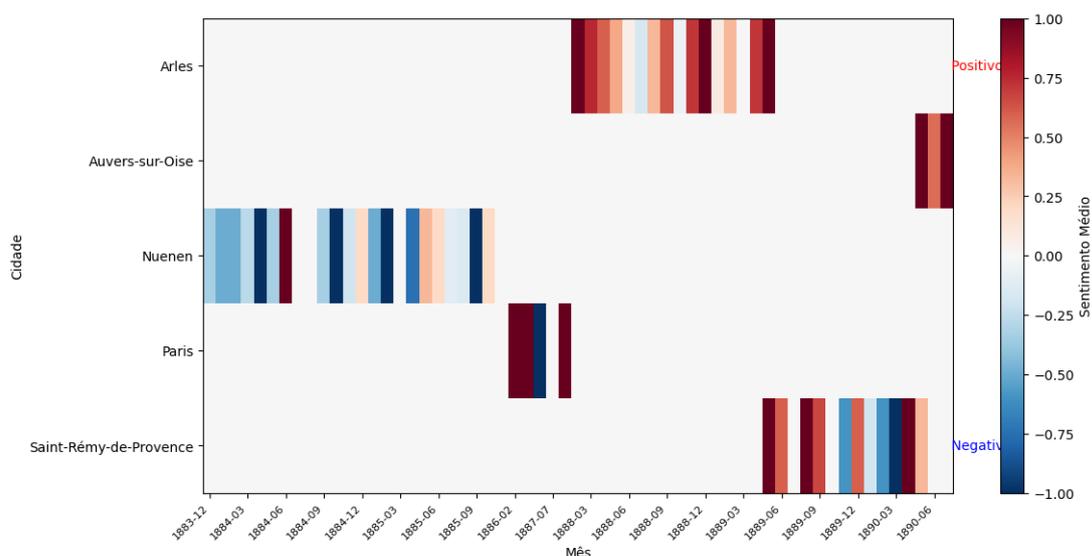


Figura 19: Distribuição do tom emocional inferido das cartas de Van Gogh escritas durante suas estadias nas cidades de Nuenen, Paris, Arles, Saint-Rémy-de-Provence e Auvers-sur-Oise.

Uma análise qualitativa das cartas de Van Gogh corrobora em parte com os achados propostos pelo algoritmo de processamento de linguagem natural *Transformers*. As cartas do período de Nuenen revelam lutas iniciais e incertezas, marcadas por sentimentos de mal-estar físico e emocional, ansiedade em relação ao futuro financeiro e profissional, e uma perspectiva pessimista. Van Gogh expressa sentir-se um estranho e um fardo para seu irmão Theo, indicando isolamento social e baixa autoestima. Há também indícios de arrependimento juntamente com uma profunda tristeza e sentimento de responsabilidade.

Observa-se também um forte foco no trabalho artístico, um desejo de reconhecimento e uma luta contínua com a precariedade financeira.

As cartas escritas em Paris são caracterizadas por um terrível aperto financeiro e pela necessidade urgente de moradia, indicando estresse contínuo. Há também incerteza artística, levando a uma pausa na pintura para se concentrar no desenho. Van Gogh expressa desconfiança em relação às pessoas de seu convívio, sugerindo um quadro de mal-estar social. Suas reflexões posteriores no período de Paris revelam uma consciência da dificuldade de encontrar certeza e conforto na vida, bem como a prevalência da melancolia e do pessimismo.

As cartas escritas em Arles apontam, inicialmente, para um entusiasmo e intensa energia criativa, mas também preocupação com a saúde e as dificuldades financeiras de outros artistas, sugerindo empatia. As cartas revelam instabilidade física e emocional, com relatos de febre e falta de apetite. Mais tarde, o período é marcado por uma sensação de que o aprendizado em Paris está desaparecendo, levando a uma busca por uma expressão artística mais pessoal e ao uso da cor de forma arbitrária para expressar emoções fortes. Há também um sentimento crescente de estar sobrecarregado e uma mudança para a resignação, com expectativas reduzidas e receio em relação ao trabalho. Após um período de hospitalização, há uma “vaga tristeza” persistente, apesar da melhora da força física, e uma consciência da necessidade de procurar atendimento institucional devido à instabilidade mental.

As cartas do período de Saint-Remy, durante sua estadia em um asilo, expressam uma mistura de alívio e aceitação de sua condição mental, mas também uma perda de desejo e esperança. Há uma luta contínua com a motivação e a autocrítica, mas um retorno gradual da vontade de trabalhar. Ele relata um estado de saúde instável, mas sente-se mais feliz trabalhando no asilo do que fora dele, indicando uma preferência pelo ambiente estruturado. Há momentos de tédio e anedonia, juntamente com intensa ansiedade e terror ao pensar em sua situação. Ele sente falta de seu irmão Theo, experimentando, em alguns momentos, isolamento e falta de ideias para o futuro. Mais tarde, há uma queda significativa em seu estado emocional, marcada por tristeza, tédio, retraimento emocional e um desejo de mudança, sugerindo uma recorrência de sintomas depressivos.

Por fim, as cartas escritas por Van Gogh em Auvers-sur-Oise mantêm a ideia de uma mistura de sinais positivos e negativos, com agradáveis lembranças de visitas familiares, mas também frustração e uma percepção negativa de experiências passadas. Há produtividade artística contínua e uma busca por validação. No entanto, as cartas posteriores indicam uma deterioração da saúde mental e um sentimento de que sua vida está “atacada pela raiz”, culminando em seu suicídio. A Tabela 3 traça uma panorama geral desses períodos.

Período	Exemplos/Temas Específicos de Cartas	Possíveis Sintomas Depressivos Indicados
Nuenen	Sentimento de mal-estar; Pessimismo sobre o futuro e finanças; Sentimento de ser um estranho e um fardo; Arrependimento.	Humor deprimido, Ansiedade; Desesperança; Baixa autoestima; Isolamento social; Culpa.
Paris	Dificuldades financeiras e incerteza artística; Reflexões sobre melancolia e pessimismo.	Ansiedade, baixo humor, perda de interesse, isolamento social.
Arles	Preocupação com outros artistas; Instabilidade física e emocional; Sentimento de estar sobrecarregado; Resignação e expectativas reduzidas; Vaga tristeza; Sentimento de incapacidade e culpa; Desespero.	Empatia excessiva, instabilidade emocional, sentimento de estar sobrecarregado, perda de esperança, tristeza, culpa, desespero.
Saint-Rémy-de-Provence	Perda de desejo e esperança; Autocrítica e insatisfação; Anedonia; Ansiedade e ataques de pânico; Sentimento de isolamento; Falta de ideias para o futuro; Percepção negativa do ambiente; Retraimento emocional; Sentimento de aprisionamento.	Perda de interesse, desesperança, autocrítica, incapacidade de sentir prazer, ansiedade, isolamento social, falta de motivação, sentimento de estar preso.
Auvers-sur-Oise	Frustração e percepção negativa; Ansiedade social.	Frustração, ansiedade.

Tabela 3: : Possíveis Indicadores de Depressão nas Cartas de Van Gogh (por Período)

6.3 Análise estrutural nas obras de Van Gogh

Foi implementada uma rede neural convolucional com foco na identificação de características que diferenciem as obras de Van Gogh de acordo com as cinco cidades nas quais as obras foram produzidas. Para atingir esse objetivo, foram conduzidos 4 (quatro) experimentos, cada um modificando um aspecto específico da configuração da rede, a fim de avaliar seu impacto individual na capacidade de generalização da rede. A arquitetura base da CNN foi mantida constante entre os experimentos.

A Figura 20 mostra os resultados da métrica acurácia nos 4 (quatro) experimentos propostos. O gráfico (a) mostra os resultados do experimento 1. Observa-se um aumento gradual da acurácia de treinamento, atingindo cerca de 55%, enquanto a acurácia de validação apresenta um comportamento similar, porém com valores mais baixos, em torno de 40%, e maior oscilação. Essa diferença sugere que o modelo está aprendendo com os dados de treinamento, mas apresenta dificuldades em generalizar para novas amostras, o que pode indicar um leve *overfitting*.

O gráfico (b) apresenta os resultados do experimento 2. Com o aumento da taxa de aprendizado, a acurácia de treinamento aumenta mais rapidamente, chegando a aproximadamente 70%, mas com oscilações mais evidentes. A acurácia de validação, por outro lado, permanece em níveis baixos, entre 20% e 40%, e com grande instabilidade. Esse padrão indica que o modelo está aprendendo mais rápido com os dados de treinamento, porém a instabilidade na validação sugere dificuldades em generalizar o aprendizado para novas amostras, possivelmente devido a uma taxa de aprendizado muito alta.

Em relação ao experimento 3, a remoção da regularização L2 resulta em uma acurácia de treinamento que aumenta rapidamente, chegando a cerca de 60%, com várias oscilações. A acurácia de validação permanece baixa com comportamento semelhante, oscilando entre 20% e 30%, e sem tendência clara de aumento. Esse comportamento indica que o modelo está tendendo ao *overfitting*, ajustando-se em excesso aos dados de treinamento e perdendo a capacidade de generalizar para novas amostras. O gráfico (c) traz esse cenário.

Por fim, o gráfico (d) mostra os resultados do Experimento 4. A redução da taxa de *dropout* leva a uma acurácia de treinamento e validação semelhante entre 10% a 40% até aproximadamente metade das épocas. Após esse intervalo, a taxa de treinamento apresenta oscilações mais acentuadas com picos superiores a 60%. No entanto, isso sugere que a redução do *dropout* não teve um impacto significativo na capacidade de generalização do modelo, mantendo um comportamento similar à linha de base.

Comparando a acurácia dos quatro experimentos, pode-se observar que o experimento 2 possui melhor equilíbrio entre acurácia de treinamento e validação, com uma diferença menor entre as curvas e maior estabilidade na validação. Entretanto, de modo geral, todos os modelos apresentam dificuldades na generalização dos dados.

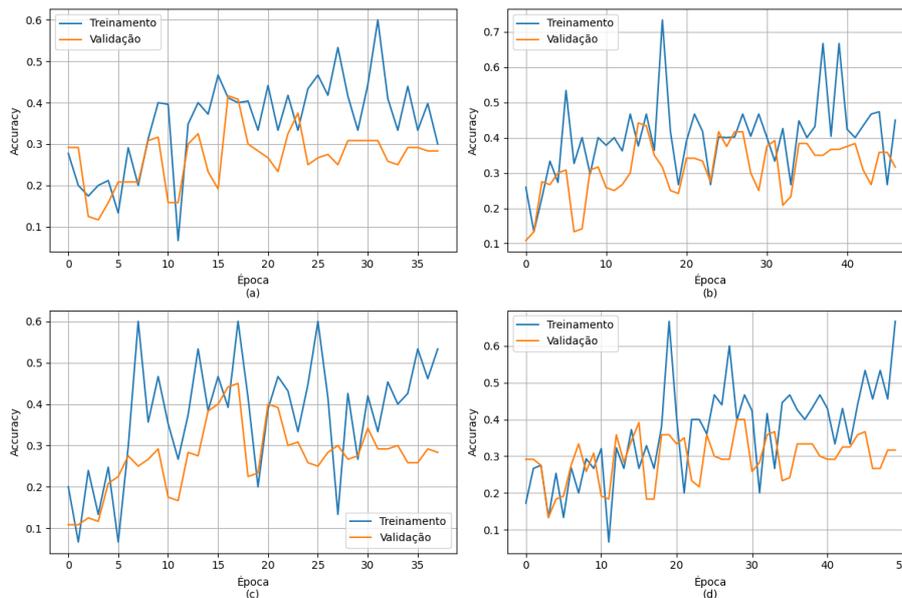


Figura 20: Resultados da acurácia de treinamento e validação ao longo das épocas para os Experimentos (a) 1, (b) 2, (c) 3 e (d) 4 da rede neural convolucional, utilizada para classificar as pinturas de Van Gogh de acordo com a cidade de produção.

A Figura 21 contém os achados da métrica *loss*. Em relação os resultados do experimento 1, no gráfico (a), percebe-se uma queda gradual e consistente nas curva de treinamento, convergindo para valores próximos a 1,3 a partir do meio do experimento, aproximadamente. A perda de validação também diminui, mas com valores maiores e algumas oscilações, em torno de 1,7. Esses comportamentos corroboram com a acurácia, em que as curvas sugerem que o modelo está aprendendo com os dados de treinamento, mas apresenta dificuldades em generalizar para novas amostras, o que pode indicar um leve *overfitting*.

No experimento 2, com o aumento da taxa de aprendizado, a curva de *loss* de treinamento diminui rapidamente, mas com oscilações mais pronunciadas após metade das épocas de aprendizagem. A perda de validação, por outro lado, apresenta valores maiores com instabilidade. Novamente, esse comportamento indica que o modelo está aprendendo mais rápido com os dados de treinamento, porém a instabilidade na validação sugere dificuldades em generalizar o aprendizado para novas amostras, possivelmente devido a uma taxa de aprendizado muito alta. Esses dados estão no gráfico (b).

A remoção da regularização L2 do experimento 3, presente no gráfico (c), resulta em uma perda na curva de treinamento que diminui rapidamente e converge para um valor baixo. No entanto, a perda de validação permanece alta e instável, indicando *overfitting*. O modelo está se ajustando em excesso aos dados de treinamento e não consegue generalizar para novas amostras.

A redução da taxa de *dropout* no experimento 4 leva a uma perda de treinamento que diminui de forma similar ao experimento 1, convergindo para valores entre 1,2 e 1,6.

A perda de validação também apresenta comportamento similar ao experimento 1, com valores em torno de 1,6 e 1,8, com algumas oscilações. Isso sugere que a redução do *dropout* não teve um impacto significativo na capacidade de generalização do modelo de forma esperada.

O experimento 2 apresenta o melhor desempenho geral, com uma perda de treinamento e validação mais baixas e maior estabilidade na validação. O experimento 2, com a taxa de aprendizado aumentada, mostra um aprendizado mais rápido, mas com maior instabilidade e dificuldades em generalizar. O experimento 3, sem regularização L2, apresenta comportamento semelhante ao *overfitting*, com baixa perda no treinamento e alta na validação. O experimento 4, com *dropout* reduzido, não apresenta diferenças significativas aos demais experimentos.

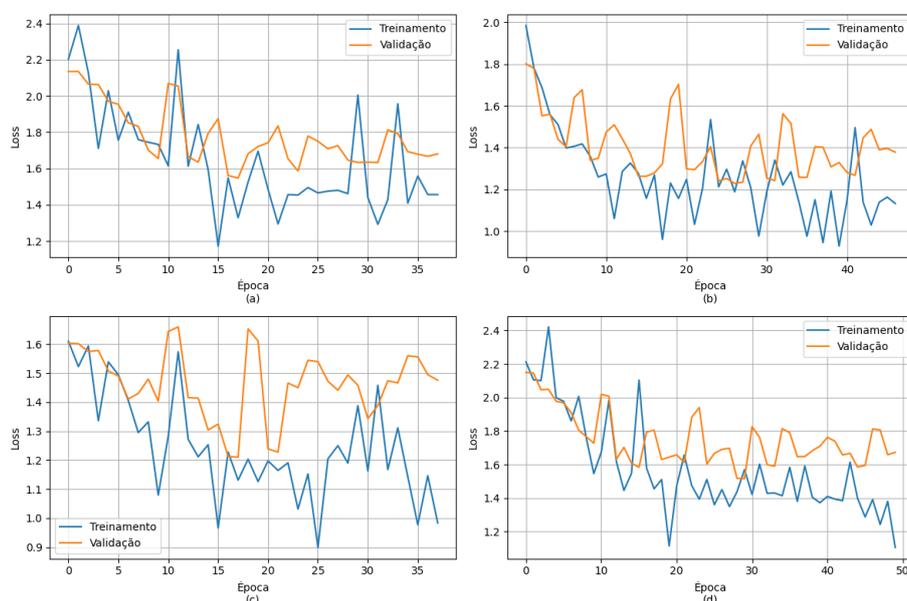


Figura 21: Resultados do *loss* de treinamento e validação ao longo das épocas para os Experimentos (a) 1, (b) 2, (c) 3 e (d) 4 da rede neural convolucional, utilizada para classificar as pinturas de Van Gogh de acordo com a cidade de produção.

A Figura 22 contém os resultados referentes a precisão dos modelos. No gráfico (a) o experimento 1 comporta-se com grande amplitude de variação da curva de treinamento, oscilando entre 0 e 1 durante o desenvolvimento do processo de aprendizagem. Por sua vez, a curva de validação apresenta oscilação expressivas entre 0 e 0,8 durante a primeira metade das épocas e, posteriormente, variações menor na segunda metade variando entre 0,4 e 0,6, com leve tendência a se estabilizar próximo a 0,4. Essa diferença sugere que o modelo está aprendendo a classificar as amostras de treinamento, mas com alguma dificuldade em generalizar essa capacidade para novas amostras de validação.

Com o aumento da taxa de aprendizado no experimento 2 com os dados contidos no gráfico (b), a precisão de treinamento aumenta rapidamente tanto para a curva de treinamento e validação, mas com oscilações mais pronunciadas entre 0 e 1 ao longo do

processo. No geral, a precisão de validação permanece em níveis baixos e com instabilidade, indicando que o modelo está tendo dificuldades em generalizar o aprendizado para novas amostras, possivelmente devido à taxa de aprendizado muito alta.

No gráfico (c), o experimento 3 também comporta-se com grande amplitude de variação das curvas de treinamento e validação, oscilando entre 0 e 1 durante a primeira metade do processo de aprendizagem. Esse cenário converge para a ideia de uma tendência a *overfitting*. O modelo está se ajustando em excesso aos dados de treinamento e não generaliza bem para novas amostras.

No gráfico (d), a redução da taxa de *dropout* do experimento 4 leva a uma precisão de treinamento e validação que aumentam de forma similar ao Experimento 1. Tal cenário sugere que a redução do *dropout* não teve um impacto significativo na capacidade de generalização do modelo. O experimento 4 apresenta uma precisão de validação ligeiramente superior em algumas épocas, o que permite inferir que a redução do *dropout* pode ter um impacto positivo na capacidade de generalização do modelo. O aumento da taxa de aprendizado no experimento 2 pode acelerar o aprendizado, mas exige cuidado para evitar instabilidade e *overfitting*. A remoção da regularização L2 no experimento 3 leva a um cenário de *overfitting*,

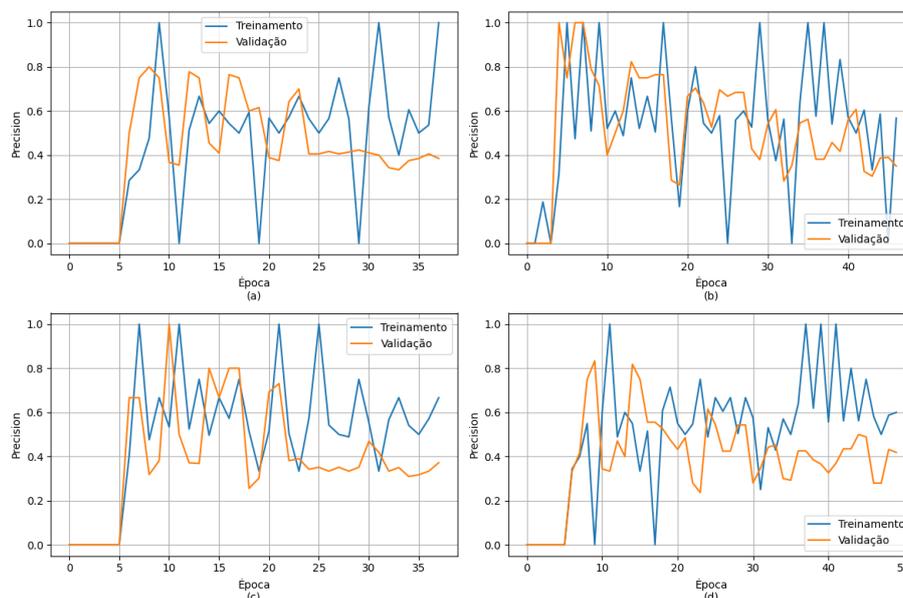


Figura 22: Resultados da precisão de treinamento e validação ao longo das épocas para os Experimentos (a) 1, (b) 2, (c) 3 e (d) 4 da rede neural convolucional, utilizada para classificar as pinturas de Van Gogh de acordo com a cidade de produção.

Os resultados sobre a métrica *recall* estão na Figura 23. No experimento 1, o *recall* de treinamento aumenta gradualmente, com picos próximos a 0,2, enquanto o *recall* de validação apresenta comportamento similar, porém com valores mais baixos e menor oscilação. Essas características permitem inferir que o modelo tem mais dificuldade em generalizar a capacidade de identificar amostras positivas para novos dados. Esses dados

podem ser analisados no gráfico (a).

Com o aumento da taxa de aprendizado no experimento 2, o *recall* de treinamento aumenta mais rapidamente, mas com números menores. O *recall* de validação permanece em níveis baixos e com menores instabilidades, indicando que o modelo está tendo dificuldades em generalizar o aprendizado para novas amostras, possivelmente devido à taxa de aprendizado muito alta. Esses resultados estão no gráfico (b).

O experimento 3, a curva de treinamento possui um pico observado com valores próximo a 0,5. No entanto, de decorrer do processo de aprendizagem, os valores assumidos por essa curva giram em torno de 0,1 a 0,2. Com relação a curva de validação, esta comporta-se de maneira mais homogênea no que diz respeito as oscilações ao longo das épocas, variando entre 0 e 0,1, aproximadamente. Essa diferença sugere que o modelo está aprendendo a identificar as amostras positivas de treinamento, mas com alguma dificuldade em generalizar essa capacidade para novas amostras de validação. Esses resultados podem ser avaliados no gráfico (c).

A redução da taxa de *dropout* no experimento 4, apresentada no gráfico (d), traz um *recall* com comportamento similar ao Experimento 2, com índices variando entre 0 e 0,35 para a curva de treinamento e 0 a 0,2 para a curva de validação. Novamente, esse contexto sugerem que a redução do *dropout* não teve um impacto significativo na capacidade de generalização do modelo.

De modo geral, o experimento 1 apresenta as piores métricas no que diz respeito as taxas de *recall* de treinamento e validação. O experimento 2, com a taxa de aprendizado aumentada, mostra um aprendizado mais rápido, mas com dificuldades em generalizar. O experimento 3, sem regularização L2 e o experimento 4, com *dropout* reduzido, não apresentam diferenças significativas em relação aos demais experimentos.

A Figura 24 contém os achados a métrica *F1-score*. No gráfico (a), em relação ao experimento 1, as curvas de treinamento e validação tem comportamentos semelhantes com amplitude oscilante, variando entre 0,1 e, aproximadamente, 0,4 em boa parte do processo de treinamento. Ainda observa-se um pico da curva de treinamento próximo a 0,6. Esse contexto indica que o modelo está aprendendo com os dados de treinamento, mas tem dificuldades em generalizar para novas amostras.

A respeito do *F1-score* do experimento 2, no gráfico (b), o conjunto de treinamento aumenta mais rapidamente, mas com oscilações mais pronunciadas. O *F1-score* de validação permanece similar com níveis ligeiramente mais baixos e oscilações, indicando que a taxa de aprendizado mais alta pode estar prejudicando a generalização.

Os resultados do experimento 3 mostram um *F1-score* de treinamento que aumenta rapidamente, enquanto o *F1-score* de validação permanece baixo e instável, evidenciando *overfitting*. O modelo se ajusta em excesso aos dados de treinamento e não generaliza bem para novas amostras. Esses resultados podem ser visualizados no gráfico (c).

No gráfico (d), sobre o experimento 4, o *F1-score* de treinamento aumenta de forma

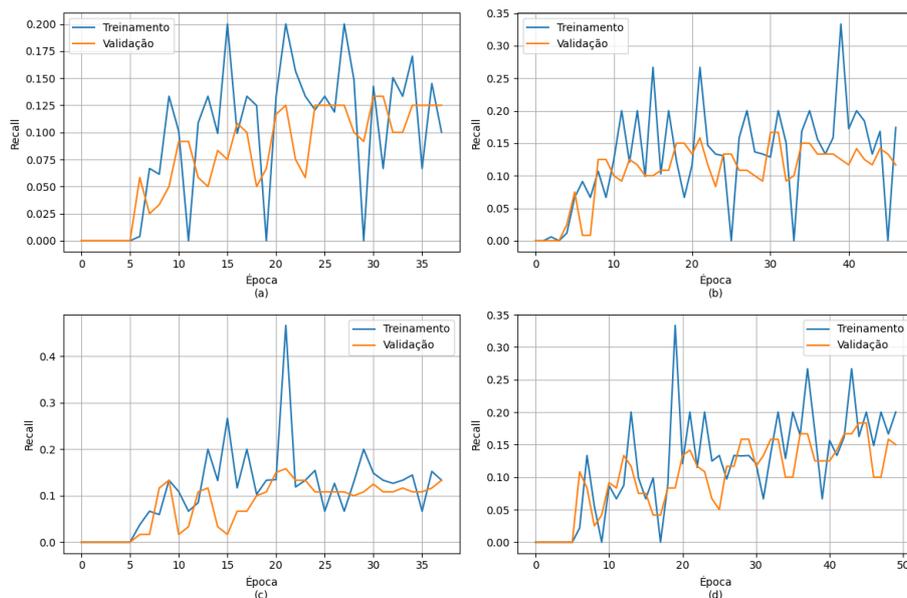


Figura 23: Resultados da *recall* de treinamento e validação ao longo das épocas para os Experimentos (a) 1, (b) 2, (c) 3 e (d) 4 da rede neural convolucional, utilizada para classificar as pinturas de Van Gogh de acordo com a cidade de produção.

similar ao Experimento 1, e o *F1-score* de validação também apresenta comportamento similar, com valores um pouco maiores em algumas épocas e maior oscilações. Isso sugere que a redução do *dropout* pode ter tido um pequeno impacto positivo na capacidade de generalização do modelo.

No geral, os 4(quatro) experimentos apresentaram resultados muito semelhantes tanto para a curva de treinamento e validação. Todos os Experimentos resultam grandes oscilações em ambas as curvas sugerindo que o modelo possivelmente tem dificuldades em classificar as obras de Van Gogh de acordo com a cidade onde foram produzidas.

Para finalizar, a Figura 25 explicita os resultados da matriz de confusão dos modelos propostos nos 4 (quatro) experimentos. Os achados obtidos pelos experimentos 1, 2, 3 e 4 são representados pelas matrizes (a), (b), (c) e (d), respectivamente. Na matriz (a), a matriz de confusão do experimento 1 revela que o modelo tem maior facilidade em classificar corretamente as obras de Auvers sur Oise, Nuenen e Paris com 14, 12 e 13 acertos, respectivamente. Por outro lado, as previsões de Saint-Rémy-de-Provence e Arles apresentou resultados piores com 11 e 4 acertos, respectivamente.

O experimento 2 traz um cenário diferente. A cidade de Arles mostra o maior número de obras com acertos (22 obras), seguidas por Paris com 12 acertos, Nuenen com 11 acertos e Auvers sur Oise com 9 acertos. A cidade de Saint-Rémy-de-Provence se destaca por não ter possuir nenhum acerto. Essas informações estão na matriz (b).

O experimento 3, representado na matriz (c), possui comportamento similar ao experimento 2. A cidade de Arles mantém a melhor quantidade de obras corretas com 22 acertos, seguidas por Auvers sur Oise com 13 acertos, Nuenen e Paris com 11 acertos. A

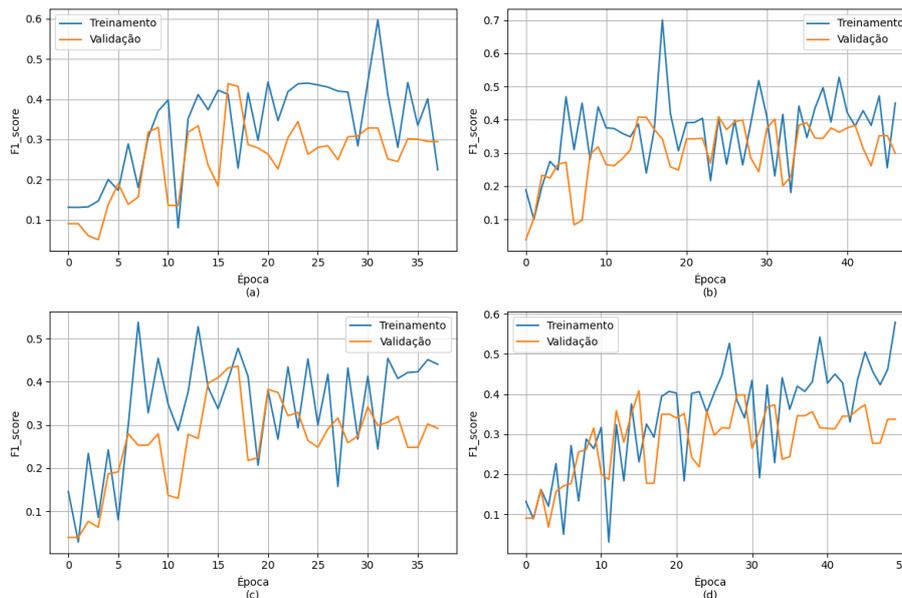


Figura 24: Resultados da *F1-score* de treinamento e validação ao longo das épocas para os Experimentos (a) 1, (b) 2, (c) 3 e (d) 4 da rede neural convolucional, utilizada para classificar as pinturas de Van Gogh de acordo com a cidade de produção.

cidade de Saint-Rémy-de-Provence permanece com o pior desempenho com taxa de dois acertos.

A matriz (d), do experimento 4, traz as cidades de Auvers sur Oise, Paris e Nuenen os melhores resultados com, respectivamente, 15, 12 e 10 acertos. Os piores resultados são observados com Arles e Saint-Rémy-de-Provence com 1 e 2 acerto, respectivamente.

Comparando as matrizes de confusão dos 4 (quatro) experimentos, pode-se observar que o padrão de classificação é similar em todos eles, com maior dificuldade em classificar as obras de Saint-Rémy-de-Provence. As obras de Arles e Auvers sur Oise são classificadas com mais precisão em todos os experimentos, e as cidades de Nuenen e Paris com uma taxa de acerto moderada.

Na sequência, são mostrados os resultados da aplicação da rede neural com foco específico em cada período de vida de Van Gogh. As obras do conjunto de treinamento e de teste são com obras pertencentes somente ao período analisado. A Figura 26 apresenta os resultados da cidade de Nuenen. De modo geral, obteve-se um bom desempenho do modelo na tarefa de classificar as pinturas como pertencentes ao período de Nuenen com alto número de acertos nos quatro tipos de Experimentos. Os experimentos 1 e 3 apresentaram os melhores resultados representados pelas matrizes (a) e (c). Considerando todos os experimentos, o número de acertos variou entre 119 e 122. Já o número de erros girou entre 8 e 11. Esses achados fornecem evidências da capacidade do aprendizado de máquina em identificar padrões visuais que podem distinguir as obras de Van Gogh pertencentes ao período de Nuenen, não havendo diferenças significativas nos resultados nas configurações de Experimentos propostas.

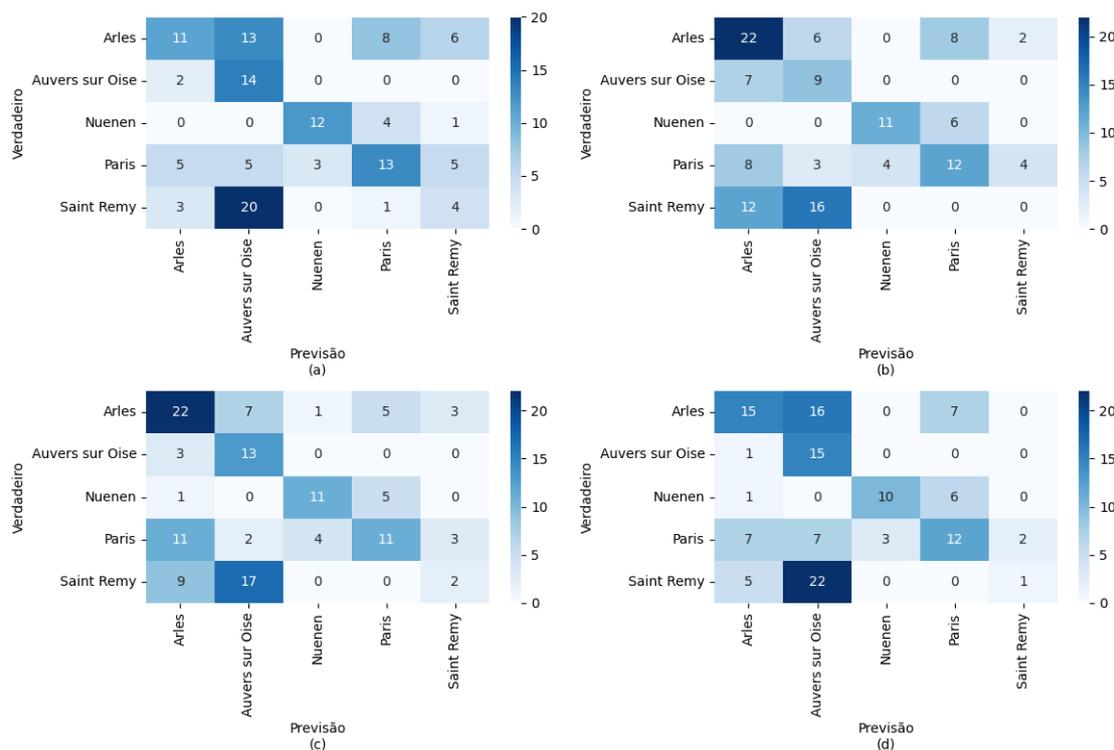


Figura 25: Matrizes de confusão dos resultados da classificação das obras de Van Gogh por cidade, utilizando uma rede neural convolucional nos Experimentos (a) 1, (b) 2, (c) 3 e (d) 4, mostrando o número de acertos e erros para cada cidade (Auvers sur Oise, Nuenen, Paris, Saint-Rémy-de-Provence, Arles).

A Figura 27 traz as matrizes de confusão das obras produzidas em Paris. O desempenho dos modelos apresentam uma ligeira variabilidade entre as diferentes configurações e quando comparado ao período anterior. As matrizes (c) e (d), correspondentes aos experimentos 3 e 4, respectivamente, obtiveram um desempenho superior em comparação aos experimentos 1 e 2, representados pelas matrizes (a) e (b). De modo geral, o número de acertos variou entre 99 e 104. A quantidade de erros ficou entre 26 e 31.

A Figura 28 mostra as matrizes de confusão da cidade de Arles. Os dados apresentam uma variação entre as diferentes configurações de experimentos, similar ao observado em Paris, mas com uma tendência geral de melhor desempenho do que as configurações menos eficazes para Paris. A análise geral mostra melhor desempenho dos experimentos 2 e 4. De maneira geral, o número de acertos variou entre 92 e 114. A quantidade de erros ficou compreendido entre 16 e 38, apresentando amplitude maior de variação.

A Figura 29 representa os resultados da cidade de Saint-Rémy-de-Provence. De forma geral, todos os experimentos apresentaram dificuldades em classificar as obras desse período. A matriz (c) trouxe os melhores resultados. A quantidade de acertos está compreendida entre 72 e 101 e a taxa de erro varia entre 29 e 58. O número de erros pertence ao intervalo de 29 a 58.

A Figura 30 representa os resultados da cidade de Auvers Sur Oise. As matrizes (b)

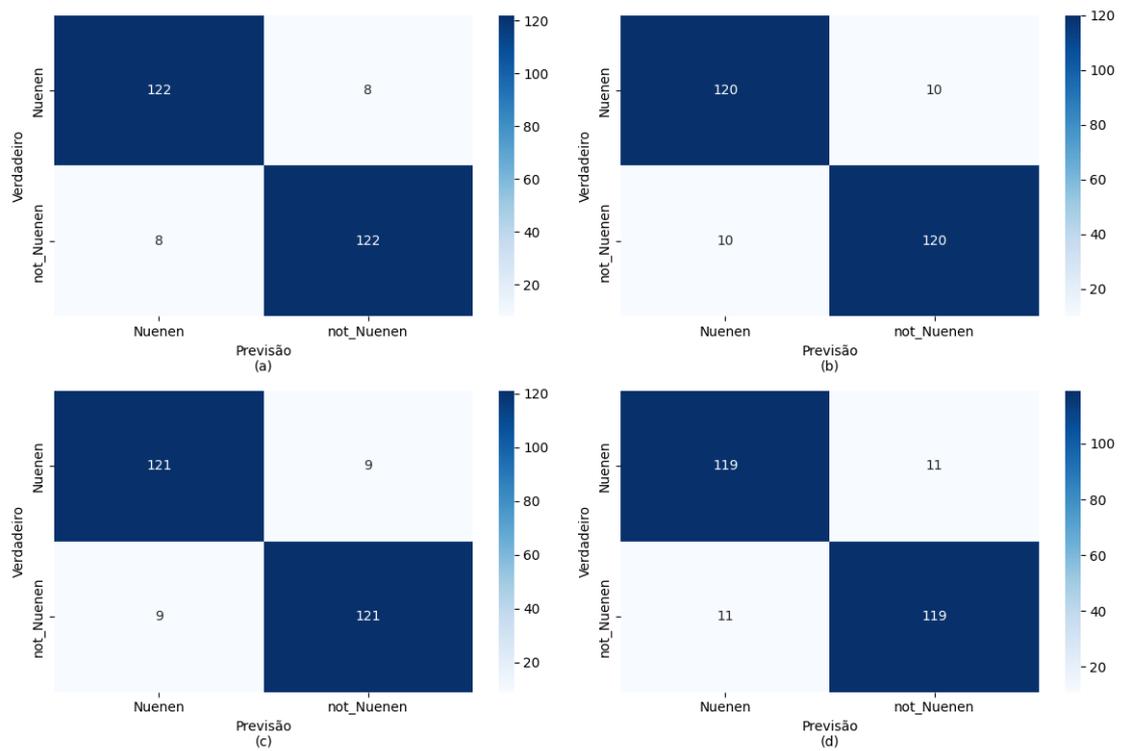


Figura 26: Matrizes de confusão combinadas dos Experimentos (a) 1, (b) 2, (c) 3 e (d) 4, mostrando o desempenho da rede neural convolucional na classificação das obras de Van Gogh produzidas em Nuenen.

e (d) mostram os melhores resultados. A quantidade de acertos está compreendida entre 110 e 114 e a taxa de erro varia entre 29 e 58. A quantidade de erros pertence ao intervalo de 16 a 38.

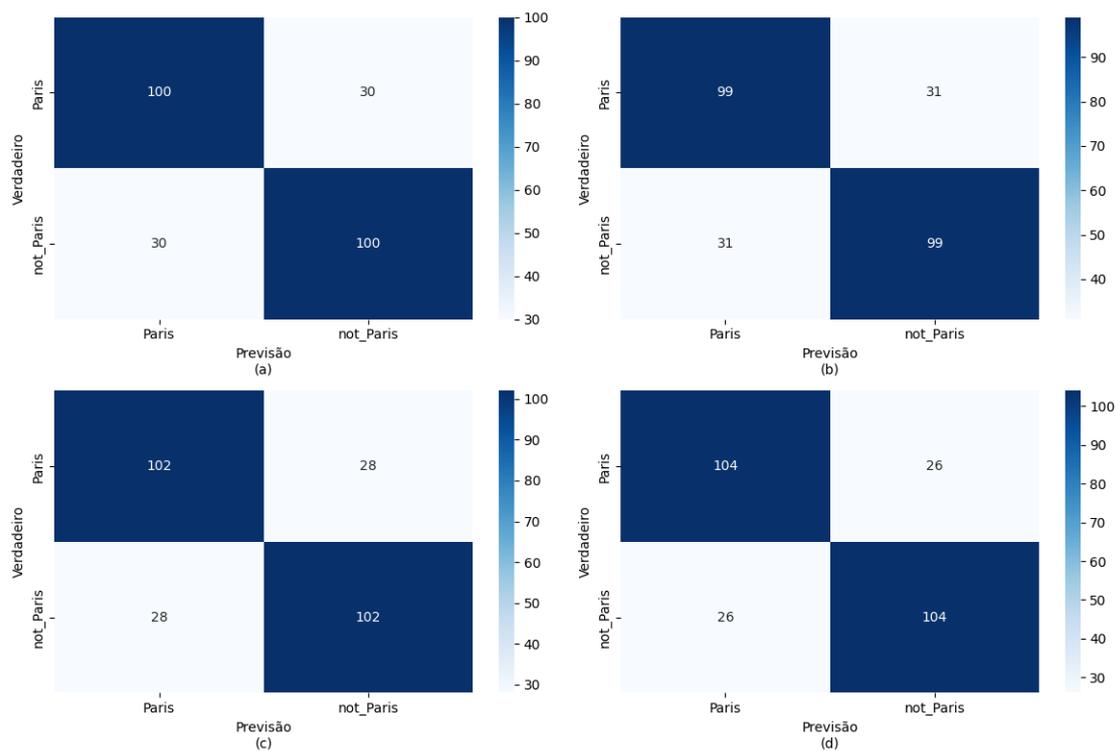


Figura 27: Matrizes de confusão combinadas dos Experimentos (a) 1, (b) 2, (c) 3 e (d) 4, mostrando o desempenho da rede neural convolucional na classificação das obras de Van Gogh produzidas em Paris.

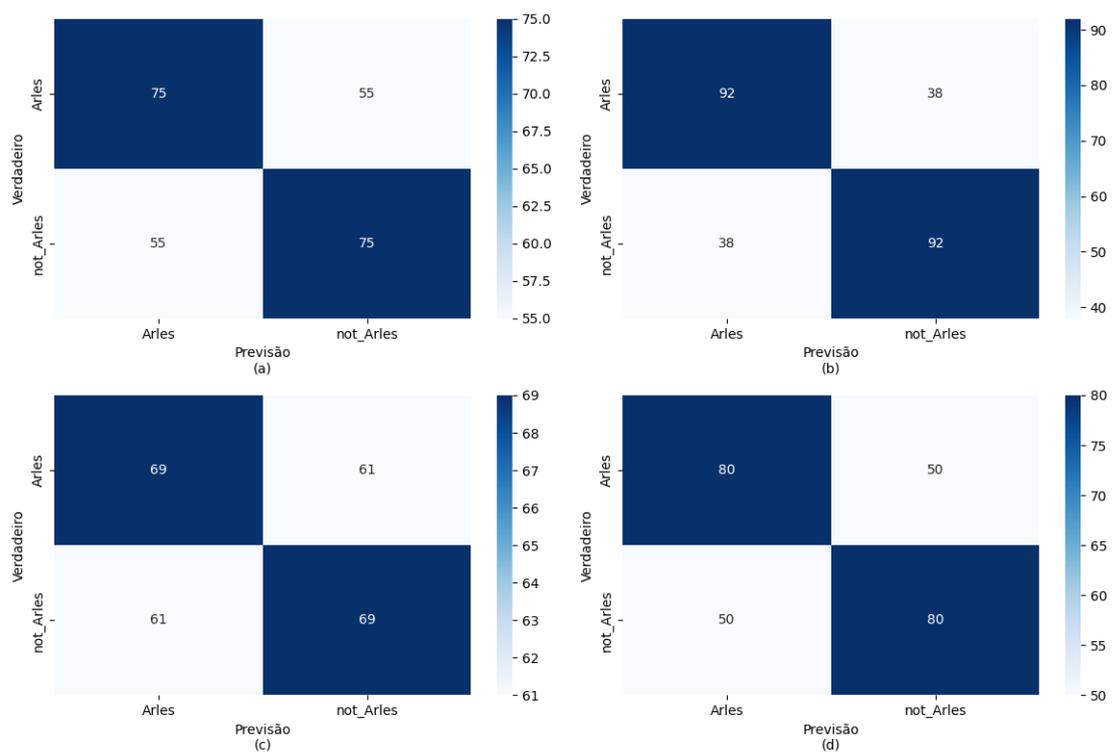


Figura 28: Matrizes de confusão combinadas dos Experimentos (a) 1, (b) 2, (c) 3 e (d) 4, mostrando o desempenho da rede neural convolucional na classificação das obras de Van Gogh produzidas em Arles.

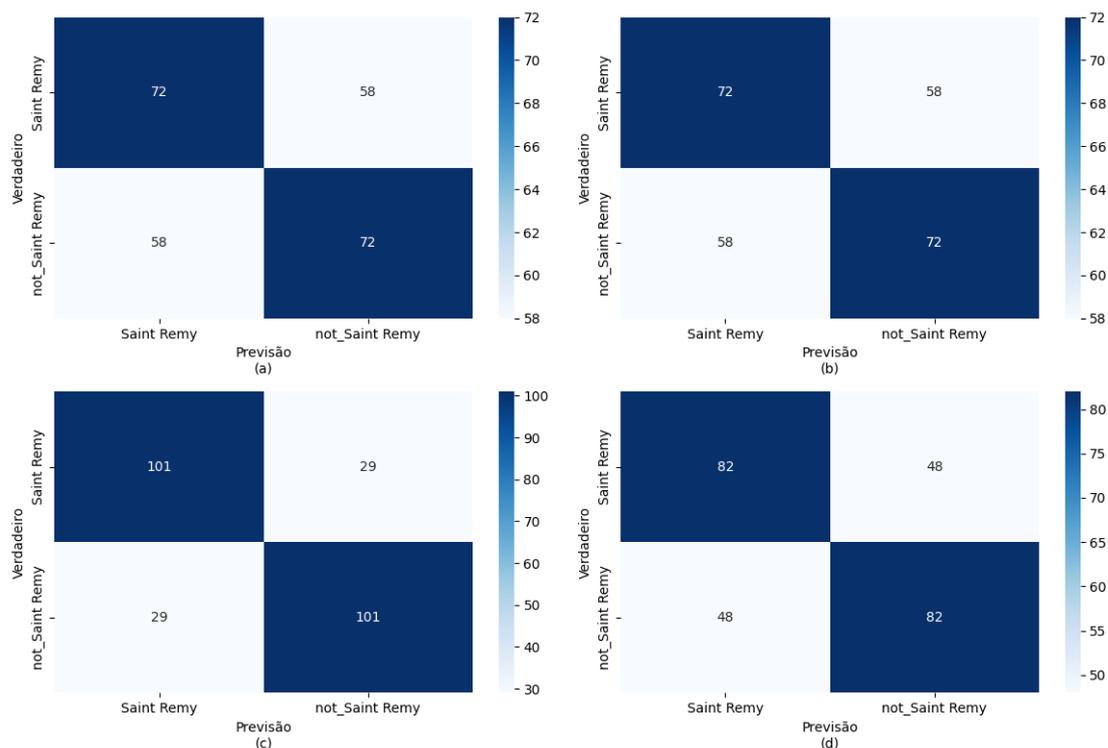


Figura 29: Matrizes de confusão combinadas dos Experimentos (a) 1, (b) 2, (c) 3 e (d) 4, mostrando o desempenho da rede neural convolucional na classificação das obras de Van Gogh produzidas em Saint-Rémy-de-Provence.

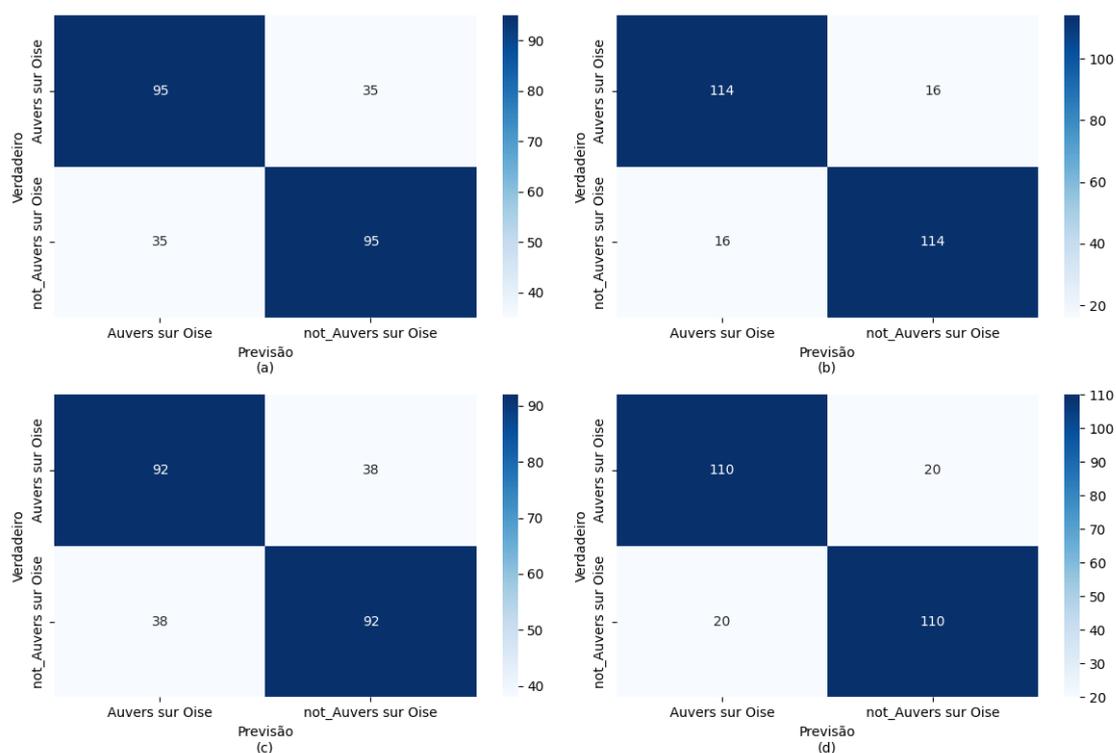


Figura 30: Matrizes de confusão combinadas dos Experimentos (a) 1, (b) 2, (c) 3 e (d) 4, mostrando o desempenho da rede neural convolucional na classificação das obras de Van Gogh produzidas em Auvers Sur Oise.

7 DISCUSSÃO

Esse Capítulo traz algumas discussões com base nos resultados dessa pesquisa. Nas primeiras cinco Seções desse Capítulo são discutidos os resultados de acordo com cada período proposto nessa pesquisa. Na última Seção é feita a análise da rede neural implementada nas obras de Van Gogh.

7.1 Nuenen

Os resultados de Nuenen apontam para uma paleta de cores de Van Gogh predominantemente composta por tons escuros. Suas obras desse período eram nitidamente escuras, o que não estava em sintonia com o estilo brilhante do impressionismo da época. Além disso, Van Gogh produziu diversas obras de retratos de camponeses, retratando expressões de cansaço. Tal característica sugere um interesse pela condição humana e uma tentativa de se conectar com os outros através de sua arte. As paisagens, embora menos frequentes, também costumavam apresentar cores apagadas e uma atmosfera de quietude, o que pode refletir um estado emocional introspectivo.

Os resultados da análise de textura e padrão de pinceladas observadas por essa pesquisa apontam que as obras de Van Gogh produzidas em Nuenen apresentam um contraste relativamente alto, sugerindo diferenças significativas de intensidade entre *pixels* vizinhos, com as direções diagonais mostrando ligeiramente mais contraste que a horizontal e vertical. A dissimilaridade é moderada, indicando variações locais de intensidade não tão extremas quanto o contraste, com a direção horizontal exibindo valores mais baixos. A homogeneidade não é muito alta, o que é esperado em pinturas com pinceladas visíveis, sendo menor nas direções diagonais. A energia e o ASM são baixos, sugerindo texturas pouco uniformes e não repetitivas, com uma ligeira tendência a menor energia nas diagonais. A correlação é alta, indicando uma forte relação linear entre *pixels* vizinhos, apesar da textura visível, sendo mais forte na direção horizontal.

No contexto de sua vida pessoal, esse momento é marcado pelo retorno de Van Gogh a casa de seus pais após um período em que morou em outra cidade. Em algumas cartas escritas por Van Gogh, este relata que sentia-se um intruso em sua casa, comparando-

se como um cachorro grande e peludo que não era bem vindo. Por outro lado, seus pais tinham dificuldades em conviver com ele em virtude de seus hábitos desorganizados. Esse cenário permite inferir que o ambiente doméstico eram instável, o que possivelmente contribuiu para seu estado de isolamento emocional [52].

Apesar das relações familiares conturbadas, Nuenen ofereceu a Van Gogh um ambiente propício para o desenvolvimento de sua arte como “pintor de camponeses”. A região abrigava uma vasta comunidade de agricultores, trabalhadores rurais e tecelões, que se tornaram os principais sujeitos de suas pinturas e desenhos. Van Gogh sentia uma profunda admiração pelo estilo de vida honesto e simples dessas pessoas e desejava retratar suas vidas com autenticidade, sem qualquer idealização. Essa imersão na vida camponesa pode ser vista como uma busca por um senso de propósito e autenticidade, em contraste com suas próprias dificuldades emocionais e sociais. Inicialmente, seu pai providenciou um pequeno estúdio para Vincent. No entanto, devido a desentendimentos com o pai, Van Gogh procurou outro espaço para trabalhar. Após a morte de seu pai em março de 1885, Van Gogh mudou-se para este estúdio, onde pintaria sua obra mais emblemática desse período, “Os Comedores de Batata”. A necessidade de mudar de estúdio devido a conflitos familiares remete a falta de estabilidade e espaço pessoal em sua vida, o que provavelmente aumentou seus conflitos emocionais [52].

A estadia em Nuenen também foi marcada pelo relacionamento amoroso com uma vizinha, doze anos mais velha. Esta era considerada emocionalmente instável. O relacionamento enfrentou forte oposição de ambas as famílias e terminou tragicamente no verão de 1884, com uma tentativa de suicídio da vizinha. Essa experiência dolorosa e traumática pode ter intensificado os sentimentos de solidão que Van Gogh já poderia estar vivenciando. Além disso, o envolvimento com uma das modelos para a obra “Os Comedores de Batata” gerou escândalo na comunidade, com rumores de uma possível gravidez e a reação negativa do pároco local, que tentou impedir os moradores de posarem para Van Gogh. Esse acontecimentos podem ter contribuiu ainda mais para o seu isolamento [52].

A morte de seu pai em março de 1885 foi uma perda significativa. Van Gogh chegou a adaptar uma pintura da igreja de seu pai após sua morte, adicionando figuras de camponeses em luto. Este ato sugere uma forma de processar o luto e uma possível mudança em seu foco artístico para temas de perda e mortalidade. Em novembro de 1885, Van Gogh tomou a decisão de deixar Nuenen. Sua principal motivação era o desejo de se desenvolver como artista, esperando encontrar um ambiente mais estimulante e oportunidades para vender seu trabalho e continuar seus estudos. Essa mudança representava uma busca por crescimento artístico e uma possível necessidade de escapar do ambiente emocionalmente carregado de Nuenen [52].

7.2 Paris

Os resultados encontrados ao analisar os dados de Paris em relação a paleta de cores indica um padrão semelhante a Nuenen, mas com uma ligeira transição para tons mais claros. Ainda percebe-se uma tonalidade mais escura sugerindo o predomínio de uma atmosfera mais sombria. No entanto, já é possível observar influência do movimento impressionista com tonalidades vibrantes e luminosas.

Os resultados propostos pela análise de textura e pinceladas dessa pesquisa sugerem um aumento no contraste e na dissimilaridade em comparação a Nuenen, indicando variações de intensidade mais acentuadas, especialmente nas diagonais. A homogeneidade é ligeiramente mais baixa, sugerindo uma menor uniformidade nas texturas. A energia e o ASM são mais altos, embora ainda indiquem uma ausência de padrões fortemente repetitivos. A correlação permanece alta, com a direção horizontal mostrando uma correlação mais forte. Essa fase parece indicar uma mudança no estilo de pincelada, com maior ênfase em variações horizontais.

Em Paris, Van Gogh foi morar com seu irmão Theo. A relação com Theo foi fundamental para Van Gogh, que dependia do apoio financeiro e emocional do irmão para se dedicar à pintura. Theo, com suas conexões no mundo da arte, também proporcionou a Vincent acesso a novas ideias e a outros artistas. No entanto, a convivência nem sempre foi fácil, e a personalidade intensa de Vincent, juntamente com suas lutas internas, geraram tensões na relação com Theo. Ao chegar a Paris, Van Gogh mergulhou no vibrante cenário artístico da cidade. Ele visitou museus e galerias com frequência, buscando inspiração e familiarizando-se com as obras dos mestres antigos, como Rembrandt e Delacroix, que o impressionaram profundamente. Ele também teve seu primeiro contato direto com o trabalho dos impressionistas, cujas cores claras e pinceladas soltas inicialmente o deixaram cético. Em uma carta à sua irmã Willemien, Van Gogh expressou sua decepção inicial com os impressionistas, achando suas obras descuidadas e desagradáveis. No entanto, essa primeira impressão logo começou a mudar à medida que ele se tornava mais familiarizado com os princípios e as técnicas do impressionismo [52].

A análise da obra de Van Gogh durante o período parisiense revela possíveis conexões entre seu estilo de pintura e seus estados emocionais. A transição para o uso de cores vibrantes e luminosas, característico de sua fase impressionista, pode ser interpretado de diversas maneiras. Por um lado, reflete a influência do impressionismo e sua busca pela representação da luz e da atmosfera. O contato com seu irmão, artistas do movimento impressionista pode ter contribuído positivamente para o estado emocional. Por outro lado, o uso de cores intensas pode ter sido uma forma de expressar um desejo de vitalidade e de superar uma possível escuridão interior. Em suas cartas desse período, Van Gogh frequentemente associava a cor à vitalidade e ao entusiasmo pela vida.

A intensidade e a energia de suas pinceladas também podem ser vistas como um re-

flexo de sua turbulência emocional. A pincelada vigorosa e, por vezes, agitada pode transmitir uma sensação de conflito interno e de luta. A maneira como ele aplicava a tinta na tela, com camadas espessas e texturizadas, confere uma qualidade palpável às suas emoções, como se a própria tinta carregasse o peso de seus sentimentos.

A escolha de temas também pode ser significativa. Semelhante ao período holandês, as paisagens urbanas de Paris, com seus cafés e ruas movimentadas, podem ter representado uma tentativa de se conectar com o mundo ao seu redor, de encontrar beleza e interesse na vida cotidiana. Os auto-retratos, que ele pintou em grande número durante esse período, podem ser vistos como uma forma de auto-exame e de expressão de sua identidade e de seus estados emocionais em constante mudança. A natureza morta, com sua representação de objetos simples e cotidianos, pode ter oferecido a Van Gogh uma sensação de ordem e controle em um mundo interior que ele talvez sentisse caótico. A maneira como ele organizava e pintava esses objetos pode refletir uma busca por significado e beleza nas coisas mais simples da vida.

7.3 Arles

Os resultados em Arles consolidam a transição para uma paleta de cores mais clara em conformidade com o modelo impressionista, sugerindo um predomínio de cores quentes e intensas, com destaque para amarelos e laranjas vibrantes. De acordo com os resultados observados por esse trabalho, as pinturas do período de Arles mantêm um contraste e uma dissimilaridade altos, semelhantes aos de Paris, com uma tendência a valores mais baixos nessas características nas direções horizontal e vertical. A homogeneidade é baixa, similar a Paris e mais baixa que em Nuenen, novamente com valores maiores nas direções horizontal e vertical. A energia e o ASM permanecem baixos, indicando texturas pouco uniformes, com uma tendência a valores mais baixos nas direções diagonais. A correlação é alta, semelhante aos períodos anteriores, mas com uma correlação mais alta nas direções horizontal e vertical.

Nesse período, o estilo de pintura de Van Gogh passou por uma evolução significativa, desenvolvendo um estilo expressivo e individual por meio de cores ousadas e pinceladas dinâmicas. As suas pinceladas tornaram-se pesadas, modeladas e rítmicas. Van Gogh preferia usar a cor como uma expressão dos seus sentimentos, empregando pinceladas rápidas e dinâmicas para capturar a energia e a emoção das cenas que retratava. A incorporação de cores e estilos introduzidos pelos impressionistas observada em Paris fundiu-se com a sua paixão por pintar ao ar livre exercitada em Nuenen. Essa mudança no seu estilo pode ser interpretada como uma manifestação visual da sua crescente intensidade emocional e possivelmente da turbulência interior associada ao seu estado emocional [52].

Paul Gauguin, pintor francês, chegou a Arles em 23 de outubro, após repetidos convites de Van Gogh. Eles viveram e pintaram juntos por cerca de dois meses. Inici-

almente, foi um período de grande inspiração mútua, com ambos artistas pintando os mesmos temas. O entusiasmo inicial pela colaboração pode ter levado a um período de experimentação e trocas artísticas, potencialmente influenciando os estilos um do outro. No entanto, as suas visões artísticas e filosofias pessoais muitas vezes chocavam, levando a discussões. A crescente tensão e os desentendimentos artísticos podem ter contribuído para os problemas emocionais de Van Gogh. Esse contexto pode ter se manifestado na sua arte através de pinceladas mais agitadas ou paletas de cores mais escuras em certas obras. O relacionamento deles deteriorou-se consideravelmente. Em 23 de dezembro de 1888, Van Gogh perseguiu Gauguin com uma navalha e depois cortou parte do seu próprio lóbulo da orelha esquerda. Gauguin deixou Arles para sempre após o incidente. Van Gogh foi admitido no hospital de Arles na manhã seguinte a ter cortado a orelha. Foi diagnosticado com “mania aguda com delírio generalizado” pelo hospital. Este evento demonstra uma clara manifestação do estado mental severamente comprometido de Van Gogh [52].

As cartas de Van Gogh ao seu irmão Theo fornecem relatos diretos de sua turbulência emocional. Ele expressou sentimentos de estar “bastante deprimido”. Descreveu “horríveis ataques de ansiedade, aparentemente sem causa, ou então uma sensação de vazio e fadiga na cabeça”. Mencionou “ataques de melancolia e de atroz remorso”. Sentiu “angústia indescritível”. Viveu períodos de prostração ao ponto da exaustão. Expressou o desejo de “nunca mais acordar” devido ao “horror da vida” e à “melancolia”. Sentiu uma “terrível necessidade de religião” e saía à noite para pintar as estrelas. Descreveu-se como se sentindo “falido e louco”. Lamentou a desintegração física e mental que acreditava ser causada pela sua criatividade obsessiva. Segundo seu relato, sentiu-se “tão zangado consigo mesmo porque não conseguia fazer o que gostaria de fazer, e num momento desses sentia-se como se estivesse deitado amarrado pelos pés e mãos no fundo de um poço escuro e profundo, completamente indefeso”. Descreveu também períodos de estar “absolutamente perturbado” [70].

Embora não seja possível realizar um diagnóstico retroativamente, as evidências apresentadas sugerem fortemente que Vincent Van Gogh experimentou perturbações de humor consistentes com o transtorno de humor bipolar durante sua estadia em Arles. Os temas recorrentes de ansiedade, melancolia, desespero e auto-reprovação nas suas cartas, a mudança acentuada da paleta de cores mais clara e quente, o aumento expressivo da quantidade de novas obras, a intensidade nas relações interpessoais com forte oscilações destas, a ocorrência de episódios de delírio e automutilação podem indicar o período de mania característico de episódio maníacos do transtorno bipolar.

7.4 Saint-Rémy-Provence

Os resultados da paleta de cores em Saint-Rémy-Provence apontam para a continuidade de uma paleta de cores claras com cores vivas, mantendo padrão semelhante a Arles. A investigação do padrão de pinceladas e textura sugere que as obras de Van Gogh continuam a apresentar alto contraste e dissimilaridade, com as pinceladas nas diagonais mostrando maior contraste e a direção horizontal exibindo menor variação local de intensidade. A homogeneidade permanece baixa, com uma tendência a valores mais altos nas direções horizontais e verticais. A energia e o ASM são baixos, indicando a persistência de texturas não uniformes. A correlação é alta, com a direção horizontal mostrando valores mais altos. Essa fase reforça a tendência de forte correlação entre *pixels* no sentido horizontal.

Vincent Van Gogh chegou a Saint-Rémy-Provence em maio de 1889. Ele se internou voluntariamente em um hospital psiquiátrico após uma grande crise mental em Arles. Apesar de sua instabilidade emocional, este período foi um dos mais produtivos de sua carreira artística. Em seu pequeno quarto de hospital, ele produziu cerca de 150 pinturas e inúmeros desenhos, incluindo obras famosas como “A Noite Estrelada, Ramo de Amendoeira em Flor e Íris”. Saint-Rémy tornou-se, assim, um cenário fundamental na vida do artista, onde a beleza da paisagem provençal contrastava fortemente com a sua turbulência interior. A decisão de Van Gogh de se internar voluntariamente sugere um certo nível de autoconsciência e um desejo de procurar ajuda em meio à sua angústia mental. Em vez de ser forçado a se submeter a tratamento, ele tomou a iniciativa, indicando um reconhecimento de que sua condição exigia cuidados profissionais após um episódio grave [52].

A relativa liberdade e o acesso a um estúdio dentro do hospital provavelmente facilitaram sua continuidade na produção artística. A disponibilidade de um estúdio privado e a permissão posterior para pintar ao ar livre foram fatores importantes nessa continuidade. Isso sugere que um ambiente de apoio, mesmo dentro do confinamento, pode fomentar a criatividade. A vista de sua janela inspirou muitas pinturas de paisagens. O uso proeminente de azuis e amarelos em muitas pinturas de Saint-Rémy, incluindo “A Noite Estrelada”, pode refletir um estado emocional ou psicológico específico, potencialmente uma mistura de ansiedade, por meio da cor azul, e um anseio por luz ou esperança, com a utilização da cor amarela. A combinação recorrente de azuis e amarelos vívidos em obras icônicas deste período é notável. O azul é frequentemente associado à melancolia ou introspecção, enquanto o amarelo pode simbolizar energia, otimismo ou até intensidade. Sua justaposição pode representar a complexa interação das emoções de Van Gogh durante seu tempo no asilo, oscilando entre o desespero e momentos de clareza ou inspiração. Além disso, as pinceladas energéticas e em espiral podem ser interpretadas como uma manifestação visual de sua turbulência interior e estado emocional

intensificado[52].

7.5 Auvers-sur-Oise

Van Gogh chegou a Auvers-sur-Oise no mês de maio de 1890. A sua decisão de se mudar para esta aldeia a norte de Paris foi motivada por vários fatores. Principalmente, procurava estar mais perto do seu irmão Theo, que vivia em Paris, permitindo-lhes visitas frequentes. Além disso, Theo providenciou para que Van Gogh ficasse sob os cuidados do Dr. Paul Gachet, um médico com interesse em arte e amigo de pintores, que poderia supervisionar a sua saúde. Inicialmente, Van Gogh teve impressões positivas da aldeia, descrevendo-a como bela e notando a presença de antigas casas com telhados de colmo e os belos campos que a rodeavam. Esta reação inicial positiva sugere uma possível melhoria no seu humor após a chegada, talvez impulsionada pela esperança de um ambiente mais estável e uma renovada inspiração artística [52].

Os resultados dessa pesquisa em relação a paleta de cores no período em Auvers-sur-Oise mostram o uso de cores com tonalidade mais clara, caracterizado pelo uso de tons ousados, vibrantes e frequentemente saturados. As suas obras desse período exploram diversos temas. As paisagens, particularmente os campos de trigo, ocupam um lugar proeminente, como se observa em obras como “Campo de Trigo com Corvos e Campo de Trigo sob Céu Tempestuoso”. Os retratos também foram um foco significativo, incluindo pessoas do seu cotidiano como o Dr. Paul Gachet. A utilização de cores contrastantes era uma característica notável, empregada para criar ressonância emocional. Esta intensidade aumentada e a profundidade emocional transmitida pelas suas escolhas de cores vibrantes podem ser interpretadas como um reflexo da sua turbulência emocional interior, com as cores a servirem talvez como uma saída direta para sentimentos que não conseguia expressar verbalmente. O uso de cores puras e saturadas pode indicar um desejo de intensificar a sua percepção do mundo, possivelmente como uma forma de contrariar sentimentos de distanciamento ou apatia associados à depressão.

Os resultados proposto por esse estudo sugerem que as obras de Auvers-sur-Oise mantiveram um padrão alto de contraste e dissimilaridade, comparáveis aos períodos anteriores, com a direção horizontal tendendo a apresentar menor contraste e dissimilaridade. A homogeneidade é baixa, com a direção horizontal mostrando valores mais altos. A energia e o ASM são baixos, indicando a continuidade de texturas pouco uniformes, com uma ligeira tendência a maior energia na direção horizontal e menor uniformidade na diagonal para o ASM. O atributo energia apresentou uma escala de menores valores absolutos, o que pode sinalizar o momento de grande instabilidade emocional apontado pelos relatos documentais dessa época. A correlação é alta, com a direção horizontal mostrando uma correlação maior. Essa fase final continua a exhibir as características de pinceladas expressivas e texturizadas, com nuances específicas nas diferentes direções analisadas.

As suas pinceladas eram tipicamente agitadas, irregulares, rodopiantes e altamente. Esta técnica criava textura, movimento e dinamismo emocional. A pincelada enérgica e frequentemente turbulenta pode ser uma manifestação visual da sua inquietação e ansiedade interior. A aplicação espessa de tinta pode sugerir uma necessidade forte e urgente de se expressar. Os céus ameaçadores e a pincelada agitada podem simbolizar a sua agitação mental, e os padrões rodopiantes podem refletir uma sensação de estar sobrecarregado ou preso num vórtice de emoções negativas.

7.6 Considerações acerca da Rede Neural Convolutional

Os resultados gerais dos quatro experimentos, ao tentar classificar as obras entre as cinco cidades, revelaram desafios significativos na generalização dos dados, com indícios de *overfitting* em parte dos casos. O experimento 2, com aumento da taxa de aprendizado, demonstrou um melhor equilíbrio entre a acurácia de treinamento e validação, mas nenhum dos modelos conseguiu atingir um desempenho consistentemente alto em todas as métricas. As matrizes de confusão indicaram uma dificuldade particular em classificar as obras de Saint-Rémy-Provence, enquanto as pinturas de Arles e Auvers sur Oise foram geralmente classificadas com maior precisão, sugerindo que certas características visuais podem ser mais distintivas para esses períodos.

Um ponto interessante dessa análise é que, de modo geral, as obras produzidas em Arles, Saint-Rémy-Provence e Auvers sur Oise relacionam-se entre si, tanto considerando respostas certas como erradas em todos os experimentos. Tendo em vista que esses períodos podem ser considerados de maior instabilidade emocional, pode-se inferir que há possibilidade de haver uma relação entre as pinturas dessa época com o estado emocional de Van Gogh.

Ao focar a análise em cada cidade individualmente, os resultados apresentaram variações interessantes. O modelo demonstrou um bom desempenho na classificação das obras do período de Nuenen em todas as configurações experimentais. Para Paris e Arles, houve uma ligeira variabilidade no desempenho entre os diferentes experimentos, com algumas configurações se mostrando mais eficazes do que outras. Contudo, houve dificuldade em classificar as obras de Saint-Rémy-de-Provence, reforçando a ideia de que as características visuais desse período podem ser menos distintas ou mais complexas de serem capturadas pelo modelo. Já para Auvers sur Oise, alguns experimentos específicos apresentaram resultados promissores.

8 CONCLUSÃO

A presente dissertação investigou a aplicação de técnicas computacionais, em especial o aprendizado de máquina, na análise das obras de Vincent Van Gogh, com o objetivo de identificar possíveis correlações entre características visuais, documentais e os transtornos mentais que o artista enfrentou ao longo de sua vida.

A análise das obras de Van Gogh revelou padrões que, em alguns casos, corroboram com interpretações existentes baseadas na história da arte e na biografia do artista, enquanto em outros, sugerem novas perspectivas. Os resultados obtidos mostram uma transição da paleta de cores de tons escuros para tonalidades mais claras ao longo dos períodos considerados. Também observou-se que, ao investigar os padrões de pinceladas e textura, o contraste e a dissimilaridade tendem a ser mais elevados nas pinturas produzidas em Paris, Arles e Saint-Rémy-Provence. A homogeneidade tende a ser menor em Arles e Saint-Rémy, indicando imagens menos uniformes. A energia se mantém baixa em todas as cidades, sugerindo texturas não muito repetitivas. A correlação é consistentemente alta em todos os períodos. O atributo energia apresentou os piores índices nas obras produzidas em Saint-Rémy, o que pode estar relacionado ao período de maior intensidade de suas dificuldades emocionais, conforme documentado em suas cartas e análises biográficas.

Nesse contexto, em relação as direções das pinceladas, não observou-se um padrão distinto relevante entre os períodos avaliados. Identificou-se uma maior variação de intensidade na direção horizontal e vertical na homogeneidade, energia correlação e ASM e, na direção das diagonais no contraste e dissimilaridade. Os ângulos de 45° e 135° , referentes as diagonais, apresentaram comportamento muito semelhantes.

A análise da aplicação de uma rede neural convolucional mostra a complexidade em se estabelecer um padrão para as obras de Van Gogh. De modo geral, os experimentos propostos apresentam desempenho baixo no qual, em muitas casos, chegando a um estado de *overfitting*. Ao se comparar todas os períodos nos mesmos experimentos, observou-se um padrão interessante entre as pinturas de Rémy-de-Provence e Auvers-sur-Oise no qual, a rede implementada concentrou-se em relacioná-las tanto nos casos de acerto como de erro. Essa característica também pode estar relacionada com os momentos de maior

dificuldade emocional que Van Gogh vivenciou, de acordo com a análise documental.

Esta pesquisa se alinha com uma crescente onda de estudos que aplicam métodos computacionais para buscar objetividade e novas perspectivas em um campo tradicionalmente dominado pela análise qualitativa. Esta dissertação busca contribuir para essa área, oferecendo uma metodologia e resultados que podem servir de base para futuras pesquisas. É crucial notar que, enquanto a análise computacional pode revelar padrões, a interpretação desses padrões requer uma compreensão tanto das técnicas de aprendizado de máquina quanto do contexto histórico, artístico e psicológico da obra analisada.

É importante ressaltar também que a arte é uma forma complexa de expressão, influenciada por diversos fatores além do estado mental, incluindo influências artísticas, contexto social e cultural, e a própria evolução do estilo do artista. No entanto, a consistência com que certos padrões emergem da análise de aprendizado de máquina sugere que o estado psicológico de Van Gogh pode ter desempenhado um papel significativo na formação de sua linguagem visual.

Apesar de alguns resultados interessantes, é importante pontuar algumas limitações. Primeiramente, a disponibilidade e a natureza dos dados sobre o estado mental de Van Gogh são limitados. Depende-se de suas cartas, relatos de terceiros e diagnósticos retrospectivos, que podem ser subjetivos e incompletos. Em segundo lugar, a escolha das características visuais extraídas das pinturas e as técnicas de aprendizado de máquina utilizadas podem influenciar os resultados. Diferentes abordagens podem levar a diferentes conclusões, e é importante explorar uma variedade de métodos para obter uma compreensão mais robusta. Tendo em vista a complexidade computacional necessária para realizar as análises, somente algumas possibilidades foram investigadas.

Esta pesquisa pode servir para futuras investigações. Uma direção promissora seria a aplicação das mesmas metodologias à obra de outros artistas que também enfrentaram transtornos mentais, permitindo comparações e a identificação de padrões mais gerais. A exploração de outras técnicas de aprendizado de máquina para analisar a evolução do estilo de Van Gogh ao longo do tempo também pode ser relevante.

REFERÊNCIAS

- [1] Amawi, R. M. and Murdoch, M. J. (2022). Understanding color associations and their effects on expectations of drugs' efficacies. *Pharmacy (Basel)*, 10(4):82.
- [2] American Psychiatric Association (2013). *Diagnostic and Statistical Manual of Mental Disorders: DSM-5*. American Psychiatric Association.
- [3] American Psychiatric Association (2014). *Manual Diagnóstico e Estatístico de Transtornos Mentais: DSM-5*. Artmed, Porto Alegre. Tradução da 5ª edição americana.
- [4] Asare, K. O., Terhorst, Y., Vega, J., Peltonen, E., Lagerspetz, E., and Ferreira, D. (2021). Predicting depression from smartphone data: A longitudinal exploratory study. *JMIR Mhealth Uhealth*.
- [5] Azeemi, S. T. Y., Rafiq, H. M., Ismail, I., Kazmi, S. R., and Azeemi, A. (2019). The mechanistic basis of chromotherapy: Current knowledge and future perspectives. *Complementary Therapies in Medicine*, 46:217–222.
- [6] Barlow, D. H., Durand, V. M., and Hofmann, S. G. (2021). *Psicopatologia: Uma Abordagem Integrada*. Cengage Learning, Brasil, 8 edition. Tradução da 8ª edição norte-americana.
- [7] Barrett, L. F. (2017). *How Emotions Are Made: The Secret Life of the Brain*. Houghton Mifflin Harcourt.
- [8] Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- [9] Boureau, Y.-L., Ponce, J., and LeCun, Y. (2010). A theoretical analysis of feature pooling in visual recognition. In *Proceedings of the 27th international conference on machine learning (ICML-10)*, pages 111–118.
- [10] Bourke, P. (1988). *RGB Coordinates of the CIE 1931 Chromaticity Diagram*. Australian National University.

- [11] Britannica, E. (2024). Catharsis — psychological release, emotional purging & tragedy. Acessado: 28-07-2024.
- [12] Cannon, W. B. (1927). The james-lange theory of emotions: A critical examination and an alternative theory. *American Journal of Psychology*, 39(1/4):106–124.
- [13] Cherry, K. (2024a). Color psychology: Does it affect how you feel? Accessed: 2023-07-24.
- [14] Cherry, K. (2024b). James-lange theory of emotion. *Verywell Mind*.
- [15] Chung, Y. J. and Teo, A. R. (2022). Artificial intelligence in mental health care: a systematic review of diagnosis, monitoring, and intervention applications. *Psychological Medicine*, pages 1–18.
- [16] DAVIES, S. (2015). Defining art and artworlds. *The Journal of Aesthetics and Art Criticism*.
- [17] Ebner, M. (2007). *Color Constancy*. John Wiley & Sons.
- [18] Editors, S. (2024). Poetics: Katharsis and its function in tragedy. Acessado: 28-07-2024.
- [19] Ekman, P. (1992). An argument for basic emotions. *Cognition and Emotion*, 6(3-4):169–200.
- [20] Ekman, P. and Friesen, W. V. (1971). Constants across cultures in the face and emotion. *Journal of Personality and Social Psychology*, 17(2):124–129.
- [21] Elliot, A. J. (2015). Color and psychological functioning: a review of theoretical and empirical work. *Frontiers in Psychology*, 6.
- [22] Elliot, A. J. and Aarts, H. (2011). Perception of the color red enhances the force and velocity of motor output. *Emotion*, 11(2):445–449.
- [23] Elliot, A. J., Maier, M. A., Moller, A. C., Friedman, R., and Meinhardt, J. (2007). Color and psychological functioning: the effect of red on performance attainment. *Journal of Experimental Psychology: General*, 136(1):154–168.
- [24] Emani, R., Ghavami, H., Radfar, M., and Khalkhali, H. R. (2020). Impact of chromotherapy on professional quality of life in intensive care unit nurses: a randomized controlled trial. *Fatigue: Biomedicine, Health Behavior*, 8(3):121–129.
- [25] Faceli, K., Lorena, A. C., Gama, J., and de Leon Ferreira de Carvalho, A. C. P. (2011). *Inteligência artificial: uma abordagem de aprendizado de máquina*. LTC, Rio de Janeiro.

- [26] Fairchild, M. D. (2005). *Color Appearance Models*. Wiley-Interscience.
- [27] Foucault, M. (2006). *Madness and civilization: A history of insanity in the age of reason*. Routledge.
- [28] Frank, M. G. and Gilovich, T. (1988). The dark side of self- and social perception: black uniforms and aggression in professional sports. *Journal of Personality and Social Psychology*, 54(1):74–85.
- [29] Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep learning*. MIT press.
- [30] Hassib, M., Hossam, N., Sameh, J., and Torki, M. (2022). Aradepsu: Detecting depression and suicidal ideation in arabic tweets using transformers. In *Proceedings of the Seventh Arabic Natural Language Processing Workshop (WANLP)*, Abu Dhabi, United Arab Emirates (Hybrid). Association for Computational Linguistics.
- [31] Hemphill, M. (1996). A note on adults' color-emotion associations. *The Journal of Genetic Psychology*, 157(3):275–280.
- [32] Iyortsuun, N. K., Kim, S.-H., Jhon, M., Yang, H.-J., and Pant, S. (2023). A review of machine learning and deep learning approaches on mental health diagnosis. *Healthcare*, 17(3):285.
- [33] Izard, C. E. (2010). The many meanings/aspects of emotion: Definitions, functions, activation, and regulation. *Emotion Review*, 2(4):363–370.
- [34] Jonauskaite, D., Abu-Akel, A., Dael, N., and et al. (2020a). Universal patterns in color-emotion associations are further shaped by linguistic and geographic proximity. *Psychological Science*.
- [35] Jonauskaite, D., Abu-Akel, A., and Mohr, C. (2020b). Universal patterns in color-emotion associations are further shaped by linguistic and geographic proximity. *Psychological Science*.
- [36] Jung, C. G. (1964). *Man and His Symbols*. Dell Publishing.
- [37] Karpathy, A., Toderici, G., Shetty, S., Leung, T., Sukthankar, R., and Fei-Fei, L. (2014). Large-scale video classification with convolutional neural networks. In *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*, pages 1725–1732.
- [38] Kaya, N. and Epps, H. H. (2004). Relationship between color and emotion: A study of college students. *College Student Journal*, 38(3):396–405.
- [39] Kim, A. (2022). Van gogh paintings dataset. Mendeley Data.

- [40] Kim, S.-H., Lee, J.-H., and Kim, E.-J. (2022). Machine learning models for predicting risk of depression in korean college students: Identifying family and individual factors. *Frontiers in Psychology*, 13:1–12.
- [41] Knafo, D. (2012). Dancing with the unconscious: The art of psychoanalysis and the psychoanalysis of art. *The American Journal of Psychoanalysis*, 74:275–291.
- [42] Kozbelt, A. (2016). Creativity and culture in visual art. *SpringerLink*.
- [43] Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, pages 1097–1105.
- [44] Kumar, Y., Kumar, R., Kumar, R., Kumawat, R., Soren, N., Jangir, S. K., and Singh, T. (2024). A review on image forgery detection techniques using machine learning. *7th International joint conference on computing sciences*.
- [45] LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324.
- [46] Lee, C. and Kim, H. (2022). Machine learning-based predictive modeling of depression in hypertensive populations. *PLOS ONE*.
- [47] Lilley, E. (2008). A rediscovered english review of the 1874 impressionist exhibition. *The Burlington Magazine*, 150(1260):172–175.
- [48] Liu, Xiaoming, Wang, Li, Chen, and Jianping (2021a). Identification of diagnostic markers for major depressive disorder using machine learning methods. *Frontiers in Neuroscience*.
- [49] Liu, X., Wang, L., and Chen, J. (2021b). Use of machine learning approach to predict depression in the elderly from the chinese longitudinal healthy longevity survey (clhls). *Journal of Affective Disorders*.
- [50] Long, J., Shelhamer, E., and Darrell, T. (2015). Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3431–3440.
- [51] Mazza, C., Ricci, E., Biondi, S., Colasanti, M., Ferracuti, S., Napoli, C., and Roma, P. (2022). Depression and anxiety during the covid-19 pandemic: Epidemiology, mechanism, and treatment. *Neuroscience Bulletin*.
- [52] Naifeh, S. and Smith, G. W. (2011). *Van Gogh: A vida*. Random House.

- [53] Nair, V. and Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. *Proceedings of the 27th international conference on machine learning (ICML-10)*, pages 807–814.
- [54] O’Connor, Z. (2011). Colour psychology and colour therapy: Caveat emptor. *Color Research and Application*, 36(3):229–234.
- [55] Organização Mundial da Saúde (1997). *Classificação Estatística Internacional de Doenças e Problemas Relacionados à Saúde: CID-10*. Edusp, São Paulo. Tradução da 10ª edição internacional.
- [56] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.
- [57] Poynton, C. (2003). *Digital Video and HDTV: Algorithms and Interfaces*. Morgan Kaufmann.
- [58] Python Software Foundation (2023). *Python: A Programming Language*.
- [59] Rahman, H. A., Kwicklis, M., Ottom, M., Amornsriwatanakul, A., Abdul-Mumin, K. H., Rosenberg, M., and Dinov, I. D. (2023). Machine learning-based prediction of mental well-being using health behavior data from university students. *Bioengineering*, 10(5):575.
- [60] Razavi, R., Gharipour, A., and Gharipour, M. (2020). Depression screening using mobile phone usage metadata: a machine learning approach. *Journal of the American Medical Informatics Association*.
- [61] Richter, T., Fishbain, B., Markus, A., Richter-Levin, G., and Okon-Singe, H. (2020). Using machine learning to differentiate cognitive biases in anxiety and depression. *Scientific Reports*, 317:15–27.
- [62] Rogers, C. R. (1961). *On Becoming a Person: A Therapist’s View of Psychotherapy*. Houghton Mifflin Harcourt.
- [63] Rumelhart, D. E., Hinton, G. E., and Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088):533–536.
- [64] Schachter, S. and Singer, J. E. (1962). Cognitive, social, and physiological determinants of emotional state. *Psychological Review*, 69(5):379–399.

- [65] Simjanoski, M. and et al. (2022). Lifestyle predictors of depression and anxiety during covid-19: a machine learning approach. *Trends in psychiatry and psychotherapy*, 44:e20210365.
- [66] Soh, L. F. and Tsatsoulis, C. (1999). Texture analysis of sar imagery using gray level co-occurrence matrices (glcm). *IEEE Transactions on Geoscience and Remote Sensing*, 37(3):1430–1441.
- [67] Taylor, C., Schloss, K., Palmer, S. E., and Franklin, A. (2013). Color preferences in infants and adults are different. *Psychonomic Bulletin and Review*, 20(5):916–922.
- [68] Ugail, H., Stork, D. G., Edwards, H., Seward, S. C., and Brooke, C. (2023). Deep transfer learning for visual analysis and authentication of paintings by raphael. *Heritage Science*.
- [69] van der Walt, S., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., Gouillart, E., Yu, T., and the scikit-image contributors (2014). *scikit-image: Image processing in Python*.
- [70] van Gogh, V. (2025). Vincent van gogh: The complete letters. <https://vggallery.com/letters/main.htm> – Acessado em: 17-03-2025.
- [71] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
- [72] Yang, J. and Shen, X. (2023). The application of color psychology in community health environment design. *Journal of Environmental and Public Health*.
- [73] Zhang, Z. (2023). Early warning model of adolescent mental health based on big data and machine learning. *Soft Computing*, 278:811–828.
- [74] Zhao, Z. (2024). Enhancing artistic analysis through deep learning: a graphic art element recognition model based on ssd and fpt. *PeerJ*.