Análise de texturas dinâmicas baseada em sistemas complexos

Lucas Correia Ribas

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Lucas Correia Ribas

Análise de texturas dinâmicas baseada em sistemas complexos

Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como parte dos requisitos para obtenção do título de Mestre em Ciências – Ciências de Computação e Matemática Computacional. VERSÃO REVISADA

Área de Concentração: Ciências de Computação e Matemática Computacional

Orientador: Prof. Dr. Odemir Martinez Bruno

USP – São Carlos
Junho de 2017

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/ USP,
com os dados fornecidos pelo(a) autor(a)

R482a Ribas, Lucas Correia
Análise de texturas dinâmicas baseada em sistemas complexos / Lucas Correia Ribas; orientador Odemir Martinez Bruno. - São Carlos - SP, 2017.
147 p.

Dissertação (Mestrado - Programa de Pós-Graduação em Ciências de Computação e Matemática Computacional) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, 2017.

1. Textura dinâmica. 2. Sistemas complexos. 3. Redes complexas. 4. Caminhada determinística parcialmente auto-repulsiva. 5. Complexidade. I. Bruno, Odemir Martinez, orient. II. Título.

Lucas Correia Ribas

Dynamic texture analysis based on complex systems

Master dissertation submitted to the Instituto de Ciências Matemáticas e de Computação – ICMC-USP, in partial fulfillment of the requirements for the degree of the Master Program in Computer Science and Computational Mathematics. FINAL VERSION

Concentration Area: Computer Science and Computational Mathematics

Advisor: Prof. Dr. Odemir Martinez Bruno

USP – São Carlos
June 2017

Aos meus pais, Luís e Maria.

AGRADECIMENTOS

Primeiramente, a Deus, pela minha vida e por tudo que tens feito nela.

Aos meus pais, Luís e Maria, pela confiança, apoio e carinho que manifestaram ao longo da minha vida. Apesar da distância e dificuldades, os seus esforços e incentivos me mantêm firme nessa caminhada. Sem vocês, nada disso seria possível.

Ao meu irmão Thiago, por sempre estar ao meu lado.

Ao meu orientador Odemir Martinez Bruno, pela confiança, orientação, amizade e participação ativa na minha formação acadêmica.

Aos amigos de grupo e que fiz na universidade pelos momentos de descontração, discussão e troca de conhecimento.

Aos professores de graduação Amaury A. de Castro Jr e Wesley Nunes Gonçalves por me incentivar a fazer o mestrado e pelas contribuições na minha formação.

Ao Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (ICMC-USP) pela oportunidade, aos professores e funcionários e a todos, que direta ou indiretamente, contribuíram para com este trabalho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro.

“ Eu não tenho ídolos. Tenho admiração por trabalho, dedicação e competência.”
(Ayrton Senna)

RESUMO

RIBAS, L.C.. Análise de texturas dinâmicas baseada em sistemas complexos. 2017. 147 f. Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação (ICMC/USP), São Carlos – SP.

A análise de texturas dinâmicas tem se apresentado como uma área de pesquisa crescente e em potencial nos últimos anos em visão computacional. As texturas dinâmicas são sequências de imagens de textura (i.e. vídeo) que representam objetos dinâmicos. Exemplos de texturas dinâmicas são: evolução de colônia de bactérias, crescimento de tecidos do corpo humano, escada rolante em movimento, cachoeiras, fumaça, processo de corrosão de metal, entre outros. Apesar de existirem pesquisas relacionadas com o tema e de resultados promissores, a maioria dos métodos da literatura possui limitações. Além disso, em muitos casos as texturas dinâmicas são resultado de fenômenos complexos, tornando a tarefa de caracterização um desafio ainda maior. Esse cenário requer o desenvolvimento de um paradigma de métodos baseados em complexidade. A complexidade pode ser compreendida como uma medida de irregularidade das texturas dinâmicas, permitindo medir a estrutura dos pixels e quantificar os aspectos espaciais e temporais. Neste contexto, o objetivo deste mestrado é estudar e desenvolver métodos para caracterização de texturas dinâmicas baseado em metodologias de complexidade advindas da área de sistemas complexos. Em particular, duas metodologias já utilizadas em problemas de visão computacional são consideradas: redes complexas e caminhada determinística parcialmente auto-repulsiva. A partir dessas metodologias, três métodos de caracterização de texturas dinâmicas foram desenvolvidos: (i) baseado em difusão em redes $\mathbb{R}^d$ (ii) baseado em caminhada determinística parcialmente auto-repulsiva $\mathbb{R}^d$ (iii) baseado em redes geradas por caminhada determinística parcialmente auto-repulsiva. Os métodos desenvolvidos foram aplicados em problemas de nanotecnologia e tráfego de veículos, apresentando resultados potenciais e contribuindo para o desenvolvimento de ambas áreas.

Palavras-chave: Textura dinâmica, Sistemas complexos, Redes complexas, Caminhada determinística parcialmente auto-repulsiva, Complexidade.

ABSTRACT

RIBAS, L.C.. Dynamic texture analysis based on complex systems. 2017. 147 f. Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação (ICMC/USP), São Carlos – SP.

Dynamic texture analysis has been an area of research increasing and in potential in recent years in computer vision. Dynamic textures are sequences of texture images (i.e. video) that represent dynamic objects. Examples of dynamic textures are: evolution of the colony of bacteria, growth of body tissues, moving escalator, waterfalls, smoke, process of metal corrosion, among others. Although there are researches related to the topic and promising results, most literature methods have limitations. Moreover, in many cases the dynamic textures are the result of complex phenomena, making a characterization task even more challenging. This scenario requires the development of a paradigm of methods based on complexity. The complexity can be understood as a measure of irregularity of the dynamic textures, allowing to measure the structure of the pixels and to quantify the spatial and temporal aspects. In this context, this masters aims to study and develop methods for the characterization of dynamic textures based on methodologies of complexity from the area of complex systems. In particular, two methodologies already used in computer vision problems are considered: complex networks and deterministic walk partially self-repulsive. Based on these methodologies, three methods of characterization of dynamic textures were developed: (i) based on diffusion in networks $\frac{EM}{GO}$ (ii) based on deterministic walk partially self-repulsive $\frac{EM}{GO}$ (iii) based on networks generated by deterministic walk partially self-repulsive. The developed methods were applied in problems of nanotechnology and vehicle traffic, presenting potencial results and contributing to the development of both areas.

Key-words: Dynamic texture, Complex system, Deterministic walk partially self-repulsive, Complex networks, Complexity.

LISTA DE ILUSTRAÇÕES

Figura 1	– Exemplos de texturas caóticas e complexas obtidas de diagramas espaço-tempo evoluídos de autômatos celulares.	33
Figura 2	– Exemplos de folhas de plantas com nervuras.	34
Figura 3	– Exemplos de alguns vídeos de textura dinâmica representados por cubos. A terceira dimensão representa o movimento da textura dinâmica no tempo. . .	38
Figura 4	– Este grafo possui 5 vértice e 5 arestas, ao aplicarmos a definição C, temos 1 triângulo e 6 triplas conectadas, portanto $C = \frac{3-1}{6} = \frac{1}{2}$	49
Figura 5	– Ilustração da metodologia abordada pelos métodos da literatura que utilizam redes complexas em imagens.	53
Figura 6	– Exemplo da CDPAR com tamanho de memória $\mu = 2$ em uma imagem. Cada círculo representa um pixel com a sua intensidade dentro. Os círculos azuis corresponde ao transiente e os verdes ao atrator.	57
Figura 7	– Exemplos de distribuição conjunta obtidas com $\mu = 5$ e regra de movimento $r = \min$ de duas imagens de textura.	58
Figura 8	– Exemplos de atratores em uma imagem. A região quadriculada azul é o transiente da caminhada e o trecho listrado em verde o atrator.	59
Figura 9	– Ilustração das listas utilizadas para detectar atratores. A Figura(a) exemplifica a lista que guarda a caminhada e a (b) as listas associadas aos pixels.	60
Figura 10	– Tamanho médio das caminhadas para diferentes tamanhos de memória μ . . .	61
Figura 11	– Ilustração geral da metodologia proposta. (1) métodos baseados em redes complexas e CDPARs são desenvolvidos; (2) caracterização das texturas dinâmicas; (3) treinamento e classificação.	63
Figura 12	– Ilustração dos 4 passos do método proposto para reconhecimento de texturas dinâmicas baseado na atividade em redes direcionadas.	65
Figura 13	– Rede regular modelando uma textura dinâmica com três quadros.	66
Figura 14	– Exemplos da aplicação da função $f(t, E)$ sobre as arestas de uma rede regular: (a) Rede regular, (b) $t = 20$, (c) $t = 50$, (d) $t = 80$	68
Figura 15	– Imagens da atividade dos pixels/vértices de uma textura dinâmica, com diferentes raios r e limiares t	70
Figura 16	– Imagens com a atividade do pixel/vértice de várias texturas dinâmicas. A rede foi construída com raio $r = \sqrt{\frac{p}{2}}$ e limiar $t = 120$	71

Figura 17 – Exemplos de distribuições conjuntas obtidas de três texturas dinâmicas (ilustradas pelo primeiro quadro). As texturas dinâmicas foram modeladas em redes com $r = \overset{p}{\bar{2}}$ e $t = 30$	72
Figura 18 – Histograma da atividade correlacionada com o grau de entrada no mesmo quadro $h_m^{r,t}(j)$ e no tempo $h_t^{r,t}(j)$ para quatro classes de texturas dinâmicas. As texturas dinâmicas foram modeladas em redes com $r = \overset{p}{\bar{3}}$ e $t = 100$	74
Figura 19 – Tamanho médio da caminhada em função do limiar e com vários tamanhos de raio para a base Dyntex++.	75
Figura 20 – Ilustração das etapas do método proposto de CDPARs executadas em descritores espacial e temporal para caracterização de texturas dinâmicas.	76
Figura 21 – Ilustração dos descritores espacial e temporal de um vídeo de textura dinâmica. No descritor espacial a CDPAR só pode mover-se em pixels do mesmo quadro, enquanto no descritor temporal a CDPAR só pode mover-se em pixels de diferentes quadros.	77
Figura 22 – Visão geral do método proposto de redes geradas por CDPARs. (1) Uma estratégia de execução é definida; (2) CDPARs são executadas nos vídeos de texturas dinâmicas; (3) redes são geradas e medidas estatísticas são extraídas.	81
Figura 23 – Exemplo de uma CDPAR com memória $\mu = 5$ e regra de movimento $r = \min$ executada em uma imagem em nível de cinza, com a respectiva rede gerada pela caminhada.	83
Figura 24 – Ilustração de redes geradas por CDPARs para os descritores espacial e temporal de um vídeo de textura dinâmica. No descritor espacial as arestas conectam somente vértices que correspondem a pixels do mesmo quadro, enquanto no descritor temporal as arestas ligam vértices referentes a pixels de quadros diferentes.	84
Figura 25 – Ilustração dos três planos ortogonais de um vídeo de textura dinâmica.	84
Figura 26 – Ilustração de redes geradas por CDPARs para modelar os três planos ortogonais de um vídeo de textura dinâmica.	85
Figura 27 – Exemplos de algumas texturas dinâmicas, ilustradas pelo primeiro quadro, da base de dados Dyntex++.	91
Figura 28 – Primeiro quadro de algumas texturas dinâmicas da base de dados UCLA.	92
Figura 29 – Análise dos parâmetros em função da taxa de classificação correta de cada base de dados. Para a base de dados Dyntex++ a melhor configuração de parâmetro foi $t_0 = 2, t_i = 48, n_f = 4$ e $r = [\overset{p}{\bar{1}}, \overset{p}{\bar{2}}]$, enquanto para a base de dados UCLA foi $t_0 = 8, t_i = 96, n_f = 2$ e $r = [\overset{p}{\bar{1}}, \overset{p}{\bar{2}}, \overset{p}{\bar{3}}]$	93
Figura 30 – Ilustração das quatro classes de texturas sintéticas utilizadas para analisar as características de movimento obtidas pelo método proposto.	95
Figura 31 – Características extraídas pelo método proposto de difusão em redes das 4 classes de movimento projetadas em duas dimensões usando t-SNE.	96

Figura 32 – Histogramas de atividade extraídos de quatro vídeos de texturas dinâmicas rotacionados.	96
Figura 33 – Análise das características extraídas para as bases de dados a partir do descritor espacial e temporal usando diferentes combinações de memória e regras de movimento.	98
Figura 34 – Análise das características extraídas para as bases de dados com os descritores espacial e temporal concatenados e usando diferentes combinações de memória e regras de movimento.	99
Figura 35 – Quatro classes de texturas dinâmicas sintéticas utilizadas para analisar as características de movimento extraídas pelo método proposto a partir do descritor temporal.	100
Figura 36 – Projeção das características extraídas da base sintética de movimento usando o método de CDPA Rs aplicado somente no descritor temporal.	101
Figura 37 – Três classes de textura dinâmica sintética utilizada para avaliar as características de aparência extraídas pelo descritor de espacial:(a) algas, (b) escada, (c) flores.	102
Figura 38 – Projeção das características extraídas da base sintética de aparência usando o método de CDPA Rs aplicado somente no descritor espacial.	102
Figura 39 – Taxa de classificação correta para diferentes combinações de tamanhos de memória, regras de movimento e descritores com a estratégia de execução da CDPA Rs de descritores espacial e temporal para gerar as redes. Cada gráfico apresenta os resultados para tipo de descritor de uma base de dados.	103
Figura 40 – Taxas de classificação correta para diferentes concatenações de tamanhos de memória e regra de movimento usando os descritores temporal e espacial combinados em todos os casos.	104
Figura 41 – Taxas de classificação correta usando diferentes combinações de tamanhos de memória e regras de movimento para a estratégia de planos ortogonais. Cada gráfico corresponde a um plano ortogonal e uma base de dados.	105
Figura 42 – Análise das taxas de classificação correta obtidas com a combinação das características extraídas das redes dos três planos ortogonais.	105
Figura 43 – Matriz de confusão da base de dados UCLA dividida em 8 classes.	111
Figura 44 – Primeiro quadro dos vídeos de cada condição experimental.	115
Figura 45 – Ilustração do esquema de obtenção das amostras sem sobreposição de um vídeo de uma condição experimental de corrosão de aço carbono.	116
Figura 46 – Taxa de classificação correta da difusão em redes para diferentes valores de parâmetro na base de dados de corrosão de aço carbono.	117
Figura 47 – Projeção com t-SNE dos vetores de características extraídos pelo método de difusão em redes da base de corrosão de aço carbono.	118

Figura 48 – Taxa de classificação correta para diferentes conjuntos de tamanho de memória e regras de movimento obtidas pelo método de CDPA Rs executadas em descritores espacial e temporal na base de dados de corrosão de aço carbono.	119
Figura 49 – Taxa de classificação correta da base de corrosão de aço para diferentes combinações de tamanhos de memória e regras de movimento do método de redes geradas por CDPA Rs com a estratégia de execução de descritores espacial e temporal.	120
Figura 50 – Taxas de classificação correta usando diferentes combinações de tamanhos de memória e regras de movimento para a estratégia de planos ortogonais na base de dados de corrosão de aço carbono.	121
Figura 51 – Exemplos do primeiro quadro das três classes de texturas dinâmicas da base de dados de tráfego.	122
Figura 52 – Análise dos parâmetros da difusão em redes como função da taxa de classificação correta da base de tráfego.	123
Figura 53 – Resultados do método de CDPA Rs em texturas dinâmicas com características extraídas da base de dados de tráfego a partir do descritor espacial e temporal usando diferentes combinações de memória e regras de movimento.	124
Figura 54 – Resultados da base de tráfego para diferentes combinações de tamanhos de memória, regras de movimento e descritores do método de redes geradas por CDPA Rs com a estratégia de execução de descritores espacial e temporal.	125
Figura 55 – Taxas de classificação correta usando diferentes combinações de tamanhos de memória e regras de movimento para a estratégia de planos ortogonais no vídeos de tráfego de veículos.	126
Figura 56 – Matriz de confusão da base de tráfego.	127
Figura 57 – Projeção com t-SNE dos vetores de características extraídos pelo método de difusão em redes da base de tráfego.	128
Figura 58 – Exemplos do primeiro quadro de algumas amostras similares de intensidade de tráfego médio e pesado.	128

LISTA DE TABELAS

Tabela 1 – Resultados para diferentes combinações de medidas estatísticas de redes geradas usando a estratégia de descritores espacial e temporal.	106
Tabela 2 – Resultados para diferentes medidas de redes complexas geradas pelo turista nos três planos ortogonais	106
Tabela 3 – Comparação dos resultados de classificação do método proposto com os métodos da literatura para a base UCLA com 50 classes. Obs. # é o tamanho do vetor de características.	108
Tabela 4 – Comparação dos resultados de classificação do método proposto com os métodos da literatura para a base UCLA com 9 classes. Obs. # é o tamanho do vetor de características.	109
Tabela 5 – Comparação dos resultados de classificação do método proposto com os métodos da literatura para a base UCLA com 8 classes. Obs. # é o tamanho do vetor de características.	110
Tabela 6 – Comparação dos resultados de classificação do método proposto com os métodos da literatura para a base Dyntex++.	110
Tabela 7 – Condições experimentais que influenciam no tipo de corrosão.	115
Tabela 8 – Comparação dos resultados de classificação do método proposto com os métodos da literatura para a base de tráfego.	127

SUMÁRIO

1	INTRODUÇÃO	25
1.1	Objetivos	28
1.2	Organização	28
2	TEXTURAS	31
2.1	Problemas em texturas	34
2.2	Análise de Texturas Estáticas	35
2.3	Análise de Texturas Dinâmicas	37
2.3.1	Métodos baseados em fluxo óptico	39
2.3.2	Métodos baseados em geometria	40
2.3.3	Métodos baseados em modelos	40
2.3.4	Métodos baseados em filtragem	41
2.3.5	Métodos baseados em discriminação	41
2.3.6	Métodos baseados em autômatos	42
3	METODOLOGIAS DE COMPLEXIDADE	43
3.1	Redes complexas	43
3.1.1	Definição	44
3.1.2	Modelos de redes	45
3.1.2.1	Rede Aleatória	45
3.1.2.2	Rede Pequeno Mundo	46
3.1.2.3	Rede Livre de Escala	46
3.1.3	Medidas de redes	47
3.1.3.1	Grau e Conectividade	47
3.1.3.2	Caminhos e Distância	48
3.1.3.3	Coeficiente de Aglomeração e Transitividade	49
3.1.3.4	Centralidade	50
3.1.3.5	Difusão em redes	51
3.1.4	Redes complexas em imagens/ vídeos	52
3.2	Caminhadas Determinísticas Parcialmente Auto-repulsivas - CDPARs	54
3.2.1	Definição	55
3.2.2	CDPARs em imagens	56
3.2.3	Deteção de atratores	58

3.2.4	Análise de complexidade computacional	59
4	CARACTERIZAÇÃO DE TEXTURAS DINÂMICAS	63
4.1	Difusão em redes direcionadas aplicado em texturas dinâmicas . . .	64
4.1.1	Modelagem de texturas dinâmicas em redes direcionadas	65
4.1.2	Aplicação da função de limiar sobre as arestas	67
4.1.3	Estimativa da atividade de textura dinâmica	68
4.1.4	Vetor de características	69
4.1.5	Análise de complexidade computacional	74
4.2	Caminhada determinística parcialmente auto-repulsiva aplicada em textura dinâmica	75
4.2.1	CDPARs aplicadas em vídeo	76
4.2.2	Vetor de características	78
4.3	Redes complexas geradas por CDPARs para textura dinâmica . . .	80
4.3.1	Modelagem de texturas dinâmicas em redes por meio de CDPARs	81
4.3.1.1	Descritores Espacial e Temporal	83
4.3.1.2	Planos Ortogonais	83
4.3.2	Vetor de Características	85
4.4	Conclusão	87
5	EXPERIMENTOS E RESULTADOS	89
5.1	Configurações experimentais e bases de dados	89
5.2	Análise experimental	90
5.2.1	Difusão em redes direcionadas aplicado em texturas dinâmicas . . .	90
5.2.1.1	Análise dos parâmetros	90
5.2.1.2	Análise de movimento e rotação	94
5.2.2	Caminhada determinística parcialmente auto-repulsiva aplicada em textura dinâmica	97
5.2.2.1	Análise dos parâmetros	97
5.2.2.2	Análise do método proposto	98
5.2.3	Redes complexas geradas por caminhada determinística parcialmente auto-repulsiva para textura dinâmica	101
5.3	Comparação com métodos da literatura	106
5.4	Conclusão	112
6	APLICAÇÕES	113
6.1	Classificação de tipos de corrosão de aço carbono	113
6.1.1	Base de dados	114
6.1.2	Experimentos e Resultados	116
6.2	Análise de intensidade de tráfego de veículos em rodovias	118

6.2.1	Base de dados	120
6.2.2	Classificação de intensidade de tráfego	121
6.2.2.1	Comparação com outros métodos	125
6.3	Conclusão	127
7	CONCLUSÃO	129
7.1	Contribuições	130
7.2	Trabalhos Futuros	130
7.3	Trabalhos Gerados	131
REFERÊNCIAS		133

INTRODUÇÃO

A análise e reconhecimento de padrões em textura é uma área de pesquisa fundamental em visão computacional e processamento de imagens. As suas aplicações estão presentes em diversas áreas da ciência e indústria, tais como, medicina ([RAMAMOORTHY; KIRUBAKARAN; SUBRAMANIAN, 2015](#)), biologia ([BACKES; CASANOVA; BRUNO, 2010](#); [JR. et al., 2011](#)), controle de qualidade de alimentos ([CHEN et al., 2014](#)), sensoriamento remoto ([ZHU; YANG, 1998](#)), entre outros. Embora a sua compreensão e percepção sejam naturais para os seres humanos, a definição formal e descrição utilizando métodos computacionais provou ser uma tarefa desafiadora. Algumas definições da literatura descrevem texturas como padrões repetitivos e regulares, entretanto, elas podem ser bem mais complexas ([GONCALVES, 2013](#)). As texturas podem apresentar padrões combinados em diferentes escalas, serem formadas por ausência de padrões (e.g. ruído) e até mesmo por padrões complexos, como em grande parte das texturas presentes na natureza. Em geral, tais padrões são resultados das propriedades físicas da superfície de objetos, como por exemplo, rugosidade, granulosidade, suavidade, entre outros ([TUCERYAN; JAIN, 1998](#)). Essas características fazem com que as texturas sejam um excelente descritor local.

A área de pesquisa em análise de texturas pode ser dividida em duas categorias específicas: estáticas e dinâmicas. A principal diferença entre essas duas categorias reside na adição da extensão temporal para representação de objetos dinâmicos. Enquanto as texturas estáticas são formadas por padrões de texturas presentes em uma única imagem, refletindo objetos estáticos representados (e.g. cascas de árvore, pedras, tecidos, folhas, tijolos, entre outros), as texturas dinâmicas são sequências de imagens de texturas (i.e. vídeos) que representam objetos dinâmicos e exibem certas propriedades estacionárias no tempo ([DORETTO et al., 2003](#)). Exemplos de texturas dinâmicas estão presentes no nosso cotidiano (e.g. árvores balançando, fumaça, cachoeira, ondas do mar, entre outras) e, em diversas áreas da ciência, como na biologia (e.g. evolução de colônias de bactérias ([ZHANG et al., 2010](#)), crescimento de tecidos do corpo humano ([KHALIL et al., 2009](#)), crescimento de tumores ([SILVA et al., 2012](#); [WU et al., 2015](#))) e na ciência dos materiais (e.g. processo de corrosão de metais e nanoestruturas ([ZIMER et al.,](#)

2011)). Embora sejam duas categorias correlacionadas, este trabalho irá abordar especificamente as texturas dinâmicas.

As primeiras pesquisas da área de análise de texturas dinâmicas foram realizadas no início da década de 90 por Nelson e Polana (1992). No entanto, devido às diversas limitações, apenas recentemente a área voltou a atrair a atenção de pesquisadores. Em parte, essa atenção foi impulsionada pelos avanços dos aparelhos de captura, a maior capacidade de processamento computacional e as diversas aplicações potenciais. No que se referem às aplicações, essas têm como objetivo contribuir com a sociedade na solução de problemas reais, alguns exemplos são: monitoramento de tráfego de carros (GONÇALVES; BRUNO, 2013b), reconhecimento de atividade humana (KELLOKUMPU; ZHAO; PIETIKÄINEN, 2008), reconhecimento de expressão facial (ZHAO; PIETIKAINEN, 2007a), análise de imagens médicas (BRIEU et al., 2010), entre outras.

No que tange às abordagens, diferentes métodos foram propostos ao longo dos últimos anos. Esses métodos podem ser divididos em cinco categorias: baseados em fluxo óptico (POLANA; NELSON, 1997b); baseados em modelos (SOATTO; DORETTO; WU, 2001; CHAN; VASCONCELOS, 2007); baseados em filtragem (DUBOIS; PÉTERI; MÉNARD, 2009a; ZHONG; SHI; VISONTAI, 2004); baseados em propriedades geométricas (OTSUKA et al., 1998a); baseados em discriminação (TIWARI; TYAGI, 2016c; ZHAO; PIETIKAINEN, 2007b) e; baseados em autômatos (GONÇALVES; BRUNO, 2013c; GONÇALVES; BRUNO, 2013b). Embora grandes avanços tenham sido reportados pelos métodos nos últimos anos, ainda existem diversas limitações e desafios na caracterização de texturas dinâmicas, tais como: obter características invariantes a transformações (e.g. rotação), não combinar explicitamente características espaciais e temporais (e.g. alguns métodos analisam as texturas baseado somente no movimento) e realizar uma análise multi-escala.

Recentemente, muitos trabalhos têm defendido o uso de abordagens de sistemas dinâmicos lineares para caracterização de texturas dinâmicas (DORETTO et al., 2003; DORETTO; JONES; SOATTO, 2004; RAVICHANDRAN; CHAUDHRY; VIDAL, 2013; RAVICHANDRAN; VIDAL, 2011a). Essas abordagens baseiam-se em uma suposição linear que a torna restritiva, isto porque a maioria das texturas dinâmicas reais são geradas por sistemas dinâmicos não-lineares com padrões complexos no tempo (e.g. água fervendo e ondas do mar). A presença de padrões complexos dificulta a tarefa de descrição usando sistemas lineares, o que requer o desenvolvimento de um paradigma de métodos baseado em complexidade e sistemas dinâmicos não-lineares. Nesse cenário, alguns trabalhos na literatura vêm conseguindo resultados interessantes usando abordagens baseadas em teoria do caos (WANG; HU, 2016; WANG; HU, 2015) e geometria fractal (XU et al., 2011; Ji et al., 2013). Neste contexto, a motivação desta dissertação é utilizar metodologias advindas da área de sistemas complexos como medida de complexidade de texturas dinâmicas. Em particular, duas metodologias são consideradas: redes complexas e caminhadas determinísticas parcialmente auto-repulsivas (CDPARs) (CAMPITELI;

MARTINEZ; BRUNO, 2006; LIMA; MARTINEZ; KINOUCI, 2001).

As redes complexas são uma área de pesquisa que combina a teoria dos grafos e métodos advindos da mecânica estatística para modelar e analisar problemas. A sua origem pode ser atribuída aos estudos de redes aleatórias realizados por Erdős e Rényi (1960) em meados dos anos 1960. Mais recentemente, os avanços científicos e tecnológicos fizeram com que as redes complexas emergissem como uma alternativa ao modelo reducionista pelo o seu caráter multidisciplinar e integrativo (MIRANDA; MACHICAO; BRUNO, 2016). Em visão computacional, diversos trabalhos empregaram as redes complexas com sucesso na extração de características e classificação em diferentes problemas (BACKES; BRUNO, 2013; GONÇALVES; MACHADO; BRUNO, 2015). Por outro lado, a CDPAR, conhecida também como caminhada determinística do turista, foi introduzida no início dos anos 2000 por Lima, Martinez e Kinouchi (2001) com o objetivo de analisar e compreender o efeito de caminhadas simples em ambientes desordenados. Posteriormente, as CDPARs foram aplicadas em problemas de visão computacional como uma medida de complexidade (BACKES, 2010; BACKES; MARTINEZ; BRUNO, 2011).

Os resultados atingidos por esses trabalhos indicam a existência de uma linha de pesquisa promissora e com grande potencial para desenvolvimento do ponto de vista de medida de complexidade em visão computacional. Embora não haja uma definição formal de complexidade, esta pode ser compreendida como uma medida de irregularidade das texturas dinâmicas. Assim, é possível medir a estrutura dos pixels, permitindo quantificar o seu aspecto espacial e temporal (BACKES, 2010). Além disso, como já demonstrado em trabalhos anteriores (BACKES; MARTINEZ; BRUNO, 2011; GONÇALVES; MARTINEZ; BRUNO, 2012; GONÇALVES et al., 2012), ambas metodologias têm em comum a possibilidade de uso combinado, o que torna a pesquisa com potencial para alcançar bons resultados.

Nesse sentido, este trabalho tem por objetivo investigar o uso dessas duas metodologias de pesquisa para o desenvolvimento de novos métodos de análise de texturas dinâmicas. No âmbito teórico, foram propostos três novos métodos para análise de texturas dinâmicas. O primeiro método modela as texturas dinâmicas em redes direcionadas e, em seguida, caracteriza tais redes por meio da difusão. Um segundo método propõe a aplicação das CDPARs em uma estratégia de descritores espacial e temporal, permitindo a caracterização adequada de aparência e movimento. Como este método utiliza somente o tamanho das caminhadas no vídeo para caracterização, um terceiro método é proposto com o objetivo de obter informações mais ricas das CDPARs. Para tanto, é utilizado a capacidade de uso combinado das duas metodologias. Assim, redes são geradas pelas CDPARs e, então, medidas estatísticas são extraídas das redes para caracterização das texturas dinâmicas. Neste método, duas diferentes estratégias de execução das CDPARs nos vídeos foram consideradas: descritores espacial e temporal, e planos ortogonais.

Do ponto de vista prático, diferentes experimentos foram realizados para validação dos métodos propostos. Para avaliar as propriedades dos métodos e o desempenho na classificação, experimentos foram realizados em texturas dinâmicas sintéticas e base de dados da literatura.

Como apresentado nos experimentos, os métodos propostos obtiveram bons resultados, superando em alguns casos os principais métodos da literatura. Em relação às aplicações, os métodos desenvolvidos foram testados em dois problemas: classificação de tipos de corrosão de aço carbono e reconhecimento de intensidade de tráfego em rodovias. Os resultados obtidos indicaram que os métodos podem contribuir com a sociedade ajudando em problemas práticos.

1.1 Objetivos

Esta dissertação tem como principal objetivo estudar e investigar metodologias advindas da área de sistemas complexos para o desenvolvimento de novos métodos de caracterização de texturas dinâmicas. Para tanto, as seguintes metodologias de complexidade são utilizadas: redes complexas e caminhadas determinísticas parcialmente auto-repulsivas. De forma resumida, os objetivos deste trabalho foram:

- Investigar e analisar os métodos da literatura de textura dinâmica.
- Propor novos métodos para caracterização de texturas dinâmicas baseado nas metodologias de sistemas complexos.
- Analisar e comparar os métodos desenvolvidos com o estado da arte.
- Aplicar os métodos desenvolvidos em problemas potenciais reais.

1.2 Organização

Esta dissertação está organizada da seguinte maneira:

Capítulo 2: neste capítulo são discutidas as texturas em geral e realizado uma revisão dos métodos da literatura de análise de texturas estáticas e dinâmicas.

Capítulo 3: este capítulo apresenta em detalhes as duas metodologias de complexidade que serão utilizadas para o desenvolvimento dos métodos de caracterização de texturas dinâmicas.

Capítulo 4: neste capítulo são apresentados os três métodos desenvolvidos para caracterização de texturas dinâmicas. Os métodos desenvolvidos são: difusão em redes, CDPARs aplicada em descritores espacial e temporal e redes geradas por CDPARs.

Capítulo 5: os experimentos e resultados obtidos com os métodos desenvolvidos são apresentados, bem como a comparação com os demais métodos da literatura.

Capítulo 6: cada seção deste capítulo descreve uma aplicação dos métodos desenvolvidos em dois problemas: classificação de tipos de corrosão de aço carbono e análise de intensidade de tráfego de veículos em rodovias.

Capítulo 7: por fim, este capítulo apresenta as conclusões, contribuições e trabalhos gerados a partir deste mestrado.

TEXTURAS

O estudo de textura é um campo de pesquisa importante na comunidade de visão, que abrange diferentes áreas da ciência, como a neurociência (JULESZ; BERGEN, 1983), psicofísica e ciência da computação (TUCERYAN; JAIN et al., 1993). No que diz respeito à neurociência e psicofísica, os estudos se concentram em compreender os processos neurais que estão envolvidos na percepção visual humana, ou seja, como as células do córtex visual humano respondem a estímulos relacionados a textura (ZHOU, 2006). Do ponto de vista computacional, as investigações estão focadas em como reconhecer ou segmentar automaticamente imagens/vídeos de texturas por meio de representações matemáticas.

A textura é uma importante propriedade presente na superfície de objetos, tais como, madeira, folhas de plantas, pele, etc. Tanto na visão computacional como na visão biológica a textura é uma informação importante no processo de compreensão de cenas e objetos. Em particular, a percepção de texturas na visão biológica é um dos primeiros passos para compreensão de um ambiente (e.g. praia, florestas e ruas) (BERGEN; LANDY, 1991; JULESZ, 1962). Embora a sua percepção visual seja intuitiva, não há na literatura de visão computacional uma definição precisa e abrangente. Na verdade, a definição de textura é motivada pela percepção em particular ou, mais comum, pela aplicação em que a definição é empregada.

Os primeiros estudos relacionados a textura foram realizados por Julesz (JULESZ, 1962; JULESZ et al., 1973; JULESZ, 1981), que tinha como motivação verificar como o sistema visual humano responde a variação estatística de uma determinada ordem. Inicialmente, Julesz (1962) definiu que texturas parecidas possuem estatística de segunda ordem idênticas, entretanto, essa conjectura foi provada ser falsa após contra-exemplos do próprio Julesz (JULESZ et al., 1973). Por outro lado Hawkins (1970) definiu textura como uma ordem local repetida sobre uma região maior, que é organizada regularmente em pequenas partes elementares aproximadamente uniformes. Embora não exista uma única definição aceita pela comunidade, algumas clássicas são:

- "Uma imagem de textura é descrita pelo número e tipos de suas primitivas e a organização espacial ou disposição de suas primitivas." (HARALICK, 1979)
- "A textura é uma repetição regular de um elemento ou padrão em uma superfície. Imagens de textura são padrões visuais compostos por entidades com sub-padrões com brilho, cor, forma e tamanho característicos." (SRINIVASAN; SHOBHA, 2008)
- "A textura é gerada por um ou mais padrões básicos locais que se repetem de maneira periódica em alguma região da imagem." (WECHSLER, 1980)

Diversos autores definem textura como padrões básicos ou primitivos regulares. No entanto, Hájek (2006) sugere que texturas são padrões complexos compostos por elementos com brilho, cor, forma e tamanho. Algumas texturas, principalmente naturais, são formadas por padrões que quando vistos de maneira global possuem certa complexidade. O fato é que texturas apresentam diferentes propriedades contraditórias, como regularidade em relação à aleatoriedade, uniformidade e distorções, homogeneidade e heterogeneidade (ZHOU, 2006). Essa variedade de propriedades está diretamente relacionada com a diversidade e complexidade das texturas presentes na natureza.

Os autômatos celulares unidimensionais (ACUs) são exemplos de sistemas dinâmicos não-lineares que geram padrões de texturas caóticos e complexos. Basicamente, os ACUs consistem de um conjunto de regras que determinam o próximo estado de uma célula baseado no seu estado atual e no das células vizinhas da direita e esquerda. Tais autômatos geram diagramas espaço-tempo que possuem padrões de textura complexo e caótico. Wolfram (1984) afirmou que todos os autômatos celulares podem ser classificados em quatro classes, de acordo com o comportamento visual dos diagramas espaço-tempo gerado pela evolução do autômato. As classes são: (i) homogênea, (ii) periódica, (iii) padrões caóticos e, (iv) complexa. Na verdade, a afirmação de Wolfram está relacionada com a percepção de textura do sistema visual humano. Baseado nessa conjectura, pesquisadores utilizaram descritores de textura aplicados nas imagens dos diagramas espaço-tempo para classificar os autômatos celulares de forma automática (SILVA et al., 2016). Os resultados mostram que a classificação dos autômatos postulada por Wolfram é plausível. Na Figura 1, é possível ver algumas texturas com padrões complexos e caóticos geradas por regras das classes complexa e caótica.

Outros exemplos de texturas complexas podem ser vistos na própria natureza, como as folhas de plantas. As folhas possuem vasos condutores de seiva que são chamados de nervura. As ramificações dessas nervuras na maioria das folhas apresentam padrões complexos que podem descrever a espécie da folha. Alguns exemplos de texturas formadas por folhas de plantas com nervuras podem ser vistas na Figura 2. Essa diversidade de definições e a presença de padrões complexos em texturas serve como motivação para a análise de texturas com ferramentas de complexidade advindas da área de sistemas complexos.

Figura 1 – Exemplos de texturas caóticas e complexas obtidas de diagramas espaço-tempo evoluídos de autômatos celulares.

(a) Caótica

Regra 91

Regra 18

Regra 93171

Regra 45

(b) Complexa

Regra 1804

Regra 110

Regra 1951

Regra 86658

Fonte: Elaborada pelo autor.

Figura 2 – Exemplos de folhas de plantas com nervuras.

Fonte – (DAS et al., 2014; CASANOVA; JUNIOR; BRUNO, 2009; BRUNO et al., 2008)

Na Seção 2.1, os problemas em texturas são apresentados. As texturas podem ser divididas em dois tipos: estáticas e dinâmicas. O foco deste trabalho são as texturas dinâmicas. No entanto, como as texturas dinâmicas estão diretamente relacionadas com as texturas estáticas, na Seção 2.2 é feita uma breve descrição dos métodos de texturas estáticas. Por fim, na Seção 2.3 os métodos de análise de texturas dinâmicas são apresentados.

2.1 Problemas em texturas

As texturas são importantes atributos presentes na maioria das imagens, isso faz com que exista uma grande variedade de aplicações que as utilizam. Em consequência disso, existe uma grande variedade de métodos de extração de características de textura na literatura. Esses métodos têm como objetivo captar diferentes propriedades de textura para sua representação. Nesse sentido, os métodos podem ser aplicados em três categorias de problemas (GONCALVES, 2013): classificação, segmentação e síntese. Cada categoria de problema é detalhada abaixo.

- Classificação: consiste em atribuir para cada textura uma classe (XU et al., 2011; TIWARI; TYAGI, 2016c; AZENCOTT; WANG; YOUNES, 1997). A classificação pode ser realizada de duas maneiras: supervisionada e não-supervisionada. Na classificação supervisionada um conjunto de texturas com conhecimento prévio da classe é utilizada para treinamento de um classificador (e.g. rede neural), para posteriormente ser realizada a classificação de amostras com classes não conhecidas. Já na classificação não-supervisionada não é necessário um conhecimento prévio das classes. Em geral, os métodos de classificação de texturas envolvem um processo com duas etapas: extração de características de cada imagem/vídeos de textura e classificação baseada em algoritmos de aprendizagem de máquina. A classificação de texturas pode ser utilizada em uma variedade de aplicações, como por exemplo, inspeção da qualidade de tintas, sensoriamento remoto, diagnóstico médico e detecção de corrosão em metal.
- Segmentação: nesse problema, a imagem é dividida em diferentes regiões baseado nas propriedades de texturas, de modo que cada região apresenta um tipo de textura (CHAN; VASCONCELOS, 2008; GONÇALVES; BRUNO, 2013c; JAIN; FARROKHNI, 1990). Essa é uma tarefa difícil devido a duas questões: não conhecer a priori os tipos de texturas e as regiões na imagem que têm texturas. A divisão da imagem em um mapa de regiões similares é útil em uma gama de aplicações, tais como, detecção de objetos em imagens e mudança de terrenos em imagens aéreas.
- Síntese: a síntese de texturas é muito comum na computação gráfica. O objetivo das técnicas de síntese é criar texturas baseadas em características extraídas de uma amostra (ZHOU, 2006; XIA et al., 2014). Basicamente, dada uma amostra de textura, características relevantes são extraídas e, posteriormente, outras amostras com características de texturas similares são sintetizadas. A síntese de textura pode ser utilizada para: testar de maneira empírica métodos de análise de texturas, edição de imagens, síntese de vídeos, etc.

2.2 Análise de Texturas Estáticas

As texturas estáticas são padrões regulares ou complexos presentes em uma única imagem. Esses padrões são importantes características usadas para descrever regiões de imagens relacionadas com a superfície de objetos e condições de ambiente (GONÇALVES, 2013). As texturas podem ser vistas em objetos artificiais e naturais, alguns exemplos são: madeira, folhas, tecido, pele, parede, entre outras.

A análise de texturas estáticas se concentra em extrair características de imagens. Assim, um conjunto de características distintivas o suficiente para caracterizar texturas é selecionada. A partir dessas, é possível representar uma textura complexa em um pequeno vetor de características mensuráveis, o que permite automatizar o processo de classificação, segmentação e síntese de texturas (ZHOU, 2006).

Ao longo dos anos, muitas abordagens para análise de texturas estáticas têm sido propostas na literatura. As abordagens diferem uma das outras, principalmente pelo método utilizado para extrair as características de textura da imagem. Basicamente, os métodos podem ser divididos em cinco categorias: (i) estatísticos, (ii) geométricos, (iii) baseado em modelos, (iv) espectrais e, (v) baseado em autômatos. Abaixo são descritas as abordagens de cada categoria.

- Métodos estatísticos: esses métodos descrevem texturas em imagens por meio de medidas estatísticas de primeira e segunda ordem, que estão relacionadas aos níveis de cinza dos pixels. As estatísticas de primeira ordem (relacionadas ao histograma de níveis de cinza) mede somente propriedades individuais dos pixels, limitando a descrição da textura. Portanto, é utilizado com mais frequência estatísticas de segunda ordem. O método mais popular é o descritores de Haralick ([HARALICK; SHANMUGAM; DINSTEN, 1973](#)), que baseia-se na matriz de co-ocorrência dos níveis de cinza (GLCM) para extrair medidas estatísticas, tais como, contraste, correlação, energia, entropia, entre outros. Outro método muito utilizado é o padrões binários locais (LBP) ([OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002](#)). Esse método calcula a frequência de simples padrões locais, combinando uma abordagem estatística e estrutural.
- Métodos estruturais: nessa categoria, assume-se que a textura é uma composição bem definida de micro texturas que estão organizadas em uma hierarquia de arranjos espaciais (macro textura) ([BHARATI; LIU; MACGREGOR, 2004](#)). A vantagem desse tipo de abordagem é uma boa descrição simbólica de imagens regulares. Entretanto, uma descrição abstrata pode não ser adequada em texturas naturais, que possuem padrões mais complexos de macro e micro textura ([MATERKA; STRZELECKI et al., 1998](#)). Inicialmente, foram propostos métodos que usavam diferentes estruturas regulares para descrever texturas reais ([ZUCKER, 1976](#); [CARLUCCI, 1972](#)). Em seguida, outros trabalhos ([VOORHEES; POGGIO, 1987](#); [BLOSTEIN; AHUJA, 1989](#); [TOMITA; TSUJI, 1990](#)) utilizaram filtragem com o Laplaciano da Gaussiana (LoG) em diferentes escalas combinadas para identificar primitivas. As primitivas correspondem às regiões homogêneas na imagem e para caracterização são extraídas informações, tais como tamanho e orientação. Outro método proposto por Lazebnik ([LAZEBNIK; SCHMID; PONCE, 2005](#)), utiliza os detectores de ponto de interesse Harris e Laplaciano para identificar regiões na imagem. Cada região detectada é considerada um elemento de textura que apresenta um padrão distinto, esse padrão é caracterizado pelo descritor RIFT.
- Métodos baseado em modelos: os métodos dessa categoria baseiam-se na construção de modelos da imagem e utilizam os parâmetros estimados para descrever a textura. Basicamente, os modelos utilizados são os estocásticos e fractais. Os principais métodos que utilizam modelos estocásticos são baseados nos campos aleatórios de Markov ([CROSS; JAIN, 1983](#); [CHELLAPPA; CHATTERJEE, 1985](#)). Esses modelos assumem que a intensidade de cada pixel da imagem depende apenas da vizinhança. Já o modelo fractal tornou-se

bastante popular na análise de textura devido a capacidade de modelar texturas naturais. Conceitualmente, os fractais são padrões complexos que apresentam a propriedade de auto-similaridade em várias escalas. Em geral, os métodos baseados em fractal estimam a complexidade da textura por meio da dimensão fractal. Alguns métodos consideram a imagem de textura como um mapa de pixels 3D, onde a intensidade do pixel representa o terceiro plano. Desse modo, a dilatação de Minkowski-Bouligand é utilizada para estimar a dimensão fractal da textura (BACKES; BRUNO, 2013; BACKES; CASANOVA; BRUNO, 2009b; BACKES; CASANOVA; BRUNO, 2012). Além disso, outros trabalhos utilizam multi-fractal (XU; JI; FERMÜLLER, 2009) e a dimensão fractal multi-escala (BACKES; BRUNO, 2010; FLORINDO; BRUNO, 2013) para caracterizar texturas.

- Métodos espectrais: esses métodos convertem a imagem em uma nova baseado em propriedades de frequências espaciais da intensidade dos pixels (BHARATI; LIU; MACGREGOR, 2004). Um método clássico é o descritor de Fourier (AZENCOTT; WANG; YOUNES, 1997; GONZALEZ; WOODS, 2006), a ideia básica desse método é aplicar a transformada de Fourier 2D sobre a imagem e extrair características de textura no domínio da frequência. Além desse, características extraídas por um conjunto de filtros de Gabor (BOVIK; CLARK; GEISLER, 1990) e por meio da transformada Wavelet (UNSER, 1995; CHANG; KUO, 1993) também têm sido bastante utilizado em análise de texturas.
- Métodos baseados em autômatos: essa é uma categoria recente, em que os métodos propostos utilizam um indivíduo guiado por uma regra determinística. Em geral, esse indivíduo realiza sucessivas caminhadas pela imagem de textura e informações da sua caminhada (e.g. comprimento e número de visitas) são extraídas como assinatura. Exemplos de métodos baseado em agentes são a caminhada determinística do turista (BACKES et al., 2010; BACKES et al., 2006) e rastreadores artificiais (GONÇALVES; MACHADO; BRUNO, 2014).

2.3 Análise de Texturas Dinâmicas

Texturas dinâmicas são padrões de textura em movimento que consistem em uma sequência de imagens com certa estacionariedade no tempo (CHETVERIKOV; PÉTERI, 2005; DORRETO; JONES; SOATTO, 2004). Nelson e Polana (1992) definiram que texturas dinâmicas possuem regularidade estatística, mas com uma extensão espaço-temporal caracterizada pelo movimento complexo não-rígido. Isto ocorre devido aos movimentos complexos serem impulsionados por sistemas dinâmicos não-lineares com certo caos (XU et al., 2011). Exemplos de texturas dinâmicas no mundo real incluem ondas do mar, fumaça, árvores balançando, bandeira em movimento, fogo, multidão de pessoas, entre outras. Na Figura 3 pode ser visto alguns exemplos de vídeos de texturas dinâmicas representados por cubos.

Figura 3 – Exemplos de alguns vídeos de textura dinâmica representados por cubos. A terceira dimensão representa o movimento da textura dinâmica no tempo.

Fonte: Elaborada pelo autor.

Nos últimos anos, a pesquisa em texturas dinâmicas tem atraído atenção da comunidade de visão computacional em grande parte pelas potenciais aplicações. Em (ZHAO; PIETIKAINEN, 2007b; KOELSTRA; PANTIC; PATRAS, 2010), métodos de reconhecimento de texturas dinâmicas baseados em padrões locais binários foram aplicado para identificar a expressão facial em vídeos (e.g. feliz, triste, etc). Outro trabalho (KELLOKUMPU; ZHAO; PIETIKÄINEN, 2008), utiliza descritores de texturas dinâmicas para detectar atividade humana em vídeos, que

é um tema com diversas aplicações (e.g. vigilância, análise de vídeos de esporte, ambientes inteligentes, etc). Já em [Zhao et al. \(2011\)](#), o reconhecimento de fogo em vídeos é realizado por meio de descritores de textura dinâmica. Em [Gonçalves e Bruno \(2013b\)](#), vídeos de monitoramento de tráfego de carros são modelados como texturas dinâmicas, para posteriormente, serem classificados de acordo com a intensidade do tráfego (leve, médio e pesado). Além dessas, outras aplicações podem ser citadas como: análise de imagens médicas ([BRIEU et al., 2010](#)) e recuperação de vídeo ([RAVICHANDRAN; VIDAL, 2011b](#)).

A análise de texturas dinâmicas possui diversos desafios, tais como relacionados à caracterização da aparência e movimento, periodicidade temporal, padrões complexos de textura, complexidade computacional, entre outros. Os desafios para caracterização e a gama de aplicações potências levam a diferentes abordagens computacionais para a análise de texturas dinâmicas. Tais abordagens podem ser divididas em seis categorias: (i) baseados em fluxo óptico, (ii) baseado em geometria, (iii) baseado em modelos, (iv) baseado em filtragem, (v) baseados em discriminação e, (vi) baseado em autômatos. A seguir cada categoria e seus métodos são descritos resumidamente.

2.3.1 Métodos baseados em fluxo óptico

Os métodos dessa categoria extraem medidas de movimento através do fluxo óptico. Esses métodos são populares devido ao baixo custo computacional e a eficiência na análise de movimento dos vídeos. No entanto, duas desvantagens desses métodos podem ser citadas: a alta correlação entre o fluxo normal e a aparência espacial das texturas dinâmicas, e pressuposição de constância de brilho e suavidade local, que em geral não ocorre em texturas dinâmicas estocásticas ([DERPANIS; WILDES, 2012](#)). Os primeiros estudos utilizaram o campo vetorial de fluxo normal para caracterizar a magnitude global e direção do movimento das texturas dinâmicas ([NELSON; POLANA, 1992](#); [POLANA; NELSON, 1997a](#)). Em [Peh e Cheong \(2002\)](#), as magnitudes e direções do fluxo normal são mapeadas como texturas dinâmicas para posterior análise com ferramentas tradicionais de texturas.

Outra abordagem proposta por [Péteri e Chetverikov \(2005\)](#), tenta caracterizar a magnitude do movimento, direcionalidade e periodicidade combinando características de fluxo normal com periodicidade. [Lu et al. \(2005\)](#) propôs um método baseado nos histogramas do vetor de aceleração e velocidade para representar características temporais e espaciais de texturas dinâmicas. Em [Fazekas e Chetverikov \(2007\)](#), características invariantes a escala e rotação são extraídas da textura dinâmica por meio de distorções locais na imagem calculadas pelo fluxo normal. [Chen et al. \(2013\)](#) utiliza descritores locais (LBP) para obter características de aparência e combina com características de movimento extraídas por histogramas de fluxo óptico orientado. Essa combinação de descritores locais e técnicas de fluxo ópticos também é utilizada para segmentação de texturas dinâmicas por [Soygaonkar, Paygude e Vyas \(2015\)](#).

2.3.2 Métodos baseados em geometria

Essa é uma categoria menos popular em que os métodos se baseiam em propriedades geométricas para caracterizar o domínio espaço-temporal. O estudo precursor nessa categoria foi realizado por [Otsuka et al. \(1998b\)](#). Neste trabalho, é considerado que o vídeo de textura pode ser representado por contornos em movimento, explorando propriedades da superfície da trajetória. Assim, características de aparência e movimento são extraídas com base na distribuição do plano tangente. Posteriormente, uma extensão proposta por [Zhong e Scarlaroff \(2002\)](#), extrai características da textura dinâmica com base em contornos 3D no domínio espaço-tempo, isto é, as características são calculadas por voxels com base no gradiente espaço-temporal.

2.3.3 Métodos baseados em modelos

Os métodos dessa categoria possuem como objetivo construir modelos baseados em processos generativos para representar a textura dinâmica ([CHETVERIKOV; PÉTERI, 2005](#); [YANG et al., 2016](#); [DORETTO; JONES; SOATTO, 2004](#)). Em seguida, as diferentes texturas dinâmicas são classificadas com base nos parâmetros estimados dos modelos que as representam. [Doretto et al. \(2003\)](#) desenvolveu um modelo baseado em um sistema dinâmico linear que explora as regularidades espaciais e temporais das texturas dinâmicas para caracterização. Em [Chan e Vasconcelos \(2008\)](#), o algoritmo expectation-maximization é derivado para estimar os parâmetros e classificar as texturas dinâmicas. Além desse, eles propuseram um método baseado em modelos auto-regressivos ([CHAN; VASCONCELOS, 2005a](#)). [Ravichandran, Chaudhry e Vidal \(2013\)](#) modelou o vídeo de textura em um conjunto de sistemas dinâmicos lineares que descrevem regiões do vídeo e considera diferentes pontos de vista e escala. Assim, uma representação baseada no bag-of-features chamada de bag-of-system é utilizada para classificar os vídeos.

Recentemente, [Wang, Liu e Sun \(2016\)](#) utilizou um algoritmo de propagação de afinidade para representar o conjunto de sistemas dinâmicos e classificou os vídeos com o algoritmo extreme learning machine. [Qiao e Weng \(2015\)](#) usa o modelo oculto de Markov (hidden Markov model-HMM) para caracterizar as texturas dinâmicas. Neste método, a intensidade do pixel ao longo do tempo é modelada como um HMM que codifica as informações de aparência com as variáveis observadas, e as informações de movimento com os estados ocultos. Outros métodos tem utilizado com sucesso características caóticas (e.g. dimensão fractal), estas são eficientes para representar séries temporais ([WANG; HU, 2015](#); [WANG; HU, 2016](#)). Em [Xu et al. \(2012\)](#) é usado o espectro multi-fractal para extrair o comportamento de lei de potência do descritor local SIFT, este método é conhecido como 3D-OTF. Além desses, outros métodos baseados em modelos podem ser citados ([TOREYIN; CETIN, 2007](#); [GHANEM; AHUJA, 2007](#)).

2.3.4 Métodos baseados em filtragem

Nessa categoria, os métodos caracterizam a textura dinâmica através da sua decomposição em várias escalas utilizando filtragem espaço-temporal. O uso desse tipo de abordagem se faz necessário para obter informações locais e globais de movimento e aparência. O estudo inicial desenvolvido por Wildes e Bergen (2000), analisou padrões espaço-temporal locais, a sua orientação e energia, por meio de filtros orientado a energia. Outros trabalhos (WU et al., 2001; SMITH; LIN; NAPHADE, 2002; DUBOIS; PÉTERI; MÉNARD, 2009b), utilizaram a transformada wavelet para decompor o movimento da textura. Assim, é possível analisar diferentes escalas de movimento, por exemplo, uma árvore balançando apresenta um movimento global do tronco e local das folhas. Esses movimentos possuem periodicidades diferentes, o que resulta em máxima energia em diferentes escalas (CHETVERIKOV; PÉTERI, 2005). Em Gonçalves, Machado e Bruno (2011), é proposto um método com base nos filtros de Gabor que são bastante popular em texturas estáticas. Neste método, é realizada a convolução das sequências de imagem de textura com um banco de filtros de Gabor espaço-temporal. Em seguida, a energia estatística de cada resposta do filtro é utilizada para caracterizar a textura dinâmica.

2.3.5 Métodos baseados em discriminação

Estes métodos utilizam propriedades estatísticas da distribuição espacial de nível de cinza e calculam características locais de cada pixel (TIWARI; TYAGI, 2016b). Dentre os vários métodos dessa categoria, os mais conhecidos são os baseado no LBP (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002), que foi originalmente proposto para imagens. No método proposto por Zhao e Pietikäinen (2007), as texturas dinâmicas são caracterizadas por padrões binários locais volumétricos (LBPV). Basicamente, o método considera uma vizinhança 3D de um pixel de acordo com um raio r (vizinhos que estão no mesmo quadro, no quadro anterior e posterior) e transforma a vizinhança em uma sequência binária que é convertida em um número inteiro. Cada número representa um padrão local da textura dinâmica. Assim, o histograma dos padrões locais da textura dinâmica é utilizado como vetor de característica. A principal desvantagem desse método é a dimensão de 16,384 do vetor de características.

Outra extensão proposta por Zhao e Pietikainen (2007b) é o LBP-TOP. Esse método aplica o método LBP nos três planos ortogonais do vídeo. Os planos são: XY, que são os quadros; XT, que considera os pixels do eixo x no tempo; YT, que abrange os pixels do eixo y no tempo. Basicamente, considerando o vídeo de textura como um cubo, o plano XT seria uma sequência de cortes do cubo em fatias na horizontal e o plano YT cortes na vertical. Esses dois planos fornecem informações de transição no espaço e tempo. Os padrões binários locais de todos os pixels são obtidos dos três planos de forma independente. Finalmente, os histogramas de ocorrência dos padrões locais dos três planos são concatenados para formar o vetor de característica. Zhao et al. (2012) apresentou um método que utiliza a transformada de Fourier para calcular características invariantes de histogramas de padrões locais não invariantes. Por outro lado, Tiwari e Tyagi

(2016c) propôs o VLBP completo (CVLBP) que inclui contraste e informações da estrutura central dos pixels para melhorar a classificação de texturas dinâmicas. Outros métodos dessa categoria que podem ser citados são: HLBP (TIWARI; TYAGI, 2016a), WLBPC (TIWARI; TYAGI, 2016d) e MEWLSP (TIWARI; TYAGI, 2016e).

2.3.6 Métodos baseados em autômatos

Recentemente, tem sido proposto métodos com base em autômatos. Esses métodos (GONÇALVES; BRUNO, 2013c; GONÇALVES; BRUNO, 2013b; GONÇALVES; BRUNO, 2011), utilizam uma caminhada determinística com memória para descrever as texturas dinâmicas. A caminhada é iniciada em cada pixel e é guiada por regras baseadas nas diferenças de intensidade entre os pixels vizinhos. Após um período chamado de transiente o caminhante fica preso em um ciclo e, os tamanhos do transiente e do ciclo são utilizados como informação de textura. Para caracterizar a textura dinâmica, as caminhadas são realizadas nos três planos ortogonais do vídeo. Os resultados com esse tipo de abordagem demonstraram potencial em diversas aplicações desafiadoras.

METODOLOGIAS DE COMPLEXIDADE

Em geral, as abordagens em sistemas lineares consistem em dividir o sistema em partes menores e analisar isoladamente cada parte. Neste caso, o comportamento do todo é a superposição dos efeitos de cada parte. No entanto, essa mesma abordagem não é possível em sistemas complexos, que são grupos ou organizações compostas por vários elementos que interagem entre si e o meio em que está inserido ([RODRIGUES, 2007](#)). Exemplos de sistemas complexos incluem sistemas sociais (e.g. redes sociais, sociedade), sistemas biológicos (e.g. colônia de formigas, ecossistemas), sistemas físicos (e.g. clima), sistemas artificiais (e.g. redes de roteadores, web), economia, entre outros. Em tais sistemas, os elementos e as interações entre eles apresentam comportamento que visto de maneira global não pode ser facilmente explicado. Ou seja, a informação individual de cada elemento não é suficiente para explicar o comportamento coletivo do sistema ([MITCHELL; NEWMAN, 2002](#)).

Devido ao desenvolvimento dos computadores e de modelos matemáticos, a investigação de sistemas complexos tem se tornado uma área promissora. O caráter interdisciplinar desta área faz com que suas ferramentas de investigação sejam objeto de interesse de diversos campos da ciência. Como visto no Capítulo 2, texturas em geral também apresentam padrões que observados de maneira global possuem certa complexidade. Este fato motiva o uso de metodologias advindas do campo de sistemas complexos como medida de complexidade para a análise de texturas dinâmicas. Neste capítulo, são apresentadas e discutidas as duas metodologias de complexidade utilizadas no desenvolvimento desta dissertação: redes complexas e as caminhadas determinísticas parcialmente auto-repulsivas. Essas duas metodologias já apresentaram resultados promissores quando aplicadas em problemas de visão computacional.

3.1 Redes complexas

Grafos ou Redes? Os dois termos estão relacionados ao mesmo objeto de estudo que surgiu na matemática como teoria dos grafos. A teoria dos grafos surgiu com a solução de Euler

do famoso problema das sete pontes de Königsberg em 1736 (EULER, 1741) e, desde então, têm sido estudado em matemática e, após a década de 50, em ciência da computação. Nas últimas décadas, a teoria dos grafos atraiu atenção da física, que contribuiu para a área incorporando a análise e métodos que são advindos da mecânica estatística. A combinação de grafos e mecânica estatística é conhecida na literatura como redes complexas ou somente redes (onde a presença de fenômenos complexos não são obrigatórios nos grafos) (NEWMAN, 2010; COHEN; HAVLIN, 2010). As redes complexas têm como principais marcos três grandes descobertas (COSTA et al., 2007): investigação de redes pequeno mundo (WATTS; STROGATZ, 1998), redes livre de escala (BARABÁSI; ALBERT, 1999) e identificação de estruturas de comunidade em redes (GIRVAN; NEWMAN, 2002).

Nos últimos anos, os estudos em redes complexas se tornaram úteis devido a sua capacidade de representação e análise de uma ampla variedade de sistemas em diferentes áreas, como por exemplo, redes de sistemas sociais (e.g. Wasserman e Faust (1994), Newman e Park (2003)), biológicos (e.g. Jeong et al. (2001), Barabasi e Oltvai (2004)), físicos (e.g. Bornholdt e Schuster (2006), Amaral e Ottino (2004)), de infraestrutura (e.g. Nasiruzzaman, Pota e Mahmud (2011)), tecnológicos (e.g. Holme (2003)), entre outros. Esta variabilidade de aplicações e investigações em diversas áreas da ciência e sob perspectivas distintas fazem com que a área de redes complexas avance rapidamente.

3.1.1 Definição

Uma rede é representada por um par $R(V, E)$, onde $V = (v_1, v_2, \dots, v_N)$ é um conjunto de N vértices e $E = (e_1, e_2, \dots, e_M)$ um conjunto de M arestas. As arestas da rede podem ser direcionadas, quando há um sentido na ligação, ou não-direcionadas, quando o sentido da ligação não importa. Além disso, as arestas podem possuir um peso, que está associado a alguma medida da rede, como por exemplo, a distância de estradas que ligam cidades. Neste caso, a rede possui ainda o conjunto $W = (w_1, w_2, \dots, w_M)$ que representa os pesos das arestas, sendo a rede representada por $R(V, E, W)$. Redes com arestas direcionadas e com peso são as mais gerais, podendo ser obtidas as demais configurações através das operações de limitarização, para remoção dos pesos das arestas e, simetrização, para a obtenção de redes não-direcionadas (RODRIGUES, 2007).

As redes também podem possuir vários componentes desconectados (subgrafos), isto é, um subconjunto de vértices e arestas R_i pode não ter relação de adjacência com outro subconjunto R_j . Em algumas situações, é utilizado o maior componente da rede, ou seja, o componente que possui mais vértices. Em termos computacionais, uma rede pode ser armazenada usando uma matriz de adjacência A . Caso dois vértices i e j estejam conectados, a posição a_{ij} na matriz de adjacência irá receber 1, caso contrário 0. Em redes com pesos, ao invés de se utilizar 1 e 0 para conectar os vértices na matriz de adjacência, é utilizado a matriz de pesos W , sendo w_{ij} o peso da conexão do vértice i com o j .

Entre várias propriedades topológicas de redes, umas das principais é a distribuição do grau dos vértices. O grau k de um vértice i é o número de conexões incidentes nele. A distribuição do grau é uma função de probabilidade que indica a probabilidade de ocorrência $P(k)$ de um determinado vértice i ter grau k (Equação 3.1 e 3.2). Através da distribuição do grau é possível diferenciar modelos de redes e, verificar por exemplo, se a rede possui estrutura de conexões aleatória, livre de escala ou pequeno mundo.

$$P(k) = \begin{cases} 1, & k = k_i \\ 0, & \text{caso contrário} \end{cases} \quad (3.1)$$

$$k_i = \sum_{j=1}^N a_{ij}. \quad (3.2)$$

A maioria das redes são caracterizadas por uma distribuição de graus heterogênea, em que nós com baixo grau se relacionam com nós altamente conectados, chamados de hubs. Tal heterogeneidade do grau dos nós, indica que existe uma ampla diversificação dos seus papéis na rede (PERRA; FORTUNATO, 2008). Neste contexto, diversas medidas são investigadas para caracterizar as redes, tais como: transitividade, coeficiente de aglomeração, distância, entropia, centralidade, eficiência, entre outras. Nas seções a seguir são descritos em detalhes os modelos de redes, medidas e redes em imagens.

3.1.2 Modelos de redes

Ao decorrer dos anos, foram introduzidos na literatura diferentes modelos de redes complexas. Até o ano de 1959, as redes eram analisadas de forma determinística, posteriormente, foram considerados objetos estocásticos pelos matemáticos Paul Erdős e Alfred Rényi. As redes são classificadas em modelos de acordo com propriedades estatísticas, entre elas a distribuição do grau e o coeficiente de aglomeração. Os três principais modelos de redes complexas da literatura são descritos a seguir.

3.1.2.1 Rede Aleatória

Em 1959, os matemáticos Paul Erdős e Alfred Rényi, criaram um modelo de redes geradas à partir de conexões aleatórias entre os vértices. A rede aleatória pode ser considerada o modelo mais básico de redes complexas. Nesta rede, o grau dos vértices segue uma distribuição de Poisson. Este modelo é definido de duas maneiras: fixando um número de vértices e arestas ou uma probabilidade de conexão p .

Na primeira, distribui-se M arestas entre N vértices de forma aleatória. O algoritmo consiste basicamente em selecionar um par de vértices aleatoriamente e conectá-los com uma aresta a cada passo, até o número de arestas na rede serem iguais a M . Na segunda maneira, para cada uma das possíveis conexões da rede, sorteia-se um número uniformemente $q \in [0, 1]$

$[0, 1]$ e adiciona-se uma aresta se $q < p$. Neste modelo, as redes geradas têm uma estrutura altamente homogênea, já que todas as conexões possuem a mesma probabilidade p de ocorrer (RODRIGUES, 2007).

3.1.2.2 Rede Pequeno Mundo

Em 1998, os pesquisadores Watts e Strogatz (1998) observaram que redes reais, como de neurônios e de energia elétrica, não eram completamente aleatórias e nem completamente regular, mas sim estavam entre os dois extremos. Essas redes possuem caminho médio pequeno entre os vértices, isto é, a distância entre qualquer par de vértices é dada por um número pequeno de aresta. Além disso, existe a presença de ciclos de ordem três muito maiores que nas redes aleatórias. Esse fenômeno ficou conhecido como redes de pequeno mundo. Tal efeito implica diretamente em processos dinâmicos. Por exemplo, uma epidemia se propaga muito mais rapidamente em uma rede que possui caminho médio entre os vértices igual a 6 arestas do que 50 arestas.

Para construção de redes deste modelo, é iniciada uma rede regular composta por N vértices dispostos em círculo que estão ligados aos k vizinhos mais próximos em cada direção. Em seguida, cada aresta deve ser redirecionada para outro vértice escolhido aleatoriamente, com uma probabilidade fixa p de conexão. Como regra, um vértice não pode ser conectado a ele mesmo e, não pode existir mais de uma conexão entre dois vértices da rede (WATTS; STROGATZ, 1998). Neste modelo de rede, quando $p = 0$ a rede é completamente regular e quando $p = 1$ a rede é aleatória.

3.1.2.3 Rede Livre de Escala

Até o ano de 1999 as redes eram descritas utilizando os modelos aleatórios e de pequeno mundo. No ano de 1999, Barabási e Albert (1999) verificaram que a organização das conexões de algumas redes reais (e.g. rede da web) apresentavam características de pequeno mundo e a distribuição das conexões não eram aleatórias, mas do tipo livre de escala (RODRIGUES, 2007). Nas redes livre de escala, alguns poucos vértices possuem um alto número de conexões em comparação ao restante da rede, fazendo com que a distribuição do grau siga uma lei de potência.

Devido as propriedades matemáticas e pela ocorrência em diversos fenômenos naturais e artificiais, as redes livre de escala atraiu enorme interesse da comunidade nos últimos anos (CLAUSET; SHALIZI; NEWMAN, 2009), tornando necessário a utilização de um modelo para gerar tais redes. Neste modelo, o número de vértice não é fixo e a probabilidade de conexão entre um par de vértices não é uniforme, ao contrário, do modelo de Erdős-Reny. O modelo proposto por Barabási e Albert (BARABÁSI; ALBERT, 1999) é baseado em duas regras: i) crescimento: a cada passo de tempo um novo vértice é adicionado com m arestas; ii) ligação preferencial: a probabilidade de uma aresta do novo vértice i ser conectada a um vértice j é proporcional ao

número de conexões de j (Equação 3.3).

$$P(i \rightarrow j) = \frac{k_j}{\sum_u k_u} \quad (3.3)$$

Ou seja, vértices com um número maior de conexões têm maior probabilidade de receber uma nova conexão, esta é a ideia do rico fica mais rico. Para obtenção de uma rede livre de escala, considere os seguintes passos:

1. A rede é iniciada com um pequeno número N_0 de vértices conectados de forma arbitrária.
2. A cada passo um novo vértice com m ($< N_0$) arestas é adicionado.
3. O vértice recém adicionado na rede é ligado proporcionalmente com os vértices mais conectados, ou seja, a probabilidade p de conexão de um vértice na rede está associada ao seu grau.

3.1.3 Medidas de redes

Redes complexas podem apresentar diferentes estruturas, topologias e características ao representar um sistema. Portanto, diversas medidas são utilizadas para a sua caracterização, comparação, classificação e modelagem. A través dessas medidas é possível determinar qual modelo melhor representa uma rede real, analisar processos dinâmicos e compreender os mecanismos evolutivos que regem o crescimento da rede. Algumas das principais medidas são: relacionadas à conectividade, ciclos e distância; medidas hierárquicas; identificação de comunidades e; redes com diferentes tipos de vértices. Outras medidas também são apresentadas em [Costa et al. \(2007\)](#). A seguir as principais medidas são descritas em detalhes.

3.1.3.1 Grau e Conectividade

Para caracterização da rede, uma das medidas básicas é o grau dos vértices. Esta medida calcula o número de vértices incidentes a outros vértices:

$$k_i = \sum_{j=1}^N a_{ij}. \quad (3.4)$$

Através do grau do vértice pode ser obtido o grau médio da rede. Esta medida é calculada por meio da média do grau de todos os vértices, de acordo com Equação 3.5.

$$h_k = \frac{1}{N} \sum_{i=1}^N k_i. \quad (3.5)$$

Em redes com peso, pode-se obter também o grau ponderado somando o peso das arestas

3.7.

$$k_i^w = \sum_{j=1}^N w_{ij}. \quad (3.6)$$

Outra medida considerada é o grau conjunto de um vértice. Esta é uma medida de correlação entre o grau de dois vértices conectados. Assim, o grau conjunto de um vértice i é dado como a probabilidade de dois vértices i e j com o mesmo grau estarem conectados:

$$k_i = \frac{c(i)}{k_i} \quad (3.7)$$

onde $c(i) = |\{j \in V | e_{ij} \in E \wedge k_i = k_j\}|$ é o número de vértices conectados ao vértice i que possuem o mesmo grau k_i e $|\cdot|$ é a cardinalidade do conjunto.

Para medir a heterogeneidade da rede, pode-se calcular a energia E , entropia H e contraste C dos graus a partir da distribuição $P(k)$:

$$E = \sum_i P(k_i)^2. \quad (3.8)$$

$$H = - \sum_i P(k_i) \log P(k_i). \quad (3.9)$$

$$C = \sum_i P(k_i) k_i^2. \quad (3.10)$$

3.1.3.2 Caminhos e Distância

O comprimento do caminho entre dois vértices d_{ij} é igual ao número de arestas no percurso entre eles. O caminho geodésico l_{ij} é igual ao comprimento do menor caminho entre os vértices i e j . Como medida de caracterização da rede, pode-se utilizar a média das distâncias geodésicas (Equação 3.11).

$$L = \frac{1}{N(N-1)} \sum_{i=1}^N \sum_{j=1}^N l_{ij} \quad (3.11)$$

Caso i e j não estejam conectados por um caminho, então a distância $d_{ij} = \infty$, por definição $l_{ij} = \infty$. Uma solução adotada é utilizar somente o maior componente conectado da rede, isto é, o maior subgrafo. Uma medida mais simples da rede é o diâmetro, esta é o comprimento do maior caminho geodésico (Equação 3.12).

$$D = \max_{i,j} \{l_{ij}\} \quad (3.12)$$

Outra medida relacionada é a eficiência, esta caracteriza globalmente a rede baseado nas distâncias geodésicas entre os vértices (Equação 3.13). Além disso, também se apresenta como uma alternativa ao problema de componentes desconectados na rede. A eficiência mede o tráfego na rede, ou seja, a capacidade de propagação de informação.

$$E_c = \frac{1}{N(N-1)} \sum_{i=1}^N \sum_{j=1}^N \frac{1}{l_{ij}} \quad (3.13)$$

3.1.3.3 Coeficiente de Aglomeração e Transitividade

O coeficiente de aglomeração mede o grau de transitividade, isto é, o número de agrupamentos intrínsecos nas redes. Isto ocorre quando o vértice i está conectado ao vértice j e, j está conectado ao vértice z , logo há uma alta probabilidade de A também estar ligado a z . Portanto, em termos de topologia de redes, transitividade significa um elevado número de triângulos, que são conjuntos de três vértices conectados entre si. Esta é uma medida interessante para se quantificar padrões de texturas em imagens, já que tais padrões consistem na relação de um pixel com a vizinhança. O coeficiente de aglomeração C pode ser quantificado pela seguinte definição:

$$C = \frac{3 \rightarrow \text{número de triângulos na rede}}{\text{número de triplas conectadas}} \quad (3.14)$$

onde triplas conectadas são um único vértice conectado a outros dois vértices (veja o exemplo da Figura 4). Esta definição mede a fração de triplas que têm a terceira aresta conectada para completar o triângulo. O fator três do numerador se deve ao fato de que um triângulo contém três triplas e assegura que C encontra-se no intervalo $0 \leq C \leq 1$, onde $C = 1$ é a transitividade perfeita e $C = 0$ que a rede não possui triângulos.

Figura 4 – Este grafo possui 5 vértice e 5 arestas, ao aplicarmos a definição C , temos 1 triângulo e 6 triplas conectadas, portanto $C = \frac{3 \rightarrow 1}{6} = \frac{1}{2}$.

Fonte: Elaborada pelo autor.

Uma definição alternativa a C , dada por Watts e Strogatz (1998), e também amplamente utilizada é o coeficiente de clustering local:

$$cc(i) = \frac{2e_i}{k_i(k_i-1)} \quad (3.15)$$

onde e_i é o número de arestas entre os vértices adjacentes a i . Nesta definição, se $k_i = 1$ então $cc(i) = 0$. Como medida de caracterização global da rede é usado a média dos coeficientes de clustering local (Equação 3.16).

$$hcci = \frac{1}{N} \sum_{i=1}^N cc(i) \quad (3.16)$$

Apesar de serem medidas relacionadas à clustering, C e $hcci$ não são medidas iguais, C dá o mesmo peso para cada triângulo, enquanto $hcci$ atribui o mesmo peso para cada vértice independente do grau.

3.1.3.4 Centralidade

Uma questão tipicamente abordada em redes sociais é a centralidade da rede, isto é, quais são os indivíduos que estão melhores conectados a outros ou que possuem maior influência. Esta questão foi estendida para outros campos de pesquisa em redes complexas, se tornando fundamental a investigação de medidas que identifique componentes centrais (importantes) nas redes. Na literatura, existem diversas medidas que calculam a importância dos vértices na rede, as mais importantes serão descritas a seguir.

Degree centrality. A centralidade do grau é a medida mais básica de centralidade da rede. Nesta medida, assume-se que um vértice é central se possui um grau alto. Assim, a centralidade de um vértice i é dada pelo seu grau k_i . Um problema desta medida são os hubs periféricos, isto é, que possuem grau alto, mas que são periféricos na rede. Portanto, são vértices centrais localmente e importante somente localmente.

Closeness centrality (FREEMAN, 1979). Essa medida é definida através da média das menores distâncias de um vértice i para todos os outros da rede. Assim um vértice é mais central se possui distâncias menores em relação aos outros vértices da rede. Portanto, a closeness centrality de um vértice i é

$$CC_i = \frac{1}{\frac{1}{N} \sum_{j=1}^N d_{ij}} \quad (3.17)$$

onde d_{ij} é a menor distância entre o vértice i e j . Um vértice é central se apresenta valores altos de CC_i . No entanto, em redes reais os valores de d_{ij} tendem a ser pequeno, tipicamente a distância em uma rede aumenta de forma logarítmica. Isto é $\frac{\max(CC_i)}{\min(CC_i)} < 5$ e como essa diferença é pequena, flutuações na estrutura da rede podem mudar CC_i drasticamente. Outra limitação é caso a rede contenha mais de um componente, neste caso, $d_{ij} = \infty$ e $CC_i = 0$ para todos vértices da rede. Uma solução é utilizar somente o maior componente, o que irá deixar d_{ij} menor ainda. Outra solução mais robusta é usar a média harmônica das menores distâncias, assim CC_i é dado por $\overline{CC_i} = \frac{1}{N-1} \sum_{j=1, j \neq i}^N \frac{1}{d_{ij}}$.

Betweenness centrality (FREEMAN, 1979). O Betweenness centrality ou grau de intermediação é uma medida de centralidade do grau (pode-se medir a centralidade das arestas também) que quantifica o número de vezes que um vértice está no caminho mais curto entre outros vértices da rede. Por exemplo, assuma que mensagens são trocadas entre pares de vértices e que as mensagens trafegam pelos menores caminhos. Isso vai gerar pontos de congestionamento na rede, espera-se então que esses pontos sejam centrais. Logo, é possível definir uma medida de centralidade baseada na carga do vértice:

$$\hat{B}_i = \sum_{s=1}^N \sum_{t=1}^N n_{st}^i \quad (3.18)$$

$$n_{st}^i = \begin{cases} 1 & \text{se } i \text{ está no menor caminho entre } s \text{ e } t \\ 0 & \text{caso contrário} \end{cases} \quad (3.19)$$

Um problema é caso exista vários menores caminhos entre os vértices s e t , por isso pondera-se o número de menores caminhos

$$B_i = \sum_{s=1}^N \sum_{t=1}^N \frac{n_{st}^i}{g_{st}} \quad (3.20)$$

onde g_{st} é o número total de distâncias geodésicas entre s e t . Caso $n_{st}^i = 0$ então $\frac{n_{st}^i}{g_{st}} = 0$. Portanto, quanto maior o valor de B_i mais central será o vértice i .

Eigenvector centrality (BONACICH; LLOYD, 2001). Nesta medida, um vértice é importante se ele está ligado a outros vértices importantes. Este conceito define a medida Eigenvector centrality. Portanto, podemos medir a centralidade de um vértice baseado em seus vizinhos. Inicialmente, a centralidade de cada vértice é definida como: $x_0(i) = 1/\delta_i$. Em seguida, o Eigenvector de cada vértice é calculado de forma iterativa:

$$x_{t+1}(i) = \sum_{j=1}^N a_{ij} x_t(j). \quad (3.21)$$

Em notação matricial esta medida pode ser representada como $\begin{bmatrix} x_{t+1} \\ \vdots \\ x_{t+1} \end{bmatrix} = A \begin{bmatrix} x_t \\ \vdots \\ x_t \end{bmatrix}$. No entanto, esse método não é válido para redes dirigidas. Para essas redes uma solução que pode ser adotada é o PageRank.

3.1.3.5 Difusão em redes

O método de difusão em redes foi proposto para a área de redes complexas por Comin et al. (2014). Este método é baseado em caminhadas aleatórias tradicional. Uma caminhada aleatória é definida como uma partícula saindo de um vértice e caminhando aleatoriamente pela rede por L passos. Em cada passo, a partícula visita um vértice e, o vértice a ser visitado no passo

$(t + 1)$ é definido por um sorteio uniforme (cada vértice possui um mesmo peso) dos vértices adjacentes ao vértice visitado no passo t , de acordo com a seguinte probabilidade:

$$p(i \rightarrow j) = \frac{1}{k_i}. \quad (3.22)$$

Como se trata de um processo estocástico, em cada vértice é iniciado M caminhadas. Para caracterização da estrutura topológica da rede é estimado um histograma de atividade. A atividade de cada vértice é dada pela frequência de visitas recebidas. Assim, o histograma soma o número de visitas recebidas por todos os vértices que possuem um mesmo grau.

3.1.4 Redes complexas em imagens/ vídeos

Na literatura, o uso de redes complexas/grafos é empregado em diferentes problemas de visão computacional e processamento de imagens, tais como: segmentação (e.g. [Morris, Lee e Constantinides \(1986\)](#), [Xu e Uberbacher \(1997\)](#)), análise de texturas (e.g. [Chalumeau et al. \(2006\)](#), [Chalumeau et al. \(2008\)](#), [Backes, Casanova e Bruno \(2013\)](#)), refinamento de bordas (e.g. [Suk e Song \(1984\)](#), [Ferrari, Tuytelaars e Gool \(2006\)](#)), extração de características de contorno (e.g. [Backes, Casanova e Bruno \(2009a\)](#), [Zhao, Kong e Luo \(2006\)](#), [Tang, Zhang e Luo \(2006\)](#)), reconhecimento de objetos em cenas (e.g. [Matas, Marik e Kittler \(1995\)](#)), compressão de imagens (e.g. [Labelle et al. \(1998\)](#)), entre outros. No entanto, devido ao objetivo deste trabalho, o foco nesta seção serão os métodos de extração de características de texturas estáticas e dinâmicas baseados em redes complexas.

Em geral, os métodos de extração de características baseado em redes utilizam a seguinte metodologia ilustrada na Figura 5: modelagem da imagem em uma rede para, posteriormente, utilizar aspectos topológicos da rede na caracterização e classificação da textura. O estudo inicial que utiliza essa abordagem em imagens de textura foi realizado em [Chalumeau et al. \(2006\)](#) e [Chalumeau et al. \(2008\)](#). Nesse estudo, cada pixel i da imagem representa um vértice v_i , que é conectado por arestas a outros vértices que estão a uma distância menor ou igual a r . As arestas possuem pesos w que estão relacionados a diferença de intensidade de cor entre os pixels e, arestas que possuem peso acima de um limiar são removidas do grafo. Para caracterização, são obtidas medidas baseadas no grau e coeficiente de aglomeração dos grafos hierárquicos derivados do grafo original.

Após esse trabalho precursor, surgiram outras abordagens variantes do original. Uma abordagem similar que utiliza esse tipo de modelagem é descrita em [Gonçalves et al. \(2012\)](#). Nesse trabalho, para obter uma análise multi-escala, a rede original é transformada por uma função de remoção das arestas de acordo com vários valores de limiar. As redes transformadas são descritas pela distribuição conjunta do tempo de transiente e período do atrator das trajetórias produzidas pela caminhada determinística do turista sobre a rede. O vetor de características é composto por histogramas do tempo de transiente e período do atrator, obtidos da distribuição

Figura 5 – Ilustração da metodologia abordada pelos métodos da literatura que utilizam redes complexas em imagens.

Fonte: Elaborada pelo autor.

conjunta utilizando diferentes valores de memória μ e regras de movimento. Já em [Backes, Casanova e Bruno \(2013\)](#), o peso da aresta é definido por uma relação entre o quadrado da distância entre os pixels e a diferença de intensidade. As medidas de grau médio, entropia, energia e contraste são extraídas das redes transformadas pela função de limiar para caracterização da textura. Basicamente, esta função de limiar exclui arestas da rede que possui um peso maior que um dado limiar. Para obter diferentes características, um conjunto de limiares é considerado. Uma característica importante deste método, de acordo com experimentos realizados em bases sintéticas, é a robustez na classificação de imagens rotacionadas e com ruído.

De maneira diferente, [Backes, Martinez e Bruno \(2011\)](#) utilizam as trajetórias da caminhada determinística do turista na imagem para gerar as redes. A grande vantagem desse método é o número reduzido de parâmetros em relação às propostas anteriores. Inicialmente, o conjunto de arestas E da rede é vazio. Assim, a relação de adjacência entre os vértices é determinada pelo movimento do turista de acordo com uma regra determinística e uma memória. A cada movimento do turista uma aresta não direcionada é adicionada ao conjunto de arestas E . Cada pixel é o ponto inicial de uma caminhada, obtendo uma rede com o conjunto de trajetórias auto-repulsivas. Para compor o vetor de características, o grau médio e a entropia do grau conjunto são extraídos de cada rede gerada por diferentes regras de movimento e valores de memória. Os resultados nos experimentos realizados na base de textura Brodatz mostraram excelente desempenho do método em comparação com métodos tradicionais da literatura.

Outra abordagem, proposta por [Gonçalves et al. \(2016\)](#), mapeia a imagem em uma

rede direcionada. Para isso, as arestas que possuem peso negativo são removidas. O peso negativo é referente à diferença de intensidade de dois pixels, isto é, se $I(v_i) < I(v_j)$ então o peso da aresta será negativo. Assim, se $I(v_i) > I(v_j)$ então a aresta é direcionada de v_i para v_j . Além disso, arestas com peso menor que um conjunto de limiares são desconsideradas. Em cada vértice é iniciada uma caminhada aleatória e a frequência relativa de visitas do vértice é a sua atividade. A estrutura topológica das redes é, então, caracterizada por um histograma da atividade correlacionada com o grau dos vértices. Em [Junior, Backes e Cortez \(2013\)](#), a imagem é modelada em uma rede não direcionada com o peso das arestas determinado por: $|I(v_i) - I(v_j)| + \frac{I(v_i) + I(v_j)}{2}$. Os caminhos mais curtos entre pares de vértices em diferentes escalas e orientações da imagem são explorados para descrever as texturas. Nos experimentos realizados em imagens de textura da base UIUC, o método apresentou resultados promissores, com robustez para invariância a rotação e mudança de perspectiva.

Para descrição de texturas dinâmicas por meio de redes complexas, o primeiro estudo foi realizado por [Gonçalves, Machado e Bruno \(2015\)](#). Apesar do campo de redes serem ainda inexplorado em texturas dinâmicas, este primeiro trabalho apresentou resultados interessantes. Primeiramente, o vídeo da textura é modelado em uma rede regular. Para isso, cada pixel é representado por um vértice e dois vértices são conectados se a distância relativa entre os pixels é menor ou igual a um dado raio r . O peso das arestas é dado pela diferença absoluta da intensidade de cor entre os pixels. Para evidenciar propriedades topológicas específicas de cada classe de textura, uma função de remoção de arestas é aplicada sobre a rede regular. Posteriormente, o método caracteriza as redes considerando o grau espacial e temporal. Apesar de simples, essas medidas descrevem adequadamente diferentes características de aparência e de movimento na textura.

3.2 Caminhadas Determinísticas Parcialmente Auto-repulsivas - CDPARs

As caminhadas determinísticas em meios regulares e desordenados vem apresentando resultados promissores, com destaque para a caminhada determinística parcialmente auto-repulsiva, também conhecida como caminhada determinística do turista. O estudo inicial da CDPAR foi introduzido por [Lima, Martinez e Kinouchi \(2001\)](#), com o objetivo de analisar o efeito de caminhadas simples em ambientes desordenados. Essas caminhadas são autômatos capazes de obter diversas características ou informações ricas do ambiente em que são realizadas.

Recentemente, a CDPAR surgiu como uma abordagem promissora em visão computacional, apresentando resultados interessantes na análise de texturas estáticas (e.g. [Backes et al. \(2010\)](#), [Backes, Martinez e Bruno \(2011\)](#), [Gonçalves et al. \(2012\)](#), [Gonçalves e Bruno \(2013a\)](#)) e dinâmicas (e.g. [Gonçalves e Bruno \(2013c\)](#), [Gonçalves e Bruno \(2013b\)](#)) e no reconhecimento de folhas de plantas (e.g. [Backes et al. \(2006\)](#)). O primeiro trabalho proposto para análise de

imagens é descrito em [Campitelli, Martinez e Bruno \(2006\)](#). Basicamente, o método proposto utiliza o período do atrator e tempo do transiente obtidos da distribuição conjunta para caracterizar as imagens de texturas. Em seguida, [Backes et al. \(2006\)](#) propôs uma variação do método original que combina duas regras determinísticas de caminhada e uma nova medida extraída da distribuição conjunta. Neste trabalho, o método desenvolvido foi aplicado no reconhecimento de espécies de plantas através da sua imagem.

Outra variante proposta por [Backes, Martinez e Bruno \(2010\)](#), resolve o problema de empate nas caminhadas utilizando uma nova regra de movimentação baseada na direção do contraste da vizinhança. Os experimentos apresentaram resultados interessantes em relação a outros métodos para análise de textura e na classificação de imagens rotacionadas da base de dados Brodatz. Por outro lado, em [Gonçalves e Bruno \(2013a\)](#) a caminhada do turista e a dimensão fractal foram combinadas para representar texturas. Neste trabalho, ao invés de utilizar somente o tamanho do atrator e tempo de transiente para descrever as texturas, foi considerado a incidência, a distribuição e o arranjo espacial dos atratores que são caracterizados pelos descritores fractais. Além desses trabalhos, outras duas abordagens ([GONÇALVES et al., 2012](#); [BACKES; MARTINEZ; BRUNO, 2011](#)) combinaram redes complexas e CDPAR para análise de textura, como visto na Seção 3.1.4.

Para caracterização de texturas dinâmicas, dois estudos baseados na caminhada determinística parcialmente auto-repulsiva foram realizados em [Gonçalves e Bruno \(2013b\)](#), [Gonçalves e Bruno \(2013c\)](#). Nestes trabalhos as caminhadas foram aplicadas em três planos ortogonais (XY, XT e YT) do vídeo para extrair características de aparência e movimento da textura. Em [Gonçalves e Bruno \(2013b\)](#), o método foi validado com três problemas de textura dinâmica: reconhecimento, agrupamento e segmentação. Os resultados na base de dados Dyntex++ indicaram que a CDPAR melhora a representação de texturas dinâmicas em relação à outros métodos da literatura. Já em [Gonçalves e Bruno \(2013c\)](#) as CDPAR foram aplicadas na tarefa de segmentação de texturas dinâmicas. Para isso, vetores de características são extraídos de blocos por meio das CDPARs e, em seguida, o algoritmo k-means é aplicado para segmentar as diferentes regiões do vídeo. A seguir, a CDPAR é definida em detalhes.

3.2.1 Definição

A caminhada determinística parcialmente auto-repulsiva pode ser interpretada como um turista que deseja visitar N cidades distribuídas de forma aleatória em uma mapa de d dimensões ([BACKES et al., 2006](#)). O turista irá iniciar a caminhada de uma cidade pré-definida e a regra de movimento determinística que irá direcioná-lo para outra cidade é: vá para a cidade mais próxima que não tenha sido visitada nos últimos μ passos ([LIMA; MARTINEZ; KINOUCI, 2001](#); [BACKES, 2010](#); [GONÇALVES; BRUNO, 2013a](#)). Nesta regra, dominada como $r = \min$, o turista irá se movimentar minimizando as distâncias entre as cidades. Por outro lado, na regra $r = \max$ o turista irá maximizar as distâncias entre as cidades. A memória μ será a janela em

que o turista irá realizar uma caminhada determinística parcialmente auto-repulsiva. Isto é, o turista irá considerar uma cidade já visitada atrativa novamente após ter percorrido μ cidades. A regra de movimento é baseada na vizinhança da cidade e em uma curta memória μ , que apesar de simples, pode gerar CDPARs de grande complexidade (BACKES, 2010).

A caminhada do turista pode ser dividida em duas partes: transiente e atrator. O transiente é a parte inicial da caminhada que possui tamanho t e, o atrator a parte final da caminhada, composta por um ciclo de período r em que o atrator fica preso. O atrator é um ciclo de cidades de período r que sempre serão visitadas pelo turista, isto é, ao entrar em um atrator o turista não consegue escapar. Portanto, o transiente é o percurso do turista até encontrar um atrator, sendo o seu tamanho t o número de cidades percorridas pelo turista desde a cidade inicial até a primeira cidade do atrator. Em alguns casos, dependendo da disposição das cidades vizinhas e do tamanho de memória μ , pode ocorrer do turista não encontrar um atrator. Nesse caso, a trajetória é considerada somente pelo tempo do transiente t .

A trajetória do turista está diretamente relacionada à cidade em que é iniciada, portanto, cada cidade do mapa é considerada como condição inicial de uma caminhada. Assim, dado um conjunto de N cidades, obtêm-se um conjunto de N trajetórias produzidas pelas caminhadas. Para medir estatisticamente o conjunto de trajetórias realizadas em um mapa, é utilizado uma distribuição conjunta $S_{\mu,r}(t, r)$. Essa distribuição combina o tempo de transiente t e o período do atrator r , armazenando em cada posição da distribuição a frequência de caminhadas que obtiveram transiente t e atrator r (Equação 3.23) (GONÇALVES; BRUNO, 2013c; GONÇALVES et al., 2012; BACKES et al., 2010).

$$S_{\mu,r}(t, r) = \frac{1}{N} \sum_{i=1}^N \begin{cases} 1, & \text{se } t_i = t \text{ e } r_i = r \\ 0, & \text{caso contrário} \end{cases} \quad (3.23)$$

onde i é a cidade em que foi iniciada a caminhada.

3.2.2 CDPARs em imagens

Para a aplicação da CDPAR em imagens, considere uma imagem bidimensional composta por um conjunto finito de pixels P , em que cada pixel possui uma localização $p_i = (x_i, y_i)$, e intensidade $I(p_i) \in [0, 255]$. Cada pixel p_i é considerado uma cidade e a vizinhança $h(p_i)$ do pixel p_i é composta pelos pixels que estão à uma distância Euclidiana de p_i menor ou igual a $\sqrt{2}$, de acordo com a Equação 3.24.

$$h(p_i) = \{ p_j \mid \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \leq \sqrt{2} \} \quad (3.24)$$

A distância entre dois pixels p_i e p_j é dada pelo módulo da diferença entre as intensidades de cor: $w(p_i, p_j) = |I(p_i) - I(p_j)|$. A regra de movimento $r = \min$ do turista é definida como: vá para o pixel em $h(p_i)$ que está à uma menor distância e que não esteja na memória M_μ . Além

dessa, pode ser utilizada a regra de movimento $r = \max$ proposta por [Backes et al. \(2010\)](#). Essa regra direciona o turista para o pixel vizinho que possui a maior distância, isto é, que maximiza o peso $w(p_i, p_j)$. A caminhada é encerrada quando o turista encontra um atrator, isto é, um conjunto de pixels em que não consegue escapar. Dessa forma, uma trajetória composta de uma parte transiente e um atrator é produzida na imagem.

Uma vez que pode ter mais de uma distância mínima (ou máxima para o caso da regra $r = \max$), uma situação que pode ocorrer na caminhada na imagem é o empate. Neste caso, existe na literatura diferentes maneiras de resolver o conflito (e.g. desempate considerando ambas direções e análise da vizinhança, considerando os últimos passos do turista) ([BACKES, 2010](#)). No entanto, essas abordagens não resolvem completamente o problema, minimizando apenas. Nesse sentido, neste trabalho um índice único é atribuído para cada pixel, e assim, dentre os pixels empatados, é selecionado o pixel com o menor índice ([CAMPITELI; MARTINEZ; BRUNO, 2006](#)). Como os índices são fixos, a ordem em que os pixels são visitados (e.g. sentido horário) não influencia a escolha do próximo a ser visitado. Embora não seja a mais sofisticada, esta estratégia resolve o problema de maneira simplificada e mantém a natureza determinística do método.

A Figura 6 exemplifica uma trajetória da caminhada do turista em uma imagem. No exemplo, os pixels são representados pelos círculos que contém o valor da sua intensidade de cinza dentro. O turista sai do primeiro pixel da imagem e caminha até encontrar um atrator. O transiente ($t = 5$) é dado pelos círculos azuis e o atrator ($r = 4$) é formado pelos círculos verdes.

Figura 6 – Exemplo da CDPAR com tamanho de memória $\mu = 2$ em uma imagem. Cada círculo representa um pixel com a sua intensidade dentro. Os círculos azuis corresponde ao transiente e os verdes ao atrator.

Fonte: Adaptada de [Gonçalves e Bruno \(2013a\)](#).

Para cada pixel da imagem, é iniciada uma CDPAR com um dado tamanho de memória μ e uma regra de movimento r , produzindo diferentes trajetórias. Dessa forma, para uma imagem I com N pixels, serão obtidas N trajetórias. A caracterização da imagem pode ser feita com a distribuição conjunta $S_{\mu,r}(t, r)$ que combina o tempo de transiente t e o período do atrator r . A Figura 7 apresenta duas distribuições conjuntas obtidas de duas imagens de textura.

Figura 7 – Exemplos de distribuição conjunta obtidas com $\mu = 5$ e regra de movimento $r = \min$ de duas imagens de textura.

Fonte: Elaborada pelo autor.

3.2.3 Detecção de atratores

Um atrator em uma CDPAR é uma parte da caminhada que se inicia e termina sempre em um mesmo pixel, o que configura um ciclo em que o turista é preso. Alguns exemplos de atratores podem ser vistos na Figura 8. O fato de iniciar e terminar em um mesmo pixel, pode se levar a crer que uma segunda visita a um determinado pixel representa a presença de um atrator na caminhada. Entretanto, isso pode não ocorrer, já que o turista possui uma memória

que permite que determinados pontos da trajetória sejam repetidos, produzindo caminhadas mais sofisticadas (BACKES, 2010). Veja exemplos dessa situação na Figura 8 (b).

Figura 8 – Exemplos de atratores em uma imagem. A região quadriculada azul é o transiente da caminhada e o trecho listrado em verde o atrator.

Fonte: Adaptada de Backes (2010).

Nesse contexto, a tarefa de detectar um atrator durante a caminhada torna-se computacionalmente custosa. Assim, uma abordagem proposta por Backes et al. (2010) diminui o custo computacional e soluciona este problema. Essa abordagem utiliza listas encadeadas para verificar a repetição de trechos iguais na caminhada.

Uma primeira lista armazena cada passo (pixel visitado) da caminhada realizada pelo turista, funcionando como um histórico. Quando um pixel é visitado por no mínimo três vezes pelo turista é possível identificar se há um ciclo. Para isso, é realizada a comparação entre as seções desse pixel na lista. Por exemplo, na Figura 9 (a) temos um exemplo de lista contendo o histórico da caminhada. O pixel B é visitado em três ocasiões (2, 5, 8) e ao compararmos as seções em que estão contidas as visitas (2 a 5 e 5 a 8), é detectado duas repetições na trajetória e, portanto, a presença de um atrator. Para verificar rapidamente a quantidade de visitas que um pixel recebeu e, em que posições aparecem na lista, é utilizado uma lista auxiliar associada a cada pixel da imagem (Figura 9 (b)). Esta lista guarda as posições que cada pixel apareceu na lista que armazena a caminhada (BACKES et al., 2010).

3.2.4 Análise de complexidade computacional

Dado um imagem/vídeo com N pixels, uma CDPAR é executada para cada pixel. Cada caminhada possui tamanho l , sendo composta de um transiente de tempo t e um atrator de período r , caso ele exista. Para casos em que um atrator não é encontrado, o turista caminha até

Figura 9 – Ilustração das listas utilizadas para detectar atratores. A Figura (a) exemplifica a lista que guarda a caminhada e a (b) as listas associadas aos pixels.

Fonte: Adaptada de Backes (2010).

um dado número de passos M . Em alguns trabalhos M é definido como $M = N$. Nesta dissertação, como é utilizado somente os primeiros elementos da distribuição conjunta, foi definido $M = 100$. Portanto, o tamanho máximo de uma caminhada é 100 passos.

A complexidade computacional do método é dada pelo número de pixel onde são iniciadas caminhadas e pelo tamanho de cada caminhada, $O(N \rightarrow (t + 2r))$. Como é necessário percorrer duas vezes o mesmo ciclo de pixels para identificar um atrator, tem-se $2r$. O melhor caso ocorre quando o tamanho de todas as caminhadas é 1, isto é, quando o tempo de transiente é nulo ($t = 0$) e o período do atrator é $r = 1$. Uma vez que não existe atratores com tamanho menor do que $(\mu + 1)$, o melhor caso ocorre com tamanho de memória $\mu = 0$, em que atratores com $r = 1$ podem ser encontrados. A complexidade do método para o melhor caso é então $O(N)$.

Por outro lado, o pior caso acontece quando nenhum atrator é encontrado pela CDPAR. Assim, para qualquer tamanho de memória μ , a CDPAR irá possuir um tamanho M , levando a uma complexidade de pior caso $O(N \rightarrow M)$. Este pior caso é mais raro, acontecendo em um contexto de vídeo muito específico.

Para o caso médio, a Figura 10 mostra o tamanho médio das caminhadas em uma imagem com $N = 40000$ pixels para diferentes tamanhos de memória μ . Note que a curva possui um comportamento linear. Para o maior tamanho de memória utilizado nessa dissertação $\mu = 9$ o tamanho médio da caminhada é igual $M = 41$. Isso significa que com memória $\mu = 9$ o turista caminha em média por 41 pixels até encontrar um atrator. Este resultado leva a complexidade de

caso médio bem próxima ao melhor caso $O(N)$, já que M é significativamente menor do que N .

Figura 10 – Tamanho médio das caminhadas para diferentes tamanhos de memória μ .

Fonte: Elaborada pelo autor.

CARACTERIZAÇÃO DE TEXTURAS DINÂMICAS

O principal objetivo deste mestrado foi verificar o potencial na caracterização de texturas dinâmicas das metodologias de complexidade: caminhada determinística parcialmente auto-repulsiva e das redes complexas. Para tanto, foi desenvolvido um método com base em cada metodologia. Além disso, através de um terceiro método desenvolvido pode-se verificar o uso combinado dessas duas metodologias para a análise de texturas dinâmicas. A Figura 11 apresenta o esquema geral dos métodos desenvolvidos neste mestrado.

Neste capítulo, são apresentados os métodos desenvolvidos ao decorrer deste mestrado.

Figura 11 – Ilustração geral da metodologia proposta. (1) métodos baseados em redes complexas e CDPARs são desenvolvidos; (2) caracterização das texturas dinâmicas; (3) treinamento e classificação.

Fonte: Elaborada pelo autor.

4.1 Difusão em redes direcionadas aplicado em texturas dinâmicas

Nesta seção é proposto um método para reconhecimento de texturas dinâmicas baseado em difusão em redes complexas. De acordo com o conhecimento do autor, este é o segundo trabalho a utilizar redes complexas no reconhecimento de texturas dinâmicas. No método proposto neste mestrado, a textura dinâmica é modelada como uma rede direcionada e, a difusão na rede é utilizada para caracterizar as texturas dinâmicas modeladas. A difusão é uma medida mais sofisticada que caracteriza as redes por meio de caminhadas aleatórias. Em [Gonçalves et al. \(2016\)](#) a difusão em redes foi utilizada para caracterizar texturas estáticas com excelentes resultados. Assim, é esperado que cada classe de textura dinâmica resulte em redes com características topológicas específicas e que essas sejam medidas pela atividade na rede.

Basicamente, o método proposto para reconhecimento de texturas dinâmicas baseado em atividade em redes direcionadas pode ser descrito em quatro passos. Os passos que estão ilustrados na Figura 12, são:

- Passo 1 - Modelar texturas dinâmicas como uma rede regular: primeiramente, o vídeo da textura dinâmica é modelado como uma rede regular direcionada. Para isso cada pixel é considerado um vértice. Cada vértice é ligado a outros vértices de acordo com um dado raio de distância Euclidiana e um peso é definido como a diferença de intensidade de cinza entre os vértices.
- Passo 2 - Explorar a dinâmica da rede: a rede direcionada é transformada por uma função de corte aplicada sobre as arestas. Esta função consiste em remover arestas em que o peso é maior que um dado limiar, evidenciando características específicas de cada padrão da textura dinâmica.
- Passo 3 - Difusão em redes: caminhadas aleatórias são iniciadas de cada vértice das redes direcionadas obtidas no passo 2. O caminhante move de acordo com um sorteio aleatório em que a probabilidade de visita de um vértice está associada ao peso da aresta. A atividade de cada vértice é então o número de visitas em equilíbrio recebidas pelas caminhadas aleatórias.
- Passo 4 - Vetor de características: são consideradas as características de aparência e movimento da textura dinâmica para compor o vetor de características. Assim, é obtido um histograma da atividade associada ao grau de entrada temporal (i.e. número de arestas que conectam um vértice a outros em diferentes quadros) e um histograma de atividade associado ao grau de entrada espacial (i.e. número de arestas que ligam um vértice a outros no mesmo quadro).

Nas seções a seguir, os passos do método proposto são descritos com mais detalhes.

Figura 12 – Ilustração dos 4 passos do método proposto para reconhecimento de texturas dinâmicas baseado na atividade em redes direcionadas.

Fonte: Elaborada pelo autor.

4.1.1 Modelagem de texturas dinâmicas em redes direcionadas

Neste método, o vídeo é considerado uma matriz em três dimensões que contém todos os quadros. Assim, cada pixel i pode ser endereçado como $i = (x_i, y_i, t_i)$, onde t é o tempo ou, em termos discretos, o quadro que o pixel pertence e, x, y são suas coordenadas. Neste modelo,

a intensidade de um pixel é dada por $I(i) \in [0, 255]$. Para modelar o vídeo de textura dinâmica em uma rede $R = (V, E)$, cada pixel i é mapeado em um vértice $v_i \in V$. Dois vértices v_i e v_j associados aos pixels i e j são conectados por uma aresta $e_{v_i, v_j} \in E$, se a distância Euclidiana $D(i, j)$ entre i e j é menor ou igual a um dado raio r (Equação 4.1) (GONÇALVES; MACHADO; BRUNO, 2015).

$$e_{v_i, v_j} \in E | D(i, j) \leq r, \quad (4.1)$$

onde $D(i, j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2 + (t_i - t_j)^2}$ é a distância euclidiana entre os pixels i e j .

Na Figura 13 é apresentado um exemplo de rede regular obtida a partir de um vídeo de textura com três quadros. Cada vértice está conectado com vértices do mesmo quadro e de quadros diferentes. Além disso, cada vértice possui o mesmo grau, com exceção aos da borda.

Figura 13 – Rede regular modelando uma textura dinâmica com três quadros.

Fonte: Elaborada pelo autor.

Para cada aresta da rede, é atribuído um peso $w(e_{v_i, v_j})$ de acordo com a diferença de intensidade entre os pixels que correspondem aos vértices:

$$w(e_{v_i, v_j}) = |I(i) - I(j)|, \text{ se } D(i, j) \leq r \quad (4.2)$$

É importante ressaltar que os pesos das arestas são invariantes a mudanças de iluminação, devido a diferença $I(i) - I(j)$ não ser afetada por alterações de iluminação homogênea (GONÇALVES et al., 2016).

Como o objetivo é obter redes direcionadas para estimativa da atividade, é preciso considerar uma direção para as arestas. Observando a Equação 4.2 é possível notar que são obtidos pesos negativos quando $I(i) < I(j)$. Assim, neste trabalho é considerado somente arestas com peso positivo e, portanto, uma aresta e_{v_i, v_j} é direcionada de v_i para v_j , se $I(i) > I(j)$. A modelagem com redes direcionadas é mais apropriada no uso de processos dinâmicos para captar características topológicas da rede, como é o caso das caminhadas aleatórias. Portanto, este trabalho além de utilizar uma abordagem diferente para descrição da rede, também difere da proposta anterior de redes em texturas dinâmicas (GONÇALVES; MACHADO; BRUNO, 2015) no uso de redes direcionadas.

4.1.2 Aplicação da função de limiar sobre as arestas

Apesar de ter obtido uma rede, esta possui comportamento regular (se não considerarmos a direção) e, portanto, não apresenta nenhuma propriedade importante ou comportamento complexo. Neste passo, a rede é transformada para que propriedades relevantes da textura dinâmica sejam evidenciadas. Uma abordagem interessante para extrair informações da estrutura e dinâmica da rede é aplicar uma série de transformações sobre a rede original e caracterizar as estruturas obtidas em cada etapa (COSTA et al., 2007). A transformação pode ser realizada na rede aplicando uma função de limiar $f(t, E)$ sobre o conjunto de arestas. Esta função consiste em selecionar um conjunto $E_t, E_t \subseteq E$, onde cada aresta $e_{v_i, v_j} \in E_t$ possui peso menor ou igual a um dado limiar t (Equação 4.3) (GONÇALVES et al., 2012; BACKES; CASANOVA; BRUNO, 2013).

$$E_t = f(t, E) = \{ e_{v_i, v_j} \in E \mid 0 < w(e_{v_i, v_j}) \leq t \} \quad (4.3)$$

O novo conjunto de arestas E_t e o conjunto original de vértices V , constitui a nova rede $R_t = (V, E_t)$, que representa um estágio intermediário da evolução da rede (BACKES; CASANOVA; BRUNO, 2013).

Exemplos da aplicação da função $f(t, E)$ sobre uma rede regular é apresentado na Figura 14. A evolução da rede ao aplicar a função $f(t, E)$ com diferentes valores de t pode ser considerada uma análise multi-escala da rede (GONÇALVES; SILVA; BRUNO, 2010). Para valores baixo de t (Figura 14(b)) é possível analisar e descrever micro detalhes da textura, enquanto, a medida que t é incrementado detalhes globais são realizados. Assim, o método proposto aplica um conjunto de limiares $t, t \in G$, sobre a rede original, e combina as características extraídas pela atividade em redes transformadas com limiares t para obter uma análise multi-escala.

Figura 14 – Exemplos da aplicação da função $f(t, E)$ sobre as arestas de uma rede regular: (a) Rede regular, (b) $t = 20$, (c) $t = 50$, (d) $t = 80$.

Fonte: Elaborada pelo autor.

4.1.3 Estimativa da atividade de textura dinâmica

Para caracterizar as redes transformadas pela função de limiar, é utilizada a atividade estimada de cada vértice da rede. A atividade de um vértice é estimada por caminhadas aleatórias. Considere uma partícula que está no vértice v_i , o próximo passo é visitar um vértice v_j com probabilidade:

$$p(v_i, v_j) = \frac{w(e_{v_i, v_j})}{\hat{A}_{v_k 2h(v_i)} w(e_{v_i, v_k})}, \quad (4.4)$$

em que $h(v_i)$ são os vértices adjacentes ao vértice v_i . De acordo com esta probabilidade, a aresta que tiver maior peso (i.e. a maior diferença de nível de cinza entre dois pixels) terá maior prioridade para ser escolhida pela partícula. A partícula realiza a caminhada de acordo com Equação 4.4 até encontrar um vértice absorvente (i.e. o vértice não possui nenhuma aresta de saída) ou enquanto o comprimento da caminhada for menor do que um dado valor máximo $L = 1000$. A atividade $a(v_i)$ do vértice v_i é definida como o número de vezes que a partícula visitou o vértice durante todas as caminhadas realizadas no vídeo. Por se tratar de um processo estocástico, para estimar com maior precisão a atividade, M caminhadas são iniciadas de cada vértice da rede (neste trabalho foi considerado $M = 50$). Este valor foi considerado com base em testes prévios realizados com o método. Nos testes foi possível observar que para valores

maiores do que $M = 50$ a taxa de classificação estabiliza.

A Figura 15 mostra imagens da atividade do primeiro quadro, do movimento lateral e superior dos pixels/vértices de uma textura dinâmica para diferentes valores de raio r e limiar t utilizados para modelar a textura em uma rede. Como pode ser visto, a atividade dos pixels reflete as principais propriedades da textura dinâmica, mantendo as características de aparência e movimento. Os pixels próximos de bordas tendem a possuir atividade elevada, devido ao peso de suas arestas serem maiores do que em regiões homogêneas (GONÇALVES et al., 2016). Isto é, o peso da aresta que liga um pixel p_i com intensidade $I(p_i) = 255$ a um pixel p_j com intensidade $I(p_j) = 0$ é $w(e_{v_i, v_j}) = 255$, o que atrai a partícula aleatória a visitar o pixel p_j .

Além disso, ao incrementar o limiar t e o raio r é possível notar que a borda fica em maior evidência, ou seja, os pixels próximos da borda possuem maior atividade e o de regiões homogêneas menor atividade. Isso ocorre por dois motivos. O primeiro é o aumento do limiar, que mantém um maior número de arestas na rede, fazendo com que as partículas se movam mais rapidamente para as bordas. O segundo é o aumento do raio, que faz com que as partículas alcancem mais rapidamente os pixels da borda, sem precisar caminhar por pixels intermediários.

Na Figura 16, é mostrado imagens da atividade dos pixels/vértices para diferentes texturas dinâmicas, utilizado $r = \frac{p}{2}$ e $t = 120$ para construir a rede direcionada. É possível observar que a atividade consegue caracterizar diferentes tipos de texturas dinâmicas, captando características de movimento e aparência da textura.

4.1.4 Vetor de características

A atividade nas redes descreve importantes propriedades da textura. Em geral, para caracterizar uma textura estática é utilizado um histograma da atividade, que correlaciona a atividade do vértice e o seu grau de entrada. No entanto, como já citado, em texturas dinâmicas um dos desafios é descrever propriedades de aparência e movimento da textura. Para isso, neste trabalho é proposto correlacionar a atividade $a(v_i)$ do vértice v_i com o seu grau de entrada no mesmo quadro $k_m^{in}(v_i)$ e o grau de entrada temporal $k_t^{in}(v_i)$. O grau de entrada no mesmo quadro $k_m^{in}(v_i)$ é o número de arestas de entrada em v_i que vem de vértices que estão no mesmo quadro:

$$k_m^{in}(v_i) = \hat{A}_{v_j \in V} \begin{cases} 1, & e_{v_i, v_j} \in E \text{ e } t_i = t_j \\ 0, & \text{caso contrário} \end{cases} \quad (4.5)$$

Por outro lado o grau de entrada temporal $k_t^{in}(v_i)$ do vértice é o número de arestas de entrada em v_i que vem de vértices que estão em quadros diferentes de v_i :

$$k_t^{in}(v_i) = \hat{A}_{v_j \in V} \begin{cases} 1, & e_{v_i, v_j} \in E \text{ e } t_i \neq t_j \\ 0, & \text{caso contrário} \end{cases} \quad (4.6)$$

Figura 15 – Imagens da atividade dos pixels/vértices de uma textura dinâmica, com diferentes raios r e limiares t .

Fonte: Elaborada pelo autor.

Figura 16 – Imagens com a atividade do pixel/vértice de várias texturas dinâmicas. A rede foi construída com raio $r = 2$ e $\text{limiar } t = 120$.

Fonte: Elaborada pelo autor.

Correlacionando o grau de entrada no mesmo quadro e temporal é possível obter a

seguinte distribuição conjunta:

$$S^{r,t}(k_m^{in}, k_t^{in}) = \frac{1}{N} \hat{A}_{v_i 2V} \begin{cases} a^{r,t}(v_i), & k_m^{in}(v_i) = k_m^{in} \text{ e } k_t^{in}(v_i) = k_t^{in} \\ 0, & \text{caso contrário} \end{cases} \quad (4.7)$$

onde $N = M \rightarrow N \rightarrow T$ é o número de vértices da rede, r o raio e t o limiar.

Através desta distribuição conjunta, é possível descrever apropriadamente as texturas dinâmicas pelo método proposto. Exemplos de distribuição conjunta obtidas de três texturas dinâmicas são apresentados na Figura 17. As texturas dinâmicas foram modeladas em uma rede direcionada com $r = \sqrt{2}$ e $t = 30$. Para cada classe de textura dinâmica, é possível observar que as distribuições conjuntas obtidas são diferentes e que nem sempre os vértices com maior grau possuem maior atividade, refletindo as características de aparência e movimento da textura dinâmica.

Figura 17 – Exemplos de distribuições conjuntas obtidas de três texturas dinâmicas (ilustradas pelo primeiro quadro). As texturas dinâmicas foram modeladas em redes com $r = \sqrt{2}$ e $t = 30$.

Fonte: Elaborada pelo autor.

No entanto, devido ao grande número de informações presentes na distribuição conjunta, dois histogramas são calculados para agregar informações. O histograma $h_m^{r,t}(j)$ correlaciona a

atividade $a(v_i)$ e o grau de entrada no mesmo quadro k_m^{in} :

$$h_m^{r,t}(j) = \begin{cases} \hat{A} a^{r,t}(v_i), & k_m^{in}(v_i) = j \\ 0, & \text{caso contrário} \end{cases} \quad (4.8)$$

Enquanto o histograma $h_t^{r,t}(j)$ correlaciona a atividade $a(v_i)$ e o grau de entrada temporal k_t^{in} :

$$h_t^{r,t}(j) = \begin{cases} \hat{A} a^{r,t}(v_i), & k_t^{in}(v_i) = j \\ 0, & \text{caso contrário} \end{cases} \quad (4.9)$$

Para compreender os histogramas descritos acima, considere a seguinte interpretação. É esperado que quanto maior o grau de entrada, maior a probabilidade de um vértice receber uma visita. Entretanto, isto nem sempre ocorre devido ao peso das arestas, refletindo diretamente as propriedades das texturas dinâmicas na rede (GONCALVES, 2013). Além disso, pode ocorrer, por exemplo, de vértices com grau de entrada temporal $k_t^{in}(v_i) = 0$ possuir atividade $a^{r,t}(v_i)$ alta, o que reflete a aparência da textura em relação ao movimento. Neste caso, a atividade do vértice está diretamente relacionada somente com o grau de entrada no mesmo quadro $k_m^{in}(v_i)$. A situação inversa também pode ocorrer. Portanto, os histogramas de atividade contêm informações correlacionadas com a dinâmica e aparência da textura dinâmica.

Como ilustração, na Figura 18 são plotados alguns exemplos dos histogramas da atividade $h_m^{r,t}(j)$ e $h_t^{r,t}(j)$ com $r = \frac{p}{3}$ e $t = 100$. Os histogramas foram obtidos de quatro classes de texturas dinâmicas com três amostras cada classe (Figura 18(a)). As classes são chamadas de velas, ondas do mar filmadas de uma distância longe, ondas do mar filmadas de uma distância média e trânsito pesado de uma rodovia. A partir dos gráficos do histograma $h_m^{r,t}(j)$ (Figura 18(b)) e histograma $h_t^{r,t}(j)$ (Figura 18(c)), pode ser visto que cada classe de textura dinâmica apresenta um histograma diferente. Além disso, embora as texturas dinâmicas das classes onda médio e onda longe sejam parecidas, é possível separá-las usando o método.

Para obter uma análise multi-escala da textura dinâmica, são considerados os histogramas para diferentes valores de limiares t , $t \geq G$. O conjunto G é composto por valores de limiares que estão no intervalo $t_0 \leq t \leq t_f$ e incrementados pela constante t_i . Portanto, o vetor de característica do histograma $h_m^{r,t}$ que considera redes transformadas com um mesmo raio, é dado por:

$$y_m^r = [h_m^{r,t_0}, h_m^{r,t_0+t_i}, \dots, h_m^{r,t_f}]. \quad (4.10)$$

Para o histograma $h_t^{r,t}$, o vetor de característica é dado por:

$$y_t^r = [h_t^{r,t_0}, h_t^{r,t_0+t_i}, \dots, h_t^{r,t_f}]. \quad (4.11)$$

Por fim, para descrever características de aparência e movimento o vetor final j é composto pela concatenação dos vetores y_m^r e y_t^r para diferentes valores de raio r :

$$j = [y_m^{r_0}, y_t^{r_0}, \dots, y_m^{r_n}, y_t^{r_n}]. \quad (4.12)$$

Figura 18 – Histograma da atividade correlacionada com o grau de entrada no mesmo quadro $h_m^{r,t}(j)$ e no tempo $h_t^{r,t}(j)$ para quatro classes de texturas dinâmicas. As texturas dinâmicas foram modeladas em redes com $r = \sqrt{3}$ e $t = 100$.

Fonte: Elaborada pelo autor.

4.1.5 Análise de complexidade computacional

Basicamente, o método proposto converte um vídeo de textura de $n \rightarrow n \rightarrow T$ pixels em uma rede direcionada. Posteriormente, M caminhadas aleatórias de tamanho l são iniciadas de cada vértice para estimar a sua atividade como caracterização. Cada pixel é mapeado em um vértice, que é conectado com os $(2r + 1) \rightarrow (2r + 1) \rightarrow (2r + 1)$ vizinhos. Portanto, para construir a rede é necessária $O((2r + 1) \rightarrow (2r + 1) \rightarrow (2r + 1) \rightarrow n^2 \rightarrow T)$ operações. No entanto, na prática o raio r da vizinhança é muito menor que o número de pixels no vídeo, tal que $r \ll n^2 \rightarrow T$.

A complexidade computacional é dada então por $O(M \rightarrow I \rightarrow n^2 \rightarrow T)$. Entretanto, M é uma constante multiplicativa (nesse trabalho $M = 50$) em que $M \propto n^2 \rightarrow T$, podendo ser desconsiderada. A outra variável que afeta a complexidade é o tamanho da caminhada I . O melhor caso ocorre quando os vértices estão desconectados. Assim o tamanho da caminhada é $I = 1$, levando a uma complexidade de $O(n^2 \rightarrow T)$. O pior caso ocorre quando o tamanho de todas caminhadas for o máximo, ou seja, igual a L (neste trabalho $L = 1000$). A complexidade de pior caso é então $O(L \rightarrow n^2 \rightarrow T)$.

O caso médio é avaliado na base de dados Dyntex++ (GHANEM; AHUJA, 2010a), que possui 3600 amostras de vídeo de $50 \rightarrow 50 \rightarrow 50$. A Figura 19, apresenta o tamanho médio da caminhada para diferentes raios r e limiares t . Em geral, o tamanho médio das caminhadas é menor do que 5, por exemplo, para $r = \sqrt[4]{p}$ e $t = 20$ o tamanho médio é $I = 3.46$. Isso leva a uma complexidade computacional bem próxima do melhor caso, que é $O(n^2 \rightarrow T)$. Portanto, a complexidade do método é competitiva em relação aos métodos tradicionais da literatura.

Figura 19 – Tamanho médio da caminhada em função do limiar e com vários tamanhos de raio para a base Dyntex++.

Fonte: Elaborada pelo autor.

4.2 Caminhada determinística parcialmente auto-repulsiva aplicada em textura dinâmica

Na caracterização de texturas dinâmicas, dois tipos de informações são importantes para a tarefa de reconhecimento: características espaciais relacionadas à aparência e características temporais associadas ao movimento das texturas dinâmicas. Nesse sentido, para contemplar essas

informações, nesta seção são propostos dois tipos de descritores: espacial e temporal. Assim, para descrever as texturas dinâmicas, as CDPARs são executadas independentemente em cada descritor. Como ilustra a Figura 20, o método proposto pode ser descrito em três passos:

- **Descritores espacial e temporal:** a textura dinâmica presente no vídeo é caracterizada considerando dois tipos de descritores: espacial, que é responsável pelas informações de aparência e, temporal, que caracteriza as informações de movimento.
- **Execução das CDPARs:** caminhadas independentes com diferentes tamanhos de memória e regra de movimento são executadas para a obtenção de uma distribuição conjunta contendo informações de aparência e outra com informações de movimento da textura dinâmica.
- **Vetor de características:** um histograma de frequências de tamanho de trajetórias é obtido de cada distribuição conjunta. Por fim, o vetor de característica final é composto pela concatenação de características de aparência e movimento com diferentes valores de memória e regra de movimento.

Nas seções a seguir, os passos do método proposto são descritos em detalhes.

Figura 20 – Ilustração das etapas do método proposto de CDPARs executadas em descritores espacial e temporal para caracterização de texturas dinâmicas.

Fonte: Elaborada pelo autor.

4.2.1 CDPARs aplicadas em vídeo

Dado um vídeo de texturas dinâmicas, este consiste em um conjunto finito de pixels P e um mapeamento I que atribui para cada pixel $i = (x_i, y_i, t_i) \in P$ uma intensidade $I(i) \in [0, 255]$. As

coordenadas do vídeo são definidas como: $x_i \in [0, W]$ e $y_i \in [0, H]$ são as coordenadas espaciais e $t_i \in [0, T]$ é a coordenada temporal do vídeo. Cada pixel possui uma vizinhança $h(i)$ contendo os pixels vizinhos.

Um dos desafios para caracterizar texturas dinâmicas é descrever as características de movimento e aparência do vídeo apropriadamente. Deste modo, é proposta uma estratégia para executar as CDPARs, que separa o vídeo em descritores espaciais e temporais, como ilustra a Figura 21. Basicamente, a vizinhança $h(i)$ é alterada de modo que um conjunto de vizinhos seja definido para os descritores espaciais e outro conjunto para os descritores temporais. A mudança na função de vizinhança altera a trajetória do turista, o que permite explorar diferentes propriedades da textura dinâmica presente no vídeo.

Figura 21 – Ilustração dos descritores espacial e temporal de um vídeo de textura dinâmica. No descritor espacial a CDPAR só pode mover-se em pixels do mesmo quadro, enquanto no descritor temporal a CDPAR só pode mover-se em pixels de diferentes quadros.

Fonte: Elaborada pelo autor.

O descritor espacial tem como objetivo descrever as características de aparência presentes nas texturas dinâmicas. Assim, o turista caminha somente em pixels que pertencem ao mesmo quadro do vídeo, como ilustrado na Figura 21(a). Isto é, a variância espacial das texturas dinâmicas são descritas para cada quadro, de maneira independente (GONÇALVES; BRUNO, 2013c). Portanto, a vizinhança é definida de modo que um pixel j pertence ao conjunto de vizinhos $h(i)^E$, se a distância Euclidiana entre i e j é menor do que $\frac{p}{2}$ e as coordenadas temporais t_i e t_j forem iguais, de acordo com:

$$h(i)^E = \{ j \mid \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \leq \frac{p}{2} \text{ e } t_i = t_j \}. \quad (4.13)$$

No que tange ao descritor temporal, este visa realçar as características de movimento da textura dinâmica. Neste descritor, o turista caminha entre diferentes quadros, caracterizando a variação temporal dos padrões de texturas dinâmicas presentes no vídeo (Figura 21(b)). Deste

modo, a vizinhança $h(i)^T$ é definida pelos pixels j cuja a distância Euclidiana é menor do que $\sqrt[3]{p}$ e a coordenada t_i é diferente a t_j , de acordo com:

$$h(i)^T = \{j \mid \sqrt[3]{\frac{q}{(x_i - x_j)^2 + (y_i - y_j)^2 + (t_i - t_j)^2}} \leq \sqrt[3]{p} \text{ e } t_i \neq t_j\}. \quad (4.14)$$

Para descrever os padrões de movimento e aparência das texturas dinâmicas, CDPA Rs são iniciadas de maneira independente para os descritores espaciais e temporais. Portanto, para os descritores espaciais E , dado que um turista está em um pixel w_t , o próximo passo é mover-se para um pixel da vizinhança $h(w_t)^E$ que minimize o peso de conexão $w(i, j) = |I(i)^E - I(j)^E|$ e que não esteja na memória M_u . Além da regra de movimento $r = \min$ que minimiza o peso $w(i, j)$, o turista também é executado de forma análoga usando a regra $r = \max$ que maximiza o peso. Para os descritores temporais, a ideia é a mesma, entretanto, agora as CDPA Rs são executadas considerando a vizinhança $h(w_t)^T$. Assim, a variação dos pixels no tempo pode ser explorada para descrever a textura dinâmica.

Uma vez iniciada uma CDPA R usando a regra descrita acima, o turista caminha t_i^E passos até encontrar um atrator de período r_i^E em que é aprisionado. Cada situação inicial produz uma trajetória diferente, portanto, cada pixel i é considerado um ponto inicial de caminhada. Desta forma, a distribuição conjunta $S_{\mu,r}^E(t, r)$ que calcula a probabilidade de trajetórias com tempo de transiente t_i^E e período de atrator r_i^E é obtida de acordo com a Equação:

$$S_{\mu,r}^E(t, r) = \frac{1}{N} \sum_{i=1}^N \begin{cases} 1, & \text{se } t_i^E = t \text{ e } r_i^E = r \\ 0, & \text{caso contrário} \end{cases} \quad (4.15)$$

onde μ é o tamanho da memória, r é a regra de movimento e $N = W \rightarrow H \rightarrow T$ é o número de pixels do vídeo.

Para cada descritor, CDPA Rs são executadas de forma independente. Deste modo, duas distribuições conjuntas são obtidas: $S_{\mu,r}^E(t, r)$ e $S_{\mu,r}^T(t, r)$. A distribuição $S_{\mu,r}^T(t, r)$ é obtida de forma análoga pela Equação 4.15. A partir dessas distribuições, o método proposto combina informações relacionadas à aparência e movimento, caracterizando apropriadamente as texturas dinâmicas.

4.2.2 Vetor de características

A distribuição conjunta $S_{\mu,r}^Q(t, r)$ (onde Q é um dos dois descritores) contém um enorme número de informações sobre o ambiente em que as CDPA Rs foram realizadas. Nesse sentido, diversos trabalhos investigaram maneiras de representação a partir desta distribuição (BACKES et al., 2010). Aqui, é utilizado um histograma $h_{\mu,r}^Q(I)$ que sumariza a frequência de trajetórias com tamanho igual a $(I = t + r)$ em uma distribuição com tamanho de memória μ e uma regra

de movimento r :

$$h_{\mu,r}^Q(l) = \sum_{b=0}^{l \lfloor \frac{E}{r} \rfloor} S_{\mu,r}^Q(b, l \lfloor \frac{E}{r} \rfloor b). \quad (4.16)$$

Este histograma provou conseguir bons resultados em termos de classificação (GONÇALVES; BRUNO, 2013a; GONÇALVES et al., 2012). Diversos trabalhos anteriores mostraram que as principais informações do histograma $h_{\mu,r}^Q(l)$ concentram-se nos seus primeiros elementos (BACKES et al., 2010; GONÇALVES; BRUNO, 2013b). Portanto, os primeiros n elementos do histograma são selecionados para compor o vetor de característica. Como não existem atratores de tamanho menor do que $\mu + 1$, a primeira posição usada do histograma é a $\mu + 1$. Assim, dado um tamanho de memória específico μ e uma regra de movimento r , um vetor de característica $n_{\mu,r}^Q$ é construído:

$$n_{\mu,r}^Q = [h_{\mu,r}^Q(\mu + 1), h_{\mu,r}^Q(\mu + 2), \dots, h_{\mu,r}^Q(\mu + n)] \quad (4.17)$$

O tamanho da memória influencia diretamente na complexidade das trajetórias e, consequentemente, nas informações extraídas pelo método. Por exemplo, CDPARs executadas com baixos valores de memória realizam uma melhor análise local (GONÇALVES; BRUNO, 2013c). Nesse sentido, histogramas obtidos com diferentes tamanhos de memória são utilizados para uma caracterização mais robusta dos diferentes padrões presentes em vídeos de texturas dinâmicas, de acordo com:

$$J_r^Q = [n_{\mu_1,r}^Q, n_{\mu_2,r}^Q, \dots, n_{\mu_m,r}^Q]. \quad (4.18)$$

Esta estratégia vem sendo discutida e usada para aprimorar a caracterização por vários trabalhos anteriores que utilizam CDPARs (GONÇALVES et al., 2012; BACKES et al., 2010; BACKES, 2010). Para caracterizar padrões de aparência e movimento das texturas dinâmicas é considerado um vetor de característica que consiste da concatenação dos descritores espacial e temporal. Deste modo, este vetor de característica é composto das características extraídas a partir do descritor espacial E e temporal T usando diferentes valores de memória, como descrito na Equação:

$$I_r = [J_r^E, J_r^T]. \quad (4.19)$$

O vetor obtido na Equação 4.19 é referente a uma única regra de movimento. Embora este vetor possa ser capaz de caracterizar apropriadamente as texturas dinâmicas, uma outra possibilidade é combinar as duas regras de movimento. A regra de movimento é outro parâmetro que influencia na trajetória do turista. Portanto, informações diferentes são extraídas de acordo com cada uma. Nesse sentido, é considerado um vetor final que consiste na concatenação de

vetores de características obtidos com as duas regras de movimento $r = \min$ e $r = \max$, como descreve a Equação:

$$I = [I_{\min}, I_{\max}] \quad (4.20)$$

É importante ressaltar que este vetor final pode não alcançar necessariamente o melhor resultado, na Seção 5.2.2.1 será analisado detalhadamente o efeito de cada vetor de característica em termos de classificação.

4.3 Redes complexas geradas por CDPARs para textura dinâmica

Nesta seção é apresentada a metodologia desenvolvida para análise de texturas dinâmicas combinando CDPARs e redes complexas. Até o momento foi abordado à utilização dessas duas ferramentas para análise de texturas dinâmicas de maneira independente. No entanto, como investigado por vários trabalhos (GONÇALVES et al., 2012; BACKES; MARTINEZ; BRUNO, 2011; GONÇALVES; MARTINEZ; BRUNO, 2012), as CDPARs e redes complexas podem ser combinadas de modo a potencializar os resultados na tarefa de reconhecimento de padrões.

Apesar dos resultados promissores dos métodos de textura dinâmica baseado em CDPARs, estes consideram somente o tamanho dos atratores e tempo de transiente obtidos da distribuição conjunta para caracterização. No entanto, certamente as trajetórias do turista fornecem informações muito mais ricas do meio em que são realizadas. Deste modo, nesta seção é avaliada a utilização das CDPARs sobre as texturas dinâmicas como forma de gerar redes complexas, para posterior extração de características. Assim, o método proposto aqui, em vez de utilizar somente o tamanho e frequência das trajetórias, considera também o arranjo espacial dos atratores e transientes. A capacidade de modelagem e as medidas de redes complexas podem obter importantes informações das trajetórias e, conseqüentemente, das texturas dinâmicas.

Para executar as CDPARs nos vídeos de textura dinâmica foram consideradas duas estratégias: descritor espacial e temporal (descrito na Seção 4.2) e três planos ortogonais XY, XT e YT (proposto em (GONÇALVES; BRUNO, 2013c; ZHAO; PIETIKAINEN, 2007b; GONÇALVES; BRUNO, 2013a)). Portanto, o estudo realizado aqui contribui para a área de duas formas: um novo tipo de análise de trajetórias de CDPARs em vídeo e uma nova metodologia de modelagem de vídeos em redes complexas. De forma resumida, a metodologia proposta pode ser descrita em três passos, que estão ilustrados na Figura 22.

- 1- Estratégia de execução: inicialmente, uma estratégia para execução das CDPARs em vídeos é definida. As CDPARs podem ser executadas usando descritores espaciais e temporais ou planos ortogonais.

- 2- Execução das CDPARs: a CDPAR com um tamanho de memória e regra de movimento é aplicada sobre os vídeos gerando redes complexas das trajetórias. Cada aresta da rede corresponde a um movimento do turista entre dois pixels.
- 3- Redes geradas e caracterização: medidas estatísticas são extraídas das redes geradas para caracterização das texturas dinâmicas. Um vetor de características final é composto de medidas de redes geradas por CDPARs com diferentes tamanhos de memória e regra de movimento.

Figura 22 – Visão geral do método proposto de redes geradas por CDPARs. (1) Uma estratégia de execução é definida; (2) CDPARs são executadas nos vídeos de texturas dinâmicas; (3) redes são geradas e medidas estatísticas são extraídas.

Fonte: Elaborada pelo autor.

4.3.1 Modelagem de texturas dinâmicas em redes por meio de CDPARs

Nesta dissertação e em trabalhos anteriores em geral, as CDPARs são caracterizadas por meio da distribuição conjunta do tempo de transiente e período do atrator das trajetórias. Aqui, as CDPARs são analisadas por meio do comportamento das trajetórias produzidas pelo turista nos vídeos de textura dinâmica. Basicamente, a trajetória é a sequência de passos realizada pelo turista entre pixels, de acordo com uma memória e uma regra de movimento. Para analisar tais trajetórias, cada movimento realizado pelo turista entre dois pixels pode ser considerado uma

aresta de uma rede (BACKES; MARTINEZ; BRUNO, 2011). Deste modo, uma rede pode ser construída a partir do conjunto de trajetórias realizadas pela CDPAR em um vídeo. Uma vez obtida uma rede, medidas estatísticas da sua estrutura podem ser usadas para caracterizar as trajetórias formadas pelo transiente e o atrator.

Considere uma rede $R_{\mu,r}$ gerada por CDPARs com memória μ e regra de movimento r . Esta rede consiste de um par $R_{\mu,r} = (V, A)$, em que V é um conjunto de vértices e A um conjunto de arestas. Cada vértice v_i corresponde a um pixel i do vídeo e, o movimento do turista entre dois pixels i e j corresponde a uma aresta não-direcionada a_{v_i,v_j} adicionada ao conjunto A ligando os vértices v_i e v_j . O turista irá se movimentar de acordo com uma regra determinística r (min ou max) e uma memória M_μ de tamanho μ até ficar aprisionado em um atrator. É importante ressaltar que o turista pode se movimentar entre dois pixels várias vezes, entretanto, somente uma aresta ligando os vértices correspondentes é adicionada ao conjunto A . Isto é, uma aresta a_{v_i,v_j} só é adicionada ao conjunto A caso $a_{v_i,v_j} \notin A$. Além disso, cada aresta possui um peso que corresponde ao módulo da diferença de intensidade entre os dois pixels que representam os vértices $w(v_i, v_j) = |I(i) - I(j)|$.

Seguindo a descrição acima, dada uma trajetória iniciada de um pixel i de tamanho $(l = t + r)$, a sua conversão em arestas e adição ao conjunto A pode ser definida como

$$A = \bigcup_{w=1}^l \{ a_{v_w, v_{w+1}} \mid a_{v_w, v_{w+1}} \notin A \}. \quad (4.21)$$

A Figura 23 exemplifica uma CDPAR com tamanho de memória $\mu = 5$ e regra de movimento $r = \text{min}$ saindo de um pixel de uma imagem em nível de cinza e a rede gerada por ela. Na imagem (Figura 23(a)), cada pixel é representado por um quadrado com o seu nível de cinza. O transiente da trajetória são os pixels azuis e o ciclo do atrator é representado pelos pixels em verde. Uma rede em que cada pixel corresponde a um vértice é gerada com cada passo da CDPAR representando uma aresta (Figura 23(b)).

Cada pixel é considerado uma condição inicial de caminhada, portanto, são N trajetórias em um vídeo de $N = W \rightarrow H \rightarrow T$ pixels. Dado as N trajetórias, uma rede sem vértices desconectados pode ser construída para, em seguida, realizar a extração de características. Uma vez que as CDPARs são baseadas na variação de nível de cinza do vídeo, as arestas das trajetórias refletem diretamente os padrões de texturas. Dessa forma, a estrutura da rede possuirá informações dos transientes e atratores e, conseqüentemente, importantes propriedades da textura dinâmica analisada. Como em texturas dinâmicas é necessário caracterizar padrões relacionados ao movimento e aparência, uma única rede gerada por uma simples aplicação das CDPARs no vídeo não contemplaria essas propriedades. Portanto, é necessário definir uma estratégia para aplicar as CDPARs nos vídeos de modo que padrões de aparência e movimento sejam analisados separadamente. Nessa dissertação, são estudadas duas diferentes estratégias para executar as CDPARs em vídeos e gerar redes. A seguir, essas duas estratégias são apresentadas em detalhes.

Figura 23 – Exemplo de uma CDPAR com memória $\mu = 5$ e regra de movimento $r = \text{min}$ executada em uma imagem em nível de cinza, com a respectiva rede gerada pela caminhada.

Fonte: Elaborada pelo autor.

4.3.1.1 Descritores Espacial e Temporal

Para aplicar a CDPAR em vídeos de textura dinâmica, uma estratégia considerada é usar os descritores espacial e temporal, como descrito na Seção 4.2. Dessa forma, dado um vídeo e considerando o descritor espacial E , CDPARs com um tamanho de memória μ e regra de movimento r são executadas para gerar uma rede $R_{\mu,r}^E$. Essa rede representa as regiões transitivas e atrativas para o descritor espacial e , consequentemente, caracteriza as propriedades de aparência da textura dinâmica.

Por outro lado, considerando o descritor temporal T , outra rede $R_{\mu,r}^T$ é gerada executando CDPARs com um tamanho de memória μ e regra de movimento r . A rede gerada contém informações das trajetórias realizadas pelo turista no tempo. Assim, informações relacionadas ao movimento dos vídeos de textura podem ser caracterizadas por meio de medidas extraídas da estrutura da rede. A Figura 24 ilustra redes geradas por CDPAS a partir de um vídeo para os dois descritores.

4.3.1.2 Planos Ortogonais

Uma segunda estratégia considerada para executar as CDPARs nos vídeos de textura dinâmica e gerar as redes é a divisão do vídeo em três planos ortogonais, proposta em (GONÇALVES; BRUNO, 2013c; GONÇALVES; BRUNO, 2013a). Os três planos denominados XY, XT e YT são mostrados na Figura 25. Basicamente, os planos definem a função de vizinhança $h(i)$ de um pixel, alterando as trajetórias do turista. A ideia é que cada plano realce diferentes características do vídeo: o plano XY é responsável pelas características de aparência, enquanto os planos XT e YT correspondem às características de movimento.

Figura 24 – Ilustração de redes geradas por CDPARs para os descritores espacial e temporal de um vídeo de textura dinâmica. No descritor espacial as arestas conectam somente vértices que correspondem a pixels do mesmo quadro, enquanto no descritor temporal as arestas ligam vértices referentes a pixels de quadros diferentes.

Fonte: Elaborada pelo autor.

Figura 25 – Ilustração dos três planos ortogonais de um vídeo de textura dinâmica.

Fonte: Elaborada pelo autor.

No plano XY o turista irá caminhar em pixels do mesmo quadro, caracterizando a variação espacial da distribuição de nível de cinza nos vídeos. Portanto, a vizinhança $h^{XY}(i)$ de um pixel i no plano XY é definida como todos pixels j que estão a uma distância Euclidiana menor ou igual à $\sqrt[p]{2}$ e o índice temporal t_i e t_j é igual, de acordo com:

$$h(i)^{XY} = \{ j \mid \sqrt[p]{(x_i - x_j)^2 + (y_i - y_j)^2} \leq \sqrt[p]{2} \text{ e } t_i = t_j \}. \quad (4.22)$$

Para o plano XT, a vizinhança $h^{XT}(i)$ de um pixel i é definida como os pixels j cuja a distância Euclidiana é menor ou igual à $\sqrt[p]{2}$ e se as coordenadas y_i e y_j forem iguais, como dado por:

$$h(i)^{XT} = \{ j \mid \sqrt[p]{(x_i - x_j)^2 + (t_i - t_j)^2} \leq \sqrt[p]{2} \text{ e } y_i = y_j \}. \quad (4.23)$$

Por outro lado, no plano YT, um pixel j pertence a vizinhança $h^{YT}(i)$ se as coordenadas x_i e x_j forem iguais, de acordo com:

$$h(i)^{YT} = \{j \mid \sqrt{(t_i - t_j)^2 + (y_i - y_j)^2} \leq \frac{p}{2} \text{ e } x_i = x_j\}. \quad (4.24)$$

Para gerar redes com características de movimento e aparência, CDPARs são executadas de maneira independente em cada plano ortogonal. Assim, dado um vídeo, CDPARs com memória μ e regra de movimento r são executadas independentemente nos planos XY, XT e YT para gerar as redes correspondentes $R_{\mu,r}^{XY}$, $R_{\mu,r}^{XT}$ e $R_{\mu,r}^{YT}$. Tais redes são responsáveis por descrever as características de aparência ($R_{\mu,r}^{XY}$) e de movimento ($R_{\mu,r}^{XT}$ e $R_{\mu,r}^{YT}$) da textura dinâmica. A Figura 26 ilustra redes geradas por CDPARs em cada plano ortogonal.

Figura 26 – Ilustração de redes geradas por CDPARs para modelar os três planos ortogonais de um vídeo de textura dinâmica.

Fonte: Elaborada pelo autor.

4.3.2 Vetor de Características

A proposta deste método é utilizar as características topológicas das redes geradas pelas CDPARs para caracterizar as texturas dinâmicas. Para tanto, são consideradas medidas de redes complexas baseada no grau k , grau ponderado $\bar{k}$ e grau conjunto $\mathbf{k}$ dos vértices. O grau k_{v_i} de um vértice v_i é o número de arestas adjacentes a ele, enquanto o grau ponderado $\bar{k}_{v_i}$ é a soma dos pesos das arestas adjacentes ao vértice v_i . Já o grau conjunto $\mathbf{k}_{v_i}$ é uma medida de correlação entre dois vértices que é definido como a probabilidade de ter um vértice v_i adjacente a outro v_j com o mesmo grau. Essa medida pode quantificar o comportamento do turista em uma determinada região da rede e como consequência na textura dinâmica (BACKES; MARTINEZ; BRUNO, 2011). Por exemplo, vértices com o mesmo grau pode indicar que o turista tem um mesmo comportamento naquela região.

A partir dessas medidas dos vértices é possível calcular a distribuição do grau $P(k)$, que dá a probabilidade de um vértice v_i ter grau k . Dessa distribuição são obtidas as seguintes

medidas de heterogeneidade: entropia H , contraste C e energia E . Essas medidas foram descritas na Seção 3.1.3.1. Além dessas, foram usadas a entropia do grau conjunto

$$H = - \sum_{v_i}^N k_{v_i} \log_2[k_{v_i}], \quad (4.25)$$

e a energia do grau ponderado

$$E = \sum_{v_i}^N k_{v_i}^2. \quad (4.26)$$

Para caracterizar um vídeo de textura dinâmica, uma rede $R_{\mu,r}^Q$ para um descritor ou plano ortogonal Q é gerada por CDPARs com um tamanho de memória μ e regra de movimento r . Em seguida, as cinco medidas estatísticas descritas acima são extraídas da rede para compor um vetor de características $V_{\mu,r}^Q$ (Equação 4.27). Essa combinação foi definida devido ao melhor desempenho em classificação comparado com outras combinações testadas nos experimentos, como mostrado na Seção 5.2.3. Assim, com esse vetor é possível medir a dispersão de pares de vértices com o mesmo grau e a heterogeneidade da rede, caracterizando o comportamento do turista na textura dinâmica.

$$V_{\mu,r}^Q = [H_{\mu,r}^Q, C_{\mu,r}^Q, E_{\mu,r}^Q, H_{\mu,r}^Q, E_{\mu,r}^Q] \quad (4.27)$$

Como já discutido, a trajetória é fortemente dependente da regra de movimentação e o tamanho da memória usada pela CDPAR. Dessa forma, para caracterizar diferentes propriedades da textura dinâmica, medidas estatísticas são extraídas de redes geradas por CDPARs com diferentes tamanhos de memória. Assim, um segundo vetor de características consiste na concatenação de medidas extraídas para diferentes memórias, dado por:

$$J_r^Q = [V_{\mu_1,r}^Q, V_{\mu_2,r}^Q, \dots, V_{\mu_n,r}^Q]. \quad (4.28)$$

Para combinar características de movimento e aparência, concatenações do vetor J_r^Q devem ser feitas de acordo com a estratégia de aplicação das CDPARs no vídeo. Na estratégia de descritores espacial e temporal, medidas extraídas de redes geradas de cada descritor é combinada para formar um vetor u_r que contém características de aparência e movimento, de acordo com:

$$u_r = [J_r^E, J_r^T]. \quad (4.29)$$

Do mesmo modo, ao usar a estratégia de planos ortogonais, medidas obtidas a partir dos três planos são concatenadas para compor um vetor j_r , dado por:

$$j_r = [J_r^{XY}, J_r^{XT}, J_r^{YT}]. \quad (4.30)$$

Uma vez combinado as características de movimento e aparência de acordo com a estratégia de aplicação das CDPA Rs, um vetor de características final combinando as duas regras de movimento pode ser considerado. Esse vetor parte do fato de que cada regra de movimento produz trajetórias distintas e, conseqüentemente, redes com informações diferentes. Assim, a combinação das duas regras pode produzir um vetor com novas informações que melhore o desempenho de classificação. Apesar de ocorrer na maioria dos casos, essa melhora não é uma regra, como visto na Seção 5.2.3. O vetor final referente a estratégia de descritores espacial e temporal é dado por

$$u = [u_{\min}, u_{\max}], \quad (4.31)$$

enquanto o vetor correspondente a estratégia de planos ortogonais é dado por

$$j = [j_{\min}, j_{\max}]. \quad (4.32)$$

4.4 Conclusão

Neste capítulo, foram propostos três métodos de caracterização de texturas dinâmicas baseado nas duas metodologias de complexidade consideradas nessa dissertação: redes complexas e CDPA Rs. O primeiro método propõe a modelagem do vídeo de textura dinâmica em uma rede complexa para, em seguida, extrair característica por meio da difusão em redes. Características de movimento e aparência são obtidas por meio de dois histogramas de atividade que são concatenadas para representas as texturas dinâmicas.

O segundo método propõe a aplicação das CDPA Rs em dois tipos de descritores: espacial e temporal. As características extraídas pelas CDPA Rs de cada descritor irão salientar as propriedades de movimento e aparência presentes nas texturas dinâmicas. Por fim, foi proposto um método que combina as CDPA Rs e redes complexas para caracterizar as texturas dinâmicas. Neste método, as redes são geradas pelas CDPA Rs em duas diferentes estratégias de execução: descritores espacial e temporal e planos ortogonais. Cada estratégia consiste em uma maneira diferente de modelar o vídeo de textura dinâmica em uma rede, conseqüentemente, diferentes características podem ser obtidas.

EXPERIMENTOS E RESULTADOS

Neste capítulo, são apresentados os experimentos e resultados obtidos com os métodos desenvolvidos para caracterização de texturas dinâmicas. Diversas análises foram feitas com o objetivo de verificar propriedades e influência de parâmetros dos métodos propostos. Além disso, comparações com outros métodos da literatura foram realizadas.

5.1 Configurações experimentais e bases de dados

Nos experimentos, um vetor de características é extraído de cada textura dinâmica das bases de dados e são classificados utilizando o classificador k-vizinhos mais próximo (k-nearest neighbor - KNN), com $k = 1$. O valor de $k = 1$ obteve o melhor desempenho nos experimentos realizados e também é o adotado como padrão pelos métodos da literatura comparados neste trabalho. A escolha deste classificador deve-se a sua simplicidade, o que evidencia a importância das características extraídas pelos métodos. Para separação do conjunto de treinamento e teste, foi adotado um esquema específico para cada base de dados, de acordo com o estabelecido na literatura. Na análise dos parâmetros dos métodos propostos, foi utilizado validação cruzada em 4 pastas para a base de dados UCLA e com 10 pastas para a base de dados Dyntex++ em 10 execuções. Essas duas bases de dados são referências em avaliar métodos de reconhecimento de texturas dinâmicas. A seguir cada base é descrita em detalhes.

- Dyntex++ ([GHANEM; AHUJA, 2010a](#)): esta base de dados é uma versão compilada da base de dados Dyntex++ ([PÉTERI; FAZEKAS; HUISKES, 2010](#)). Nesta base, as amostras foram pré-processada para evidenciar somente a sua textura dinâmica, eliminando amostras com fundos estáticos ou dinâmicos não representativos, zoom e texturas sem movimento. Assim, cada amostra possui uma única classe de textura dinâmica. A base consiste em 3600 vídeos de texturas dinâmicas, divididos em 36 classes com 100 amostras cada. Algumas texturas dinâmicas presentes são: água fervendo, água de rio, colônia de formigas, fumaça,

entre outras. Exemplos do primeiro quadro de algumas texturas dinâmicas são mostrados na Figura 27.

- UCLA (CHAN; VASCONCELOS, 2005b): esta base de dados é referência ao longo dos últimos anos no reconhecimento de texturas dinâmicas. É composta por 200 vídeos de texturas dinâmicas separados em 50 classes com 4 amostras por classe. Cada vídeo contém $160 \rightarrow 110 \rightarrow 75$ pixels e é capturado de um único ponto de vista. Deste modo, cada vídeo foi cortado em uma janela de $48 \rightarrow 48 \rightarrow 75$ pixels a fim de obter características estatísticas e dinâmicas representativas. Como nesta base muitas amostras de diferentes classes representam semanticamente a mesma cena, duas variações da base de dados original é proposta por Ravichandran, Chaudhry e Vidal (2009). Nessas variações a base é reorganizada de modo a combinar amostras de diferentes pontos de vista. Na primeira variação as amostras são divididas em 9 classes: água fervendo, fogo, flor, fonte, planta, mar, fumaça, água e cascata. Como a classe plantas possui mais amostras do que as demais, as suas amostras são eliminadas, gerando uma segunda variação com 8 classes. Essas três configurações são usadas para comparação com os demais métodos da literatura. Na Figura 28 é mostrado o primeiro quadro de algumas texturas dinâmicas presentes na base.

5.2 Análise experimental

Nesta seção são apresentados os resultados da análise experimental realizada com os métodos propostos. O objetivo das análises é compreender o comportamento dos métodos para cada parâmetro em função da taxa de classificação correta e para as propriedades dos métodos na caracterização. Nestes experimentos são utilizadas as bases de dados Dyntex++ e UCLA organizada em 50 classes.

5.2.1 Difusão em redes direcionadas aplicado em texturas dinâmicas

5.2.1.1 Análise dos parâmetros

Para avaliar o método proposto, é realizada uma análise dos parâmetros para compreender a sua influência na tarefa de classificação de texturas dinâmicas. Os parâmetros do método são: limiar inicial t_0 , limiar de incremento t_i , limiar final t_f e raio r de distância entre os pixels para modelar a textura dinâmica em uma rede direcionada. Como as caminhadas são guiadas por um processo estocástico, para estimar mais precisamente a atividade dos vértices foram iniciadas $M = 50$ caminhadas de cada vértice. A seguir, são apresentados os resultados de classificação para diferentes configurações dos parâmetros.

Os parâmetros t_0 , t_i e t_f , indicam o conjunto de limiares utilizados na função de corte de arestas $f(t, E)$. Esses parâmetros são responsáveis pela análise multi-escala do método. Na Figura 29(a) são apresentados as taxas de classificação correta (TCC) em função do limiares

Figura 27 – Exemplos de algumas texturas dinâmicas, ilustradas pelo primeiro quadro, da base de dados Dyntex++.

Fonte: Elaborada pelo autor.

Figura 28 – Primeiro quadro de algumas texturas dinâmicas da base de dados UCLA.

Fonte: Elaborada pelo autor.

iniciais t_0 para as duas bases de dados. Os valores de limiar inicial que obtiveram as melhores TCC foram $t_0 = 2$ e 8 , para as bases Dyntex++ e UCLA, respectivamente. Esses valores obtidos, mostram que baixos limiares iniciais t_0 são importantes por evidenciar pequenos detalhes de escala no estágio de reconhecimento (GONÇALVES; MACHADO; BRUNO, 2015). Ou seja, valores baixos de t_0 faz com que pequenas regiões bem homogêneas sejam mantidas conectadas, podendo ser analisadas.

O limiar de incremento t_i , é responsável pelo intervalo em que os limiares partindo de t_0 até t_f serão incrementados. Assim, faz com que o método proposto analise uma diversidade de escalas. As taxas de classificação para diferentes valores de t_i são plotadas na Figura 29 (b). Para as bases Dyntex++ e UCLA, os valores de limiares de incremento foram $t_i = 48, 96$, respectivamente. Nas duas bases, como se esperava foram obtidos valores altos de t_i . Os valores altos fazem com que o método explore escalas bem distintas, analisando a variação dos padrões de micro para macro detalhes.

Para avaliar o limiar final t_f , é considerado o número de limiares n_f , tal que $t_f = t_0 + (n_f - 1) \cdot t_i$. Assim, n_f é o número de limiares utilizados na análise multi-escala. Na Figura 29(c) é mostrado o resultado de classificação em função de n_f . Os números de limiares que obtiveram os melhores resultados foram $n_f = 4, 2$ nas bases Dyntex++ e UCLA, respectivamente. Os números de limiares baixos obtidos estão associados aos altos valores do limiar de incremento t_i , portanto, não é necessário um grande número de limiares para obter bons resultados de classificação.

Figura 29 – Análise dos parâmetros em função da taxa de classificação correta de cada base de dados. Para a base de dados Dyntex++ a melhor configuração de parâmetro foi $t_0 = 2$, $t_i = 48$, $n_f = 4$ e $r = [p_1, p_2]$, enquanto para a base de dados UCLA foi $t_0 = 8$, $t_i = 96$, $n_f = 2$ e $r = [p_1, p_2, p_3]$

Fonte: Elaborada pelo autor.

Por fim, é avaliado o raio r , cujo resultado de classificação combinando diferentes raios é apresentado na Figura 29. O raio é a distância máxima de conexão entre vértices (pixels) na modelagem da textura dinâmica em rede. Na base de dados Dyntex++, o melhor resultados de classificação foi obtido com a concatenação das características das redes com raio $r = [p_1, p_2]$. A base de dados UCLA, obteve a melhor taxa de classificação com a concatenação $r = [p_1, p_2, p_3]$.

Finalmente, a partir das análises acima é possível determinar o conjunto de limiares de cada base e as respectivas combinações de raios. De um modo geral, os conjuntos de limiares obtidos das bases são próximos. Note que bons resultados são obtidos com conjuntos compostos por limiares que iniciam com valores baixos, são incrementados por valores altos (em média 85), e terminam com valores próximos ao peso máximo, que é 255. Em relação ao raio, ao realizar a

combinação $r = [\overset{p}{1}, \overset{p}{2}, \overset{p}{3}]$ ou superior, é possível obter bons resultados de classificação.

5.2.1.2 Análise de movimento e rotação

Uma importante propriedade dos métodos de classificação de texturas dinâmicas é a sua capacidade de lidar com diferentes padrões de movimento. A atividade em redes já demonstrou capacidade de discriminar imagens de texturas rotacionadas e com diferentes aparências em outros trabalhos (GONÇALVES et al., 2016). No entanto, essas propriedades precisam ser avaliadas para padrões de movimento. Nesta seção, são avaliadas as características extraídas pelo método proposto de acordo com diferentes tipos movimentos e rotações. Para isso, foram utilizados 120 vídeos de texturas dinâmicas sintéticas. Os vídeos são divididos em quatro categorias de padrão de movimento: circular, aleatório, linear e sem movimento. Cada vídeo possui $180 \rightarrow 220$ pixels de resolução e aproximadamente 60 quadros. Os vídeos são compostos por duas texturas dinâmicas, uma textura de ondas do mar como fundo e outra textura de algas marinhas para simular o padrão de movimento. Exemplos de vídeos de texturas de cada classe são mostrados na Figura 30 com o padrão de movimento ilustrado em vermelho.

O experimento foi conduzido da seguinte forma. Primeiramente, o método proposto foi aplicado em cada vídeo de textura, utilizando os parâmetros já obtidos para a base de dados UCLA ($t_0 = 8$, $t_i = 96$, $n_f = 4$ e $r = [\overset{p}{1}, \overset{p}{2}, \overset{p}{3}]$). Como o objetivo do experimento é discriminar os vídeos de acordo com o movimento da textura, é considerado somente o histograma $h_t^{r,t}$. Assim, de cada vídeo de textura é obtido um histograma $h_t^{r,t}$. Para visualização, os vetores de características compostos pelos histogramas $h_t^{r,t}$ são projetados em um espaço bidimensional através do método t-Distributed Stochastic Neighbor Embedding (t-SNE) (MAATEN; HINTON, Nov 2008). O t-SNE é uma técnica para visualização de dados de alta dimensão que atribui para cada vetor de características uma localização em um mapa de duas dimensões. É importante ressaltar que o t-SNE não usa informação de classe para realizar a projeção. Portanto, as amostras são rotuladas em classes apenas para fins de visualização.

A Figura 31 apresenta a projeção em duas dimensões dos vetores de características de cada vídeo de textura dinâmica. Note que, como esperado os vídeos que possuem o mesmo padrão de movimento estão agrupados. Isto sugere que o método proposto consegue separar os diferentes padrões de movimento. Outra propriedade desejável nos métodos de caracterização é a invariância à rotação. Essa propriedade é satisfeita, já que a partícula escolhe o próximo vértice baseado em um sorteio aleatório e uma probabilidade. Como pode ser visto na Figura 30 o movimento linear possui amostras em diferentes rotações. Entretanto, a projeção indica que as amostras estão agrupadas em uma mesma classe.

Para corroborar a propriedade de rotação do método foi realizado outro experimento. Primeiramente, considere um vídeo V e um vídeo transformado V^0 por um mapa Z , tal que $V^0(p) = V(Zp)$. Esse mapa pode ser considerado uma determinada rotação. Dada duas redes R e R^0 obtidas de vídeos V e V^0 , elas precisam ser exatamente a mesma para o método ser

Figura 30 – Ilustração das quatro classes de texturas sintéticas utilizadas para analisar as características de movimento obtidas pelo método proposto.

(a) Movimento aleatório

(b) Movimento circular

(c) Movimento linear

(d) Sem movimento

Fonte: Elaborada pelo autor.

Figura 31 – Características extraídas pelo método proposto de difusão em redes das 4 classes de movimento projetadas em duas dimensões usando t-SNE.

Fonte: Elaborada pelo autor.

invariante a rotação. Desta forma, histogramas $h_m^{r,t}$ e $h_t^{r,t}$ foram obtidos de vídeos em quatro diferentes rotações, como mostra a Figura 32. Note que os histogramas para os quatro ângulos são exatamente os mesmos. Isto corrobora a análise de rotação realizada em difusão em redes para texturas estáticas (BACKES; CASANOVA; BRUNO, 2013; GONÇALVES et al., 2016).

Figura 32 – Histogramas de atividade extraídos de quatro vídeos de texturas dinâmicas rotacionados.

5.2.2 Caminhada determinística parcialmente auto-repulsiva aplicada em textura dinâmica

5.2.2.1 Análise dos parâmetros

Uma análise experimental foi realizada com o objetivo de investigar o efeito dos parâmetros deste método na tarefa de reconhecimento de texturas dinâmicas. Os parâmetros investigados foram: (i) tamanhos de memória μ ; (ii) regras de movimento r (min e max); (iii) descritores Q (espacial e temporal). Os experimentos foram realizados usando os $n = 3$ primeiros elementos do histograma $h_{\mu,r}^Q(I)$ para a base de dados UCLA e os $n = 5$ primeiros para a base de dados Dyntex++. Estes valores foram definidos partindo da premissa de que as principais informações se concentram nos primeiros elementos do histograma e por testes prévios.

A Figura 33 apresenta a análise dos descritores separadamente para diferentes concatenações de tamanho de memória e regras de movimento em termos de taxa de classificação correta. De modo geral, note que os resultados sugerem que a concatenação de tamanhos de memória pequeno (0 e 1) alcança taxas de classificação correta inferiores. Por outro lado, ao concatenar tamanhos de memória acima de $\mu = 2$ a taxa de classificação correta é incrementada. Entretanto, à medida que o tamanho da memória é incrementado, a taxa de classificação correta estabiliza devido a maior dificuldade em encontrar um atrator na caminhada. Portanto, a combinação de tamanhos de memórias menores, responsáveis por uma análise mais local dos pixels, com tamanhos de memórias maiores, responsáveis por uma análise mais global, fornece uma melhor análise da textura dinâmica, refletindo diretamente na taxa de classificação correta.

Em relação a regra de movimento, os melhores resultados foram obtidos com a regra de movimento $r = \text{max}$. Esta regra de movimento está relacionada a regiões heterogêneas do vídeo, isto é, onde a mudança no nível de cinza dos pixels é mais alta. Enquanto a regra de movimento $r = \text{min}$ está associada a regiões homogêneas com pouca mudança no nível de cinza. Isso indica que regiões heterogêneas podem ter informações mais ricas sobre a textura dinâmica. No que tange aos descritores, na base de dados Dyntex++ o descritor temporal obteve melhores taxa de classificação correta comparado ao descritor espacial. Já na base de dados UCLA (Figura 33(c) e (d)), o descritor espacial forneceu melhores resultados de classificação.

Por fim, a Figura 34 apresenta os resultados para concatenações de descritores e regras de movimento. Nas duas bases de dados, os melhores resultados foram obtidos concatenando os descritores espacial e temporal. Isto corrobora a importância dos dois descritores e, consequentemente, das informações de aparência e movimento para caracterização das texturas dinâmicas. Além disso, essas bases de dados demonstraram um mesmo comportamento para as concatenações de tamanhos de memórias e regras de movimento. Ambas bases obtiveram a melhor taxa de classificação correta com memórias $\mu = [0, 1, 2, 3, 4, 5, 6, 7, 8]$ e regras de movimento $r = [\text{min}, \text{max}]$. As maiores taxas de classificação correta foram de 94,5% e 96,0% para as bases de dados Dyntex++ e UCLA, respectivamente.

Esses resultados são interessantes porque indicam que o método não é fortemente dependente dos parâmetros. Assim, como esperado o vetor final é composto da combinação de características extraídas com diferentes regras de movimento, tamanhos de memórias e descritores. Isso acontece porque as características extraídas pelas CDPA Rs com diferentes configurações contemplam diferentes propriedades das texturas dinâmicas, tais como, informações locais (tamanhos de memórias pequenos) e informações globais (tamanhos de memórias grandes), heterogeneidade e homogeneidade. Isto faz com que a taxa de classificação correta seja incrementada, tornando a tarefa de reconhecimento mais robusta.

Figura 33 – Análise das características extraídas para as bases de dados a partir do descritor espacial e temporal usando diferentes combinações de memória e regras de movimento.

Fonte: Elaborada pelo autor.

5.2.2.2 Análise do método proposto

Nesta seção, é apresentada uma análise experimental da influência dos descritores espacial e temporal na caracterização de texturas dinâmicas. Os experimentos com o método proposto foram conduzidos utilizando os parâmetros obtidos na Seção 5.2.2.1 para as bases de dados UCLA e Dyntex++ ($\mu = [0, 1, 2, 3, 4, 5, 6, 7, 8]$ e $r = [\text{min}, \text{max}]$). Para verificar a influência

Figura 34 – Análise das características extraídas para as bases de dados com os descritores espacial e temporal concatenados e usando diferentes combinações de memória e regras de movimento.

Fonte: Elaborada pelo autor.

de cada descritor na caracterização, foram utilizados 72 vídeos de texturas dinâmicas sintéticas de $220 \rightarrow 180$ pixels com aproximadamente 60 quadros. Cada vídeo é composto por duas texturas dinâmicas, uma textura dinâmica de ondas do mar como fundo e outra textura dinâmica para simular o movimento (algas, escada rolante e flores).

Primeiramente, o descritor temporal é avaliado com um conjunto de texturas dinâmicas sintéticas divididas em 4 classes de movimento básico: aleatório, circular, linear e sem movimento. Cada classe contém 18 amostras diferentes de movimentos simulados por texturas dinâmicas de algas, escada rolante e flores. A Figura 35 ilustra os vídeos de textura dinâmica sintética para as classes de movimento usadas para análise. Na ilustração o movimento é representado pelos traços em amarelo. Para cada vídeo de textura dinâmica, é extraído um vetor de característica composto somente do descritor temporal. A Figura 36 mostra a projeção desses vetores em duas dimensões usando a técnica de visualização t-SNE. Através desta figura, é possível observar que as amostras com o mesmo padrão de movimento estão agrupadas. Assim, o descritor temporal consegue separar adequadamente os diferentes padrões de movimento independentemente da textura dinâmica usada para simular o movimento. Isto é, os padrões de aparência não afetam as características extraídas através do descritor temporal, tornando este descritor apropriado apenas para caracterizar os padrões de movimento.

Um segundo experimento foi conduzido para analisar o descritor espacial. Neste, os vídeos estão divididos em três classes de aparência: algas, escada rolante e flores. Cada classe contém 24 amostras com diferentes padrões de movimento, como ilustra a Figura 37. Na Figura 38 é apresentada a projeção com t-SNE dos vetores de características extraídos de cada vídeo usando apenas o descritor espacial. Como é possível notar, as três classes de aparência estão agrupadas. Dessa forma, as características de aparência são descritas apropriadamente pelo descritor espacial. Além disso, é importante notar que apesar de cada classe de aparência

possuir amostras com diferentes tipos de movimento, somente as características de aparência são consideradas pelo descritor. Assim, como esperado, o descritor espacial não pode caracterizar corretamente texturas dinâmicas com um mesmo padrão de movimento. Portanto, os dois descritores se completam na caracterização das texturas dinâmicas.

Figura 35 – Quatro classes de texturas dinâmicas sintéticas utilizadas para analisar as características de movimento extraídas pelo método proposto a partir do descritor temporal.

Fonte: Elaborada pelo autor.

Figura 36 – Projeção das características extraídas da base sintética de movimento usando o método de CDPA Rs aplicado somente no descritor temporal.

Fonte: Elaborada pelo autor.

5.2.3 Redes complexas geradas por caminhada determinística parcialmente auto-repulsiva para textura dinâmica

Nesta seção é apresentado um estudo dos parâmetros do método proposto e a sua consequência na tarefa de reconhecimento de texturas dinâmicas nas bases de dados. Os parâmetros do método proposto são: (i) tamanhos de memória μ (ii) regra de movimento r (iii) medidas de redes complexas.

Inicialmente, para análise do método foi considerada as cinco medidas de redes complexas: entropia H , contraste C , energia E , entropia do grau conjunto H_g e energia do grau ponderado E_g . A Figura 39 resume os resultados da análise de diferentes tamanhos de memória e regras de movimento usando a estratégia de descritores espacial e temporal para execução das CDPA Rs nos vídeos. Cada gráfico apresenta os resultados para uma base de dados e um descritor. De modo geral, os resultados indicam que à medida que o tamanho da memória é incrementado, a taxa de classificação correta incrementa. Entretanto, é possível observar que esse incremento é baixo, principalmente depois do tamanho $\mu = 2$.

Em relação à regra de movimento, na maioria dos casos a regra $r = \max$ obteve uma melhor taxa de classificação, apresentando um comportamento similar ao do método da Seção 5.2.2.1. No que tange aos descritores, é possível notar que embora o desempenho entre os dois descritores sejam próximos, o descritor temporal apresentou taxas de classificação corretas levemente superiores. Isso corrobora a importância de cada descritor na caracterização, tornando necessária a combinação dos dois para uma classificação robusta.

Figura 37 – Três classes de textura dinâmica sintética utilizada para avaliar as características de aparência extraídas pelo descritor de espacial: (a) algas, (b) escada, (c) flores.

Fonte: Elaborada pelo autor.

Figura 38 – Projeção das características extraídas da base sintética de aparência usando o método de CDPA Rs aplicado somente no descritor espacial.

Fonte: Elaborada pelo autor.

Nesse sentido, resultados interessantes foram obtidos com a combinação das características extraídas a partir de cada descritor, como apresenta a Figura 40. Nas bases de dados Dyntex++ (Figura 40(a)) e UCLA (Figura 40(b)), as melhores taxas de classificação correta foram obtidas usando a combinação das duas regras de movimento. Para a base UCLA, a melhor taxa de classificação correta foi de 98,0%, enquanto para a base Dyntex++ foi de 92,6%. Tais resultados foram obtidos com a concatenação dos tamanhos de memória $\mu = [0, 1, 2, 3]$ e $\mu = [0, 1, 2, 3, 4, 5, 6, 7, 8]$ para as bases UCLA e Dyntex++, respectivamente. No entanto, note que a variação na taxa de classificação para diferentes concatenações de tamanhos de memória é muito baixa. Isto indica que o método não é tão sensível a escolha dos tamanhos de memória.

Figura 39 – Taxa de classificação correta para diferentes combinações de tamanhos de memória, regras de movimento e descritores com a estratégia de execução da CDPA Rs de descritores espacial e temporal para gerar as redes. Cada gráfico apresenta os resultados para tipo de descritor de uma base de dados.

Fonte: Elaborada pelo autor.

Na Figura 41 são apresentados os resultados da análise experimental conduzida para a estratégia de planos ortogonais para aplicação das CDPA Rs nos vídeos de textura dinâmica. Na figura, cada gráfico apresenta os resultados de um plano ortogonal e uma base de dados. Nas duas bases de dados, note que ao incrementar o tamanho da memória, a taxa de classificação correta também foi incrementada. Isto reforça que o uso de diferentes tamanhos de memória

Figura 40 – Taxas de classificação correta para diferentes concatenações de tamanhos de memória e regra de movimento usando os descritores temporal e espacial combinados em todos os casos.

Fonte: Elaborada pelo autor.

faz com que a CDPAR model e redes com diferentes características da textura dinâmica. Com relação às regras de movimento, para as duas bases, a regra de movimento $r = \max$ obteve um desempenho superior em relação a regra $r = \min$.

No que se refere à influência dos planos ortogonais, é possível notar que o desempenho em classificação de cada plano é bem próximo. Isto corrobora o fato de que cada plano obtém separadamente características importantes para caracterização da textura dinâmica e se completam. Dessa forma, a combinação das características extraídas das redes de cada plano é uma forma de melhorar o desempenho na classificação, como é mostrado na Figura 42. Como pode ser visto, nas bases de dados UCLA e Dyntex++ a combinação dos três planos e das duas regras de movimento forneceram um melhor desempenho em termos de classificação. No entanto, nessas duas bases tanto a regra de movimento $r = \max$ e a combinação $r = [\min, \max]$, quanto as diferentes combinações de tamanho de memória obtiveram taxas de classificação muito próximas. Na base de dados UCLA (Figura 42 (b)) a melhor taxa de classificação correta foi de 93,0% usando a combinação de tamanhos de memória $\mu = [0, 1]$, enquanto na base de dados Dyntex++ (Figura 42 (b)) o melhor resultado de 93,5% foi alcançado com a combinação $\mu = [0, 1, 2, 3, 4, 5, 6]$.

Finalmente, uma vez obtidos os parâmetros acima, uma última análise é conduzida a fim de avaliar o desempenho do método com diferentes combinações de medidas estatísticas extraídas das redes complexas geradas. A Tabela 1 apresenta as taxas de classificação correta para as diferentes combinações de medidas estatísticas usando a estratégia de descritores temporal e espacial. Note que a combinação das cinco medidas estatísticas apresentou melhor desempenho nas três bases de dados. Os resultados também mostram que ao considerar uma única medida para caracterização, o melhor desempenho em todas as bases foi obtido com a entropia da distribuição do grau H.

Figura 41 – Taxas de classificação correta usando diferentes combinações de tamanhos de memória e regras de movimento para a estratégia de planos ortogonais. Cada gráfico corresponde a um plano ortogonal e uma base de dados.

Fonte: Elaborada pelo autor.

Figura 42 – Análise das taxas de classificação correta obtidas com a combinação das características extraídas das redes dos três planos ortogonais.

Fonte: Elaborada pelo autor.

Na Tabela 2 é apresentado os resultados com diferentes combinações de medidas estatísticas para a estratégia de planos ortogonais. Nessa estratégia a combinação das cinco medidas também apresentou um melhor desempenho na classificação das três bases de texturas dinâmicas. Além disso, a entropia da distribuição do grau demonstrou ter maior poder de caracterização quando comparada com as demais medidas.

Nas duas estratégias de execução das CDPA Rs o comportamento das combinações de medidas em termos de classificação foi bem próximo. Tal comportamento corrobora o uso das cinco medidas estatísticas como forma de realizar uma caracterização robusta das texturas dinâmicas. No entanto, é importante ressaltar que em alguns casos outras combinações forneceram resultados interessantes, como por exemplo, a energia do grau e do grau ponderado $([E, \bar{E}])$ e entropia do grau e a energia do grau ponderado $([H, \bar{E}])$.

Tabela 1 – Resultados para diferentes combinações de medidas estatísticas de redes geradas usando a estratégia de descritores espacial e temporal.

Medidas					Bases	
H	E	C	H	$\bar{E}$	UCLA	Dyntex++
x					93,50	88,30
	x				92,00	87,41
		x			93,00	88,30
			x		89,00	87,69
				x	91,50	71,77
x				x	98,00	89,66
	x			x	97,50	89,25
x	x				93,50	89,47
x	x	x			95,00	90,27
x	x	x	x		94,50	91,69
x	x	x	x	x	98,00	92,60

Fonte: Dados da pesquisa.

5.3 Comparação com métodos da literatura

Nesta seção, os resultados dos métodos propostos neste mestrado são comparados com outros métodos da literatura nas duas bases de dados. Para isso, são consideradas as taxas de

Tabela 2 – Resultados para diferentes medidas de redes complexas geradas pelo turista nos três planos ortogonais

Medidas					Bases	
H	E	C	H	$\bar{E}$	UCLA	Dyntex++
x					84.00	89.91
	x				76.00	88.67
		x			86.50	90.63
			x		67.50	90.61
				x	79.00	80.41
x				x	90.00	91.22
	x			x	90.00	90.58
x	x				89.00	90.00
x	x	x			90.00	91.80
x	x	x	x		87.50	92.94
x	x	x	x	x	92.50	93.50

classificação correta, desvio padrão e número de características dos métodos, quando descrito nos artigos originais. As quatro abordagens desenvolvidas nessa dissertação são utilizadas para comparação: difusão em redes, CDPARs em descritores espaciais e temporais (CDPAR DET), redes geradas por CDPARs em descritores espaciais e temporais (CDPAR+Redes DET), redes geradas por CDPARs nos três planos ortogonais (CDPAR+Redes TOP). Os resultados dos métodos desenvolvidos usados para comparação são referentes as melhores configurações de parâmetros analisada na Seção 5.2.

Os resultados obtidos com os métodos da literatura LBP-TOP, VLBP, CNDT e CDT-TOP foram computados usando a própria implementação disponibilizada pelos autores, enquanto os resultados dos demais métodos foram obtidos diretamente dos seus artigos originais. É importante ressaltar que os resultados de todos os métodos foram obtidos utilizando uma mesma configuração experimental, isto é, um mesmo classificador e esquema de validação. Portanto, a comparação do desempenho dos métodos é feita de maneira justa.

A Tabela 3 resume os resultados de classificação obtidos pelos métodos na base de dados UCLA separadas em 50 classes. De modo similar a configuração experimental estabelecida na literatura (SAISAN et al., 2001; DERPANIS; WILDES, 2012), nesta base os experimentos foram realizados com validação cruzada em 4 pastas e o classificador 1-vizinho mais próximo. Como se pode ver, dois métodos propostos superam os outros métodos com um incremento de até 3% na taxa de classificação correta. Os métodos propostos de difusão em redes e CDPAR+Redes DET obtiveram o melhor desempenho, com 98,5% e 98,0% de taxa de classificação correta, respectivamente. O método CDPAR DET alcançou uma TCC superior a maioria dos métodos da literatura, enquanto o método CDPAR+Redes TOP não teve um bom desempenho.

No que se refere aos métodos baseados em redes, o método proposto de difusão em redes melhora em 3,5% a taxa de classificação comparado com o método CNDT (GONÇALVES; MACHADO; BRUNO, 2015). Este método usa medidas baseado na distribuição do grau para caracterizar as texturas dinâmicas, enquanto o método proposto usa a atividade dos vértices estimada pela difusão na rede. Portanto, como os resultados sugerem, o uso de uma medida mais sofisticada da rede melhora a caracterização das texturas dinâmicas. Em relação aos métodos baseados em CDPARs, o método da literatura CDT-TOP (GONÇALVES; BRUNO, 2013c) é superado em 3% e 1% pelos métodos CDPAR+Redes DET e CDPAR DET, respectivamente. Isto indica que as características extraídas usando a estratégia de descritores espacial e temporal (DET) pode ser mais apropriada para caracterização de movimento e aparência do que outras estratégias, tal como, três planos ortogonais (TOP).

A segunda comparação é feita com a base de dados UCLA composta por 9 classes. Nesta configuração a base de dados UCLA é reorganizada de forma a combinar as texturas dinâmicas que estão em diferentes pontos de vista. Assim, cada classe será composta por texturas dinâmicas com diferentes pontos de vista, testando a capacidade dos métodos de classificar tal invariância. Nesta comparação, a configuração experimental usada foi a mesma definida em (GHANEM;

Tabela 3 – Comparação dos resultados de classificação do método proposto com os métodos da literatura para a base UCLA com 50 classes. Obs. # é o tamanho do vetor de características.

Métodos	#	TCC (%)
KDT-MD (CHAN; VASCONCELOS, 2007)	-	89,50
DFS (XU et al., 2011)	-	89,50
3D-OTF (XU et al., 2012)	290	87,10
WLBPC (TIWARI; TYAGI, 2016d)	-	96,50
CVLBP (TIWARI; TYAGI, 2016c)	-	93,00
HLBP (TIWARI; TYAGI, 2016a)	1536	95,00
MEWLSP (TIWARI; TYAGI, 2016e)	1536	96,50
RI-VLBP (ZHAO; PIETIKÄINEN, 2007)	16384	77,50 ($\pm$ 8.98)
LBP-TOP (ZHAO; PIETIKAINEN, 2007b)	768	95,00 ($\pm$ 4.44)
CDT-TOP (GONÇALVES; BRUNO, 2013b)	75	95,00 ($\pm$ 4.78)
CNDT (GONÇALVES; MACHADO; BRUNO, 2015)	420	95,00 ($\pm$ 5.19)
CDPAR DET	180	96,00 ($\pm$ 3.16)
CDPAR+Redes DET	80	98,00 ($\pm$ 3.50)
CDPAR+Redes TOP	60	93,00 ($\pm$ 4.25)
Difusão em Redes	169	98,50 ($\pm$ 3.37)

Fonte: Dados da pesquisa.

AHUJA, 2010b). Para cada validação, 50% das amostras são selecionadas para treinamento e as 50% restante são usadas para teste. O experimento é repetido 20 vezes usando o classificador 1-vizinho mais próximo.

A Tabela 4 apresenta os resultados obtidos com a base de dados UCLA com 9 classes. Note que, o método proposto CDPAR+Redes TOP obteve uma leve melhora em relação aos métodos HLBP, MEWLSP e DNGP. Além disso, os demais métodos desenvolvidos alcançam resultados próximos dos melhores. Em relação aos métodos que são baseados em complexidade (i.e. High level feature, Chaotic vector, 3D-OTF e DFS), os métodos desenvolvidos conseguiram uma considerável melhora na taxa de classificação. Tais resultados evidenciam a capacidade dos métodos em reconhecer texturas dinâmicas obtidas em diferentes pontos de vistas em uma mesma classe.

Os resultados para a configuração da base de dados UCLA com 8 classes são apresentados na Tabela 5. A configuração experimental usada nessa comparação é a mesma definida na base com 9 classes (GHANEM; AHUJA, 2010b). Note que os métodos desenvolvidos obtiveram desempenho bem próximo, com cerca de 96% de taxa de classificação. Esse desempenho é levemente inferior a alguns métodos da literatura, como por exemplo, o HLBP, MEWLSP e MBSIF. No entanto, o tamanho do vetor de características desses métodos (i.e. 1,536 para o HLBP e MEWLSP, e 6,144 para o MBSIF) é significativamente superior aos vetores de características dos métodos desenvolvidos. A Figura 43 apresenta a matriz de confusão do método CDPAR DET para a base de dados UCLA com 8 classes. A partir desta matriz é possível ver em detalhe o desempenho do método proposto para cada classe. Note que o método CDPAR

Tabela 4 – Comparação dos resultados de classificação do método proposto com os métodos da literatura para a base UCLA com 9 classes. Obs. # é o tamanho do vetor de características.

Métodos	#	TCC (%)
3D-OTF (XU et al., 2012)	290	96,32
CVLBP (TIWARI; TYAGI, 2016c)	-	96,90
HLBP (TIWARI; TYAGI, 2016a)	1536	98,30
MEWLSP (TIWARI; TYAGI, 2016e)	1536	98,50
MBSIF (ARASHLOO; KITTLER, 2014)	6144	98,75
High level feature (WANG; HU, 2015)	-	92,60
DNGP (RIVERA; CHAE, 2015)	-	98,10
WMFS (JI et al., 2013)	702	96,95
WLBPC (TIWARI; TYAGI, 2016d)	-	97,17
Chaotic vector (WANG; HU, 2016)	300	85,10
RI-VLBP (ZHAO; PIETIKÄINEN, 2007)	16384	96,30
LBP-TOP (ZHAO; PIETIKAINEN, 2007b)	768	96,00
CDT-TOP (GONÇALVES; BRUNO, 2013b)	75	96,33 (± 2.46)
CNDT (GONÇALVES; MACHADO; BRUNO, 2015)	336	95,61 (± 2.72)
CDPAR-DET	180	96,80 (± 2.36)
CDPAR+Redes DET	80	98,40 (± 2.01)
CDPAR+Redes TOP	60	99,10 (± 0.86)
Difusão em Redes	169	97,80 (± 1.53)

Fonte: Dados da pesquisa.

DET confundiu amostras de fumaça com ondas, água com cascata e fonte com cascata. Essa confusão ocorre porque as amostras podem ser muito parecidas, tanto nas características de aparência como no movimento. Por exemplo, as classes fonte, água e cascata são compostas basicamente por água, tornando as características de aparência muito similares.

Por fim, a Tabela 6 resume os resultados obtidos com a base de dados Dyntex++. Para essa base de dados, a configuração experimental usada foi validação cruzada em 10 pastas e o classificador 1-vizinho mais próximo. Dentre os métodos desenvolvidos, o método que obteve o melhor desempenho foi o CDPAR-DET com 94,6% de classificação correta. No geral, os métodos desenvolvidos melhoraram a taxa de classificação em 3% com relação ao método de CDPAR (CDT-TOP) e 8,9% comparado ao de redes complexas (CNDT) da literatura. Os métodos RI-VLBP e LBP-TOP alcançaram os melhores desempenhos, com 96,14% e 97,72% de taxa de classificação correta, respectivamente. Entretanto, os métodos propostos ainda são competitivos no que tange ao tamanho dos vetores de características, por exemplo, o RI-VLBP possui um vetor com 16,384 características, enquanto o CDPAR-DET extrai somente 180 características.

De modo geral, analisando os resultados em todas as bases de dados é possível concluir que os métodos desenvolvidos apresentaram um bom desempenho comparado com os demais métodos da literatura, que são o estado da arte no campo de análise de texturas dinâmicas. Alguns pontos importantes podem ser citados, como por exemplo, o desempenho dos métodos que se baseiam nos três planos ortogonais para extração de características. Em três bases de dados

Tabela 5 – Comparação dos resultados de classificação do método proposto com os métodos da literatura para a base UCLA com 8 classes. Obs. # é o tamanho do vetor de características.

Métodos	#	TCC (%)
3D-OTF (XU et al., 2012)	290	95,80
CVLBP (TIWARI; TYAGI, 2016c)	-	95,65
HLBP (TIWARI; TYAGI, 2016a)	1536	97,50
MEWLSP (TIWARI; TYAGI, 2016e)	1536	98,04
MBSIF (ARASHLOO; KITTLER, 2014)	6144	97,80
High level feature (WANG; HU, 2015)	-	85,65
DNGP (RIVERA; CHAE, 2015)	-	97,00
WMFS (Ji et al., 2013)	702	97,18
WLBPC (TIWARI; TYAGI, 2016d)	-	97,60
Chaotic vector (WANG; HU, 2016)	300	85,00
RI-VLBP (ZHAO; PIETIKÄINEN, 2007)	16384	91,96
LBP-TOP (ZHAO; PIETIKAINEN, 2007b)	768	93,67
CDT-TOP (GONÇALVES; BRUNO, 2013b)	75	93,41 ($\pm$ 6.01)
CNDT (GONÇALVES; MACHADO; BRUNO, 2015)	336	94,32 ($\pm$ 4.18)
CDPAR-DET	180	96,59 ($\pm$ 7.12)
CDPAR+Redes DET	80	96,55 ($\pm$ 7.13)
CDPAR+Redes TOP	60	96,15 ($\pm$ 7.02)
Difusão em Redes	169	96,22 ($\pm$ 4.80)

Fonte: Dados da pesquisa.

Tabela 6 – Comparação dos resultados de classificação do método proposto com os métodos da literatura para a base Dyntex++.

Métodos	#	TCC (%)
RI-VLBP (ZHAO; PIETIKÄINEN, 2007)	16384	96,14 ($\pm$ 0.77)
LBP-TOP (ZHAO; PIETIKAINEN, 2007b)	768	97,72 ($\pm$ 0.43)
CDT-TOP (GONÇALVES; BRUNO, 2013b)	75	91,39 ($\pm$ 1.29)
CNDT (GONÇALVES; MACHADO; BRUNO, 2015)	336	83,86 ($\pm$ 1.40)
CDPAR-DET	180	94,60 ($\pm$ 1.20)
CDPAR+Redes DET	180	92,60 ($\pm$ 1.86)
CDPAR+Redes TOP	210	93,50 ($\pm$ 1.27)
Difusão em redes	141	93,80 ($\pm$ 1.08)

Fonte: Dados da pesquisa.

(i.e. UCLA 9 e 8 classes, e Dyntex++) os métodos baseados nessa estratégia obtiveram melhor desempenho, com o método proposto CDPAR+Redes TOP superando os demais na base de UCLA com 9 classes.

Outra categoria que pode ser analisada é a de métodos que tratam as texturas dinâmicas como um sistema dinâmico com variação complexa no tempo e, assim, utilizam abordagens advindas da área de sistemas complexos como medida de complexidade das texturas dinâmica (e.g. dimensão fractal, redes complexas, CDPARs e teoria do caos). Como os métodos desenvolvidos neste mestrado seguem essa linha, uma comparação pode ser feita entre estes métodos (i.e.

Figura 43 – Matriz de confusão da base de dados UCLA dividida em 8 classes.

Fonte: Elaborada pelo autor.

CNDT, CDT-TOP, High level feature, Chaotic features e DFS). Note que em todas as bases de dados, os métodos propostos conseguiram melhorar a taxa de classificação correta em relação aos métodos da categoria. No entanto, não é possível indicar uma única abordagem que tem um desempenho superior em todas as comparações. Isto porque os desempenhos destes métodos variam, embora pouco, de acordo com as características específicas de cada base de dados, que pode favorecer uma abordagem ou outra.

Uma característica dos métodos de reconhecimento de textura dinâmica que também pode ser considerada nas comparações é o tamanho do vetor de característica. Isto porque estes métodos vêm sendo usados em diferentes aplicações de tempo real em que o tempo computacional é importante. Portanto, um vetor de características de alta dimensão irá afetar diretamente o tempo computacional para classificação das texturas dinâmicas. Diversos estudos ao longo dos últimos anos indicam que um vetor de característica de baixa dimensão é um ponto chave para o sucesso dos métodos de reconhecimento de texturas dinâmicas (ZHAO; PIETIKAINEN, 2007b; WANG; HU, 2015; OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002; TIWARI; TYAGI, 2016a). Este fato é interessante para os métodos propostos, já que seus vetores de características possuem uma baixa dimensão. Por exemplo, para todas as bases de dados UCLA, os métodos propostos CDPAR+Redes DET e CDPAR+Redes TOP atingem uma taxa de classificação correta competitiva com um vetor de características de dimensão 80 e 60, respectivamente. Por outro

lado, métodos como o HLBP, MBSIF e RI-VLBP possuem vetor de características com dimensão 1,536, 6,144 e 16,384, respectivamente.

5.4 Conclusão

Neste capítulo, foram realizados experimentos de análise de parâmetros e análise dos métodos propostos. Além disso, os resultados obtidos com os métodos propostos foram comparados com outros da literatura. O método de difusão em redes demonstrou ser eficaz em caracterizar diferentes tipos de movimento e texturas dinâmicas rotacionadas. Do mesmo modo, o método de CDPARs aplicado em descritores espacial e temporal demonstrou ser robusto na caracterização de diferentes tipos de movimento com o descritor temporal independente da aparência. Além disso, o descritor espacial conseguiu caracterizar apropriadamente texturas dinâmicas com a mesma aparência independente do padrão de movimento.

Por fim, o método de redes geradas por CDPARs apresentou excelentes resultados de classificação na base de dados UCLA. Nesse método, as duas estratégias de execução de CDPARs mostraram serem eficazes na caracterização de movimento e aparência. De modo geral, os métodos propostos obtiveram bons resultados comparados com os demais da literatura, com destaque para a baixa dimensão dos vetores de características.

APLICAÇÕES

Um dos objetivos dessa dissertação é aplicar os métodos desenvolvidos para ajudar a resolver problemas reais. Além de contribuir com a sociedade na solução de problemas, tais aplicações ajudam a medir a pesquisa realizada em termos práticos. Neste capítulo, os métodos desenvolvidos são aplicados na classificação de tipos de corrosão de aço carbono e na análise de intensidade de tráfego em rodovias.

6.1 Classificação de tipos de corrosão de aço carbono

O processo de corrosão em materiais metálicos é um fenômeno natural que vem sendo estudado pela ciência para sua compreensão e prevenção. Esse fenômeno ocorre em diferentes tipos de metais quando expostos às condições atmosférica e água. Um dos metais mais afetados por esse problema são as ligas ferrosas como aço carbono. Este metal é bastante utilizado pelas indústrias metalomecânicas e da construção civil para confecção de chapas, barras, tubos e etc. Ao longo do tempo, esses materiais são afetados pela corrosão necessitando de reparação ou substituição. Isto irá gerar custos diretos e indiretos (e.g. danos ambientais, desperdício de recursos e de tempo de produção) que podem ser otimizados com a utilização de tecnologias de controle de corrosão ([GONCALVES, 2013](#)).

Basicamente, a corrosão pode ser definida como a deterioração de um metal através da interação com o meio corrosivo a partir da sua superfície. A complexidade das diferentes condições atmosféricas e geográficas (e.g. temperatura, umidade, poluição, velocidade e direção do vento) torna a compreensão do processo de corrosão complexo e de difícil simulação em experimentos laboratoriais ([SILVA et al., 2015](#)). Essas condições de interação entre o metal e o meio corrosivo definem o tipo de corrosão.

Atualmente existem diferentes técnicas que são amplamente utilizadas para o monitoramento do processo de corrosão, tais como, medidas de perda de massa, inspeção visual,

radiografia, termografia e sensores de hidrogênio (CRAGNOLINO, 2008). Entretanto, tais técnicas apresentam resultados muitas vezes imprecisos ou não conclusivo para alguns tipos de corrosão. Por exemplo, a inspeção visual é lenta e subjetiva para pequenas mudanças na corrosão e a medida de perda de massa pode não ser confiável quanto a pequenas perdas de massa em alguns tipos de corrosão (GONCALVES, 2013).

Neste contexto, esta seção realiza um estudo do processo de corrosão de aço carbono presente em vídeos. Esses vídeos são compostos de sequências de imagens que podem ser obtidas facilmente através de microscopia de uma parte do material. Além das indústrias metalomecânicas e da construção civil, o aço carbono é amplamente utilizado para confecção de oleodutos e maquinários para extração de petróleo. Em particular no Brasil, a busca por novos campos de exploração levou a Petrobrás a extrair petróleo em alto mar. Essa extração é feita juntamente com águas que possui alta presença de sais e microrganismos agressivos ao aço da tubulação, agravando o problema de corrosão (MENDES, 2009). Como a corrosão de uma tubulação pode causar vazamento de petróleo e afetar o meio ambiente, a investigação de tecnologias para minimizar e prever esse problema é importante. Assim, este trabalho contribui para a área aplicando os métodos desenvolvidos na classificação do tipo de corrosão de aço carbono submetidos a diferentes meios. Para isso, a corrosão de aço carbono presente em sequências de imagens é modelado como uma textura dinâmica.

Nas seções a seguir, a base de dados contendo os vídeos de corrosão de aço carbono é descrita e, em seguida, os experimentos e resultados obtidos são apresentados.

6.1.1 Base de dados

A base de dados utilizada nesta aplicação foi fornecida pelos pesquisadores Dr. Ernesto Chaves Pereira e Dr. Alexsandro Mendes Zimer do departamento de química da Universidade Federal de São Carlos (UFSCAR). Esta base é composta de micrografias dos eletrodos de aço carbono 1020. Estes foram expostos a um meio corrosivo da espécie H_2S em solução (faixa de pH 3-5) nas concentrações de 100 e 1000 ppm, com ausência e presença de cloreto Cl (concentração fixa de 3,5%). As soluções utilizadas nas medidas voltamétricas foram preparadas com água obtida pelo Sistema de Osmose Reversa da marca Gehaka - modelo OS- 20-LX- FARMA. O H_2S foi gerado pela dissociação do sal $Na_2S \cdot 9H_2O$ na concentração de $0,311 \text{ mol L}^{-1}$, o que conferia a solução final de 100 mL uma concentração de 10.000 ppm usada como estoque para futuras diluições obtendo as concentrações de 100 e 1000 ppm (MENDES, 2009).

Os vídeos foram filmados in situ com um microscópio óptico triocular em duas técnicas diferentes. A primeira é a de curvas de polarização (CP), esta é uma técnica específica que faz uma varredura de potenciais na direção anódica registrando a corrente do processo corrosivo durante esta varredura. De um modo geral, a velocidade de corrosão é acelerada em um meio específico, ou seja, o processo corrosivo é filmado sobre influência de um potencial externo. A segunda técnica monitora especificamente o potencial de circuito aberto (Eoc). Nesse caso, a

Tabela 7 – Condições experimentais que influenciam no tipo de corrosão.

Condições experimentais
Eoc H ₂ S 100 ppm e Cl
Eoc H ₂ S 100 ppm
Eoc H ₂ S 1000 ppm e Cl
Eoc H ₂ S 1000 ppm
CP H ₂ S 100 ppm e Cl
CP H ₂ S 100 ppm
CP H ₂ S 1000 ppm e Cl
CP H ₂ S 1000 ppm

corrosão ocorre de forma espontânea.

Dessa forma, podem ser consideradas oito condições experimentais que influenciam o tipo de corrosão, que são listadas na Tabela 7. Cada amostra da base de dados é composta por vídeo in situ da superfície do eletrodo com um tempo de aquisição de cada imagem de 0,1 s. Como o processo de corrosão é muito lento e, conseqüentemente, possui poucas mudanças a cada 0,1s, neste trabalho são consideradas as imagens obtidas a cada 25 s. Portanto, cada condição experimental resultou em um vídeo de 80 quadros com 1280 → 1024 pixels. A Figura 44 mostra o primeiro quadro de cada condição experimental. Para aplicar os métodos desenvolvidos, foram obtidas 25 amostras de 180 → 180 → 80 pixels sem sobreposições de cada condição experimental, como mostra a Figura 45.

Figura 44 – Primeiro quadro dos vídeos de cada condição experimental.

Fonte: Elaborada pelo autor.

Figura 45 – Ilustração do esquema de obtenção das amostras sem sobreposição de um vídeo de uma condição experimental de corrosão de aço carbono.

Fonte: Elaborada pelo autor.

6.1.2 Experimentos e Resultados

Nesta seção, os resultados de classificação de tipo de corrosão obtidos com os métodos desenvolvidos são apresentados. Para realizar os experimentos, cada condição experimental que resulta em um tipo de corrosão foi considerada uma classe, totalizando 8 classes. Os resultados foram validados por um esquema de validação cruzada em 10 pastas e classificador 1-vizinho mais próximo. Embora os parâmetros dos experimentos anteriores alcance excelentes resultados nessa aplicação, foi realizado um novo estudo para compreensão das características do problema de corrosão.

Os resultados para os diferentes parâmetros do método de difusão em redes são apresentados na Figura 46. Note que a taxa de classificação correta de 100% foi atingida usando somente os limiares 1 e 2 e o raio $\rho = 1$. Isso mostra que pelo menos no início do processo de corrosão os quadros são bastante homogêneos, isto é, sem mudanças bruscas no nível de cinza. Na Figura 47 é mostrado a projeção dos vetores de características extraídos pelo método usando a técnica de visualização t-SNE. Como pode ser visto, as amostras de cada tipo de corrosão estão agrupadas.

A Figura 48 resume os resultados para o métodos de CDPA Rs executadas em descritores espacial e temporal com diferentes conjuntos de tamanho de memória e regras de movimento. O método atingiu 100% de classificação correta com a combinação dos dois descritores e diferentes combinações de tamanho de memória. Por outro lado, como mostra a Figura 49 o método de

Figura 46 – Taxa de classificação correta da difusão em redes para diferentes valores de parâmetro na base de dados de corrosão de aço carbono.

Fonte: Elaborada pelo autor.

redes geradas por CDPARs usando a estratégia de descritores espacial e temporal obteve 99,5% de taxa de classificação correta combinando os dois descritores, independente do conjunto de tamanho de memórias. Este mesmo resultado foi obtido pelo método de redes geradas por CDPAR usando três planos ortogonais, como apresenta a Figura 50. Nesse método os melhores resultados foram obtidos com concatenações dos três planos ortogonais e regras de movimento para todos os conjuntos de tamanho de memória.

Os resultados mostraram que os métodos propostos conseguem classificar adequadamente os tipos de corrosão sem muita interferência dos valores dos parâmetros. De modo geral, foi possível constatar que em todos os métodos, as características extraídas referente ao movimento foram mais importantes na classificação dos tipos de corrosão comparada com as características de aparência. De fato, a aparência de alguns tipos de corrosão são muito similares, como mostra a Figura 44. No entanto, como mostrou os experimentos, os padrões do processo de corrosão ao longo do tempo mudam de acordo com o tipo da corrosão. Isso faz com que as características de movimento sejam mais robustas, permitindo uma melhor separação dos tipos de corrosão.

Figura 47 – Projeção com t-SNE dos vetores de características extraídos pelo método de difusão em redes da base de corrosão de aço carbono.

Fonte: Elaborada pelo autor.

6.2 Análise de intensidade de tráfego de veículos em rodovias

Um dos principais problemas nos últimos anos em grandes cidades são os congestionamentos de veículos que afetam diariamente o deslocamento das pessoas. Uma das soluções frequentemente adotada pelas autoridades para amenizar este problema é a construção de novas estradas. No entanto, esta solução tradicional gera elevados custos e muitas vezes são ineficazes. Deste modo, alternativas contemporâneas concentram-se em otimizar o escoamento nas rodovias através da análise de diferentes aspectos do tráfego (DERPANIS; WILDES, 2011). Nesse tipo de abordagem a utilização de câmeras têm crescido pelo baixo custo, facilidade na instalação em relação aos radares tradicionais e por permitir uma compreensão mais detalhada das informações de fluxo de tráfego (e.g. velocidade, ocupação das faixas da pista e número de carros) (GONCALVES, 2013).

Na literatura, diferentes abordagens foram propostas para o monitoramento de tráfego em rodovias por meio de vídeos. A maioria dos trabalhos relatados concentram-se em combinar algoritmos de segmentação e rastreamento (MAGEE, 2004; JUNG; LEE; HO, 2001; KAMIJO et al., 2000). Estas abordagens consistem basicamente em segmentar os carros por meio de características de movimento, para em seguida rastrear a trajetória dos veículos nos quadros

Figura 48 – Taxa de classificação correta para diferentes conjuntos de tamanho de memória e regras de movimento obtidas pelo método de CDPARs executadas em descritores espacial e temporal na base de dados de corrosão de aço carbono.

Fonte: Elaborada pelo autor.

através de filtros preditivos. No entanto, essas abordagens apresentam diversas limitações, tais como, imprecisão da segmentação devido a variações no ambiente (e.g., iluminação, chuva, noite), oclusões e baixa resolução nos vídeos (DERPANIS; WILDES, 2011). Além dessas, os algoritmos de rastreamento também apresentam problemas quando existem muitos veículos nos vídeos, por exemplo, como nos congestionamentos. (GONCALVES, 2013; CHAN; VASCONCELOS, 2005a).

Neste contexto, uma alternativa é utilizar uma abordagem macroscópica para analisar o fluxo de tráfego. Assim, a variação do campo de movimento é modelada sem a necessidade de detectar e rastrear carros individualmente. Deste modo, nesta seção os vídeos de tráfego são considerados texturas dinâmicas, ou seja, o fluxo de tráfego pode ser caracterizado em termos do conjunto de elementos e a sua dinâmica. Para isso, os métodos propostos no Capítulo 4 são utilizados para caracterização dos vídeos de tráfego. Após a extração de características, os vídeos podem ser classificados de acordo com a sua intensidade do tráfego.

Figura 49 – Taxa de classificação correta da base de corrosão de aço para diferentes combinações de tamanhos de memória e regras de movimento do método de redes geradas por CDPARs com a estratégia de execução de descritores espacial e temporal.

Fonte: Elaborada pelo autor.

Nas seções a seguir, a base de dados utilizada nos experimentos é descrita. Em seguida, os resultados de classificação da intensidade de tráfego com os métodos propostos são apresentados.

6.2.1 Base de dados

A base de dados consiste em vídeos de tráfego diurno da rodovia interestadual I-5 em Seattle coletados pelo departamento de transportes de Washington. A base de dados foi disponibilizada em (CHAN; VASCONCELOS, 2005a). O vídeo totaliza 20 minutos de filmagem e possui uma variedade de padrões de tráfego e condições climáticas (e.g., chuva, sol, nublado). Esse vídeo tem resolução de 320 → 240 pixels e foi dividido em 254 amostras de 42 a 52 quadros a 10 quadros por segundo. Os vídeos foram manualmente rotulados em uma das seguintes classes de intensidade de tráfego: leve (156), médio (45) e pesado (44). Os valores entre parênteses são os números de amostras por classe. A Figura 51 apresenta o primeiro quadro de algumas amostras da base.

Figura 50 – Taxas de classificação correta usando diferentes combinações de tamanhos de memória e regras de movimento para a estratégia de planos ortogonais na base de dados de corrosão de aço carbono.

Fonte: Elaborada pelo autor.

6.2.2 Classificação de intensidade de tráfego

Nesta seção são apresentados os resultados de classificação da intensidade de tráfego de veículos com os métodos desenvolvidos. Inicialmente é realizada uma análise dos parâmetros para compreender o comportamento dos métodos nessa tarefa. Em seguida, os resultados obtidos são comparados com outras abordagens da literatura. Os experimentos realizados utilizaram validação cruzada em 10 pastas e o classificador 1-vizinho mais próximo.

O primeiro método avaliado foi o de difusão em redes aplicado em texturas dinâmicas. Os parâmetros do método são t_0 , t_i e t_f , que indicam o conjunto de limiares utilizados na função de corte de arestas $f(t, E)$ e o raio de conexão r . A Figura 52 sumariza as taxas de classificação correta em função de diferentes limiares e o raios. A melhor taxa de classificação correta foi de 96,60% obtida com o conjunto de limiares iniciado em $t_0 = 4$, incrementando por um valor $t_i = 110$ por $n_f = 1$ vez. Portanto, este conjunto é composto pelos limiares 4 e 114. Este resultado foi atingido usando a concatenação de raios $r = [p_1, p_2, p_3, p_4, p_5]$.

Figura 51 – Exemplos do primeiro quadro das três classes de texturas dinâmicas da base de dados de tráfego.

Fonte: Elaborada pelo autor.

Figura 52 – Análise dos parâmetros da difusão em redes como função da taxa de classificação correta da base de tráfego.

Fonte: Elaborada pelo autor.

O segundo experimento conduzido foi a aplicação do método de caminhadas determinísticas parcialmente auto-repulsivas nos vídeos de tráfego. Assim como na base de dados UCLA, os experimentos foram realizados usando os $n = 3$ primeiros elementos do histograma $h_{\mu,r}^Q(l)$. A Figura 53 apresenta os resultados para os descritores espacial e temporal e a combinação desses dois descritores usando diferentes regras de movimento e memórias. Note que, independente da regra de movimento, os resultados são bem próximos, com uma leve superioridade da regra $r = \min$. O melhor resultado foi obtido com a concatenação dos tamanhos de memória $\mu = [0, 1, 2, 3]$ e usando somente o descritor temporal.

Em particular, os resultados sugerem que nos vídeos de tráfego os padrões de movimento (isto é, relacionados a velocidade dos carros na rodovia) são mais importantes do que os de aparência na tarefa de reconhecimento. De fato, há poucas mudanças intraclass na aparência dos vídeos (que é basicamente composta por veículos), sendo a velocidade do tráfego (i.e. leve, médio e pesado) na rodovia o principal indicador da sua intensidade. Portanto, esta base de dados

deve ser tratada como um caso em particular, no geral, as informações de aparência e movimento são necessárias para uma caracterização adequada.

Figura 53 – Resultados do método de CDPA Rs em texturas dinâmicas com características extraídas da base de dados de tráfego a partir do descritor espacial e temporal usando diferentes combinações de memória e regras de movimento.

Fonte: Elaborada pelo autor.

Por fim, o método de redes geradas por CDPA Rs é aplicado nos vídeos de tráfego. Os experimentos foram realizados considerando as cinco medidas de redes complexas que obtiveram os melhores resultados na análise experimental. Na Figura 54 é apresentado os resultados da análise de diferentes tamanhos de memória e regras de movimento com a estratégia de descritores espacial e temporal para execução das CDPA Rs nos vídeos. Note que a melhor taxa de classificação correta de 90,6 % foi obtida somente com a combinação dos dois descritores, a regra de movimento $r = \text{min}$ e concatenação de memórias $\mu = [0, 1]$.

A Figura 55 resume os resultados da análise experimental conduzida para a estratégia de planos ortogonais para aplicação das CDPA Rs. Cada gráfico apresenta os resultados de um plano ortogonal e dos planos combinados. Como se pode ver, o incremento do tamanho da memória não teve grande influencia na taxa de classificação. Além disso, a regra de movimento

Figura 54 – Resultados da base de tráfego para diferentes combinações de tamanhos de memória, regras de movimento e descritores do método de redes geradas por CDPARs com a estratégia de execução de descritores espacial e temporal.

Fonte: Elaborada pelo autor.

$r = \min$ teve um desempenho levemente superior comparada a regra $r = \max$ e combinação das duas regras. A melhor taxa de classificação correta de 89,00 % foi obtida com a combinação de tamanhos de memórias $\mu = [0, 1, 2, 3]$ e usando os três planos ortogonais combinados.

6.2.2.1 Comparação com outros métodos

Nesta seção, os resultados obtidos com os métodos propostos na análise anterior são comparados com os métodos da literatura. A configuração experimental utilizada para todos os métodos foi validação cruzada em 10 pastas com o classificador 1-vizinho mais próximo. A Tabela 8 sumariza os resultados obtidos para cada método. Como pode ser visto, as melhores taxas de classificação correta foram obtidas pelo método proposto de difusão em redes e pelo método da literatura CNDT, com 96,46% e 96,60% de taxas de acerto, respectivamente. Além disso, o método proposto CDPAR DET obteve uma taxa de classificação correta de 93,00% que é próxima dos métodos da literatura RI-VLBP, LBP-TOP e CDT-TOP. No entanto, observe que a dimensão do vetor de característica do método CDPAR DET é de apenas 12 dimensões, enquanto

Figura 55 – Taxas de classificação correta usando diferentes combinações de tamanhos de memória e regras de movimento para a estratégia de planos ortogonais no vídeos de tráfego de veículos.

Fonte: Elaborada pelo autor.

os demais métodos possuem vetores com dimensões bastante superiores (e.g. LBP-TOP possui um vetor de 768 dimensões). Portanto, os resultados destes dois métodos comparados com os demais da literatura demonstram que eles conseguem caracterizar adequadamente os vídeos de tráfego que possuem padrões de aparência similar e diferentes padrões de movimento.

A Figura 56 mostra a matriz de confusão obtida com o método de difusão em redes. Note que a classe que teve o pior desempenho foi a de tráfego médio com amostras classificadas incorretamente como tráfego leve e pesado. Em geral, os vídeos de tráfego são confundidos entre leve ou médio e pesado ou médio. Isto ocorre devido a proximidade dos padrões de intensidade de tráfego médio de algumas amostras com as demais classes. Isto é corroborado na projeção em duas dimensões usando t-SNE dos vetores de características extraídos pelo método de difusão em redes, como mostra a Figura 57. Veja alguns exemplos do primeiro quadro das duas classes na Figura 58. Como pode ser visto, o número de carros na rodovia nas amostras dessas duas classes é bastante próxima, consequentemente, a velocidade também é muito similar. Isto torna a distinção entre dessas amostras através dos padrões de movimento uma tarefa difícil.

Tabela 8 – Comparação dos resultados de classificação do método proposto com os métodos da literatura para a base de tráfego.

Métodos	N. de características	TCC (%)	Precision	Recall	ROC
RI-VLBP	16384	93,31 ($\pm$ 4,34)	0,93	0,93	0,96
LBP-TOP	768	93,70 ($\pm$ 4,70)	0,94	0,94	0,95
CDT-TOP	75	93,70 ($\pm$ 4,83)	0,94	0,94	0,96
CNDT	144	96,46 ($\pm$ 4,10)	0,97	0,97	0,98
CDPAR DET	12	93,00 ($\pm$ 5,40)	0,90	0,90	0,93
CDPAR+Redes DET	20	90,60 ($\pm$ 4,16)	0,90	0,90	0,93
CDPAR+Redes TOP	60	89,00 ($\pm$ 4,32)	0,89	0,89	0,93
Difusão em redes	297	96,60 ($\pm$ 4,38)	0,95	0,95	0,96

Fonte: Dados da pesquisa.

Figura 56 – Matriz de confusão da base de tráfego.

Fonte: Elaborada pelo autor.

6.3 Conclusão

Neste capítulo, os métodos desenvolvidos nessa dissertação foram aplicados em dois problemas reais. Na aplicação de classificação de tipos de corrosão os métodos propostos conseguiram separar adequadamente as diferentes condições experimentais de corrosão do aço carbono. Na aplicação de reconhecimento de intensidade de tráfego o método proposto de difusão em redes obteve o melhor resultado em comparação com os demais métodos da literatura. Assim, foi possível reconhecer adequadamente a intensidade de tráfego da rodovia. Além disso, foi possível concluir que a intensidade do tráfego está mais relacionada com as características de movimento do que de aparência do vídeo.

Figura 57 – Projeção com t-SNE dos vetores de características extraídos pelo método de difusão em redes da base de tráfego.

Fonte: Elaborada pelo autor.

Figura 58 – Exemplos do primeiro quadro de algumas amostras similares de intensidade de tráfego médio e pesado.

Fonte: Elaborada pelo autor.

CONCLUSÃO

Embora diversas abordagens tenham sido reportadas ao longo dos anos, a análise de texturas dinâmicas em vídeos permanece um problema desafiador em visão computacional e com uma grande possibilidade de aplicações. Uma das razões para isso é a natureza complexa das texturas dinâmicas, tornando difícil uma definição objetiva e abrangente. Dado a sua complexidade, uma abordagem interessante para caracterização é utilizar técnicas de complexidade advindas da área de sistemas complexos. Apesar de não existir uma definição formal para o termo complexidade, esta pode ser compreendida como uma medida de irregularidade das texturas dinâmicas, permitindo quantificar padrões de aparência e movimento.

Neste sentido, este trabalho traz justamente a proposta de aplicar metodologias de complexidade para o desenvolvimento de novos métodos de caracterização de texturas dinâmicas. Ao decorrer do trabalho, foram propostos três métodos para caracterização de texturas dinâmicas baseados em redes complexas e CDPA Rs. Em relação as redes complexas, o método modela as texturas dinâmicas em redes direcionadas e utiliza a difusão para a sua caracterização. Como se verificou nos experimentos, a difusão captura as principais características das texturas dinâmicas presentes nos vídeos. No que tange as CDPA Rs, a estratégia de execução das caminhadas em descritores espacial e temporal demonstrou ser adequada para caracterizar aparência e movimento das texturas dinâmicas, respectivamente. Por fim, um terceiro método gera as redes com as trajetórias das CDPA Rs nos vídeos de texturas dinâmicas em duas diferentes estratégias de execução. As medidas extraídas das redes demonstraram em algumas situações ser mais eficaz na caracterização do que o histograma do tamanho das trajetórias.

O desenvolvimento destes métodos permitiu cumprir outro objetivo dessa dissertação: desenvolvimento de aplicações em problemas reais. As aplicações são uma forma de avaliar a inserção e contribuição do trabalho para com a sociedade e o seu enquadramento em termos práticos. Dessa forma, os métodos desenvolvidos foram aplicados em dois problemas potenciais. Na classificação de tipos de corrosão de aço carbono os métodos conseguiram classificar adequa-

damente as diferentes condições experimentais, mostrando que as características relacionadas ao movimento são essenciais nessa aplicação. Para a análise da intensidade de tráfego de veículos em rodovias, o método de difusão em redes demonstrou ser capaz de reconhecer apropriadamente a intensidade de tráfego nas rodovias. Os demais métodos obtiveram resultados satisfatórios com vetores de características de baixa dimensão. Os resultados alcançados pelos métodos demonstram a sua aplicabilidade em diferentes áreas.

7.1 Contribuições

As principais contribuições originárias deste trabalho podem ser resumidas da seguinte maneira:

- Revisão bibliográfica dos métodos de análise de texturas e sobre redes complexas e CDPARs.
- Desenvolvimento de método de difusão em redes para análise de texturas dinâmicas.
- Desenvolvimento de método de caracterização de texturas dinâmicas baseado em CDPARs.
- Proposta de método combinando o uso de CDPARs e redes complexas para caracterização de texturas dinâmicas.
- Aplicação dos métodos desenvolvidos nos problemas de corrosão de aço carbono e tráfego de veículos.

7.2 Trabalhos Futuros

De modo geral, os resultados alcançados pelos métodos baseado em complexidade demonstraram enorme potencial para caracterização de texturas dinâmicas. Nesse sentido, existem diversos trabalhos futuros que podem ser desenvolvidos. A seguir os trabalhos futuros são sugeridos.

- Utilizar regras de movimento das CDPARs mais sofisticadas.
- Pesquisar novos métodos para modelagem de texturas dinâmicas em redes.
- Utilizar novas medidas de redes para caracterização.
- Aprofundar os estudos de corrosão de aço carbono.
- Aplicar os métodos desenvolvidos em outros problemas potenciais, tais como em outros tipos de materiais e em problemas de vigilância.

7.3 Trabalhos Gerados

As contribuições deste trabalho resultaram em diversos artigos na área de computação, que estão publicados, submetidos ou em fase de redação. A seguir são listados os trabalhos desenvolvidos ao longo desse mestrado.

- RIBAS, L. C.; BRUNO, O. M.. Fast deterministic tourist walk for texture analysis. In: XII Workshop de Visão Computacional (WVC), 2016, Campo Grande-MS. Proceedings of XII Workshop de Visão Computacional, 2016. p. 45-50.
- RIBAS, L. C.; GONCALVES, W. N. ; BRUNO, O. M.. Texture analysis using deterministic partially self-avoiding walk with thresholds. In: Proceedings of XII Workshop de Visão Computacional, 2016, Campo Grande-MS. Proceedings of XII Workshop de Visão Computacional, 2016. p. 39-44.
- RIBAS, L. C.; GONÇALVES, W. N.; BRUNO, O. M.. Dynamic texture analysis with diffusion in networks. Expert System with Applications, 2017 (submetido).
- RIBAS, L. C.; NEIVA, M. B.; BRUNO, O. M.. Distance Transform Network for Shape analysis. Pattern Recognition, 2017 (submetido).
- MACHICAO, J.; RIBAS, L. C.; SCABINI, L. F. S.; BRUNO, O. M.. Cellular automata rule characterization and classification using texture descriptors. Physica A: Statistical Mechanics and its Applications. (submetido)
- RIBAS, L. C.; BRUNO, O. M.. Dynamic texture analysis using networks generated by deterministic partially self-avoiding walks. (Redação)
- RIBAS, L. C.; BRUNO, O. M.. Dynamic texture analysis with deterministic partially self-avoiding walks. (Redação)

REFERÊNCIAS

AMARAL, L. A.; OTTINO, J. M. Complex networks. *The European Physical Journal B-Condensed Matter and Complex Systems*, Springer, v. 38, n. 2, p. 147–162, 2004. Citado na página 44.

ARASHLOO, S. R.; KITTLER, J. Dynamic Texture Recognition Using Multiscale Binarized Statistical Image Features. *Multimedia, IEEE Transactions on*, v. 16, n. 8, p. 2099–2109, 2014. Citado 2 vezes nas páginas 109 e 110.

AZENCOTT, R.; WANG, J.-P.; YOUNES, L. Texture classification using windowed fourier filters. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, IEEE*, v. 19, n. 2, p. 148–153, 1997. Citado 2 vezes nas páginas 35 e 37.

BACKES, A.; BRUNO, O.; CAMPITELI, M.; MARTINEZ, A. Deterministic tourist walks as an image analysis methodology based. In: *Progress in Pattern Recognition, Image Analysis and Applications*. Springer Berlin Heidelberg, 2006. v. 4225, p. 784–793. ISBN 978-3-540-46556-0. Disponível em: <http://dx.doi.org/10.1007/11892755_81>. Citado 3 vezes nas páginas 37, 54 e 55.

BACKES, A. R. Estudos de métodos de análise de complexidade em imagens. Tese (Doutorado em Ciências Matemáticas e de Computação) — ICMC - Universidade de São Paulo, São Carlos, 2010. Citado 7 vezes nas páginas 27, 55, 56, 57, 59, 60 e 79.

BACKES, A. R.; BRUNO, O. M. Plant leaf identification using color and multi-scale fractal dimension. In: *International Conference on Image and Signal Processing*. [S.l.: s.n.], 2010. p. 463–470. Citado na página 37.

_____. Texture analysis using volume-radius fractal dimension. *Applied Mathematics and Computation*, v. 219, n. 11, p. 5870 – 5875, 2013. ISSN 0096-3003. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0096300312012854>>. Citado 2 vezes nas páginas 27 e 37.

BACKES, A. R.; CASANOVA, D.; BRUNO, O. M. A complex network-based approach for boundary shape analysis. *Pattern Recognition*, v. 42, n. 1, p. 54 – 67, 2009. ISSN 0031-3203. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0031320308002793>>. Citado na página 52.

_____. Plant leaf identification based on volumetric fractal dimension. *INTERNATIONAL JOURNAL OF PATTERN RECOGNITION AND ARTIFICIAL INTELLIGENCE*, v. 23, n. 6, p. 1145–1160, 2009. Citado na página 37.

_____. Identificação de plantas por análise da textura foliar. In: *Anais do VI Workshop de Visão Computacional (WVC 2010)*, Presidente Prudente, SP. [S.l.: s.n.], 2010. p. 19–24. Citado na página 25.

_____. Color texture analysis based on fractal descriptors. *PATTERN RECOGNITION*, v. 45, n. 5, p. 1984–1992, 2012. Citado na página 37.

_____. Texture analysis and classification: A complex network-based approach. *Information Sciences*, v. 219, n. 0, p. 168 – 180, 2013. ISSN 0020-0255. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0020025512004677>>. Citado 4 vezes nas páginas 52, 53, 67 e 96.

BACKES, A. R.; GONÇALVES, W. N.; MARTINEZ, A. S.; BRUNO, O. M. Texture analysis and classification using deterministic tourist walk. *Pattern Recognition*, Elsevier, v. 43, n. 3, p. 685–694, 2010. Citado 7 vezes nas páginas 37, 54, 56, 57, 59, 78 e 79.

BACKES, A. R.; MARTINEZ, A. S.; BRUNO, O. M. Texture analysis based on maximum contrast walker. *Pattern Recogn. Lett.*, Elsevier Science Inc., New York, NY, USA, v. 31, n. 12, p. 1701–1707, set. 2010. ISSN 0167-8655. Disponível em: <<http://dx.doi.org/10.1016/j.patrec.2010.05.022>>. Citado na página 55.

_____. Texture analysis using graphs generated by deterministic partially self-avoiding walks. *Pattern Recognition*, v. 44, n. 8, p. 1684 – 1689, 2011. ISSN 0031-3203. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S003132031100046X>>. Citado 7 vezes nas páginas 27, 53, 54, 55, 80, 82 e 85.

BARABÁSI, A.-L.; ALBERT, R. Emergence of scaling in random networks. *science, American Association for the Advancement of Science*, v. 286, n. 5439, p. 509–512, 1999. Citado 2 vezes nas páginas 44 e 46.

BARABASI, A.-L.; OLTVAI, Z. N. Network biology: understanding the cell's functional organization. *Nature reviews genetics*, Nature Publishing Group, v. 5, n. 2, p. 101–113, 2004. Citado na página 44.

BERGEN, J. R.; LANDY, M. S. Computational modeling of visual texture segregation. *Computational models of visual processing*, CiteSeer, v. 1, p. 253–271, 1991. Citado na página 31.

BHARATI, M. H.; LIU, J. J.; MACGREGOR, J. F. Image texture analysis: methods and comparisons. *Chemometrics and intelligent laboratory systems*, Elsevier, v. 72, n. 1, p. 57–71, 2004. Citado 2 vezes nas páginas 36 e 37.

BLOSTEIN, D.; AHUJA, N. Shape from texture: Integrating texture-element extraction and surface estimation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, IEEE, v. 11, n. 12, p. 1233–1251, 1989. Citado na página 36.

BONACICH, P.; LLOYD, P. Eigenvector-like measures of centrality for asymmetric relations. *Social Networks*, v. 23, n. 3, p. 191 – 201, 2001. ISSN 0378-8733. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378873301000387>>. Citado na página 51.

BORNHOLDT, S.; SCHUSTER, H. G. Handbook of graphs and networks: from the genome to the internet. [S.l.]: John Wiley & Sons, 2006. Citado na página 44.

BOVIK, A.; CLARK, M.; GEISLER, W. Multichannel texture analysis using localized spatial filters. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 12, n. 1, p. 55–73, 1990. Cited By 836. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-0025263482&partnerID=40&md5=58dc5073e0e0c6b63b76b3d089d51624>>. Citado na página 37.

BRIEU, N.; SERBANOVIC-CANIC, J.; CVEJIC, A.; STEMPLE, D.; OUWEHAND, W.; NAVAB, N.; GROHER, M. Thrombus segmentation by texture dynamics from microscopic image sequences. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. SPIE Medical Imaging. [S.l.], 2010. p. 76233Z–76233Z. Citado 2 vezes nas páginas 26 e 39.

BRUNO, O. M.; PLOTZE, R. de O.; FALVO, M.; CASTRO, M. de. Fractal dimension applied to plant identification. *Information Sciences*, v. 178, n. 12, p. 2722 – 2733, 2008. ISSN 0020-0255. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0020025508000364>>. Citado na página 34.

CAMPITELI, M.; MARTINEZ, A.; BRUNO, O. An image analysis methodology based on deterministic tourist walks. In: *Advances in Artificial Intelligence - IBERAMIA-SBIA 2006*. Springer Berlin Heidelberg, 2006, (Lecture Notes in Computer Science, v. 4140). p. 159–167. ISBN 978-3-540-45462-5. Disponível em: <http://dx.doi.org/10.1007/11874850_20>. Citado 3 vezes nas páginas 27, 55 e 57.

CARLUCCI, L. A formal system for texture languages. *Pattern Recognition*, v. 4, n. 1, p. 53–72, 1972. Cited By 31. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-0012811683&partnerID=40&md5=ce47a8244cc46869241ff64d7c4d849a>>. Citado na página 36.

CASANOVA, D.; JUNIOR, J. J. de M. S.; BRUNO, O. M. Plant leaf identification using gabor wavelets. *International Journal of Imaging Systems and Technology*, Wiley Subscription Services, Inc., A Wiley Company, v. 19, n. 3, p. 236–243, 2009. ISSN 1098-1098. Disponível em: <<http://dx.doi.org/10.1002/ima.20201>>. Citado na página 34.

CHALUMEAU, T.; COSTA, L. d.; LALIGANT, O.; MERIAUDEAU, F. Texture discrimination using hierarchical complex networks. In: DAMIANI, E.; YÄTONGNON, K.; SCHELKENS, P.; DIPANDA, A.; LEGRAND, L.; CHBEIR, R. (Ed.). *Signal Processing for Image Enhancement and Multimedia Processing*. Springer US, 2008, (Multimedia Systems and Applications Series, v. 31). p. 95–102. ISBN 978-0-387-72499-7. Disponível em: <http://dx.doi.org/10.1007/978-0-387-72500-0_9>. Citado na página 52.

CHALUMEAU, T.; COSTA, L. d. F.; LALIGANT, O.; MERIAUDEAU, F. Texture discrimination using hierarchical complex networks. In: *INTERNATIONAL CONFERENCE ON SIGNAL IMAGE TECHNOLOGY AND INTERNET BASED SYSTEMS (SITIS)*. [S.l.]: Springer US, 2006. p. 543–550. Citado na página 52.

CHAN, A.; VASCONCELOS, N. Modeling, clustering, and segmenting video with mixtures of dynamic textures. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 30, n. 5, p. 909–926, May 2008. ISSN 0162-8828. Citado 2 vezes nas páginas 35 e 40.

CHAN, A. B.; VASCONCELOS, N. Classification and retrieval of traffic video using autoregressive stochastic processes. In: *IEEE. Intelligent Vehicles Symposium, 2005. Proceedings. IEEE*. [S.l.], 2005. p. 771–776. Citado 3 vezes nas páginas 40, 119 e 120.

_____. Probabilistics for the classification of auto-regressive visual processes. In: *IEEE. Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*. [S.l.], 2005. v. 1, p. 846–851. Citado na página 90.

_____. Classifying video with kernel dynamic textures. In: *CVPR*. [S.l.: s.n.], 2007. p. 1–6. Citado 2 vezes nas páginas 26 e 108.

- CHANG, T.; KUO, C.-C. J. Texture analysis and classification with tree-structured wavelet transform. *IEEE Transactions on Image Processing*, v. 2, n. 4, p. 429–441, 1993. Cited By 893. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-0027677864&partnerID=40&md5=e214674f43b20ae9d93e67c877b01dc1>>. Citado na página 37.
- CHELLAPPA, R.; CHATTERJEE, S. Classification of textures using gaussian markov random fields. *Acoustics, Speech and Signal Processing, IEEE Transactions on*, IEEE, v. 33, n. 4, p. 959–963, 1985. Citado na página 36.
- CHEN, H.; XIA, Q.; ZUO, T.; TAN, H.; BIAN, Y. Quality grading method of shiitake based on texture analysis. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering*, v. 30, n. 3, p. 285–292, 2014. Cited By 0. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84894832133&partnerID=40&md5=d57a03ca5cfed6ee06e937b1dd13815f>>. Citado na página 25.
- CHEN, J.; ZHAO, G.; SALO, M.; RAHTU, E.; PIETIKAINEN, M. Automatic dynamic texture segmentation using local descriptors and optical flow. *Image Processing, IEEE Transactions on*, v. 22, n. 1, p. 326–339, Jan 2013. ISSN 1057-7149. Citado na página 39.
- CHETVERIKOV, D.; PÉTERI, R. A brief survey of dynamic texture description and recognition. In: *Computer Recognition Systems*. [S.l.]: Springer, 2005. p. 17–26. Citado 3 vezes nas páginas 37, 40 e 41.
- CLAUSET, A.; SHALIZI, C. R.; NEWMAN, M. E. Power-law distributions in empirical data. *SIAM review*, SIAM, v. 51, n. 4, p. 661–703, 2009. Citado na página 46.
- COHEN, R.; HAVLIN, S. *Complex Networks: Structure, Robustness and Function*. Cambridge University Press, 2010. ISBN 9781139489270. Disponível em: <<https://books.google.com.br/books?id=1ECLiFrKullC>>. Citado na página 44.
- COMIN, C. H.; VIANA, M. P.; ANTIQUEIRA, L.; COSTA, L. da F. Random walks in directed modular networks. *Journal of Statistical Mechanics: Theory and Experiment*, v. 2014, n. 12, p. P12003, 2014. Disponível em: <<http://stacks.iop.org/1742-5468/2014/i=12/a=P12003>>. Citado na página 51.
- COSTA, L.; RODRIGUES, F.; TRAVIESO, G.; BOAS, P. Characterization of complex networks: A survey of measurements. *Advances in Physics*, Taylor & Francis, v. 56, n. 1, p. 167–242, 2007. ISSN 0001-8732. Citado 3 vezes nas páginas 44, 47 e 67.
- CRAGNOLINO, G. A. 2 - corrosion fundamentals and characterization techniques. In: YANG, L. (Ed.). *Techniques for Corrosion Monitoring*. Woodhead Publishing, 2008, (Woodhead Publishing Series in Metals and Surface Engineering). p. 6 – 45. ISBN 978-1-84569-187-5. Disponível em: <<http://www.sciencedirect.com/science/article/pii/B9781845691875500029>>. Citado na página 114.
- CROSS, G.; JAIN, A. Markov random field texture models. *IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-5*, n. 1, p. 25–39, 1983. Cited By 630. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-0020497293&partnerID=40&md5=d1ffd7906436ef91b94bbf4873694cb2>>. Citado na página 36.
- DAS, A.; BUCKSCH, A.; PRICE, C. A.; WEITZ, J. S. Clearedleavesdb: an online database of cleared plant leaf images. *Plant Methods*, v. 10, n. 1, p. 1–8, 2014. ISSN 1746-4811. Disponível em: <<http://dx.doi.org/10.1186/1746-4811-10-8>>. Citado na página 34.

DERPANIS, K. G.; WILDES, R. P. Classification of traffic video based on a spatiotemporal orientation analysis. In: IEEE. Applications of Computer Vision (WACV), 2011 IEEE Workshop on. [S.l.], 2011. p. 606–613. Citado 2 vezes nas páginas 118 e 119.

DERPANIS, K. G. P.; WILDES, R. Spacetime texture representation and recognition based on a spatiotemporal orientation analysis. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 34, n. 6, p. 1193–1205, June 2012. ISSN 0162-8828. Citado 2 vezes nas páginas 39 e 107.

DORETTO, G.; CHIUSO, A.; WU, Y.; SOATTO, S. Dynamic textures. International Journal of Computer Vision, Kluwer Academic Publishers, v. 51, n. 2, p. 91–109, 2003. ISSN 0920-5691. Disponível em: <<http://dx.doi.org/10.1023/A%3A1021669406132>>. Citado 3 vezes nas páginas 25, 26 e 40.

DORETTO, G.; JONES, E.; SOATTO, S. Spatially homogeneous dynamic textures. In: Computer Vision-ECCV 2004. [S.l.]: Springer, 2004. p. 591–602. Citado 3 vezes nas páginas 26, 37 e 40.

DUBOIS, S.; PÉTERI, R.; MÉNARD, M. A comparison of wavelet based spatio-temporal decomposition methods for dynamic texture recognition. In: Pattern Recognition and Image Analysis. [S.l.]: Springer, 2009. p. 314–321. Citado na página 26.

_____. Pattern recognition and image analysis: 4th iberian conference, ibpria 2009 póvoa de varzim, portugal, june 10-12, 2009 proceedings. In: _____. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009. cap. A Comparison of Wavelet Based Spatio-temporal Decomposition Methods for Dynamic Texture Recognition, p. 314–321. ISBN 978-3-642-02172-5. Disponível em: <http://dx.doi.org/10.1007/978-3-642-02172-5_41>. Citado na página 41.

ERDŐS, P.; RÉNYI, A. On the evolution of random graphs. In: PUBLICATION OF THE MATHEMATICAL INSTITUTE OF THE HUNGARIAN ACADEMY OF SCIENCES. [S.l.: s.n.], 1960. p. 17–61. Citado na página 27.

EULER, L. Solutio problematis ad geometriam situs pertinentis. Commentarii academiae scientiarum Petropolitanae, v. 8, p. 128–140, 1741. Citado na página 44.

FAZEKAS, S.; CHETVERIKOV, D. Dynamic texture recognition using optical flow features and temporal periodicity. In: Content-Based Multimedia Indexing, 2007. CBMI '07. International Workshop on. [S.l.: s.n.], 2007. p. 25–32. Citado na página 39.

FERRARI, V.; TUYTELAARS, T.; GOOL, L. V. Object detection by contour segment networks. In: Computer Vision-ECCV 2006. [S.l.]: Springer, 2006. p. 14–28. Citado na página 52.

FLORINDO, J. B.; BRUNO, O. M. Texture analysis by multi-resolution fractal descriptors. EXPERT SYSTEMS WITH APPLICATIONS, v. 40, n. 10, p. 4022–4028, 2013. Citado na página 37.

FREEMAN, L. C. Centrality in social networks conceptual clarification. Social networks, Elsevier, v. 1, n. 3, p. 215–239, 1979. Citado 2 vezes nas páginas 50 e 51.

GHANEM, B.; AHUJA, N. Phase based modelling of dynamic textures. In: IEEE. Computer Vision, 2007. ICCV 2007. IEEE 11th International Conference on. [S.l.], 2007. p. 1–8. Citado na página 40.

_____. Maximum margin distance learning for dynamic texture recognition. In: Proceedings of the 11th European Conference on Computer Vision: Part II. Berlin, Heidelberg: Springer-Verlag, 2010. (ECCV'10), p. 223–236. ISBN 3-642-15551-0, 978-3-642-15551-2. Disponível em: <<http://dl.acm.org/citation.cfm?id=1888028.1888046>>. Citado 2 vezes nas páginas 75 e 89.

_____. _____. In: SPRINGER. European Conference on Computer Vision. [S.l.], 2010. p. 223–236. Citado na página 108.

GIRVAN, M.; NEWMAN, M. E. Community structure in social and biological networks. Proceedings of the national academy of sciences, National Acad Sciences, v. 99, n. 12, p. 7821–7826, 2002. Citado na página 44.

GONÇALVES, W. N. Análise de texturas estáticas e dinâmicas e suas aplicações em biologia e nanotecnologia. Tese (Doutorado em Física Aplicada) — Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos, 2013. Citado 8 vezes nas páginas 25, 34, 35, 73, 113, 114, 118 e 119.

GONÇALVES, W. N.; BACKES, A. R.; MARTINEZ, A. S.; BRUNO, O. M. Texture descriptor based on partially self-avoiding deterministic walker on networks. Expert Systems with Applications, v. 39, n. 15, p. 11818 – 11829, 2012. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417412001078>>. Citado 8 vezes nas páginas 27, 52, 54, 55, 56, 67, 79 e 80.

GONÇALVES, W. N.; BRUNO, O. M. Advanced concepts for intelligent vision systems: 13th international conference, acivs 2011, ghent, belgium, august 22-25, 2011. proceedings. In: _____. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. cap. Dynamic Texture Analysis and Classification Using Deterministic Partially Self-avoiding Walks, p. 349–359. ISBN 978-3-642-23687-7. Disponível em: <http://dx.doi.org/10.1007/978-3-642-23687-7_32>. Citado na página 42.

_____. Combining fractal and deterministic walkers for texture analysis and classification. Pattern Recognition, v. 46, n. 11, p. 2953 – 2968, 2013. ISSN 0031-3203. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0031320313001416>>. Citado 6 vezes nas páginas 54, 55, 57, 79, 80 e 83.

_____. Dynamic texture analysis and segmentation using deterministic partially self-avoiding walks. Expert Systems with Applications, v. 40, n. 11, p. 4283 – 4300, 2013. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417412013346>>. Citado 9 vezes nas páginas 26, 39, 42, 54, 55, 79, 108, 109 e 110.

_____. Dynamic texture segmentation based on deterministic partially self-avoiding walks. Computer Vision and Image Understanding, v. 117, n. 9, p. 1163 – 1174, 2013. ISSN 1077-3142. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1077314213000921>>. Citado 11 vezes nas páginas 26, 35, 42, 54, 55, 56, 77, 79, 80, 83 e 107.

GONÇALVES, W. N.; MACHADO, B. B.; BRUNO, O. M. Spatiotemporal gabor filters: a new method for dynamic texture recognition. Workshop de Visão Computacional, Curitiba, PR, p. 184–189, 2011. Citado na página 41.

_____. A complex network approach for dynamic texture recognition. Neurocomputing, v. 153, n. 0, p. 211 – 220, 2015. ISSN 0925-2312. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231214015677>>. Citado 9 vezes nas páginas 27, 54, 66, 67, 92, 107, 108, 109 e 110.

GONÇALVES, W. N.; MARTINEZ, A. S.; BRUNO, O. M. Complex network classification using partially self-avoiding deterministic walks. *Chaos: An Interdisciplinary Journal of Nonlinear Science, American Institute of Physics AIP*, v. 22, n. 3, p. 033139, sep 2012. ISSN 1054-1500. Disponível em: <<http://aip.scitation.org/doi/10.1063/1.4737515>>. Citado 2 vezes nas páginas 27 e 80.

GONÇALVES, W. N.; SILVA, J. A.; BRUNO, O. M. A rotation invariant face recognition method based on complex network. In: *Iberoamerican Congress on Pattern Recognition*. [S.l.: s.n.], 2010. p. 426–433. Citado na página 67.

GONÇALVES, W. N.; SILVA, N. R. da; COSTA, L. da F.; BRUNO, O. M. Texture recognition based on diffusion in networks. *Information Sciences*, v. 364–365, p. 51 – 71, 2016. ISSN 0020-0255. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S002002551630305X>>. Citado 6 vezes nas páginas 53, 64, 67, 69, 94 e 96.

GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing (3rd Edition)*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006. ISBN 013168728X. Citado na página 37.

GONÇALVES, W. N.; MACHADO, B. B.; BRUNO, O. M. Texture descriptor combining fractal dimension and artificial crawlers. *Physica A: Statistical Mechanics and its Applications*, v. 395, p. 358 – 370, 2014. ISSN 0378-4371. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378437113009825>>. Citado na página 37.

HÁJEK, M. Texture analysis for magnetic resonance imaging. [S.l.]: *Texture Analysis Magn Resona*, 2006. Citado na página 32.

HARALICK, R.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on, SMC-3*, n. 6, p. 610–621, Nov 1973. ISSN 0018-9472. Citado na página 36.

HARALICK, R. M. Statistical and structural approaches to texture. *Proceedings of the IEEE, IEEE*, v. 67, n. 5, p. 786–804, 1979. Citado na página 32.

HAWKINS, J. K. Textural properties for pattern recognition. *Picture processing and psychopictorics*, Academic Press New York, p. 347–370, 1970. Citado na página 31.

HOLME, P. Congestion and centrality in traffic flow on complex networks. *Advances in Complex Systems, World Scientific*, v. 6, n. 02, p. 163–176, 2003. Citado na página 44.

JAIN, A. K.; FARROKHNI, F. Unsupervised texture segmentation using gabor filters. In: *IEEE. Systems, Man and Cybernetics, 1990. Conference Proceedings, IEEE International Conference on*. [S.l.], 1990. p. 14–19. Citado na página 35.

JEONG, H.; MASON, S. P.; BARABÁSI, A.-L.; OLTVAI, Z. N. Lethality and centrality in protein networks. *Nature, Nature Publishing Group*, v. 411, n. 6833, p. 41–42, 2001. Citado na página 44.

Jl, H.; YANG, X.; LING, H.; XU, Y. Wavelet domain multifractal analysis for static and dynamic texture classification. *IEEE Transactions on Image Processing, IEEE*, v. 22, n. 1, p. 286–299, 2013. Citado 3 vezes nas páginas 26, 109 e 110.

JR., J. de S.; BACKES, A.; ROSSATTO, D.; KOLB, R.; BRUNO, O. Measuring and analyzing color and texture information in anatomical leaf cross sections: An approach using computer vision to aid plant species identification. *Botany*, v. 89, n. 7, p. 467–479, 2011. Cited By 2. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-80051556556&partnerID=40&md5=4e409b9d83f0f38170a6afcdf2d1ffbd>>. Citado na página 25.

JULESZ, B. Visual pattern discrimination. *Information Theory, IRE Transactions on*, IEEE, v. 8, n. 2, p. 84–92, 1962. Citado na página 31.

_____. Textons, the elements of texture perception, and their interactions. *Nature*, v. 290, n. 5802, p. 91–97, 1981. Citado na página 31.

JULESZ, B.; BERGEN, J. R. Human factors and behavioral science: Textons, the fundamental elements in preattentive vision and perception of textures. *The Bell system technical journal*, Alcatel-Lucent, v. 62, n. 6, p. 1619–1645, 1983. Citado na página 31.

JULESZ, B.; GILBERT, E.; SHEPP, L.; FRISCH, H. Inability of humans to discriminate between visual textures that agree in second-order statistics-revisited. *Perception*, v. 2, n. 4, p. 391–405, 1973. Citado na página 31.

JUNG, Y.-K.; LEE, K.-W.; HO, Y.-S. Content-based event retrieval using semantic scene interpretation for automated traffic surveillance. *IEEE Transactions on Intelligent Transportation Systems*, IEEE, v. 2, n. 3, p. 151–163, 2001. Citado na página 118.

JUNIOR, J. J. de M. S.; BACKES, A. R.; CORTEZ, P. C. Texture analysis and classification using shortest paths in graphs. *Pattern Recognition Letters*, v. 34, n. 11, p. 1314 – 1319, 2013. ISSN 0167-8655. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167865513001633>>. Citado na página 54.

KAMIJO, S.; MATSUSHITA, Y.; IKEUCHI, K.; SAKAUCHI, M. Traffic monitoring and accident detection at intersections. *IEEE transactions on Intelligent transportation systems*, IEEE, v. 1, n. 2, p. 108–118, 2000. Citado na página 118.

KELLOKUMPU, V.; ZHAO, G.; PIETIKÄINEN, M. Human activity recognition using a dynamic texture based method. In: *BMVC*. [S.l.: s.n.], 2008. v. 1, p. 2. Citado 2 vezes nas páginas 26 e 38.

KHALIL, A.; APONTE, C.; ZHANG, R.; DAVISSON, T.; DICKEY, I.; ENGELMAN, D.; HAWKINS, M.; MASON, M. Image analysis of soft-tissue in-growth and attachment into highly porous alumina ceramic foam metals. *Medical Engineering and Physics*, v. 31, n. 7, p. 775 – 783, 2009. ISSN 1350-4533. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S135045330900068X>>. Citado na página 25.

KOELSTRA, S.; PANTIC, M.; PATRAS, I. A dynamic texture-based approach to recognition of facial actions and their temporal models. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 32, n. 11, p. 1940–1954, Nov 2010. ISSN 0162-8828. Citado na página 38.

LABELLE, L.; LAUZON, D.; KONRAD, J.; DUBOIS, E. Arithmetic coding of a lossless contour based representation of label images. In: *IEEE. Image Processing, 1998. ICIP 98. Proceedings. 1998 International Conference on*. [S.l.], 1998. v. 1, p. 261–265. Citado na página 52.

LAZEBNIK, S.; SCHMID, C.; PONCE, J. A sparse texture representation using local affine regions. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 27, n. 8, p. 1265–1278, Aug 2005. ISSN 0162-8828. Citado na página 36.

LIMA, G. F.; MARTINEZ, A. S.; KINOUCI, O. Deterministic walks in random media. *Phys. Rev. Lett., American Physical Society*, v. 87, p. 010603, Jun 2001. Disponível em: <<http://link.aps.org/doi/10.1103/PhysRevLett.87.010603>>. Citado 3 vezes nas páginas 27, 54 e 55.

LU, Z.; XIE, W.; PEI, J.; HUANG, J. Dynamic texture recognition by spatio-temporal multiresolution histograms. In: *IEEE. Application of Computer Vision, 2005. WACV/MOTIONS' 05 Volume 1. Seventh IEEE Workshops on. [S.l.]*, 2005. v. 2, p. 241–246. Citado na página 39.

MAATEN, L. van der; HINTON, G. Visualizing high-dimensional data using t-sne. *Journal of Machine Learning Research*, v. 9: 2579–2605, Nov 2008. Citado na página 94.

MAGEE, D. R. Tracking multiple vehicles using foreground, background and motion models. *Image and vision Computing, Elsevier*, v. 22, n. 2, p. 143–155, 2004. Citado na página 118.

MATAS, J.; MARIK, R.; KITTLER, J. On representation and matching of multi-coloured objects. In: *IEEE. Computer Vision, 1995. Proceedings., Fifth International Conference on. [S.l.]*, 1995. p. 726–732. Citado na página 52.

MATERKA, A.; STRZELECKI, M. et al. Texture analysis methods—a review. Technical university of lodz, institute of electronics, COST B11 report, Brussels, p. 9–11, 1998. Citado na página 36.

MENDES, A. Z. Estudo da corrosão do aço ao carbono em meio de sulfeto. Tese (Doutorado em Ciências Exatas e da Terra) — Universidade Federal de São Carlos, 2009. Citado na página 114.

MIRANDA, G. H. B.; MACHICAO, J.; BRUNO, O. M. Exploring Spatio-temporal Dynamics of Cellular Automata for Pattern Recognition in Networks. *Scientific Reports, The Author(s)*, v. 6, p. 37329, nov 2016. Citado na página 27.

MITCHELL, M.; NEWMAN, M. Complex systems theory and evolution. *Encyclopedia of Evolution, Citeseer*, p. 1–5, 2002. Citado na página 43.

MORRIS, O.; LEE, M. J.; CONSTANTINIDES, A. Graph theory for image analysis: an approach based on the shortest spanning tree. *Communications, Radar and Signal Processing, IEE Proceedings F*, v. 133, n. 2, p. 146–152, April 1986. ISSN 0143-7070. Citado na página 52.

NASIRUZZAMAN, A.; POTA, H.; MAHMUD, M. Application of centrality measures of complex network framework in power grid. In: *IEEE. IECON 2011-37th Annual Conference on IEEE Industrial Electronics Society. [S.l.]*, 2011. p. 4660–4665. Citado na página 44.

NELSON, R. C.; POLANA, R. Qualitative recognition of motion using temporal texture. *CVGIP: Image Underst., Academic Press, Inc., Orlando, FL, USA*, v. 56, n. 1, p. 78–89, jul. 1992. ISSN 1049-9660. Disponível em: <[http://dx.doi.org/10.1016/1049-9660\(92\)90087-J](http://dx.doi.org/10.1016/1049-9660(92)90087-J)>. Citado 3 vezes nas páginas 26, 37 e 39.

NEWMAN, M. *Networks: An Introduction*. New York, NY, USA: Oxford University Press, Inc., 2010. ISBN 0199206651, 9780199206650. Citado na página 44.

NEWMAN, M. E.; PARK, J. Why social networks are different from other types of networks. *Physical Review E, APS*, v. 68, n. 3, p. 036122, 2003. Citado na página 44.

OJALA, T.; PIETIKÄINEN, M.; MÄENPÄÄ, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *Pattern Analysis and Machine Intelligence, IEEE Transactions on, IEEE*, v. 24, n. 7, p. 971–987, 2002. Citado 3 vezes nas páginas 36, 41 e 111.

OTSUKA, K.; HORIKOSHI, T.; SUZUKI, S.; FUJII, M. Feature extraction of temporal texture based on spatiotemporal motion trajectory. In: *IEEE. Pattern Recognition, 1998. Proceedings. Fourteenth International Conference on. [S.l.], 1998. v. 2, p. 1047–1051*. Citado na página 26.

_____. _____. In: *Pattern Recognition, 1998. Proceedings. Fourteenth International Conference on. [S.l.: s.n.], 1998. v. 2, p. 1047–1051 vol.2. ISSN 1051-4651*. Citado na página 40.

PEH, C.-H.; CHEONG, L.-F. Synergizing spatial and temporal texture. *Image Processing, IEEE Transactions on*, v. 11, n. 10, p. 1179–1191, Oct 2002. ISSN 1057-7149. Citado na página 39.

PERRA, N.; FORTUNATO, S. Spectral centrality measures in complex networks. *Physical Review E, APS*, v. 78, n. 3, p. 036107, 2008. Citado na página 45.

PÉTERI, R.; CHETVERIKOV, D. Dynamic texture recognition using normal flow and texture regularity. In: *Pattern Recognition and Image Analysis. [S.l.]: Springer, 2005. p. 223–230*. Citado na página 39.

PÉTERI, R.; FAZEKAS, S.; HUISKES, M. J. Dyntex: A comprehensive database of dynamic textures. *Pattern Recogn. Lett., Elsevier Science Inc., New York, NY, USA*, v. 31, n. 12, p. 1627–1632, set. 2010. ISSN 0167-8655. Disponível em: <<http://dx.doi.org/10.1016/j.patrec.2010.05.009>>. Citado na página 89.

POLANA, R.; NELSON, R. Motion-based recognition. In: _____. Dordrecht: Springer Netherlands, 1997. cap. Temporal Texture and Activity Recognition, p. 87–124. ISBN 978-94-015-8935-2. Disponível em: <http://dx.doi.org/10.1007/978-94-015-8935-2_5>. Citado na página 39.

_____. Temporal texture and activity recognition. In: SHAH, M.; JAIN, R. (Ed.). *Motion-Based Recognition*. Springer Netherlands, 1997, (Computational Imaging and Vision, v. 9). p. 87–124. ISBN 978-90-481-4870-7. Disponível em: <http://dx.doi.org/10.1007/978-94-015-8935-2_5>. Citado na página 26.

QIAO, Y.; WENG, L. Hidden markov model based dynamic texture classification. *Signal Processing Letters, IEEE*, v. 22, n. 4, p. 509–512, April 2015. ISSN 1070-9908. Citado na página 40.

RAMAMOORTHY, S.; KIRUBAKARAN, R.; SUBRAMANIAN, R. Texture feature extraction using mgrlbp method for medical image classification. *Advances in Intelligent Systems and Computing*, v. 324, p. 747–753, 2015. Cited By 0. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84914695032&partnerID=40&md5=a4348e0330a543a5898b3ffa497df995>>. Citado na página 25.

RAVICHANDRAN, A.; CHAUDHRY, R.; VIDAL, R. View-invariant dynamic texture recognition using a bag of dynamical systems. In: 2009 IEEE Conference on Computer Vision and Pattern Recognition. [S.l.: s.n.], 2009. p. 1651–1657. ISSN 1063-6919. Citado na página 90.

_____. Categorizing dynamic textures using a bag of dynamical systems. Pattern Analysis and Machine Intelligence, IEEE Transactions on, IEEE, v. 35, n. 2, p. 342–353, 2013. Citado 2 vezes nas páginas 26 e 40.

RAVICHANDRAN, A.; VIDAL, R. Video registration using dynamic textures. Pattern Analysis and Machine Intelligence, IEEE Transactions on, v. 33, n. 1, p. 158–171, Jan 2011. ISSN 0162-8828. Citado na página 26.

_____. _____. Pattern Analysis and Machine Intelligence, IEEE Transactions on, v. 33, n. 1, p. 158–171, Jan 2011. ISSN 0162-8828. Citado na página 39.

RIVERA, A. R.; CHAE, O. Spatiotemporal directional number transitional graph for dynamic texture recognition. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 37, n. 10, p. 2146–2152, Oct 2015. ISSN 0162-8828. Citado 2 vezes nas páginas 109 e 110.

RODRIGUES, F. A. Caracterização, classificação e análise de redes complexas. Tese (Doutorado em Física) — Instituto de Física de São Carlos - Universidade de São Paulo, São Carlos, 2007. Citado 3 vezes nas páginas 43, 44 e 46.

SAISAN, P.; DORETTO, G.; WU, Y. N.; SOATTO, S. Dynamic texture recognition. In: Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on. [S.l.: s.n.], 2001. v. 2, p. II–58–II–63 vol.2. ISSN 1063-6919. Citado na página 107.

SILVA, A. C. d.; CABRAL, F. R.; MAMANI, J. B.; MALHEIROS, J. M.; POLLI, R. S.; TANNUS, A.; VIDOTO, E.; MARTINS, M. J.; SIBOV, T. T.; PAVON, L. F. et al. Tumor growth analysis by magnetic resonance imaging of the c6 glioblastoma model with prospects for the assessment of magnetohyperthermia therapy. Einstein (São Paulo), SciELO Brasil, v. 10, n. 1, p. 11–15, 2012. Citado na página 25.

SILVA, M. V. F.; PEREIRA, M. C.; CODARO, E. N.; ACCIARI, H. A. Carbon steel corrosion: an everyday approach for chemistry teaching. Quimica Nova, sciELO, v. 38, p. 293 – 296, 02 2015. ISSN 0100-4042. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-40422015000200293&nrm=iso>. Citado na página 113.

SILVA, N. R. da; BAETENS, J. M.; OLIVEIRA, M. W. da S.; BAETS, B. D.; BRUNO, O. M. Classification of cellular automata through texture analysis. Information Sciences, v. 370–371, p. 33 – 49, 2016. ISSN 0020-0255. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0020025516304881>>. Citado na página 32.

SMITH, J.; LIN, C.-Y.; NAPHADE, M. Video texture indexing using spatio-temporal wavelets. In: Image Processing. 2002. Proceedings. 2002 International Conference on. [S.l.: s.n.], 2002. v. 2, p. II–437–II–440 vol.2. ISSN 1522-4880. Citado na página 41.

SOATTO, S.; DORETTO, G.; WU, Y. N. Dynamic textures. In: IEEE. Computer Vision, 2001. ICCV 2001. Proceedings. Eighth IEEE International Conference on. [S.l.], 2001. v. 2, p. 439–446. Citado na página 26.

SOYGAONKAR, P.; PAYGUDE, S.; VYAS, V. Proceedings of the 3rd international conference on frontiers of intelligent computing: Theory and applications (ficta) 2014: Volume 2. In: _____. Cham: Springer International Publishing, 2015. cap. Dynamic Texture Segmentation Using Texture Descriptors and Optical Flow Techniques, p. 281–288. ISBN 978-3-319-12012-6. Disponível em: <http://dx.doi.org/10.1007/978-3-319-12012-6_31>. Citado na página 39.

SRINIVASAN, G.; SHOBHA, G. Statistical texture analysis. In: Proceedings of world academy of science, engineering and technology. [S.l.: s.n.], 2008. v. 36, p. 1264–1269. Citado na página 32.

SUK, M.; SONG, O. Curvilinear feature extraction using minimum spanning trees. Computer vision, graphics, and image processing, Elsevier, v. 26, n. 3, p. 400–411, 1984. Citado na página 52.

TANG, J.; ZHANG, C.; LUO, B. Shape representation and distance measure based on relational graph. In: IEEE. Hybrid Intelligent Systems, 2006. HIS' 06. Sixth International Conference on. [S.l.], 2006. p. 20–20. Citado na página 52.

TIWARI, D.; TYAGI, V. A novel scheme based on local binary pattern for dynamic texture recognition. Computer Vision and Image Understanding, v. 150, p. 58–65, 2016. Citado 5 vezes nas páginas 42, 108, 109, 110 e 111.

_____. Dynamic texture recognition: a review. In: Information Systems Design and Intelligent Applications. [S.l.]: Springer, 2016. p. 365–373. Citado na página 41.

_____. Dynamic texture recognition based on completed volume local binary pattern. Multidimensional Systems and Signal Processing, v. 27, n. 2, p. 563–575, 2016. ISSN 1573-0824. Disponível em: <<http://dx.doi.org/10.1007/s11045-015-0319-6>>. Citado 6 vezes nas páginas 26, 35, 42, 108, 109 e 110.

_____. Improved weber's law based local binary pattern for dynamic texture recognition. Multimedia Tools and Applications, p. 1–18, 2016. ISSN 1573-7721. Disponível em: <<http://dx.doi.org/10.1007/s11042-016-3362-x>>. Citado 4 vezes nas páginas 42, 108, 109 e 110.

TIWARI, R. D.; TYAGI, V. ARTICLE IN PRESS Dynamic texture recognition using multiresolution and edge-weighted local structure pattern. 2016. Citado 4 vezes nas páginas 42, 108, 109 e 110.

TOMITA, F.; TSUJI, S. Computer Analysis of Visual Textures. Norwell, MA, USA: Kluwer Academic Publishers, 1990. ISBN 0792391144. Citado na página 36.

TOREYIN, B. U.; CETIN, A. E. Hmm based method for dynamic texture detection. In: IEEE. Signal Processing and Communications Applications, 2007. SIU 2007. IEEE 15th. [S.l.], 2007. p. 1–5. Citado na página 40.

TUCERYAN, M.; JAIN, A. K. Texture analysis. The handbook of pattern recognition and computer vision, v. 2, p. 207–248, 1998. Citado na página 25.

TUCERYAN, M.; JAIN, A. K. et al. Texture analysis. Handbook of pattern recognition and computer vision, v. 2, p. 235–276, 1993. Citado na página 31.

UNSER, M. Texture classification and segmentation using wavelet frames. *IEEE Transactions on Image Processing*, v. 4, n. 11, p. 1549–1560, 1995. Cited By 949. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-0029409269&partnerID=40&md5=352fd52fc7ebce84e824b64e1640c849>>. Citado na página 37.

VOORHEES, H.; POGGIO, T. Detecting textons and texture boundaries in natural images. *Proceedings of the First International Conference on Computer Vision*, London, p. 250–258, 1987. Citado na página 36.

WANG, L.; LIU, H.; SUN, F. Dynamic texture video classification using extreme learning machine. *Neurocomputing*, v. 174, Part A, p. 278–285, 2016. ISSN 0925-2312. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231215011480>>. Citado na página 40.

WANG, Y.; HU, S. Exploiting high level feature for dynamic textures recognition. *Neurocomputing*, Elsevier, v. 154, p. 217–224, 2015. Citado 5 vezes nas páginas 26, 40, 109, 110 e 111.

_____. Chaotic features for dynamic textures recognition. *Soft Computing*, Springer, v. 20, n. 5, p. 1977–1989, 2016. Citado 4 vezes nas páginas 26, 40, 109 e 110.

WASSERMAN, S.; FAUST, K. *Social network analysis: Methods and applications*. [S.l.]: Cambridge university press, 1994. v. 8. Citado na página 44.

WATTS, D. J.; STROGATZ, S. H. Collective dynamics of small-world networks. *nature*, Nature Publishing Group, v. 393, n. 6684, p. 440–442, 1998. Citado 3 vezes nas páginas 44, 46 e 49.

WECHSLER, H. Texture analysis—a survey. *Signal Processing*, Elsevier, v. 2, n. 3, p. 271–282, 1980. Citado na página 32.

WILDES, R. P.; BERGEN, J. R. Computer vision — eccv 2000: 6th european conference on computer vision dublin, ireland, june 26–july 1, 2000 proceedings, part ii. In: _____. Berlin, Heidelberg: Springer Berlin Heidelberg, 2000. cap. Qualitative Spatiotemporal Analysis Using an Oriented Energy Representation, p. 768–784. ISBN 978-3-540-45053-5. Disponível em: <http://dx.doi.org/10.1007/3-540-45053-X_49>. Citado na página 41.

WOLFRAM, S. Universality and complexity in cellular automata. *Physica D: Nonlinear Phenomena*, Elsevier, v. 10, n. 1, p. 1–35, 1984. Citado na página 32.

WU, P.; RO, Y. M.; WON, C. S.; CHOI, Y. Computer analysis of images and patterns: 9th international conference, caip 2001 warsaw, poland, september 5–7, 2001 proceedings. In: _____. Berlin, Heidelberg: Springer Berlin Heidelberg, 2001. cap. Texture Descriptors in MPEG-7, p. 21–28. ISBN 978-3-540-44692-7. Disponível em: <http://dx.doi.org/10.1007/3-540-44692-3_4>. Citado na página 41.

WU, P.-H.; PHILLIP, J.; KHATAU, S.; CHEN, W.-C.; STIRMAN, J.; ROSSEEL, S.; TSCHUDI, K.; PATTEN, J. V.; WONG, M.; GUPTA, S.; BARAS, A.; LEEK, J.; MAITRA, A.; WIRTZ, D. Evolution of cellular morpho-phenotypes in cancer metastasis. *Scientific Reports*, v. 5, 2015. Cited By 0. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84950240054&partnerID=40&md5=af3acda836c57925d1b13730dbfacac2>>. Citado na página 25.

- XIA, G.-S.; FERRADANS, S.; PEYRÉ, G.; AUJOL, J.-F. Synthesizing and mixing stationary gaussian texture models. *SIAM Journal on Imaging Sciences*, v. 7, n. 1, p. 476–508, 2014. Cited By 5. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84897497789&partnerID=40&md5=b07de7b429032b6b377170670d63c948>>. Citado na página 35.
- XU, Y.; HUANG, S.; JI, H.; FERMÜLLER, C. Scale-space texture description on sift-like textons. *Computer Vision and Image Understanding*, Elsevier, v. 116, n. 9, p. 999–1013, 2012. Citado 4 vezes nas páginas 40, 108, 109 e 110.
- XU, Y.; JI, H.; FERMÜLLER, C. Viewpoint invariant texture description using fractal analysis. *International Journal of Computer Vision*, Springer, v. 83, n. 1, p. 85–100, 2009. Citado na página 37.
- XU, Y.; QUAN, Y.; LING, H.; JI, H. Dynamic texture classification using dynamic fractal analysis. In: 2011 International Conference on Computer Vision. [S.l.: s.n.], 2011. p. 1219–1226. ISSN 1550-5499. Citado 4 vezes nas páginas 26, 35, 37 e 108.
- XU, Y.; UBERBACHER, E. C. 2d image segmentation using minimum spanning trees. *Image and Vision Computing*, Elsevier, v. 15, n. 1, p. 47–57, 1997. Citado na página 52.
- YANG, F.; XIA, G.-S.; LIU, G.; ZHANG, L.; HUANG, X. Dynamic texture recognition by aggregating spatial and temporal features via ensemble {SVMs}. *Neurocomputing*, v. 173, Part 3, p. 1310 – 1321, 2016. ISSN 0925-2312. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231215013119>>. Citado na página 40.
- ZHANG, H. P.; BE'ER, A.; FLORIN, E.-L.; SWINNEY, H. L. Collective motion and density fluctuations in bacterial colonies. *Proceedings of the National Academy of Sciences*, v. 107, n. 31, p. 13626–13630, 2010. Disponível em: <<http://www.pnas.org/content/107/31/13626.abstract>>. Citado na página 25.
- ZHAO, G.; AHONEN, T.; MATAS, J.; PIETIKAINEN, M. Rotation-invariant image and video description with local binary pattern features. *IEEE Transactions on Image Processing*, IEEE, v. 21, n. 4, p. 1465–1477, 2012. Citado na página 41.
- ZHAO, G.; PIETIKAINEN, M. Dynamic texture recognition using local binary patterns with an application to facial expressions. *Pattern Analysis and Machine Intelligence*, *IEEE Transactions on*, v. 29, n. 6, p. 915–928, June 2007. ISSN 0162-8828. Citado na página 26.
- _____. _____. *Pattern Analysis and Machine Intelligence*, *IEEE Transactions on*, v. 29, n. 6, p. 915–928, June 2007. ISSN 0162-8828. Citado 8 vezes nas páginas 26, 38, 41, 80, 108, 109, 110 e 111.
- ZHAO, G.; PIETIKÄINEN, M. Dynamical vision: lccv 2005 and eccv 2006 workshops, wdv 2005 and wdv 2006, beijing, china, october 21, 2005, graz, austria, may 13, 2006. revised papers. In: _____. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. cap. Dynamic Texture Recognition Using Volume Local Binary Patterns, p. 165–177. ISBN 978-3-540-70932-9. Disponível em: <http://dx.doi.org/10.1007/978-3-540-70932-9_13>. Citado 4 vezes nas páginas 41, 108, 109 e 110.
- ZHAO, H.; KONG, M.; LUO, B. Shape representation based on polar-graph spectra. In: *Intelligent Computing in Signal Processing and Pattern Recognition*. [S.l.]: Springer, 2006. p. 900–905. Citado na página 52.

ZHAO, Y.; ZHAO, J.; DONG, E.; CHEN, B.; CHEN, J.; YUAN, Z.; ZHANG, D. Artificial intelligence and computational intelligence: Third international conference, aici 2011, taiyuan, china, september 24-25, 2011, proceedings, part iii. In: _____. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. cap. Dynamic Texture Modeling Applied on Computer Vision Based Fire Recognition, p. 545–553. ISBN 978-3-642-23896-3. Disponível em: <http://dx.doi.org/10.1007/978-3-642-23896-3_67>. Citado na página 39.

ZHONG, H.; SHI, J.; VISONTAI, M. Detecting unusual activity in video. In: IEEE. Computer Vision and Pattern Recognition, 2004. CVPR 2004. Proceedings of the 2004 IEEE Computer Society Conference on. [S.l.], 2004. v. 2, p. II–819. Citado na página 26.

ZHONG, J.; SCARLAROFF, S. Temporal texture recognition model using 3d features. Technical report, MIT Media Lab Perceptual Computing, Technical Report, 2002. Citado na página 40.

ZHOU, D. Texture Analysis and Synthesis Using a Generic Markov-Gibbs Image Model. Computer Science)–University of Auckland, 2006. Disponível em: <<https://books.google.com.br/books?id=shR8NwAACAAJ>>. Citado 3 vezes nas páginas 31, 32 e 35.

ZHU, C.; YANG, X. Study of remote sensing image texture analysis and classification using wavelet. International Journal of Remote Sensing, Taylor & Francis, v. 19, n. 16, p. 3197–3203, 1998. Citado na página 25.

ZIMER, A. M.; RIOS, E. C.; MENDES, P. de C. D.; GONÇALVES, W. N.; BRUNO, O. M.; PEREIRA, E. C.; MASCARO, L. H. Investigation of { AISI } 1040 steel corrosion in { H₂S } solution containing chloride ions by digital image processing coupled with electrochemical techniques. Corrosion Science, v. 53, n. 10, p. 3193 – 3201, 2011. ISSN 0010-938X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0010938X11002952>>. Citado na página 26.

ZUCKER, S. Toward a model of texture. Computer Graphics and Image Processing, v. 5, n. 2, p. 190–202, 1976. Cited By 51. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-0016964586&partnerID=40&md5=7dfe9c4841cbf0c0025f68fb2408be9b>>. Citado na página 36.