



Universidade Estadual de Campinas
Instituto de Computação



Elisangela Silva dos Santos

Abordagens para Busca de Séries Temporais
Representadas por Imagens de Recorrência

CAMPINAS
2019

Elisangela Silva dos Santos

**Abordagens para Busca de Séries Temporais Representadas por
Imagens de Recorrência**

Dissertação apresentada ao Instituto de Computação da Universidade Estadual de Campinas como parte dos requisitos para a obtenção do título de Mestra em Ciência da Computação.

Orientador: Prof. Dr. Ricardo Da Silva Torres

Este exemplar corresponde à versão final da Dissertação defendida por Elisangela Silva dos Santos e orientada pelo Prof. Dr. Ricardo Da Silva Torres.

CAMPINAS
2019

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca do Instituto de Matemática, Estatística e Computação Científica
Ana Regina Machado - CRB 8/5467

Santos, Elisangela Silva dos, 1986-
Sa59a Abordagens para busca de séries temporais representadas por imagens de
recorrência / Elisangela Silva dos Santos. – Campinas, SP : [s.n.], 2019.

Orientador: Ricardo da Silva Torres.
Dissertação (mestrado) – Universidade Estadual de Campinas, Instituto de
Computação.

1. Séries temporais. 2. Gráfico de recorrência. 3. Recuperação da
informação. 4. Fenologia. 5. Busca de séries temporais. I. Torres, Ricardo da
Silva, 1977-. II. Universidade Estadual de Campinas. Instituto de Computação.
III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Time series approaches represented by recurrence images

Palavras-chave em inglês:

Time series

Recurrence plot

Information retrieval

Phenology

Time series search

Área de concentração: Ciência da Computação

Títuloção: Mestra em Ciência da Computação

Banca examinadora:

Ricardo da Silva Torres [Orientador]

Luiz Camolesi Junior

Julio César dos Reis

Data de defesa: 11-07-2019

Programa de Pós-Graduação: Ciência da Computação

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: <https://orcid.org/0000-0002-8922-6318>

- Currículo Lattes do autor: <http://lattes.cnpq.br/9500745507945796>



Universidade Estadual de Campinas
Instituto de Computação



Elisangela Silva dos Santos

Abordagens para Busca de Séries Temporais Representadas por Imagens de Recorrência

Banca Examinadora:

- Prof. Dr. Ricardo da Silva Torres
Instituto de Computação - UNICAMP
- Prof. Dr. Luiz Camolesi Júnior
Faculdade de Tecnologia - UNICAMP
- Prof. Dr. Julio Cesar dos Reis
Instituto de Computação - UNICAMP

A ata da defesa, assinada pelos membros da Comissão Examinadora, consta no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

Campinas, 11 de julho de 2019

Agradecimentos

Sou grata a Deus acima de tudo, meu ponto de equilíbrio, minha fonte energia e meu protetor que me conduziu durante toda esta caminhada.

Aos meus pais Regina e Cristovão(In memoriam), e meu irmão que sempre me incentivaram e apoiaram nos momentos de indecisões e escolhas de novos caminhos, permitindo que eu pudesse continuar meus estudos.

Agradeço ao meu orientador, Prof. Ricardo da Silva Torres, por ser o grande guia, responsável por esse trabalho que estou concluindo. As indicações, as dicas, as correções, e até mesmo alguns desencontros que passaram por esta relação entre orientador-orientando. Tudo isto compõe uma somatória fundamental não só para a construção do trabalho entregue, mas também para a maturidade/crescimento de toda uma vida a seguir. Sou grata por tudo!

Agradeço aos companheiros integrantes do laboratório RECOD pelo companheirismo, brincadeiras e interação que tornaram o ambiente mais estimulante e produtivo.

Também agradeço aos funcionários do Instituto da computação que contribuíram direta e indiretamente para a conclusão deste trabalho.

Este trabalho contou com o apoio do CNPq, FAPESP (#2014/12236-1, #2015/24494-8, #2016/50250-1, e #2017/20945-0) e o Instituto Virtual FAPESP-Microsoft (#2013/50155-0, #2013/50169-1, and #2014/50715-9). O presente trabalho foi realizado também com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Resumo

A representação de imagens por meio de assinatura textual tem apresentado bons resultados em tarefas de recuperação de informação. A assinatura textual consegue sumarizar as principais características de uma imagem em uma representação. Os vetores de características são organizados em estrutura de dados que permitem sua indexação, tornando mais ágil o processamento das consultas. O apoio a buscas de séries temporais pode ser crucial em vários domínios, nos quais a análise de séries temporais longas com base na identificação de padrões similares e diferentes é uma tarefa amplamente comum. Neste trabalho, nós apresentamos um novo método de busca que utiliza uma técnica da extração assinatura textual como abordagem para representação de séries temporais. O método combina dois componentes principais: a representação da série a partir de assinaturas textuais extraídas de uma imagem de recorrência; e a recuperação de séries a partir de índice textuais. A solução compreende quatro etapas principais: representação da série temporal em uma imagem; caracterização do conteúdo da imagem por meio de uma descrição baseada em histograma que extrai propriedades e padrões das séries; mapeamento das propriedades e padrões extraídos para uma assinatura textual; e indexação de assinaturas textuais usando tecnologias de Recuperação de Informação (RI) bem estabelecidas. Neste trabalho, demonstramos tanto a eficácia quanto a eficiência da solução apresentada em problemas de recuperação de séries temporais relacionados ao gerenciamento de dados fenológicos associados a imagens de vegetação próxima à superfície. Nosso método conseguiu superar métodos da literatura, demonstrando bom desempenho tanto em termos de eficiência quanto de eficácia.

Abstract

The representation of images through textual signatures have been leading to effective results in search tasks. Textual signatures can summarize key features of an image into a representation. Feature vectors are organized into data structures that allow them to be indexed, making query processing faster. Time series searches can be crucial in many domains, where time series analysis based on the identification of similar and different patterns is a widely common task. In this work, we present a new search method that uses a textual signature extraction technique for time series representation. The method combines two components: the representation of time series series by means of textual signatures extracted from recurrence images; and the search of time series through textual indices. The solution consists of four main steps: representation of time series into an image; characterization of the image content through a histogram-based description that extracts properties and patterns from the input time series; mapping of properties and patterns to a textual signature; and indexing of textual signatures using well-established information retrieval (IR) technologies. In this work, we demonstrate both the effectiveness and the efficiency of the solution presented in time series retrieval problems related to the management of phenological data associated with time series of near-surface vegetation images. Experimental results show that our method was able to overcome baselines, yielding promising results in terms of both efficiency and effectiveness.

Sumário

1	Introdução	10
1.1	Considerações Iniciais	10
1.2	Motivação	11
1.3	Objetivos do Trabalho	12
1.4	Organização	12
2	Fundamentação Teórica e Trabalhos Relacionados	14
2.1	Considerações Iniciais	14
2.2	Séries temporais	14
2.3	<i>Recurrence Plot</i>	15
2.3.1	Recorrência	15
2.3.2	Cálculo de <i>Recurrence Plot</i>	16
2.4	Descritores	18
2.4.1	<i>Histogram of Oriented Gradients (HOG)</i>	19
2.4.2	<i>Local Binary Patterns (LBP)</i>	24
2.5	Obtenção de Assinaturas Textuais de Imagens: Método S-BoVW	26
2.6	Busca de séries temporais	30
2.6.1	Representação de séries temporais	30
2.6.2	Indexação	31
2.7	Considerações Finais	32
3	Sistema de Busca Proposto	33
3.1	Considerações Iniciais	33
3.2	Extração de Assinaturas Textuais de Séries Temporais	33
3.3	Busca de Séries Temporais a partir de Assinaturas Textuais	37
3.4	Aspectos de Implementação	39
3.5	Considerações Finais	41
4	Avaliação Experimental	42
4.1	Considerações Iniciais	42
4.2	Protocolo Experimental	42
4.2.1	Base de Dados de Séries Temporais de Fenologia	42
4.2.2	Critérios de Avaliação	44
4.2.3	Protocolo de Comparação	44
4.2.4	Baselines	45
4.3	Resultados Experimentais e Análise	45
4.3.1	Seleção de Parametros para HOG e LBP	45
4.3.2	Comparação com <i>Baselines</i>	48
4.3.2.1	Avaliação da Eficácia	48

4.3.3	Avaliação da Eficiência	52
4.3.4	Discussão	52
4.4	Considerações Finais	53
5	Conclusão	54
5.1	Considerações Finais	54
5.2	Principais Contribuições	55
5.3	Trabalhos Futuros	55
	Referências Bibliográficas	57

Capítulo 1

Introdução

1.1 Considerações Iniciais

Uma série temporal é uma sequência de medidas de alguma variável ao longo do tempo, ou seja, uma coleção de observações feitas cronologicamente [26]. Exemplos incluem a sequência de valores de cotação do dólar a cada dia do mês ou o índice de pluviosidade de uma região em um mês. A análise de uma série temporal ajuda a compreender as mudanças de seus valores ao decorrer do tempo. As séries temporais são usadas para resolver problemas de diversas áreas como biologia, economia, finanças e mercado de ações, etc. No contexto destas aplicações, grandes volumes de séries temporais vêm sendo gerados, demandando a criação de sistemas eficientes e eficazes para o seu gerenciamento.

O uso crescente de dados de séries temporais possibilitou o surgimento de uma grande quantidade de tentativas de pesquisa e o desenvolvimento no campo da mineração de dados [9, 12, 26]. No contexto da mineração de dados de séries temporais, o problema fundamental é como representar os dados da série temporal [12, 26]. Uma das abordagens comuns é transformar a série temporal em outro domínio para redução de dimensionalidade seguida de um mecanismo de indexação. Além disso, a definição de uma medida de similaridade entre séries temporais constitui etapa importante de tarefas de mineração de dados. Diferentes tarefas de mineração podem ser encontradas na literatura e podem ser classificadas em quatro campos: classificação, agrupamento e descoberta de padrões frequentes, descoberta de regras e sumarização. Algumas das pesquisas se concentram em um desses campos, enquanto os outros podem se concentrar em mais de um dos processos acima.

Problemas típicos relacionados ao gerenciamento de séries temporais incluem: volume grande de dados, alta dimensionalidade e atualização contínua [26]. Além disso, os dados de séries temporais, que são caracterizados pela sua natureza numérica e contínua, são sempre considerados como um todo, em vez de um campo numérico individual. Portanto, ao contrário de bancos de dados tradicionais, em que a busca por similaridade é baseada em correspondência exata, a busca por similaridade em dados de série temporal geralmente é realizada de maneira aproximada [26].

Em especial, para lidar com a questão de recuperação em grandes volumes de dados de séries temporais, é necessário o uso de descritores eficazes que sejam capazes de caracterizar de forma apropriada séries temporais e o uso de estrutura de dados eficientes que

permitam a execução de consultas com tempo de processamento reduzido. A eficiência está associada à realização de operações utilizando-se de menos recursos computacionais ou com menos tempo, enquanto a eficácia consiste em possibilitar que resultados relevantes sejam retornados pelo sistema de busca.

No nosso caso, trabalhamos com o desafio de permitir a realização de buscas que sejam ao mesmo tempo eficientes e eficazes em grandes coleções de séries temporais. Uma busca eficiente e eficaz está relacionada diretamente com o uso dos índices, protocolos de recuperação textual e de descritores que permitam extrair boas assinaturas. Existem soluções existentes que tratam do problema da eficiência e eficácia separadamente. Por exemplo, no trabalho de [13], o autor trata de descritores eficazes para a extração de features de séries temporais. Em [19], a autora usa índices eficientes para processamento de consulta. Na literatura poucos trabalhos lidam com os dois aspectos ao mesmo tempo.

1.2 Motivação

A busca por série temporal é uma tarefa de muito interesse em várias áreas e aplicações, pois permite a recuperação de outras séries que tenham os mesmos (ou similares) padrões. Na busca de séries temporais, o usuário define uma série como consulta e o sistema de busca retorna um conjunto de séries que são ranqueadas de acordo com a semelhança (padrão) que elas possuem com a consulta. Buscas de séries temporais não utilizam correspondência exata, como correspondência de duas *strings*. Usualmente, é preciso usar uma função de distância ou de similaridade para comparar séries. Um dos desafios de fazer isso é que nem sempre é possível indexar facilmente os dados de uma série temporal longa, ou seja, em várias aplicações, é preciso extrair as características mais representativas para então se construir um índice.

A fenologia vegetal é área que estuda eventos recorrentes do ciclo de vida das plantas e é um componente principal para a compreensão do impacto das mudanças climáticas em plantas. Estudos nessa área tipicamente estão associados à análise de mudanças das plantas ao longo tempo. Boa parte destes estudos é baseada no uso e análise de séries temporais. Em fenologia, a análise de séries temporais longas com base na identificação de padrões similares e diferentes é uma tarefa muito comum, mas difícil. A motivação do nosso trabalho é apoiar a busca de séries temporais no contexto da fenologia, em especial em tarefas de reconhecimento de plantas. Nesta dissertação, trabalharemos com uma coleção de séries temporais relacionadas a índices de vegetação [3]. Os esquema de extração de séries para a coleção funciona da seguinte forma: a partir de uma imagem de vegetação, são definidas várias regiões de interesse (usualmente, cada região de interesse está associada a um indivíduo de uma espécie de planta). Para cada uma dessas regiões, são extraídas séries temporais que representam índices de vegetação. A solução proposta permite buscas nesta coleção de séries temporais de índices de vegetação com o objetivo de apoiar a identificação de plantas que sejam da mesma espécie, a partir de padrões de séries temporais. Outra aplicação consiste na busca de regiões da imagem, que tenha plantas que funcionem fenologicamente de forma similar, isto é, não necessariamente são da mesma espécie.

1.3 Objetivos do Trabalho

O foco do nosso trabalho é propor um sistema integrado, eficiente e eficaz, para representação, indexação e busca de séries temporais. No nosso sistema, nós sugerimos que a eficácia seja obtida a partir da utilização de novas representações baseadas em *Recurrence plot* (RP). *Recurrence plot* é uma técnica usada para representar séries temporais e tem por objetivo facilitar a extração de informações e descoberta de padrões a partir da análise da recorrência de uma série a determinados estados [13]. O uso de representações baseadas em RPs é motivada pelos resultados recentes associados ao uso destas representações em problemas de busca e classificação de séries temporais [23, 24, 41]. A solução da eficiência consiste no uso de técnicas de Recuperação da informação (RI) usada para indexar assinaturas associadas às imagens de RP. A construção de sistemas de busca de séries temporais, que tiram vantagem do uso de abordagens de indexação e recuperação tipicamente empregados na busca de documentos textuais, se justifica pela maturidade, abrangência, e escalabilidade de soluções existentes.

Além disso, o desenvolvimento desta pesquisa teve outros objetivos específicos como: investigar o uso do método de extração da assinatura textual para a recuperação de séries temporais em grandes coleções de dados, testar o uso de descritores de textura para caracterização de representações de séries temporais e o uso de diferentes algoritmos de indexação na etapa de armazenamento. Para isso, as seguintes etapas foram necessárias:

1. Realizar uma comparação experimental de diferentes descrições de imagens, visando à caracterização de representações em RP de séries temporais.
2. Definir uma configuração adequada para a resolução do problema, incluindo a configuração dos seguintes parâmetros associados à caracterização de imagens de RP, a partir de assinaturas: tipo de particionamento, número de blocos, limiar e função de similaridade.

Em resumo, a pesquisa foi voltada à comparação de diversos descritores e investigação do seu uso como função de mapeamento no método de extração de assinaturas textuais, para verificarmos quais apresentam melhores resultados. Também foi incluída na pesquisa a busca pela combinação mais adequada dos parâmetros do método para a extração da assinatura textual de séries temporais. No decorrer da pesquisa, realizaram-se experimentos visando avaliar a eficácia dos descritores utilizados, e a eficiência da estrutura de indexação utilizada.

1.4 Organização

Esta dissertação de mestrado está organizada da seguinte forma: no Capítulo 2, são apresentados conceitos e fundamentos considerados relevantes para o entendimento deste trabalho e soluções propostas na literatura que estão relacionadas aos objetivos deste trabalho; no Capítulo 3, é apresentado o sistema de busca proposto; no Capítulo 4, apresentamos a metodologia utilizada para a validação do sistema de busca proposto;

por fim, o Capítulo 5 apresenta as conclusões do trabalho, assim como aponta possíveis trabalhos futuros.

Capítulo 2

Fundamentação Teórica e Trabalhos Relacionados

2.1 Considerações Iniciais

Este capítulo apresenta conceitos fundamentais considerados importantes para o entendimento do trabalho, assim como soluções propostas na literatura consideradas relevantes e relacionadas aos objetivos deste trabalho.

2.2 Séries temporais

Segundo [8], uma série temporal é uma coleção de observações feitas sequencialmente no tempo. Séries temporais são geradas e são objeto de estudo nas mais diversas áreas. Alguns exemplos incluem: séries temporais associadas a sinais fisiológicos (por exemplo, sinais de eletroencefalografia – EEG – para registrar atividades elétricas do cérebro em segundos sucessivos); associadas a variáveis de interesse no mercado financeiro (por exemplo, preço de fechamento das ações em meses sucessivos); associadas a meteorologia (por exemplo, valores da temperatura mínima de uma cidade em anos sucessivos); associadas ao comportamento fenológico de plantas e animais (por exemplo, mudanças no crescimento de uma planta em meses sucessivos, mudanças no comportamento de uma planta em determinada hora do dia) – ilustrada na Figura 2.1.

A análise de séries temporais é fundamental em várias aplicações, principalmente aquelas voltadas ao estudo e entendimento de mudanças de variáveis de interesse ao longo do tempo. Estudos típicos incluem [9, 11, 13] análise de correlação entre variáveis, predição de valores de séries no futuro a partir de histórico de comportamento, e busca de séries temporais com padrões de interesse similares a uma dada consulta. O foco deste trabalho é na criação de sistemas de busca de séries temporais.

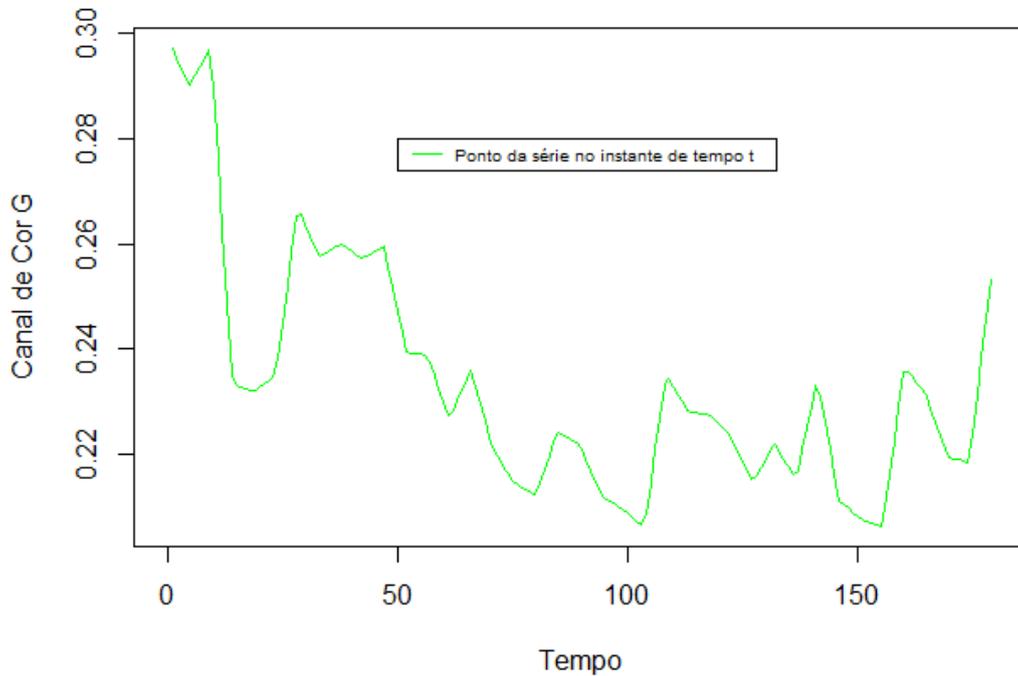


Figura 2.1: Exemplo de série temporal na área de Fenologia: variação da intensidade do canal de cor G ao longo de dias.

2.3 *Recurrence Plot*

Nós exploramos uma representação simbólica de séries temporais, mas, diferente de iniciativas anteriores, calculamos essa representação com base em padrões de séries temporais complexos codificados em representações de imagens de *Recurrence Plot* (RP). Representações baseadas em RP foram usadas antes em problemas de classificação de séries temporais [55], mesmo no contexto de estudos de fenologia [23, 24], domínio de validação considerado em nosso trabalho (ver Capítulo 4). Esta seção apresenta conceitos associados a recorrência e representações típicas associadas.

2.3.1 *Recorrência*

A recorrência é uma característica do que é recorrente, do que retorna, e se repete. A recorrência é uma propriedade fundamental de sistemas dinâmicos, que são sistemas físicos que evoluem no tempo. Geralmente são sistemas com comportamentos complexos não-lineares.

O conhecimento da existência da recorrência já vem de longa data, e foi inicialmente estudado por *Poincaré*, no seu estudo do problema dos três corpos [18, 39, 47]. De uma forma simplista, o Teorema de Recorrência de *Poincaré* afirma que, depois de um certo tempo, certos sistemas irão retornar a um estado muito próximo ao estado inicial. Dessa forma, o tempo de recorrência de *Poincaré* é o tempo decorrido até a recorrência de um

certo estado [6]. Segundo [18, 39], a recorrência na análise de séries temporais é quando um estado x_i em um tempo $t = i$ é similar ao estado do sistema x_j em outro tempo $t = j$. Ou seja, o valor de x é similar a esse estado inicial ou muito próximo. Um estado x_i qualquer é dito recorrente se, durante a trajetória do sistema, um novo estado x_j ($i \neq j$) estiver muito próximo, ou igual de x_i no espaço de fase.

2.3.2 Cálculo de Recurrence Plot

Seguindo a idéia de Poincaré [47], Eckman et al. [22] criaram a representação chamada *Recurrence Plot* – RPs ou gráfico de recorrência, que são gráficos usados para visualizar a recorrência de sistemas dinâmicos.

O gráfico de recorrência de uma série temporal de N pontos é uma matriz binária de tamanho $N \times N$. A partir desta matriz binária, ou matriz de recorrência R , um ponto recorrente é definido como $R_{i,j} = 1$, se o estado x_i for vizinho de x_j no espaço de fases, caso contrário, $R_{i,j} = 0$. Um estado x_i qualquer é dito recorrente se, durante a trajetória do sistema, o estado x_j estiver próximo o bastante de x_i no espaço de fases respeitando um limiar ε [18, 22, 54]. A definição de recorrência pode ser formulada da seguinte forma:

$$R_{i,j}(\varepsilon) = \Theta(\varepsilon - \|\vec{x}_i - \vec{x}_j\|), \vec{x}_{i,j} \in \mathfrak{R}^m, i, j = 1, \dots, N \quad (2.1)$$

em que N é o tamanho da série temporal x_i , ε_i é o limiar, $\|\cdot\|$ é o norma da vizinhança (por exemplo, norma Euclidiana), m é a dimensão de imersão, and $\Theta(\cdot)$ é a função de Heaviside, definida pela Equação 2.2

$$\Theta(z) = 0 \text{ se } z < 0, \text{ e } 1 \text{ caso contrário} \quad (2.2)$$

A Figura 2.2 ilustra o processo de obtenção de uma representação RP. Visualmente na Figura 2.2(a), podemos observar que os pontos \vec{x}_7 , \vec{x}_8 e \vec{x}_9 são similares aos pontos \vec{x}_2 , \vec{x}_3 e \vec{x}_4 (ilustrados na Figura 2.2(b)). Logo, ao preencher a matriz de recorrência para esses pontos, teremos o resultado ilustrado na Figura 2.2(c). Vale observar que a diagonal da matriz sempre será preenchida por zero uma vez que diz respeito à distância de um ponto pra ele mesmo, o que sempre será menor que qualquer *threshold* definido [13].

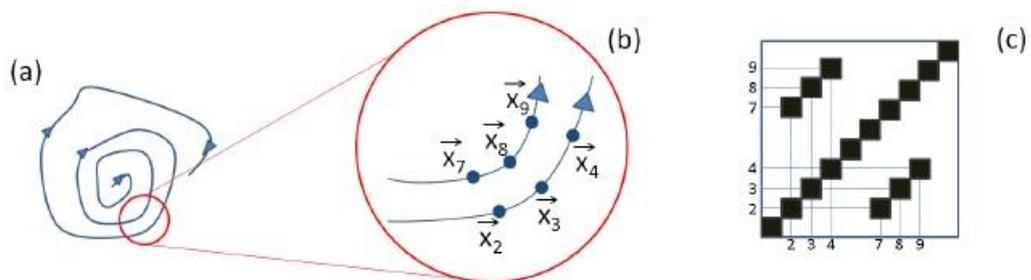
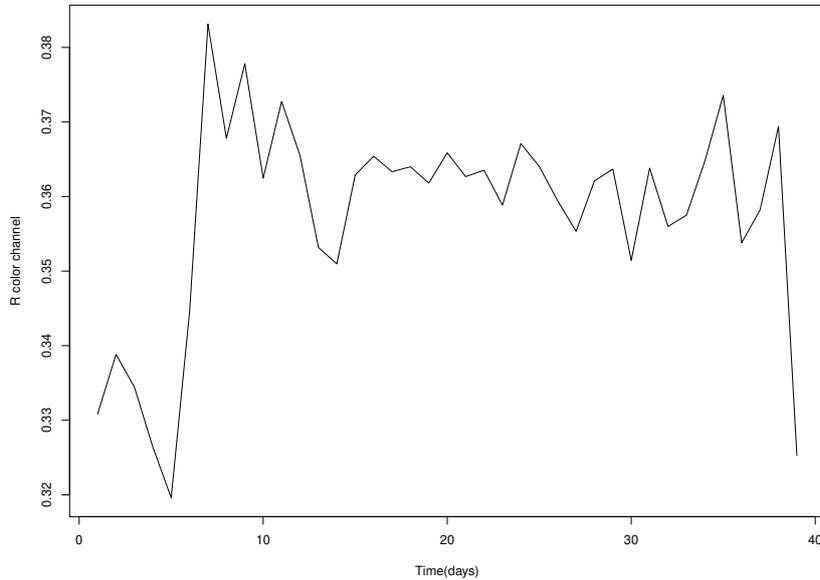


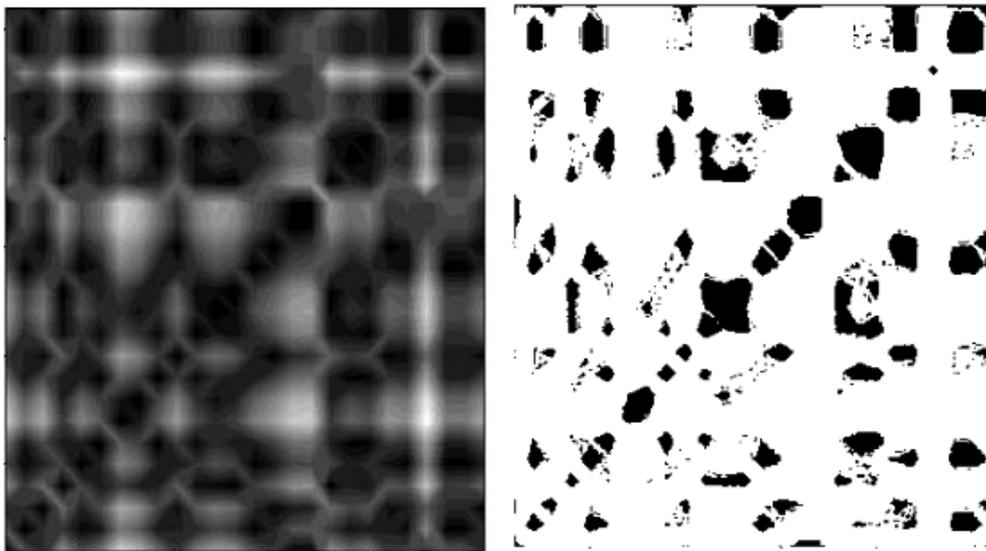
Figura 2.2: Processo de obtenção de uma representação RP (figura adaptada de [13]).

A matriz $R_{i,j}$ pode ser vista como uma imagem quadrada (de dimensão $N \times N$), geralmente conhecida como imagem de gráfico de recorrência, que codifica informações temporais complexas. Essa imagem pode ser binária ou em escala de cinza, dependendo

do uso de um *threshold* aplicado à matriz de distância. A Figura 2.3 mostra uma série temporal em tempo real a partir do conjunto de dados e dois exemplos de gráfico de recorrência ou *Recurrence Plot* considerando essas séries em tempo real para os casos de escala de cinza (Figura 2.3(b)) e binária (Figura 2.3(c)).



(a)



(b)

(c)

Figura 2.3: (a) Série temporal. (b) Exemplo de imagem RP em nível de cinza associada à série em (a). (c) Exemplo de imagem RP binária, obtida com $\Theta(\cdot) < 20$, $N = 37$, e $m = 1$.

A escolha da técnica de Recurrence Plot foi motivado pelo tratamento de dados fenológicos, domínio alvo da pesquisa. Outras técnicas de representações baseadas em imagens poderiam ser utilizadas, mas nós escolhemos a técnica de recurrence Plot (RP), por dois

principais motivos: pela sua simplicidade; e também pelo fato que a análise fenológica é tipicamente baseada no estudo de eventos cíclicos, se encaixando perfeitamente no uso do RP.

2.4 Descritores

A extração de *features* a partir do uso de descritores é a base da recuperação da informação, ou seja, o descritor de um objeto é um dos principais componentes de um sistema de recuperação da informação. Um descritor é responsável por representar objetos como pontos de um espaço n -dimensional. Estes pontos podem ser usados em seguida para determinar a similaridade entre os objetos, comumente definida a partir da proximidade de seus pontos no espaço de característica. Dois objetos são similares entre si, se a distância entre seus pontos (suas representações) for pequena. Quanto menor a distancia, maior é a similaridade.

Particularmente para o caso de imagens, um descritor é definido como uma tupla (ϵ_d, δ_d) [14], em que: ϵ_d é a função responsável por caracterizar o conteúdo visual de uma imagem e codificá-lo em um vetor de características, e δ_d é uma função responsável por comparar dois vetores de características. Dados dois vetores, essa função calcula um *score* que define a similaridade ou a distância entre duas imagens. A Figura 2.4 mostra o fluxo da extração de características e de realização de buscas de imagens. A extração de características é feita para cada imagem da coleção, usando a função ϵ_d . Como resultado, temos vetores que codificam características visuais (cor, forma e/ou textura) da imagem. Quando uma consulta é definida, o processo de extração é realizado sobre a imagem de consulta e um vetor de característica é gerado. Esse vetor é comparado com os vetores de características que foram gerados para as imagens da coleção. Como resultado desse processo de busca, cada imagem da coleção é colocada em uma lista ordenada (*ranked list*) de acordo com seu grau de similaridade com relação à imagem de consulta [19].

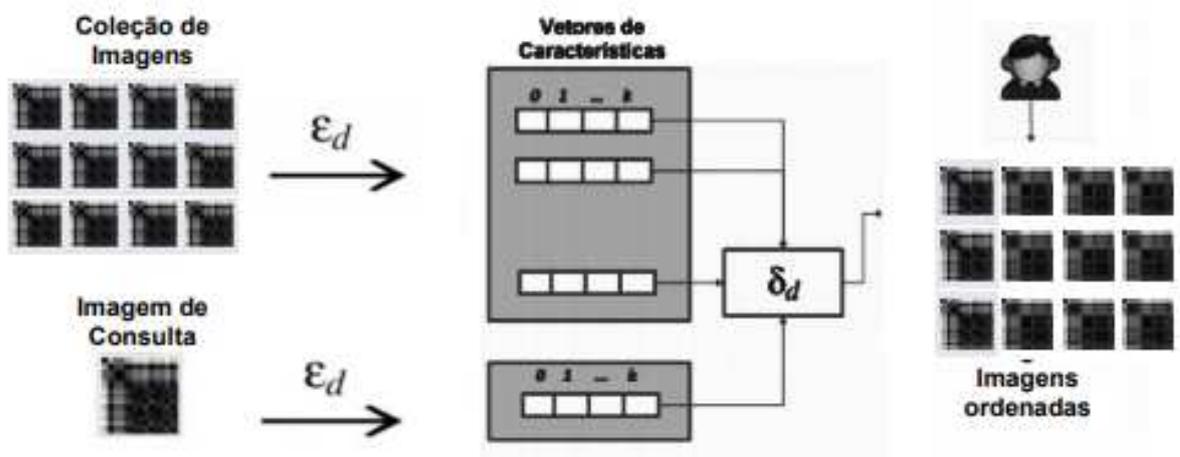


Figura 2.4: Fluxo de extração de características e busca de imagens (figura adaptada de [19]).

A eficácia de um descritor não depende somente do tipo de extração de características, mas depende também da função de similaridade empregada. A escolha da função de similaridade ajuda a melhorar o resultado das consultas. A escolha do descritor mais adequado para uma determinada aplicação geralmente depende da realização de experimentos comparativos utilizando diferentes descritores para verificar qual deles apresenta melhor desempenho, em termos de eficácia e eficiência. Para cada aplicação, podemos escolher quais características serão extraídas e codificadas como um vetor.

Exemplos de propriedades visuais tipicamente exploradas pelos descritores são: cor, textura e forma [14]. A cor é uma das propriedades visuais mais utilizadas em sistemas de busca de imagens. Essa é uma propriedade robusta por apresentar independência do tamanho da imagem e da orientação da mesma. Descritores típicos de cor buscam caracterizar a distribuição das cores de uma imagem de forma a recuperar imagens que sejam compostas por cores similares. A textura contém informação importante sobre o arranjo estrutural de regiões de imagem, ou seja, os descritores de textura buscam caracterizar nas imagens padrões visuais locais associados a propriedades de homogeneidade que são indiferentes às variações de cor e levando em conta o relacionamento de vizinhança entre os pixels da imagem. Isso permite a representação de atributos como: rugosidade, contraste, aspereza e semelhança de linhas. Exemplos de textura em imagens incluem areia, pedras, folhagem, nuvens, vegetação, paredes, cabelo [21]. Segundo [17, 21, 35], descritores de forma usam técnicas que consideram a descrição total da borda de objetos (abordagem baseada em contorno) ou a descrição das características morfológicas das regiões presentes na imagem (abordagem baseada em regiões). Esses descritores são usados quando é necessário executar buscas com base no perfil e na estrutura física de um objeto, deixando em segundo plano características como cor e textura. A seguir, apresentamos alguns descritores que selecionamos para usar no nosso trabalho.

2.4.1 *Histogram of Oriented Gradients (HOG)*

HOG [16], histogramas de gradientes orientados, é um descritor de textura e forma amplamente utilizado em diversas aplicações [16]. No descritor HOG, a imagem de entrada é de tamanho $64 \times 128 \times 3$ e o vetor de característica final é de tamanho 3780. No HOG, computa-se a distribuição (histogramas) das direções dos gradientes (gradientes orientados). Os gradientes (derivadas nas direções x e y) de uma imagem são úteis porque a magnitude dos gradientes é grande em torno de bordas e cantos (regiões de mudanças bruscas de intensidade), ou seja, bordas e cantos contêm muito mais informações sobre a forma do objeto do que regiões planas.

A seguir, apresentam-se as etapas para geração do vetor de característica do HOG, de acordo com o artigo original [16] e conforme ilustrado em¹:

- Pré-processamento: O vetor de característica HOG é calculado em regiões da imagem de tamanho 64×128 de uma imagem. Naturalmente, uma imagem pode ser de qualquer tamanho. Os *patches* (regiões) em várias escalas são analisados. A única

¹<https://www.learnopencv.com/histogram-of-oriented-gradients/> (Último acesso em Maio de 2019).

restrição é que as regiões analisadas tenham uma proporção fixa. Neste caso, os *patches* precisam ter uma proporção de 1:2. Por exemplo, eles podem ser 100×200 , 128×256 , ou 1000×2000 , mas não 10×205 . Para ilustrar este passo, considere a Figura 2.5, que mostra uma imagem com dimensão 720×475 . Seleccionamos um *patch* (parte) de tamanho 100×200 para calcular o descritor HOG. O *patch* é recortado da imagem e redimensionado para 64×128 . Feito isto, podemos calcular o descritor HOG para este *patch*.

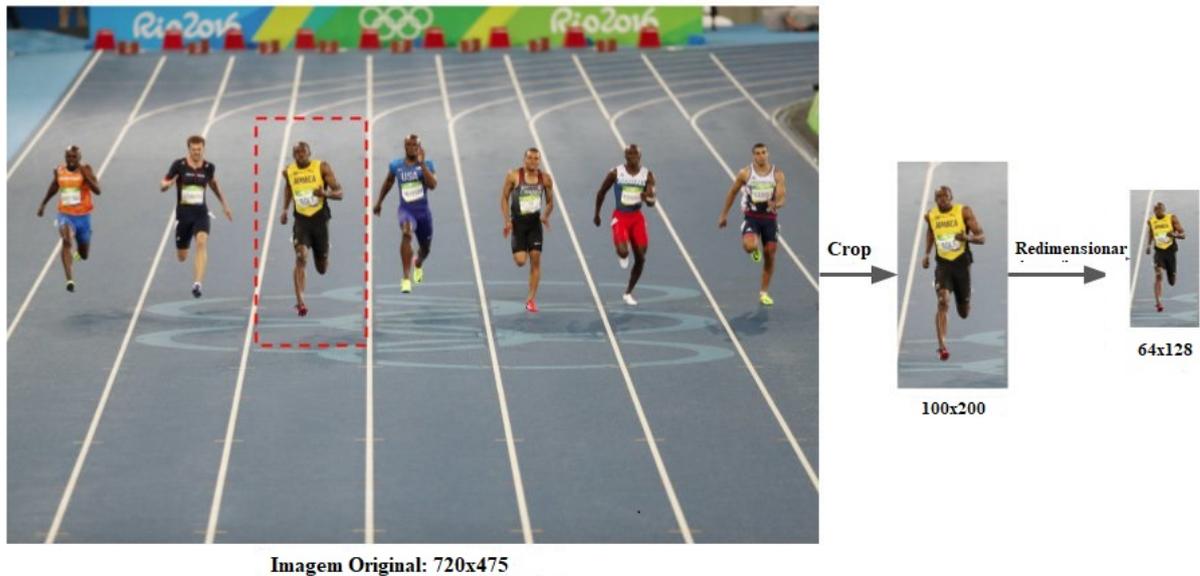


Figura 2.5: Ilustração da etapa de pré-processamento do descritor HOG (figura adaptada de [38]).

- Cálculo dos gradientes das imagens: Para calcular um descritor de HOG, precisamos primeiro calcular os gradientes horizontal e vertical; afinal, queremos calcular o histograma dos gradientes. Isto é facilmente conseguido filtrando (a partir de operações de convolução) a imagem com máscara, conforme aquelas mostradas na Figura 2.6.

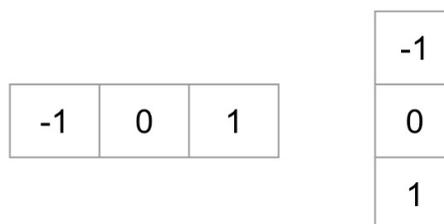


Figura 2.6: Máscaras para calcular os gradientes da imagem (figura adaptada de [38]).

Em seguida, podemos encontrar a magnitude e direção do gradiente usando as Equações 2.3 e 2.4:

$$g = \sqrt{g_x^2 + g_y^2} \quad (2.3)$$

$$\theta = \arctan \frac{g_y}{g_x} \quad (2.4)$$

em que g_x e g_y são os valores dos gradientes ao longo das direções x e y , respectivamente.

A Figura 2.7 ilustra o cálculo dos gradientes e da magnitude, considerando-se a imagem de entrada mostrada na Figura 2.5. Observe que o gradiente x está relacionado a linhas verticais, enquanto o gradiente y é associado a linhas horizontais. A magnitude dos gradientes codifica onde há uma mudança brusca de intensidade. Nenhuma destas imagens codifica informação associada a regiões homogêneas.

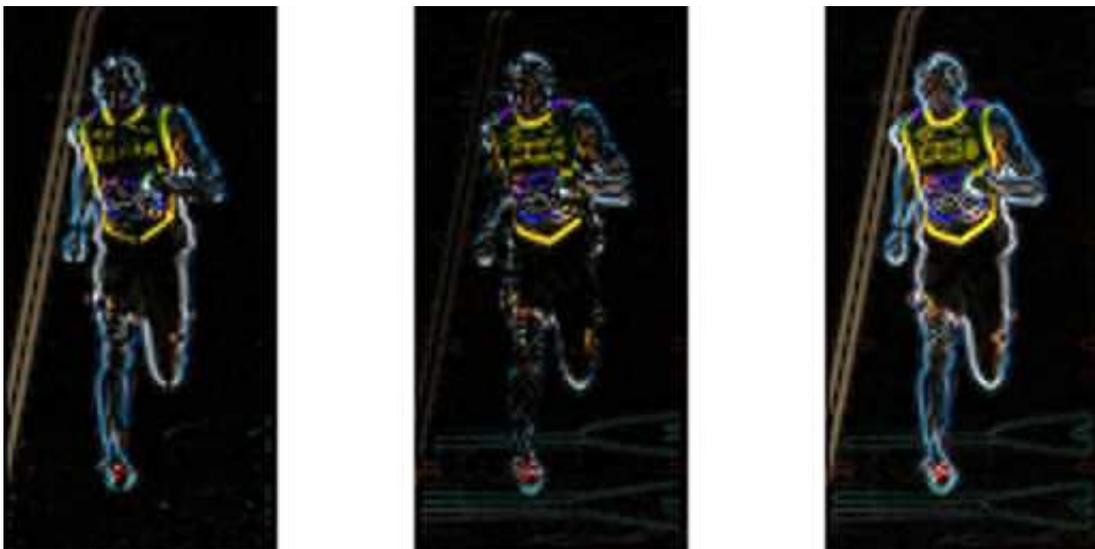


Figura 2.7: Na esquerda: valor absoluto do gradiente x . No centro: valor absoluto do gradiente y . Na direita: magnitude do gradiente (figura adaptada de [38]).

A imagem do gradiente removeu muitas informações não essenciais (por exemplo, fundo colorido constante), mas destacou os contornos. Ou seja, pode-se olhar para a imagem de gradiente e ainda identificar facilmente que há uma pessoa na imagem.

Em cada pixel, o gradiente tem uma magnitude e uma direção. Para imagens coloridas, os gradientes dos três canais são avaliados (como mostrado na figura acima). A magnitude do gradiente em um pixel é o máximo da magnitude dos gradientes dos três canais, e o ângulo corresponde ao gradiente máximo.

- Cálculo do histograma de gradientes em células 8×8 : Nesta etapa, a imagem é dividida em células 8×8 e um histograma de gradientes é calculado para cada uma das células.

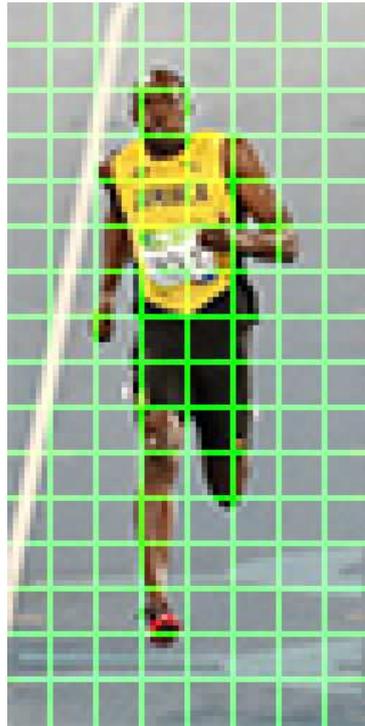


Figura 2.8: Células 8×8 do HOG. A imagem é dimensionada $4 \times$ maior para exibição (figura adaptada de [38]).

Uma das razões importantes para usar um descritor de características para descrever um patch (parte) de uma imagem é que ele fornece uma representação compacta. Um patch (parte) de imagem 8×8 contém $8 \times 8 \times 3 = 192$ pixels. O gradiente deste patch contém 2 valores (magnitude e direção) por pixel que somam $8 \times 8 \times 2 = 128$ números. Mais adiante veremos como esses 128 números são representados usando um histograma de 9 caixas (bins) que pode ser armazenado como uma matriz de 9 números. Não apenas a representação é mais compacta, o cálculo de um histograma sobre um patch (parte) torna essa representação mais robusta a ruído.

O histograma é essencialmente um vetor (ou uma matriz) de 9 posições (bins) com números correspondentes aos ângulos $0, 20, 40, 60 \dots 160$.

A Figura 2.9 ilustra o cálculo dos gradientes. A imagem no centro mostra um patch (parte) da imagem de entrada (esquerda) sobreposta com setas mostrando o gradiente. A seta mostra a direção do gradiente e seu comprimento, a magnitude. Observe como a direção das setas aponta para a direção da mudança na intensidade e a magnitude mostra quão grande é a diferença. À direita, vemos os números brutos representando os gradientes nas células 8×8 com uma pequena diferença – os ângulos estão entre 0° e 180° graus, em vez de 0° a 360° graus. Estes são chamados de gradientes “sem sinal” porque um gradiente positivo e outro e negativo são representados pelos mesmos números. Em outras palavras, uma seta gradiente e outra 180° graus oposta a ela são consideradas as mesmas. Algumas implementações do HOG permitem especificar o uso de gradientes com sinal.

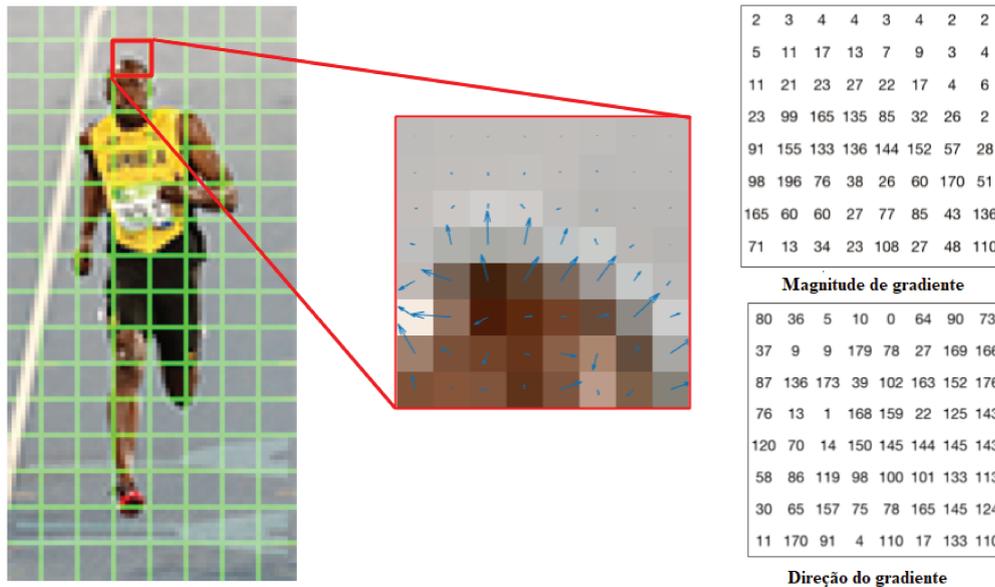


Figura 2.9: No centro: O patch (parte) RGB e os gradientes representados usando setas. Na direita: os gradientes no mesmo patch (parte) são representados como números (figura adaptada de [38]).

O próximo passo é criar um histograma de gradientes nessas células 8. O histograma contém 9 dimensões correspondentes aos ângulos 0, 20, 40 . . . 160. A Figura 2.10 ilustra o processo. Estamos olhando para magnitude e direção de um mesmo gradiente do mesmo patch (parte) 8×8 como na figura anterior. Uma posição (bin) é selecionada com base na direção e no voto (o valor que entra na posição é selecionado com base na magnitude). Vamos primeiro focar no pixel circulado em azul. Tem um ângulo (direção) de 80 graus e magnitude de 2. Assim, adiciona 2 a quinta posição. O gradiente no pixel circundado em vermelho tem um ângulo de 10 graus e magnitude de 4. Como 10 graus estão a meio caminho entre 0 e 20, o voto pelo pixel divide-se uniformemente nas duas posições.

As contribuições de todos os pixels nas regiões 8×8 são adicionadas para criar o histograma de 9 posições.

- Normalização de blocos 16×16 : Na etapa anterior, descrevemos como calcular um histograma com base no gradiente da imagem. Os gradientes de uma imagem são sensíveis à iluminação geral. Idealmente, queremos que o descritor seja independente das variações de iluminação. Em outras palavras, gostaríamos de “normalizar” o histograma para que eles não sejam afetados por variações de iluminação.

A solução típica empregada consiste em normalizar sobre um bloco maior de 16×16 . Um bloco de 16×16 tem 4 histogramas que podem ser concatenados para formar um vetor que é normalizado pela norma do vetor.

- Cálculo do vetor de característica HOG: Para calcular o vetor final para todo o patch de imagem, os vetores dos patches são concatenados, levando a um vetor final com 3780 dimensões.

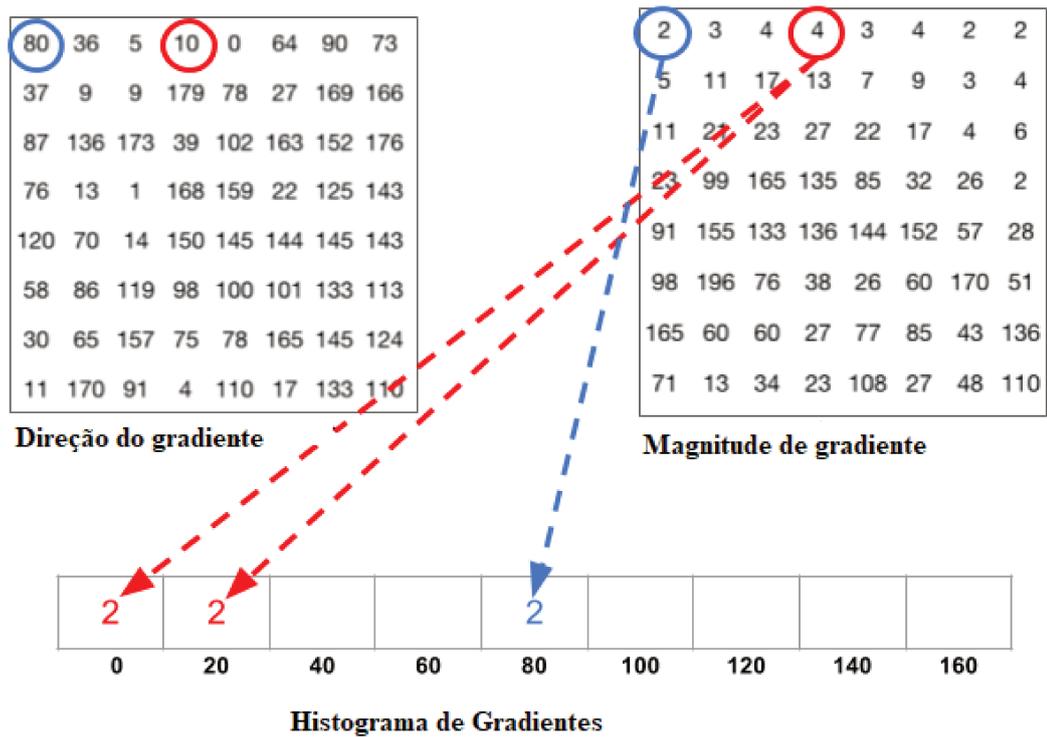


Figura 2.10: Criação do histograma de gradientes do HOG (figura adaptada de [38]).

Nós escolhemos o descritor HOG, porque ele já foi utilizado em outros trabalhos [13, 15] que usam séries e apresentou bons resultados. Inclusive ele foi usado com sucesso em alguns dos principais [13, 15] trabalhos relacionados a esta dissertação.

2.4.2 Local Binary Patterns (LBP)

Em imagens, as texturas são arranjos locais definidos em termos de níveis de intensidade. As texturas nas imagens podem ser medidas com base em três parâmetros: contraste, janela e direcionalidade. O contraste refere-se às diferenças nos níveis de cinza, a janela é o tamanho da área definida no local onde a diferença ocorre, e a direcionalidade é direção da textura. LBP [44, 45], códigos binários locais, é um descritor local de textura. A ideia básica deste descritor é que as texturas podem ser descritas por duas medidas complementares: padrões espaciais locais e contraste dos níveis de cinza. LBP resume as estruturas locais gerando uma representação estatística dessas estruturas.

O LBP original [45], conforme ilustrado na Figura 2.11, considera uma vizinhança 3×3 em torno de cada pixel.

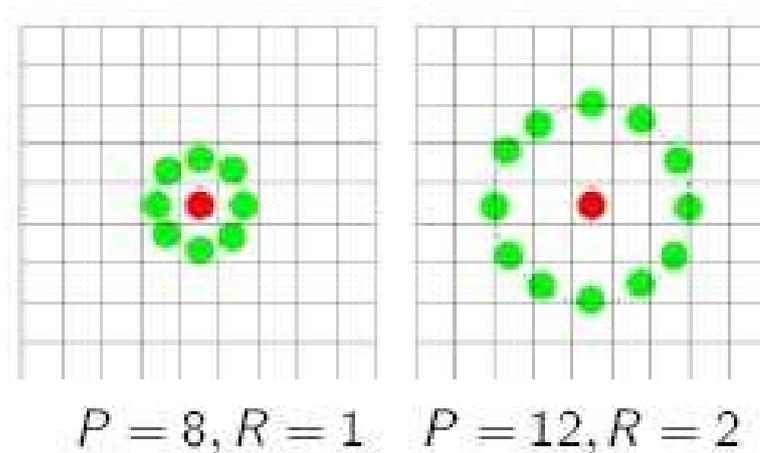


Figura 2.11: LBP original considerando uma vizinhança 3×3 (figura adaptada de [45]).

Para cada pixel na vizinhança, compara-se sua intensidade com a intensidade pixel central e se atribui 1 para o pixel se ele é maior ou igual ao pixel central e 0, caso contrário. O código LBP de cada pixel é calculado como um número de 8 bits. Em seguida, é calculado um histograma dos códigos LBP calculados. A Figura 2.12 ilustra o esquema de pesos usado para a codificação do padrão contido em uma janela 3×3 .

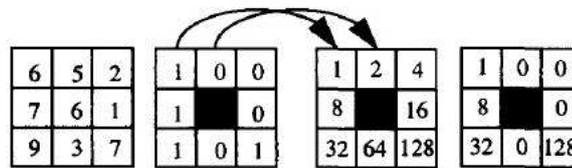


Figura 2.12: LBP original: códigos calculados para uma vizinhança 3×3 (figura adaptada de [45]).

A formulação do LBP proposta em [44] apresenta um LBP mais geral baseado em vizinhanças circulares e com um número arbitrário de pontos. A seguir colocamos alguns pontos principais do LBP proposto em [44]:

- O valor de um código LBP para um pixel central c , de coordenada (x_c, y_c) , com amostragem de P vizinhos no raio R é:

$$LBP_{P,R} = \sum_{p=0}^{P-1} S(g_p, g_c) 2^p \quad (2.5)$$

$$s(x) = \left\{ \begin{array}{ll} 1, & \text{se } x > 0, \\ 0, & \text{caso contrário,} \end{array} \right\} \quad (2.6)$$

em que g_p e g_c são os níveis de cinza dos pontos da vizinhança p central c .

- Considera a vizinhança de pixel com P pontos de amostragem em um círculo de raio R . A Figura 2.13 ilustra conjuntos vizinho circularmente simétricos para vários $(P; R)$.

- Um vetor de características pode ser calculado por meio do histograma dos LBPs.

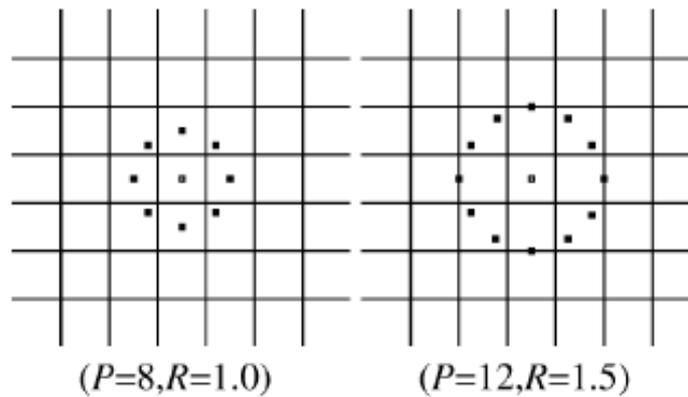


Figura 2.13: Vizinhança circular usada no LBP genérico. Conjuntos vizinhos simétricos circulares para diferentes $(P; R)$ (figura adaptada de [44]).

Nós escolhemos o descritor LBP, porque ele foi usado, nos principais [19–21, 34, 35] trabalhos relacionados a essa dissertação. Esse descritor apresentou bons resultados nesses trabalhos citados e isso nos motivou a usar ele no nosso trabalho.

2.5 Obtenção de Assinaturas Textuais de Imagens: Método S-BoVW

O uso de assinaturas textuais em problemas de busca de imagens foi inicialmente investigado por Kimura e colaboradores [17, 35]. Estes trabalhos utilizaram descritor de cor e partições fixas chamadas de regiões. Resultados experimentais obtidos apontaram que partições na imagem resultavam em melhor precisão e melhor desempenho em buscas de imagens; em parte por conta da combinação de características visuais extraídas de múltiplas regiões de uma imagem. A Figura 2.14 ilustra o modelo de partições que utilizado.

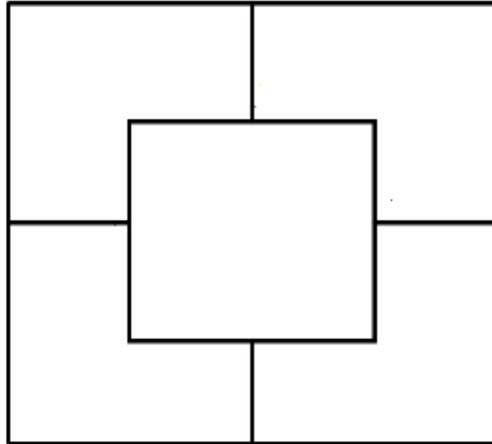


Figura 2.14: Imagem dividida em cinco partições (regiões) – figura adaptada de [17].

Vidal et al. [59] deram continuidade ao trabalho, utilizando descritor de cor e dividindo a imagem em muitas partições chamadas blocos. Este particionamento foi chamado de particionamento extremo por dividir a imagem em muitas partes. A Figura 2.15 ilustra o modelo de partições usado em [59].



Figura 2.15: Imagem dividida em muitas partições(blocos) (figura adaptada de [59]).

A partir do trabalho de [59], foi criado o método *Signature-based of visual words (S-BoVW)* [19, 20] que é apresentado como uma nova categoria de métodos para recuperação de imagens. Este método será utilizado como ponto de partida da pesquisa proposta neste trabalho.

O método S-BoVW divide a imagem em blocos e regiões. E com o auxílio de funções de mapeamento, são criadas assinaturas textuais para cada bloco. A Figura 2.16 apresenta as etapas do método S-BoVW desde a partição da imagem em regiões até a extração da assinatura textual. Na Figura 2.16(a), uma imagem é dividida em 5 regiões. Na Figura 2.16(b), por sua vez, a região 1 é dividida em 9 blocos. Em seguida, uma função de mapeamento genérica gera a assinatura textual do bloco. Na Figura 2.16(c), o bloco tem seu conteúdo representado por uma assinatura textual.

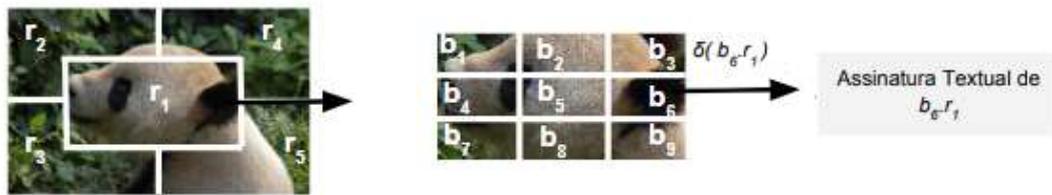


Figura 2.16: Processo de extração da assinatura Textual pelo S-BoVW usando função de mapeamento genérica (figura adaptada de [21]).

A função de mapeamento é baseada no uso de um descritor utilizado para extrair características associadas às propriedades visuais da imagem. Esta função é responsável por transformar um bloco da imagem em um termo textual (*string*). A função de mapeamento é a peça principal do método S-BoVW; é ela que diferencia vários métodos S-BoVW. A seguir, apresentamos algumas funções de mapeamento que foram testadas no contexto do método S-BoVW.

A Figura 2.17 apresenta as etapas do método S-BoVW desde a partição da imagem em regiões até a extração da assinatura textual, usando o *Descriptor Sorted Dominant Local Color* (SDLC). Um bloco da imagem é passado como entrada. Em seguida, a função de mapeamento do SDLC recebe como entrada o histograma de cor de um bloco da imagem e produz uma assinatura composta pela identificação da região onde o bloco reside, concatenada com os códigos das cores cujas frequências estão acima de um limiar ϵ . Os códigos são ordenados de forma decrescente para gerar uma assinatura textual. A função de mapeamento é um descritor utilizado para extrair a assinatura. Por exemplo, se um bloco de uma região 1 de uma imagem contiver apenas as cores 200, 30 e 40 com frequência superior a um limiar ϵ escolhido, esse bloco será representado pela assinatura textual “r1-200-40-30”.

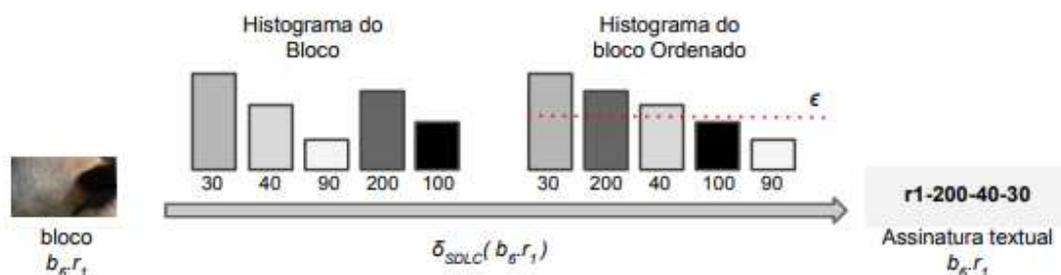


Figura 2.17: Processo de extração da assinatura Textual pelo S-BoVW usando função de mapeamento SDLC (figura adaptada de [21]).

A Figura 2.18 apresenta as etapas do método S-BoVW desde a partição da imagem em regiões até a extração da assinatura textual, usando o *Sorted Dominant Local Texture* (SDLT). Novamente, um bloco da imagem é definido como entrada. Em seguida, a função de mapeamento SDLT recebe como entrada o histograma de código LBP de um bloco da imagem e produz uma assinatura composta pela identificação da região onde o bloco reside, concatenada com os códigos dos padrões de textura cuja frequência esteja

acima de um limiar ϵ . Tais códigos são ordenados de forma decrescente. Por exemplo, se um bloco de uma região 1 de uma imagem contiver os padrões de textura 129, 64 e 256 com frequência superior a um limiar ϵ , esse bloco será representado pela assinatura textual “r1-256-129-64”.

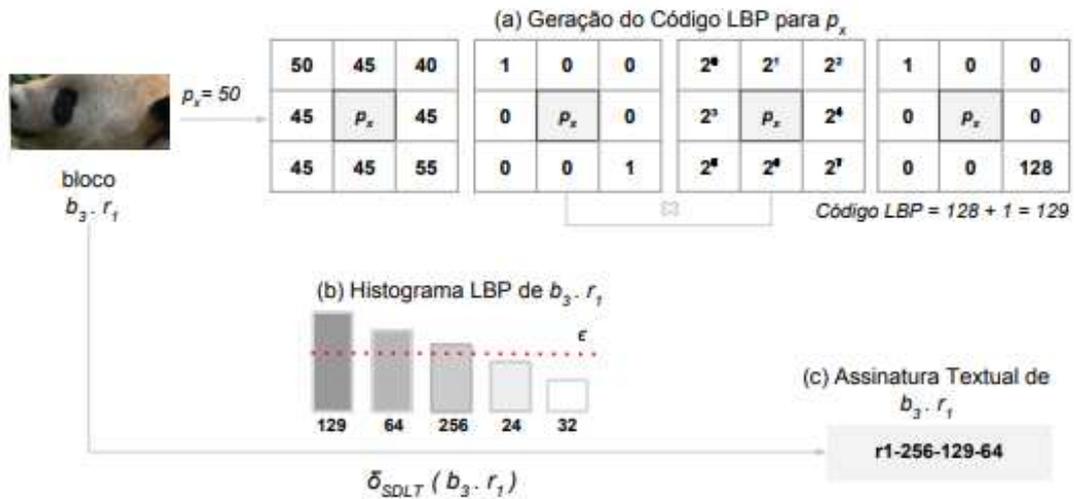


Figura 2.18: Processo de extração da assinatura Textual pelo S-BoVW usando função de mapeamento SDLT (figura adaptada de [21]).

A Figura 2.19 apresenta as etapas do método S-BoVW desde a partição da imagem em regiões até a extração da assinatura textual, usando o *Sorted Dominant Local Color and Texture* (SDLCT). Esta função unifica as características de cor e textura para obter uma representação melhor da imagem. Cada bloco da imagem é passado como entrada tanto para a função de mapeamento do SDLC quanto para a função mapeamento do SDLT, como pode ser visualizado na Figura 2.19(a). Assim, a assinatura textual gerada pela função SDLCT para um bloco será composta por duas palavras, sinalizando apenas qual foi o método que deu origem as palavras, por exemplo C para o SDLC e T para o SDLT, como pode ser visualizado na Figura 2.19(b). As assinaturas textuais de cada bloco e região são concatenadas formando uma assinatura textual da imagem inteira. Em seguida, as assinaturas são indexadas e armazenadas. No processo de busca, é utilizada uma função de similaridade para determinar quais imagens da coleção são relevantes.

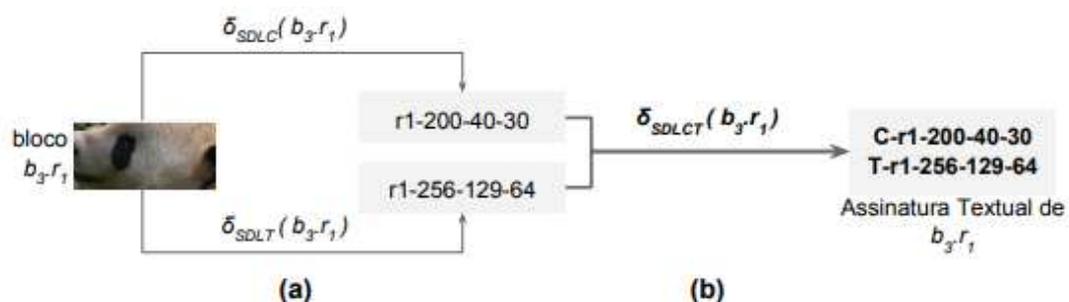


Figura 2.19: Processo de extração da assinatura Textual pelo S-BoVW usando função de mapeamento SDLCT (figura adaptada de [21]).

2.6 Busca de séries temporais

Esta seção apresenta uma breve descrição de iniciativas voltadas para representação e indexação de séries temporais, discutindo-se semelhanças e diferenças frente ao proposto neste trabalho de pesquisa. Na Seção 2.6.1, abordaremos vários tipos de representações utilizadas para séries temporais. Na Seção 2.6.2, apresentaremos técnicas de indexação disponíveis e faremos uma breve introdução sobre a técnica de indexação que utilizamos.

2.6.1 Representação de séries temporais

Aspectos de eficácia em sistemas de busca de séries temporais por similaridade têm sido freqüentemente abordados por meio de representações de séries temporais ou de funções de similaridade de séries temporais. Exemplos de representações de séries temporais amplamente usadas incluem [26]: aproximação agregada por partes (PAA) [33], aproximação constante por partes adaptativas (APCA) [32], soma de variação segmentada (SSV) [36], aproximação de nível de bit [4].

No método PAA [33], é introduzida uma nova transformação para alcançar a redução de dimensionalidade de séries temporais. O método é motivado pela simples observação de que, na maioria das vezes, conjuntos de dados em série podem ser aproximados a partir da segmentação das seqüências em seções de mesmo tamanho e registrando o valor médio dessas seções. Isto significa que os valores podem então ser indexados eficientemente em um espaço de menor dimensão. Na formulação APCA [32], séries temporais são indexadas usando uma estrutura de índice multidimensional. Além disso, duas medidas de distância no espaço indexado que exploram a alta fidelidade do APCA para busca rápida utilizando-se de uma aproximação da distância Euclidiana. A abordagem SSV [36], é proposta uma técnica de redução de dimensionalidade para indexação de séries temporais baseada em distância mínima, definida em termos de cálculo de autocorrelação. No trabalho [4], usa-se uma operação de *clipping* para geração de representações de séries temporais. *Clipping* é o processo de transformar uma série com valor real em uma seqüência de bits que representa se cada valor de um dado instante de tempo está acima ou abaixo da média. O recorte é uma transformação útil e flexível para a análise exploratória de grandes conjuntos de dados dependentes do tempo. As séries temporais armazenadas como bits podem ser compactadas eficientemente.

Os métodos acima dependem do particionamento da série temporal em segmentos, que são representados usando diferentes estratégias de amostragem. Outros caminhos de pesquisa na área exploram aproximações de séries temporais por linhas retas (por exemplo, linear por partes representação – PLR) [31], o uso de representações simbólicas para codificar séries numéricas (por exemplo, aproximação agregada simbólica – SAX) [61], e o uso de representações baseadas em *shapelet* [64].

No trabalho [31], os autores apresentam um método para busca de similaridade que é robusto para escalonamento no eixo do tempo, além de ruído, conversão de deslocamento e escala de amplitude. Os autores mostram que uma representação linear por partes permite uma correspondência de seqüência robusta que é muito mais rápida que as técnicas atuais. Na representação SAX [61], séries temporais são representadas por cadeias de caracteres

que codificam transições de estados definidos pela técnica de redução de dimensionalidade definida do PAA [33]. Este tipo de representação abre a oportunidade do uso de funções de distância definidas para busca de *strings*. Shapelets de séries temporais são padrões locais pequenos que são altamente preditivos de uma classe de interesse [64]. Basicamente, esta representação codifica a complexidade local da forma encontrada na série temporal.

No trabalho [55], os autores investigam o uso de gráficos de recorrência como representação de séries temporais para tarefas de classificação. A investigação avaliou o uso de descritores de textura, baseados em matrizes de co-ocorrência e LBP. Estes resultados motivaram a investigação de representações RPs em problemas de classificação de séries temporais em fenologia [23, 24]. Nesses trabalhos, adotou-se um protocolo baseado na combinação de diferentes descritores visuais, incluindo inclusive descritores de cor. Diferente desses trabalhos, no entanto, nós exploramos representação em uma configuração de problema de busca por similaridade.

Em várias pesquisas, o foco reside em encontrar funções de similaridade/distância, que se destinam a atribuir pequenas pontuações de similaridade a séries temporais pertencentes a diferentes classes, ou seja, que se espera que sejam muito diferentes umas das outras. Juntamente com boas representações, essas funções podem levar a sistemas de recuperação eficazes. Os leitores podem se referir às iniciativas apresentadas em [11, 37], que realizam estudos comparativos de funções de similaridade de séries temporais para diferentes domínios. Nesta dissertação, adotamos funções bem sucedidas de similaridade de documentos textuais amplamente utilizadas (por exemplo, baseadas em frequência de documento termo-inversa de frequência(TF-IDF) para realizar comparações de séries temporais. A escolha por TF-IDF, se motivou pelo fato que o peso tf-idf é um peso frequentemente usado na recuperação de informação e mineração de texto. Esse peso é uma medida estatística usada para avaliar a importância de uma palavra para um documento em uma coleção ou corpus. A importância aumenta proporcionalmente ao número de vezes que uma palavra aparece no documento, mas é compensada pela frequência da palavra no corpus. Variações do esquema de ponderação tf-idf são frequentemente usadas pelos mecanismos de busca como uma ferramenta central na classificação e classificação da relevância de um documento, dada uma consulta do usuário.

2.6.2 Indexação

Os sistemas de busca do mundo real precisam conciliar os aspectos de eficácia e eficiência. No contexto da recuperação de séries temporais, as iniciativas para abordar os aspectos de eficiência geralmente dependem: do uso de esquemas de indexação [7]; capacidades de hardware específicas como GPUs [65]; ou estratégias para acelerar o cálculo de funções dispendiosas de similaridade / distância (por exemplo, Dynamic Time Warping – WTD) [5, 42].

No trabalho [5], os autores propõem uma nova estratégia de poda que explora os limites superior e inferior referentes ao uso do *Dynamic Time Warping* (DTW). O objetivo é reduzir uma grande fração dos cálculos caros de distância. A validação se deu em problemas de clusterização de séries temporais. No trabalho [7], por sua vez, os autores apresentam o iSAX 2.0, uma estrutura de índice projetada especificamente para coleções

muito grandes de séries temporais, codificadas em representações SAX [61]. No trabalho [42], os autores buscam otimizar a eficiência e eficácia do algoritmo DTW básico e dos algoritmos de alto nível que exploram o DTW, como busca de similaridade, clusterização e classificação. Em [65], os autores investigam como melhorar significativamente a escalabilidade da descoberta de padrões exatos, aproveitando o hardware da GPU e modificando o algoritmo STAMP [63]. O algoritmo STAMP calcula subsequência de séries temporais com um algoritmo eficiente a qualquer momento. A escalabilidade é demonstrada extração de padrões de um conjunto de dados com cem milhões de objetos. Nesse trabalho também é introduzido o STOMP, um novo algoritmo para a descoberta de padrões de séries temporais.

Diferente dessas abordagens, exploramos tecnologias de recuperação de informações prontas, incluindo esquemas de indexação eficientes, tornando a solução inteira mais simples de ser adotada em uma variedade de cenários e aplicativos de uso prático. A principal motivação é se beneficiar da maturidade, abrandência e escalabilidade destas tecnologias. Utilizamos a Ferramenta Lucene [25], uma biblioteca de mecanismo de pesquisa de texto de alto desempenho e repleta de recursos, escrita inteiramente em Java. É uma tecnologia adequada para praticamente qualquer aplicativo que exija pesquisa de texto completo, especialmente entre plataformas.

2.7 Considerações Finais

Neste capítulo foram apresentados resumidamente os principais conceitos relacionados a busca de séries temporais. Foram apresentados os conceitos de séries temporais, que é o dado fundamental para o processo de busca. Também foi discutida a técnica de *Recurrence Plot*, etapa fundamental para que a série possa ser processada. Também discutimos o conceito de descritores e apresentamos os dois descritores utilizados no nosso trabalho. Outro conceito importante apresentado foi o Método S-BoVW, responsável por transformar nossas séries em documentos textuais. Por fim, apresentamos o processo de busca de séries temporais, dividido em duas partes: representação e indexação. Em resumo, este capítulo teve como objetivo introduzir ao leitor os principais conceitos que fundamentam a nossa pesquisa.

Capítulo 3

Sistema de Busca Proposto

3.1 Considerações Iniciais

Este capítulo apresenta o sistema de busca proposto, assim como seus componentes principais. As Seções 3.2 e 3.3 fornecem uma visão geral do método proposto, destacando seus componentes. A Seção 3.4 descreve como cada componente foi implementado, ou seja, como efetivamente extraímos uma representação de uma série temporal, como são criadas assinaturas textuais, como se dá o uso de técnicas de indexação para acelerar a busca de assinaturas textuais associadas a séries temporais, e como funciona a busca de séries temporais baseada nestas assinaturas.

3.2 Extração de Assinaturas Textuais de Séries Temporais

A Figura 3.1 apresenta as etapas associadas à extração de assinaturas textuais de séries temporais.

Na etapa (a), *Extrair representação RP*, representações baseadas em *recurrence plots* são computadas. Em seguida, as propriedades visuais (seu conteúdo) da imagem RP são descritas. Nesta etapa, seguimos a abordagem proposta em [21], que compreende duas etapas principais: particionamento de imagem em sub-regiões de interesse e caracterização de seus conteúdos, etapas (b) e (c) da figura. Em (b), a imagem é particionada em regiões e blocos. A etapa (c), *Extrair característica*, contempla a caracterização das propriedades visuais de blocos, utilizando-se de alguma técnica baseada no uso de histogramas. Na etapa (d), *Extração da assinatura textual para cada bloco*, assinaturas textuais são computadas a partir dos histogramas computados. A etapa (e) diz respeito à concatenação de assinaturas textuais de blocos para a construção da assinatura textual de toda a imagem de *recurrence plot*. Na etapa (f), *Indexação e armazenamento*, assinaturas textuais são indexadas e armazenadas em um repositório. A seguir, estas etapas são detalhadas:

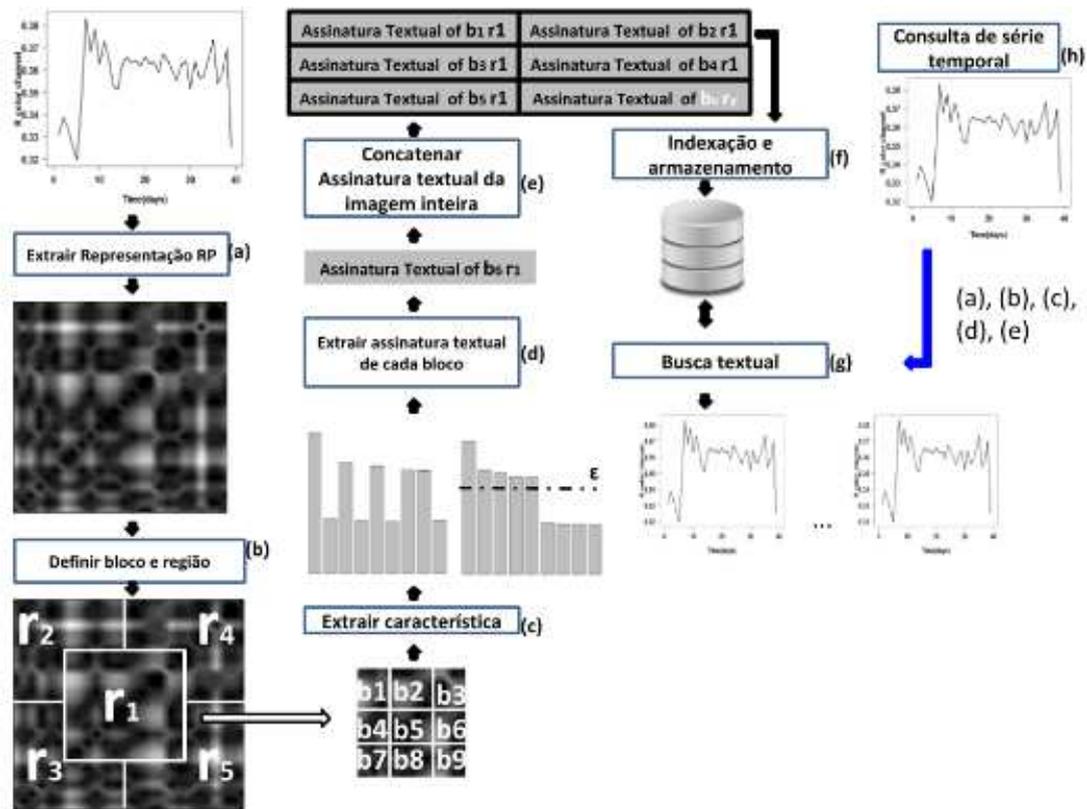
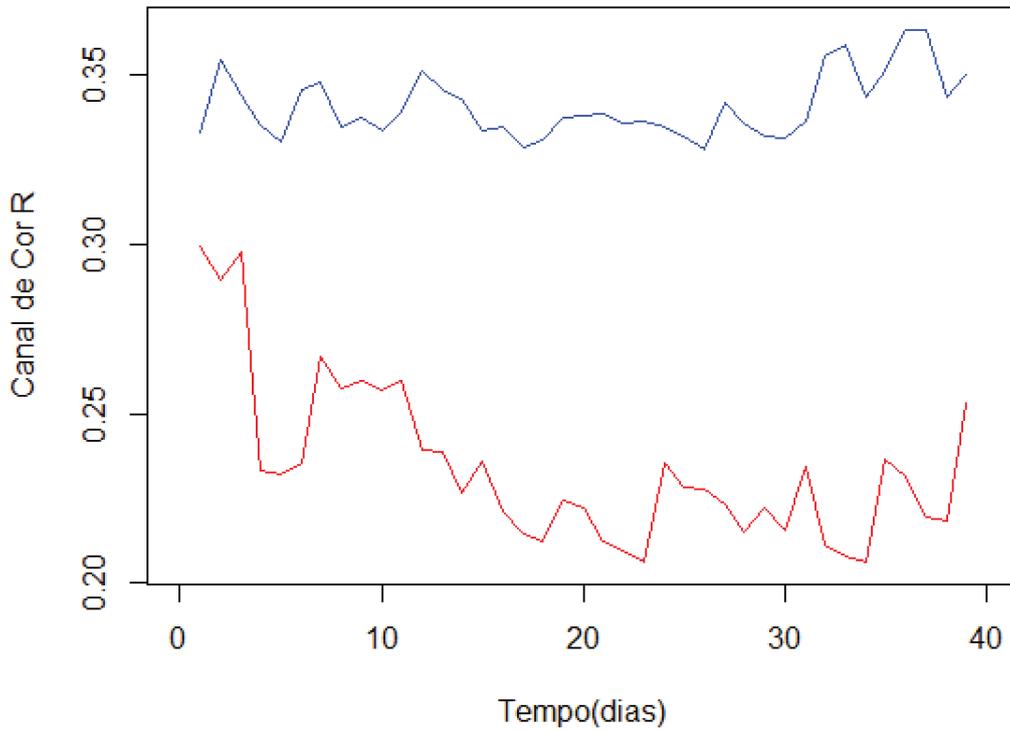
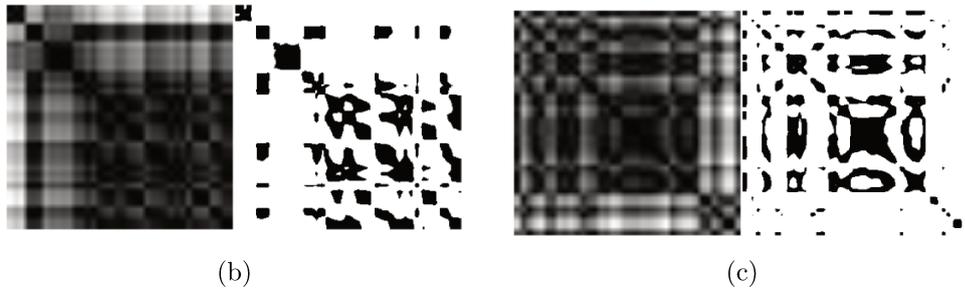


Figura 3.1: Diagrama esquemático da solução proposta para busca de séries temporais baseada em assinaturas textuais.

- Extrair representação: nesta etapa, a série temporal é transformada em uma matriz $R_{i,j}$ que é vista como uma imagem quadrada (de dimensão $N \times N$), conhecida como *Recurrence plot* (RP). *Recurrence plot* é uma técnica de representação que facilita a extração de informação e descoberta de padrões em séries temporais (ver Seção 2.3). O *Recurrence plot* pode ser codificado em uma imagem binária ou uma imagem em escala de cinza, dependendo de limiar empregado na matriz de distância definida. Figure 3.2 mostra duas séries temporais e dois exemplos de gráfico de recorrência considerando codificações em nível de cinza e binária (Figuras 3.2(b) e 3.2(c)). Como pode ser observado, padrões encontrados nas séries temporais são codificados de forma distintas nas respectivas representações RPs.



(a)



(b)

(c)

Figura 3.2: (a) Séries temporais, (b) Exemplos de imagem RP em nível de cinza (esquerda) e binária (direita) associadas à série temporal em azul em (a), (c) Exemplos de imagem RP em nível de cinza (esquerda) e binária (direita) associadas à série temporal em vermelho em (a).

- Definir bloco e região: nesta etapa, a imagem de *Recurrence plot* (RP) gerada na etapa anterior é particionada em bloco e regiões. Seja \hat{I}_{RP} uma imagem de *Recurrence plot* e $\mathcal{R} = \{r_1, r_2, \dots, r_\eta\}$ seja uma conjunto de η partições de \hat{I}_{RP} , de modo que cada *pixel* p em \hat{I} pertença a apenas uma região $r_j \in \mathcal{R}$. Seja $\mathcal{B}_{r_j} = \{b_{1.r_j}, b_{2.r_j}, \dots, b_{\beta.r_j}\}$ um conjunto de blocos não sobrepostos de pixels consecutivos da região r_j . Nós trabalhamos com dois tipos de partições. O primeiro é chamado de particionamento em blocos e regiões. A Figura 3.3 ilustra a utilização de um particionamento em 5 regiões dentro de uma imagem RP e nove blocos definidos por

uma grade 3×3 na região central. Nós trabalhamos também com o particionamento extremo, onde a imagem é particionada no maior número de blocos possíveis. A Figura 3.4 exemplifica a utilização de uma imagem particionada em 2500 blocos. O particionamento em blocos e regiões prioriza mais a parte central da imagem, enquanto o particionamento extremo considera todas as partes da imagem com a mesma importância, produzindo inclusive melhores resultados como veremos no próximo capítulo. O uso da imagem particionada é motivado pela tentativa de combinar assinaturas extraídas de múltiplas regiões da imagem, isto é, relações entre diferentes instantes de tempo da série temporal. Foi observado também que o uso destes tipos de particionamento levou a bons resultados de eficácia em trabalhos recentes [19, 21, 43, 59].

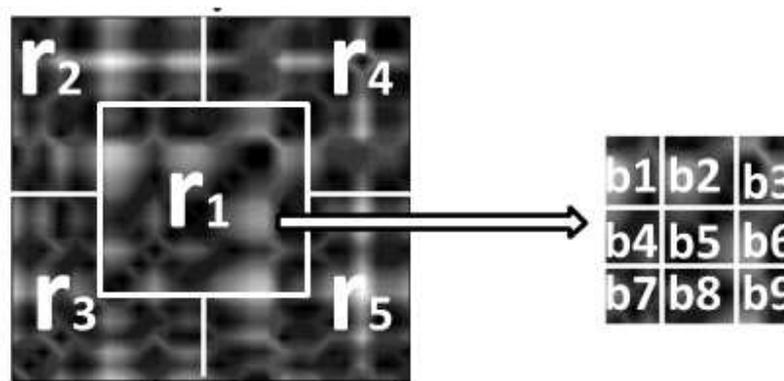


Figura 3.3: Particionamento em 5 Regiões e 9 Sub-regiões(blocos 3×3).

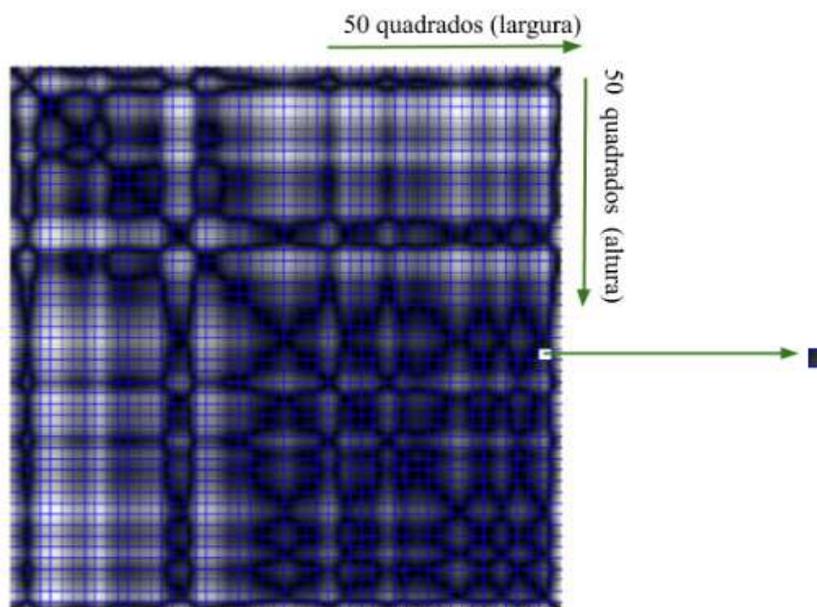


Figura 3.4: Particionamento extremo: 50×50 (2500 blocos).

- Extrair característica: nesta etapa, cada bloco $b_i.r_j \in \mathcal{B}_{r_j}$ tem seu conteúdo representado por meio de uma descrição de imagem baseada em histograma definido em

termos de uma função $D(b_i.r_j)$, que atribui um vetor de característica $fv_{i,j}$ para $b_i.r_j$. O uso de histogramas baseados em cor e textura foi investigado em [21]. Nesta dissertação, nós investigamos o uso da abordagem *Histograms of Orientated Gradients* (HOG) [16] – ver Seção 2.4.1 – e *Local Binary Patterns* (LBP) [44] – ver Seção 2.4.2 – para a caracterização de blocos de regiões.

- Extrair assinatura textual de cada bloco da imagem: Nesta etapa, cada bloco $b_i.r_j \in \mathcal{B}_{r_j}$ tem seu conteúdo representado por meio de uma assinatura textual que é gerada por uma função $\delta(fv_{i,j})$. Essa função é responsável por mapear o vetor de característica do bloco $fv_{i,j}$ para uma palavra no domínio textual. A assinatura gerada é definida como

$$\delta(fv_{i,j}) = \langle \hat{r}_j - \hat{c}_1 - \hat{c}_2 - \dots - \hat{c}_n \rangle,$$

em que $n \geq 0$, \hat{r}_j identifica a região r_j onde o bloco b_i ocorre e ‘-’ é um símbolo de separação. Cada valor \hat{c}_k codifica uma propriedade de conteúdo (por exemplo, cor, textura ou forma) que ocorre no bloco, de modo que a frequência da propriedade no bloco seja maior que um limite ϵ e $e(\hat{c}_i) > (\hat{c}_j)$, for $i < j$.

- Concatenar as assinaturas textuais da imagem inteira: o conjunto de assinaturas dos blocos são combinados para formar a assinatura de toda a imagem RP.
- Indexar e armazenar: As assinaturas textuais são indexadas usando esquemas de indexação tradicionais e amplamente usados com base em arquivos invertidos. Em nossa implementação, aproveitamos as bibliotecas de indexação disponíveis gratuitamente no sistema Lucene [40]. O Lucene usa o índice invertido, para indexar termos textuais. O índice invertido armazena estatísticas sobre os termos para tornar a pesquisa baseada em termos mais eficiente. Isso porque ele pode listar, para um termo, os documentos que o contêm. Esse é o inverso do relacionamento natural, no qual os documentos contêm termos.

3.3 Busca de Séries Temporais a partir de Assinaturas Textuais

O processo de busca utiliza o Modelo Vetorial (VSM) [50]. As assinaturas textuais das séries temporais são transformadas em vetores utilizando o esquema TF-IDF, de acordo com as frequências de seus termos, e depois é feito o cálculo da similaridade entre os modelos vetoriais utilizando-se da similaridade de cosseno. A Figura 3.1 apresenta as etapas necessárias para o processo de busca, usando assinatura textual. Em (h), *consultas de séries temporais*, uma sessão de busca é iniciada a partir de uma série temporal de consulta que também passará por todas as etapas de extração e geração de uma assinatura textual (etapas (a), (b), (c), (d), (e), e (f) na figura). Essa assinatura textual será a entrada para o módulo de busca (etapa (g), *busca textual*), responsável por retornar todas as séries similares existentes na coleção, considerando-se suas assinaturas textuais.

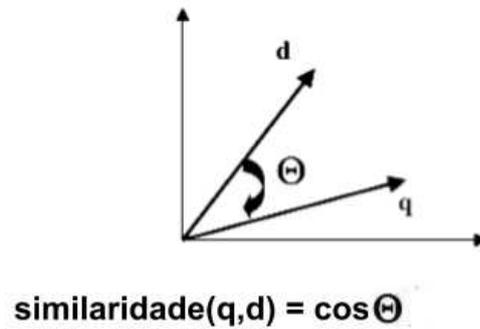


Figura 3.5: Ilustração do cálculo da similaridade entre dois vetores d e q a partir do cosseno do ângulo definido entre os vetores.

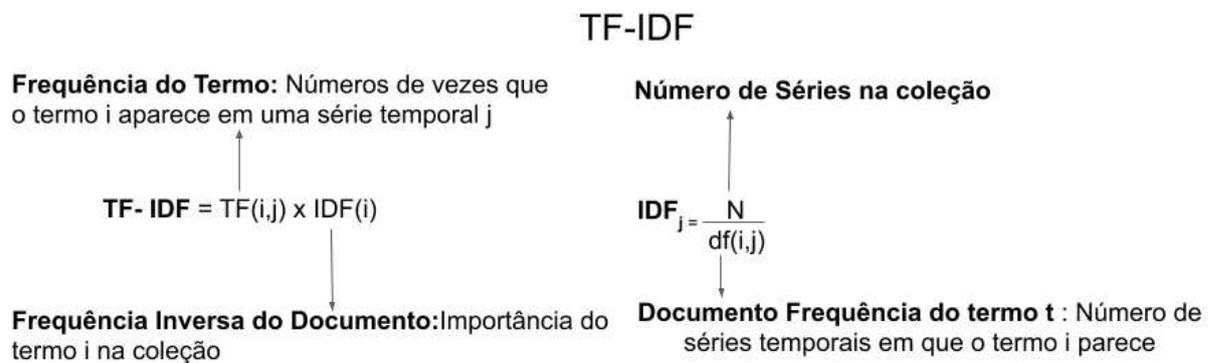


Figura 3.6: Esquema de ponderação de pesos $\text{TF} \times \text{IDF}$.

- Busca textual: nesta etapa, as séries temporais da coleção são classificadas de acordo com sua similaridade com a consulta, com base no modelo *Vector Space Model* (VSM) [50], ilustrado na Figura 3.5. Representações vetoriais baseadas em assinaturas textuais são calculadas com base no esquema tradicional de ponderação de termos $\text{tf} \times \text{idf}$. $tf_{i,j}$ representa o número de ocorrências do termo t_j em uma assinatura textual da série temporal i . idf_j , por sua vez, quantifica a importância do termo t_j na coleção, tal que $idf_j = \log\left(\frac{N}{df_j}\right)$, em que N é o número de séries temporais na coleção e df_j é o número de séries temporais em que o termo t_j aparece, conforme Figura 3.6. O cálculo das listas de ordenação (*ranked lists*) é baseado na função de similaridade de cosseno, disponível no sistema Lucene.
- Consulta de série temporal: Dada uma série temporal de consultas, suas assinaturas textuais são extraídas usando os mesmos procedimentos utilizados para indexação, depois ela entra no módulo de busca, que irá retornar todas as séries semelhantes existentes na coleção (seta destacada em azul na Figura 3.1 e ampliada na Figura 3.7).

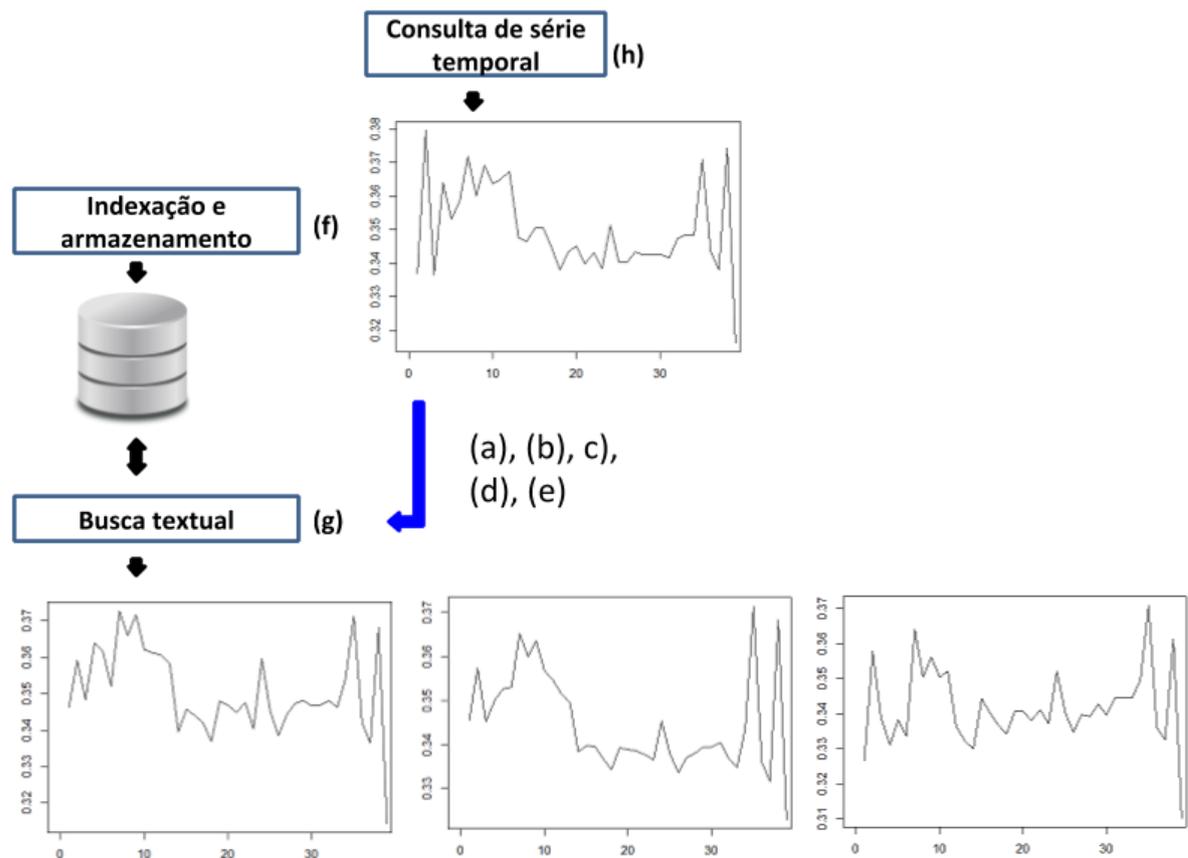


Figura 3.7: Consulta de Série Temporal e Busca Textual

3.4 Aspectos de Implementação

Cada série temporal é representada por uma imagem de *Recurrence plot* (RP). Em nossa implementação, utilizamos a função *recurr* do RStudio para extrair a representação de cada série temporal.

No **particionamento** (definição de bloco e região) da imagem utilizamos a biblioteca *imager* do RStudio. Essa biblioteca disponibiliza um conjunto de ferramentas chamado *gimptools*, que permite editar imagens. Dentre essas ferramentas, por exemplo, temos a função $px = \{X_c(img)\%inr\%c(X_1, X_2)\} \& \{Y_c(img)\%inr\%c(Y_1, Y_2)\}$ que permite particionarmos a nossa imagem em regiões, a partir da definição das coordenadas da imagem original. Após este processo, usamos em mesma função para particionarmos as regiões em blocos.

Na etapa de **extração de característica** utilizamos os descritores de forma *Histograms of Orientated Gradients* (HOG) [16] e de textura *Local Binary Patterns* (LBP) [44] para a extrair das características. Nosso ponto de partida foi o descritor *Histograms of Orientated Gradients* (HOG) [16] utilizado em [13], no qual o autor faz um estudo com o objetivo de identificar descritores de forma que são os mais adequados para a caracterização e identificação de padrões em séries temporais. Em seguida, utilizamos o descritor de textura *Local Binary Patterns* (LBP) [44] para verificar o desempenho de ambos no con-

texto de busca de séries temporais. No processo de extração, cada bloco é passado como entrada para o descritor utilizado que irá extrair as *features* desse bloco, ordenar o vetor de *features* e utilizar somente os valores acima de um limiar. Em seguida, o algoritmo gera uma **assinatura textual** composta por: número do bloco, e os identificadores de posições do histogramas cujas frequências estão acima do limiar. Um exemplo de assinatura textual gerada pelo LBP é apresentado na Figura 3.8.

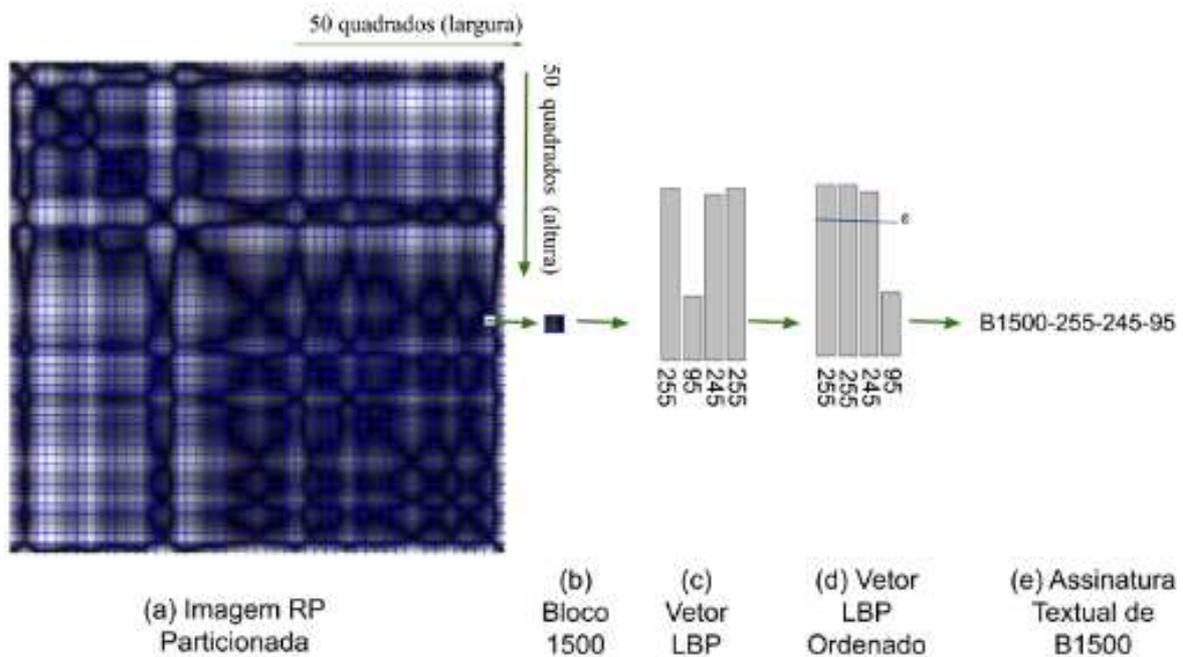


Figura 3.8: Assinatura Textual gerada para um Bloco – Descritor LBP.

Após a extração da assinatura, concatenamos a assinatura de todos os blocos da representação RP. O conjunto de assinaturas dos blocos irá compor a assinatura total de uma região da representação RP, e o conjunto assinaturas de cada região irá gerar a assinatura textual total da representação RP. Esse processo é feito por uma função do Rstudio.

A assinatura textual gerada para cada representação RP é indexada e armazenada para ser buscada em um segundo momento. Utilizamos o Lucene para indexação das assinaturas. O Lucene é uma biblioteca de mecanismo de procura de texto escalável e gratuita. Esta biblioteca foca principalmente na indexação e na busca textual. Ela permite indexar quaisquer dados disponíveis no formato textual e também que se executem buscas rápidas por palavras-chave e se localizem documentos relevantes a uma determinada consulta. Antes que os dados de texto sejam incluídos no índice, eles são processados por um analisador (usando um processo de análise). O Lucene armazena os dados de entrada em uma estrutura de dados chamada de índice invertido, que é armazenado no sistema de arquivos ou na memória como um conjunto de arquivos de índice.

Na etapa de busca textual, também usamos a biblioteca Lucene. No Lucene, consulta é uma classe abstrata para a qual, há várias implementações concretas de consultas possíveis. O Lucene fornece a possibilidade de criarmos nossas próprias consultas usando

sua API. No nosso caso, utilizamos funções relacionadas a buscas por *Multiple terms*. Criamos nossa própria consulta para fornecer como entrada a partir do agrupamento dos termos da assinatura textual associada ao objeto de consulta. O resultado gerado é um *ranked list*, no qual objetos da coleção (séries temporais) são ordenados de acordo com as suas similaridades (medida em termos da medida de similaridade de cosseno) em relação ao objeto de consulta. A Figura 3.9 ilustra um *ranked list* de uma consulta para uma determinada série de consulta.

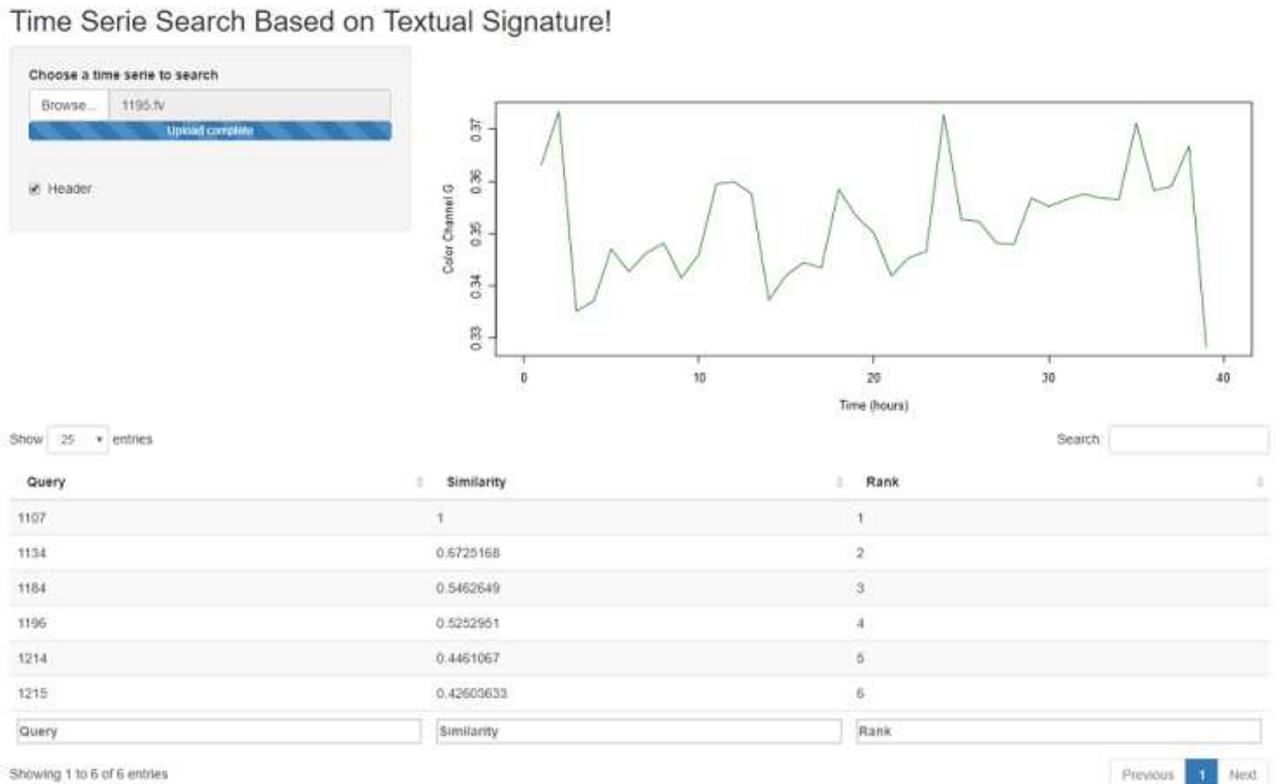


Figura 3.9: Busca de séries temporais baseada em assinaturas textuais.

3.5 Considerações Finais

Neste capítulo, nós primeiramente apresentamos e descrevemos um diagrama esquemático (Figura 3.1), mostrando todos os componentes do sistema de busca de séries temporais proposto. Nós também descrevemos as técnicas utilizadas na implementação de cada componente. Nosso sistema é dividido 8 etapas: cinco (etapas *a*, *b*, *c*, *d*, e *e*) são responsáveis por extrair assinaturas textuais de séries temporais e as outras 3 (etapas *f*, *g*, e *h*) estão associadas ao processamento de consultas por similaridade. Vale destacar que a técnica utilizada em cada etapa do nosso sistema foi selecionada de acordo com resultados recentes da literatura, assim como a partir de características (tratamento de eventos cíclico) da aplicação-alvo (Fenologia). Porém, nosso sistema é genérico e pode ser aplicado para outros problemas, inclusive utilizando outras técnicas na implementação de cada etapa.

Capítulo 4

Avaliação Experimental

4.1 Considerações Iniciais

Este capítulo apresenta o protocolo experimental adotado para validar o sistema de busca de séries temporais proposto, assim como apresenta e discute resultados obtidos. A Seção 4.2 apresenta o protocolo experimental adotado, indicando a coleção de séries temporais utilizadas e critérios de avaliação. A Seção 4.3 apresenta e discute os resultados experimentais obtidos.

4.2 Protocolo Experimental

Nós realizamos experimentos para analisar o desempenho das funções de mapeamento propostas em termos de eficácia e eficiência. Os experimentos foram realizados em um conjunto de dados de séries temporais, que são descritos na Seção 4.2.1. Em seguida, a Seção 4.2.2 apresenta os critérios de avaliação adotados. Por fim, a Seção 4.2.3 descreve o protocolo de comparação adotado.

4.2.1 Base de Dados de Séries Temporais de Fenologia

O sistema desenvolvido foi validado em uma base de dados associada ao projeto e-phenology. O e-Phenology¹ é um projeto multidisciplinar desenvolvido no âmbito de uma colaboração envolvendo o Instituto de Computação da Universidade Estadual de Campinas e o Departamento de Botânica (Laboratório de Fenologia) da Universidade Estadual Paulista. Este projeto combina pesquisas nas áreas de computação e fenologia. Seu objetivo é solucionar problemas teóricos e práticos envolvidos na utilização de novas tecnologias para observação fenológica remota, visando detectar mudanças ambientais locais e compreender os efeitos do aquecimento global nos tópicos. Ele tem como foco os seguintes requisitos:

1. A utilização das novas tecnologias de monitoramento ambiental com base em sistemas de monitoramento remoto de fenologia usando imagens digitais de vegetação;

¹<http://www.recod.ic.unicamp.br/ephenology/client/index.html> (Último acesso em Maio de 2019).

2. A criação de um protocolo para um programa de monitoramento de fenologia de longo prazo no Brasil e para integração entre diversas disciplinas, avançando o conhecimento atual de respostas sazonais dentro dos tópicos para mudanças climáticas;
3. Especificação e desenvolvimento de modelos, métodos e algoritmos de apoio à gestão, integração e análise de dados de sistemas de fenologia remota.

O conjunto de dados considerado neste estudo refere-se a uma sequência de imagens de vegetação capturadas pelo projeto e-phenology. O projeto tem um sistema de aquisição baseado no uso de câmera instalada no topo de uma torre de 18m existente em uma região de Cerrado restrito (Figura 4.1), onde se encontra uma vegetação do tipo savana localizada em Itirapina, São Paulo, Brasil. Para obter as imagens, uma câmera digital de lente hemisférica (Mobotix Q24) foi instalada no topo da torre, fixada em um braço de ferro no sentido nordeste. A atividade desta câmera é controlada por um temporizador e sua fonte de energia é uma bateria de 12v carregada por um painel solar. A câmera foi configurada para capturar automaticamente uma sequência diária de cinco imagens JPEG (em 1280×960 pixels de resolução) por hora, entre 06:00 às 18:00h (UTC-3). As imagens do nosso estudo foram registradas no final da estação seca, entre 29 de agosto e 03 de outubro de 2011 [1, 2, 13]. Utilizamos o algoritmo de Guigues [28] para segmentar imagens hierarquicamente. A imagem usada para obter a hierarquia de regiões segmentadas foi tirada às 12:00h do dia 15 de outubro de 2011. Cinco escalas de segmentação da hierarquia foram consideradas para a extração de séries temporais. A melhor escala, composta por 27.380 regiões, foi usada para avaliação de eficiência; enquanto a escala mais grosseira, que contém 8.849 regiões, foi usada para avaliação da eficácia. A Figura 4.1 ilustra as escalas segmentadas em uma amostra de sub-imagem.

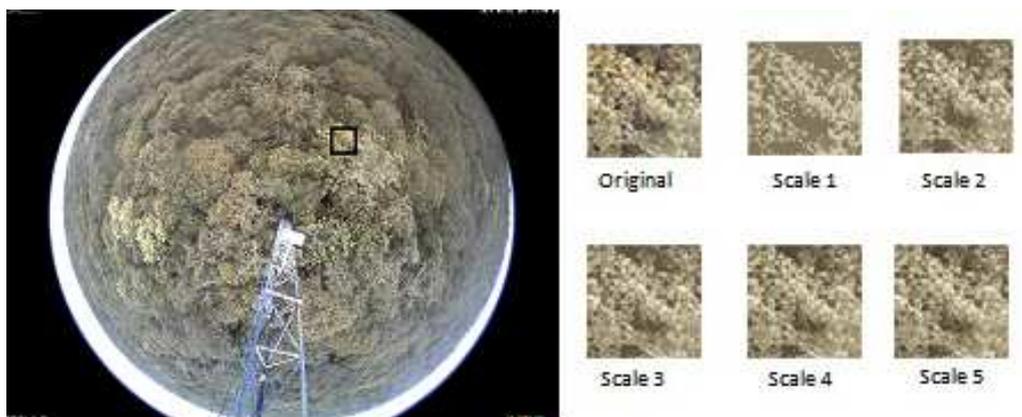


Figura 4.1: Exemplo de uma imagem de uma região de Cerrado capturada pela câmera em 3 de outubro de 2011 e os resultados da segmentação para as escalas selecionadas na amostra de uma sub-imagem.

Séries temporais são extraídas de cada região da imagem segmentada. Essas séries temporais referem-se à variação da contribuição das cores primárias (vermelho, verde e azul) ao longo do tempo. Conforme proposto por Richardson et al. [49], calculamos, para

cada canal de cor, o valor médio da intensidade do pixel. Em seguida, a importância relativa de cada canal é calculada como:

$$Total_{avg.} = Red_{avg.} + Green_{avg.} + Blue_{avg.} \quad (4.1)$$

$$Rcc = \frac{Red_{avg.}}{Total_{avg.}} \quad (4.2)$$

$$Gcc = \frac{Green_{avg.}}{Total_{avg.}} \quad (4.3)$$

$$Bcc = \frac{Blue_{avg.}}{Total_{avg.}} \quad (4.4)$$

4.2.2 Critérios de Avaliação

A eficácia do sistema de busca de séries temporais é calculada em termos da Precisão média em 5 (Precisão @ 5) para diferentes consultas. Trata-se de uma medida de avaliação de eficácia largamente utilizada na literatura [62]. A precisão @ 5, ou apenas P@5, é definida como a taxa de séries temporais relevantes recuperadas nas 5 primeiras posições da lista de classificação retornada. A avaliação de eficiência é medida pelo tempo médio de processamento da consulta para responder a uma única consulta de série temporal. Nós rodamos os experimentos em uma máquina Intel Core i5-3230M, com processador de 2.60GHz \times 4, 7,7 Gb de memória, e sistema operacional Ubuntu.

Avaliamos a significância estatísticas dos resultados obtidos, a partir do uso de um teste estatístico não-paramétrico, especificamente o teste pareado de consulta chamado *Wilcoxon signed-rank test*. O Teste de Wilcoxon Pareado é um método alternativo não-paramétrico do test-t pareado para duas amostras, que é usado para testar se as diferenças entre as localizações das populações são iguais [27]. Definimos o intervalo de confiança, nível de confiança, para 95% e a hipótese nula H_0 ($\mu_1 - \mu_2 = 0$, isto é, que os modelos comparados são equivalentes) considerando a diferença de eficácia (P@5) para cada consulta. Esse teste retorna um valor próximo de zero se os métodos forem iguais, e um *p-value* que é usado para determinar se a hipótese nula pode ser rejeitada. Um *p-value* \leq a 0,05 indica hipótese nula falsa. Um *p-value* \geq a 0,05 indica hipótese nula verdadeira. Se a hipótese nula for verdadeira, podemos concluir que os métodos são diferentes.

4.2.3 Protocolo de Comparação

Nossa estratégia para avaliar tanto a eficácia quanto a eficiência do sistema de busca proposto, usando o dataset de fenologia, se baseia na avaliação da similaridade entre regiões associadas a indivíduos da mesma espécie, com base em suas respectivas séries temporais. Definimos seis RIs (Figura 4.2) com base na seleção aleatória de seis espécies de plantas identificadas na imagem: (1) *Aspidosperma tomentosum* (região verde na Figura 4.2), (2) *Caryocar brasiliensis* (região azul), (3) *Myrcia guianensis* (região vermelha), (4) *Miconia rubiginosa* (região roxa), (5) *Pouteria ramiflora* (região rosa), e (6) *Pouteria torta* (região amarela).



Figura 4.2: Regiões de interesse (RIs) definidas para a análise de seis espécies de plantas da vegetação de cerrado-savana.

Utilizamos, portanto, um protocolo de recuperação, no qual séries temporais associadas a regiões pertencentes a indivíduos da mesma espécie são relevantes entre si. Este protocolo define um conjunto de séries (regiões na imagem) relevantes para cada consultas, isto é, o *ground truth* da consulta.

4.2.4 Baselines

Para comparação com o nosso método, utilizamos dois baselines implementado a partir da construção de sistemas de busca envolvendo:

- o uso de descritores de forma apresentados em [15], utilizados para caracterização de séries temporais;
- a comparação direta de séries temporais a partir do uso da medida de distância *Dynamic Time Warping* (DTW), uma das abordagens mais utilizadas na literatura.

4.3 Resultados Experimentais e Análise

Esta seção apresenta os resultados experimentais obtidos, assim como os discute.

4.3.1 Seleção de Parâmetros para HOG e LBP

Os experimentos foram realizados considerando duas configurações:

- **Configuração 1:** Na primeira configuração, usamos séries temporais originais, com 37 instantes de tempo. A implementação do descritor HOG é baseada no uso de 3 posições do vetor com maior valor, enquanto a do descritor LBP considera 5 posições do vetor com maior valor. A imagem de entrada foi particionada em 5 regiões e cada região dividida em 9 blocos.

- **Configuração 2:** Na segunda configuração, utilizamos séries temporais reamostradas com 180 (HOG) e 150 (LBP) pontos. A reamostragem visa verificar o impacto do uso de mais pontos para construção de imagens de RP de maior dimensão. As imagens de RP, neste caso foram particionadas em 60×60 blocos (HOG) e 50×50 blocos (LBP). Estas configurações foram definidas a partir de experimentos empíricos.

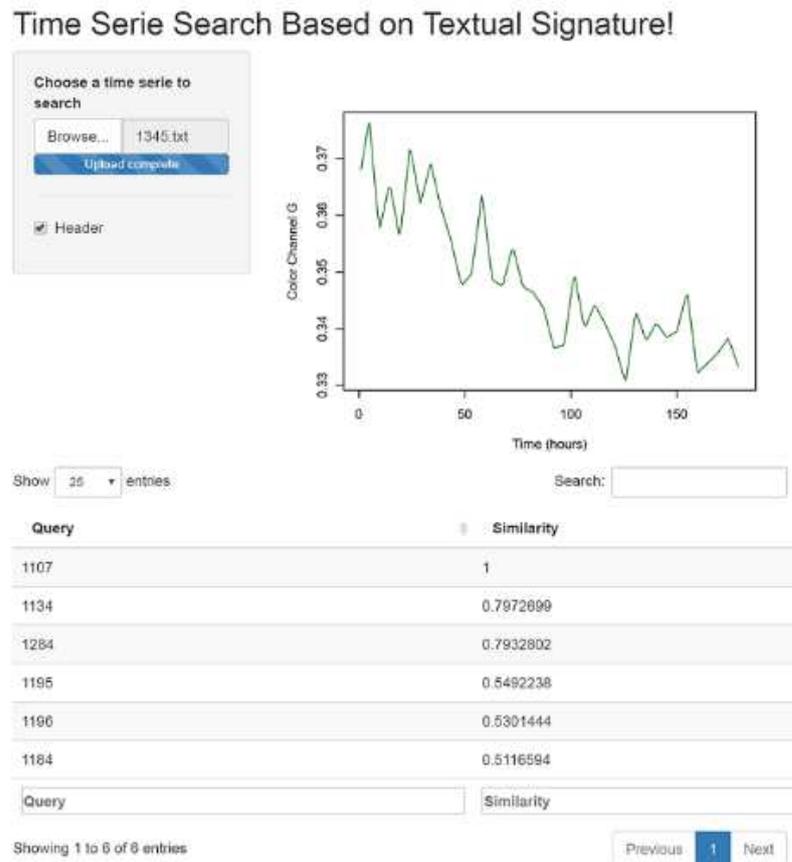


Figura 4.3: Exemplo de uma consulta com a série 1345 e das séries retornadas nas primeiras posições. Neste exemplo, foi realizada uma reamostragem com 180 pontos.

As duas configurações foram selecionadas de acordo com algumas observações feitas durante os experimentos. Na primeira configuração, definimos a utilização das séries originais para testar o comportamento do nosso dataset sem alterações. Selecionamos algumas posições do descritor HOG e algumas do LBP para obter somente as características mais marcantes de cada série. Em seguida, particionamos a imagem em regiões e blocos para obter uma boa descrição da imagem. Utilizando essa configuração, bons resultados foram observados. No entanto, observamos que a configuração de blocos combinados em regiões priorizava mais a região central da imagem RP.

Com base nas nossas observações, nós criamos uma segunda configuração, com maior número de pontos e particionamento somente em blocos para observar o comportamento de séries maiores quando não se considera a região central com maior destaque. Empiricamente nós definimos certa quantidade de pontos para LBP e HOG e com base no

trabalho de Vidal [58], nós definimos o particionamento extremo. A partir disso, nós observamos que as séries com maior número de pontos e particionadas em muitos blocos conseguem uma melhor precisão nos resultados. O particionamento extremo permite extrair melhor as características da imagem, isso porque com ele a imagem RP é dividida (ver Capítulo 3.4 – Figura 3.4) de modo que todas as regiões da imagem, ou seja, todos os instantes de tempo da série temporal tenham a mesma importância. À medida que a o número de pontos da série é aumentado, aumenta a resolução da imagem de *Recurrence plot* (RP) e o HOG consegue observar melhor os padrões e representar melhor as recorrências, por isso a precisão dos experimentos melhoram.

Em relação aos descritores, nós observamos que o desempenho do HOG funciona melhor com séries originais, enquanto o HOG aumentou o desempenho com séries reamostradas. Isso se deve ao fato que o LBP trabalha com a forma e intensidade da vizinhança, então em um espaço menor, ele consegue extrair melhor as características. O HOG tem um comportamento diferente. A forma e a aparência de um objeto descrito pelo HOG podem ser caracterizados muitas vezes pela intensidade dos gradientes ou a direção das bordas, e uma medida de intensidade em uma região maior da imagem pode ser utilizada para normalizar todos os valores do histograma, o que pode resultar em melhor invariância quanto a mudanças em iluminação [48, 52]. Isso nos explica formalmente o que já havíamos observado empiricamente, ou seja, quanto maior a imagem melhor será o desempenho do HOG.

Passando essa explicação para um nível mais prático, mostraremos alguns exemplos visuais dos nossos experimentos. Por exemplo, com séries reamostradas, o Hog demonstrou um excelente desempenho no canal de Cor Rcc as 18pm (ver Tabela 4.2). A Figura 4.4 mostra o *Recurrence plot* (RP) de uma série de consulta reamostrada com 180 pontos, do Canal de cor Rcc às 18 horas.

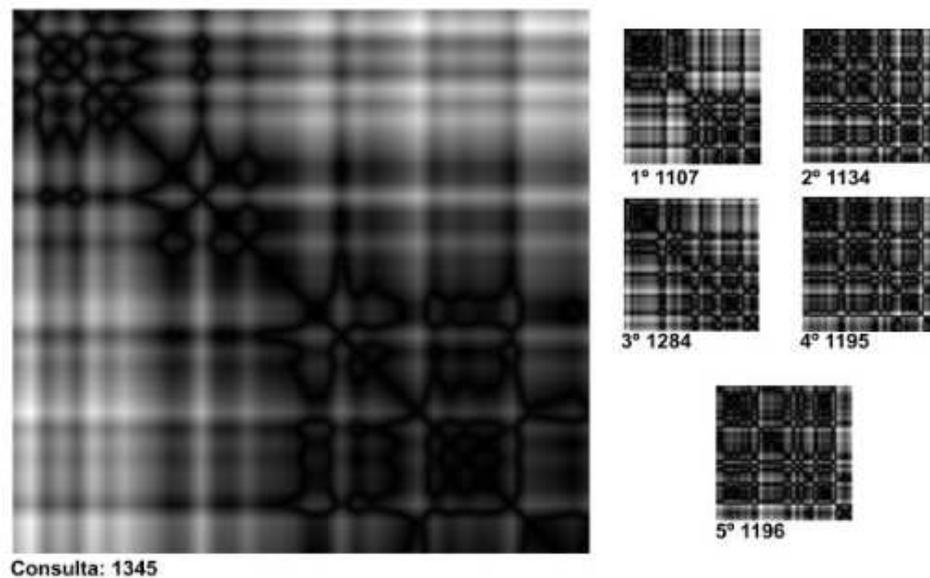


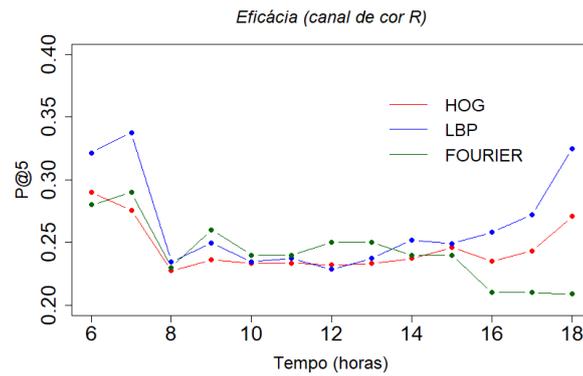
Figura 4.4: Exemplo de imagem RP em nível de cinza para a série de consulta 1345 do canal de cor RCC às 18 horas. As imagens à esquerda são os resultados de imagens RPs das séries retornadas nas primeiras posições da consulta, considerando-se uma reamostragem com 180 pontos.

4.3.2 Comparação com *Baselines*

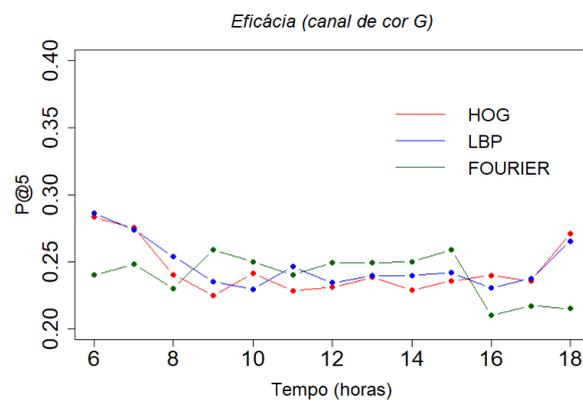
Esta seção apresenta os resultados obtidos pelo método proposto, assim como dos *baselines*.

4.3.2.1 Avaliação da Eficácia

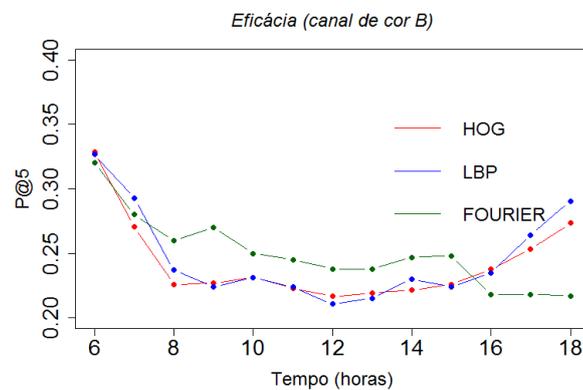
A Figura 4.5 apresenta os resultados da eficácia com as séries temporais de Fenologia, considerando a **Configuração 1**. Os resultados da eficácia em termos de Precision @ 5, considerando as séries temporais de Rcc, Gcc e Bcc das 6h às 18h. Em todos os casos, geralmente, resultados mais eficazes são observados no início da manhã e no final da tarde, independentemente dos descritores usados (HOG ou LBP). Resultados similares foram observados em outros estudos [2, 3, 15]. Além disso, os resultados observados para o descritor LBP foram superiores aos observados do HOG, considerando as curvas Rcc. Em relação aos resultados para as séries temporais Gcc e Bcc, os resultados do LBP e HOG são similares.



(a) Rcc.



(b) Gcc.



(c) Bcc.

Figura 4.5: Precisão @5 para os índices de vegetação (a) Rcc, (b) Gcc, e (c) Bcc, considerando a **Configuração 1**.

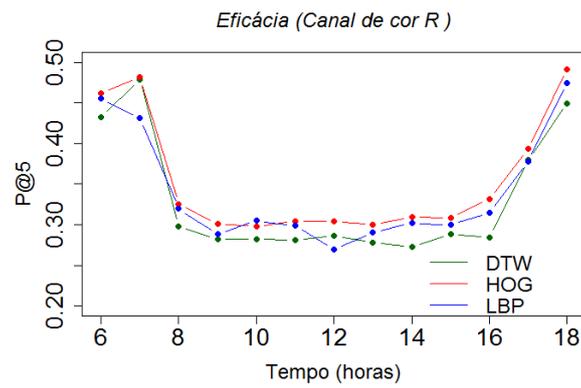
A Tabela 4.1 compara os resultados da eficácia o uso do sistema de recuperação de séries temporais de Rcc, Gcc e Bcc com os resultados do *baseline*. O *baseline* considerado neste estudo é baseado no uso da abordagem de descrição da forma de Fourier [46] para caracterizar séries temporais associadas a índices de vegetação. Este método produziu os melhores resultados na avaliação de abordagens de descrição de forma para caracterização de séries temporais apresentadas em [15]. A tabela apresenta as médias do Precision @ 5 juntamente com a hora do dia relacionada ao melhor desempenho.

Tabela 4.1: Resultados da eficácia em termos de Precision@5, considerando a **Configuração 1**.

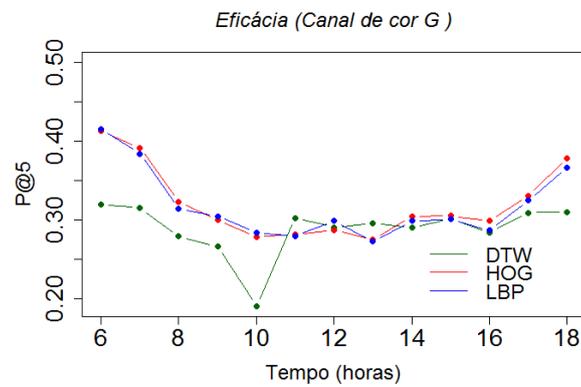
	Rcc	Gcc	Bcc
LBP	0.338 (7am)	0.286 (6am)	0.327 (6am)
HOG	0.290 (6am)	0.283 (6am)	0.329 (6am)
Fourier [15]	0.290 (7am)	0.249 (6am)	0.320 (6am)

Como podemos observar, independentemente do índice de vegetação, o esquema de busca proposto produziu os melhores resultados (destacados em negrito). O LBP foi mais eficaz para o Rcc e o Gcc, enquanto o HOG teve o melhor desempenho para o índice Bcc. Os testes estatísticos indicam que: o LBP 07am é estatisticamente melhor que HOG 06am para o Rcc; em relação ao Gcc, os melhores resultados foram observados para o LBP 12am; por fim, resultados estatisticamente superiores foram observados para o HOG 6am para as séries Bcc.

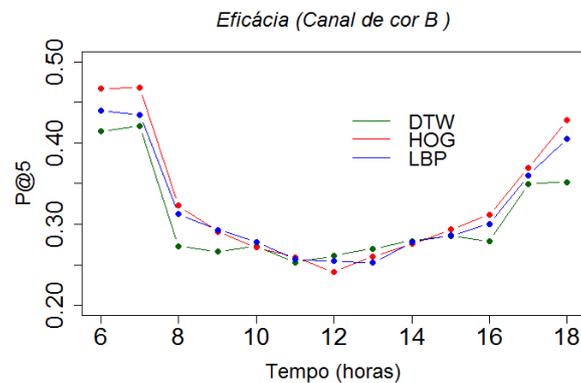
A Figura 4.6 apresenta os resultados da eficácia com as séries temporais de Fenologia, considerando a **Configuração 2**. A figura mostra os resultados de eficácia em termos de Precision @ 5, considerando as séries temporais de Rcc, Gcc e Bcc das 6h às 18h. Como pode ser observado, o uso de reamostragem com mais pontos levou a resultados mais eficazes. Por exemplo, o resultado observado para o HOG (Rcc) aumentou de 0,2709 para 0,4915, comparando-se os valores de $P@5$ para as 18 horas.



(a) Rcc.



(b) Gcc.



(c) Bcc.

Figura 4.6: Precisão @5 para os índices de vegetação (a) Rcc, (b) Gcc, e (c) Bcc, considerando a **Configuração 2**.

A Tabela 4.2, por sua vez, compara os resultados da eficácia para diferentes tipos de séries temporais. A tabela apresenta as médias de Precision @ 5 juntamente com a hora do dia relacionada ao melhor desempenho. O *baseline* considerado neste estudo é baseado no uso da abordagem *Dynamic time warping* (DTW) para comparação direta das séries temporais associadas a índices de vegetação.

Como podemos observar, independentemente do índice de vegetação, o esquema de busca proposto produziu os melhores resultados (destacados em **negrito**). O HOG foi

Tabela 4.2: Resultados da eficácia em termos de Precision@5 (Comparação com outros métodos da literatura), considerando a **Configuração 2**.

	Rcc	Gcc	Bcc
LBP	0.4749(18pm)	0.4146(6am)	0.4397(6am)
HOG	0.4915(18pm)	0.4131(6am)	0.4678(7am)
DTW	0.4784(7am)	0.3196(6am)	0.4211(7am)

mais eficaz para o Rcc e o Bcc, enquanto o LBP teve o melhor desempenho para o índice Gcc. Os testes estatísticos indicam que: o HOG 18pm é estatisticamente melhor que LBP 18pm para as séries Rcc; para as séries Gcc, LBP 06am teve melhor eficácia do que HOG 06am; por fim, para as séries Bcc, HOG 07am teve o melhor desempenho.

4.3.3 Avaliação da Eficiência

A Figura 4.7 apresenta resultados relacionados a aspectos de eficiência das séries temporais de fenologia. Este gráfico mostra o tempo médio em milissegundos para processar uma consulta. O desempenho do sistema de pesquisa aumenta com o número de séries temporais indexadas. O uso do descritor LBP leva aos resultados mais eficientes. Esses resultados são ainda mais impressionantes, uma vez que não foi usado uma máquina potente nos experimentos realizados.

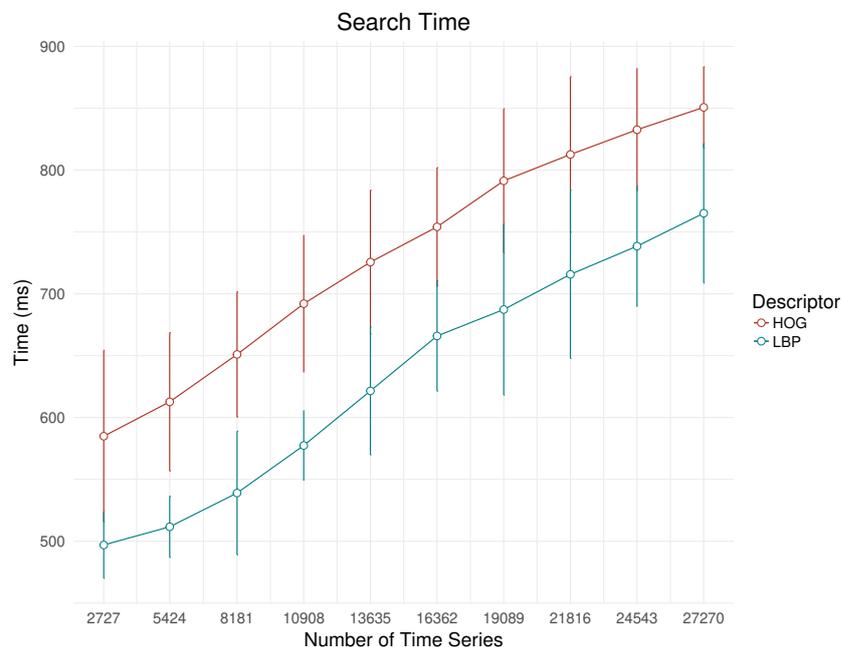


Figura 4.7: Tempo médio de resposta (em ms) para diferentes números de séries temporais de fenologia.

4.3.4 Discussão

Nesta dissertação, apresentamos um arcabouço para implementação de sistemas de buscas de séries temporais que explora representações bidimensionais baseadas em RPs e técnicas

de recuperação de informação. Na avaliação realizada, investigaram-se diferentes formulações para instanciação do arcabouço. Dois descritores de textura, HOG e LBP, foram explorados na caracterização de propriedades visuais das imagens de RPs. O objetivo foi caracterizar padrões texturais codificados nestas imagens que representam padrões das série temporais de entrada. A validação considerou o uso de séries temporais associadas a índices de vegetação extraídos de imagens de vegetação empregadas em análises fenológicas.

Tanto a implementação utilizando-se LBP, quanto aquela usando HOG levaram a resultados de eficácia superiores àqueles observados por *baselines*. Estes resultados sugerem que a investigação de abordagens apropriadas para caracterização de propriedades visuais de imagens de RPs constitui um caminho promissor de pesquisa. Neste sentido, o uso de algoritmos de extração de features baseados em redes convolucionais [10, 29, 30, 53, 56, 57], estado da arte na representação de objetos multimídia, se apresenta como um caminho natural.

Os resultados obtidos, considerando-se o uso de uma amostragem para geração de séries mais longas, foram superiores àqueles relacionados ao uso de séries originais curtas. Estes resultados sugerem que padrões visuais de imagens de RPs são mais representativos em imagens de maior resolução. O arcabouço proposto, desta forma, parece mais promissor para cenários envolvendo o processo de buscas de séries temporais longas.

Em relação à eficiência, ambos os descritores foram eficientes e tiveram resultados escaláveis. Entretanto, o descritor HOG teve em geral melhor desempenho em termos de eficiência, em parte devido ao tamanho pouco maior do vetor/assinatura associada ao descritor LBP. Estes resultados sugerem que o uso de tecnologias consolidadas na área de Recuperação de Informação é viável para implementação de sistemas de buscas de séries temporais. Por outro lado, estudos mais aprofundados, considerando coleções de séries temporais ainda maiores [7], se fazem necessários.

4.4 Considerações Finais

Neste capítulo, nós apresentamos a avaliação experimental dos nossos experimentos, mostrando em termos práticos os resultados do nosso trabalho. O protocolo experimental apresenta a nossa base de dados, os critérios que utilizamos para avaliar o trabalho, o tipo de comparação utilizado e quais forma nossos *baselines*. Em resultados experimentais e análises nós discutimos utilização dos descritores HOG e LBP, apresentamos as nossas comparações com *baselines* e discutimos avaliações da eficácia e eficiência do nosso sistema.

Capítulo 5

Conclusão

5.1 Considerações Finais

A fenologia vegetal é área que estuda eventos recorrentes do ciclo de vida das plantas e é um componente principal para a compreensão do impacto das mudanças climáticas nas plantas. Estudos nessa área tipicamente estão associados à análise de mudanças das plantas ao longo tempo. Boa parte destes estudos é baseada no uso e análise de séries temporais. Em fenologia, a análise de séries temporais longas com base na identificação de padrões similares e diferentes é uma tarefa muito comum, mas difícil. [3]

Um dos desafios é que não é possível indexar facilmente os dados de séries temporais longa, ou seja, em parte por conta da dificuldade de extrair as características discriminativas representativas para o problema-alvo. Aspectos de eficiência também são desafiadores. Características extraídas devem ser indexadas de forma a acelerar o processo de busca. Neste cenário, nem sempre a indexação de características extraídas de séries temporais é um processo simples. Este trabalho buscou tratar destes dois desafios simultaneamente.

Em aplicações de eScience, existe uma enorme necessidade do desenvolvimento de técnicas para gerenciar grandes coleções de séries temporais. Em especial, o apoio a buscas de similaridade de séries temporais pode ser crucial para aplicações de diversos domínios, que envolve grandes quantidades de séries. Isso é especial verdade para no que diz respeito à busca de séries temporais no contexto da fenologia – nossa aplicação-alvo –, em especial em tarefas de reconhecimento de plantas.

Nesta dissertação, nós abordamos o problema de busca de séries temporais sob uma nova perspectiva. Introduzimos o uso de tecnologias de recuperação de informação (do inglês *information retrieval* – IR) na busca de séries temporais. A solução envolve quatro etapas principais: extração de uma representação de série temporal baseada em imagem; descrição do conteúdo da imagem para codificar propriedades e padrões de séries temporais; extração da assinatura textual baseada em descrições de conteúdo da imagem; e indexação da assinatura textual usando abordagens de IR disponíveis no mercado. Tratamos a eficácia a partir do uso de descritores visuais robustos aplicados a representações de séries temporais em *Recurrence Plot*; e abordamos a eficiência por meio do uso de técnicas de indexação disponíveis no mercado. Isso faz a nossa solução simples e flexível para ser usada em diferentes contextos.

Este capítulo sumariza as principais contribuições do trabalho, assim como aponta

direções para trabalhos futuros.

5.2 Principais Contribuições

Em resumo, as principais contribuições do trabalho são:

1. Proposta de um arcabouço para busca de séries temporais baseada em assinaturas textuais. A novidade da pesquisa consiste na combinação da **eficácia** de algoritmos de processamento de imagens na caracterização de propriedades visuais de representações de séries temporais com a **eficiência** de soluções existentes na área de Recuperação de Informação na indexação de assinaturas textuais.
2. Avaliação de diferentes esquemas para construção de assinaturas textuais a partir de representações de séries temporais.

Parte dos resultados apresentados nesta dissertação foram reportados em artigo científico [51], publicado nos anais da IEEE Geoscience and Remote Sensing Symposium (IGARSS 2019).

5.3 Trabalhos Futuros

A pesquisa realizada abre oportunidades de pesquisa voltadas por exemplo:

- ao uso de assinaturas obtidas a partir de descritores baseadas em técnicas de aprendizado profundo: A área de visão computacional tem se beneficiado de representações de imagem aprendidas utilizando-se redes convolucionais profundas [10, 29, 30, 53, 56, 57]. Esta frente de pesquisa diz respeito à investigação destas técnicas na obtenção de assinaturas textuais de séries temporais.
- à avaliação do arcabouço proposto em outras aplicações. A validação realizada considerou séries temporais associadas a dados fenológicos. A solução proposta, por outro lado, é genérica e potencialmente pode beneficiar aplicações que dependem de sistemas de busca em outros domínios (por exemplo, séries temporais associadas a variáveis climatológicas ou séries temporais de finanças). A investigação do uso do arcabouço proposto em outros domínios constitui caminho de pesquisa promissor.
- à avaliação de abordagens para combinação de descritores de imagem: No trabalho de [21], investigou-se a obtenção de assinaturas textuais a partir da combinação de vetores de características associados a diferentes algoritmos de processamento de imagem (por exemplo, voltados para caracterizar propriedades de cor e textura). Investigações acerca da combinação de múltiplos descritores na construção de assinaturas textuais no contexto de problemas de busca de séries temporais se fazem necessárias.

- à avaliação de outras representações baseadas em imagens para séries temporais: Representações alternativas, na forma de imagem, ao uso de Recurrence Plot têm sido investigadas recentemente [60], com bons resultados em vários domínios. Uma frente de pesquisa promissora consiste na avaliação de mecanismos para extração de assinaturas textuais destas representações, visando à construção de sistemas de busca de séries temporais mais eficientes e eficazes. Novamente, estratégias para fusão de assinaturas textuais poderiam ser investigadas.

Referências Bibliográficas

- [1] Bruna Alberton, Jurandy Almeida, Raimund Helm, Ricardo da S. Torres, Annette Menzel, and Leonor Patricia Cerdeira Morellato. Using phenological cameras to track the green up in a cerrado savanna and its on-the-ground validation. *Ecological Informatics*, 19(0):62 – 70, January 2014. [43](#)
- [2] Jurandy Almeida, Jefersson A. dos Santos, Bruna Alberton, Ricardo da S. Torres, and Leonor Patricia C. Morellato. Applying machine learning based on multiscale classifiers to detect remote phenology patterns in cerrado savanna trees. *Ecological Informatics*, 23(0):49 – 61, 2014. Special Issue on Multimedia in Ecology and Environment. [43](#), [48](#)
- [3] Jurandy Almeida, Jefersson A. dos Santos, Waner O. Miranda, Bruna Alberton, Leonor Patricia C. Morellato, and Ricardo da S. Torres. Deriving vegetation indices for phenology analysis using genetic programming. *Ecological Informatics*, 26, Part 3:61 – 69, 2015. [11](#), [48](#), [54](#)
- [4] Anthony Bagnall, Ann Ratanamahatana, Eamonn Keogh, Stefano Lonardi, and Gareth Janacek. A bit level representation for time series data mining with shape based similarity. *Data Mining and Knowledge Discovery*, 13(1):11–40, 2006. [30](#)
- [5] Nurjahan Begum, Liudmila Ulanova, Jun Wang, and Eamonn Keogh. Accelerating dynamic time warping clustering with a novel admissible pruning strategy. In *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pages 49–58. ACM, 2015. [31](#)
- [6] Vitaly Bergelson. The multifarious poincaré recurrence theorem. *Descriptive Set Theory and Dynamical Systems*, pages 31–57, 2000. [16](#)
- [7] Alessandro Camerra, Jin Shieh, Themis Palpanas, Thanawin Rakthanmanon, and Eamonn Keogh. Beyond one billion time series: indexing and mining very large time series collections with i SAX2+. *Knowledge and Information Systems*, 39(1):123–151, 2014. [31](#), [53](#)
- [8] Chris Chatfield. *The analysis of time series: an introduction*. CRC Press, Florida, US, 6th edition, 2004. [14](#)
- [9] Daniel Yoshinobu Takada Chino. *Mineração de padrões frequentes em séries temporais para apoio à tomada de decisão em agrometeorologia*. PhD thesis, Universidade de São Paulo, 2014. [10](#), [14](#)

- [10] François Chollet. Xception: Deep learning with depthwise separable convolutions. *CoRR*, abs/1610.02357, 2016. [53](#), [55](#)
- [11] José Conti, Fabio A. Faria, Jurandy Almeida, Bruna Alberton, Leonor Patrícia Morellato, Luis Camolesi, and Ricardo da Silva Torres. Evaluation of time series distance functions in the task of detecting remote phenology patterns. In *22nd International Conference on Pattern Recognition*, pages 3126–3131, Stockholm, Sweden, Aug 2014. [14](#), [31](#)
- [12] José Carlos Conti. Eficácia de medidas de similaridade para a classificação de séries temporais associadas ao comportamento fenológico de plantas. Master’s thesis, Faculdade de Tecnologia (FT- UNICAMP), 2 2013. [10](#)
- [13] Ederlon Barbosa Cruz. Representação de séries temporais usando descritores de forma aplicados a recurrence plots. Master’s thesis, Universidade Estadual de Campinas (UNICAMP), 2 2016. [11](#), [12](#), [14](#), [16](#), [24](#), [39](#), [43](#)
- [14] Ricardo da S. Torres and Alexandre X. Falcão. Content-based image retrieval: Theory and applications. *Revista de Informática Teórica e Aplicada (RITA)*, 13(2):161–185, 2006. [18](#), [19](#)
- [15] Ricardo da S. Torres, Makoto Hasegawa, Salvatore Tabbone, Jurandy Almeida, Jeffersson A. Santos, Bruna Alberton, and Leonor Patrícia Morellato. Shape-based time series analysis for remote phenology studies. In *Geoscience and Remote Sensing Symposium (IGARSS), 2013 IEEE International*, pages 3598–3601, July 2013. [24](#), [45](#), [48](#), [49](#), [50](#)
- [16] Navneet Dalal and Bill Triggs. Histograms of oriented gradients for human detection. In *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2005), 20-26 June 2005, San Diego, CA, USA*, pages 886–893, 2005. [19](#), [37](#), [39](#)
- [17] Petrina de Assis da Silva Kimura. Um descritor baseado em análise local de cor para busca de imagens em grandes coleções. Master’s thesis, Universidade Federal do Amazonas (UFAM), 2 2011. [19](#), [26](#), [27](#)
- [18] Diego Guimarães de Brito Costa. Uso de gráfico de recorrência e redes complexas para caracterização de sistemas complexos de baixa dimensão. Master’s thesis, Instituto Nacional de Pesquisas Espaciais (INPE), 7 2014. [15](#), [16](#)
- [19] Joyce Miranda dos Santos. *Descritores de imagens baseados em assinatura textual*. PhD thesis, Universidade Federal do Amazonas (UFAM), 11 2016. [11](#), [18](#), [26](#), [27](#), [36](#)
- [20] Joyce Miranda dos Santos, Edleno Silva de Moura, Altigran Soares da Silva, Joao Marcos B. Cavalcanti, Ricardo da Silva Torres, and Márcio Luiz A. Vidal. A signature-based bag of visual words method for image indexing and search. *Pattern Recognition Letters*, 65:1 – 7, 2015. [27](#)

- [21] Joyce Miranda dos Santos, Edleno Silva de Moura, Altigran Soares da Silva, and Ricardo da S. Torres. Color and texture applied to a signature-based bag of visual words method for image retrieval. *Multimedia Tools and Applications*, 76(15):16855–16872, August 2017. [19](#), [26](#), [28](#), [29](#), [33](#), [36](#), [37](#), [55](#)
- [22] J-P Eckmann, S Oliffson Kamphorst, and David Ruelle. Recurrence plots of dynamical systems. *EPL (Europhysics Letters)*, 4(9):973, 1987. [16](#)
- [23] Fabio A. Faria, Jurandy Almeida, Bruna Alberton, Leonor Patricia C. Morellato, and Ricardo da S. Torres. Fusion of time series representations for plant recognition in phenology studies. *Pattern Recognition Letters*, 83(Part 2):205 – 214, November 2016. [12](#), [15](#), [31](#)
- [24] Fabio A. Faria, Jurandy Almeida, Bruna Alberton, Leonor Patricia C. Morellato, Anderson Rocha, and Ricardo da Silva Torres. Time series-based classifier fusion for fine-grained plant species recognition. *Pattern Recognition Letters*, 81:101–109, October 2016. [12](#), [15](#), [31](#)
- [25] Apache Software Foundation. Apache lucene core, 2019. [Online; accessed 19-Agosto-2019]. [32](#)
- [26] Tak-chung Fu. A review on time series data mining. *Engineering Applications of Artificial Intelligence*, 24(1):164–181, 2011. [10](#), [30](#)
- [27] Jean Dickinson Gibbons and Subhabrata Chakraborti. Nonparametric statistical inference marcel dekker. *Inc. New York*, 2003. [44](#)
- [28] Laurent Guigues, Jean Pierre Cocquerez, and Hervé Le Men. Scale-sets image analysis. *International Journal of Computer Vision*, 68(3):289–317, 2006. [43](#)
- [29] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. *CoRR*, abs/1512.03385, 2015. [53](#), [55](#)
- [30] Gao Huang, Zhuang Liu, and Kilian Q. Weinberger. Densely connected convolutional networks. *CoRR*, abs/1608.06993, 2016. [53](#), [55](#)
- [31] Eamonn Keogh. Fast similarity search in the presence of longitudinal scaling in time series databases. In *Tools with Artificial Intelligence, 1997. Proceedings., Ninth IEEE International Conference on*, pages 578–584. IEEE, 1997. [30](#)
- [32] Eamonn Keogh, Kaushik Chakrabarti, Michael Pazzani, and Sharad Mehrotra. Locally adaptive dimensionality reduction for indexing large time series databases. *ACM Sigmod Record*, 30(2):151–162, 2001. [30](#)
- [33] Eamonn Keogh and Michael J. Pazzani. A simple dimensionality reduction technique for fast similarity search in large time series databases. In *Pacific-Asia Conference on Knowledge Discovery and Data Mining*, pages 122–133. Springer, 2000. [30](#), [31](#)

- [34] Petrina A. S. Kimura, João M. B. Cavalcanti, Patrícia C. Saraiva, Ricardo da S. Torres, and Marcos André Gonçalves. Evaluating retrieval effectiveness of descriptors for searching in large image databases. *Journal of Information and Data Management (JIDM)*, 2(3):305–320, 2011. [26](#)
- [35] Petrina AS. Kimura, João MB. Cavalcanti, Patricia C. Saraiva, Ricardo da S. Torres, and Marcos A. Gonçalves. Evaluating retrieval effectiveness of descriptors for searching in large image databases. *Journal of Information and Data Management*, 2(3):305, 2011. [19](#), [26](#)
- [36] Sangjun Lee, Dongseop Kwon, and Sukho Lee. Dimensionality reduction for indexing time series based on the minimum distance. *Journal of Information Science and Engineering*, 19(4):697–711, 2003. [30](#)
- [37] Stef Lhermitte, Jan Verbesselt, Willem W Verstraeten, and Pol Coppin. A comparison of time series similarity measures for classification and change detection of ecosystem dynamics. *Remote Sensing of Environment*, 115(12):3129–3152, 2011. [31](#)
- [38] Satya Mallick. Histogram of oriented gradients, 2016. [Online; accessed 27-Outubro-2018]. [20](#), [21](#), [22](#), [23](#), [24](#)
- [39] Norbert Marwan, M. Carmen Romano, Marco Thiel, and Jürgen Kurths. Recurrence plots for the analysis of complex systems. *Physics reports*, 438(5):237–329, 2007. [15](#), [16](#)
- [40] Michael McCandless, Erik Hatcher, and Otis Gospodnetic. *Lucene in Action, Second Edition: Covers Apache Lucene 3.0*. Manning Publications Co., Greenwich, CT, USA, 2010. [37](#)
- [41] Nathalia Menini, Alexandre Esteves Almeida, Rubens A. C. Lamparelli, Gueric Le Maire, Jefersson A. Santos, Helio Pedrini, Marina Hirota, and Ricardo da S. Torres. A soft computing framework for image classification based on recurrence plots. *IEEE Geoscience and Remote Sensing Letters*, 16(2):320–324, Feb 2019. [12](#)
- [42] Abdullah Mueen and Eamonn Keogh. Extracting optimal performance from dynamic time warping. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pages 2129–2130. ACM, 2016. [31](#), [32](#)
- [43] Mario A Nascimento and Vishal Chitkara. Color-based image retrieval using binary signatures. In *Proceedings of the 2002 ACM symposium on Applied computing*, pages 687–692. ACM, 2002. [36](#)
- [44] T. Ojala, M. Pietikainen, and T. Maenpaa. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7):971–987, Jul 2002. [24](#), [25](#), [26](#), [37](#), [39](#)

- [45] Timo Ojala, Matti Pietikäinen, and David Harwood. A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, 29(1):51–59, 1996. [24](#), [25](#)
- [46] E. Persoon and K. Fu. Shape Discrimination Using Fourier Descriptors. *IEEE Transactions on Systems, Man, and Cybernetics*, 7(3):170–178, 1977. [49](#)
- [47] Henri Poincaré. Sur le probleme des trois corps et les équations de la dynamique. *Acta mathematica*, 13(1):A3–A270, 1890. [15](#), [16](#)
- [48] Ana Carolina Correia Rézio et al. Super-resolução de imagens baseada em aprendizado utilizando descritores de características. Master’s thesis, Universidade Estadual de Campinas (UNICAMP), 2 2011. [47](#)
- [49] Andrew D Richardson, Julian P Jenkins, Bobby H Braswell, David Y Hollinger, Scott V Ollinger, and Marie-Louise Smith. Use of digital webcam images to track spring green-up in a deciduous broadleaf forest. *Oecologia*, 152(2):323–334, 2007. [43](#)
- [50] Gerard Salton and M. J. McGill. *Introduction to Modern Information Retrieval*. McGraw-Hill, 1983. [37](#), [38](#)
- [51] Elisangela Silva Santos, Bruna Alberton, Leonor Patricia Morellato, and Ricardo da Silva Torres. An information retrieval approach for large-scale time series retrieval. In *IEEE International Geoscience and Remote Sensing Symposium*, pages 254–257, Yokohama, Japan, July 2019. [55](#)
- [52] Thiago S. Santos, Kelson RT. Aires, RV. Romuere, Kalyf AB. Silva, Rodrigo MS. Veras, and André CB. Soares. Histograma de gradientes orientados na detecção de motocicletas. [47](#)
- [53] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *CoRR*, abs/1409.1556, 2014. [53](#), [55](#)
- [54] Everton Granemann Souza. Caracterização de sistemas dinâmicos através de gráficos de recorrência. Master’s thesis, Universidade Federal do Paraná (UFPR), 8 2008. [16](#)
- [55] Vinicius M. A. Souza, Diego F. Silva, and Gustavo Batista. Extracting texture features for time series classification. In *Pattern Recognition (ICPR), 2014 22nd International Conference on*, pages 1425–1430. IEEE, 2014. [15](#), [31](#)
- [56] Christian Szegedy, Sergey Ioffe, and Vincent Vanhoucke. Inception-v4, inception-resnet and the impact of residual connections on learning. *CoRR*, abs/1602.07261, 2016. [53](#), [55](#)
- [57] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jonathon Shlens, and Zbigniew Wojna. Rethinking the inception architecture for computer vision. *CoRR*, abs/1512.00567, 2015. [53](#), [55](#)

- [58] Márcio Vidal, João M. B. Cvalcanti, Edleno S. Moura, Altigran S. Silva, and Ricardo da S. Torres. Sorted dominant local color for searching large and heterogeneous image databases. In *21st International Conference on Pattern Recognition (ICPR)*, pages 1960–1963, Tsukuba Science City, Japão, Nov 2012. [47](#)
- [59] Marcio Luís Assis Cavalcanti Vidal. *Um Descritor de Imagens baseado em Particionamento Extremo para Busca em Bases Grandes e Heterogêneas*. PhD thesis, Universidade Federal do Amazonas (UFAM), 8 2013. [27](#), [36](#)
- [60] Zhiguang Wang and Tim Oates. Imaging time-series to improve classification and imputation. *CoRR*, abs/1506.00327, 2015. [56](#)
- [61] Zhijia Yang and Guangzhou Zhao. Application of symbolic techniques in detecting determinism in time series [and emg signal]. In *Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE*, volume 5, pages 2670–2673. IEEE, 1998. [30](#), [32](#)
- [62] Ricardo Baeza Yates and Berthier Ribeiro-Neto. *Modern Information Retrieval*. Addison-Wesley, 1a edição edition, 1999. ISBN 978-02-01398-29-8. [44](#)
- [63] Chin-Chia Michael Yeh, Yan Zhu, Liudmila Ulanova, Nurjahan Begum, Yifei Ding, Hoang Anh Dau, Diego Furtado Silva, Abdullah Mueen, and Eamonn Keogh. Matrix profile i: all pairs similarity joins for time series: a unifying view that includes motifs, discords and shapelets. In *2016 IEEE 16th international conference on data mining (ICDM)*, pages 1317–1322. IEEE, 2016. [32](#)
- [64] Jesin Zakaria, Abdullah Mueen, Eamonn Keogh, and Neal Young. Accelerating the discovery of unsupervised-shapelets. *Data mining and knowledge discovery*, 30(1):243–281, 2016. [30](#), [31](#)
- [65] Yan Zhu, Zachary Zimmerman, Nader Shakibay Senobari, Chin-Chia Michael Yeh, Gareth Funning, Abdullah Mueen, Philip Brisk, and Eamonn Keogh. Exploing a novel algorithm and gpus to break the ten quadrillion pairwise comparisons barrier for me series mofs and joins. *Knowledge and Information Systems*, 54(1):203–236, 2018. [31](#), [32](#)