

Aprendizado de representações e caracterização de redes complexas com aplicações em visão computacional

Lucas Correia Ribas¹, Odemir Martinez Bruno²

¹Instituto de Ciências Matemáticas e de Computação (ICMC) - Universidade de São Paulo (USP)
Av. Trab. São Carlense, 400 – Centro, São Carlos – SP, 13566-590

²Instituto de Física de São Carlos (IFSC) - Universidade de São Paulo (USP)
Av. Trab. São Carlense, 400 – Centro, São Carlos – SP, 13566-590

lucascorreiaribas@gmail.com, bruno@ifsc.usp.br

Abstract. *This work aims to investigate and propose new modeling and characterization techniques for complex networks focusing on application to computer vision problems. Regarding modeling, an efficient and optimized approach to map texture images and videos into directed complex networks was studied. Regarding the characterization, new ways of characterizing complex networks were investigated, with emphasis on the use of randomized neural networks to representation learning, resulting in several proposed methods for analyzing gray-level, color and dynamic textures and shape analysis. Promising results have been achieved by the developed methods in comparison to literature methods in image classification tasks using several benchmark datasets. Additionally, to assess the potential of the developed methods, five applications were investigated in real problems in the areas of biology, botany, physical-chemistry and medicine, achieving interesting results and contributing to the development of these areas.*

Resumo. *Este trabalho apresenta um resumo da tese de doutorado que tem como objetivo investigar e propor novas técnicas de modelagem e caracterização de redes complexas focando na aplicação em problemas de visão computacional. Em relação à modelagem, foi estudada uma abordagem eficaz e otimizada para mapear as imagens e vídeos de texturas em redes complexas direcionadas. A respeito da caracterização, novas formas de caracterizar as redes complexas foram investigadas, com destaque para o uso de redes neurais randomizadas para aprendizado de representações, resultando em vários métodos propostos para análise de texturas em níveis de cinza, coloridas e dinâmicas e análise de formas. Resultados promissores foram alcançados pelos métodos desenvolvidos em comparação aos métodos da literatura em tarefas de classificação de imagens/vídeos usando vários conjuntos de dados que são referência. Adicionalmente, para avaliar o potencial dos métodos desenvolvidos, foram investigadas cinco aplicações em problemas reais nas áreas de biologia, botânica, físico-química e medicina, alcançando resultados interessantes e contribuindo para o desenvolvimento destas áreas.*

1. Introdução

Ao longo de séculos, o paradigma de pesquisa na ciência foi pautado por uma abordagem reducionista dos dados, em que cada disciplina científica era estudada individual-

mente [Miranda et al. 2016]. Por outro lado, mais recentemente, suportado pelos avanços científicos e tecnológicos, computadores com alto poder de processamento e armazenamento foram desenvolvidos, contribuindo com a explosão na quantidade de dados disponíveis. Como consequência desses avanços, surge uma alta demanda pelo desenvolvimento de abordagens multidisciplinares e integrativas que englobem várias áreas da ciência. Nesse sentido, a ciência das redes complexas (RCs) tem se destacado como uma alternativa ao modelo reducionista devido ao seu carácter multidisciplinar e capacidade de representar e estudar qualquer estrutura natural, sistemas e dados complexos [Ribas 2021].

Os fundamentos teóricos da área de redes complexas surgem com base na interseção de conceitos da teoria dos grafos, física, mecânica estatística e ciência da computação. Assim, esse novo campo de pesquisa não somente apenas estende o formalismo de grafos, mas também propõe métricas e técnicas embasadas em propriedades reais de sistemas complexos para estudá-los [Costa et al. 2007]. Um dos principais interesses nas pesquisas que envolvem a área é em como modelar o dado ou sistema de interesse em uma rede para, em seguida, realizar uma análise das suas propriedades topológicas por meio de um conjunto de medidas [Costa et al. 2007]. Em relação à modelagem, a questão está em: como a partir de um conjunto de indivíduos ou elementos, estabelecer o relacionamento entre estes, visando construir um conjunto de relações ou arestas. Em muitos casos, a própria definição dos elementos que serão atribuídos aos vértices é uma tarefa desafiadora, que precisa ser otimizada. No que tange à análise topológica, diversos estudos têm proposto medidas que extraem características da estrutura de redes com a finalidade de compreender e explicar o funcionamento dos sistemas construídos sobre estas, possibilitando o reconhecimento de padrões intrínsecos [Ribas 2021].

Atualmente, com a introdução da ciência dos dados e da Era de “*Big Data*”, há uma necessidade por métodos de reconhecimento de padrões que lidam com dados formados por relações não-lineares, tornando as redes complexas uma ferramenta importante em diversas áreas que necessitam de reconhecimento de padrões, tais como, visão computacional [Scabini et al. 2017, Ribas et al. 2020], atribuição de autoria [Machicao et al. 2018], reconstrução filogenética [Banerjee and Jost 2008], entre outros. O reconhecimento de padrões baseado em redes complexas visa classificar um conjunto de redes em várias classes e distingui-las de acordo com suas características intrínsecas [Banerjee and Jost 2008, Miranda et al. 2016]. Em visão computacional, técnicas baseadas em redes complexas têm sido empregadas, com sucesso em diversos problemas, como uma medida de irregularidade e complexidade [Backes 2010]. Apesar desses resultados promissores, novas técnicas de modelagem mais rápidas e simples que melhorem a captura da complexidade das imagens precisam ser investigadas mais profundamente. Além disso, em termos de caracterização, o desenvolvimento de técnicas mais sofisticadas pode permitir o aprimoramento da descrição topológica das redes complexas em comparação com medidas clássicas mais simples.

Por outro lado, o grande volume de dados, a crescente complexidade dos problemas a serem processados computacionalmente e a elevada capacidade dos recursos computacionais atualmente disponíveis, são fatores que também favorecem a expansão da área de aprendizado de máquina [Gama et al. 2011]. Nessa área, a pesquisa com técnicas de redes neurais artificiais tem atraído crescente interesse da comu-

nidade científica e de empresas. Esse recente interesse foi motivado, principalmente, pelos excelentes resultados dos modelos de redes neurais profundas, que são ferramentas poderosas empregadas em diferentes problemas, tais como, processamento de áudio [Purwins et al. 2019], processamento de linguagem natural [Young et al. 2018], visão computacional [Szegedy et al. 2017], entre outras. Esses resultados, e o potencial integrativo e multidisciplinar das redes complexas, também motivaram pesquisas para a combinação de ambas as ferramentas para reconhecimento de padrões [Xin et al. 2018].

Na literatura, as redes neurais têm sido amplamente utilizadas para aprendizado automático de representações ou características em diversos tipos de dados. Tais representações se diferem de abordagens mais tradicionais, como as baseadas em RCs, que produzem atributos conhecidos como *handcrated* [Simon and Uma 2020]. Em relação aos métodos denominados *handcrated*, os atributos são computados por modelos matemáticos, estatísticos ou técnicas projetadas manualmente para descrever determinados aspectos do dado em questão, permitindo uma compreensão dos mecanismos relativa ao funcionamento da caracterização [Nanni et al. 2017]. De outro modo, no aprendizado de representações por redes neurais, as camadas ocultas são treinadas com grandes quantidades de dados e aprendem a extrair as principais características que descrevem o problema, variando das mais básicas até as mais específicas [Ribas 2021].

Com o propósito de se aproveitar da capacidade de aprendizado de características sofisticadas das redes neurais, nesta tese, as Redes Neurais Randomizadas (em inglês, *Randomized Neural Network* (RNN)) [Schmidt et al. 1992, Pao et al. 1994, Huang et al. 2006] foram investigadas como uma nova ferramenta para melhorar a caracterização das redes complexas. Em contraste com as técnicas de redes neurais profundas, a RNN se destaca pela simplicidade (uma camada oculta), algoritmo de aprendizado rápido e bom desempenho de classificação, mesmo com poucos dados de treinamento [Sá Junior and Backes 2016]. Isso torna essa rede neural uma excelente opção para o aprendizado de representações das RCs visando a sua caracterização, mantendo propriedades desejáveis nas técnicas desenvolvidas como simplicidade, rápido processamento e utilização de poucos dados. Esta seção apresenta a motivação, conceitos, objetivos e contribuições que estão detalhadas no Capítulo 1 da tese.

1.1. Objetivos

O objetivo principal desta tese é o estudo, a proposta e análise de métodos para modelagem e caracterização de redes complexas com foco em problemas de visão computacional. Na modelagem, foram estudadas novas formas de mapear as texturas em RCs direcionadas e ponderadas. Para a caracterização das redes complexas, propôs-se a investigação das seguintes metodologias: métricas clássicas, RNNs e autômatos de rede. Os métodos desenvolvidos para os problemas de visão computacional foram avaliados em aplicações de biologia, botânica, físico-química e medicina.

Resumidamente, os objetivos desta tese são:

- investigar e analisar os métodos da literatura de reconhecimento de padrões baseado em RCs e, quando possível, propor melhorias. Nesse sentido, foram propostas duas melhorias: (i) padrões binários em autômatos de rede (LLNA-BP) para caracterização de RCs e (ii) redes de transformada da distância para análise de formas;

- estudo e desenvolvimento de técnicas de modelagens simples e otimizadas para mapear texturas em níveis de cinza, colorida e dinâmicas em redes complexas;
- propor métodos para caracterização de RCs baseados em representações aprendidas com RNN, combinando, assim, ambas as metodologias;
- avaliar e comparar os métodos propostos com trabalhos da literatura;
- aplicar os métodos desenvolvidos em problemas reais.

Uma visão geral do desenvolvimento do trabalho é apresentada na Figura 1. Os dados são modelados como redes complexas e, em seguida, é realizada a sua caracterização com uma das metodologias consideradas. Com base nesse fluxo, métodos para diversas tarefas foram desenvolvidos e, depois, aplicados em diferentes problemas reais. A cor da seta representa um fluxo específico da metodologia usada para desenvolver os métodos.

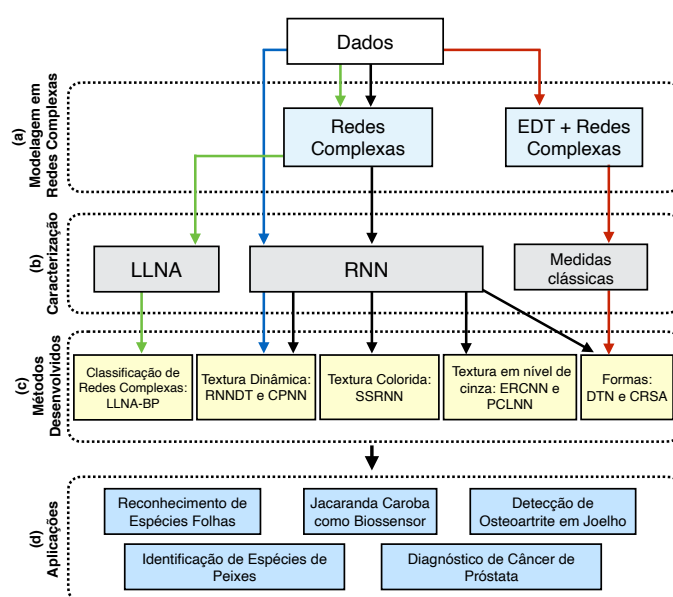


Figura 1. Visão geral do desenvolvimento do trabalho. As setas representam o fluxo metodológico para o desenvolvimento dos métodos, em que cada cor representa um tipo de abordagem [Ribas 2021].

1.2. Contribuições

A investigação de novas formas de modelagem e caracterização de redes complexas permitiu contribuições nos âmbitos teóricos e práticos, como mostrado na Figura 1 (c)-(d). Isto proporcionou uma multidisciplinaridade ao trabalho, resultando em diversas contribuições tanto computacionais como em outras áreas da ciência que podem ser assim sumarizadas:

- desenvolvimento de modelagens rápidas e simples que mapeiam texturas em níveis de cinza, coloridas e dinâmicas para RCs direcionadas e ponderadas;
- desenvolvimento de novas abordagens para análise de texturas que utilizam redes neurais randomizadas para caracterizar RCs por meio de representações aprendidas, que entregam baixo custo computacional combinado com altas acurácias;
- proposta de dois métodos que empregam RNNs e RCs para caracterização de texturas dinâmicas, que superam métodos da literatura em complexidade e taxa de classificação;

- desenvolvimento de dois métodos de análise de formas baseados na combinação de redes complexas com transformada da distância e RNNs, que são robustos à ruído e invariantes à escala e rotação;
- caracterização e classificação de redes complexas gerais usando uma melhoria do método LLNA que emprega dicionários de padrões binários nos diagramas de padrões de evolução temporal, melhorando a taxa de acurácia de classificação;
- aplicações dos métodos desenvolvidos para estudar cinco problemas reais das áreas de biologia, botânica, físico-química e médica.

2. Desenvolvimento e Resultados

Esta seção apresenta um breve resumo dos principais resultados do trabalho (detalhados nos Capítulos de 4 à 8 da tese), divididos em 3 partes (seções): (i) aprendizado de representações para texturas, nesse caso, são propostos novas estratégias de modelagens e novas formas de caracterização usando redes neurais; (ii) análise de formas, nessa parte, são apresentados dois métodos para análise de contorno de formas; (iii) aplicações em diversos problemas reais.

2.1. Aprendizado de representações usando RNN para texturas

Nesta seção, são apresentados os métodos desenvolvidos a partir da investigação de RNNs para aprendizado de representações de RCs. Esses métodos e resultados estão descritos no Capítulo 5 da tese. A Figura 2 mostra um diagrama geral dos métodos baseados em aprendizado de representação de RCs.

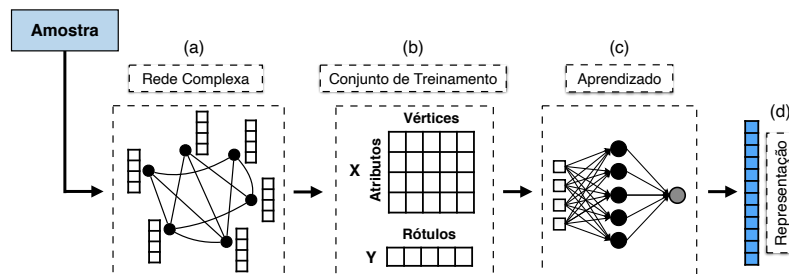


Figura 2. Diagrama geral do processo de aprendizado de representações de RCs empregado nos métodos desenvolvidos no doutorado [Ribas 2021].

Textura Cinza: Aprendizado de Representações da Evolução de Redes Complexas (ERCNN): Esta abordagem proposta e os resultados estão descritos no artigo publicado no periódico *Pattern Recognition* [Ribas et al. 2020]. Para esta abordagem, um novo modelo de RCs direcionadas mapeando uma textura em níveis de cinza foi desenvolvido usando apenas 1 parâmetro (raio de conexão r). A abordagem proposta consiste em empregar RNNs para o aprendizado de representações a partir da dinâmica de evolução das RCs construídas com diferentes valores de raio r . É importante enfatizar que nessa abordagem, a RNN é treinada usando como entrada e saída características de uma única amostra de textura. Assim, para cada vértice é construído um vetor de atributos (que também pode ser entendido como uma abordagem *node2vec*) para compor a matriz de entrada e a intensidade de nível de cinza é utilizado como o rótulo no processo de aprendizado da RNN. Dessa forma, a representação da textura será composto pelos pesos treinados da camada de saída da RNN, que codifica as principais características da dinâmica da RC

e, conseqüentemente, da propriedades de textura. Os resultados em 4 bases de dados de textura demonstraram que o método produz representações altamente discriminativas, superando diversos métodos da literatura em termos de acurácia. Além disso, o método demonstrou ser robusto quanto à rotação e possuir baixo tempo computacional.

Textura Cinza: Aprendizado de Representações usando Padrões Locais Complexos (PLCNN): Nesta segunda abordagem desenvolvida, a ideia também é caracterizar a topologia das RCs modeladas usando RNNs como no método anterior, entretanto, o foco é na análise dos padrões locais dos pixels/vértices. Para tanto, propõe-se uma maneira diferente para construir os vetores de entrada dos vértices e seus respectivos rótulos a partir das RCs. Essa proposta aplica janelas de tamanho 3×3 na RC para construir a matriz de vetores de atributos de entrada para a rede neural. Os resultados alcançados são superiores ao método proposto anterior (ERCNN) e a outros métodos da literatura, incluindo métodos baseados em redes neurais convolucionais.

Textura Colorida: Aprendizado de Representação Espaço-Espectral (SSRNN): Esta abordagem proposta para analisar imagens de textura colorida calcula uma representação espaço-espectral (em inglês, *Spatio-Spectral Representation*(SSR)) aprendida por RNNs a partir do modelo de RCs direcionada SSN. As imagens de textura colorida são modeladas como SSNs (redes espaço-espectral) direcionadas, que definem os pixels para todos os canais como vértices e criam conexões entre os mesmos e diferentes canais empregando uma vizinhança radialmente simétrica. A RNN é treinada a partir das métricas dos vértices (grau e força) para prever a dinâmica de evolução da SSN à medida que o raio r é variado, e os pesos aprendidos da camada de saída são usados como um vetor de características, chamado de representação espaço-espectral. Assim, a contribuição é uma caracterização discriminativa da SSN a partir da representação aprendida pela RNN, que realiza uma descrição das propriedades espaciais e espectrais da imagem colorida. Os resultados superaram vários métodos comparados nas três bases de dados, demonstrando que a abordagem proposta produz representações espaço-espectral altamente discriminativas e competitivas em comparação com as arquiteturas de CNN profundas. O potencial da abordagem proposta também é demonstrado na aplicação de caracterização da plasticidade foliar de espécies de Jacaranda Caroba como um biomarcador natural de poluentes.

Textura Dinâmica: Aprendizado de Representações de Três Planos Ortogonais: Essa abordagem foi proposta para análise de textura dinâmica (vídeos) baseada em representações aprendidas por RNNs. Primeiramente, o vídeo de textura dinâmica é dividido em três planos ortogonais. Para cada plano ortogonal, matrizes de vetores de entrada X e seus respectivos rótulos Y são construídos a partir de cada fatia. Essas matrizes de entrada e saída são submetidas as RNNs, e os pesos da camada de saída são usados como representação da fatia. Em seguida, a média dessas representações é a representação do plano ortogonal. Por último, a representação final é a concatenação das três representações do plano ortogonal. Os resultados alcançados pelo método superam vários métodos da literatura, inclusive baseados em redes neurais profundas. Outros aspectos interessantes dessa abordagem são tamanho pequeno do vetor de atributos gerado e também o baixo custo computacional. A abordagem desenvolvida e resultados foram publicados em [Sá Junior et al. 2019].

Textura Dinâmica: Aprendizado de Representações de Redes Complexas Espaço-Temporal (CPNN): Esta segunda abordagem desenvolvida para analisar textura dinâmica

emprega RNN para aprender características de RCs modeladas e foi publicada no periódico *Applied Soft Computing* [Ribas et al. 2022a]. Para tanto, usando uma textura dinâmica, a RNN pode ser treinada para prever o valor do nível de cinza de um pixel a partir da dinâmica de evolução de suas propriedades topológicas locais, fornecidas por medidas das RCs espaço \times tempo que modelam o vídeo com diferentes valores do parâmetro raio r . Assim como nas abordagens anteriores, o vetor de peso aprendido da camada de saída da RNN é usado para compor a representação do vídeo. As contribuições desta abordagem podem ser resumidas em: (i) uma modelagem mais simples do que em trabalhos anteriores [Gonçalves et al. 2015] e baseada em apenas um parâmetro (raio); (ii) uma representação robusta aprendida para caracterizar a RC usando RNN, ao invés de usar medidas estatísticas; e (iii) um descritor de textura dinâmica que fornece acurácia e tempo de processamento competitivos em comparação com métodos da literatura.

2.2. Análise de Formas

Esta seção apresenta duas técnicas propostas para análise de formas usando RCs, transformada da distância e RNNs que estão detalhadas no Capítulo 6 da tese.

Redes de Transformada da Distância para Análise de Formas (DTN). Abordagem para a extração de características de formas que foi publicada em [Ribas et al. 2019]. Diferentemente do método proposto por [Backes et al. 2009], neste trabalho, a transformada da distância Euclidiana (em inglês, *Euclidean Distance Transform* (EDT)) é aplicada na imagem de contorno e, em seguida, os pixels que pertencem a um dado raio de dilatação r são modelados como uma RC. As características de diferentes raios de dilatação são usadas para descrever o contorno da forma. Portanto, o método proposto adiciona informações sobre a propagação de ondas da EDT no contorno. Resultados em bases de dados de formas genéricas e de folhas demonstraram que o método é competitivo em relação a outros métodos tradicionais da literatura. Além disso, o método demonstrou ser uma interessante opção para a aplicação de reconhecimento de peixes baseado no contorno do otólito.

Aprendizado de Representações Complexas por meio de RNNs em Mapas de Características Topológicas (CRSA): Nesse segundo trabalho de análise de formas, um método foi proposto com base em representações complexas aprendidas empregando RNNs em mapas de características topológicas obtidos a partir de um esquema de modelagem de contorno em RCs. Neste método, o contorno da forma é modelado como uma rede complexa considerando cada ponto como um vértice e conectando todos os vértices por arestas. Em seguida, mapas de características topológicas derivados da dinâmica de evolução da RC são calculados, estes são correlacionados às características físicas do contorno da forma. As RNNs são empregadas nos mapas de características usando uma abordagem de janela deslizante para aprender as representações. Os pesos treinados da camada de saída da RNN formam uma representação que é empregada em tarefas de classificação. Os resultados de classificação em bases de planta e de peixe demonstraram que o método produz representações altamente discriminativas para descrever formas, superando métodos comparados da literatura e sendo robusto a transformações.

2.3. Aplicações

Neste trabalho, métodos desenvolvidos foram aplicados em colaboração com outros pesquisadores na solução de cinco problemas reais de diferentes áreas. Estas aplicações, que

estão descritas no Capítulo 8 da tese, são:

- **Reconhecimento de Espécies de Peixes baseado no Contorno do Otólito:** os métodos de análise de formas desenvolvidos foram aplicados na classificação de espécies de peixes baseada no contorno do otólito. Essa tarefa é difícil devido à similaridade nas características morfológicas na forma do otólito das diferentes espécies, sendo elas diferenciadas por detalhes. Os resultados demonstram que os métodos propostos podem ser uma boa ferramenta para caracterização do otólito, pois atingem altas acurácias na classificação de espécies e famílias de peixes.
- **Análise de Plasticidade Foliar de Jacaranda Caroba como biossensor natural de poluentes:** neste estudo, foi investigado a possibilidade de usar a espécie de Jacaranda Caroba como um biossensor natural de poluentes. Para tanto, foi analisado a plasticidade foliar de imagens hiperespectrais capturadas por microscopia das folhas da planta expostas a diferentes condições de poluição (pulverização de fluoreto de potássio (KF)). Em diferentes experimentos, os métodos demonstraram um bom desempenho de classificação, com destaque para o método de texturas coloridas, sugerindo serem uma boa alternativa para o problema.
- **Diagnóstico de Câncer de Próstata por meio de Imagens de Genossensores:** nos últimos anos, esforços têm sido realizados para o desenvolvimento de técnicas de detecção para diferentes doenças, como o câncer de próstata, uma doença geralmente assintomática, em que a detecção tardia faz com que esta seja uma das principais causas de morte em homens em países industrializados [Ibau et al. 2017]. Para tanto, trabalhos têm investigado vários tipos de biossensores para a obtenção de testes de baixo custo e a exploração de novos nanomateriais. Neste estudo, publicado em [Rodrigues et al. 2021], os métodos de análise de imagens de textura e aprendizado de máquina foram aplicados em imagens microscópicas dos genossensores (um tipo de biossensor), demonstrando ser uma promissora metodologia para detecção e diagnóstico de câncer de próstata. Ao contrário das abordagens padrão que envolvem análise de imagem da própria amostra biológica, este trabalho usa a imagem da unidade de detecção. Até onde se sabe, este trabalho [Rodrigues et al. 2021] é o primeiro que aplica análise de texturas e aprendizado de máquina nas imagens de genossensores para fins de detecção.
- **Detecção de Osteoartrite Precoce de Joelho por meio de Imagens de raio-X:** foi investigado a aplicação de métodos de análise texturas em imagens de raio-X para detecção precoce de OA em joelho. As imagens de raio-X são adquiridas de forma simples e com baixo custo, além de ser facilmente compreendidas, o que é importante para uma aplicação robusta e barata. Este trabalho é fruto da cooperação com o grupo de pesquisa da Universidade de Orleans (França) liderado pelo prof. Rachid Jennane, que já resultou na seguinte publicação [Ribas et al. 2022b]. De modo geral, os métodos desenvolvidos de texturas em níveis de cinza demonstraram ser uma boa opção para aplicação na detecção precoce de OA de joelhos, alcançando resultados promissores.
- **Reconhecimento de Espécies de Plantas baseado em Análise de Textura Foliar:** os métodos de análise de texturas são aplicados para identificação de espécies de plantas. Essa tarefa é desafiadora devido à variação de padrões texturais e de cor dentro de uma mesma espécie ou até mesmo de uma mesma folha, além da similaridade de características entre diferentes espécies e de variações que podem ser resultado de diversos fatores tais como exposição a chuva, clima, sol etc.

Portanto, neste estudo, os métodos são testados para caracterizar a textura foliar de imagens escaneadas de plantas. Os métodos propostos conseguiram atingir mais uma vez as maiores acurácias de classificação em ambos os tipos de imagem (em nível de cinza e RGB). Assim, os resultados demonstram a capacidade de caracterização e robustez dos métodos propostos mesmo em um problema real e complexo, tornando-os ferramentas interessantes para o desenvolvimento de sistemas automatizados de baixo custo computacional para identificar espécies de plantas.

3. Conclusões

A modelagem e caracterização de RCs permanecem como tópicos de pesquisa desafiadores, sendo amplamente investigados por cientistas, apesar dos diversos trabalhos que têm sido reportados ao longo das duas últimas décadas. À luz dos resultados alcançados, de forma mais ampla, acredita-se que este trabalho oferece uma contribuição relevante para a área de RCs e com o novo e promissor campo de pesquisa que estuda como conectar redes neurais artificiais e RCs para reconhecimento de padrões. Tais resultados motivam investigações futuras que explorem modelos de RCs e arquiteturas mais sofisticadas de RNN para reconhecimento de padrões. Além disso, os métodos desenvolvidos com base nessas ferramentas proporciona importantes contribuições para as áreas de visão computacional estudadas (análise de texturas em níveis de cinza, coloridas e dinâmicas, e análise de formas), motivando pesquisas futuras com essas metodologias. Por fim, a multidisciplinaridade inerente do trabalho também resultou em contribuições em termos práticos para as áreas de visão computacional, biologia, botânica, físico-química e médica.

Referências

- Backes, A. R. (2010). *Estudos de métodos de análise de complexidade em imagens*. Doutorado em Ciências Matemáticas e de Computação, ICMC - Universidade de São Paulo, São Carlos.
- Backes, A. R., Casanova, D., and Bruno, O. M. (2009). A complex network-based approach for boundary shape analysis. *Pattern Recognition*, 42(1):54–67.
- Banerjee, A. and Jost, J. (2008). Spectral plot properties: Towards a qualitative classification of networks. *NHM*, 3(2):395–411.
- Costa, L. d. F., Rodrigues, F., Traviesso, G., and Boas, P. R. V. (2007). Characterization of complex networks: A survey of measurements. *Advances in Physics*, 56(1):167–242.
- Gama, J., Faceli, K., Lorena, A., and De Carvalho, A. (2011). *Inteligência artificial: uma abordagem de aprendizado de máquina*. Grupo Gen - LTC.
- Gonçalves, W. N., Machado, B. B., and Bruno, O. M. (2015). A complex network approach for dynamic texture recognition. *Neurocomputing*, 153:211 – 220.
- Huang, G.-B., Zhu, Q.-Y., and Siew, C.-K. (2006). Extreme learning machine: theory and applications. *Neurocomputing*, 70(1):489–501.
- Ibau, C., Arshad, M. M., and Gopinath, S. C. (2017). Current advances and future visions on bioelectronic immunosensing for prostate-specific antigen. *Biosensors and Bioelectronics*, 98:267–284.
- Machicao, J., Corrêa, E. A., Miranda, G. H. B., Amancio, D. R., and Bruno, O. M. (2018). Authorship attribution based on life-like network automata. *PLOS ONE*, 13(3):e0193703.

- Miranda, G. H. B., Machicao, J., and Bruno, O. M. (2016). Exploring spatio-temporal dynamics of cellular automata for pattern recognition in networks. *Scientific Reports*, 6(37329).
- Nanni, L., Ghidoni, S., and Brahnam, S. (2017). Handcrafted vs. non-handcrafted features for computer vision classification. *Pattern Recognition*, 71:158–172.
- Pao, Y.-H., Park, G.-H., and Sobajic, D. J. (1994). Learning and generalization characteristics of the random vector functional-link net. *Neurocomputing*, 6(2):163–180.
- Purwins, H., Li, B., Virtanen, T., Schlüter, J., Chang, S.-Y., and Sainath, T. (2019). Deep learning for audio signal processing. *IEEE Journal of Selected Topics in Signal Processing*, 13(2):206–219.
- Ribas, L. C. (2021). *Aprendizado de representações e caracterização de redes complexas com aplicações em visão computacional*. Doutorado em ciências de computação e matemática computacional, ICMC - Universidade de São Paulo.
- Ribas, L. C., de Mesquita Sá Junior, J. J., Manzanera, A., and Bruno, O. M. (2022a). Learning graph representation with randomized neural network for dynamic texture classification. *Applied Soft Computing*, 114:108035.
- Ribas, L. C., Neiva, M. B., and Bruno, O. M. (2019). Distance transform network for shape analysis. *Information Sciences*, 470:28 – 42.
- Ribas, L. C., Riad, R., Jennane, R., and Bruno, O. M. (2022b). A complex network based approach for knee osteoarthritis detection: Data from the osteoarthritis initiative. *Biomedical Signal Processing and Control*, 71:103133.
- Ribas, L. C., Sá Junior, J. J. M., Scabini, L. F., and Bruno, O. M. (2020). Fusion of complex networks and randomized neural networks for texture analysis. *Pattern Recognition*, 103:107189.
- Rodrigues, V. C., Soares, J. C., Soares, A. C., Braz, D. C., Melendez, M. E., Ribas, L. C., Scabini, L. F., Bruno, O. M., Carvalho, A. L., Reis, R. M., et al. (2021). Electrochemical and optical detection and machine learning applied to images of genosensors for diagnosis of prostate cancer with the biomarker pca3. *Talanta*, 222:121444.
- Sá Junior, J. J. M. and Backes, A. R. (2016). ELM based signature for texture classification. *Pattern Recognition*, 51:395–401.
- Sá Junior, J. J. M., Ribas, L. C., and Bruno, O. M. (2019). Randomized neural network based signature for dynamic texture classification. *Expert Systems with Applications*, 135:194–200.
- Scabini, L. F., Fistarol, D. O., Cantero, S. V., Gonçalves, W. N., Machado, B. B., and Rodrigues Jr, J. F. (2017). Angular descriptors of complex networks: A novel approach for boundary shape analysis. *Expert Systems with Applications*, 89:362–373.
- Schmidt, W. F., Kraaijveld, M. A., and Duin, R. P. W. (1992). Feedforward neural networks with random weights. In *Proceedings., 11th IAPR International Conference on Pattern Recognition. Vol.II. Conference B: Pattern Recognition Methodology and Systems*, pages 1–4.
- Simon, P. and Uma, V. (2020). Deep learning based feature extraction for texture classification. *Procedia Computer Science*, 171:1680–1687.
- Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A. A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. In *Thirty-First AAAI Conference on Artificial Intelligence*.
- Xin, R., Zhang, J., and Shao, Y. (2018). Complex network classification with convolutional neural network. *CoRR*, abs/1802.00539.
- Young, T., Hazarika, D., Poria, S., and Cambria, E. (2018). Recent trends in deep learning based natural language processing. *IEEE Computational Intelligence Magazine*, 13(3):55–75.