



ANÁLISE DE ARQUITETURAS DE REDES NEURAIS SIAMESAS PARA A CLASSIFICAÇÃO DE ESPÉCIES DE PLANTAS



Matheus Moresco (morescomatheus77@gmail.com)[1], Profº Dr. Alceu de Souza Britto Jr. (alceubritto@uepg.br)[1], Profº Dr. Yandre Maldonado e Gomes da Costa (yande@dim.uem.br)[2]
1[Universidade Estadual de Ponta Grossa - UEPG], 2[Universidade Estadual de Maringá - UEM]

WPCCG 2021

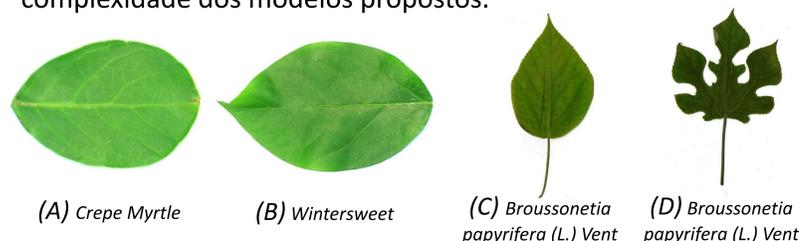
WPCCG 2021

RESUMO

- A classificação de plantas, em especial a que utiliza a imagem da folha, é tida como um grande desafio, devido ao grande número de espécies.
- Com o intuito de facilitar o processo de classificação de plantas, sistemas automáticos que usam técnicas de aprendizagem de máquina e visão computacional para diferenciar as espécies têm sido propostos.
- Redes Neurais Convolucionais (CNN) necessita de um grande número de imagens para realizar seu treinamento. Porém, o uso de tal ferramenta não permite a escalabilidade do modelo, de maneira que, caso uma nova classe seja adicionada, a rede precisa ser treinada novamente. Assim, uma alternativa interessante tem sido o uso de Redes Neurais Siamesas (SNN).
- A combinação de características extraídas de camadas intermediárias das SNNs pode ter um impacto positivo no desempenho do modelo.

PROBLEMA

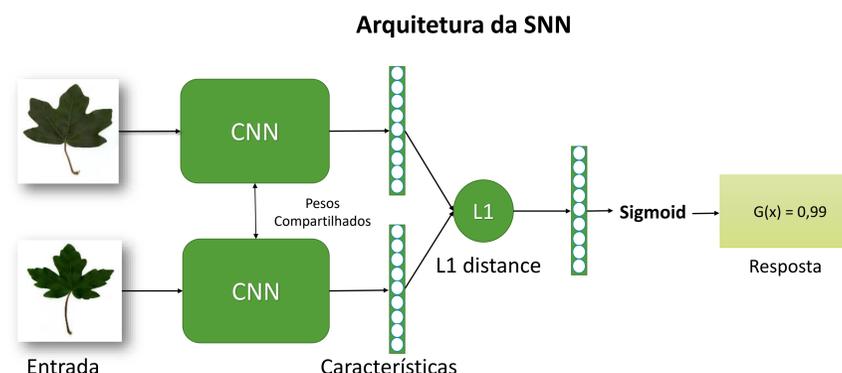
- Classificação em Subcategorias:** Visa classificar imagens de uma mesma classe geral em sub categorias, tornando a classificação mais difícil. Gerando na base:
 - Semelhança interespécie:** imagens de classes diferentes, tem forma, cor e textura semelhantes. Como ocorre nas imagens (A) e (B).
 - Variabilidade intraespécie:** imagens de diferentes cores e formas dentro da mesma classe. Como ocorre nas imagens (C) e (D).
- Dados desbalanceados:** Dificuldade de acesso e a raridade de determinadas espécies de plantas acabam deixando as classes correspondentes a essa espécie com poucos exemplos.
- Quantidade de espécies:** existem cerca de 391 mil espécies de plantas, o grande número de espécies existentes, aumenta a complexidade dos modelos propostos.



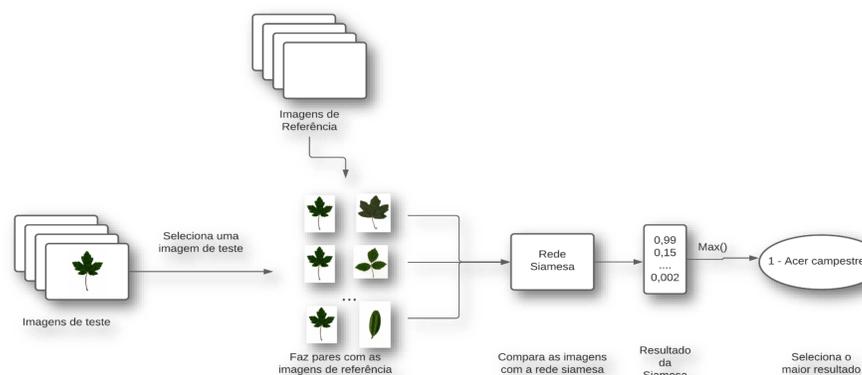
OBJETIVOS

- Desenvolver diferentes arquiteturas de Redes Neurais Siamesas para a classificação de espécies de plantas a partir da imagem da folha
- Investigar a combinação de características extraídas de camadas intermediárias das CNNs constituintes.

MODELO PROPOSTO



Processo de Classificação do Modelo



MÉTODOS

A fim de comparar diferentes arquiteturas de redes siamesas, o projeto foi organizado em 5 etapas:

- Escolha e treino da CNN:** Foi feito o *fine-tuning* das redes pré-treinadas.
- Definição do modelo interno da SNN:** Usar diferentes modelos pré-treinados na arquitetura da SNN.

- Uso de camadas intermediárias nas SNN:** Foram combinadas a características extraídas de camadas intermediárias da CNN constituinte. As redes foram divididas em blocos Convolucionais como mostra o exemplo da Figura 1.
- Avaliação das CNNs e SNNs com base de treino reduzida:** avaliar o desempenho das redes propostas em bases com poucos exemplos.
- Teste de escalabilidade:** serão removidas, aleatoriamente, n classes da base durante o treino e depois adicionadas novamente durante o teste.

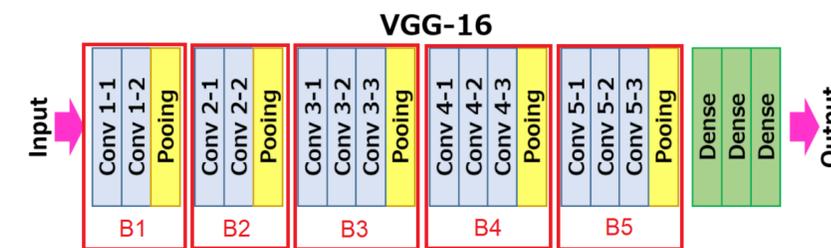


Figura 1 - Arquitetura de uma Rede neural VGG-16 dividida em Blocos.

RESULTADOS

- Experimentos realizados com as bases de imagens de folhas *Flavia* e considerando na estrutura da SNN as arquiteturas *DenseNet* e *VGG-16*, demonstram que a combinação de características extraídas de camadas intermediárias é promissora.
- O melhor resultado (99,82%) foi observado com o uso da *DenseNet*, e representou uma melhora de 0,35 pontos percentuais quando comparada a SNN convencional (99,47%) e 1,22 quando comparada a CNN-*DenseNet* (98,6%).

	CNN	SNN	SNN-Multicamdas
VGG-16	97,90%	97,73%	98,60%
DenseNet	98,60%	99,47%	99,82%

CONCLUSÕES

- A escolha da CNN interna de uma SNN influencia no desempenho da classificação.
- O uso de características multicamadas tem um impacto positivo no desempenho.
- O modelo da SNN permite a inserção de novas classes durante o teste, sem treinar o modelo novamente.