

Nuvens, Modelos e Imagens II

Palavras-Chave:

Inteligência Artificial, Modelos Computacionais, Processamento de Imagens

Autores/as:

Isadora Rodrigues de Toledo (Cotil - Colégio Técnico de Limeira)

João Victor de Oliveira Murer (Cotil - Colégio Técnico de Limeira)

Rafael Viana de Araújo (E.E. Castelo Branco)

Théo de Barros Assis (E.E. Brasil)

Prof. Dr. André F. de Angelis (orientador) [Unicamp]

INTRODUÇÃO:

Este trabalho é parte da pesquisa “Aplicações Científicas e Tecnológicas da Classificação de Imagens por Redes Neurais Convolucionais Profundas” (*Scientific and Technological Applications of Image Classification by Deep Convolutional Neural Networks*), que investiga a possibilidade do uso combinado de redes neurais profundas (*Deep Learning*), bancos de dados de séries temporais e imagens de satélite para resolver questões em aberto na área de previsão de vazões de rios e bacias hidrográficas, a saber:

- aprimorar modelos e técnicas de previsão;
- superar as limitações de confiabilidade, periodicidade e representatividade dos dados de entrada que alimentam os diferentes modelos de previsão de vazão.

Neste projeto PIBIC-EM, os alunos foram apresentados aos temas da pesquisa e seu estado corrente, aprenderam sobre as

questões envolvidas na investigação e desenvolveram habilidades de programação em Java.

O projeto contou com atividades teóricas de estudo, levantamento bibliográfico e nivelamento. No entanto, o ponto principal do projeto foi a criação de modelos para geração de imagens sintéticas e a análise dos resultados de classificação das imagens por uma ferramenta de Inteligência Artificial.

METODOLOGIA:

O projeto correu em duas frentes: uma para embasamento e contexto e a outra para a execução em si.

Embasamento

Inicialmente, fez-se um embasamento teórico sobre Ciência, Método Científico, Inteligência Artificial, Redes Neurais, Aprendizado de Máquina e Aprendizado

Profundo. O Código de Boas Prática de Pesquisa (FAPESP) foi usado para discutir a questão de ética na pesquisa. Realizou-se um estudo introdutório em computação sobre tópicos selecionados: computadores e sua arquitetura, sistemas operacionais, aplicações e linguagens de programação.

As pesquisas correntes do laboratório foram apresentadas aos bolsistas, incluindo os resultados obtidos por pós-graduandos e perspectivas, de modo que puderam compreender o contexto do seu projeto e entender qual o fluxo de trabalho esperado para sua integração.

Os bolsistas tiveram uma iniciação prática à programação, na qual foi introduzido IDE Eclipse, utilizando a linguagem de programação Java com o método de programação orientada a objetos (POO).

Execução

A execução do projeto partiu do estudo dos modelos já empregados na pesquisa, com vistas ao desenvolvimento de novos geradores para imagens semelhantes a nuvens vistas por satélites. Os bolsistas projetaram cada qual seu modelo seguindo o processo ilustrado no fluxograma da Fig. 1.

A codificação dos modelos geradores em Java foi feita pelo professor, dada a complexidade de integração com o software de controle Fisgen 2.0. Os bolsistas discutiram e analisaram individualmente os dados de eficiência de classificação das imagens pela ferramenta Nvidia Digits 6: o valor de acurácia da primeira classe (*Top-1 Accuracy*) e das 5 primeiras classes (*Top-5 Accuracy*).

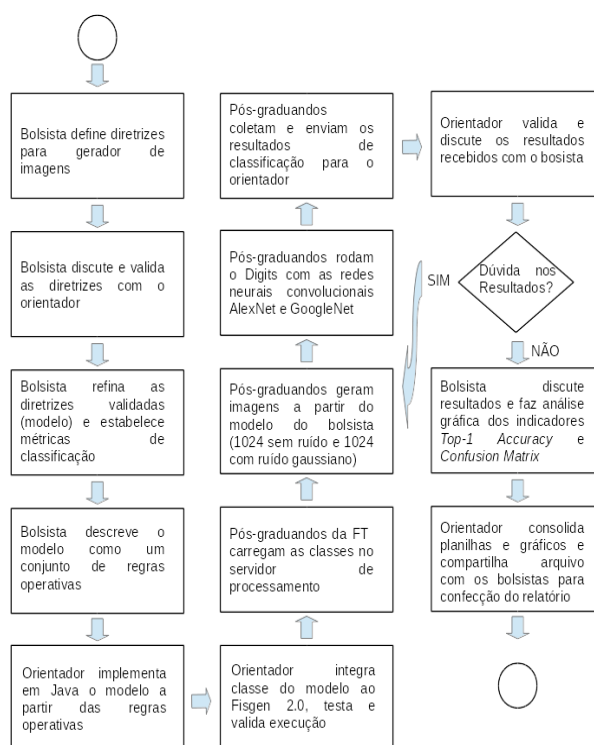


Fig. 1: Fluxograma de Trabalho

Na Fig. 2, são exemplificadas imagens geradas pelos modelos dos bolsistas Isadora, Rafael e Théo. Cada modelo implica uma métrica de classificação e teve um resultado por rede neural utilizada. Foram rodadas as rotinas para criação de dois conjuntos de 1.024 imagens de 256 x 256 pixels, um deles com e outro sem ruído. O ruído foi simulado na imagem pelo uso de 10% de pontos aleatoriamente distribuídos logo após a geração de cada figura. O Fisgen foi parametrizado para agrupar os rótulos de classificação em aproximadamente 10 categorias (intervalo real ficou em [10,11]).

O Digits foi parametrizado para usar 75% das imagens para treinamento e 25% para validação e executar o treinamento nas redes AlexNet e GoogleNet com 100 épocas. Os demais valores e hiperparâmetros permaneceram nos valores padrão (*defaults*).




Fig. 2: Oito imagens aleatoriamente selecionadas do conjunto de 1.024 geradas para os modelos *Gradient Cores Cloud* (acima), *Random White Cells* (meio) e *Diffuse Cores Clouds* (abaixo)

RESULTADOS E DISCUSSÃO:

Nesta seção estão apresentadas as discussões sobre a classificação das imagens de cada modelo pelo Digits.

Modelo Nuvem de Núcleos em Gradiente – *Gradient Cores Cloud* (Isadora)




Fig. 3: Principais dados de análise do modelo *Gradient Cores Cloud*

Vê-se na Figura 3 o valor dos indicadores de acurácia e percebe-se que houve saturação para *Top-5 Accuracy*, quando o classificador coloca corretamente a imagem em um conjunto de 5 classes mais prováveis. Na mesma figura, vê-se que a rede AlexNet apresentou pequena melhora com a inserção de ruído, enquanto a GoogleNet teve uma queda de desempenho mais sensível. A métrica de agrupamento do modelo é o número de núcleos presentes contra o fundo neutro.

Modelo Células Brancas Aleatórias – *Random White Cells* (Rafael)

A métrica de agrupamento do modelo é o número de núcleos circulares presentes contra o fundo preto.




Fig. 4: Principais dados de análise do modelo *Random White Cells*

Conforme a Figura 4, a rede AlexNet obteve acerto de 47,5% na presença de ruído e 65,4% sem ele no indicador *Top1-Accuracy*. A GoogleNet ficou próxima a 60% nas duas situações. Nenhuma delas conseguiu classificar corretamente todas as imagens entre os 5 grupos mais prováveis, possivelmente em função das sobreposições das áreas brancas.

Modelo Nuvem de Núcleos Difusos – *Diffuse Cores Clouds* (Théo)

Esse foi o modelo mais trabalhoso de se implementar, tendo em conta a difusão de cores a partir do centro de cada núcleo, feita de maneira suave conforme ilustrado no terço inferior da Fig. 2. A métrica de agrupamento do modelo é o número de núcleos presentes contra o fundo preto.




Fig. 5: Principais dados de análise do modelo *Gradient Cores Cloud*

Vê-se na Figura 5 que o desempenho das redes foi bastante similar em situações idênticas de presença ou ausência de ruídos.

Dada a similaridade estrutural deste modelo e do *Gradient Cores Cloud*, o desempenho da AlexNet se mostrou consistente para a métrica de agrupamento.

Resultados comparativos

A Figura 6 mostra o comparativo de todos os modelos em *Top-1* e *Top-5 Accuracy*, na ausência de ruído. Percebe-se que o primeiro indicador é fortemente afetado pelo modelo gerador das sequências de imagens, ou seja, pelo próprio conteúdo e métrica de agrupamento das imagens.




Fig. 6: Comparação dos indicadores de acurácia para os modelos discutidos

As redes se comportaram aproximadamente da mesma forma para 3

dos modelos, mantendo um desempenho superior a 60% em *Top-1* e praticamente 100% em *Top-5 Accuracy*. No entanto, o modelo *Random Gray Cells* foi mal reconhecido pela AlexNet e muito bem reconhecido pela GoogleNet. Neste caso particular, os experimentos foram repetidos e confirmaram este desempenho atípico. A AlexNet agrupa todas as imagens em uma única class, dentre as 10 desejadas, o que leva o valor de *Top-1 Accuracy* para próximo de 10%, que corresponde ao percentual de imagens que deveria estar naquela classe. O oposto ocorre com a GoogleNet, que discrimina muito bem as classes e faz um reconhecimento quase perfeito, mesmo em presença de ruído.

CONCLUSÕES:

O projeto foi concluído com sucesso, colaborando na formação dos bolsistas e contribuindo com as pesquisas em andamento pela ampliação do acervo de modelos geradores e pela análise das redes neurais profundas em sua classificação.

AGRADECIMENTOS

Ao CNPq e à Unicamp pelas bolsas PIBIC-EM; aos bolsistas BAS que colaboraram com o projeto:

- Bruno Carlos Oliveira da Silva
- Kallynne Yanne Rosa
- Leonardo Nicolas Bueno Rosa
- Mônica Eduarda Albuquerque Mariano

BIBLIOGRAFIA

- ANTONIO JOAQUIM SEVERINO. Metodologia do Trabalho Científico. Cortez. 2007. 23a. ed. 304p.
- BALLINI, R.; SOARES, S.; ANDRADE, M. G. Previsão de vazões médias mensais usando redes neurais nebulosas. Revista Controle & Automação, Vol. 14, no. 3, Julho de 2003.
- BENGIO, Y. Learning Deep Architectures for AI. Foundations and Trends in Machine Learning Vol. 2, No. 1 (2009) 1–127. DOI: 10.1561/22000000006
- DEITEL & DEITEL. Java: como programar. Prentice-Hall, 8a edição, 2010
- FAPESP. Código de Boas Práticas de Pesquisa. 2014.
- GOMES, C. F. L.; MONTENEGRO, S. M. G. L.; VALENÇA, M. J. S. Modelo baseado na técnica de redes neurais para previsão de vazões na bacia do rio São Francisco. Revista Brasileira de Recursos Hídricos, Vol. 15, no. 1, Janeiro/Março 2010.
- HASHEMA, I.A.; YAQOOBA, I.; ANUARA, N.B.; MOKHTARA, S.; GANIA, A.; KHANB, S.U. The rise of “big data” on cloud computing: Review and open research issues. Information Systems. Volume 47, January 2015, Pages 98–115. DOI: <https://doi.org/10.1016/j.is.2014.07.006>
- HIDALGO, I. G. Ferramentas e metodologia para consolidação de dados de usinas hidrelétricas brasileiras. Tese de Doutorado, FEEC/UNICAMP, 2009.
- JAGADISH, Y.H.V.; GEHRKE, J.; LABRINIDIS, A.; PPAKONSTANTINOY, Y.; PATEL, J.M.; RAMAKRISHNAN, R.; SHAHABI, C. Big data and its technical challenges. Communications of the ACM. Volume 57 Issue 7, July 2014. Pages 86-94. ACM New York, NY, USA. DOI: >10.1145/2611567
- LECUN, Y., BENGIO, Y., HINTON, G. Deep learning. Disponível em: <http://www.nature.com/nature/journal/v521/n7553/full/nature14539.html>. Acesso em: 02/05/2021.
- LIMA, Klebiano Kennedy da Silva et al. Desenvolvimento e comparação de redes neurais convolucionais para classificação de objetos. 2019.
- RAUL SIDNEI WAZLAWICK. Metodologia de Pesquisa para Ciência da Computação. Campus/Elsevier. 2009. 159p.
- ROCHA, T. Aplicação do SMAP para a bacia do Rio Tietê. (Dissertação de Mestrado). Faculdade de Tecnologia. Unicamp. 2015.
- ROCHA, T.; HIDALGO, I.G.; ANGELIS, A.F. de; LOPES, J.E.G. Hydrological simulation in the Tiete basin. 4th IAHR Europe Congress, Liege Belgium. July 2016.
- SCHMIDHUBER, J. Review - Deep learning in neural networks: An overview. Neural Networks 61 (2015) 85–117.
- SOUZA, Wanderson dos S.; SOUZA, Francisco de A. S. Rede neural artificial aplicada à previsão de vazão da bacia hidrográfica do rio Piancó. Revista Brasileira de Engenharia Agrícola e Ambiental, Vol. 14, no. 2, 2010.