

Nuvens, Modelos e Imagens III

Palavras-Chave: Modelos Computacionais, Redes Neurais, Aprendizado de Máquina

Davi Furtado de Fáveri (ETEC Trajano Camargo)

Guilherme Garcia Nallin (Colégio Técnico de Limeira)

Isabella Bergamin Freitas (Colégio Técnico de Limeira)

Prof. Dr. André F. de Angelis (orientador) (FT - Unicamp)

INTRODUÇÃO:

Este projeto se insere numa pesquisa de longo prazo 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 as questões em aberto na área de previsão de vazões de rios e bacias hidrográficas.

O objetivo geral do projeto foi integrar os alunos de Ensino Médio às pesquisas realizadas pelo docente e seus orientados de pós-graduação no tema de recuperação automática de informação com Inteligência Artificial (IA) aplicada a sequências de imagens sintéticas. O objetivo específico foi que os alunos desenvolvessem e implementassem computacionalmente modelos para a geração de imagens que se assemelhem a nuvens vistas por um satélite, do tipo daquelas empregadas nas pesquisas do Laboratório de Matemática Concreta.

METODOLOGIA:

No projeto, os bolsistas tiveram contato com as pesquisas em andamento e criaram modelos conceituais para geração de imagens,

posteriormente implementados em módulos Java (Modelos de Animação Gráfica - MAGs). Foram geradas sequências rotuladas de imagens que, por sua vez, foram submetidas à avaliação de uma ferramenta *deep learning* (Nvidia DIGITS). Os resultados foram analisados pelos bolsistas, através de textos e planilhas. A Fig. 1 apresenta o fluxograma geral do projeto, brevemente descrito a seguir.

Os bolsistas tiveram aulas e palestras curtas sobre o tema, estudaram publicações a respeito das pesquisas em andamento no laboratório e tiveram discussões com o professor e os monitores. Examinaram os trabalhos feitos pelos pós-graduandos e por equipes de projetos anteriores.

Eles criaram modelos conceituais das sequências de imagem que desejavam, utilizando rascunhos e experimentações diversas. Descreveram e refinaram os algoritmos de geração das imagens até o momento em que puderam implementados.

Foram codificadas quatro classes de modelos de animação gráfica e uma classe para estruturação do código. Essas classes implementam a interface *abstractGenerator* para o programa Fisgen, na versão 2.0.01, que

é um software para suporte à pesquisa e tem como função automatizar a geração de longas sequências de imagens rotuladas. Os rótulos das imagens individuais correspondem a uma ou mais métricas calculadas pelo programa em

função da figura gerada. A programação seguiu o paradigma da Orientação a Objetos e o código foi escrito em linguagem Java no ambiente Eclipse.

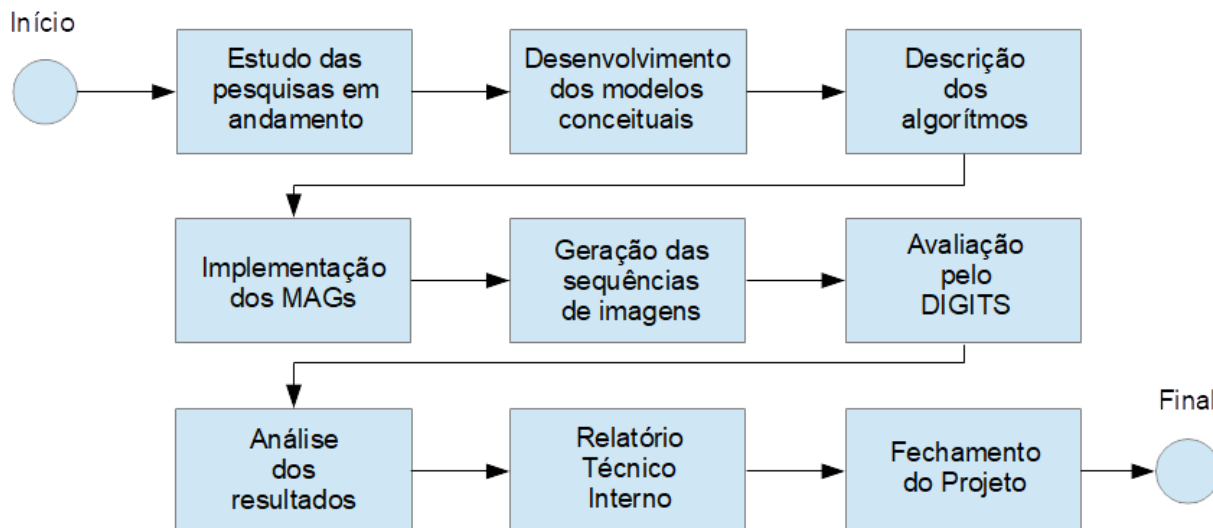


Figura 1: Fluxograma geral do projeto

Foram geradas sequências de 1.024 imagens em formato *jpeg*, com dimensões de 256 x 256 pixels, 3 canais de 8 bits de cores, agrupadas em 10±1 categorias. Cada modelo foi usado para produzir 2 sequências: uma com as imagens limpas e outra com a adição de ruído branco correspondente à distribuição aleatória de 5% dos pixels em cor de desenho (*foreground color*).

As imagens foram submetidas à avaliação da ferramenta de aprendizado profundo de máquina (DIGITS) pela Dra. Thaís Rocha. Ao final, ela entregou aos bolsistas os relatórios de execução do programa, com valores dos hiperparâmetros, classificação realizada, matriz de confusão, indicadores de acurácia, curvas de custo, de perda e de taxa de aprendizagem,

Os bolsistas, de posse dos relatórios de avaliação, elaboraram planilhas para

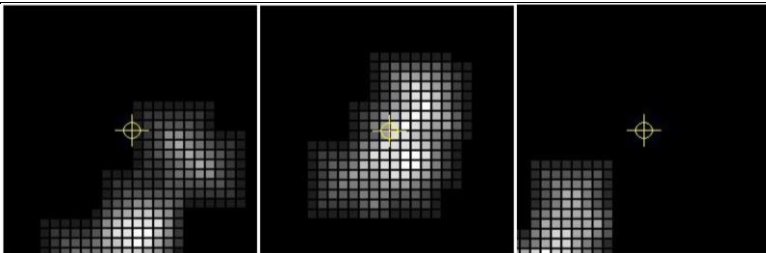
tabulação dos dados, geração de gráficos e análises de correlação. Adicionalmente eles responderam a questões de interpretação dos resultados, propostas pelo professor.

RESULTADOS E DISCUSSÃO:

Esta seção apresenta uma amostra ilustrativa dos resultados obtidos no projeto, que incluem as saídas produzidas pelo software DIGITS e análises feitas pelos bolsistas

O Quadro 1 apresenta um exemplo das informações coletadas após a execução da classificação das sequências pelo DIGITS. Veem-se os dados do MAG (desenvolvido pelo bolsista Davi), das imagens, da rede neural (*alexnet*), do framework (*Caffe*) e dos parâmetros e hiperparâmetros de execução, além dos indicadores de acurácia (*Top-1* e *Top-5*).

Quadro 1: Saída do DIGITS e dados complementares para um dos MAGs desenvolvidos

| | |
|-------------------------------|--------------------------------------------------------------------------------------|
| Software de geração | Fisgen 2.0.01 |
| Classe geradora | imageGenerators.PIBICEM2021_Davi_RestrictMultiSquaresSett |
| Tipo de imagem | Jpg, escala de cinza |
| Tamanho de imagem | 256 x 256 pixels |
| Software <i>deep learning</i> | Nvidia DIGITS 6 |
| Rede neural | alexnet |
| Imagens Treinamento | 768 |
| Imagens Validação | 153 |
| Imagens Teste | 103 |
| Total de imagens | 1.024 |
| Classes | 10 |
| Framework | Caffe |
| Épocas | 200 |
| Ruído branco | 0,0% |
| <i>Top-1 Accuracy</i> | 37,86% |
| <i>Top-5 Accuracy</i> | 67,96% |
| Tempo treinamento | |
| Tempo avaliação | 9 segundos |
| Exemplos de imagem |  |

A seguir encontra-se um exemplo da análise do bolsista Guilherme para o seu modelo *RestrictRoundSquareSet*, a partir da saída do DIGITS (rede alexnet, *framework* Caffe, 11 classes, 200 épocas, 1.024 imagens jpg: 769 para treinamento, 153 para validação e 102 para teste) e questões do professor.

Questões para Análise

1. Qual o percentual de acertos diretos de classificação?

R: 36,63%

2. Qual o percentual de acertos em até 5 tentativas de classificação?

R: 73,27%

3. Qual a classe com melhor reconhecimento?

R: Classe 10.

4. Qual a classe com mais imagens?

R: R-0

5. Qual a classe com menos imagens?

R: R-9

6. A partir de quantas épocas houve estabilização da curva de perdas?

R: A partir de 40 épocas

7. A partir de quantas épocas houve progressão para menor taxa de aprendizado?

R: A partir de 130 épocas.

8. A partir das respostas das questões 6 e 7, sugira um limite para o número de épocas deste caso e justifique sua sugestão.

R: 65 épocas é um bom limite para obter uma estabilização da curva de perdas e também obter a progressão para uma menor taxa de aprendizado, que, mesmo caindo novamente, não varia de forma significativa.

9. Há uma relação entre a acurácia e o número de imagens na classe? Justifique.

R: Não, o valor [de correlação de Pearson] não ultrapassa 0,5, portanto tem baixa correlação.

10. Calcule a média da acurácia por classes. Este valor é igual à acurácia top-1? Este valor tem utilidade na análise?

R: A média de acurácia top-1 da matriz de confusão é 18%, este valor não tem utilidade analítica.

11. Veja o gráfico de acurácia por classe. A média que você calculou na questão anterior é um valor típico dos dados? Por quê?

R: A média calculada não é um valor típico dos dados pois se afasta muito dos outros valores.

12. Calcule a acurácia top-1 a partir da matriz de confusão, exibindo a memória de cálculo.

R: Somatório = 37, Qtd Imagens = 101, Acurácia top-1 = 0,36

13. Pesquise o que são as métricas “Precision” e “Recall”. Calcule estas métricas a partir da matriz de confusão.

R: Precision = 1 e Recall = 0.3663

14. Faça um resumo das métricas “accuracy top-1”, “precision” e “recall” para o caso analisado.

R: Enquanto a “precision” atingiu o valor máximo a “recall” ficou muito baixa.

15. Você acha que a rede classificou bem imagens deste modelo? Por quê?

R: Não, o modelo não classificou bem as imagens pois as taxas de acerto top-1 e top-5 foram baixas assim como a quantidade de imagens que foram colocadas em classes às quais não pertenciam foi grande.

As figuras 2 a 5 apresentam, exemplos de imagens de dois MAGs (desenvolvidos pelos bolsistas Guilherme e Isabella), gráfico das funções custo e perda para cada época de treinamento atingida e curva de evolução da taxa de aprendizagem, automaticamente calibrada pelo software a cada interação.




Figura 2: Exemplos aleatórios de imagens geradas por MAG do bolsista Guilherme




Figura 3: Exemplos aleatórios de imagens geradas por MAG da bolsista Isabella




Figura 4: Exemplo de gráfico das funções custo e perda analisadas durante o projeto




Figura 5: Exemplo de gráfico da variação da taxa de aprendizagem analisada durante o projeto

CONCLUSÕES:

O projeto cumpriu seus objetivos. Os bolsistas integraram-se às pesquisas correntes e puderam interagir com graduandos e pós-graduandos. Tiveram contato com temas como Metodologia Científica, Boas Práticas de Pesquisa, Inteligência Artificial, Redes Neurais, Aprendizado de Máquina Profundo, distribuições estatísticas e análise de dados.

Fizeram a definição e a descrição de modelos computacionais que, depois de implementados e submetidos a um classificador *Deep Learning*, produziram os resultados analisados neste trabalho.

Os bolsistas estudaram Programação Orientada a Objetos e se capacitaram a desenvolver software em linguagem Java.

O projeto e colaborou na formação dos alunos de Ensino Médio e de monitores que atuaram em períodos específicos.

AGRADECIMENTOS

A Nvidia Inc. pela cessão da placa gráfica GPU Titan X que foi usada neste projeto; à Dra. Thaís Rocha pelas várias colaborações; aos monitores (alunos de graduação) Leonardo Nicolas Bueno Rosa, Kallynne Yanne Rosa, Bruno Carlos Oliveira da Silva e Mônica Eduarda Albuquerque Mariano; ao CNPq, à Unicamp e ao SAE pelas bolsas e auxílios concedidos.

BIBLIOGRAFIA

ANGELIS, A. F.; GOFFINET, C. C.; SILVA, G. F.; BARBOSA, M. L.; PINHEIRO, M. S. Nuvens, Modelos e Imagens In: XXVIII Congresso de Iniciação Científica da Unicamp, 2020, Campinas / SP. 2020.

- ANGELIS, A. F.; ROCHA, T. Evaluating the Deep Learning accuracy in data extraction from synthetic image sequences. JOURNAL OF COMPUTACIONAL INTERDISCIPLINARY SCIENCES. v.10, p.145 - 151, 2019.
- ANGELIS, A.F; HIDALGO, I. G.; ANDRADE, J. G. P. Efficiency Curves for Hydroelectric Generating Units. Journal of Water Resources Planning and Management. v.140, p.120817003119004 - 91, 2014.
- CASTRO, CLAUDIO DE MOURA. Como Redigir e Apresentar um Trabalho Científico. Pearson. 2011. 130p.
- DEITEL & DEITEL. Java: como programar. Prentice-Hall, 8a edição, 2010
- FAPESP. Código de Boas Práticas de Pesquisa. 2014.
- GUERRA, EDUARDO. Design Patterns com Java: Projeto Orientado a Objetos guiado por Padrões. Casa do Código. 1ª. ed. 2013.
- MARTIN, ROBERT C. Código Limpo: Habilidades Práticas do Agile Software (Ed. Revisada). Alta Books. 2011.
- ROCHA, T.; ANGELIS, A. F.; LOPES, J. E. G.; HIDALGO, I. G. Conceptual Model Of Inflow Forecasting For Measurement Stations At São Paulo. SODEBRÁS. v.15, p.117 - 122, 2020.
- ROCHA, T.; HIDALGO, I. G.; ANGELIS, A. F. DE; LOPES, J. E. G. Hydrological simulation in the Tiete basin In: Sustainable Hydraulics in the Era of Global Change: Advances in Water Engineering and Research.1 ed.London: Taylor & Francis Group; CRC Press, 2016, v.1, p. 116-123.
- ROCHA, T.; HIDALGO, I. G.; ANGELIS, A. F. Synthetic Images Generation for Deep Learning Assessment Towards the Infow Forecast for Power Systems Operation In: Brazilian Conference on Dynamics, Control and Applications - DINCON 2017, 2017. Anais do DINCON 2017. São José do Rio Preto/SP: SBMAC. 2017.
- SCHILD, HERBERT. Java: The Complete Reference. 9ª. ed. Oracle Press. 2014.
- SEVERINO, ANTONIO JOAQUIM. Metodologia do Trabalho Científico. Cortez. 2007. 23a. ed. 304p.
- WAZLAWICK, RAUL SIDNEI. Metodologia de Pesquisa para Ciência da Computação. Campus/Elsevier. 2009. 159p.