

APLICAÇÃO DE REDES NEURAIS CONVOLUCIONAIS PARA CLASSIFICAÇÃO DE DADOS ASTRONÔMICOS

Giovana Ramon Luiz Neto¹, Rafael Sfair^{1,2}, Altair Ramos Gomes Junior¹

1 - UNESP, Grupo de Dinâmica Orbital e Planetologia. Guaratinguetá, Brazil


2- Institut für Astronomie und Astrophysik, Eberhard Karls Universität Tübingen. Tübingen, Germany

giovana.ramon@unesp.br



Introdução

- Grande número de dados gerados por observações astronômicas e simulações numéricas
- Como exemplo, na pesquisa observacional, espera-se que o Large Synoptic Survey Telescope (LSST) entre em operação em 2022, gerando aproximadamente 15 TB a cada noite
- Em problemas de dinâmica orbital os dados geralmente são interpretados por meio de gráficos de elementos orbitais.



Large Synoptic Survey Telescope (LSST)




Gráfico da excentricidade versus semi-eixo maior de NEAs (cortesia de R. A. N. Araujo)

Machine Learning

Os métodos de Machine Learning (ML) ganharam amplo destaque por automatizar processos com grande quantidade de dados. O ML aplica métodos computacionais que usam a experiência para melhorar o desempenho ou fazer previsões precisas (Mohri et al., 2012).





Objetivos

Implementar e analisar métodos de aprendizado de máquina para classificar imagens geradas em problemas de dinâmica orbital, tipicamente gráficos que mostram a evolução temporal dos elementos orbitais. Dentre os objetivos específicos, nosso algoritmo pode ser utilizado para realizar:

- Classificação de órbitas
- Análise de ângulos de ressonantes



Convolutional Neural Network (CNN)


- Análise de imagem e vídeo, visando principalmente a classificação
- As CNNs buscam e aprendem padrões das imagens de entrada através do processo de convolução
- Na prática, divide-se nas etapas de treinamento e teste

Training

No treinamento, é utilizado um conjunto de imagens que são pré-classificadas pelo usuário e através delas o modelo aprende a associar cada padrão a um determinado rótulo.

Test

As imagens de teste são aquelas nas quais serão feitas previsões que retornarão a taxa de sucesso do programa.



Exemplo da estrutura de uma rede neural.



Metodologia


Para verificar a viabilidade da proposta, foi realizada uma análise com dados orbitais da evolução dinâmica dos NEAs (Near Earth Asteroids). O modelo de ML foi construído usando a biblioteca Keras de redes neurais em Python (Chollet et al., 2018).




TensorFlow

Resultados


- Gráficos da excentricidade versus semi-eixo maior da órbita NEAS
- Conjunto de 429 imagens
- Foram realizadas duas análises diferentes, devido a um padrão de sobreposição parcial entre as classes tipo 2 e tipo 3:
 - Duas classes (tipo 1 e tipo 3 + tipo 2)
 - Três classes (tipo 1 e tipo 3 e tipo 2)
- As figuras foram gentilmente cedidas pela Dra. Rosana Araujo e Dr. Othon Winter



Tipo 1



Tipo 3



Tipo 2

Resultados

Duas classes


- Precisão maior que 0,9 usando 30% das imagens como etapa de treinamento;
- A precisão chegou a 0,98 quando o conjunto de treinamento correspondia a 50% da amostra.

	total images	test images	% test images	train images	% train images	acc	size	epoch
1	273	164	60%	109	40%	0,97	200 x 200	300
2	273	164	60%	109	40%	0,95	200 x 200	300
3	273	164	60%	109	40%	0,95	300 x 300	300
4	273	164	60%	109	40%	0,96	300 x 300	300
5	273	191	70%	82	30%	0,89	500 x 500	200
6	273	191	70%	82	30%	0,9	500 x 500	200
7	273	205	75%	68	25%	0,89	480 x 640	200
8	273	137	50%	136	50%	0,98	480 x 640	200
9	273	137	50%	136	50%	0,93	480 x 640	200

Tabela com os resultados de precisão para o teste com duas classes (ressonante e guiado/confinado).

Três classes

- No caso com três classes, a acurácia foi inferior (<0,86);
- Este último resultado se relaciona à semelhança entre duas das classes, dificultando a separação entre elas.



Exemplo de plots que o modelo pode confundir devido a similaridade.



Considerações Finais

O modelo funcionou bem sendo que o desempenho variou de acordo com:

- O número de épocas (número de vezes que as camadas são aplicadas);
- A proporção do conjunto de treinamento;

Para melhorar a performance do modelo, deve-se aumentar o conjunto de dados, ou quando isso não for possível, pode-se aprimorar as camadas da rede neural para aperfeiçoar a identificação de padrões.

Referências

- Chollet, F. et al. **(2018)**. Keras: The Python Deep Learning library.
- Mohri, M. et al. Foundations of machine learning. 2° ed. Cambridge, MA : The MIT Press, **2018**.

Agradecimentos

CNPq - PIBIC (2021/2846); FAPESP (Proc. 2016/24561-0), DFG German Research Foundation (446102036); FAPESP (Proc. 2018/11239-8).