



# Universidade: presente!



## XXXI SIC

21. 25. OUTUBRO • CAMPUS DO VALE

## Detecção de lentes gravitacionais utilizando aprendizado de máquina

Orientando: Manuel Speranza Torres Veras  
Orientadora: Cristina Furlanetto

É esperado que o recente avanço das sondagens fotométricas de grandes áreas revele uma quantidade grande de lentes gravitacionais, porém, em meio a isso, surge um desafio: encontrar métodos capazes de identificar esses objetos de forma eficiente. Em meio a esse contexto, nos propomos a estudar formas de melhorar o desempenho de redes neurais classificadoras de lentes gravitacionais. Para tal fim, a partir de um conjunto de imagens simuladas de lentes gravitacionais, nós criamos, utilizando um algoritmo de rotação-subtração, mais duas amostras de imagens. Ficamos assim com 3 amostras que serviam como dados de entrada para nossa rede neural: uma com apenas as imagens originais, outra com apenas as imagens geradas pelo método de rotação-subtração e uma que agrupava os dois conjuntos anteriores. Após comparar o desempenho de cada amostra, verificamos que o terceiro conjunto foi o que obteve a melhor eficiência em classificar as imagens.

### INTRODUÇÃO

As diversas aplicações de lentes gravitacionais fortes, tanto em Cosmologia quanto em Astrofísica, possuem uma limitação em comum: o número relativamente baixo de sistemas de lentes conhecidos para os quais estudos podem ser realizados. No entanto, várias sondagens fotométricas de grandes áreas já estão em operação ou entrarão em operação em um futuro próximo e é esperado que revelem milhares de lentes gravitacionais. Surge o desafio, portanto, de encontrar métodos eficientes de identificar automaticamente tais objetos. Entre esses, destacam-se as redes neurais convolucionais, cuja capacidade de identificação automática de imagens melhorou de maneira significativa nos últimos anos. Em meio a esse contexto, o objetivo deste trabalho é desenvolver um método de detecção automática de sistemas de lentes do tipo galáxia-galáxia utilizando redes neurais convolucionais e um novo método para a subtração da luz da galáxia que atua como lente.

### METODOLOGIA

Nesse projeto utilizamos as redes neurais de tipo convolucional (ConvNet, Figura 1). Essa arquitetura de rede neural consiste em uma sequência de camadas de convolução e pooling, que convertem a imagem de entrada em um número cada vez maior de mapas de características de resolução menor. Dessa forma, os mapas finais conseguem capturar características altamente abstratas desses objetos. Ao final, esses mapas são fornecidos como informação de entrada para uma rede perceptron multicamadas.

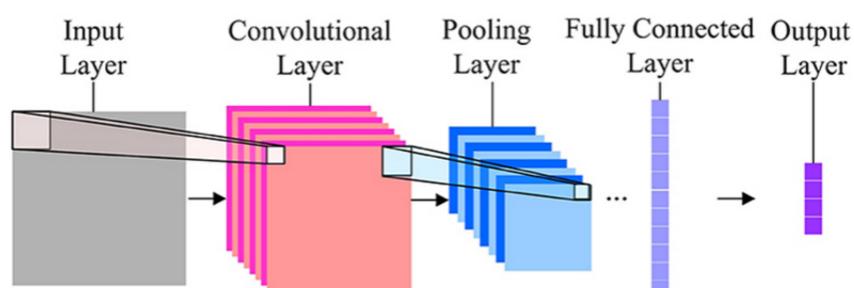


Figura 1: ilustração de uma rede neural convolucional. Imagem retirada de <https://www.frontiersin.org/articles/10.3389/fpsyg.2017.01745/full>.

Adotamos o método de rotação-subtração que consiste em subtrair de uma imagem uma rotação de 180° de si mesma (Figura 2). Essa técnica é puramente geométrica e explora a simetria das galáxias elípticas (tipo mais comuns de lentes) para remover a luz das lentes, revelando, assim, características assimétricas associadas aos arcos gravitacionais. A vantagem dessa técnica é que ela pode ser utilizada em imagens de apenas uma banda, ao contrário de outros métodos que exigem informação de cor.

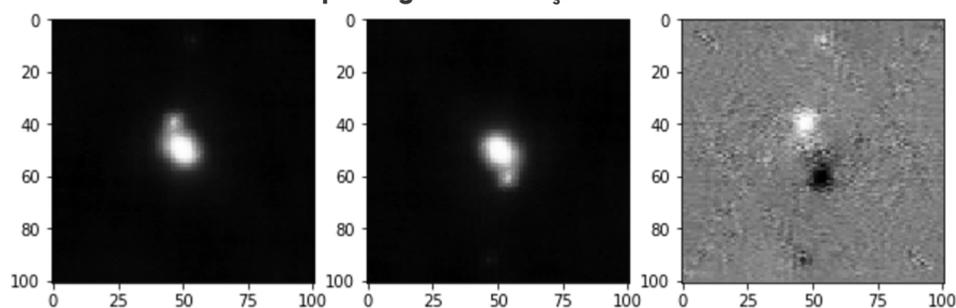


Figura 2: imagem original (painel esquerdo), imagem original rotacionada por 180° (painel central) e imagem obtida pelo método de rotação-subtração (subtração das duas imagens anteriores; painel direito).

Como conjuntos de treinamento, teste e validação da nossa ConvNet utilizamos as imagens simuladas de telescópio espacial do Strong Gravitational Lens Finding Challenge (Metcalf et al., A&A, 625, A119, 2019). Escolhemos esses dados devido à potencial aplicação do método às imagens da missão Euclid. Este conjunto de dados consiste em 20000 imagens, que foram divididas da seguinte forma: 10% para validação, 30% para teste e, 60% para treinamento. As imagens de entrada foram classificadas como lente ou não-lente.

A imagem de entrada (101x101 pixels) é processada por uma camada de convolução (64 filtros de 3x3) e subamostrada por uma camada de pooling (2x2). A seguir, são aplicadas outras 3 unidades idênticas, com dimensão crescente do espaço de convolução (128, 256 e 512 filtros). Em cada camada convolucional é aplicada uma função de ativação ReLU. A saída dessas unidades é processada por uma rede do tipo perceptron multicamadas com função de ativação ReLU. Como saída, a ConvNet prevê um valor 0 (não-lente) ou 1 (lente). Para aumentar a amostra de treinamento foram feitas uma série de transformações aleatórias (data augmentation).

### RESULTADOS

Aplicamos a nossa ConvNet nos conjuntos de dados originais (conjunto 1), no conjunto de dados obtidos a partir do método de rotação-subtração (conjunto 2) e num conjunto de dados onde foram combinadas tanto as imagens originais quanto as de rotação-subtração (conjunto 3). Utilizamos a curva ROC (Receiver Operating Characteristic) para avaliar a eficiência de nossa rede. A área abaixo dessa curva, chamada de AUC, é uma medida que pretende estimar o quão bem uma rede neural classificadora é capaz de identificar alguma classe (em nosso caso, identificar lentes gravitacionais). Por exemplo, uma rede com um desempenho perfeito, isto é, que acerta todas as previsões, tem uma AUC igual a 1. A seguir apresentamos a comparação entre os valores de AUC para os 3 conjuntos de dados (Tabela 1) e os resultados obtidos no treinamento e validação do conjunto 3 (Figuras 3, 4 e 5), que foi o conjunto que obteve o melhor desempenho.

Conjunto	AUC
original	0,876
rotação-subtração	0,880
Original e rotação-subtração	0,889

Tabela 1: Valor do AUC para cada conjunto de dados de entrada

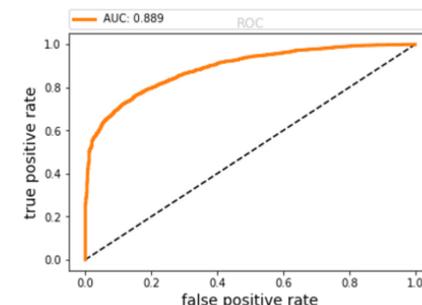


Figura 3: curva ROC

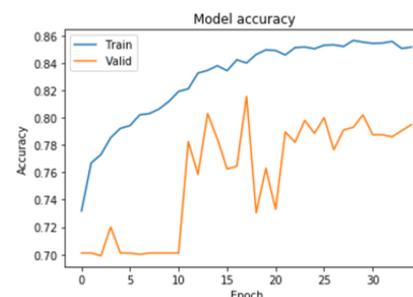


Figura 4: acurácia X época

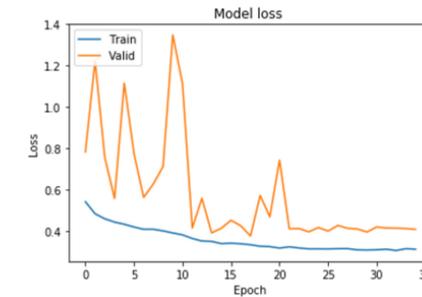


Figura 5: função perda x época.

### CONCLUSÕES E PERSPECTIVAS

Obtivemos uma pequena melhora na AUC, a área abaixo da curva ROC, para os conjuntos que utilizam as imagens obtidas pelo método da rotação-subtração. Em termos dos valores de AUC, nossa rede obteve um valor que a colocaria em quarto lugar no Strong Gravitational Lens Finding Challenge (Metcalf et al., A&A, 625, A119, 2019). No futuro, pretendemos aplicar o algoritmo de rotação-subtração para outros conjuntos de imagens e testar esse método utilizando outras redes neurais.

### AGRADECIMENTOS

Gostaríamos de agradecer o CNPQ pelo apoio financeiro. Agradecemos ao Dr. Áttila Leães Rodrigues (UFRGS) e ao Dr. Clécio de Bom (Cefet/RJ) pelas discussões e auxílio no desenvolvimento dos códigos.