

Departamento de Sistemas e Computação – FURB
Curso de Ciência da Computação
Trabalho de Conclusão de Curso – 2016/1

ASTROLAB

uma ferramenta para identificação e
classificação de corpos celestes

Acadêmico: William Maurício Glück

bigwillgluck@gmail.com

Orientador: Prof. Aurélio Hoppe

aurelio.hoppe@gmail.com

Grupo de Pesquisa em Computação
Gráfica, Processamento de Imagens e
Entretenimento Digital
<http://www.inf.furb.br/gcg>



Roteiro


- Motivação
- Fundamentação teórica
- Trabalhos correlatos
- Trabalho proposto
- Requisitos
- Desenvolvimento
- Resultados
- Problemas identificados
- Conclusão
- Extensões
- Demonstração

Motivação


- Estudo de padrões é importante para a ciência
- Processo tradicional de classificação se torna inviável diante do aumento exponencial da massa de dados
- Solução: processamento de imagem e classificadores inteligentes

Fundamentação teórica


Sistema Hubble de Classificação Morfológica de Galáxias



Exemplos



Galáxia elíptica



Galáxia lenticular

Exemplos




Galáxia espiral



Galáxia espiral barrada

Fundamentação teórica

Redes Neurais Convolucionais



Convolução

- Tamanho
- Stride
- Padding
- Quantidade de filtros


1	1	1	0	0
0	1	1 _{x1}	1 _{x0}	0 _{x1}
0	0	1 _{x0}	1 _{x1}	1 _{x0}
0	0	1 _{x1}	1 _{x0}	0 _{x1}
0	1	1	0	0

4	3	4
2	4	3

Max pooling

- Tamanho
- Stride



4	8	2	1	1	3
7	1	1	2	2	6
2	2	3	8	1	9
2	2	6	2	8	4
3	2	1	2	1	8
1	1	1	3	6	1



8	2	6
2	8	9
3	3	8

Dropout

- Porcentagem de neurônios que serão mantidos



Softmax

- Transforma um vetor de pontuações em um vetor de probabilidades

$$\sigma(\mathbf{z})_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad \text{for } j = 1, \dots, K.$$

Características dos trabalhos correlatos

Características/ trabalhos relacionados	Jenkinson et al. (2014)	Ata et al. (2009)	Elfattah et al. (2013)
Origem da base de dados	Criada pelos autores	Zsolt Frei	Zsolt Frei
Quantidade de imagens de treino	14	10	24
Quantidade de imagens de teste	3	10 (retiradas da base de treino)	68
Algoritmos utilizados para processamento das imagens	Rooting transform, Heap transform, Paired transform.	-	Detecção de bordas e remoção de ruído de ponta
Algoritmos utilizados para classificação	SVM	Diversas arquiteturas de redes neurais e SVM.	Mapas auto organizáveis e SVM
Tipo de dados de entrada	Representação esparsa das imagens	Características morfológicas e PCA	Momentos invariantes com Fisher Score
Melhor taxa de acerto de classificador supervisionado	100	99.53 (SVM)	97.29 (SVM)

Trabalho proposto

Desenvolver uma ferramenta que, aplicando técnicas de processamento de imagem e inteligência artificial em imagens astronômicas, realize a classificação morfológica de galáxias.

Objetivos específicos:

- processar imagens de galáxias realizando a diminuição de ruído;
- criar e treinar uma rede neural artificial convolucional que aprenda, a partir de um conjunto de dados de treinamento, a classificar galáxias a partir das suas características morfológicas.

Requisitos


Requisitos Funcionais:

- permitir que o usuário realize o processamento de imagens astronômicas
- permitir que o usuário realize o treinamento da rede neural que será utilizada para classificação
- permitir que o usuário informe uma imagem de galáxia e realize a classificação morfológica da mesma
- permitir que o usuário visualize a taxa de sucesso durante o treinamento da rede neural

Ferramentas utilizadas

- linguagem Python para implementação da ferramenta
- biblioteca de visão computacional OpenCV para suporte as operações de processamento de imagem
- biblioteca de aprendizado de máquina TensorFlow para criação da rede neural

Etapas do processamento



Resultado do processamento

Imagem de 512x512 reduzida para 56x56 e valor limite de 20 para binarização



Geração da base de dados

SDSS

- Desde 2000
- Mapeando um quarto do céu
- ImageCutout

Galaxy Zoo

- Desde 2007
- Galaxy Zoo 2 (2013)

Geração da base de dados


Base

- 107.620 imagens de treino
- 978 imagens de teste


Classes consideradas

- Tipo tardio
- Tipo precoce


Design da rede convolucional desenvolvida




Primeira etapa de convolução e max pooling



Segunda etapa de convolução e max pooling




Passo final: camada densa, dropout e softmax




Informações adicionais da rede

- Função de ativação ReLu
- Dropout de 50% (apenas durante treinamento)
- Função de custo: entropia cruzada
- Função de otimização: gradiente descendente estocástico com otimizador Adam
- Algoritmo de treinamento: backpropagation

Etapas do treinamento



Etapas da classificação



Operacionalidade

Processamento de uma imagem


1. Usuário informa o caminho da imagem
2. Usuário informa o tamanho da nova imagem que será criada
3. Usuário informa o caminho no qual a nova imagem será criada
4. Ferramenta realiza a redução de ruído

```
(astrolab)willgluck@willgluck-Inspiron-7520:~/media/willgluck/a2aa6a5f-a88a-45c7-af45-d38ccf2b7639/w
Welcome to Astrolab

Menu
 1 - Denoise
 2 - Train
 3 - Classify
 4 - Exit
Choose an option (numeric): 3

Classifying
Inform image path: /media/willgluck/a2aa6a5f-a88a-45c7-af45-d38ccf2b7639/w
Inform the image sizes: 56
Inform the image channels: 3
Inform the class count: 2
Prediction: 1

Menu
 1 - Denoise
 2 - Train
 3 - Classify
 4 - Exit
Choose an option (numeric): 
```



Operacionalidade

Treinamento da rede neural

1. Usuário informa o caminho das imagens de treino
2. Usuário informa o caminho do arquivo de rótulos de treino
3. Usuário informa o caminho da imagem de teste
4. Usuário informa o caminho do arquivo de rótulos de teste
5. Usuário informa a quantidade de classes de classificação
6. Usuário informa tamanho do batch de treinamento
7. Usuário informa o número de iterações do treinamento
8. Usuário informa o tamanho das imagens
9. Usuário informa o número de canais da imagem
10. Ferramenta exibe *feedback* ao usuário

Operacionalidade

Classificação pela rede neural

1. Usuário informa o caminho da imagem
2. Usuário informa o tamanho da imagem
3. Usuário informa o número de canais da imagem
4. Usuário informa a quantidade de classes de classificação
5. Ferramenta exibe a classificação da classe correspondente e exibe a imagem.

Resultados – percentual de acerto (%)


Teste	Tamanho imagens	Iterações	Duração	Acerto (%)
1	28x28	20.000	1:00:23	73.0
2	28x28	40.000	2:17:15	79.34
3	28x28	60.000	3:20:57	80.57
4	56x56	10.000	2:45:19	81.59
5	56x56	15.000	4:06:16	84.66
6	56x56	28.000	7:20:33	85.68
7	56x56	56.000	13:34:338	86.40
8	56x56	77.000	19:29:10	83.94

Comparativo em relação aos trabalhos correlatos

Características/ trabalhos relacionados	Jenkinson et al. (2014)	Ata et al. (2009)	Elfattah et al. (2013)	Trabalho proposto
Origem da base de dados	Criada pelos autores	Zsolt Frei	Zsolt Frei	SDSS e Galaxy Zoo
Quantidade de imagens de treino	14	113	24	107.620
Quantidade de imagens de teste	3	10 (retiradas da base de treino)	68	978
Algoritmos utilizados para processamento das imagens	Rooting transform, Heap transform, Paired transform.	-	Detecção de bordas e remoção de ruído de ponta	Limiarização e componentes conexas.
Algoritmos utilizados para classificação	SVM	Diversas arquiteturas de redes neurais e SVM.	Mapas auto organizáveis e SVM	Rede neural convolucional com dropout e softmax.
Tipo de dados de entrada	Representação esparsa das imagens	Características morfológicas e PCA	Momentos invariantes com Fisher Score	Imagens processadas
Melhor taxa de acerto de treinamento supervisionado	100	99.53 (SVM)	97.29 (SVM)	86.40 (na base de testes) e 97.5 (na base de treino)


Problemas no processamento

Redução de ruídos sem sucesso devido a complexidade das imagens




Problemas na classificação

Confusão entre galáxias do tipo jovem e tardio em estágios intermediários



Problemas na classificação

Confusão entre galáxias do tipo precoce e tardio quando vistas lateralmente



Conclusões

- Alta taxa de sucesso em galáxias que apresentam estruturas distintas



Conclusões

- Problemas no processamento em consequência de imagens complexas
- Falta de treinamento para galáxias em estados intermediários
- Falta de treinamento para galáxias vistas lateralmente

Extensões

- Criação de uma interface gráfica para o usuário
- Aumentar a base de dados utilizada para treinando e teste
- Otimizar a etapa de processamento das imagens a fim de reduzir o número de casos com ruído excessivo, como presença de duas galáxias na mesma imagem

Extensões

- Fazer testes com outros *designs* de rede para comparação de performance
- Realizar testes com outros tamanhos de imagens para comparação de performance;
- Implementar outros algoritmos classificadores para comparação de performance na mesma base de dados
- Utilizar *graphics processing unit* (GPU) para treinamento da rede neural

Demonstração