

Classificação de Imagens Radiográficas para Detecção de Anormalidades Musculoesqueléticas

Leodécio Braz da Silva Segundo
Orientador: Prof. Dr. Zanoni Dias
Coorientador: Prof. Dr. Hélio Pedrini

Instituto de Computação – Unicamp
leodeciobraz@liv.ic.unicamp.br

03 de Outubro de 2019

Introdução



Introdução



Úmero



Mão

Objetivos e Contribuições

Objetivos

Investigar técnicas de classificação de imagens radiográficas e propor uma metodologia eficaz para detectar anormalidades musculoesqueléticas através da exploração de métodos de redes neurais.


Contribuições

Fornecer uma abordagem eficaz para a tarefa de classificação de imagens radiográficas musculoesqueléticas baseada em modelos de aprendizado profundo.

Questões de Pesquisa

- 1 Em termos de eficácia e eficiência, são melhores múltiplos classificadores binários do que um classificador multi-classe?
- 2 Utilizar pesos de redes pré-treinadas em domínios similares ao de imagens radiográficas é mais eficaz do que se utilizar pesos de redes pré-treinadas com o conjunto ImageNet?
- 3 Utilizar os pesos de redes treinadas para imagens radiográficas de uma dada região do corpo auxilia no processo de treinamento das imagens radiográficas de outras regiões do corpo da base a ser utilizada?

Redes Neurais Convolucionais



<https://medium.com/@culurciello/analysis-of-deep-neural-networks-dcf398e71aae>


Classificação

- Métricas:
 - Acurácia balanceada (ACC_b)
 - Área sob a curva (AUC)
 - Coeficiente Kappa
 - Log Loss

Aumentação de Dados

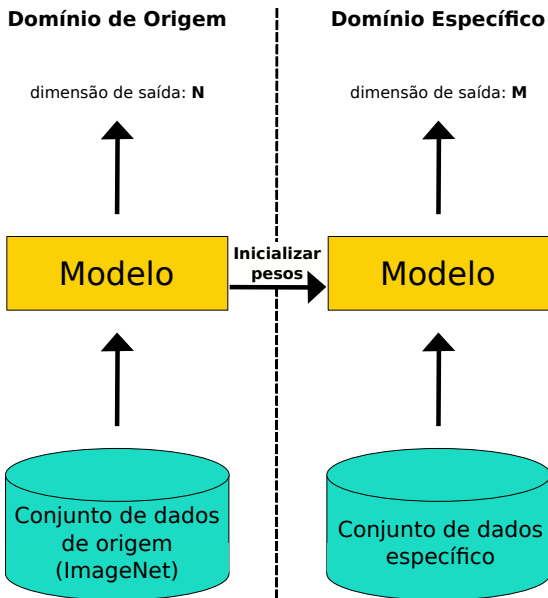


Imagem original




Imagens geradas

Transferência de Aprendizado

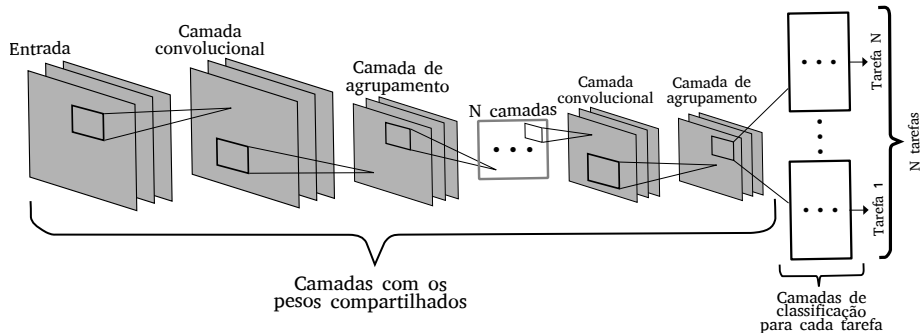


Métodos de Treinamento


- Ajuste Fino



Aprendizado em Multitarefas



Warm Starting



Lesões de pele

- Kawahara et al. (2016)
 - ▶ Base: *Dermofit Image Library*
 - ▶ 10 categorias de lesões
- Menegola et al. (2017)
 - ▶ Propuseram um conjunto de experimentos
 - ▶ Uso tanto de transferência de aprendizado quanto de ajuste fino

Imagens radiográficas

- Gale et al. (2017)
 - ▶ Detecção de fraturas no quadril
 - ▶ *CNN-frontal*, *CNN-bounding* e *CNN-metal*
- Rajpurkar et al. (2017)
 - ▶ Propuseram a base de dados MURA
 - ▶ Modelo para prever a probabilidade de anormalidade

Trabalhos Relacionados

Modelo	Tarefa	Tipo	Aumentação de Dados	Transferência Aprendizado	Ajuste Fino
Kawahara et al.	Classificação	Lesões de pele	Sim	Sim	Não
Menegola et al.	Classificação	Lesões de pele	Sim	Sim	Sim
Gale et al.	Classificação	Radiografia	Sim	Não	Não
Rajpurkar et al.	Classificação	Radiografia	Sim	Sim	Não
Proposto	Classificação	Radiografia	Sim	Sim	Sim


- MURA: Large Dataset for Abnormality Detection in Musculoskeletal Radiographs
 - ▶ 14863 casos de estudos
 - ▶ 12173 pacientes

Base de Dados

Classes	Treinamento		Validação		Teste		Total
	Normal	Anormal	Normal	Anormal	Normal	Anormal	
Pulso	4612	3189	1153	798	364	295	10411
Ombro	3368	3334	843	834	285	278	8942
Mão	3247	1187	812	297	271	189	6003
Dedo	2510	1574	628	394	214	247	5567
Cotovelo	2340	1604	585	402	235	230	5396
Antebraço	931	528	233	133	150	151	2126
Úmero	538	479	135	120	148	140	1560
Total	17546	11895	4389	2978	1667	1530	40005

Pré-Processamento


Conjunto de
treinamento



Aumentação de
dados
Remoção de
dados espúrios



Novo conjunto de
treinamento

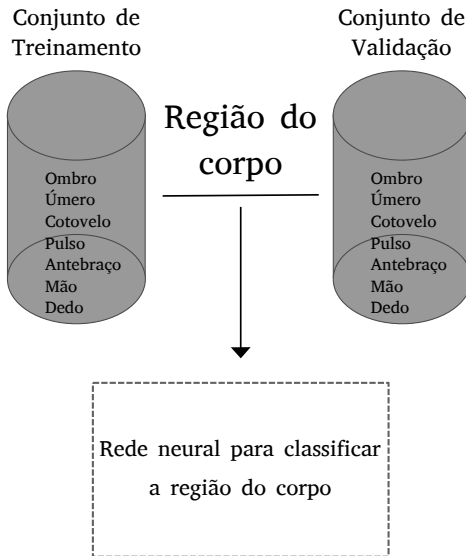


Pré-Processamento



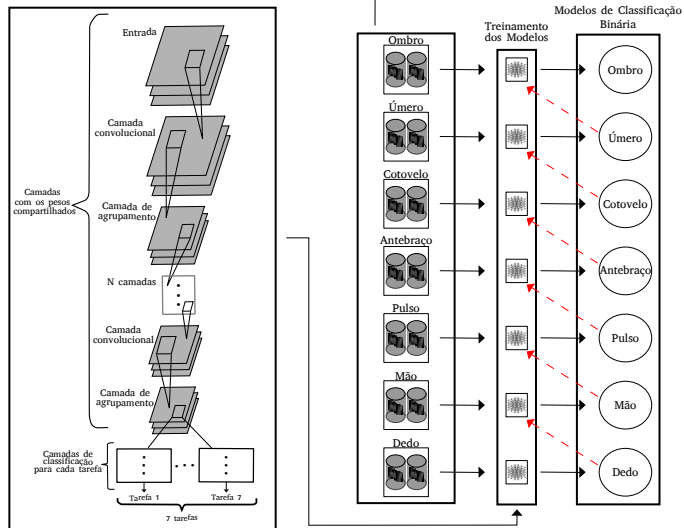
Treinamento

Treinamento - parte 1




Treinamento

Treinamento - parte 2



Teste



Resultados Preliminares

- 7 classificadores binários

Região	Arquitetura								
	VGG-16			InceptionV3			DenseNet		
	AUC	ACC _b	Kappa	AUC	ACC _b	Kappa	AUC	ACC _b	Kappa
Ombro	0,70	0,70	0,41	0,61	0,61	0,22	0,51	0,51	0,03
Cotovelo	0,73	0,73	0,49	0,53	0,57	0,14	0,50	0,42	0,00
Antebraço	0,64	0,64	0,30	0,56	0,56	0,13	0,70	0,76	0,43
Úmero	0,72	0,72	0,44	0,66	0,66	0,33	0,73	0,74	0,47
Mão	0,64	0,64	0,34	0,52	0,52	0,05	0,52	0,70	0,07
Dedo	0,71	0,71	0,43	0,54	0,54	0,07	0,58	0,64	0,18
Pulso	0,79	0,79	0,59	0,58	0,58	0,16	0,55	0,54	0,10
Média	0,70	0,70	0,43	0,57	0,58	0,16	0,58	0,62	0,18

Resultados Preliminares

- 7 classificadores binários \times 1 classificador com 14 classes

Região	7 classificadores binários			Classificador com 14 classes		
	VGG-16			VGG-16		
	AUC	ACC _b	Kappa	AUC	ACC _b	Kappa
Ombro	0,70	0,70	0,41	0,84	0,84	0,68
Cotovelo	0,73	0,73	0,49	0,89	0,88	0,79
Antebraço	0,64	0,64	0,30	0,91	0,79	0,76
Úmero	0,72	0,72	0,44	0,90	0,92	0,84
Mão	0,64	0,64	0,34	0,74	0,74	0,57
Dedo	0,71	0,71	0,43	0,91	0,91	0,81
Pulso	0,79	0,79	0,59	0,88	0,88	0,79
Média	0,70	0,70	0,43	0,87	0,85	0,75

Resultados Preliminares

- Experimento - *Warm Start*

Região	VGG-16 - ImageNet			VGG-16 - Warm Start			Δ_{Kappa}
	AUC	ACC_b	Kappa	AUC	ACC_b	Kappa	
Pulso	0,79	0,79	0,59	0,79	0,79	0,59	—
Cotovelo	0,73	0,73	0,49	0,74	0,74	0,50	1 ↑
Úmero	0,72	0,72	0,44	0,76	0,76	0,54	10 ↑
Dedo	0,71	0,71	0,43	0,69	0,69	0,41	2 ↓
Ombro	0,70	0,70	0,41	0,72	0,72	0,45	4 ↑
Mão	0,64	0,64	0,34	0,67	0,67	0,41	7 ↑
Antebraço	0,64	0,64	0,30	0,75	0,75	0,55	25 ↑
Média	0,70	0,70	0,43	0,73	0,73	0,49	6 ↑

Estado da Arte

Rank	Date	Model	Kappa
		Best Radiologist Performance <i>Stanford University</i> <i>Rajpurkar & Irvin et al., 17</i>	0.778
1	Nov 30, 2018	base-comb2-xuan-v3(ensemble) <i>jzhang Availink</i>	0.843
2	Nov 06, 2018	base-comb2-xuan(ensemble) <i>jtzhang Availink</i>	0.834
3	Oct 06, 2018	muti_type (ensemble model) <i>SCU_MILAB</i>	0.833
4	Oct 02, 2018	base-comb4(ensemble) <i>jtzhang Availink</i>	0.824
5	Nov 08, 2018	base-comb2-jun2(ensemble)	0.814
5	Nov 07, 2018	base-comb2-ping(ensemble)	0.814
6	Aug 22, 2018	base-comb3(ensemble)	0.805
7	Sep 14, 2018	double_res(ensemble model) <i>SCU_MILAB</i>	0.804
8	Aug 24, 2018	double-dense-Axy-Axyf512 <i>ensemble</i>	0.795
9	Jul 24, 2018	he_j	0.775
10	Aug 19, 2018	ianpan (ensemble) <i>RIH 3D Lab</i>	0.774

Plano de Trabalho

Atividades	2019				2020				2021
	1º	2º	3º	4º	1º	2º	3º	4º	1º
Obtenção dos créditos obrigatórios em disciplinas	•	•	•	•					
Revisão da literatura	•	•	•	•	•				
Exame de Qualificação do Mestrado (EQM)				•					
Análise e preparação dos dados		•	•	•					
Experimentos iniciais com modelos de redes neurais		•	•	•					
Construção de uma metodologia de classificação				•	•	•			
Experimentos com a metodologia definida				•	•	•			
Participação no Programa de Estágio Docente (PED)					•	•			
Análise e validação dos resultados obtidos					•	•	•		
Publicação dos resultados						•	•	•	•
Escrita da dissertação				•	•	•	•	•	•
Apresentação da dissertação de mestrado									•

Tabela: Cronograma de atividades

Comentários Finais

Detectar anormalidades em imagens de radiografias musculoesqueléticas é uma tarefa rotineira de profissionais radiologistas, que podem ser submetidos a inúmeros casos durante seus plantões.

Sistemas que possam auxiliar radiologistas nesta tarefa representam uma aplicação importante na área.

Este projeto pretende investigar o problema de detectar anormalidades em imagens radiográficas de diferentes regiões do corpo e desenvolver um método eficaz para a tarefa.

Comentários Finais

Resultados obtidos através da execução de alguns experimentos preliminares mostraram que as arquiteturas experimentadas não conseguiram obter bons resultados, indicando que a tarefa de classificar um caso de estudo como “normal” ou “anormal” não é trivial.

Esperamos que, com a implementação completa da nossa metodologia, possamos obter bons resultados, obtendo contribuições significativas tanto no contexto científico quanto no social.

Classificação de Imagens Radiográficas para Detecção de Anormalidades Musculoesqueléticas

