

ENGENHARIA DAS MISSÕES ESPACIAIS

APRENDIZADO PROFUNDO APLICADO A SENSORIAMENTO REMOTO E DRONES

Valdivino Alexandre de Santiago Júnior

Coordenação de Pesquisa Aplicada e Desenvolvimento Tecnológico (COPDT)


Programa de Pós-Graduação em Computação Aplicada (CAP)

Instituto Nacional de Pesquisas Espaciais (INPE)




INTELIGÊNCIA ARTIFICIAL (IA)

- ▶ IA pode ser considerado um campo. Principais **subcampos**.




IA: SUBCAMPOS


- ▶ **Aprendizado Profundo (*Deep Learning* - DL):** Principal razão do sucesso da IA.



IA (ML/DL): INPE



Sensoriamento Remoto



Tempo e Clima



Drones



Astrofísica/Cosmologia


- ▶ IDeepS: Classificação de imagens via redes neurais profundas e grandes bases de dados para aplicações aeroespaciais.
- ▶ Financiamento indireto (LNCC/Supercomputador SDumont): R\$ 258.132,00.

Project IDeepS



IDEEPS: OBJETIVO ESPECÍFICO 1

- ▶ Investigações em larga escala de várias redes neurais profundas, classificação de imagens de sensoriamento remoto para apoiar *land use and land cover* (LULC).



IDEEPS: OBJETIVO ESPECÍFICO 2

- Identificar as melhores redes neurais profundas para apoiar voos autônomos de drones elétricos de baixo custo.



IDEEPS: OBJETIVO GERAL


Recomendações/Sugestões



Sensoriamento Remoto

Drones






DeepS

Sensoriamento Remoto


SENSORIAMENTO REMOTO: APLICAÇÃO 1

- ▶ Aprendizado profundo e imagens *Synthetic Aperture Radar* (SAR) para detectar atividades de extração seletiva de madeira.
- ▶ Área de concessão florestal localizada na Floresta Nacional do Jamari, estado de Rondônia, Brasil.




SENSORIAMENTO REMOTO: APLICAÇÃO 1

► Rede neural profunda: U-Net.



SENSORIAMENTO REMOTO: APLICAÇÃO 2

- ▶ Segmentação semântica para apoiar análise de LULC via aprendizado profundo e um banco de imagens do bioma Cerrado.
- ▶ Método AI4LUC.




CerraData:


44% do bioma Cerrado

(Bahia, Goiás, Maranhão, Mato


Grosso, Tocantins, Distrito Federal).



AI4LUC: DATA ENGINEERING MODULE



CerraData v1
unlabeled dataset




2.500.000 samples


CerraData v3
labeled dataset




Building
class
10.000 samples




Cultivated
Area class
10.000 samples




Other uses
class
10.000 samples




Pasture
class
10.000 samples




Forest
class
10.000 samples



Non observed
class
10.000 samples




Savanna
class
10.000 samples




Water
class
10.000 samples

CerraData v2
labeled dataset




Cultivated Area
class
10.000 samples



Forest Formation
class
10.000 samples



Non Forest Area
class
10.000 samples




Savanna
Formation class
10.000 samples




Water class
10.000 samples


AI4LUC: SCENE/CONTEXTUAL CLASSIFICATION MODULE




AI4LUC: SMART MASK LABELING (SML) MODULE



AI4LUC: PIXEL-BASED CLASSIFICATION (SEMANTIC SEGMENTATION) MODULE



AI4LUC: DEEPLABV3+ (GOOGLE)




AI4LUC: RESULTADOS SML

Classes	IoU	F1-score
<i>Building (BL)</i>	0.5312	0.6424
<i>Cultivated Area (CA)</i>	0.6278	0.8152
<i>Forest (FF)</i>	0.6475	0.9525
<i>Non-Observed Area (NO)</i>	0.5012	0.7291
<i>Other uses (OU)</i>	0.3788	0.5074
<i>Pasture (PA)</i>	0.4619	0.8627
<i>Savanna Formation (SA)</i>	0.4391	0.8544
<i>Water (WT)</i>	0.1220	0.2150
Group	mIoU	F1-score
BNOW score	0.3425	0.4789
CFPS score	0.7172	0.8290
Overall	0.5068	0.6647

AI4LUC: RESULTADOS SML

- ▶ Máscaras corretas geradas pelo módulo SML.



AI4LUC: RESULTADOS DEEPLABV3+ E U-NET


Classes	DeepLabv3+		U-Net	
	IoU	F1-score	IoU	F1-score
<i>Building (BL)</i>	0.3873	0.6652	0.3788	0.6693
<i>Cultivated Area (CA)</i>	0.1661	0.3210	0.0	0.0074
<i>Forest (FF)</i>	0.0	0.0001	0.0	0.0
<i>Non-Observed Area (NO)</i>	0.3350	0.6370	0.3873	0.6430
<i>Other uses (OU)</i>	0.0	0.0380	0.0	0.0046
<i>Pasture (PA)</i>	0.2920	0.7970	0.1884	0.7818
<i>Savanna Formation (SA)</i>	0.1713	0.5677	0.0	0.0
<i>Water (WT)</i>	0.0	0.1227	0.0	0.0697
Group	mIoU	F1-score	mIoU	F1-score
BNOW score	0.1866	0.2754	0.1822	0.2592
CFPS score	0.1821	0.2859	0.0494	0.0815
Overview	0.1771	0.2775	0.1079	0.1634

AI4LUC: FEW-SHOT LEARNING (FSL)

► INPE, UNIFEI e UFSCar. Base de dados: CerraDatav2 (50.000 amostras).

PERFORMANCE ASSESSMENT: FINE-TUNING APPROACH.

Feature Extraction	Classifier	F1-score	Acc
VGG-11	DNN	83.84 ± 2.60	83.93 ± 2.66
VGG-16*	DNN	86.41 ± 1.22	86.38 ± 1.17
ResNet-18	DNN	83.87 ± 1.91	83.98 ± 1.81
ResNet-50	DNN	85.94 ± 2.18	86.03 ± 2.11
SqueezeNet	DNN	84.49 ± 2.82	84.51 ± 2.80
DenseNet-161**	DNN	86.38 ± 1.45	86.45 ± 1.41
InceptionV3	DNN	77.85 ± 2.92	78.22 ± 2.65
ShuffleNetv2 1.0	DNN	15.16 ± 3.14	24.08 ± 5.90
ResNeXt-50	DNN	84.85 ± 2.08	84.89 ± 2.11
EfficientNet B4	DNN	56.42 ± 5.89	57.81 ± 5.43
ConvNeXt-Tiny	DNN	86.04 ± 2.35	86.10 ± 2.32
VGG-16	RF	82.51 ± 1.05	82.95 ± 0.91
VGG-16	SVM	83.59 ± 0.97	83.87 ± 0.84
DenseNet-161	RF	86.16 ± 0.98	86.22 ± 0.90
DenseNet-161	SVM	86.57 ± 1.36	86.58 ± 1.30



SENSORIAMENTO REMOTO: APLICAÇÃO 3

- ▶ Redes neurais profundas aplicadas para super-resolução de imagens.
- ▶ Apresentação no WorCAP 2023: https://github.com/vsantjr/CAP/blob/master23/Talks/2023/WorCAP/WorCAP%202023_Valdivino%20Santiago%20Jr.pdf




DeepS

Drones

DRONES: APLICAÇÃO 1

- ▶ Detecção de comportamentos de veículos a partir de imagens de drones e de monitoramento.
- ▶ Estudo de caso: mais de 300.000 quadros de vídeo contendo imagens rodoviárias na região do Vale do Paraíba (São Paulo).

DRONES: APLICAÇÃO 1




Redes neurais profundas:


- YOLO (detecção de objetos);
- DeepSORT (rastreamento de objetos);
- LSTM ...

DRONES: APLICAÇÃO 2

- ▶ Redes neurais artificiais para analisar o consumo de energia e prever temperatura de computadores embarcados em veículos aéreos não tripulados (VANTs).
- ▶ Detecção de objetos (imagens e vídeos capturados durante o voo).



DRONES: APLICAÇÃO 2



Método: Analyzing Energy Consumption and Temperature of On-board computer of UAVs via Neural Networks (ETOUNN)

Computador Raspberry Pi 4

Modelos detectores de objeto:

- 1 estágio: 8 modelos da família YOLO;
- 2 estágio: 1 modelo Mask R-CNN.

ETOUNN: CONSUMO DE ENERGIA ELÉTRICA


- ▶ Variáveis: Temperatura do processador (TEMP), Porcentagem de uso de CPU (CPU) e Uso de memória (MEM).
- ▶ Rede Neural Perceptron de Múltiplas Camadas (MLP).
- ▶ Busca manual exaustiva de hiperparâmetros (GRID).
 - Número de camadas: $\{1,2,3,4,5\}$;
 - Número de neurônios por camada: $\{128,256,512\}$;
 - Dropout: $\{0, 0,2, 0,4\}$;
- ▶ Número de modelos MLP: 1.089.

ETOUNN: CONSUMO DE ENERGIA ELÉTRICA

► Resultados: MLP.


Input	C1	Dropout	C2	C3	C4	C5	MSE	R2
i)	256	0,2	x	x	x	x	0,00579	0.83552
i)	256	0,4	128	x	x	x	0,00538	0,84737
i)	128	0,2	128	256	x	x	0,00512	0,85472
i)	512	0,4	512	128	128	x	0,00512	0,85474
i)	128	0,2	128	256	128	256	0,00511	0,85550
ii)	128	0,4	x	x	x	x	0,00102	0,97114
ii)	256	0,4	256	x	x	x	0,00095	0,97307
ii)	256	0.4	512	128	x	x	0,00067	0,98104
ii)	256	0,4	128	256	128	x	0,00058	0,98338
ii)	256	0,2	256	128	256	512	0,00054	0,9847
iii)	128	0,2	x	x	x	x	0,00095	0,9728
iii)	256	0,2	512	x	x	x	0,00068	0,9807
iii)	128	0,4	256	512	x	x	0,00076	0,97835
iii)	256	0,2	512	128	128	x	0,00060	0,98121
iii)	128	0,4	128	256	128	256	0,00056	0,98331

ETOUNN: CONSUMO DE ENERGIA ELÉTRICA




ETOUNN: CONSUMO DE ENERGIA ELÉTRICA

► Melhor MLP.




ETOUNN: PREVISÃO DA TEMPERATURA DO PROCESSADOR

- ▶ Raspberry Pi 4: Temperaturas $< 70\text{ }^{\circ}\text{C}$, evitar temperaturas próximas a $80\text{ }^{\circ}\text{C}$.
- ▶ Objetivo: Prever os próximos 15 segundos de temperatura.
- ▶ Modelos de previsão: LSTM, GRU (versão simplificada de LSTM), N-Beats.



LSTM



N-Beats

ETOUNN: PREVISÃO DA TEMPERATURA DO PROCESSADOR

► Busca manual exaustiva de hiperparâmetros (GRID).

- Número de Camadas: $\{1, 3, 5\}$;
- Neurônios por camada: $\{32, 64, 128\}$;
- *Dropout*: $\{0, 0.3\}$;
- Pontos de entrada: $\{15, 30\}$;

ETOUNN: PREVISÃO DA TEMPERATURA DO PROCESSADOR

► Resultados: Melhor modelo foi uma rede LSTM.

Modelo	MSE	R2
LSTM-GRID	2,6767	0,7864
GRU-GRID	2,6851	0,7726
N-BEATS-GRID	2,7033	0,7748
ARIMA	4,4877	0,7286

ETOUNN: PREVISÃO DA TEMPERATURA DO PROCESSADOR

- ▶ Sintonização automática de hiperparâmetros.



- ▶ Detalhes:
 - ▶ Tamanho do subconjunto de treinamento: 25%, 50%, 75%, 100% do tamanho original;
 - ▶ Modelos LSTM: 108 para cada subconjunto de dados de treinamento;
 - ▶ Modelos GRU: 108 para cada subconjunto de dados de treinamento.

ETOUNN: PREVISÃO DA TEMPERATURA DO PROCESSADOR

- ▶ Busca automática de hiperparâmetros (Optuna).
 - Número de Camadas: $\{1,3,5\}$;
 - Neurônios camada 1: Grid $\{32,64,128\}$ Optuna $\{32 \text{ até } 128\}$;
 - Neurônios camada 2: Grid $\{64,128\}$ Optuna $\{32 \text{ até } 128\}$;
 - Neurônios camada 3: Grid $\{64,128\}$ Optuna $\{32 \text{ até } 128\}$;
 - Neurônios camada 4: Optuna $\{32 \text{ até } 128\}$;
 - Neurônios camada 5: Optuna $\{32 \text{ até } 128\}$;
 - *Dropout*: Grid $\{0, 0.3\}$ Optuna $\{0 \text{ até } 0.3\}$;
 - Pontos de entrada: Grid $\{15, 30\}$ Optuna $\{15 \text{ até } 30\}$;


ETOUNN: PREVISÃO DA TEMPERATURA DO PROCESSADOR

► Resultados: Melhor foi uma rede LSTM-Optuna.

Modelo	% Dados	LB	C1	D	C2	C3	C4	C5	MSE
LSTM-Grid	100%	30	128	0,3	64	64	32	32	2,6767
LSTM-Grid	75%	30	128	0,3	64	64	32	32	2,7703
LSTM-Grid	50%	30	128	0,3	64	32	32	X	3,0777
LSTM-Grid	25%	30	128	0,3	64	64	32	32	6,9458
LSTM-Optuna	100%	25	83	0,1733	105	86	39	39	2,6482
LSTM-Optuna	75%	25	82	0,1503	42	47	84	82	2,6579
LSTM-Optuna	50%	29	32	0,1385	41	93	59	X	2,6651
LSTM-Optuna	25%	27	36	0,1719	42	98	81	87	4,4498
GRU-Grid	100%	30	128	0,3	64	64	32	32	2,6851
GRU-Grid	75%	30	128	0,3	64	32	X	X	2,7652
GRU-Grid	50%	30	128	0,3	64	64	32	32	2,9768
GRU-Grid	25%	30	64	0,3	64	64	32	32	3,6939
GRU-Optuna	100%	29	114	0,2331	115	89	40	89	2,6495
GRU-Optuna	75%	30	67	0,0796	66	X	X	X	2,8317
GRU-Optuna	50%	28	66	0,1863	98	39	X	X	2,8583
GRU-Optuna	25%	30	102	0,1929	30	95	X	X	3,0865

ETOUNN: PREVISÃO DA TEMPERATURA DO PROCESSADOR

- ▶ Variando o tamanho do subconjunto de treinamentos.



ETOUNN: VERSÃO FINAL DO MÉTODO

- Adicionada sintonização automática de hiperparâmetros para prever temperatura. Modelos analisados: 1.082.


Modelo	MSE	R2
LSTM-OPTUNA	2,6482	0,7739
GRU-OPTUNA	2,6495	0,7782
CNN-OPTUNA	2,6636	0,7719
LSTM-GRID	2,6767	0,7864
GRU-GRID	2,6851	0,7726
N-BEATS-OPTUNA	2,691	0,7763
RNN-OPTUNA	2,693	0,7816
RNN-GRID	2,6999	0,7835
N-BEATS-GRID	2,7033	0,7748
CNN-1D-GRID	2,8782	0,7514
ARIMA	4,4877	0,7286
PROPHET	5,2225	0,7207

Resultados: Melhor foi uma rede LSTM-Optuna.

ETOUNN: VERSÃO FINAL DO MÉTODO

► Três melhores modelos.


Modelo	LB	C1	D	C2	C3	C4	C5	MSE	Tempo (s)
LSTM-OPTUNA	25	83	0,1733	105	86	39	39	2,6482	681,16
GRU-OPTUNA	29	114	0,2331	115	89	40	89	2,6495	595,06
CNN-OPTUNA	27	113	x	119	x	x	x	2,6636	14,06



COLABORADORES

- ▶ Mateus de Souza Miranda (INPE).
- ▶ Renato de Sousa Maximiano (ex-INPE; EMBRAER).
- ▶ Rafael Marinho de Andrade (INPE).
- ▶ Bruno Nardi de Carvalho Dantas (ex-ITA).
- ▶ Lucas Fernando Alvarenga e Silva (ex-UNIFESP; UNICAMP).
- ▶ Samuel Felipe dos Santos (ex-UNIFESP).
- ▶ Thales Sehn Körting (INPE; orientador).
- ▶ Elcio Hideiti Shiguemori (IEAv; orientador).
- ▶ Jurandy Gomes de Almeida Junior (UFSCar; orientador).
- ▶ Tahisa Neitzel Kuck (IEAv; orientadora).

OBRIGADO!



E-mail: valdivino.santiago@inpe.br

Web: <http://www.lac.inpe.br/~valdivino/>



GitHub: <https://github.com/vsantjr>