



DESENVOLVIMENTO E AVALIAÇÃO DA TÉCNICA DE *OFFLOADING* DE IMAGENS EM SERVIDORES CLOUDLETS COM VEÍCULOS AÉREOS NÃO TRIPULADOS

João Lucas Ribeiro Barbosa (Bolsista/Apresentador)¹ – Unifesspa
engjoaobarbosa@gmail.com

Warley Muricy Valente Junior (Coordenador(a) do Projeto)² - Unifesspa
wmvj@unifesspa.edu.br

Agência Financiadora: PIBIC/FAPESPA

Eixo Temático/Área de Conhecimento: Redes de Computadores e Sistemas Distribuídos

1. INTRODUÇÃO

UAVs (*Unmanned Aerial Vehicles* - Veículos Aéreos Não Tripulados) são máquinas voadoras, equipadas com pequenos motores, baterias e controladores de hardware que proporcionam o recebimento de comandos e controle ao dispositivo (MUKHERJEE et. al., 2020). Sendo vantajoso para utilização em diversas aplicações civis (e militares), o UAV se mostra capaz para missões de busca e resgate, monitoramento de tráfego, sensoriamento remoto, entre outros, graças a sua facilidade de lançamento, mobilidade e capacidade dinâmica de voo. Entretanto, com a evolução computacional de novas tecnologias, aplicações que executam em tempo real geram demandas maiores de processamento e armazenamento, necessitando de cada vez mais recursos. Tal evolução tem como consequência baterias incapazes de suprir o gasto energético por longos períodos. Para solucionar o problema de gasto energético, soluções como *Fog Computing* (Computação na névoa) se mostram viáveis por conta do *Offloading Computacional*, que é a transferência da carga de processamento do dispositivo (UAV) para servidores em nuvem próximos ao usuário (nesse caso, base controladora do UAV) (JUNIOR; SILVA; DIAS, 2018).

Desse modo, o presente trabalho teve como objetivo desenvolver uma arquitetura envolvendo *Fog Computing* que realiza o *offloading* computacional do UAV para a nuvem (*cloudlet*), usando variados algoritmos classificadores de aprendizagem de máquina para comparação e avaliação entre o melhor recurso disponível de processamento, juntamente com uma aplicação de detecção e reconhecimento facial como ferramenta de *benchmarking*.

2. MATERIAS E MÉTODOS

Fizeram parte do referencial teórico *surveys*, seminários e artigos publicados em revistas de amplo conhecimento da comunidade científica, como Springer, Elsevier e outras. Como componentes físicos do cenário proposto podemos listar um Parrot AR Drone (UAV), duas máquinas virtuais (VMs) nos servidores do CTIC (*cloudlet*) e um notebook (orquestrador responsável por selecionar em qual VM realizar o *offloading* de imagens).

¹ Graduado em Sistemas de Informação - Universidade Federal do Sul e Sudeste do Pará

² Doutor em Ciência da Computação – Professor Adjunto da Universidade Federal do Sul e Sudeste do Pará (FACEEL/IGE/Unifesspa).

De acordo com a Figura 1, inicialmente é realizada a coleta de dados do processo de *offloading* de imagens (tamanho da imagem, nível da bateria do UAV, valores de RTT e RSSI, bem como porcentagens de utilização de CPU e RAM), com os dados persistidos em uma tabela utilizando o SGBD (Sistema de Gerenciamento de Banco de Dados) MySQL. Com os dados brutos, são inicialmente realizadas análises com um algoritmo na estrutura *if-else*, comparando e rotulando em qual VM houve uma execução com menos tempo. Com os dados rotulados, são então eliminados aqueles que possuam valores que excedem acentuadamente a média dos valores gerais no banco de dados (*outliers*), visto que tais valores não são confiáveis para avaliação de desempenho por serem “pontos fora da curva”.

Após isso, os dados brutos são padronizados: diferentes recursos são trazidos para uma mesma escala. As padronizações se encaixam no processo apresentado, pois alguns classificadores lineares (como Regressão Logística e SVM) inicializam os pesos em 0, ou valores aleatórios próximos de 0. Com isso, os dados ficam preparados para então serem avaliados utilizando 6 (seis) classificadores, tendo como métricas a acurácia, F1, entre outras. Os classificadores utilizados foram: MLP, Regressão Logística, SVM, Random Forest, Naive Bayes e Dummy. Esses classificadores foram utilizados pois requerem menos recursos (como processamento e memória, por exemplo) do que técnicas de *Deep Learning* e possuem níveis de precisão aceitáveis.

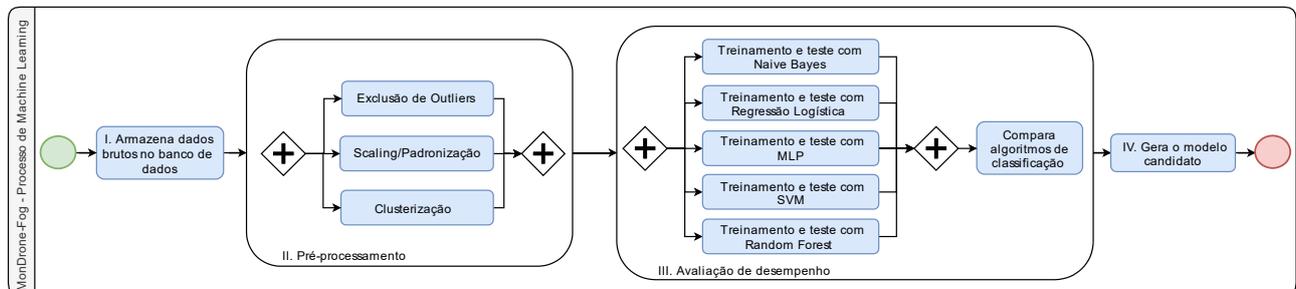


Figura 1 - Processo de avaliação de desempenho dos classificadores.

3. RESULTADOS E DISCUSSÃO

Os primeiros resultados referentes à arquitetura e provas de conceito são discutidos no artigo (BARBOSA et al., 2019). No que se refere ao desempenho dos classificadores, os resultados da Tabela 1 mostram que MLP e Regressão logística foram os algoritmos que tiveram uma maior taxa de previsões corretas dos registros (*offloading* para VM01), bem como superaram com grande vantagem algoritmos como SVM e Naive Bayes. Na métrica “especificidade”, o classificador MLP obteve o valor de 99.63%, ligeiramente maior que a Regressão Logística (com uma diferença de 0.18%) e uma diferença de 1.55%, se comparado ao classificador SVM.

As métricas FPR e FNR se referem a taxa de erros. São métricas importantes, pois em um cenário de resgate, por exemplo, uma taxa de erro alta pode gerar seleção errônea de recurso para *offloading*, o que pode custar a vida de uma pessoa. A Tabela 1 mostra que MLP e Regressão logística possuem FPR menor (0.24% e 0.84%) em comparação com SVM, Random Forest e Naive Bayes. Nota-se, também, que o algoritmo MLP possui o menor valor de FNR.

Tabela 1 - Média de cada métrica mensurada com os algoritmos (%)

Algoritmo	Precisão	FPR	FNR	Sensitividade	Especificidade
MLP	99.76 ± 0.21	0.24 ± 0.21	0.51 ± 0.24	99.49 ± 0.24	99.63 ± 0.17
R. Logística	99.16 ± 0.14	0.84 ± 0.14	0.73 ± 0.13	99.27 ± 0.13	99.45 ± 0.08
SVM	98.28 ± 0.30	1.72 ± 0.30	2.56 ± 0.25	97.44 ± 0.25	98.08 ± 0.22
R. Forest	97.27 ± 0.21	2.73 ± 0.21	3.49 ± 0.35	96.51 ± 0.35	97.47 ± 0.34
Naive Bayes	97.89 ± 0.19	2.11 ± 0.19	11.38 ± 0.31	97.31 ± 0.25	90.71 ± 0.36
Dummy	57.22 ± 0.77	42.78 ± 0.77	57.71 ± 1.20	42.02 ± 2.07	57.52 ± 1.82

Com o objetivo de mitigar taxas de erro incoerentes, advindas de dados não balanceados/padronizados, foram utilizadas as funções simétricas F1-score e G-mean, que dão a mesma relevância a ambos componentes (destinos de *offloading*). A Figura 2 ilustra os resultados relacionados à Precisão, F1 e G-mean correspondentes a Regressão Logística (LR), Random Forest (RF), Multilayer Perceptron (MLP), Support Vector Machine (SVM), Naive Bayes (NB) e Dummy (DM). No gráfico podemos ver que o classificador MLP supera, mesmo que levemente em alguns casos, todos os outros algoritmos e o algoritmo Naive Bayes registra o pior valor de precisão (93.53%) dos registros corretamente classificados.

Em termos gerais, o algoritmo Dummy se mostra com o pior desempenho na base de dados em relação aos demais, o que ocorre devido ao fato de que o algoritmo utiliza regras simples para realizar as previsões. O Dummy, portanto, acaba servindo como uma simples linha de base para comparações com os nossos outros classificadores (mais complexos em termos de predição).

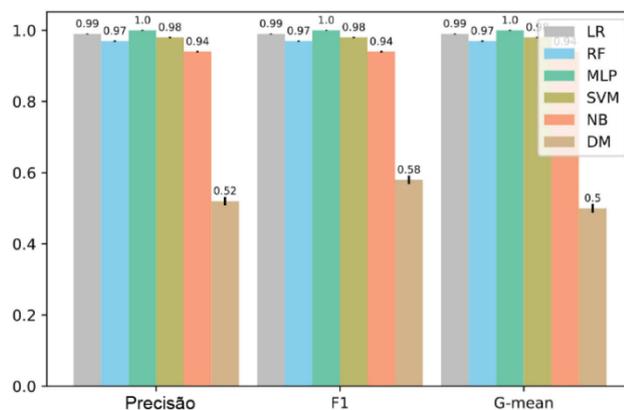


Figura 2 - Comparação entre o desempenho dos classificadores.

Para determinar se as diferenças de desempenho dos algoritmos MLP e Regressão Logística são, de fato, significantes, é utilizado o Teste de Friedman (com intervalo de confiança de 95%). O Teste de Friedman é um equivalente não-paramétrico à análise de variância (ANOVA - *Analysis of Variance*). No teste é realizado um ranqueamento dos algoritmos para cada validação cruzada (separadamente), com o melhor algoritmo recebendo o ranque 1, o segundo melhor recebendo o ranque 2, e assim por diante. Desse modo, o algoritmo de pior desempenho recebe um ranque igual a quantidade de algoritmos disponíveis (6, nesse caso).

Quando a hipótese de nulidade do Teste de Friedman (que diz que todos os classificadores são equivalentes) é rejeitada, é realizado o teste de Nemenyi para determinar quais classificadores são significativamente diferentes. Se a diferença entre as classificações médias de dois classificadores for maior do que a diferença crítica (CD) de 1.377, então o desempenho desses algoritmos se difere de forma significativa. A Figura 3 ilustra o processo, exibindo os resultados para o teste estatístico MCB (*Multiple Comparison with Best*).

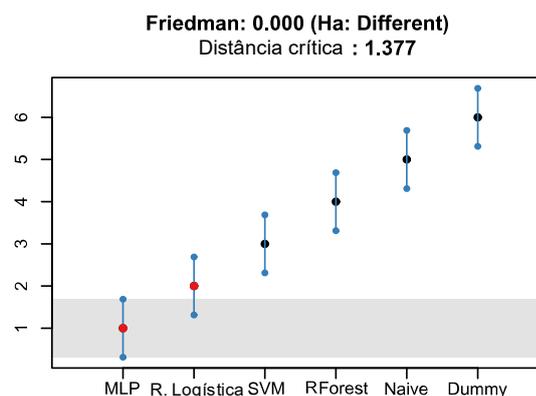


Figura 3 - Testes de Friedman e Nemenyi para comparações não-paramétricas entre os algoritmos.



A Tabela 2 mostra o ranqueamento médio de cada classificador juntamente com a distância crítica, a fim de mostrar claramente algoritmos que sejam significativamente diferentes. Desse modo, os testes estatísticos de Friedman e Nemenyi mostram que os classificadores MLP e Regressão Logística possuem desempenho melhor que os classificadores Random Forest e Naive Bayes na nossa base de dados. Com essa análise, podemos utilizar um modelo de “votação” onde os classificadores com desempenho melhor (MLP e Regressão Logística) possuem peso maior de decisão, melhorando o processo de escolha de recurso de *offloading*.

Tabela 2 – Ranqueamento médio de cada classificador.

Algoritmo de predição							
	MLP	R. Logística	SVM	R. Forest	Naive Bayes	Dummy	Distância Crítica
Posição	1	2	3	4	5	6	-
Valor	1.00	2.00	3.00	4.00	5.00	6.00	1.377

4. CONSIDERAÇÕES FINAIS

Os resultados obtidos mostram que a arquitetura proposta pode ser utilizada para avaliar o desempenho de aplicações de reconhecimento e detecção facial ao realizar o *offloading* de imagens em floresta densa (ou outras situações adversas, como operações de busca e resgate). Os classificadores MLP e Regressão Logística alcançaram precisão de 99.64% e 99.20%, respectivamente, o que pode facilitar na tomada de decisão correta de *offloading* e, conseqüentemente, melhorar o tempo de execução e diminuir o consumo de energia do UAV.

Além disso, os resultados mostram com clareza os melhores classificadores a serem utilizados na arquitetura proposta, sendo eles MLP e Regressão Logística, pelo fato de possuírem o melhor desempenho de classificação na base de dados.

A arquitetura atual é focada em uma decisão de *offloading* binária, tendo o processamento de imagens na *cloudlet* com dois recursos (VM01 e VM02). Como expectativa para trabalhos futuros, a inserção de uma *Microfog* no cenário da arquitetura proposta pode diversificar a quantidade de recursos de *offloading*, com o potencial de tornar o ambiente de processamento heterogêneo e dinâmico.

REFERÊNCIAS

BARBOSA, João et al. Análise de Desempenho da Técnica de Offloading de Imagens com Drone em Ambiente de Computação em Névoa. In: **Anais do XVIII Workshop em Desempenho de Sistemas Computacionais e de Comunicação**. SBC, 2019.

JUNIOR, Warley; SILVA, Bruno; DIAS, Kelvin. A systematic mapping study on mobility mechanisms for cloud service provisioning in mobile cloud ecosystems. **Computers & Electrical Engineering**, v. 69, p. 256-273, 2018.

MUKHERJEE, Amartya; DEY, Nilanjan; DE, Debashis. EdgeDrone: QoS aware MQTT middleware for mobile edge computing in opportunistic Internet of Drone Things. **Computer Communications**, v. 152, p. 93-108, 2020