

IDENTIFICAÇÃO DE ESTRESSE EM PLANTAS NO CAMPO: UMA ALTERNATIVA COM COMPUTAÇÃO EM NÉVOA

GREGORY SEDREZ¹; GUILHERME DE SOUZA²; GABRIEL DE TOLEDO³;
JANICE F. SILVEIRA⁴; GERSON GERALDO H. CAVALHEIRO⁵

¹Universidade Federal de Pelotas – gdbsedrez@inf.ufpel.edu.br

²Universidade Federal de Pelotas – gdsdsilva@inf.ufpel.edu.br

³Univerdidade Federal de Pelotas – gabriel.de.toledo@hotmail.com

⁴Vantum – janice@vantum.com.br

⁵Universidade Federal de Pelotas – gerson.cavalheiro@inf.ufpel.edu.br

1. INTRODUÇÃO

Em razão do aumento na produção/consumo de dados, decorrentes do crescimento do emprego de dispositivos IoT (Internet of Things) (GUBBI et al, 2013), o uso das nuvens computacionais também cresceu, aumentando as demandas por recursos de processamento, CPU e memória, da própria nuvem e a competição pelos recursos de rede providos pela Internet. Porém, mesmo sob a premissa de recursos infinitos, a nuvem conta com limitações fundamentais na sua arquitetura e no design. Como segurança, interoperabilidade e a inundação do tráfego da rede pela grande quantidade de dados gerados continuamente (MELL et al, 2011).

Para mitigar estas limitações em aplicações do mundo real, novas tecnologias oferecem novos modelos para consumo e manipulação dos dados, reduzindo, eventualmente eliminando, o papel do uso de servidores na nuvem. Assim novas tecnologias como Computação na Borda (SHI et al, 2016) e Computação em Névoa (BONOMI et al, 2012), tentam suprir o desafio de aplicações emergentes, como a necessidade de maior confiabilidade, peso de hardware (tamanho, local e número de máquinas) e consumo de rede e energia (BAYERS, 2017).

O conceito de *Smart Farms* tem crescido nos últimos anos com o uso de dispositivos IoT. Seu uso vem permitindo fornecer aos agricultores e pecuaristas, dados quase que em tempo real sobre as condições da fazenda. A disponibilidade de informação sobre a cultura ou a criação permite tomadas de decisão que viabilizam a agricultura e pecuária de precisão, com perspectiva de aumento de produtividade e, consequentemente, lucros. Assim o uso de estratégias de inteligência artificial (LI et al, 2018) têm sido incorporados às soluções, com potencial de reduzir a interferência humana nos processos de manejo no campo.


Neste artigo é estudada a viabilidade de emprego de técnicas de classificação na identificação do estado de estresse em plantas sobre dispositivos de processamento na borda. O trabalho apresentado estende resultados anteriores de TOLEDO (2019), no qual técnicas de classificação do estado de estresse de plantas foi realizado com sucesso utilizando redes neurais e aprendizado de máquina.

Neste estudo complementar, um cenário de aplicação na agricultura de precisão foi concebido e avaliado o uso da *small board* NVIDIA Jetson Nano especialmente projetado para aplicações de inteligência artificial na computação na névoa.

2. METODOLOGIA

Em uma cultura, um conjunto de plantas é selecionado para monitoramento. É esperada uma distribuição destas plantas pela área de plantio, permitindo que cada indivíduo monitorado represente a situação das plantas de seu entorno. Este dispositivo de monitoramento é capaz de armazenar a série temporal que representa a evolução do sinal eletromagnético da planta. Este dispositivo também é capaz de responder, via rede wifi, a solicitação do envio dos dados coletados.

Imagem 1: Modelo da aplicação concebido.



Um implemento agrícola circula, eventualmente, sobre esta plantação, pulverizando insumos agrícolas, como adubo ou defensivos, ou mesmo água. A quantidade de produto a ser pulverizada em uma determinada área é identificada pela classificação do nível de estresse do indivíduo monitorado naquela região.

O objeto de estudo neste trabalho é identificar a viabilidade da utilização da *small board* NVIDIA Jetson Nano. O Jetson Nano é um dispositivo focado em atender às recentes demandas de tratamento de dados nas bordas.

Tabela 1: Especificações Técnicas Do Dispositivo Jetson Nano De Acordo Com o Fabricante.

GPU	Arquitetura NVIDIA Maxwell™ com 128 NVIDIA CUDA® cores
CPU	Processador Quad-core ARM® Cortex®-A57 MPCore
Memória	4 GB 64-bit LPDDR4
Armazenamento	16 GB eMMC 5.1 Flash
Vídeo Encode/Enconde	4K @ 30 (H.264/H.265) / 4K @ 60 (H.264/H.265)
Câmera	12 lanes (3x4 or 4x2) MIPI CSI-2 DPHY 1.1 (18 Gbps)
Conectividade	Gigabit Ethernet
Visor	HDMI 2.0 ou DP1.2 eDP 1.4 2 DSI simultâneos (1 x2)
UPHY	1 x1/2/4 PCIe, 1x USB 3.0, 3x USB 2.0
I/O	1x SDIO / 2x SPI / 4x I2C / 2x I2S / GPIOs -> I2C, I2S
Dimensões	69.6 mm x 45 mm
Mecânica	Conector de ponta com 260 pinos

Dispondo de uma GPU para processamento, este dispositivo é capaz de suportar a execução de programas com grandes necessidades de processamento, como tratamento de imagens, visão computacional e *deep learning*, como é o caso deste trabalho, com baixo consumo energético (entre de 5 a 10 watts). Dado as suas características, o Jetson Nano supre as quatro

grandes necessidades apresentadas pelo conceito de borda como confiabilidade, peso de *hardware*, latência e consumo energético. Na Tabela 1 todas as demais informações podem ser vistas, conforme disponibilizado pelo fornecedor.

As séries temporais que representam os dados coletados das plantas são armazenados em um arquivo texto, uma amostra por linha, com um total de 450 mil amostras, representando duas horas de coletas de dados: 62 amostras por segundo. Esta entrada inicial é pré-processada de forma a reduzir a quantidade de dados a ser manipulada nas etapas subsequentes. Neste pré-processamento, cada intervalo de 30 mil pontos, correspondendo à aproximadamente 8 minutos, passa ser representado por uma tripla, descrevendo os valores máximo, médio e mínimo. O intervalo de 30 mil pontos foi adotado neste momento por ter sido aquele que apresentou um melhor resultado na acurácia (TOLEDO, 2019).

O resultado obtido é o de uma demanda de processamento menor para os algoritmos de classificação, sem perda na qualidade do resultado. Estes valores são armazenados em uma planilha no formato .csv, em que cada linha representa um intervalo da medição, sendo as três primeiras colunas são respectivas aos valores mínimo, médio e máximo do intervalo. No treinamento, a quarta coluna informa se a planta possui algum estresse.

Foram utilizados os seguintes algoritmos de classificação: K-NN, SVM e ANN. As implementações foram em Python, sendo utilizada a biblioteca scikit-learn nos dois primeiros e Tensorflow no segundo. No que diz respeito à acurácia da classificação, os resultados obtidos com K-NN e SVM mostraram os melhores resultados, atingindo 70% e 60%, respectivamente, de acerto. ANN apresentou uma taxa de acertos inferior, de 54%.

Para obtenção dos resultados, os algoritmos selecionados foram executados tanto em um desktop como na Jetson Nano afim de um comparativo, visando identificar a distância dos tempos de processamento obtidos em ambos.

Os tempos correspondem a uma média de 30 execuções, onde a distribuição das amostras corresponde à uma normal. O processamento no desktop (Intel i5, 2/4 *cores/threads*, 8 GB RAM) foi realizado todo em CPU; no Jetson Nano empregando a GPU acoplada. Estes tempos não contabilizam a segmentação da série temporal em intervalos de 30 mil pontos, o qual é de, aproximadamente 54 e 38 segundos, respectivamente, no Jetson Nano e no desktop.

3. RESULTADOS E DISCUSSÃO

No que diz respeito a acurácia de classificação como visto na Tabela 2, K-NN e SVM apresentaram melhor classificação dos estímulos aos quais as plantas foram submetidas nos experimentos de bancada. Já o ANN apresentou índices de acurácia inferior. Entende-se necessário um estudo mais aprofundado dos parâmetros aplicados aos algoritmos de classificação para, em um processo de *tunning*, identificar a melhor configuração para a aplicação em questão.

Os aspectos ligados ao tempo de processamento da classificação no Jetson Nano são os mais relevantes neste trabalho. Considerando que a velocidade de um implemento agrícola sobre uma cultura deva ser inferior a 15km/h, implicando em um deslocamento de aproximadamente 4m/s.

Assim os tempos inferiores à 0,2 segundos, na maioria dos casos apontados para classificação, implica em um deslocamento de 1,3m. No entanto, o tempo de obtenção da representação da rede na forma de intervalos de 30 mil amostras consome uma considerável fatia de tempo: 54 segundos, considerando uma entrada de dados de 450 mil amostras. Em termos de deslocamento, o

implemento agrícola teria percorrido mais de 200m, se afastando da região onde a medição foi realizada.

Tabela 2: Tempo De Classificação Dos Algoritmos (Tempo Em Segundos)

	Desktop			Jetson Nano		
	ANN	KNN	SVM	ANN	KNN	SVM
NaCl	0.14	0.11	0.05	2.9	0.15	0.20
Polietilenoglicol	0.13	0.11	0.06	3.0	0.14	0.19
NaCl + Polietilenoglicol	0.14	0.12	0.20	3.0	0.16	0.70

Deve ainda ser considerado que, os tempos apresentados, devem ser somados os tempos de comunicação dos dados do dispositivo ligado ao sensor ao dispositivo embarcado no implemento. Considerando uma taxa de 980bps em uma rede LoRA, bastante popular como infraestrutura de rede em aplicações para *smart farms*, o tempo de comunicação de uma série temporal de 450 mil amostras, que corresponde à cerca 6MB, consumiria cerca de 20min.

4. CONCLUSÕES

Neste trabalho foi estudada a viabilidade técnica do uso de um equipamento de borda, a NVIDIA Jetson Nano, para promover a execução de algoritmos de classificação de séries temporais em campo. A análise do desempenho mostrou que, sim, este tipo de dispositivo pode ser utilizado com sucesso para o fim específico. No entanto, o estudo realizado mostrou que, considerando as questões que envolvem a implantação real da aplicação, outros fatores devem ser considerados. A questão do volume de dados representado por uma série temporal apresenta um conjunto de dificuldades que devem ser tratados para viabilizar o sucesso da implantação do cenário proposto.

5. REFERÊNCIAS BIBLIOGRÁFICAS

LI, H.; OTA, K.; DONG, M. Learning IoT in Edge: Deep Learning for the Internet of Things with Edge Computing. **IEEE Network**, v.32, n.1, p.96-101, 2018.

BONOMI, F.; MILITO, R.; ZHU, J. ADDEPALLI, S. Fog Computing and Its Role in the Internet of Things. **Proceedings of the First Edition of the MCC Workshop on Mobile Cloud Computing**. Helsinki, Finland, p.13-16, 2012.

SHI, W., CAO, J., ZHANG, Q., LI, Y., XU, L. Edge Computing: Vision and Challenges. **IEEE Internet of Things Journal**. V.3, n.5, p.637-645, 2016.

MELL, P., GRANCE, T. **The NIST definition of cloud computing**. 2011.

GUBBI, J. BUYYA, R. MARUSIC, S. PALANISWAMI, M. Internet of Things (IoT): A vision, architectural elements, and future directions. **Future generation computer systems**. V.29, n.7, p.1645-1660, 2013.

BYERS, C. C. Architectural Imperatives for Fog Computing: Use Cases, Requirements, and Architectural Techniques for Fog-Enabled IoT Networks. **IEEE Communications Magazine**. V.55, n.8, p.14-20, 2017.

TOLEDO, G. R. A. **Caracterização eletrofisiológica do feijão *Phaseolus vulgaris* L.) cv. BRS-Expedido sob diferentes disponibilidades hídricas**. 2019. Tese (Doutorado em Fisiologia Vegetal) - Curso de Pós-graduação em Fisiologia Vegetal, Universidade Federal de Pelotas.