

IDENTIFICAÇÃO DE LACUNAS NAS LINHAS DE CULTIVO UTILIZANDO ALGORÍTMOS COMPUTACIONAIS

Emanuel Percinio Gonçalves de Oliveira - EESC e ICMC - USP

Prof. Assoc. Marcelo Becker - SEM - EESC - USP

Universidade de São Paulo

emanueloliveira@usp.br

Objetivos

O presente projeto tem como principal objetivo a identificação de lacunas em linhas de cultivo. Para tal, é feita a coleta de dados com o sensor LiDAR com o intuito de identificar padrões utilizando os algoritmos estatísticos e de aprendizado de máquina propostos. Finalmente, para a escolha da melhor solução, serão utilizadas métricas de validação de modelos e de desempenho de algoritmos.

Métodos e Procedimentos

O desenvolvimento desse projeto de pesquisa se deu por meio de 4 etapas principais. As duas primeiras foram o estudo teórico do sistema operacional ROS e dos algoritmos de análise estatística, de processamento de imagens e de aprendizado de máquina cogitados para a implementação da solução; a terceira e a quarta etapas foram realizadas a partir da implementação e validação dos CAs escolhidos para a identificação das lacunas, respectivamente. Para isso, foi utilizada a linguagem Python para realização das etapas de implementação dos CAs. Neste projeto de pesquisa, utilizou-se o robô TerraSentia da empresa EarthSense, uma plataforma de 30cm de largura e 14,5 kg de massa. Seu uso no cultivo costuma ser na coleta de dados do solo com o auxílio de suas 3 câmeras e sensor LiDAR. O sensor LiDAR em questão consiste de um 2D UST-10LX da empresa Hokuyo, com capacidade de fornecer a uma velocidade de 25 ms, a distância de objetos em uma

varredura de 270° e distância máxima de 10 m com precisão de ± 40 cm. A coleta de dados foi feita em ambiente simulado no laboratório com canos PVC e folhas secas formando uma “linha de cultivo” (Figura 1), onde o robô era direcionado para percorrer e fazer a coleta com o LiDAR. As nuvens de pontos obtidas foram, então, processadas com o auxílio de algoritmos como o DBSCAN para exclusão de *outliers* e técnicas de geração de novos dados (*data augmentation*). Em seguida, são aplicados os algoritmos propostos, sendo eles: Estatística de Moran Local por meio de Diagramas de Voronoi; algoritmos clássicos de Aprendizado de Máquina; e técnicas de Deep Learning.




Figura 1: Teste Indoor para coleta de dados.

Resultados

A princípio, a aplicação da Estatística de Moran Local não apresentou resultados satisfatórios

para a identificação das lacunas. Então as imagens geradas pelos Mapas de Moran foram aproveitadas para o treinamento de uma Rede Neural Convolutiva apresentando um desempenho de 99,16% de acurácia na identificação de lacunas. Com relação clássicas de Aprendizado de Máquina, quatro foram estudadas mais a fundo sendo elas: Árvores de Decisão; *Gradient Boosting*; Redes Neurais Artificiais rasas; e *Random Forest*. Apresentando, respectivamente, 98,09%, 98,09%, 97,47% e 97,02% de acurácia na identificação de lacunas no cultivo (Figura 2).

Algoritmo Computacional	Acurácia
CNN	99.16%
Decision Tree	98.09%
Gradient Boosting	98.09%
ANN	97.47%
Random Forest	97.02%

Figura 2: Resultado obtido para cada algoritmo.

Conclusões

Com os resultados obtidos por meio das implementações realizadas nesse projeto de pesquisa é possível concluir a gama possibilidade de algoritmos para a identificação de lacunas no cultivo com grande eficiência. Apesar da inconsistência no uso da Estatística de Moran Local, essa ainda se mostrou útil como ferramenta de construção dos Mapas de Moran que, por si, foram úteis nas tarefas de aprendizado. O projeto abre, então, a possibilidade de estudo e implementação dos algoritmos diretamente no robô para validação da identificação em tempo real e escolha da melhor solução.

Agradecimentos

Agradeço imensamente ao professor Marcelo Becker por ter aberto as portas da pesquisa científica para mim e me oferecido essa oportunidade. A conclusão desse projeto também não seria possível sem o auxílio do atual Dr. Leonardo Bonacini que terminou seu doutorado e me ajudou durante o

desenvolvimento da pesquisa, me guiando nos estudos e sanando eventuais dúvidas.

Referências

- A. Ahmadi, M. Halstead and C. McCool, "Towards Autonomous Visual Navigation in Arable Fields," 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Kyoto, Japan, 2022, pp. 6585-6592, doi: 10.1109/IROS47612.2022.9981299.
- ANSELIN, Luc. Local indicators of spatial Association—LISA. *Geographical Analysis*, [S. l.], v. 27, p. 93–115, 1995. DOI: <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>.
- AURÉLIEN GÉRON. Hands-on machine learning with Scikit-Learn and TensorFlow concepts, tools, and techniques to build intelligent systems. [s.l.] : O'Reilly Media, Inc., 2019.
- BELLELLI, Francesco S. The fascinating world of Voronoi diagrams. 2021. Disponível em: <https://fbellelli.com/posts/2021-07-08-the-fascinating-world-of-voronoi-diagrams/>.
- Breiman, L. Random Forests. *Machine Learning* 45, 5–32 (2001). <https://doi.org/10.1023/A:1010933404324>.
- Chen, J., Qiang, H., Wu, J., Xu, G., & Wang, Z. (2021). Navigation path extraction for greenhouse cucumber-picking robots using the prediction-point Hough transform. *Computers and Electronics in Agriculture*, 180, 105911. <https://doi.org/10.1016/j.compag.2020.105911>.
- HIGUTI, V. A. H. 2D LiDAR-based Perception for Under Canopy Autonomous Scouting of Small Ground Robots within Narrow Lanes of Agricultural Fields. 2021. 118p. Ph.D. Thesis - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2021.
- Velasques, Andres E. B.; AKIHIRO HISANO HIGUTI, VITOR; GASPARINO, Valverde; SIVAKUMAR, Narenthiran; BECKER, Marcelo; CHOWDHARY, Girish. Multi-sensor fusion based robust row following for compact agricultural robotsarXiv e-prints. [s.l: s.n.].