

## Algoritmo de Identificação de Obstrução de Sinal de GNSS para Agricultura de Precisão

**Handel Emanuel Natividade Peres<sup>1</sup>, Leonardo Bonacini<sup>2</sup>, Mario Luiz Tronco<sup>3</sup>,  
Marcelo Becker<sup>4</sup>, Vivian Suzano Medeiros<sup>5</sup>**

<sup>1</sup>Centro de Robótica da USP, Escola de Engenharia de São Carlos, Universidade de São Paulo, Brasil. Email: handelnatividade@usp.br

<sup>2</sup>Centro de Robótica da USP, Escola de Engenharia de São Carlos, Universidade de São Paulo, Brasil. Email: leobonacini@usp.com

<sup>3</sup>Centro de Robótica da USP, Escola de Engenharia de São Carlos, Universidade de São Paulo, Brasil. Email: mltronco@sc.usp.br

<sup>4</sup>Centro de Robótica da USP, Escola de Engenharia de São Carlos, Universidade de São Paulo, Brasil. Email: becker@sc.usp.br

<sup>5</sup>Centro de Robótica da USP, Escola de Engenharia de São Carlos, Universidade de São Paulo, Brasil. Email: viviansuzano@usp.br

### Resumo

O GNSS (*Global Navigation Satellite System*) vem sendo pesquisado como instrumento de auxílio em máquinas agrícolas desde meados da década de 90. Utiliza-se ele, principalmente, em conjunto com outros sensores na agricultura de precisão para o planejamento, mapeamento e execução das tarefas na lavoura, o que resulta em um expressivo aumento da produtividade e maior eficiência dos processos. Entretanto, a obstrução do sinal de GPS é um problema comum que pode levar a erros no posicionamento. Neste contexto, o presente artigo coletou dados de GNSS em uma lavoura de cana de açúcar com um robô terrestre e a partir da análise exploratória dos dados, por meio de gráficos de dispersão, diagramas de caixa e coeficientes de correlação, propõe um algoritmo de classificação para identificar a existência de obstrução do sinal de GNSS e, deste modo, selecionar o melhor método de navegação para tais condições, diminuindo as chances de acidentes na lavoura.

**Palavras chave:** GNSS; Robôs Agrícolas; Aprendizado de Máquina; Navegação Autônoma

### Abstract

The GNSS (Global Positioning System) has been researched as an aid instrument in agricultural machinery since the mid-1990s. It is mainly used in conjunction with other sensors in precision agriculture for planning, mapping, and carrying out tasks in the field, which significantly increases productivity and process efficiency. However, obstruction of the GNSS signal is a common problem that can lead to errors in positioning. In this context, the present article collected GNSS data in a sugarcane plantation with a ground robot and from the exploratory analysis of the data, through scatter plots, box diagrams, and correlation coefficients, proposes a classification algorithm to identify the existence of GNSS signal obstruction and select the best navigation method for such conditions, reducing the chances of accidents in the field.

**Keywords:** GNSS; Agricultural Robots; Machine Learning; Autonomous Navigation

## 1. 1. Introdução

Atualmente, existem 24 satélites em órbita e operados pelos Estados Unidos que em conjunto formam o GPS (Sistema de Posicionamento Global). O GPS funciona através da triangulação do sinal emitido por ao menos 4 satélites em diferentes posições da órbita terrestre que cruzam o sinal obtido e conseguem identificar o posicionamento de um determinado objeto na superfície terrestre.

Existem, também, outras constelações de satélites com a mesma proposta, mas operadas por diferentes países sendo elas: Galileo (União Europeia), GLONASS (Federação Russa) e BeiDou (China). Esses, em conjunto com o GPS, formam o Sistema Global de Navegação por Satélite (GNSS).

O GNSS possui diversas aplicações na sociedade contemporânea como: identificação de desastres naturais [1][2], monitoramento de trânsito [3][4], sistemas de navegação [5][6] e agricultura [7]-[10].

No que tange às pesquisas relacionadas à agricultura, o GNSS vem sendo pesquisado como instrumento de auxílio em máquinas agrícolas desde meados da década de 90 e começo dos anos 2000 [11]-[13]. Utiliza-se tal ferramenta, principalmente, em conjunto o GIS (Sistema de Informação Geográfica) na agricultura de precisão para o planejamento, mapeamento e execução das tarefas na lavoura, resultando em um expressivo aumento da produtividade e maior eficiência dos processos [14] [15].

No que diz respeito à execução das tarefas, o GNSS é utilizado como um sensor proprioceptivo fornecendo as informações de posicionamento global do sistema e possibilitando, assim, a navegação autônoma de robôs agrícolas, que utilizam os dados do GNSS para planejar e seguir trajetórias ao longo da plantação.

Estudos feitos na universidade de Purdue já demonstraram o impacto negativo que o dossel<sup>1</sup> das plantas tem na recepção do sinal de GNSS e que a folhagem é uma das maiores fontes para esse erro, diminuindo em até 47% a eficiência na aquisição de dados [16]. A degradação do sinal de GNSS, seus impactos e as técnicas de mitigação são posteriormente estudados por outros autores, e não somente a degradação do sinal causada pelo dossel de florestas

[17] e plantações, [18] mas também por prédios e outras construções do ambiente urbano [19] [20].

Deste modo, a interferência do sinal é um fator preocupante, pois resulta em erros no posicionamento e no cálculo de trajetória que, por sua vez, podem provocar acidentes, afetando a integridade das plantações.

Visando a mitigação deste problema, surgem diversas soluções baseadas principalmente na fusão do sinal de GPS, seja ele RTK (*Real Time Kinematic*) ou não, com dados de outros sensores embarcados como câmeras, LiDAR e IMU (Unidade de Medição Inercial). Isso é feito, pois a inclusão de giroscópios e acelerômetros (através da IMU) juntamente com outros sensores possibilitam que em momentos de falha do GNSS a estimativa da posição e velocidade do robô ou veículo seja ainda feita.

Estudos demonstram o resultado positivo da integração do GNSS com Sistemas de Navegação Inercial (INS) por meio do uso de IMU's baseadas em Sistemas Microeletromecânicos (MEMS) com potencial de diminuir os impactos da degradação do sinal GNSS em ambientes urbanizados. Todavia, algoritmos para redução de erros de localização foram necessários [21], devido aos erros acumulativos [22] e ruídos [23], sendo o último por meio do método MSHARKF (*Modified Sage Husa adaptive Robust Kalman Filter*).

Além disso, o uso de GPS com câmeras foi relatado juntamente com hodômetro e giroscópio (GPS/DR) para localização de veículos autônomos, mas apresentou limitações em relação aos dados longitudinais, além da própria limitação do sensor de visão em locais mal iluminados [24].

Propostas utilizando o LiDAR combinado com o GPS surgem, também, tornando os veículos ou objetos capazes de se localizarem, criar e armazenar mapas, detectar e corrigir falhas na localização e, também navegar sob o dossel de plantações [25][26]. Entretanto, erros de estimativa causados por objetos não estáticos no ambiente [27] e o custo de processamento, no caso do LiDAR 3D merecem atenção [28].

Por meio da junção do GNSS com Sistemas de Navegação Inerciais, outras soluções utilizam ainda de um Filtro de Kalman (KF) adaptativo para melhorar as estimativas de posição [29], mas testes demonstram

---

<sup>1</sup> Camadas sobrepostas de ramos e folhas que formam as copas das plantas.

uma variabilidade nos resultados da covariância para o uso do algoritmo adaptativo em diferentes parâmetros [30]. O uso de Filtro de Kalman Estendido (EKF) o GPS/INS e uma câmera é também uma proposta de implementação para obter uma resolução melhor [31], assim como a implementação da lógica *fuzzy* juntamente com EKF (AFEKF) para o ajuste das medições e a covariância. Sendo que a última apresentou em pesquisa recente, uma diminuição de 50% no erro médio quadrático (RMS) da posição e velocidade ao longo do tempo [32].

Desta forma, muitas são as implementações e pesquisas para a fusão de dados dos sensores de modo a aprimorar as informações do GNSS e se obter um algoritmo de navegação mais seguro e robusto. Vale também citar o Filtro de Kalman Estendido e Aprimorado (IEKF) com *Deep Learning* [33], e o UKF (*Unscented Kalman Filter*) que surge para superar alguns obstáculos do EKF como precisão das estimativas [34]. Reitera-se que a precisão do método apresenta uma dependência em relação aos dados disponíveis para a estimativa. Isto é, se informações não precisas são utilizadas, há uma degradação do processo [35].

Logo, evidencia-se a relevância da obtenção de dados precisos de sensoriamento para a utilização em algoritmos de mapeamento e navegação para robôs autônomos. Nesse contexto, o presente artigo objetiva a criação de um método para a identificação do nível obstrução do sinal de GNSS em plantações agrícolas para que o sistema possa descartar medidas com e optar por utilizar outros sensores e métodos para navegação. O método é aplicado em dados de GNSS obtidos em uma plantação de cana de açúcar no sudeste do Brasil, mostrando uma alta eficiência da identificação de degradação no sinal de GNSS em cenários com diferentes níveis de obstrução.

## 2. Metodologia

A metodologia utilizada neste artigo está representada na Figura 1. Como primeiro passo, determina-se as situações problemas que são investigadas. Posteriormente, realiza-se experimentos para coleta de dados, em posse dos dados, a análise exploratória dos comportamentos destes dados para os cenários investigados é feita. E, por fim, utiliza-se um modelo de *Machine Learning* (ML) que identifica a obstrução dos dados de GNSS e avalia-se o desempenho do mesmo.



Figura 1. Diagrama da Metodologia.

### 2.1 Cenários

Os cenários foram separados em três classes em um cultivo de cana de açúcar: *SemObstrução*, *ObstruçãoLateral* e *ObstruçãoLateralSuperior*.

A primeira classe (*SemObstrução*), demonstrada na Figura 2, possui plantas jovens, bem espaçadas entre si, com bastante lacunas de cultivo e sem um dossel que pudesse causar obstrução na parte superior.



Figura 2. Cenário agrícola em que a cana de açúcar jovem. Fonte: elaboração própria.

A segunda classe (*ObstruçãoLateral*), evidenciada na Figura 3, contém plantas próxima a época da colheita, entretanto, não há obstrução superior, cenário este que pode ser observado em falhas de plantio ou curva de nível. Esta situação representa a obstrução do sinal de GNSS pela lateral.



**Figura 3.** Cenário agrícola em que a cana de açúcar da época de colheita, sem obstrução superior. Fonte: elaboração própria.

A terceira classe (*ObstruçãoLateralSuperior*), apresentada na Figura 4, possui plantas próximas à colheita, neste caso, o dossel era fechado. Desta forma, a obstrução do sinal de GNSS ocorria pela lateral e superior.



**Figura 4.** Cenário agrícola em que a cana de açúcar da época de colheita, com obstrução superior. Fonte: elaboração própria.

## 2.2 Coleta de Dados

Para a coleta dos dados, aqui apresentados, utilizou-se o Agbot TerraSentia, representado na Figura 5, que é um robô desenvolvido pela empresa *EarthSense* que tem como objetivo a automação no processo de monitoramento dos fenótipos das plantas. O TerraSentia utiliza o controle de direção diferencial como método de locomoção sendo, portanto, necessário dois comandos distintos para sua movimentação, um para as rodas da direita e outro para as suas rodas da esquerda. Suas dimensões são de aproximadamente 0,51m x 0,32m x 0,40m. A versão TS2020, utilizada nos testes, possui *chassi* de plástico rígido reforçado por uma base de metal e utiliza motores *outrunners* sem escovas acoplados com sensores de efeito *Hall* da empresa Maytech para locomoção.



**Figura 5.** Robô TerraSentia, utilizado para a obtenção dos dados experimentais. Fonte: EarthSense.

O TerraSentia possui dois sensores LiDAR Hokuyo UST-10LX que têm 270° de range e resolução de 1080p. Além disso, tem uma IMU Bosch BNO0555 e um receiver GNSS Ublox Zed-F9P.

As variáveis preditoras investigadas foram precisão angular, precisão horizontal e precisão de velocidade. Estas informações são fornecidas pelo Agibot com uma taxa de aquisição de 1 Hz.

Os dados foram coletados em junho de 2022, em uma plantação de cana de açúcar no distrito de Água Vermelha, localizado no município de São Carlos no estado de São Paulo, Brasil.

## 2.3 Análise Exploratória

Para realizar a análise exploratória, propõe-se duas etapas. A primeira consiste em analisar o comportamento de cada uma das variáveis preditoras em cada cenário, utilizando um diagrama de caixa. A segunda etapa consiste em calcular o coeficiente de correlação de Pearson para analisar a relação entre as variáveis em cada classe, este coeficiente é definido pela equação (1).

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

Onde  $x_i$  é o valor da variável  $x$  para a amostra  $i$ ,  $y_i$  é o valor da variável  $y$  para a amostra  $i$ ,  $\bar{x}$  é a média da variável  $x$  e  $\bar{y}$  é a média da variável  $y$ .

## 2.3 Modelo de ML

Para este trabalho, como o objetivo é realizar a classificação de três cenários agrícolas que podem obstruir o sinal de GNSS, optou-se pela utilização da Regressão Logística Multinomial (RLM), a qual indica a probabilidade de uma dada condição de variáveis preditoras pertencer ao comportamento da variável categórica. As probabilidades, para esta técnica, são calculadas pela equação (2) e equação (3).

$$P_0 = \frac{1}{1 + \sum_{j=1}^{N-1} e^{\alpha_j + \beta_j \bar{X}}} \quad (2)$$

$$P_j = \frac{e^{\alpha_j + \beta_j \bar{X}}}{1 + \sum_{k=1}^{N-1} e^{\alpha_k + \beta_k \bar{X}}} \quad (3)$$

Onde  $P_0$  é a classe de referência,  $P_j$  é a probabilidade de classe  $j$ ,  $\alpha$  é o intercepto (coeficiente linear) de cada classe,  $\beta$  é o vetor com os coeficientes angulares de cada característica e  $\bar{X}$  é o vetor de característica e  $N$  é a quantidade de classe.

Para estimar os coeficientes da RLM, utilizou-se o método de otimização denominado Máxima Verossimilhança (MV), o qual é calculado pela equação (4).

$$LL = \sum_{i=1}^n \sum_{m=0}^{N-1} \left\{ Y_{im} \left[ \ln \left( \frac{e^{\alpha_m + \beta_m \bar{X}_i}}{\sum_{j=0}^{N-1} e^{\alpha_j + \beta_j \bar{X}_i}} \right) \right] \right\} \quad (4)$$

Onde  $LL$  é a máxima verossimilhança e  $Y_{im}$  é um valor binário que indica a presença ou ausência da classe  $m$  para a observação  $i$ .

Após estimar os coeficientes, realiza-se o procedimento *stepwise* que é responsável por selecionar variáveis preditoras para obter o melhor modelo preditivo, prevenindo, também, a existência de multicolinearidade. Esse procedimento consiste em iterar removendo e colocando variáveis preditoras no modelo, observando quando há redução no Critério de Informação de Akaike (CIA), o que indica um aumento na capacidade preditiva. Este critério é calculado pela equação (5).

$$AIC = 2LL + 2(N - 1)v \quad (5)$$

Onde  $AIC$  é o Critério de Informação de Akaike e  $v$  é o número de variáveis do modelo, incluindo o intercepto.

Como o procedimento *stepwise* pode retirar variáveis do modelo, não é possível realizar a classificação direta entre eles. Para isto, utilizou-se o Teste da Razão de Verossimilhança (TRV), apresentado na equação (6). Neste teste, a hipótese nula indica que os modelos possuem a mesma capacidade preditiva e a hipótese alternativa é que os modelos não possuem a mesma capacidade preditiva.

$$TRV = -2(LL(model_1) - LL(model_2)) \quad (6)$$

O  $TRV$  é comparado com uma distribuição  $\chi^2$  com Grau de Liberdade (GDL) igual à diferença de variáveis entre os modelos comparados. Um intervalo de confiança de 95% é adotado para este trabalho.

## 2.4 Avaliação do Modelo de ML

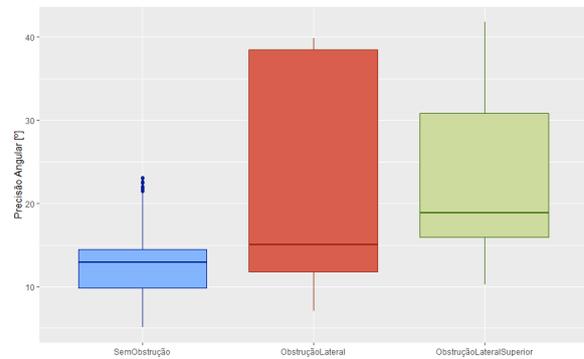
Para avaliação do desempenho do modelo, utilizou-se a matriz de confusão, que é uma tabela de contingência entre classes de uma variável categórica, nas colunas estão os valores reais e nas linhas os valores preditos por um modelo de ML.

## 3. Resultados

Durante a coleta de dados, o TS2020 foi controlado remotamente por um operador humano. Obtendo-se 3.500 amostras de cada cenário.

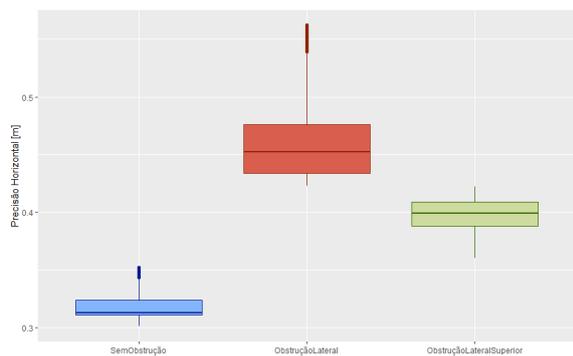
Na Figura 6 pode ser observado o diagrama de caixa da precisão angular para os cenários: *SemObstrução* (roxa), *ObstruçãoLateral* (verde) e *ObstruçãoLateralSuperior* (amarela). Observa-se que existe a presença de *outliers* apenas para o cenário em que não há obstrução (caixa roxa), além disto, percebe-se que a presença de obstrução (caixa verde e caixa amarela) aumenta a amplitude da distribuição dos dados.

Aliado a isto, verifica-se uma assimetria da distribuição dos dados quando há obstrução, principalmente no cenário que há apenas a obstrução lateral (caixa verde). Ainda, percebe-se que a precisão angular mediana aumenta com a obstrução.



**Figura 6.** Precisão Angular. Fonte: elaboração própria.

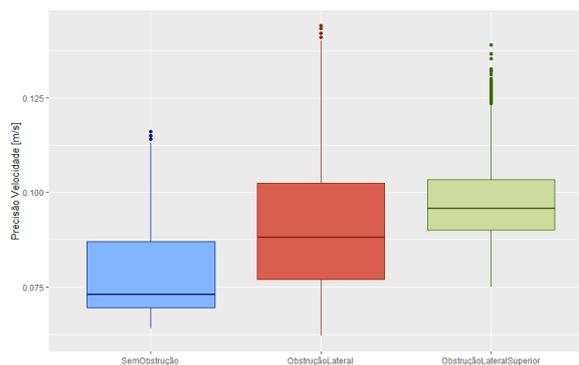
Na Figura 7 pode ser observado o diagrama de caixa da precisão horizontal para os cenários: *SemObstrução* (roxo), *ObstruçãoLateral* (verde) e *ObstruçãoLateralSuperior* (amarelo). É evidente que existe a presença de *outliers* para os cenários sem obstrução (caixa roxa) e com obstrução lateral (caixa verde) e, também, nota-se que a presença de obstrução lateral (caixa verde) teve a maior amplitude interquartil, indicando uma maior distribuição dos dados. Por outro lado, para esta variável, percebe-se uma menor assimetria da distribuição dos dados quando comparado à variável anterior. E, por fim, verificou-se que a precisão horizontal foi maior para quando há obstrução lateral (caixa verde) do que para quando há obstrução lateral e superior (caixa amarela).



**Figura 7.** Precisão Horizontal. Fonte: elaboração própria.

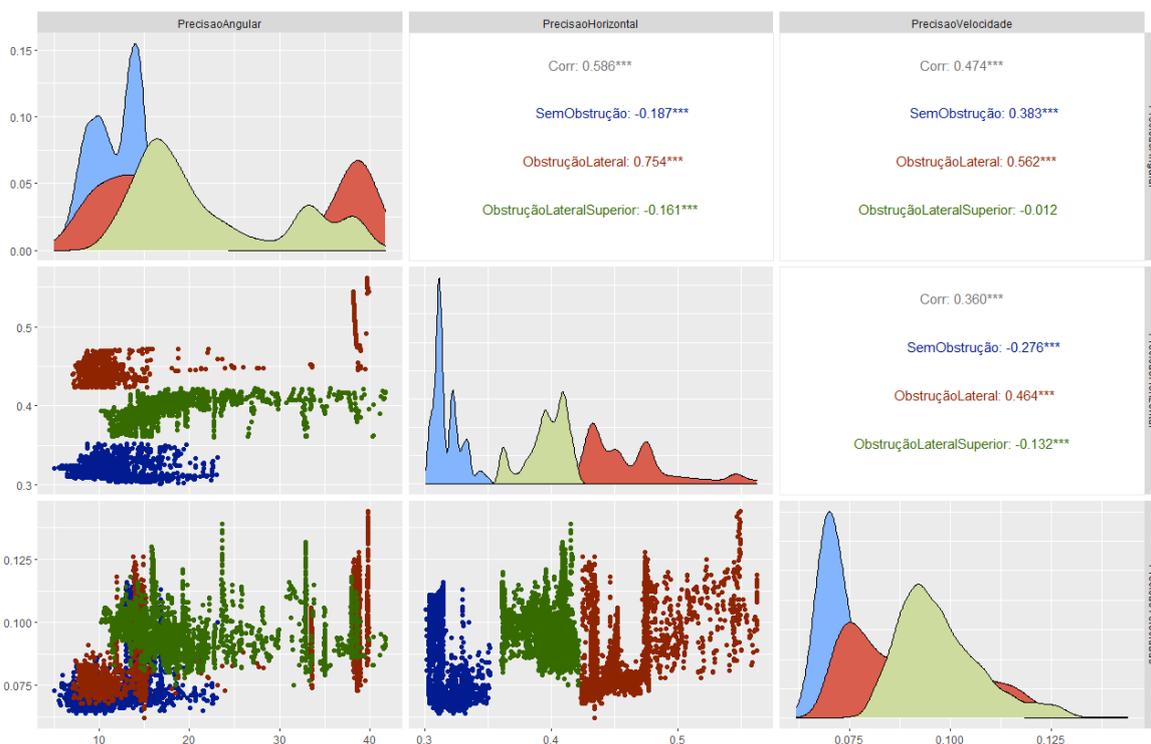
Na Figura 8 pode ser observado o diagrama de caixa da precisão de velocidade para os cenários: *SemObstrução* (roxo), *ObstruçãoLateral* (verde) e *ObstruçãoLateralSuperior* (amarelo).

Existe a presença de *outliers* para todos os cenários, além disso, observa-se que a presença de obstrução (caixa verde e caixa amarela) aumenta a amplitude da distribuição dos dados, mas não é vista a mesma relação entre as amplitudes interquartis. Nota-se, também, que existe assimetria da distribuição dos



**Figura 8.** Precisão de velocidade linear. Fonte: elaboração própria.

Na Figura 9 pode ser observado o coeficiente de correlação de Pearson entre as variáveis predictoras utilizadas nesse trabalho. O cenário com obstrução lateral foi o que gerou maior correlação linear entre as variáveis predictoras; no caso da variável “precisão angular”, a obstrução tende a criar dois picos de frequência relativa que aumenta a dispersão dos dados, fato este que pode ser causado pela mudança de quantidade de satélites durante a aquisição dos dados.



**Figura 9.** Coeficiente de correlação de Pearson. Fonte: elaboração própria

dados quando não há obstrução. Para as condições com obstrução as distribuições tendem a ser simétricas.

Adicionalmente, de acordo com os dados obtidos, a variável “precisão horizontal” torna a separação dos cenários mais evidente. Além disso, nessa mesma variável, constata-se que os valores com maiores frequência relativa entre as classes com obstrução lateral (verde) e obstrução lateral e superior (amarela)

estão próximos, o que pode ser um indicativo de que não há diferença significativa entre estas obstruções.

Posteriormente, foram obtidos dois modelos RLM utilizando a técnica k-fold com 5 iterações.

1. Completo, com todas as variáveis preditoras;
2. *Stepwise*, selecionando as melhores variáveis preditoras.

Para todos os modelos, a classe de referência adotada é a *SemObstrução*.

Os dados dos modelos estão apresentados na Tabela 1. Conforme apresentado, os valores de Máxima Verossimilhança e AIC estão próximos, o que é um indicativo que os modelos possuem a mesma capacidade preditiva. Além disto, o acurácia dos modelos foi de 100%, indicando que ambos identificam a obstrução do sinal de GNSS.

Tabela 1. Comparação entre os modelos.

Dado do Modelo	Completo	<i>Stepwise</i>
LL	-0,04	-1,75
GDL	8	4
AIC	16,08	11,50
TRV	3,42	
P-valor	0,49	
Acurácia (%)	100,00	

Comparando o TRV com uma distribuição  $\chi^2$  com GDL igual a 4, obtêm-se um p-valor de 0,49, indicando que em um 95% de intervalo de confiança, os modelos possuem a mesma capacidade preditiva.

Tabela 2. Coeficientes do modelo final de predição.

	<i>Obstrução Lateral</i>	<i>Obstrução Lateral Superior</i>
$\alpha$	-58,89	-49,62
Precisão Angular	-	-
Precisão Horizontal	316,75	85,70
Precisão Velocidade	-	-

Sendo assim, optou-se pelo modelo com menor quantidade de variáveis preditoras, pois desta forma, diminui-se o custo computacional, tornando o algoritmo de predição de obstrução do sinal de GNSS mais rápido. Os coeficientes do modelo de RLM para o modelo *stepwise* podem ser vistos na Tabela 2. A única variável preditora no modelo final foi a precisão horizontal, indicando que a mesma é suficiente para identificar se há obstrução do sinal de GNSS.

A matriz de confusão do modelo final pode ser vista na Tabela 3, como o método teve uma acurácia de

100,00%, todas as classes preditas foram classificadas corretamente.

Tabela 3. Matriz de confusão.

	<i>Sem Obstrução</i>	<i>Obstrução Lateral</i>	<i>Obstrução Lateral Superior</i>
<i>Sem Obstrução</i>	3.500	0	0
<i>Obstrução Lateral</i>	0	3.500	0
<i>Obstrução Lateral Superior</i>	0	0	3.500

#### 4. Conclusão

O presente trabalho investigou como a precisão do sinal de GNSS é afetada pela própria plantação em um cultivo de cana de açúcar. Constatou-se que a presença de obstrução, seja ela lateral ou superior, interfere na assimetria, amplitude e/ou mediana na distribuição das variáveis de precisão angular, horizontal e velocidade.

Ao utilizar um modelo de RLM, observou-se que a variável precisão horizontal é, para o sensor GNSS presente no TS2020, a mais importante para identificar a existência de obstrução no sinal de GNSS, pois este método obteve uma acurácia de 100% em todas as iterações utilizando o método *k-fold*.

Levantou-se a hipótese de que não há diferença entre obstrução lateral e lateral superior e, portanto, propõe-se mais experimentos ao longo de vários dias para fazer a validação de tal proposição.

#### 5. Agradecimentos

O presente trabalho foi realizado com o apoio da EMBRAPPII processo no. PIFS-2111.0043, Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e da EarthSense, por cederem o robô utilizado para aquisição dos testes. Por fim, os autores agradecem a Elson Mompean Rosalis pelo apoio dado à pesquisa ao disponibilizar o local para a coleta dos dados.

#### 6. Referências

- [1] C. Falck, M. Ramatschi, C. Subarya, M. Bartsch, A. Merx, J. Hoeberechts, G. Schmidt, "Near real-time GPS applications for tsunami early warning systems", *Rev. Nat. Hazards Earth Syst. Sci.*, vol. 10, pp. 181–189, 2010. [PDF]. Disponível em: <https://doi.org/10.5194/nhess-10-181-2010>

- [2] K. Jayaram, K. Janani, R. Jeyaguru, R. Kumaresh, & N. Muralidharan. “Forest fire alerting system with GPS Co-ordinates using IoT”. 5th International Conference on Advanced Computing & Communication Systems (ICACCS), IEEE, pp. 488-491, 2019.
- [3] Y. Hara, M. Kuwahara. “Traffic Monitoring immediately after a major natural disaster as revealed by probe data—A case in Ishinomaki after the Great East Japan Earthquake”. Transportation research part A: policy and practice, vol. 75, pp. 1-15, 2015.
- [4] J. C. Herrera, D. B. Work, R. , X. J. Ban, Q. Jacobson, A. M. Bayen. “Evaluation of traffic data obtained via GPS-enabled mobile phones: The Mobile Century field experiment”. Transportation Research Part C: Emerging Technologies, vol. 18, n.º4, pp. 568-583, 2010.
- [5] Y. Liu, X. Fan, C. Lv, J. Wu, L. Li, D. Ding. “An innovative information fusion method with adaptive Kalman filter for integrated INS/GPS navigation of autonomous vehicles”. Mechanical Systems and Signal Processing, vol. 100, pp. 605-616, 2018.
- [6] Y. Zein, M. Darwiche, Mokhiemar. “O. GPS tracking system for autonomous vehicles”. Alexandria engineering journal, vol. 57. n.º 4, pp. 3127-3137, 2018.
- [7] S. Wanasuria, A. Fathoni, Y. Indra, B. Surojo. “Use of GPS and laser for GIS data capture in oil palm plantations”. Planter, vol. 74, n.º 873, pp. 647-659, 1998.
- [8] B. T. W. Putra, P. Soni, B. Marhaenanto, S. S. Harsono, S. Fountas. “Using information from images for plantation monitoring: A review of solutions for smallholders”. Information Processing in Agriculture, vol. 7, n.º 1, pp. 109-119, 2020.
- [9] A. J. de Oliveira, G. F. da Silva, G. R. da Silva, A. A. C. dos Santos, D. S. A. Caldeira, M. K. C. Vilarinho, T. C. de Oliveira, Potencialidades da utilização de drones na agricultura de precisão. Brazilian Journal of Development, vol. 6, n.º 9, pp. 64140-64149, 2020.
- [10] J. Zhang, F. Zhou, C. Jing, S. Wei, Y. Wu. “Research and Design of Automatic Navigation System for Agricultural Machinery Based on GPS”. IEEE International Conference on Power, Intelligent Computing and Systems (ICPICS), pp. 984-986, 2020.
- [11] E. Tayari, Jamshid, R. Amin, H. R. Goodarzi, “Role of GPS and GIS in precision agriculture”. Journal of Scientific Research and Development, vol. 2, n.º 3, pp. 157-162, 2015.
- [12] B.L. Lee, Y.C. Kim, M.E. Park. “Interactive web interface for GIS applications in Agriculture”, Korea Agricultural Information and Technology, vol. 6, n.º 1, pp. 136-139, 1997.
- [13] D. Mandal, S. K. Ghosh. “Precision farming—The emerging concept of agriculture for today and tomorrow”. Current Science, vol. 79, n.º 12, pp. 1644-164, 2000.
- [14] C. Palaniswami, P. Gopalsundaram, A. Bhaskaran. “Application of GPS and GIS in Sugarcane Agriculture”. Sugar Tech, vol. 13, n.º 4, pp. 360-365, 2011.
- [15] F. Zhang, N. Cao. "Application and Research Progress of Geographic Information System (GIS) in Agriculture". 8th International Conference on Agro-Geoinformatics (Agro-Geoinformatics), pp. 1-5, 2019.
- [16] P. Sigrist, P. Coppin, M. Hermy. “Impact of forest canopy on quality and accuracy of GPS measurements”. International journal of remote sensing, vol. 20, n.º 18, pp. 3595-3610, 1999.
- [17] T. Yoshimura, H. Hasegawa, “Comparing the precision and accuracy of GPS positioning in forested areas”. Journal of Forest Research, vol. 8, n.º 3, pp. 147-152, 2003.
- [18] C. W. Chan, J. K. Schueller, W. M. Miller, J. D. Whitney, J. A. Cornell. “Error sources affecting variable rate application of nitrogen fertilizer”. Precision Agriculture, vol. 5, n.º 6, pp. 601-616, 2004.
- [19] K. W. Chiang, T. T. Duong, J. K. Liao. “The performance analysis of a real-time integrated INS/GPS vehicle navigation system with abnormal GPS measurement elimination”. Sensors, vol. 13. n.º 8, pp. 10599-10622, 2013.
- [20] Y. Deng, Y. Shan, Z. Gong, L. Chen. “Large-scale navigation method for autonomous mobile robot based on fusion of GPS and lidar SLAM”. In 2018 Chinese Automation Congress (CAC), IEEE, pp. 3145-3148, 2018.
- [21] S. Godha, M. E. Cannon. “GPS/MEMS INS integrated system for navigation in urban areas”. *Gps Solutions*, vol. 11, n.º 3, pp. 193-203, 2007.
- [22] K. W. Chiang, H. W. Chang, Y. H. Li, G. J. Tsai, C. L. Tseng, Y. C. Tien, P. C. Hsu. “Assessment for INS/GNSS/odometer/barometer integration in loosely-coupled and tightly-coupled scheme in a GNSS-degraded environment”. IEEE Sensors Journal, vol. 20, n.º 6, pp. 3057-3069, 2019.

- [23] M. Narasimhappa, A. D. Mahindrakar, V. C. Guizilini, M. H. Terra, S. L. Sabat. "MEMS-based IMU drift minimization: Sage Husa adaptive robust Kalman filtering". *IEEE Sensors Journal*, vol. 20, n.º 1, pp. 250-260, 2019.
- [24] B. H. Lee, J. H. Song, J. H. Im, S. H. Im, M. B. Heo, G. I. Jee. "GPS/DR error estimation for autonomous vehicle localization". *Sensors*, vol. 15, n.º 8, pp. 20779-20798, 2015.
- [25] V. A. Higuti, A. E. Velasquez, D. V. Magalhaes, M. Becker, G. Chowdhary. "Under canopy light detection and ranging-based autonomous navigation". *Journal of Field Robotics*, vol 36, n.º 3, pp.547-567, 2019.
- [26] A. E. B. Velasquez, V. A. H. Higuti, M. V. Gasparino, A. N. Sivakumar, M. Becker, G. Chowdhary. "Multi-sensor fusion based robust row following for compact agricultural robots". *arXiv preprint arXiv:2106.15029*, 2020.
- [27] L. Zheng, Y. Zhu, B. Xue, M. Liu, R. Fan. "Low-cost gps-aided lidar state estimation and map building". In *2019 IEEE International Conference on Imaging Systems and Techniques (IST)*, IEEE, pp. 1-6, 2019.
- [28] C. Donati, M. Mammarella, L. Comba, A. Biglia, P. Gay, F. Dabbene. "3D Distance Filter for the Autonomous Navigation of UAVs in Agricultural Scenarios". *Remote Sensing*, vol. 14, n.º 6, pp. 1374, 2022.
- [29] A. H. Mohamed, K. P. Schwarz. "Adaptive Kalman filtering for INS/GPS". *Journal of geodesy*, vol. 73, n.º 4, pp. 193-203, 1999.
- [30] A. Almagbile, J. Wang, W. Ding. "Evaluating the performances of adaptive Kalman filter methods in GPS/INS integration". *Journal of Global Positioning Systems*, vol. 9, n.º1, pp. 33-40, 2010.
- [31] M. Mammarella, G. Campa, M. R. Napolitano, M. L. Fravolini, Y. Gu, M. G. Perhinschi. "Machine vision/GPS integration using EKF for the UAV aerial refueling problem". *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 38, n.º 6, pp. 791-801, 2008.
- [32] J. Liu, G. Guo. "Vehicle localization during GPS outages with extended Kalman filter and deep learning". *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp. 1-10, 2021.
- [33] S. Gao, G. Hu, Y. Zhong. "Windowing and random weighting-based adaptive unscented Kalman filter". *International Journal of Adaptive Control and Signal Processing*, vol. 29, n.º 2, pp. 201-223, 2015.
- [34] G. Hu, B. Gao, Y. Zhong, C. Gu. "Unscented kalman filter with process noise covariance estimation for vehicular ins/gps integration system". *Information Fusion*, vol. 64, 1pp. 94-204, 2020.
- [35] S. Yazdkhasti, J. Z. Sasiadek, S. Ulrich. "Performance enhancement for GPS/INS fusion by using a fuzzy adaptive unscented Kalman filter". In *2016 21st International Conference on Methods and Models in Automation and Robotics (MMAR)*, IEEE, pp. 1194-1199, 2016.