

THALES MAURINO DE AQUINO SILVA

**DESENVOLVIMENTO DE UM SISTEMA SENSOR PARA ÍNDICES DE
VEGETAÇÃO E POSICIONAMENTO GLOBAL**

Dissertação apresentada à
Universidade Federal de Viçosa, como
parte das exigências do Programa de
Pós-Graduação em Engenharia
Agrícola, para a obtenção do título de
Magister Scientiae.

VIÇOSA
MINAS GERAIS - BRASIL
2018

**Ficha catalográfica preparada pela Biblioteca Central da Universidade
Federal de Viçosa - Câmpus Viçosa**

T

S586d
2018
Silva, Thales Maurino de Aquino, 1992-
Desenvolvimento de um sistema sensor para índices de
vegetação e posicionamento global / Thales Maurino de Aquino
Silva. – Viçosa, MG, 2018.
vii, 45f. : il. (algumas color.) ; 29 cm.

Inclui apêndices.

Orientador: Domingos Sárvio Magalhães Valente.

Dissertação (mestrado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Agricultura de precisão. 2. Sensoriamento remoto.
3. Satélites artificiais em agricultura. 4. Algoritmos
computacionais. 5. BeagleBone Black (Computador).
I. Universidade Federal de Viçosa. Departamento de Engenharia
Agrícola. Mestrado em Engenharia Agrícola. II. Título.

CDD 22. ed. 631.3

THALES MAURINO DE AQUINO SILVA

**DESENVOLVIMENTO DE UM SISTEMA SENSOR PARA ÍNDICES DE
VEGETAÇÃO E POSICIONAMENTO GLOBAL**

Dissertação apresentada à
Universidade Federal de Viçosa, como
parte das exigências do Programa de
Pós-Graduação em Engenharia
Agrícola, para a obtenção do título de
Magister Scientiae.

APROVADA: 28 de junho de 2018.



Nerilson Terra Santos



Francisco de Assis de Carvalho Pinto
(Coorientador)



Domingos Sárvio Magalhães Valente
(Orientador)

Dedicatória

Aos meus pais José Maurino da Silva e Goretti de Fátima de Aquino Silva

A minha companheira Nathalia Dias Ribeiro

E aos meus Irmãos Thomaz, Thalmai e Cristiano Vinicius

AGRADECIMENTOS

Quero expressar meus profundos agradecimentos, primeiramente a Deus que a todo instante está comigo e em mais esta jornada de minha vida não foi diferente.

Aos meus pais José Maurino da Silva e Goretti de Fátima de Aquino Silva, a minha companheira de todas as horas Nathalia Dias Ribeiro, aos meus irmãos Thomaz, Thalmai e Cristiano Vinicius e toda a minha família pelo apoio, incentivo e por sempre acreditarem que eu seria capaz.

À Universidade Federal de Viçosa - UFV, ao seu Departamento de Engenharia Agrícola – DEA e Programa de Pós-Graduação, assim como todos os funcionários do mesmo por oferecer-me a oportunidade de realização deste trabalho.

A todos os Professores da área de mecanização agrícola, agradeço pelos conhecimentos transmitidos, em especial aos meus coorientadores professores Daniel Marçal de Queiroz e Francisco de Assis de Carvalho Pinto, e principalmente ao professor e orientador Domingos Sárvio Magalhães Valente pelo estímulo à pesquisa, pela orientação, paciência e todo apoio nos momentos necessários.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de estudos concedida.

Minha gratidão a todos os meus colegas do laboratório de mecanização – DEA/MEC, pelo companheirismo, convivência, amizade e grandes ajudas prestadas.

Ao professor Nerilson Terra dos Santos pelos conhecimentos disponibilizados e demais contribuições ao trabalho.

Enfim, a todos aqueles que, de alguma forma, direta ou indiretamente contribuíram para a realização deste trabalho, cujos nomes não foram citados.

RESUMO

SILVA, Thales Maurino de Aquino, M.Sc., Universidade Federal de Viçosa, junho de 2018. **Desenvolvimento de um sistema sensor para índices de vegetação e posicionamento global.** Orientador: Domingos Sárvio Magalhães Valente. Coorientadores: Daniel Marçal de Queiroz e Francisco de Assis de Carvalho Pinto.

O sistema de navegação global por satélites (GNSS) é a base para manejo localizado no campo de produção pois permitem o georreferenciamento dos dados coletados e a consequente geração de mapas pelos diferentes sistemas que compõem a Agricultura de Precisão. Existe uma demanda por sistemas de orientação de baixo custo para viabilizar a utilização desses sistemas na agricultura. Uma das formas de coletar dados para a agricultura de precisão é o sensoriamento remoto. O sensoriamento remoto é uma forma de aquisição de dados onde não existe contato entre o sensor e a substância a ser medida. As aplicações de sensoriamento remoto na agricultura baseiam-se na interação da radiação eletromagnética com o solo ou o material vegetal. Essa interação pode ser mensurada e analisada através dos chamados índices de vegetação. Os índices de vegetação são importantes parâmetros de sensoriamento remoto para monitoramento de ecossistemas e processos da superfície terrestre. No Capítulo 1 dessa dissertação, objetivou-se integrar um módulo GNSS de baixo custo à um computador de placa única utilizando o filtro de Kalman na obtenção dos dados de navegação. Para avaliar o sistema foram conduzidos um experimento estático e dois cinemáticos, com três repetições cada. No estático o erro médio foi de 3,25 m com raiz quadrada do erro quadrático médio (RMSE) de 3,73 m. No primeiro experimento cinemático observou-se menor oscilação lateral dos dados na velocidade de $1,39 \text{ m s}^{-1}$. No segundo experimento cinemático o erro médio foi de 1,26 e 1,13 m, com RMSE de 1,45 e 1,27 m, para os dados antes e após a aplicação do filtro de Kalman, respectivamente. Concluiu-se que o sistema eliminou oscilações bruscas lateralmente, devido a erros aleatórios do sinal GNSS, mantendo um comportamento linear, podendo ser utilizado em determinadas aplicações agrícolas em que não seja necessária uma acurácia submétrica, como por exemplo amostragem de solo e monitoramento de produtividade. No Capítulo 2 dessa dissertação, foi desenvolvido um sistema sensor para aquisição de alguns índices de vegetação (NDVI, SR, WDRVI, SAVI, OSAVI). Esse sistema sensor foi construído utilizando a Beaglebone Black para processar os dados e fototransistores como elementos sensores. Foi realizada a calibração do sistema sensor proposto para ajustar seus valores aos de um espectroradiômetro e por último foi realizada a análise de desempenho dos índices de vegetação obtidos com o sistema sensor. Assim, nas

condições analisadas, o sistema sensor proposto pode ser utilizado na determinação de todos os índices de vegetação abordados. Uma vez que seus índices apresentaram alta e significativa correlação com os índices do espectrorradiômetro.

ABSTRACT

SILVA, Thales Maurino de Aquino, M.Sc., Universidade Federal de Viçosa, June, 2018. **Development of a sensor system for vegetation index and global positioning.** Advisor: Domingos Sárvio Magalhães Valente. Co-Advisors: Daniel Marçal de Queiroz and Francisco de Assis de Carvalho Pinto.

The Global Navigation Satellite System (GNSS) is the basis for management located in the field of production because they allow the georeferencing of the data collected and the consequent generation of maps by the different systems that make up Precision Agriculture. There is a demand for low-cost guidance systems to enable the use of these systems in agriculture. One of the ways to collect data for precision agriculture is remote sensing. Remote sensing is a form of data acquisition where there is no contact between the sensor and the substance to be measured. Remote sensing applications in agriculture are based on the interaction of electromagnetic radiation with soil or vegetation. This interaction can be measured and analyzed through so-called vegetation indices. Vegetation indices are important remote sensing parameters for monitoring ecosystems and terrestrial surface processes. In Chapter 1 of this dissertation, the objective was to integrate a low-cost GNSS module into a single board computer using the Kalman filter to obtain navigation data. To evaluate the system were conducted a static experiment and two kinematics, with three replications each. In static, the mean error was 3.25 m with root mean square error (RMSE) of 3.73 m. In the first kinematic experiment, less lateral oscillation of the data was observed at a velocity of 1.39 m s⁻¹. In the second kinematic experiment the average error was 1.26 and 1.13 m, with RMSE of 1.45 and 1.27 m, for the data before and after the application of the Kalman filter, respectively. It was concluded that the system eliminated abrupt oscillations laterally due to random errors of the GNSS signal, maintaining a linear behavior and could be used in certain agricultural applications where sub-metric accuracy is not required, such as soil sampling and crop yield monitoring.

SUMÁRIO

| | |
|---|----|
| INTRODUÇÃO GERAL | 1 |
| REFERÊNCIAS BIBLIOGRÁFICAS | 3 |
| CAPÍTULO 1 – INTEGRAÇÃO DE UM MÓDULO GNSS DE BAIXO CUSTO A UM COMPUTADOR DE PLACA ÚNICA COM FILTRO DE KALMAN ... | 6 |
| RESUMO | 6 |
| MATERIAL E MÉTODOS..... | 8 |
| RESULTADOS E DISCUSSÃO | 15 |
| CONCLUSÕES | 20 |
| AGRADECIMENTOS | 21 |
| REFERÊNCIAS BIBLIOGRÁFICAS DO CAPÍTULO 1 | 21 |
| CAPÍTULO 2 – DESENVOLVIMENTO DE UM SISTEMA SENSOR PARA AQUISIÇÃO DE ÍNDICES DE VEGETAÇÃO | 25 |
| RESUMO | 25 |
| INTRODUÇÃO..... | 26 |
| MATERIAL E MÉTODOS..... | 27 |
| RESULTADOS E DISCUSSÃO | 33 |
| CONCLUSÕES | 37 |
| AGRADECIMENTOS | 37 |
| REFERÊNCIAS BIBLIOGRÁFICAS DO CAPÍTULO 2 | 37 |
| CONCLUSÃO GERAL | 42 |
| APÊNDICES | 43 |
| APÊNDICE DO CAPÍTULO 1 | 43 |
| APÊNDICE DO CAPÍTULO 2..... | 44 |

INTRODUÇÃO GERAL

A Agricultura de Precisão (AP) é um conceito de gestão com base na observação, medição e resposta da variabilidade espacial e temporal das culturas (Lindblom et al., 2017). A AP tem como objetivo melhorar a gestão dos insumos agrícolas, tais como fertilizantes, herbicidas, sementes e combustíveis (Mulla, 2013). Para atingir esses objetivos, são utilizadas informações do solo, do clima e da cultura para garantir que a tomada de decisão seja rápida e na melhor resolução espacial possível (Harmon et al., 2005).

Uma das tecnologias mais importantes para a aplicação das técnicas de AP são os Sistemas de Navegação Global por Satélites (GNSS). Na agricultura, o GNSS é a base da orientação e da direção automática de máquinas agrícolas, permitindo o controle do tráfego nas diferentes etapas do plantio, na aplicação de fertilizantes e agrotóxicos à taxa variável e na colheita (Chen et al., 2005; Suprem et al., 2013). É esse gerenciamento localizado dos processos agrícolas que distingue a AP da agricultura convencional.

O GNSS em conjunto com outras tecnologias possibilita a visualização de dados coletados no espaço em que estão inseridos, facilitando a análise do campo e melhorando a tomada de decisão do agricultor. Uma das formas de coletar dados para a AP é o sensoriamento remoto. O sensoriamento remoto é uma forma de aquisição de dados onde não existe contato entre o sensor e a substância a ser medida. Para realizar essas medições existem diversas plataformas como satélites, aeronaves, tratores e sensores manuais. Uma das vantagens das medições terrestres é que diversas práticas agrícolas com tratores são realizadas ao longo do ciclo de uma cultura, o que torna possível acoplar o sensor ao trator e realizar a coleta de dados, simultaneamente a prática agrícola desejada, sem custos adicionais de combustível e tempo.

As aplicações de sensoriamento remoto na agricultura baseiam-se na interação da radiação eletromagnética com o solo ou com a vegetação. Essa interação pode ser mensurada e analisada através dos chamados índices de vegetação. Os índices de vegetação são importantes parâmetros de sensoriamento remoto para monitoramento de ecossistemas e processos na superfície terrestre (Ke et al., 2015). Os índices de vegetação são cálculos matemáticos realizados a partir da reflectância do dossel da cultura em determinados comprimentos de onda do visível e do infravermelho próximo.

Esses índices são indicadores de biomassa (Bendig et al., 2015), teor de clorofila (Croft et al., 2014), cobertura vegetal (Shao et al., 2016) e área foliar (Rasmussen et al., 2016). Com base no uso dos índices de vegetação é possível perceber falhas de plantio (Torres-Sánchez et al., 2015), ataque de doenças ou pragas (Lowe et al., 2017; Mahlein, 2016; Martinelli et al., 2015), falta de nitrogênio (Maresma et al., 2016), estresse hídrico (Kim & Glenn, 2015) e processos de desertificação (Higginbottom & Symeonakis, 2014).

Visto a importância do GNSS e do sensoriamento remoto para a AP, essa dissertação teve como objetivo o desenvolvimento de um sistema sensor de baixo custo para determinação da variabilidade espacial de índices de vegetação. Para isso, no capítulo 1 dessa dissertação implementou-se um sistema de navegação GNSS de baixo custo à uma plataforma embarcada para possibilitar a coleta de dados georreferenciados. No capítulo 2 dessa dissertação é apresentado o desenvolvimento de um sistema sensor para aquisição de índices de vegetação baseados nas bandas do vermelho e infravermelho próximo. Os índices coletados foram: NDVI (índice de vegetação da diferença normalizada) (Rouse et al., 1973), SR (razão simples) (Jordan, 1969), WDRVI (índice de vegetação de larga escala dinâmica) (Gitelson, 2004), SAVI (índice de vegetação ajustado ao solo) (Huete, 1988) e OSAVI (índice de vegetação ajustado ao solo otimizado) (Rondeaux et al., 1996).

REFERÊNCIAS BIBLIOGRÁFICAS

BENDIG, Juliane et al. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79-87, 2015.

CHEN, Jiang et al. The Development of Digital Agriculture and Chinese Agriculture Machinery. **Journal of Agricultural Mechanization Research**, v. 3, p. 008, 2005.

CROFT, H.; CHEN, J. M.; ZHANG, Y. The applicability of empirical vegetation indices for determining leaf chlorophyll content over different leaf and canopy structures. **Ecological Complexity**, v. 17, p. 119-130, 2014.

GITELSON, Anatoly A. Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. **Journal of plant physiology**, v. 161, n. 2, p. 165-173, 2004.

HARMON, T. et al. Precision agriculture scenario. In: **Proc. NSF Workshop on Sensors for Environmental Observatories, Baltimore, MD, USA**. 2005.

HIGGINBOTTOM, Thomas P.; SYMEONAKIS, Elias. Assessing land degradation and desertification using vegetation index data: Current frameworks and future directions. **Remote Sensing**, v. 6, n. 10, p. 9552-9575, 2014.

HUETE, Alfredo R. A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, v. 25, n. 3, p. 295-309, 1988.

JORDAN, Carl F. Derivation of leaf-area index from quality of light on the forest floor. **Ecology**, v. 50, n. 4, p. 663-666, 1969.

KE, Yinghai et al. Characteristics of Landsat 8 OLI-derived NDVI by comparison

with multiple satellite sensors and in-situ observations. **Remote Sensing of Environment**, v. 164, p. 298-313, 2015.

KIM, James Y.; GLENN, David Michael. Measurement of photosynthetic response to plant water stress using a multi-modal sensing system. **Transactions of the ASABE**, v. 58, n. 2, p. 233-240, 2015.

LINDBLOM, Jessica et al. Promoting sustainable intensification in precision agriculture: review of decision support systems development and strategies. **Precision Agriculture**, v. 18, n. 3, p. 309-331, 2017.

LOWE, Amy; HARRISON, Nicola; FRENCH, Andrew P. Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress. **Plant methods**, v. 13, n. 1, p. 80, 2017.

MAHLEIN, Anne-Katrin. Plant disease detection by imaging sensors—parallels and specific demands for precision agriculture and plant phenotyping. **Plant Disease**, v. 100, n. 2, p. 241-251, 2016.

MARESMA, Ángel et al. Analysis of vegetation indices to determine nitrogen application and yield prediction in maize (zea mays l.) from a standard uav service. **Remote Sensing**, v. 8, n. 12, p. 973, 2016.

MARTINELLI, Federico et al. Advanced methods of plant disease detection. A review. **Agronomy for Sustainable Development**, v. 35, n. 1, p. 1-25, 2015.

MULLA, David J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems engineering**, v. 114, n. 4, p. 358-371, 2013.

RASMUSSEN, Jesper et al. Are vegetation indices derived from consumer-grade cameras mounted on UAVs sufficiently reliable for assessing experimental plots?. **European Journal of Agronomy**, v. 74, p. 75-92, 2016.

RONDEAUX, Geneviève; STEVEN, Michael; BARET, Frédéric. Optimization of soil-adjusted vegetation indices. **Remote sensing of environment**, v. 55, n. 2, p. 95-107, 1996.

ROUSE JR, J_W et al. Monitoring vegetation systems in the Great Plains with ERTS. **Third ERTS Symposium**, NASA, v. 351, p. 309-317, 1973.

SHAO, Yang et al. An evaluation of time-series smoothing algorithms for land-cover classifications using MODIS-NDVI multi-temporal data. **Remote Sensing of Environment**, v. 174, p. 258-265, 2016.

SUPREM, Abhijit; MAHALIK, Nitaigour; KIM, Kiseon. A review on application of technology systems, standards and interfaces for agriculture and food sector. **Computer Standards & Interfaces**, v. 35, n. 4, p. 355-364, 2013.

TORRES-SÁNCHEZ, Jorge; LÓPEZ-GRANADOS, Francisca; PEÑA, José M. An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. **Computers and Electronics in Agriculture**, v. 114, p. 43-52, 2015.

CAPÍTULO 1 – INTEGRAÇÃO DE UM MÓDULO GNSS DE BAIXO CUSTO A UM COMPUTADOR DE PLACA ÚNICA COM FILTRO DE KALMAN

RESUMO

O sistema de navegação global por satélites (GNSS) é a base para manejo localizado no campo de produção pois permitem o georreferenciamento dos dados coletados e a consequente geração de mapas pelos diferentes sistemas que compõem a Agricultura de Precisão. Existe uma demanda por sistemas de orientação de baixo custo para viabilizar a utilização desses sistemas na agricultura. Dessa forma, objetivou-se integrar um módulo GNSS de baixo custo à um computador de placa única utilizando o filtro de Kalman na obtenção dos dados de navegação. Para avaliar o sistema foram conduzidos um experimento estático e dois cinemáticos, com três repetições cada. No estático o erro médio foi de 3,25 m com raiz quadrada do erro quadrático médio (RMSE) de 3,73 m. No primeiro experimento cinemático observou-se menor oscilação lateral dos dados na velocidade de $1,39 \text{ m s}^{-1}$. No segundo experimento cinemático o erro médio foi de 1,26 e 1,13 m, com RMSE de 1,45 e 1,27 m, para os dados antes e após a aplicação do filtro, respectivamente. Concluiu-se que o sistema diminui os erros laterais nos trechos retilíneos e não é indicado para trechos de mudança de direção, podendo ser utilizado em aplicações agrícolas como amostragem de solo e monitoramento de produtividade.

PALAVRAS-CHAVE: georreferenciamento, posicionamento, beaglebone black, algoritmo

INTRODUÇÃO

Os Sistemas Globais de Navegação por Satélite (do inglês, GNSS) são um dos pilares da Agricultura de Precisão (AP) (De Oliveira, 2016). O GNSS é a base para manejo localizado no campo de produção, utilizado durante as etapas do plantio, na aplicação de fertilizantes à taxa variáveis, na aplicação de agroquímicos e na colheita (Chen, 2005; Suprem et al., 2013). Além disso, os GNSS permitem o georreferenciamento dos dados coletados e a consequente geração de mapas pelos diferentes sistemas que compõem a AP. É esse gerenciamento localizado dos processos agrícolas que distinguem a AP da agricultura convencional (Mondal et al., 2011).

Mais recentemente, há um grande interesse na utilização de veículos robóticos terrestres (robôs) e aéreos remotamente pilotados (RPA) para agricultura de precisão (Bakker et al., 2011; Ji et al., 2012; Mousazadeh, 2013; Yin & Noguchi, 2013). Para viabilização de sistemas robóticos, principalmente para pequenas propriedades, os custos dos sistemas de navegação devem ser reduzidos (De Oliveira, 2016). Por isso, tecnologias que facilitem o acesso ao sistema GNSS são fundamentais para viabilizar a orientação de pequenas máquinas na agricultura. Computadores de placa única como a Beaglebone Black (BBB), da marca BeagleBoard modelo Beaglebone Black Revisão C (BeagleBoard.org Foundation, Michigan – USA) (BeagleBoard, 2019) são alternativas de baixo custo e permitem desenvolver rapidamente novas ferramentas para a AP (Olesen et al., 2016).

Outro fator importante a ser considerado na implantação de um sistema GNSS em máquinas agrícolas é a precisão do posicionamento. A precisão é função principalmente do ruído de medição (incerteza) e do tipo de algoritmo de navegação (Laveti et al., 2016). Na prática, a incerteza de medição nunca chega a zero, mesmo que os parâmetros e os

ruídos existentes no sistema sejam modelados efetivamente (Xu & Xu, 2016).

O algoritmo de navegação deve minimizar a variância do erro para então removê-los do sinal e assim melhorar a precisão (Fourati, 2015; Li et al., 2017). A utilização do filtro de Kalman (Kalman, 1960) é uma das formas de remover os erros do sinal em sistemas de orientação de baixo custo (Huang et al., 2018; Xiong et al., 2018; Liu et al., 2018). Nesse contexto, o presente trabalho teve como objetivo avaliar a precisão de um sistema integrado composto por um módulo GNSS de baixo custo e o computador de placa única BBB, e a aplicação do filtro de Kalman na obtenção dos dados de navegação.

MATERIAL E MÉTODOS

Foi utilizada a plataforma BeagleBone Black – Revisão C.1 (BBB), com sistema operacional Linux Debian versão 7.8 (Wheezy) (US\$63,00). Um módulo receptor GNSS da marca Simply Tronics, modelo VPN1513, foi integrado a BBB. Essa integração possibilitou a implementação de um algoritmo de filtragem nos dados de posição.

O módulo GNSS utilizado foi de baixo custo (US\$20,00), utiliza o chipset SiRF Star III com 20 canais de recepção de satélites, com sensibilidade de rastreamento de -159 dBm, capta sinais na frequência 1575.42 MHz (banda L1) e a precisão indicada pelo fabricante foi de +/- 10 m. O módulo foi operado com tensão de 5 V, energizado pela própria BBB. A BBB por sua vez foi alimentada com uma tensão de 5V via cabo USB por uma bateria externa comumente utilizada para recarregar celulares (US\$10,00).

A conexão entre o módulo GNSS e a plataforma BBB, a nível de hardware, foi feita via porta serial UART (Universal Asynchronous Receiver/Transmitter). As portas seriais UART utilizadas foram as portas UART1_TXD e UART1_RXD, localizadas no cabeçalho de expansão P9 da BBB com numeração de pinos 24 e 26, respectivamente. A

comunicação serial foi realizada utilizando-se a taxa de transmissão de dados de 9600, pois essa velocidade de comunicação foi suficiente para receber todos os dados. Os dados foram atualizados a cada segundo até o usuário encerrar a comunicação.

Implementação do algoritmo de filtragem

Foi desenvolvido um algoritmo para comunicação com o módulo GNSS, na linguagem C++ (Figura 1). O algoritmo recebia os dados do módulo GNSS, que fornecia dados padrão no formato NMEA 0183, que foi o protocolo de comunicação GNSS (Khan & Mishra, 2012). O algoritmo, então, realizou a conversão dos dados para latitude e longitude em WGS 1984 no formato graus decimais e posteriormente para a projeção métrica UTM WGS 1984. Esta última transformação foi realizada com base em Dutch (2015) adaptado para a linguagem C++.




FIGURA 1. Passos e respectivas etapas do algoritmo em C++.

A fim de melhorar a precisão dos dados de posição fornecidos pelo módulo GNSS, um algoritmo de navegação foi implementado, em linguagem C++ com base no filtro de Kalman. O filtro de Kalman tem comportamento preditor-corretor e funciona com base no método dos mínimos quadrados (Cintra et al., 2010). O filtro de Kalman é uma solução recursiva através de uma filtragem linear que é ideal para estimar as variáveis de estado dos sistemas. Para a modelagem do sistema utilizou-se os valores iniciais do posicionamento para prever e ajustar parâmetros a cada nova medida, obtendo-se o erro estimado em cada atualização de dados (Shen et al., 2015).

O filtro de Kalman utilizado apresentou dois passos principais, predição e correção (atualização), subdivididos em uma série de cinco etapas (Figura 2). As duas primeiras

etapas compreenderam o passo de predição. Neste passo, uma estimativa a priori de cada ponto coletado foi realizada com base no estado atual e no modelo do sistema. Na sequência, uma estimativa a posteriori melhorada, foi projetada com base nas três últimas etapas, finalizando assim o passo de atualização conforme apresentado por Li et al. (2016).

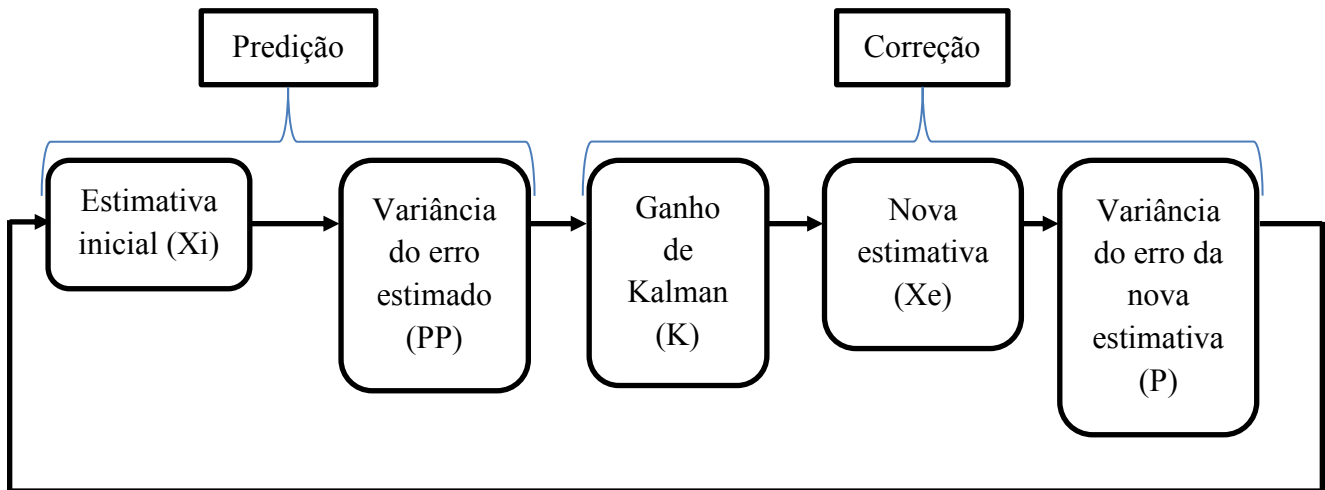


FIGURA 2. Passos e respectivas etapas do filtro de Kalman.

O processo iterativo do filtro de Kalman entre a atualização de tempo e a atualização de medida começou após a inicialização da geração de posição do GNSS, de forma similar a apresentada por Xiong et al. (2014). O sistema então foi propagado para o intervalo de tempo seguinte para obter uma estimativa para posição seguinte. Então, na posição seguinte ($i+1$), o vetor de estado atual foi atualizado para X_{i+1} . Utilizou-se o primeiro dado coletado como a primeira estimativa do vetor inicial (X_i), enquanto as demais foram calculadas a partir da Equação 1, como determina a primeira etapa. Na segunda etapa, foi calculada a variância da estimativa inicial PP (Equação 2). Foi utilizado como parâmetro de variância da perturbação e do sensor o erro máximo do GNSS, definido como 10 m pelo fabricante.

$$X_i = a X_{e_i} \quad (1)$$

Em que

X_i – Vetor de estimativa inicial;

a - constante do sistema linear;

X_{e_i} - estimativa na posição i .

$$PP = P a^2 W \quad (2)$$

Em que

PP - variância da estimativa inicial;

P - variância do sistema;

W - variância da perturbação do sistema.

A partir desse ponto, para as três últimas etapas, o ruído na medida dos sensores que compõe o sistema passou a ser considerado, obtendo-se assim uma medida corrigida do sistema. Na terceira, das cinco etapas, calculou-se o ganho de Kalman (Equação 3), que foi utilizado para encontrar a nova estimativa ($X_{e_{i+1}}$) na quarta etapa (Equação 4). Essa nova estimativa foi a saída do filtro, ou seja, a estimativa do novo ponto.

$$K = \frac{M PP}{(PP M^2) + U} \quad (3)$$

Em que

K – ganho de Kalman;

M - constante do sistema de correção;

U - variância da medida do sensor.

$$X_{e_{i+1}} = X_i + y_{i+1} - (M X_i) \quad (4)$$

Em que

$X_{e_{i+1}}$ - estimativa na posição $i+1$;

y_{i+1} – medida ruidosa na posição $i+1$ (valor de entrada do filtro e que no presente artigo serão as medidas de posição);

Na quinta e última etapa, foi calculada uma nova variância (Equação 5), agora para o erro do novo ponto. A matriz de ganho foi otimizada de tal forma a produzir uma variância mínima do erro. O valor da variância do novo ponto foi utilizado para o cálculo da próxima estimativa inicial, reiniciando assim a sequência do filtro.

$$P_{i+1} = PP (1 - K M)^2 + U K^2 \quad (5)$$

Em que

P_{i+1} - variância da estimativa na posição $i+1$.

A cada segundo, o dado de posição amostrado foi armazenado em um arquivo texto e exibido ao usuário por meio de uma interface gráfica. A interface gráfica foi desenvolvida utilizando-se como ambiente de desenvolvimento integrado (IDE) o Qt Creator Versão 4.0.2. Para visualização e interação com o usuário um visor LCD sensível ao toque (US\$75,00) foi acoplado a BBB. Sendo assim o sistema GNSS-BBB foi totalmente adquirido com US\$168,00.

Desempenho do Sistema

Os experimentos foram conduzidos nos dias 15 e 16 de outubro de 2016 no campus da Universidade Federal de Viçosa – UFV, Viçosa-Minas Gerais (nas proximidades da coordenada UTM 721399.29 m E, 7701645.99 m N, zona 23 S) das 14:00h às 16:00h. Como parâmetro de confiabilidade observou-se o PDOP (Position Dilution of Precision) dos pontos coletados sendo abaixo de 2,0. O valor de PDOP pode ser usado para avaliar o desempenho da geometria de satélites (Han et al., 2014), sendo que valores mínimos de PDOP sugerem uma melhor geometria dos satélites e, portanto, dados mais confiáveis.

Foram realizados três experimentos para a análise do sistema integrado GNSS-BBB: uma coleta de dados em modo estático e duas coletas de dados em modo cinemático. O objetivo foi determinar a acurácia dos pontos de posicionamento estático e cinemático, além do comportamento do sistema em diferentes velocidades. Os dados

obtidos com sistema integrado GNSS-BBB proposto, transformado em UTM pelo algoritmo, foram armazenados na plataforma para posterior análise.

O experimento estático consistiu na demarcação de uma malha regular quadrada contendo os pontos de referência. Em uma área de 100,0 m² foi definida uma malha quadrada regular de 5 x 5 pontos, com pontos a cada 2,5 m. Para isto, utilizou-se um GNSS Topográfico, de frequência simples L1, da marca Trimble modelo ProXT (Trimble Navigation Limited, USA) que possibilita correção diferencial pós-processada. A correção dos dados foi realizada a partir do software GPS Pathfinder Office® v.5.00, utilizando dados disponibilizados pela Rede Brasileira de Monitoramento Contínuo (RBMC) do Instituto Brasileiro de Geografia e Estatística (IBGE). Após correção dos dados de referência o GNSS Topográfico indicou um erro médio de 0,15 m. Nesta mesma malha, os 25 pontos experimentais foram coletados ao acaso três vezes utilizando o sistema GNSS-BBB proposto neste trabalho.

No primeiro experimento cinemático foram utilizadas duas linhas paralelas de 100,0 m. O objetivo desse experimento foi avaliar o comportamento do sistema GNSS-BBB antes e após a passagem do filtro de Kalman em função da velocidade. Para isso, foram utilizadas quatro velocidades médias: 1,39, 2,22, 2,78 e 4,17 m s⁻¹. O experimento foi realizado considerando as velocidades em ordem crescente e foram realizadas três repetições deste, sendo considerado a média para análise.

No segundo experimento cinemático foram realizados dois testes, com três repetições cada, na velocidade média de 1,39 m s⁻¹ em ordem aleatória. Neles considerou-se quatro linhas paralelas de 100,0 m. O objetivo deste experimento foi verificar a precisão do sistema e o raio de curvatura necessário para que o filtro de Kalman não considere os dados de uma mudança de direção como erros do sistema. Isso porque o filtro de Kalman suaviza as mudanças abruptas de direção, demandando alguns ciclos de

coleta de dados para a estabilização. Para verificar a distância necessária para mudança de direção do Filtro de Kalman as quatro linhas foram percorridas realizando-se mudança de direção na posição normal e alongando-se a cabeceira para estender a curva e verificar o comportamento do filtro de Kalman.

Análise dos resultados

Os erros de posicionamento estático (EP_e) foram calculados como sendo a diferença entre as coordenadas dos pontos experimentais, obtidos com o sistema GNSS-BBB, e os pontos de referência obtidos com o GNSS topográfico. Utilizando a Equação 6 foram determinados os erros nos dados coletados no experimento estático.

$$EP_e = \sqrt{EN^2 + EL^2} \quad (6)$$

Em que

EP_e = erro de posicionamento estático;

EN - o erro na direção norte, em metros (m);

EL - o erro na direção leste, em metros (m).

Os erros de posicionamento dos experimentos cinemáticos (EP_c) foram calculados de acordo com a Equação 7. Esta determina a distância entre as coordenadas dos pontos experimentais (x_i, y_i), obtidos com o sistema GNSS-BBB, e a reta ($ax + by + c = 0$) formada pela regressão linear dos pontos de referência obtidos com o GNSS topográfico. A média dos erros entre o sistema GNSS-BBB antes e após a filtragem foram comparadas estatisticamente utilizando o teste t-student com um nível de significância de 5%.

$$EP_c = \frac{|ax_i + by_i + c|}{\sqrt{a^2 + b^2}} \quad (7)$$

Em que

EP_c – erro de posicionamento cinemático;

a – coeficiente angular da reta no eixo x;

x_i - coordenada leste UTM;

b – coeficiente angular no eixo y;

y_i - coordenada norte UTM;

c - deslocamento da origem (0,0);

i - número do dado coletado

Utilizando a Equação 8 foi determinada a raiz quadrada do erro quadrático médio (RMSE), que indica a acurácia dos dados, ela não utiliza a média e resulta no erro absoluto em relação à referência, representando 68% de uma distribuição (Machado & Molin, 2011).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n EP^2}{n}} \quad (8)$$

Em que

RMSE – raiz quadrada do erro quadrático médio

EP - erro de posição para o experimento estático ou cinemático;

n - número de dados coletados.

RESULTADOS E DISCUSSÃO

Análise do sistema GNSS-BBB no experimento estático

Os dados apresentaram erros de posição variando entre 0,79 a 6,26 m (Figura 3) com média de 3,35 m e RMSE de 3,73 m em relação a posição indicada pelo GNSS topográfico. Os resultados do experimento estático corroboram com os encontrados por Machado & Molin (2011) que realizaram ensaios em oito receptores GNSS e encontraram valores de RMSE sem a utilização de correção variando entre 1,02 e 3,11 m para a região de Piracicaba, SP.

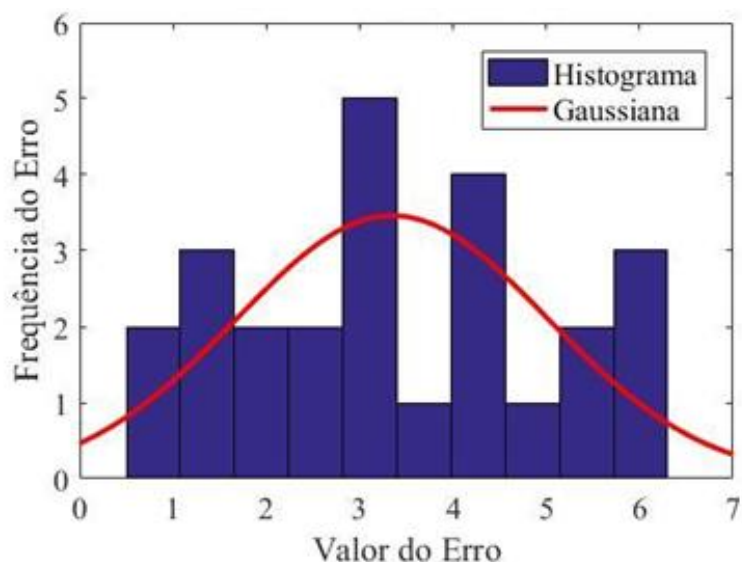


FIGURA 3. Gráfico de frequência do erro entre o GNSS topográfico e o módulo de GNSS integrado à Beaglebone Black para o experimento estático

Não se observou uma tendência na diminuição dos erros em função do aumento do tempo de coleta dos dados, uma vez que o dado de posição do GNSS se manteve constante, sendo modificado apenas se ele estivesse em movimento.

Análise do sistema GNSS-BBB no primeiro experimento cinemático

Os dados coletados com as diferentes velocidades são apresentados na Figura 4. As coordenadas UTM foram deduzidas de 721200 m no sentido L-O e 7701500 m no sentido N-S, para obter-se coordenadas de menor valor, para retornar as coordenadas aos valores originais basta somar esses valores às coordenadas apresentadas no gráfico. Dentre as 4 velocidades médias avaliadas a de $1,39 \text{ m s}^{-1}$ apresentou menor oscilação lateral e menor erro médio e RMSE (Tabela 1). Além disso, observou-se que com o aumento da velocidade média, os dados apresentaram maiores oscilações laterais e consequentemente maiores erros médios e RMSE.

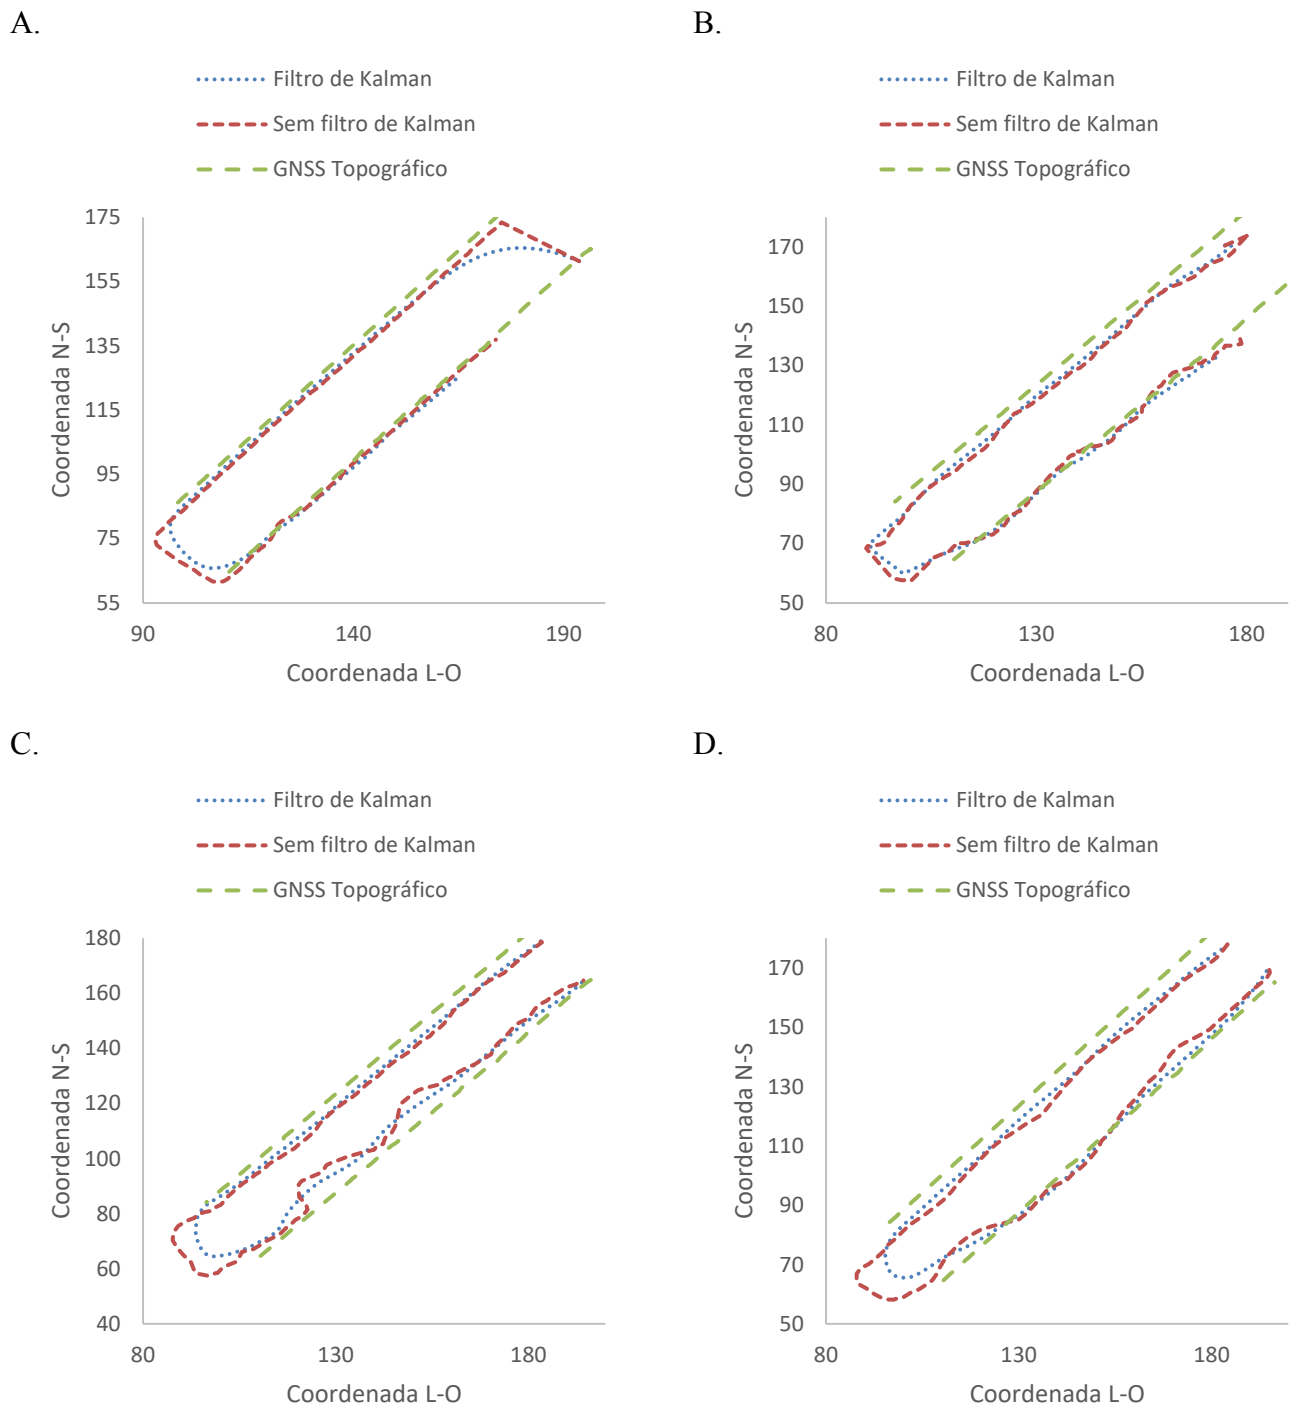


FIGURA 4. Percursos demarcados pelo sistema GNSS-BBB para as velocidades médias de $1,39 \text{ m s}^{-1}$ (A), $2,22 \text{ m s}^{-1}$ (B), $2,78 \text{ m s}^{-1}$ (C) e $4,17 \text{ m s}^{-1}$ (D).

TABELA 1. Estatística descritiva dos erros obtidos no experimento cinemático em quatro velocidades médias diferentes com e sem aplicação o filtro de Kalman.

| Velocidade (m/s) | Filtro de Kalman | Erros (m) | | | | DP ⁴ |
|---------------------|---------------------|-----------|--------|-------|-------------------|-----------------|
| | | Mínimo | Máximo | Médio | RMSE ³ | |
| 1,39 | Com ¹ | 0,01 | 2,62 | 1,27 | 1,34 | 0,40 |
| | Sem ² | 0,07 | 2,67 | 1,50 | 1,52 | 0,20 |
| 2,22 | Com ¹ | 0,01 | 5,03 | 2,37 | 2,57 | 0,91 |
| | Sem ² | 0,09 | 7,04 | 2,73 | 2,92 | 1,00 |
| 2,78 | Com ¹ | 0,72 | 5,99 | 2,96 | 3,22 | 1,24 |
| | Sem ² | 1,12 | 9,56 | 3,59 | 4,00 | 1,51 |
| 4,17 | Com ¹ | 0,09 | 5,92 | 3,32 | 3,56 | 1,19 |
| | Sem ² | 0,15 | 6,64 | 4,25 | 4,39 | 1,00 |

¹ Dados obtidos pelo sistema integrado GNSS-BBB com implementação do Filtro de Kalman; ² Dados obtidos pelo sistema integrado GNSS-BBB sem implementação do Filtro de Kalman; ³ Raiz quadrada do erro quadrático médio; ⁴ Desvio Padrão

O filtro de Kalman reduziu em todos os casos os erros médios e RMSE, além de reduzir as oscilações laterais. A redução das oscilações laterais é fundamental para implementação de direção automática em máquinas agrícolas, para que o sistema de direção não sofra mudanças bruscas de direção. A linearidade dos dados possibilita que esse sistema GNSS-BBB seja utilizado para direção automática em operações agrícolas em que não seja necessária uma acurácia submétrica, como por exemplo amostragem de solo e monitoramento de produtividade.

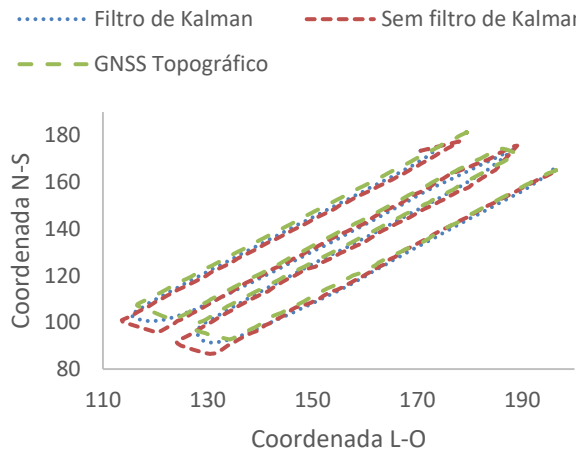
Com base nos dados apresentados na Tabela 1, é possível observar que com o aumento da velocidade houve uma tendência de aumento do erro médio, do RMSE e do desvio padrão. Observa-se que com a utilização do filtro de Kalman houve uma tendência de os dados apresentarem menor erro mínimo, máximo, médio e RMSE. O desvio padrão, foi maior com o filtro do Kalman nas velocidades de 1,39 e 4,17 m s⁻¹. Isso ocorreu provavelmente devido à não ocorrência de erros grosseiros e bruscos para essas

velocidades, conforme pode ser observado na Figura 4.

Análise do sistema GNSS-BBB no segundo experimento cinemático

Foi simulada a distância necessária para mudança de direção do Filtro de Kalman em dois testes, realizando-se mudança de direção na posição normal (Figura 5.a) e alongando-se a cabeceira para estender a curva (Figura 5.b). As coordenadas UTM foram deduzidas de 721200 m no sentido L-O e 7701500 m no sentido N-S, para obter-se coordenadas de menor valor, para retornar as coordenadas aos valores originais basta somar esses valores às coordenadas apresentadas no gráfico. Foi possível realizar uma comparação entre os dados de referência, coletados com o GNSS topográfico e aqueles coletados com o sistema proposto antes e após o filtro de Kalman. Dentre outros aspectos, observa-se que os dados antes do filtro apresentaram oscilações, apesar de o percurso ser em linha reta. Os dados após o filtro, apresentaram menor desvio e se aproximaram mais dos dados do GNSS topográfico.

A.



B.

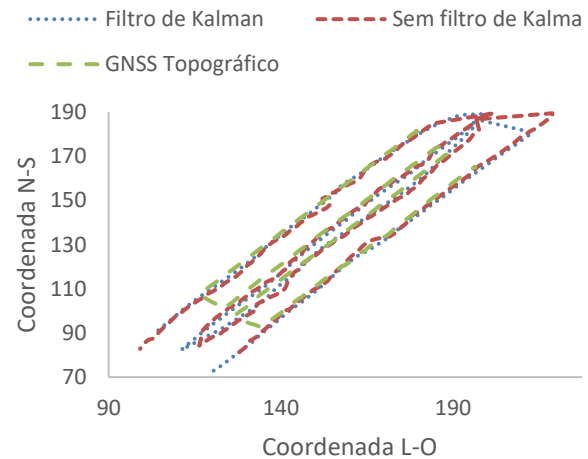


FIGURA 5. Experimento cinemático com mudança de direção na posição normal (A) e alongando-se a cabeceira para estender a curva (B).

Os erros médios de posição foram de 1,26 e 1,13 m, e RMSE de 1,45 e 1,27 m para os dados antes e após o filtro de Kalman, respectivamente, em relação ao GNSS

topográfico. De acordo com o teste estatístico t-student, após o filtro de Kalman os dados apresentaram erro médio significativamente menor do que o erro sem aplicação do filtro (Pvalor < 0,05). A melhoria se deve ao fato de o filtro de Kalman manter o comportamento, suavizando mudanças bruscas e conseqüentemente diminuindo os erros nos valores de posição (Gil et al, 2013). O filtro de Kalman retira do sinal grande parte dos erros aleatórios ocorrendo uma diminuição no erro máximo dos dados que passou de 3,58 para 2,82 m após a filtragem, corroborando com o observado por Gil et al. (2013) e Han et al. (1998).

Porém como o filtro de Kalman não é indicado em trajetos curvos (Han et al., 1998), pois mantém a tendência dos dados e então rejeita os dados provenientes da mudança de direção. Observou-se que, para a velocidade de $1,39 \text{ m s}^{-1}$ foram necessários cerca de 5 m para que o filtro de Kalman acompanhasse os dados provenientes de uma correta mudança de direção.

CONCLUSÕES

O filtro de Kalman possibilitou que os dados cinemáticos fossem mais precisos que os dados estáticos. Pois ele eliminou oscilações bruscas lateralmente, devido a erros aleatórios do sinal GNSS, mantendo um comportamento linear, e diminuiu em todos em casos os erros encontrados.

O módulo de GNSS integrado à Beaglebone Black pode ser utilizado em determinadas aplicações agrícolas em que não seja necessária uma acurácia submétrica, como por exemplo amostragem de solo e monitoramento de produtividade. Desde que operando a uma velocidade de $1,39 \text{ m s}^{-1}$ e com raio de curvatura mínimo maior que 5 m, uma vez que o filtro de Kalman não apresentou bons resultados nos trechos de mudança

de direção.

AGRADECIMENTOS

Os autores agradecem ao CNPq, Capes e Fapemig pelo apoio financeiro.

REFERÊNCIAS BIBLIOGRÁFICAS DO CAPITULO 1

Bakker T, Van Asselt K, Bontsema J, Mülher J, Straten GV (2011) Autonomous navigation using a robot platform in a sugar beet field. *Biosystems Engineering* 109(1):357-368. DOI: <https://doi.org/10.1016/j.biosystemseng.2011.05.001>

BeagleBoard (2019) Beaglebone Black. In: What is Beaglebone Black? Available: <https://beagleboard.org/black>. Accessed Mar 13, 2019.

Chen J, Shi SB, Hou JC, Xu J (2005) The Development of Digital Agriculture and Chinese Agriculture Machinery. *Journal of Agricultural Mechanization Research* 3:008.

Cintra RS, Velho HFC, Todling R (2010) Redes neurais artificiais na melhoria de desempenho de métodos de assimilação de dados: Filtro de Kalman. *Trends in Applied and Computational Mathematics* 11:29-39. DOI: <https://doi.org/10.5540/tema.2010.011.01.0029>

De Oliveira RP (2016) Apoio à Decisão na Adoção da Agricultura de Precisão: A Tecnologia da Informação em Apoio ao Conhecimento Agrônômico. *Revista Eletrônica Competências Digitais para Agricultura Familiar* 2:89-109.

Dutch S (2015) Converting UTM to Latitude and Longitude (Or Vice Versa). Available: <http://www.uwgb.edu/dutchs/UsefulData/UTMFormulas.HTM>. Accessed Mar 14, 2017.

Fourati H (2015) Heterogeneous data fusion algorithm for pedestrian navigation via foot-mounted inertial measurement unit and complementary filter. *IEEE Transactions on Instrumentation and Measurement* 64(1):221-229. DOI: <https://doi.org/10.1109/TIM.2014.2335912>

Gil JG, Gonzalez RR, Garcia SA, Gil FJG (2013) A kalman filter implementation for precision improvement in low-cost GPS positioning of tractors. *Sensors* 13:15307-15323. DOI: <https://doi.org/10.3390/s131115307>

Han S, Gui Q, Li G, Du Y (2014) Minimum of PDOP and its applications in inter-satellite links (ISL) establishment of Walker- δ constellation. *Advances in Space Research* 54:726-733. DOI: <https://doi.org/10.1016/j.asr.2014.04.020>

Han S, Zhang Q, Noh HK (1998) Applying filtering techniques to improve GPS positioning accuracy. In: 2001 ASAE Annual Meeting. American Society of Agricultural and Biological Engineers. CD Rom.

Huang Y, Zhang Y, Xu B, Wu Z, Chambers JA (2018) A new adaptive extended Kalman filter for cooperative localization. *IEEE Transactions on Aerospace and Electronic Systems* 54(1):353-368. DOI: <https://doi.org/10.1109/TAES.2017.2756763>

Ji W, Zhao D, Cheng F, Xu B, Zhang Y, Wang J (2012) Automatic recognition vision system guided for apple harvesting robot. *Computers and Electrical Engineering*, 38(1):1186-1195. DOI: <https://doi.org/10.1016/j.compeleceng.2011.11.005>

Kalman RE (1960) A new approach to linear filtering and prediction problems. *Journal of basic Engineering* 82:35-45. DOI: <https://doi.org/10.1115/1.3662552>

Khan A, Mishra R (2012) GPS–GSM based tracking system. *International Journal of Engineering Trends and Technology* 3:161-164.

Laveti G, Rao GS, Bidikar B (2016) Modified Kalman Filter for GPS Position Estimation over the Indian Sub Continent. *Procedia Computer Science* 87:198-203. DOI:

<https://doi.org/10.1016/j.procs.2016.05.148>

Li J, Song N, Yang G, Li M, Cai Q (2017) Improving positioning accuracy of vehicular navigation system during GPS outages utilizing ensemble learning algorithm. *Information Fusion* 35:1-10. DOI: <https://doi.org/10.1016/j.inffus.2016.08.001>

Li K, Chang L, Hu B (2016) A Variational Bayesian-Based Unscented Kalman Filter With Both Adaptivity and Robustness. *IEEE Sensors Journal* 16:6966-6976. DOI: <https://doi.org/10.1109/jsen.2016.2591260>

Liu Y, Fan X, Lv C, Wu J, Li L, Ding D (2018) An innovative information fusion method with adaptive Kalman filter for integrated INS/GPS navigation of autonomous vehicles. *Mechanical Systems and Signal Processing* 100:605-616. DOI: <https://doi.org/10.1016/j.ymsp.2017.07.051>

Machado TM, Molin JP (2011) Ensaio estático e cinemático de receptores de GPS. *Revista Brasileira de Engenharia Agrícola e Ambiental* 15:981-988. DOI: <https://doi.org/10.1590/s1415-43662011000900015>

Mondal P, Basu M, Bhadoria PBS (2011) Critical review of precision agriculture technologies and its scope of adoption in India. *American Journal of Experimental Agriculture* 1:49-68. DOI: <https://doi.org/10.9734/AJEA/2011/155>

Mousazadeh H (2013) A technical review on navigation systems of agricultural autonomous off-road vehicles. *Journal of Terramechanics* 50(3):211–232. DOI: DOI: <https://doi.org/10.1016/j.jterra.2013.03.004>

Olesen D, Jakobsen J, Benzoni HH, Knudsen P (2016) GNSS Software Receiver for UAVs. *European Journal of Navigation*.

Shen JC, Chang CH, Wu SJ, Hsu CT, Lien HC (2015) Real-time correction of water stage forecast using combination of forecasted errors by time series models and Kalman filter method. *Stochastic environmental research and risk assessment* 29(7):1903-1920.

DOI: <https://doi.org/10.1007/s00477-015-1074-9>

Suprem A, Mahalik N, Kim K (2013) A review on application of technology systems, standards and interfaces for agriculture and food sector. *Computer Standards & Interfaces* 35:355-364. DOI: <https://doi.org/10.1016/j.csi.2012.09.002>

Xiong B, Zhao J, Wei Z, Skyllas-Kazacos M (2014) Extended Kalman filter method for state of charge estimation of vanadium redox flow battery using thermal-dependent electrical model. *Journal of Power Sources* 262:50-61. DOI: <https://doi.org/10.1016/j.jpowsour.2014.03.110>

Xiong H, Tang J, Xu H, Zhang W, Du Z (2018) A Robust Single GPS Navigation and Positioning Algorithm Based on Strong Tracking Filtering. *IEEE Sensors Journal* 18(1):290–298. DOI: <https://doi.org/10.1109/jsen.2017.2767066>

Xu G, Xu Y (2016) *GPS: theory, algorithms and applications*. New York, Springer, 3ed. 488p.

Yin, X, Noguchi N (2013) Development of a target following system for a field robot. *IFAC Proceedings Volumes* 46(18):109–114. DOI: <https://doi.org/10.3182/20130828-2-SF-3019.00068>

CAPÍTULO 2 – DESENVOLVIMENTO DE UM SISTEMA SENSOR PARA AQUISIÇÃO DE ÍNDICES DE VEGETAÇÃO

RESUMO

Os índices de vegetação são importantes indicadores de biomassa, teor de clorofila, cobertura vegetal e área foliar. Tecnologias de baixo custo são fundamentais para facilitar o acesso dos produtores rurais a ferramentas de auxílio na tomada de decisão como, por exemplo, os índices de vegetação. Dessa forma, objetivou-se desenvolver um sistema sensor de baixo custo, com base em fototransistor para obtenção e armazenamento de índices de vegetação. Os índices abordados foram: NDVI, SR, WDRVI, SAVI e OSAVI. O desenvolvimento do sistema sensor de índices de vegetação foi realizado a partir um circuito analógico para realizar a aquisição de dados de reflectância das bandas do vermelho e infravermelho próximo. Desenvolveu-se um algoritmo que, a partir dos dados que coletados pelo circuito analógico, calcula os índices de vegetação, que são armazenados em um arquivo no formato “txt”. Foi realizada a calibração do sistema sensor para ajustar seus valores aos de um espectroradiômetro e por último foi realizada a análise de desempenho dos índices de vegetação obtidos com o sistema sensor. Nas condições analisadas, o sistema sensor proposto pode ser utilizado na determinação de todos os índices de vegetação abordados. Uma vez que suas leituras foram estatisticamente iguais ao espectroradiômetro.

PALAVRAS-CHAVE: beaglebone black, fototransistor, agricultura de precisão.

INTRODUÇÃO

Os índices de vegetação são importantes indicadores de biomassa (Bendig et al., 2015), teor de clorofila (Croft et al., 2014), cobertura vegetal (Shao et al., 2016) e área foliar (Rasmussen et al., 2016). Dentre os índices de vegetações, o Índice de Vegetação da Diferença Normalizada (NDVI), proposto por Rouse et al. (1973), tem sido um dos mais utilizados (Ke et al., 2015). O NDVI expressa o vigor vegetativo das plantas e se correlaciona com a biomassa (Prabhakara et al., 2015; Ramirez et al., 2015; Smith et al., 2015), a cobertura vegetal (White et al., 2016) e a produtividade (Wang et al., 2015). Porém, o NDVI satura para altos valores de cobertura vegetal (Jimenez-Berni et al., 2018). Dessa forma, torna-se importante o uso de outros índices como forma de suprir essa limitação, como, por exemplo, o SR (Razão Simples) (Jordan, 1969) que é sensível para altos valores de cobertura vegetal (Santos Galvanin et al., 2014).

Além do NDVI e do SR existem outros índices de vegetação como: o WDRVI (Índice de Vegetação de Larga Escala Dinâmica) que melhora a sensibilidade do NDVI para cobertura vegetal de alta densidade (Gitelson, 2004); o SAVI (Índice de Vegetação Ajustado ao Solo) (Huete, 1988) que é utilizado para diminuir o efeito do solo na observação da vegetação (Candiago et al., 2015) e; o OSAVI (Índice de Vegetação Ajustado ao Solo Otimizado) (Rondeaux et al., 1996) que é um caso particular do SAVI.

Existem diversos sensores comerciais para mensurar comprimentos de ondas eletromagnéticas que são utilizados para calcular índices de vegetação, tais como, a Parrot Sequoia (Ahmed et al., 2017), o SRS sensors (Gamon et al., 2015) e o GreenSeeker (Ali e Thind, 2015). Porém estes sensores possuem custos elevados, o que inviabiliza seu uso por grande parte dos produtores rurais.

Na literatura, alguns autores têm estudado o cálculo de índices de vegetação

utilizando imagens de sensores orbitais (Zhang e Roy, 2016; Fan e Liu, 2016 e Karlsen et al., 2014), outros capturaram imagens com veículos aéreos não tripulados (VANTs) (Zheng et al., 2016; Gago et al., 2015; Ghazal et al., 2015). No entanto, as duas técnicas apresentam dificuldades em sua implementação. No caso dos sensores orbitais, as principais dificuldades são a baixa frequência de aquisição, baixa resolução espacial e perda de informação nas imagens pela cobertura de nuvens. No caso dos VANTs, as principais dificuldades são a sua baixa autonomia de voo, capacidade de carga reduzida e necessitarem de alta demanda de processamento computacional das imagens geradas (Matese et al., 2015).

Tecnologias de baixo custo são fundamentais para facilitar o acesso dos produtores rurais a ferramentas de auxílio na tomada de decisão como, por exemplo, os índices de vegetação. Computadores de placa única, como a BeagleBone Black (BBB), são alternativas de baixo custo que permitem integrar várias funções em um mesmo sistema sensor como posicionamento GNSS e aquisição de índices de vegetação.

Neste capítulo buscou-se desenvolver um sistema sensor de baixo custo, com base em fototransistor para obtenção e armazenamento de índices de vegetação de forma direta, tornando assim a utilização de índices de vegetação mais acessível à realidade do produtor rural.

MATERIAL E MÉTODOS

O sistema sensor de índices de vegetação foi desenvolvido no Laboratório de Projeto de Máquinas e Visão Artificial (PROVISAGRO) do Departamento de Engenharia Agrícola da Universidade Federal de Viçosa, Minas Gerais. Este sistema sensor obteve as informações de reflectância nas faixas do vermelho e do infravermelho próximo e, a

partir delas, calculou os índices de vegetação: NDVI, SR, WDRVI, SAVI e OSAVI.

O desenvolvimento do sistema sensor de índices de vegetação foi dividido em quatro etapas. Na primeira, utilizou-se um circuito analógico para realizar a aquisição de dados de reflectância das bandas do vermelho e infravermelho próximo. Na segunda, foi desenvolvido um algoritmo que, a partir dos dados que coletados pelo circuito analógico, calcula os índices de vegetação, que são armazenados em um arquivo no formato “txt”. Na terceira, foi realizada a calibração do sistema sensor para ajustar seus valores aos do espectroradiômetro FieldSpec® HandHeld 2TM Spectroradiometer (Analytical Spectral Devices, Boulder, CO, EUA). Na quarta foi realizada a análise de desempenho dos índices de vegetação obtidos com o sistema sensor.

1 – Desenvolvimento do sistema sensor de índices de vegetação

1.1 - Circuito analógico do sistema sensor

Para o desenvolvimento do sistema sensor de índices de vegetação, foi utilizado um circuito analógico composto por fototransistores como elementos sensores. Os fototransistores utilizados foram o Everlight PT334-6C e o Fairchild QSD124 para capturar as bandas do vermelho e do infravermelho próximo, respectivamente. O Everlight PT334-6C tinha uma faixa de resposta espectral de 400nm a 1100nm, com pico de sensibilidade ocorrendo em 940nm, por isso foi necessário filtrar espectralmente a radiação que atingia esse fototransistor. Para isso foi instalado um filtro passa banda que transmitia seletivamente a banda vermelha de radiação para atingir a superfície de detecção do fototransistor. O filtro passa banda utilizado possui uma curva de metade da largura máxima (FWHM) de 66 nm e pico de sensibilidade ocorrendo em 679 nm, segundo medida realizada pelo espectroradiômetro. O Fairchild QSD124 possui um encapsulamento onde está contido um filtro passa banda de infravermelho com pico de sensibilidade ocorrendo em 880 nm.

Para leitura e processamento do sinal foi utilizado o computador de placa única BeagleBone Black (BBB), da marca BeagleBoard modelo Beaglebone Black Revisão C (BeagleBoard.org Foundation, Michigan – USA) (BeagleBoard, 2019), com o sistema operacional Debian versão 7.8 (Whezy) embarcado. O sinal foi recebido através das entradas analógicas AIN0 e AIN1 da BBB. Estas portas operam com sinais analógicos de tensão que variam de 0V a 1,8V.

Como os fototransistores funcionam com 5V, foi necessário um circuito com divisor de tensão para que o sinal fosse lido pela BBB. Esse circuito foi construído com um resistor de 680Ω e um de 330Ω colocados em série com cada fototransistor (Figura 1). Com a utilização desse circuito, a tensão no resistor de 330Ω variou de 0V a 1,63V sendo compatível com as entradas analógicas da BBB.

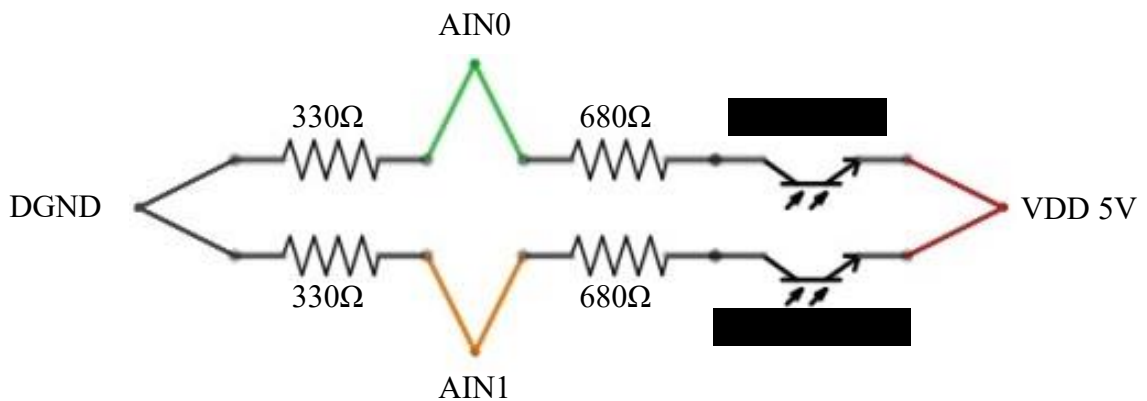


FIGURA 1. Diagrama do circuito analógico do sistema sensor. AIN0, AIN1 = Entradas analógicas da BBB; VDD 5V = Tensão de 5V da BBB; DGND = Tensão de 0V da BBB.

Para proteção do circuito analógico construído, este foi colocado em uma caixa de plástico preta com dimensões 120x57x32mm. O fototransistor Fairchild QSD124 possui ângulo de recepção de luz, indicado pelo fabricante, de $\pm 12^\circ$. Enquanto no Everlight PT334-6C o fabricante não especifica o ângulo de recepção, sendo considerado

pelos autores de $\pm 12^\circ$. Então para assegurar que não haveria interferência de luminosidade lateral, foi inserido na frente de cada fototransistor um cone preto (Figura 3).




FIGURA 3. Sistema sensor. A – Vista lateral. B – Vista inferior.

1.2 - Algoritmo do sistema sensor

Um algoritmo foi desenvolvido na linguagem C++, utilizando como ambiente de desenvolvimento integrado o software livre Qt Creator Versão 4.0.2. No algoritmo, os sinais recebidos do circuito analógico foram interpretados de forma a obter-se a reflectância no vermelho (V) e no infravermelho próximo (IV). Para obter os valores de reflectância, primeiramente, foi realizada a leitura de uma placa de Spectralon, assumindo-se que a mesma possuía reflectância uniforme e igual a um (100%). Essa leitura foi utilizada como valor de referência nas Equações 1 e 2.

$$V = \frac{V_1}{V_2} \quad (1)$$

Em que:

V = reflectância no vermelho.

V_1 = sinal do vermelho refletida pela vegetação.

V_2 = sinal do vermelho da referência (Spectralon).

$$IV = \frac{IV_1}{IV_2} \quad (2)$$

Em que:

IV = refletância no infravermelho próximo.

IV₁ = sinal do infravermelho próximo refletida pela vegetação.

IV₂ = sinal do infravermelho da referência (Spectralon).

As reflectâncias obtidas pelas Equações 1 e 2 foram utilizadas para determinar os índices de vegetação: NDVI (Equação 3) (Rouse et al., 1973), SR (Equação 4) (Jordan, 1969), WDRVI (Equação 5) (Gitelson, 2004), SAVI (Equação 6) (Huete, 1988) e, OSAVI (Equação 7) (Rondeaux et al., 1996).

$$NDVI = \frac{IV - V}{IV + V} \quad (3)$$

$$SR = \frac{IV}{V} \quad (4)$$

$$WDRVI = \frac{a * IV - V}{a * IV + V} \quad (5)$$

Em que:

a = coeficiente de ponderação.

O coeficiente de ponderação do WDRVI (a) pode variar entre 0 e 1, se ele for 1 então o WDRVI é igual ao NDVI. O valor de coeficiente geralmente utilizado para os cálculos de WDRVI é 0,2 (Xue & Su, 2017), e este foi o valor adotado neste trabalho.

$$SAVI = \frac{IV - V}{IV + V + L} * (1 + L) \quad (6)$$

Em que:

L = fator de ajuste do solo.

O fator de ajuste de solo do SAVI (L) pode variar entre 0 e 1, se ele for 0 então o SAVI é igual ao NDVI. Os fatores de ajuste normalmente utilizados são 0,25, para alta

densidade de vegetação, 0,50, para média densidade de vegetação, e, 1,00 para baixa densidade de vegetação (Hishe et al., 2017). Um valor de $L = 0,5$ funciona bem na maioria das situações sendo o valor padrão utilizado (Lu et al., 2015), e foi o valor adotado neste trabalho.

$$\text{OSAVI} = \frac{IV - V}{IVP + V + 0,16} \quad (7)$$

1.3 – Calibração do sistema sensor de índices de vegetação

Foi realizada a calibração dos dados de reflectância do sistema sensor proposto em relação aos do espectroradiômetro. Para essa calibração foram utilizadas como referência a reflectância de quatro placas de Spectralon com reflectâncias 0 (0%), 0,5 (50%), 0,75 (75%) e 1 (100%). Essas placas eram circulares com diâmetro de 0,05m.

A distância utilizada entre os aparelhos e as placas foi de 0,1m para garantir que com um ângulo de $\pm 12^\circ$ de recepção de luz dos fototransistores apenas a reflectância da placa de calibração fosse recebida. O espectroradiômetro foi calibrado para a mesma distância utilizando a placa de Spectralon com reflectância igual a 1 (100%). Para cada placa foram realizadas 60 leituras com o sistema sensor proposto. A partir da média das 60 leituras do sistema sensor, para cada placa, e as leituras do espectroradiômetro foi realizada uma regressão linear. A regressão linear entre os dados do sistema sensor e do espectroradiômetro foi avaliada através do teste F de Graybill e pelos R^2 obtidos nesses modelos lineares.

A fim de controlar o ambiente a calibração foi realizada em uma caixa preta com dimensões 1,30m x 1,00m x 0,70m e foi utilizada uma lâmpada halogênica de 650W para iluminação, localizada a 0,8m do alvo. As bandas vermelha e infravermelha do sistema sensor foram comparadas com a média das respostas do espectroradiômetro na faixa de 674-684nm e 875-885nm, respectivamente.

1.4 – Análise de desempenho do sistema sensor.

Para esta análise de desempenho, primeiramente, tanto o sistema sensor quanto o espectroradiômetro mediram a reflectância da placa de Spectralon para utilizar como valor de referência. A distância utilizada entre os aparelhos e a placa foi de 0,1m e posteriormente essa mesma distância foi utilizada para obter os índices de vegetação.

Foram obtidos os índices de vegetação de 30 unidades amostrais de grama Zoysia Japônica com o sistema sensor e com o espectroradiômetro. Essas unidades eram retangulares com dimensões 0,30 m x 0,15m. As unidades amostrais e a ordem das leituras foram selecionadas ao acaso, utilizando as mesmas condições da calibração.

A correlação entre os índices de vegetação obtidos com o sistema sensor e o espectroradiômetro foram analisados a partir do teste de significância do coeficiente de correlação de Pearson para cada índice de vegetação obtido.

RESULTADOS E DISCUSSÃO

Calibração do sistema sensor de índices de vegetação

A regressão linear dos dados obtidos com o sistema sensor e o espectroradiômetro apresentou R^2 superiores a 0,98 para o vermelho 0,99 para o infravermelho (Figura 4). Estes resultados são comparáveis aos de Ryu et al. (2010) que encontraram R^2 superiores 0,94 na construção de um sistema sensor espectral com LEDs, e Garrity et al. (2010) que encontraram R^2 superiores a 0,98 na construção de um sistema sensor espectral com Fotodiodo.

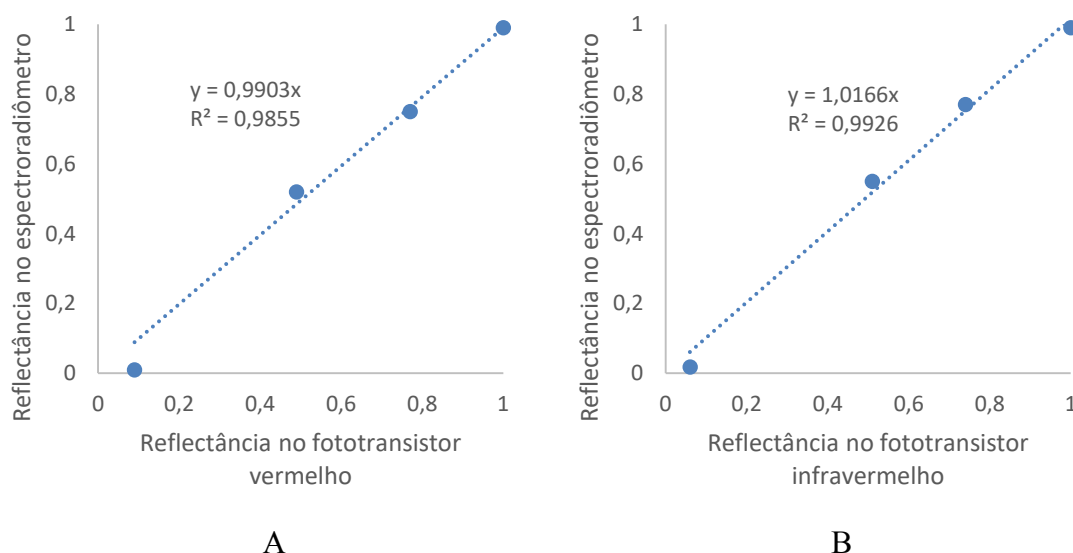
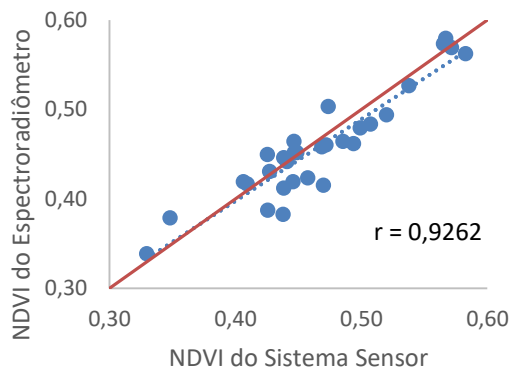


FIGURA 4. Correlação entre as reflectâncias dos fototransistores do sistema sensor e o espectroradiômetro. A – Fototransistor vermelho. B – Fototransistor infravermelho.

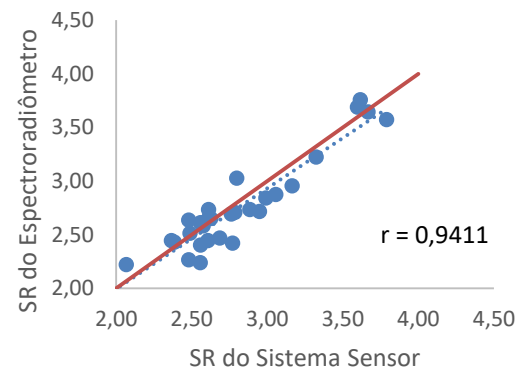
Através do teste F de Graybill, a 5% de significância, concluiu-se que as reflectâncias do vermelho e infravermelho obtidas pelo sistema sensor e pelo espectroradiômetro são estatisticamente iguais. Não sendo necessário inserir as equações dos modelos de regressão no algoritmo do sistema sensor para calibrar os resultados dele em relação aos valores do espectroradiômetro.

Análise de desempenho dos índices de vegetação obtidos com o sistema sensor

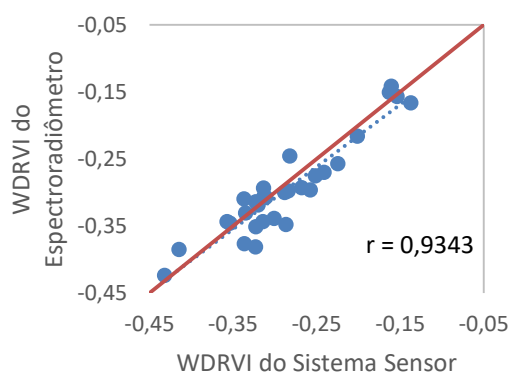
Os índices de vegetação obtidos com o espectroradiômetro e os obtidos com o sistema sensor apresentaram alta correlação (Figura 5), sendo a correlação de Pearson superior a 0,92 para todos os índices de vegetação. O teste de significância do coeficiente de correlação de Pearson (r) indicou que o valor de r obtido para a amostra é significativo e que existe correlação entre os índices obtidos com o sistema sensor e os obtidos com o espectroradiômetro para todos os índices de vegetação com nível de significância igual a 0,01.



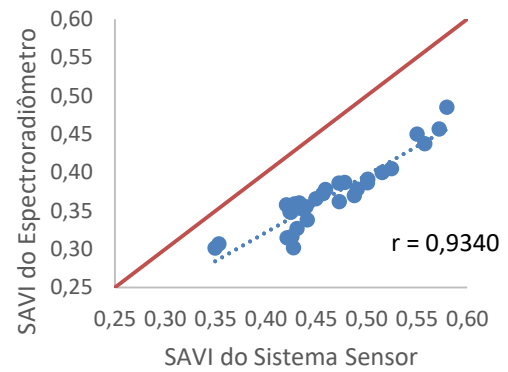
A




B



C



D



E

FIGURA 5. Índices de vegetação obtidos com o espectrorradiômetro contra os obtidos com o sistema sensor, (-) reta $x=y$. (r) coeficiente de correlação de Pearson. A – NDVI (Índice de Vegetação da Diferença Normalizada). B – SR (Razão Simples). C – WDRVI (Índice de Vegetação de Larga Escala Dinâmica). D – SAVI (Índice de Vegetação Ajustado ao Solo). E – OSAVI (Índice de Vegetação Ajustado ao Solo Otimizado).

Apesar do sistema sensor ter sido considerado estatisticamente igual ao espectrorradiômetro nota-se que os índices de vegetação não apresentam valores idênticos. Os índices NDVI, WDRVI e SR foram os que o sistema sensor se aproximou mais dos valores obtidos pelo espectrorradiômetro. A maior discrepância entre os dados do sistema sensor e do espectrorradiômetro nos índices de vegetação ajustados ao solo (SAVI e OSAVI) ocorreu porque o SAVI, e conseqüentemente o OSAVI, deslocam a origem dos espectros V e IV, através do fator L (Huete, 1988). Com isso, aumenta a inclinação da reta formada pela razão de IV por V, aumentando a diferença entre as médias dos dados do sistema sensor e do espectrorradiômetro, fazendo com que o SAVI e o OSAVI possuam as maiores diferenças percentuais das médias.

O SR apresentou o maior intervalo entre as medidas dos índices de vegetação obtidos. Esse resultado era esperado uma vez que o SR é o único índice, dentre os obtidos, que não é normalizado. Por isso ele não apresenta problemas de saturação sendo sensível para altos valores de cobertura vegetal, porém quando V é próximo de IV ele não é indicado.

O WDRVI apresentou intervalo entre as medidas maior que o NDVI, demonstrando que ele é mais sensível que o NDVI para os valores de V e IV obtidos com os aparelhos. Isso ocorre porque o procedimento de normalização utilizado no NDVI torna-o insensível à variação em IV quando ele é muito maior que V, pois ocorre a aproximação do numerador ao denominador, então a sensibilidade do índice ao aumento de IV se torna insignificante (Gitelson, 2004).

CONCLUSÕES

O sistema sensor foi mais eficiente na obtenção dos índices de vegetação NDVI, WDRVI e SR pois estes se aproximaram mais dos valores obtidos pelo espectrorradiômetro. Apesar dos índices SAVI e OSAVI obtidos pelo sistema sensor estarem deslocados dos obtidos pelo espectrorradiômetro eles também apresentaram alta correlação.

Nas condições analisadas, o sistema sensor proposto pode ser utilizado na determinação de todos os índices de vegetação abordados. Uma vez que seus índices apresentaram alta e significativa correlação com os índices do espectrorradiômetro.

AGRADECIMENTOS

Os autores agradecem ao CNPq, Capes e Fapemig pelo apoio financeiro.

REFERÊNCIAS BIBLIOGRÁFICAS DO CAPÍTULO 2

AHMED, Oumer S. et al. Hierarchical land cover and vegetation classification using multispectral data acquired from an unmanned aerial vehicle. **International journal of remote sensing**, v. 38, n. 8-10, p. 2037-2052, 2017.

ALI, A. M. et al. A framework for refining nitrogen management in dry direct-seeded rice using GreenSeeker™ optical sensor. **Computers and Electronics in Agriculture**, v. 110, p. 114-120, 2015.

BeagleBoard (2019) Beaglebone Black. In: What is Beaglebone Black? Available: <https://beagleboard.org/black>. Accessed Mar 13, 2019.

BENDIG, Juliane et al. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79-87, 2015.

CANDIAGO, Sebastian et al. Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. **Remote Sensing**, v. 7, n. 4, p. 4026-4047, 2015.

CROFT, H.; CHEN, J. M.; ZHANG, Y. The applicability of empirical vegetation indices for determining leaf chlorophyll content over different leaf and canopy structures. **Ecological Complexity**, v. 17, p. 119-130, 2014.

FAN, Xingwang; LIU, Yuanbo. A global study of NDVI difference among moderate-resolution satellite sensors. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 121, p. 177-191, 2016.

GAGO, Jorge et al. UAVs challenge to assess water stress for sustainable agriculture. **Agricultural water management**, v. 153, p. 9-19, 2015.

GAMON, J. A. et al. Monitoring seasonal and diurnal changes in photosynthetic pigments with automated PRI and NDVI sensors. **Biogeosciences**, v. 12, n. 13, p. 4149-4159, 2015.

GARRITY, Steven R.; VIERLING, Lee A.; BICKFORD, Keith. A simple filtered photodiode instrument for continuous measurement of narrowband NDVI and PRI over vegetated canopies. **Agricultural and Forest Meteorology**, v. 150, n. 3, p. 489-496, 2010.

GHAZAL, Mohammed; AL KHALIL, Yasmina; HAJJDIAB, Hassan. UAV-based remote sensing for vegetation cover estimation using NDVI imagery and level sets method. In: **Signal Processing and Information Technology (ISSPIT), 2015 IEEE**

International Symposium on. IEEE, 2015. p. 332-337.

GITELSON, Anatoly A. Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. **Journal of plant physiology**, v. 161, n. 2, p. 165-173, 2004.

HISHE, Solomon; LYIMO, James; BEWKET, Woldeamlak. Effects of soil and water conservation on vegetation cover: a remote sensing based study in the Middle Suluh River Basin, northern Ethiopia. **Environmental Systems Research**, v. 6, n. 1, p. 26, 2017.

HUETE, Alfredo R. A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, v. 25, n. 3, p. 295-309, 1988.

JIMENEZ-BERNI, Jose A. et al. High throughput determination of plant height, ground cover, and above-ground biomass in wheat with LiDAR. **Frontiers in plant science**, v. 9, p. 237, 2018.

JORDAN, Carl F. Derivation of leaf-area index from quality of light on the forest floor. **Ecology**, v. 50, n. 4, p. 663-666, 1969.

KARLSEN, Stein Rune et al. Spatial and temporal variability in the onset of the growing season on Svalbard, Arctic Norway—measured by MODIS-NDVI satellite data. **Remote Sensing**, v. 6, n. 9, p. 8088-8106, 2014.

KE, Yinghai et al. Characteristics of Landsat 8 OLI-derived NDVI by comparison with multiple satellite sensors and in-situ observations. **Remote Sensing of Environment**, v. 164, p. 298-313, 2015.

LU, Linlin et al. Evaluation of three MODIS-derived vegetation index time series for dryland vegetation dynamics monitoring. **Remote Sensing**, v. 7, n. 6, p. 7597-7614, 2015.

MATESE, Alessandro et al. Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. **Remote Sensing**, v. 7, n. 3, p. 2971-2990, 2015.

PRABHAKARA, Kusuma; HIVELY, W. Dean; MCCARTY, Gregory W. Evaluating the relationship between biomass, percent groundcover and remote sensing indices across six winter cover crop fields in Maryland, United States. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 88-102, 2015.

RAMIREZ, Marisol B. et al. Ground-based NDVI sensing: Separating the ground surface from the cotton canopy. **Transactions of the ASABE**, v. 58, n. 3, p. 597-605, 2015.

RASMUSSEN, Jesper et al. Are vegetation indices derived from consumer-grade cameras mounted on UAVs sufficiently reliable for assessing experimental plots?. **European Journal of Agronomy**, v. 74, p. 75-92, 2016.

RONDEAUX, Geneviève; STEVEN, Michael; BARET, Frédéric. Optimization of soil-adjusted vegetation indices. **Remote sensing of environment**, v. 55, n. 2, p. 95-107, 1996.

ROUSE JR, J_W et al. Monitoring vegetation systems in the Great Plains with ERTS. **Third ERTS Symposium**, NASA, v. 351, p. 309-317, 1973.

RYU, Youngryel et al. Testing the performance of a novel spectral reflectance sensor, built with light emitting diodes (LEDs), to monitor ecosystem metabolism, structure and function. **Agricultural and Forest Meteorology**, v. 150, n. 12, p. 1597-1606, 2010.

SANTOS GALVANIN, Edinéia Aparecida et al. Avaliação dos Índices de Vegetação NDVI, SR e TVI na discriminação de fitofisionomias dos ambientes do Pantanal de Cáceres/MT. **Ciência Florestal**, v. 24, n. 3, 2014.

SHAO, Yang et al. An evaluation of time-series smoothing algorithms for land-cover classifications using MODIS-NDVI multi-temporal data. **Remote Sensing of Environment**, v. 174, p. 258-265, 2016.

SMITH, Anne M.; HILL, Michael J.; ZHANG, Yongqin. Estimating ground cover in

the mixed prairie grassland of southern Alberta using vegetation indices related to physiological function. **Canadian Journal of Remote Sensing**, v. 41, n. 1, p. 51-66, 2015.

WANG, Zhenyu et al. Assessment of Spatio-Temporal Vegetation Productivity Pattern Based on MODIS-NDVI and Geo-Correlation Analysis. In: **Geo-Informatics in Resource Management and Sustainable Ecosystem**. Springer, Berlin, Heidelberg, p. 673-681, 2015.

WHITE, Davina C. et al. A generalizable NDVI-based wetland delineation indicator for remote monitoring of groundwater flows in the Australian Great Artesian Basin. **Ecological indicators**, v. 60, p. 1309-1320, 2016.

XUE, Jinru; SU, Baofeng. Significant remote sensing vegetation indices: a review of developments and applications. **Journal of Sensors**, v. 2017, 2017.

ZHANG, H. K.; ROY, David P. Landsat 5 Thematic Mapper reflectance and NDVI 27-year time series inconsistencies due to satellite orbit change. **Remote Sensing of Environment**, v. 186, p. 217-233, 2016.

ZHENG, Hengbiao et al. Evaluation of a uav-based hyperspectral frame camera for monitoring the leaf nitrogen concentration in rice. In: **Geoscience and Remote Sensing Symposium (IGARSS), 2016 IEEE International**. IEEE, p. 7350-7353, 2016.

CONCLUSÃO GERAL

O sistema sensor desenvolvido informa ao usuário os valores de vários índices de vegetação e esses dados estão georreferenciados o que auxilia muito na análise dos dados e tomada de decisão.

Ele pode ser acoplado no trator e realizar as medidas georreferenciadas dos índices de vegetação enquanto o trator realiza alguma outra função no campo, o que economiza tempo e combustível. Para isso, o sistema sensor pode ser energizado por uma bateria externa de celular o que facilita sua utilização em áreas remotas do campo.

Os dados são facilmente transferidos através de um pen drive ou conectando a Beaglebone Black no computador ou cabo ethernet.

A Beaglebone Black permite que sejam acoplados outros sensores e funções no sistema sensor proposto como, por exemplo, uma mesma Beaglebone Black pode controlar várias unidades do sistema sensor proposto ao longo de um pivô central, o que diminui ainda mais os custos de aquisição deste.

Como trabalhos futuros almeja-se realizar experimentos em campo e utilizar vários sensores acoplados a uma Beaglebone Black.

APÊNDICES

APÊNDICE DO CAPÍTULO 1



FIGURA 1. Local utilizado para os experimentos. As linhas brancas foram as retas utilizadas para os experimentos cinemáticos. Já dentro do quadrado branco foram demarcados os pontos para o experimento estático




FIGURA 2. GNSS conectado a BBB

APÊNDICE DO CAPÍTULO 2



FIGURA 1. Vista lateral do sistema sensor desenvolvido



FIGURA 2. Vista inferior do sistema sensor desenvolvido





FIGURA 3. Circuito analógico do sistema sensor