Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”

Fusão de sensores para obtenção de dados de produtividade em colhedora de
cana-de-açúcar

Jeovano de Jesus Alves de Lima

Tese apresentada para obtenção do título de Doutor em
Ciências. Área de concentração: Engenharia de Sistemas
Agrícolas

Piracicaba
2019

Jeovano de Jesus Alves de Lima
Engenheiro de Controle e Automação

Fusão de sensores para obtenção de dados de produtividade em colhedora de
cana-de-açúcar
versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:
Prof. Dr. **JOSÉ PAULO MOLIN**

Tese apresentada para obtenção do título de Doutor em
Ciências. Área de concentração: Engenharia de Sistemas
Agrícolas

Piracicaba
2019

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP

Lima, Jeovano de Jesus Alves de

Fusão de sensores para obtenção de dados de produtividade em colhedora de cana-de-açúcar / Jeovano de Jesus Alves de Lima. - - versão revisada de acordo com a resolução CoPGr 6018 de 2011. - - Piracicaba, 2019

105 p.

Tese (Doutorado) - - USP / Escola Superior de Agricultura "Luiz de Queiroz".

1.Agricultura de precisão 2. Redes neurais. 3. Fusão de sensores I.
Título

*À minha querida esposa Mônica por sua inestimável
paciência, compreensão e companheirismo*

Aos meus Filhos Samuel e Davi pela motivação

Dedico

AGRADECIMENTOS

Meus sinceros agradecimentos,

A Deus, em primeiro lugar.

À empresa AGCO do Brasil, pela disponibilidade de recursos para execução dos experimentos, das horas de trabalho e pela oportunidade de fazer parte desta empresa. Pelos colegas do laboratório de validação, principalmente o gestor Demetrius Figueiró pela confiança neste trabalho.

À Universidade de São Paulo e à Escola Superior de Agricultura “Luiz de Queiroz”, pela educação técnica, social e científica.

Ao Professor Dr. José Paulo Molin pela compreensão, orientação e incentivo dados a mim para a conclusão deste trabalho.

Aos meus amigos e colegas de pós-graduação, André F. Colaço, Leonardo Maldaner, Luis G. Mendes, Marcos F. Ferraz, Mark Spekken, Mateus T. Eitelwein, Marcelo Chan, Mauricio Martello, Rodrigo G. Trevisan, Tatiana F. Canata e Tiago R. Tavares.

E a todos que de alguma forma colaboraram para que eu chegasse até aqui, em especial a minha querida esposa Mônica por ter me apoiado mesmo nos momentos mais difíceis e aos nossos filhos Samuel e Davi.

SUMÁRIO

RESUMO	6
ABSTRACT	7
LISTA DE FIGURAS	8
LISTA DE TABELAS.....	11
LISTA DE ABREVIATURAS E SIGLAS	12
LISTA DE SÍMBOLOS	13
1. INTRODUÇÃO.....	15
2. REVISÃO BIBLIOGRÁFICA.....	17
2.1 CANA-DE-AÇÚCAR.....	17
2.2 AGRICULTURA DE PRECISÃO	20
2.3 FUSÃO DOS SENSORES	26
2.4 INTELIGÊNCIA ARTIFICIAL	33
2.5 REDES NEURAIS ARTIFICIAIS	34
3. MATERIAL E MÉTODOS	42
3.1 CONSIDERAÇÕES INICIAIS	42
3.2 ETAPA 1 – QUALIFICAÇÃO DOS SENSORES	43
3.3 ETAPA 2 – CORRELAÇÃO DOS SENSORES	48
3.4 PROCESSAMENTO DE DADOS.....	55
3.5 ETAPA 3 - VALIDAÇÃO DO CONCEITO	62
4. RESULTADOS E DISCUSSÕES	65
4.1 RESULTADOS DA ETAPA 1	65
4.2 RESULTADOS DA ETAPA 2	70
4.3 PREDIÇÃO DA PRODUTIVIDADE DA CANA-DE-AÇÚCAR UTILIZANDO RLM	76
4.4 TREINAMENTO, TESTE E VALIDAÇÃO DA RNA PARA PREDIÇÃO DA PRODUTIVIDADE DA CANA-DE-AÇÚCAR	79
4.5 IDENTIFICAÇÃO DE FALHAS NA LAVOURA DE CANA-DE-AÇÚCAR	81
4.6 MAPAS DE PRODUTIVIDADE – COMPARATIVO DOS MODELOS DE PREDIÇÃO	83
4.7 RESULTADOS DA ETAPA 3	85
5. CONCLUSÃO	91
REFERÊNCIAS	93
APÊNDICES	102

RESUMO

Fusão de sensores para obtenção de dados de produtividade em colhedora de cana-de-açúcar

A cana-de-açúcar é uma importante cultura semi-perene em regiões tropicais do mundo como a principal fonte de açúcar e bioenergia e o Brasil é seu maior produtor. Como qualquer outra cultura, demanda um aperfeiçoamento prática constante, buscando uma cultura sustentável e com maiores rendimentos e menores custos. Uma das alternativas é a utilização de práticas de agricultura de precisão para explorar a variabilidade espacial dos rendimentos potenciais e para tanto, os mapas de produtividade são essenciais. Para obter os dados necessários para gerar um mapa confiável, é necessário um sistema com capacidade de ler e georreferenciar os dados do sensor e compará-los a uma calibração. No entanto, os resultados das pesquisas mais recentes associadas aos monitores de rendimento comercial, que utilizam apenas um tipo de sensor para determinar os mapas de produtividade, não retratam a exatidão exigida para a cana-de-açúcar. Este estudo teve como objetivo explorar o potencial do uso de dados provenientes de sensores instalados em diferentes partes da colhedora de cana-de-açúcar para determinação e aplicação em monitores de produtividade e determinação de falhas na lavoura. Para fins de comparação foi utilizado um transbordo instrumentado com células de carga para aferição da massa colhida. Foram utilizadas abordagens estatísticas convencionais e inteligência artificial para fusão dos dados e predição da produtividade da cana-de-açúcar, os métodos convencionais foram regressão linear simples e múltipla, e comparado com o método de redes neurais. Além da produtividade foi possível constatar que é possível identificar as falhas na lavoura através dos dados coletados e das falhas produzidas manualmente, todos os sensores medidos identificaram as falhas georeferenciadas. Com relação aos modelos implementados e utilizados, os baseados em regressão linear múltipla não apresentaram potencial na integração e predição da produtividade com os valores de erros definidos nas premissas do trabalho que é de menor que 2%. Além disso os mapas gerados com esses modelos tiveram algumas discrepâncias quanto ao aumento da produtividade em algumas áreas e extração das falhas existentes. Já o modelo de fusão utilizando redes neurais artificiais apresentou uma excelente alternativa para predição da produtividade. Uma vez que a rede é treinada, a mesma apresentou erros inferiores a 2% em todos os mapas gerados. De maneira geral todos os sensores quando avaliados individualmente apresentaram vantagens e desvantagens na determinação da produtividade. Porém, quando fundido os dados dos diversos sensores, as respostas encontradas apresentaram coeficiente de determinação R^2 superiores a 95%, RMSE menor que 1kg e RE menor que 2%.

Palavras-chave: Agricultura de precisão; Redes neurais; Fusão de sensores

ABSTRACT

Fusion of sensors to obtain a yield data for sugarcane harvesters

Sugarcane is an important semi-perennial crop in tropical regions of the world as the main source of sugar and bioenergy, and Brazil is its largest producer. Like any other culture, it demands constant improvement in practice, seeking a sustainable culture with higher yields and lower costs. One of the alternatives is the use of precision farming practices to explore the spatial variability of potential yields and for that, productivity maps are essential. To obtain the data needed to generate a reliable map, a system is required that is capable of reading and georeferencing the sensor data and comparing them to a calibration. However, the results of the most recent surveys associated with commercial yield monitors, which use only one type of sensor to determine productivity maps, do not depict the exactitude required for sugarcane. This study aimed to explore the potential of using data from sensors installed in different parts of the sugarcane harvester for determination and application in productivity monitors and determination of crop failure, for comparison purposes a transshipment was used instrumented with load cells to measure the mass harvested. We used conventional statistical approaches and artificial intelligence for data fusion and prediction of sugarcane productivity, conventional methods were simple and multiple linear regression, and compared with the neural network method. In addition to productivity, it was possible to verify that it is possible to identify crop failures through the data collected and the failures produced manually, all the measured sensors identified georeferenced faults. Regarding the implemented and used models, those based on multiple linear regression did not present potential in the integration and prediction of productivity with the values of errors defined in the assumptions of the work that is less than 2%. In addition, the maps generated with these models had some discrepancies regarding productivity increase in some areas and extraction of existing flaws. On the other hand, the model of fusion using artificial neural networks presented an excellent alternative for prediction of productivity; since the network is trained the same one presented in all the generated maps errors inferior to 2%. In a general way all the sensors when evaluated individually presented advantages and disadvantages in determining the productivity, but when fused the data of the various sensors the answers found of coefficient of determination R^2 higher than 95%, RMSE less than 1kg and RE less than 2%.

Keywords: Precision agriculture; Artificial neural network; Fusion of sensors

LISTA DE FIGURAS

Figura 1. Processo de colheita de cana de açúcar	20
Figura 2. Exemplo de Mapa de produtividade (Molin, 2013)	23
Figura 3. Sistema de medição da pressão hidrostática (a); sistema de pesagem no elevador (b) (adaptado de Cox et al., 1998).....	24
Figura 4. Utilização de sensores ópticos (Price et al., 2007)	24
Figura 5. Sensor de deslocamento aplicado do sistema de rolos alimentadores.....	25
Figura 6. Diagrama de Blocos de fusão de sensores (a) e integração multisensores (b) adaptado de Elmenreich (2002)	26
Figura 7. Classificação baseada no modelo de Whyte (1988) adaptado de Castanedo (2013)	28
Figura 8. Classificação baseada no modelo de Dasarathy (1997) adaptado de Castanedo (2013).....	28
Figura 9. Classificação baseada no modelo de JDL (1991) adaptado de Castanedo (2013)	29
Figura 10. Arquitetura Centralizada adaptado de Castanedo (2013).....	31
Figura 11. Arquitetura Descentralizada adaptado de Castanedo (2013).....	31
Figura 12. Arquitetura Distribuída adaptado de Castanedo (2013)	32
Figura 13. Modelo Perceptron (Haykin, 2001).....	36
Figura 14. Função Sigmoide (Haykin, 2001)	36
Figura 15. Arquitetura Multicamadas Perceptron.....	37
Figura 16. Representação geométrica da obtenção do erro. Fonte: Silva et al. (2010)	39
Figura 17. Aprendizado supervisionado Silva et al. (2010).....	40
Figura 18. Etapas de desenvolvimento do trabalho	42
Figura 19. Pontos monitorados com a instalação de sensores.....	43
Figura 20. Sensor de deslocamento instalado no rolo transportador móvel	44
Figura 21. Seção para determinação do volume	44
Figura 22. Posição do acelerômetro e dos extensômetros instalados no elevador da máquina	45
Figura 23. Elementos finitos - definição dos pontos para monitoramento	46
Figura 24. Pontos de instrumentação com extensômetros	46
Figura 25. Calibração dos extensômetros	47
Figura 26. Funcionamento da FFT	47
Figura 27. Área da colheita em Luiz Antônio, SP	48
Figura 28. Pontos monitorados com a instalação de sensores.....	49
Figura 29. Fileiras de cana colhidas: sem falha (a); com falhas produzidas (b)	49
Figura 30. Produzindo falhas georeferenciadas	50
Figura 31. Funcionamento dos rolos picadores	51
Figura 32. Modelo simplificado dos carregamentos no elevador	51
Figura 33. Funcionamento do corte de base	52
Figura 34. Conceito do monitor de produtividade e da fusão dos sensores	58
Figura 35. Detalhe do algoritmo de fusão com RNA.....	59
Figura 36. Área da colheita em Luiz Antônio, SP	62

Figura 37. Curva de calibração carga nos cilindros do elevador (CCED e CCEE) e carga na base do elevador (CB).....	66
Figura 38. Período de um dos sinais coletados nas duas frequências mostrando a influência da taxa de amostragem, sinal temporal (a) e FFT (b).	66
Figura 39. Sinais dos extensômetros na base do elevador, acelerômetro e deslocamento dos rolos de alimentação.	67
Figura 40. Dados de deslocamento, pressão no picador e pressão no corte de base, respectivamente	68
Figura 41. Variação de massa em relação ao deslocamento	68
Figura 42. Defasagem de tempo do fluxo de massa entre os sensores do corte de base e picador.	69
Figura 43. Espacialização dos dados coletados: pressão do picador (a); pressão no acionamento do corte de base (b); deslocamento do rolo (c); e extensômetro base (d)	70
Figura 44. Efeitos que influenciam nos sensores ao longo do tempo e quando a máquina está parada ou em funcionamento	71
Figura 45. Efeito da velocidade da máquina que influencia no atraso entre os sinais dos sensores	71
Figura 46. Sinal temporal do fluxo de massa (kg s^{-1}) no transbordo	73
Figura 47. Sinal temporal da pressão no picador – dados da Fileira 2 (a); curva de calibração do sensor de pressão do picador – obtida com a média das 10 fileiras medidas (b)	73
Figura 48. Sinal temporal no separador dos rolos alimentadores 1 – dados da Fileira 2 (a); curva de calibração do separador dos rolos alimentadores 1 – obtida com a média das 09 fileiras medidas (b); sinal temporal no separador dos rolos alimentadores 2 – dados da Fileira 2 (c); curva de calibração do separador dos rolos alimentadores 2 – obtida com a média das 09 fileiras medidas (d)	74
Figura 49. Sinal temporal de cargas no cilindro do elevador – dados da Fileira 2 (a); curva de calibração das cargas do cilindro do elevador – obtida com a média das 09 fileiras medidas (b)	74
Figura 50. Sinal temporal da pressão no elevador – dados da Fileira 2 (a); curva de calibração da pressão no elevador – obtida com a média das 10 fileiras medidas (b)	75
Figura 51. Sinal temporal da balança no elevador – dados da Fileira 2 (a); curva de calibração da balança no elevador – obtida com a média das 10 fileiras medidas (b)	75
Figura 52. Representação gráfica dos valores do fluxo de massa no transbordo observados (medidos) em relação aos estimados por regressão linear múltipla nos modelos propostos para a primeira fileira.	79
Figura 53. Representação gráfica dos valores do fluxo de massa no transbordo observados (medidos) em relação aos estimados pela RNA nos modelos propostos para a primeira fileira.	81
Figura 54. Falhas georreferenciadas – Pontos amarelos	81
Figura 55. Sinais temporais da primeira fileira com falhas produzidas manualmente comparando os dados do transbordo (MT) com os sensores de pressão do picador (PP) e do elevador (PE) (a); sensores de deslocamento dos rolos (DR1 e DR2) (b); sensores de carga na base (CB) do elevador e nos cilindros (CE) (c)	82
Figura 56. Mapa dos pontos medidos e falhas	83
Figura 57. Mapa de falhas por sensor: dados do fluxo de massa do transbordo (a); dados da pressão no picador (b); dados da pressão no elevador (c); dados dos deslocamentos nos rolos de alimentação 1 (d); dados dos deslocamentos nos rolos de alimentação 2 (e); dados de carga na base do elevador (f); dados das cargas no cilindro do elevador (g)	83
Figura 58. Mapas de produtividade comparando os modelos de predição com dados obtidos do transbordo (a); produtividade calculada pelo modelo de regressão linear múltipla RLM-1 (b); produtividade calculada pelo modelo de regressão linear simples RLM-8 (c); produtividade calculada pelo modelo de regressão linear simples RLM-9(d) e a produtividade calculada utilizando o modelo RNA-1 (e)	84
Figura 59. Erro relativo (RE) entre os modelos de predição e a produtividade do transbordo, sendo mapa do modelo RNA-1 (a); mapa do modelo RLM-1 (b); mapa do modelo RLM-8 (c) e mapa do modelo RLM-9 (d) ..	85

Figura 60. Mapas de produtividade dos três talhões colhidos na etapa 3, sendo talhão 1 – T1a (a), talhão 1 – T1b (b), talhão 2 – T2a (c), talhão 2 – T2b (d) e talhão 3 (e).....85

Figura 61. Produtividade do talhão T1a (a, b e c), sendo os dados obtidos do transbordo (a); produtividade calculada pelo modelo de regressão linear múltipla RLM-1 (b); produtividade calculada utilizando o modelo RNA-1 (c); Produtividade do talhão T1b (d, e e f); sendo os dados obtidos do transbordo (d pelo modelo de regressão linear múltipla RLM-1 (e) e a produtividade calculada utilizando o modelo RNA-1 (f).....87

Figura 62. Produtividade do talhão T2a (a, b e c), sendo os dados obtidos do transbordo (a); produtividade calculada pelo modelo de regressão linear múltipla RLM-1 (b); produtividade calculada utilizando o modelo RNA-1 (c); Produtividade do talhão T2b (d, e e f); sendo os dados obtidos do transbordo (d pelo modelo de regressão linear múltipla RLM-1 (e) e a produtividade calculada utilizando o modelo RNA-1 (f).....88

Figura 63. Produtividade do talhão T3, sendo os dados obtidos do transbordo (a); produtividade calculada pelo modelo de regressão linear múltipla RLM-1 (b); produtividade calculada utilizando o modelo RNA-1 (c).....88

Figura 64. Mapas de produtividade dos modelos de predição com dados obtidos pelo modelo de regressão linear múltipla RLM-2 (a); produtividade calculada pelo modelo de regressão linear múltipla RLM-3 (b); produtividade calculada pelo modelo de regressão linear simples RLM-4 (c); produtividade calculada pelo modelo de regressão linear simples RLM-5(d), a produtividade calculada pelo modelo de regressão linear simples RLM-6(e) e a produtividade calculada pelo modelo de regressão linear simples RLM-7(f)..... 103

Figura 65. Mapas de produtividade dos modelos de predição com dados obtidos pelo modelo de redes neurais RNA-2 (a); produtividade calculada pelo modelo de redes neurais RNA-3 (b); produtividade calculada pelo modelo de redes neurais RNA-4 (c); produtividade calculada pelo modelo de redes neurais RNA-5 (d), a produtividade calculada pelo modelo de redes neurais RNA-6(e)), a produtividade calculada pelo modelo de redes neurais RNA-7(f) e), a produtividade calculada pelo modelo de redes neurais RNA-8 (g) e a produtividade calculada pelo modelo de redes neurais RNA-9 (h)..... 104

Figura 66. Mapa dos dados do sensor PP (a); mapa dos dados do sensor PE (b); mapa dos dados do sensor DR1 (c); mapa dos dados do sensor DR2 (d), mapa dos dados do sensor CB (e) e o mapa dos dados do sensor CC (d) 105

LISTA DE TABELAS

Tabela 1. Sistemas avaliados para medição de produtividade em colhedoras de cana.	25
Tabela 2. Lista de sensores e abreviaturas	55
Tabela 3. Variáveis independentes de entrada nos modelos computacionais de estimativa de produtividade de cana-de-açúcar.	56
Tabela 4. Nomenclatura dos modelos de predição de produtividade	56
Tabela 5. Número de amostras utilizadas para predição da produtividade.....	57
Tabela 6. Dados da calibração dos sensores do elevador	65
Tabela 7. Distâncias entre os sensores.....	71
Tabela 8. Atraso entre os sensores.....	71
Tabela 9. Dados obtidos nas medições de 10 fileiras de cana-de-açúcar	72
Tabela 10. Resultados dos valores de r (correlação cruzada)	72
Tabela 11. Dados das Regressões Lineares para cada sensor monitorado.....	75
Tabela 12. Correlação cruzada (r) entre as variáveis independentes e dependentes.....	76
Tabela 13. Coeficiente de correlação r para os modelos de RLM	77
Tabela 14. Coeficientes das equações de regressão linear múltipla e de determinação para estimativa do fluxo de massa observada no transbordo	78
Tabela 15. Coeficientes r, determinação R^2 , erro quadráticos médios (RMSE) e erro relativo (RE) das RNA	80
Tabela 16. Estatística descritiva dos dados de produtividade para os três talhões	86
Tabela 17. Erros entre os modelos comparando com a produtividade a partir do transbordo	86

LISTA DE ABREVIATURAS E SIGLAS

AGCO	Allis e Gleaner Corporation
AP	Agricultura de Precisão
CAN	Controller Area Network
CG	Centro de Gravidade
CONAB	Companhia Nacional de Abastecimento
DoD	Departamento de Defesa Americano
EUA	Estados Unidos da América
FAO	Organização das Nações Unidas para a Alimentação e a Agricultura
FFT	Fast Fourier Transform
GNSS	Global Navigation Satellite System
GPS	Global Positioning System
IA	Inteligência Artificial
IHC	Interface Homem-Computador
JDL	U.S. Joint Directors of Laboratories
MAPA	Ministério da Agricultura, Pecuária e Abastecimento
MLP	MultiLayer Perceptron
NARX	Nonlinear autoregressive with external input
RE	Erro Relativo
RLM	Regressão Linear Múltipla
RLS	Regressão Linear Simples
RMSE	Root-Mean-Square Error
RNA	Rede Neural Artificial
RPM	rotações por minuto
SIG	Sistema de Informação Geográfica
UNICA	União da Indústria de Cana-de-Açúcar

LISTA DE SÍMBOLOS

kg	quilogramas
mm	milímetro
mV/s	milivolts por segundo
mV/g	milivolts por gravidade
Ω	Resistência Elétrica ohm

1. INTRODUÇÃO

O Brasil é o maior produtor de cana-de-açúcar do mundo, com 635,6 milhões de toneladas produzidas na safra 2017/2018 (CONAB, 2018). Essa produção foi obtida em uma área de 8.738,6 mil ha, com produtividade média de 72.734 kg ha⁻¹, sendo que no estado de São Paulo, maior produtor de cana do país, 95,9% da colheita foi mecanizada (CONAB, 2018).

A cadeia produtiva da cana-de-açúcar se destaca no agronegócio brasileiro e sua relevância aumenta na medida em que a demanda por energia renovável se amplia no mundo. Com isso as áreas cultivadas com cana aumentaram rapidamente e a produção dobrou nos últimos dez anos (UNICA, 2018), fortemente influenciada pela produção de etanol devido à introdução dos motores do tipo flex para carros no mercado local. Atualmente a produção de cana-de-açúcar é a segunda fonte de energia local (etanol e eletricidade de biomassa), o que corresponde a 17,5 % do consumo energético total (BEN, 2017). Essas informações apresentam um panorama de que há um potencial do aumento na produção de cana e esse só deve acontecer com a intervenção de novas tecnologias em toda a cadeia produtiva da cana, como por exemplo, a adoção e aplicação de técnicas e tecnologias associadas ao conceito de agricultura de precisão (AP) (Molin et al., 2010).

Para adoção da AP, uma das abordagens envolve o gerenciamento integrado de entradas e saídas, ou seja, envolve o conceito do gerenciamento localizado da reposição de insumos com base na sua extração e exportação, medindo a produtividade de cada porção dos talhões espacializadas na forma de mapa (Molin, 2008).

A geração de dados relacionados à quantidade de massa colhida pode ter duas destinações de grande importância. A primeira é destinada ao gestor da produção agrícola e tem como objetivo muni-lo de informação relacionada à variabilidade espacial presente nas lavouras. A outra é dirigida à própria máquina, que pode utilizar essa informação para auto calibração de seus parâmetros visando a sua otimização.

Propostas que envolvem técnicas de AP são de grande importância nesse setor, pois a cultura da cana-de-açúcar oferece condições ideais para a implantação de tais práticas (Camelini, 2013) visto que a variabilidade espacial é grande, justificando os investimentos nos equipamentos necessários para implementação de AP. Para grande parte das usinas analisadas por Camelini, o aumento de produtividade na ordem de 5% no primeiro ano justificaria todo o investimento necessário para aderir a esta nova forma de produzir.

Uma das mais importantes informações para a AP é o mapa de produtividade, que é obtido por meio de um monitor de produtividade instalado na colhedora. No caso da cana-de-açúcar, apenas um pequeno número de desenvolvimentos é relatado visando tornar os sistemas disponíveis para detectar continuamente o fluxo de massa e a produtividade. Cox et al. (1998) desenvolveram e avaliaram um sistema de medição da pressão hidráulica dos acionamentos do picador e do elevador da colhedora para determinar o fluxo de material. Outro princípio utilizado em alguns sistemas foi o da pesagem no elevador da colhedora (Benjamin et al., 2001; Molin e Menegatti, 2004; Cerri Magalhães, 2005; Mailander et al., 2010), porém o sistema de pesagem apresenta problemas como a compensação de inclinação, a vibração e a mudança de tara causada por material mineral, sedimento e detritos. Price et al. (2007) descreveram o desenvolvimento de um monitor de produtividade utilizando sensores ópticos para a colheita da cana-de-açúcar. Outra abordagem foi a instalação de instrumentação para monitorar a abertura dos rolos de alimentação do picador feita pelo Hernandez et al. (2003, 2005) e Fernandez et al. (2007). Os erros de medição obtidos nos testes reportados ainda são cerca de 100% superiores aos obtidos nos monitores instalados nas colhedoras de grãos e nas colhedoras de forragens. Além disso, existem relatos apenas de testes resumidos, normalmente com uma calibração

ajustada para uma carga completa do transbordo. Não há relatos de medição contínua, de modo que o comportamento real dos sensores possa ser avaliado.

É prática usual em muitas áreas de produção a obtenção de dados relacionados à variabilidade espacial das lavouras a partir de amostras georreferenciadas de solo para então fazer a gestão dessa variabilidade a partir de aplicação de insumos de forma variável e localizada. A abordagem que parte dos mapas de produtividade, exige mais equipamentos, mais trabalho e maior domínio por parte do usuário ou de seu consultor. É uma estratégia que demanda tempo para a construção de um consistente conjunto de dados, mas a solução é proporcionalmente mais acertada por considerar também a variabilidade da produtividade da lavoura e não apenas aquela do conteúdo de nutrientes no solo. A maior quantidade de dados implica em informação mais consistente e o consequente diagnóstico referente à variabilidade tenderá a ser mais acertado. Dessa forma, dados de produtividade expressos por mapas são fundamentais e a interpretação da variabilidade presente nas lavouras é evidenciada nos mapas de produtividade.

Uma alternativa para que se tenha mapas de produtividade confiáveis na cultura de cana-de-açúcar, é a utilização de técnicas de fusão de sensores ao longo de uma colhedora, com a finalidade de se obter a partir desses sensores uma única saída para o monitor de produtividade, buscando assim melhorar a acurácia e a precisão dos resultados. Além da produtividade outras características da lavoura e da qualidade do produto que está sendo colhido podem ser identificadas, e com isso gerenciar a máquina buscando otimização da mesma como por exemplo o consumo de combustível.

A compreensão de fusão pode referir-se à combinação de dois ou mais dados diferentes, sendo a fusão de sensores a combinação de dados sensoriais ou dados advindos de sensores de diferentes fontes, de forma que a informação resultante é, em algum sentido, melhor do que se os dados dessas fontes fossem usados individualmente (Hall e Llinaz, 1997), por isso neste trabalho esta técnica foi utilizada. Para correlacionar sensores ao longo da colhedora de cana-de-açúcar e com isso obter o valor de produtividade, bem como realizar a auto calibração destes sensores e ao mesmo tempo identificar a presença e extensão de falhas na lavoura.

2. REVISÃO BIBLIOGRÁFICA

2.1 CANA-DE-AÇÚCAR

2.1.1 Planta

Os primeiros registros de utilização da cana-de-açúcar (*Saccharum* spp.) se dão na Ásia e a introdução no Brasil se deu no período colonial (SCHNEIDER et al., 2013). Hoje mais de 90 países nas regiões tropicais e subtropicais cultivam a cana-de-açúcar. No Brasil, vem sendo cultivada desde o ano de 1532 (NASTARI, 1983), sendo que segundo NASTARI (1983), durante o período colonial (1500 a 1822) a riqueza gerada pelo comércio de açúcar foi o dobro do valor de todo o ouro e diamantes extraídos no país durante o mesmo período.

No cenário atual a cana-de-açúcar vem sendo uma ótima opção para a geração de energia renovável, com ampla importância no cenário agrícola global. A cultura é robusta e eficiente na produção de biomassa, açúcar e também etanol (DINARDO-MIRANDA et al., 2010).

Atualmente, a cana-de-açúcar é cultivada em cerca de 26,1 milhões ha (FAO, 2011) e as condições de solo e clima para o seu desenvolvimento proporcionaram condições para que o Brasil alcançasse a posição de maior produtor, com 8,74 milhões de hectares (CONAB, 2018). A estimativa da CONAB (2018) para a safra 2017/18 é de 635,6 milhões de toneladas, queda de 3,4% em relação à safra anterior. A cana-de-açúcar é a segunda maior fonte de energia do país. Adicionalmente, representa um papel ambiental muito importante pois o etanol, subproduto da cana-de-açúcar, é uma alternativa para reduzir a emissão de gases causadores do efeito estufa (MAPA, 2015).

A cana-de-açúcar, uma cultura perene e cultivada como semi-perene, é pertencente à família Poaceae e ao gênero *Saccharum*, que abrange várias espécies. Porém, segundo Branbilla (2013), as variedades híbridas são, na sua maioria, cultivadas atualmente. A parte aérea da cana-de-açúcar é formada por colmos, folhas e inflorescência, enquanto a parte subterrânea é composta por raízes (BARROS, 2008). Segundo Krutman (1966) a cultura apresenta quatro estágios de desenvolvimento: do plantio à brotação das gemas, da brotação das gemas ao final do perfilhamento, do final do perfilhamento ao início da acumulação de açúcar e da acumulação de açúcar até a maturação.

O plantio pode ser feito de forma manual, semi-mecanizado ou mecanizado, e é uma operação determinante para o sucesso ou fracasso do investimento, pois tem reflexos nas operações subsequentes da produção, definindo a produtividade dos canaviais (MISSIO, 2016). A brotação das gemas é um dos processos que requer maior atenção, pois dela dependerá a futura população de plantas no campo (PLANA et al., 1987). Após a emergência dos colmos deve haver condições favoráveis a um máximo perfilhamento e formação de touceiras vigorosas que irão fornecer quantidade maior de colmos por área, possivelmente permitindo maior número de cortes econômicos (ROCHA, 1984). A boa capacidade de brotação é uma característica desejável nas variedades de cana-de-açúcar (CASAGRANDE, 1991).

A cana-de-açúcar, em sua etapa inicial, tem um grande desenvolvimento dos perfilhos (MAGALHÃES, 1987). Segundo Diola e Santos (2010), o perfilhamento inicia-se em torno de 40 dias após o plantio e pode durar até 120 dias, já Aude (1993) afirma que a formação das touceiras e da população de colmos que serão colhidos é definida na fase de perfilhamento. Vários fatores como variedade, luz, temperatura, umidade do solo, espaçamento e práticas de fertilização influenciam no perfilhamento (JADOSKI et al., 2010).

O número de perfilhos é diretamente influenciado pelo número de cortes e o intenso tráfego de equipamentos, tendendo a diminuir ao longo dos anos. Outro fator que provoca a diminuição da soqueira é o sistema de corte da colhedora

e da sua manutenção, pois a interação do sistema de corte e as condições do solo durante a colheita podem provocar o dano de soqueiras, ocasionando em menor número de rebrotas no próximo ciclo da cultura, com a consequente redução de perfilhos (SANTOS, 2008; SILVA et al., 2008).

Quando a touceira está no auge do perfilhamento a competição intraespecífica por luz induz à inibição no perfilhamento e com isso inicia a fase do crescimento do colmo (MARCHIORI, 2004). O crescimento da parte aérea da cana-de-açúcar é a fase mais importante do cultivo, pois é quando ocorrem a formação e o alongamento do colmo, que resulta em produção (JADOSKI et al., 2010).

A quarta e última fase do desenvolvimento da cana-de-açúcar é a maturação. Este é o principal estágio fenológico das plantas, que está envolvido com o acúmulo de sacarose e é definido como o processo fisiológico que envolve a formação de açúcares nas folhas e seu deslocamento e armazenamento no colmo, quando as plantas praticamente cessam o crescimento vegetativo. Ao final da maturação a planta está pronta para a colheita.

O período de colheita no sudeste e sul do Brasil ocorre entre os meses de abril a novembro e existem duas situações para a primeira colheita, uma em que a cana é colhida doze meses após o plantio e outra em que é colhida dezoito meses depois (MARQUES et al., 2006). Após o primeiro corte (mais produtivo) a cana-de-açúcar é colhida por um período, em média, de cinco anos; porém esse período pode ser menor, o que determina o replantio (reforma). Com o decorrer dos anos a produtividade apresenta queda, que está diretamente ligada aos tratos culturais, danos causados pelo corte de base durante a colheita, erros de tráfego e consequente compactação do solo, além do tipo de solo, das condições climáticas e das cultivares utilizadas, entre outros (MATSUOKA et al., 1995; CAVALCANTE, 2011). A diminuição da produtividade da cana-de-açúcar ao longo da condução do canavial pode comprometer o retorno econômico da cultura (SPEKKEN et al., 2015). Segundo estimativas da CONAB (2018), a produtividade média na colheita para a safra de 2017/18 será em torno de 73 toneladas ha⁻¹.

2.1.2 Cenário brasileiro

Em 1955 a área total cultivada com cana-de-açúcar no Brasil era de cerca de 1,0 milhão de ha e em 1962 já havia atingido 1,5 milhão de ha (JUNQUEIRA, 1964). Em meados da década de 1970 houve grande expansão canavieira impulsionada pelo Programa Nacional do Alcool (PROÁLCOOL), estabilizando a área total cultivada a partir da safra 1987/1988, em torno de 4,2 milhões de ha (MACEDO, 2005). Em meados da década de 1990 um novo crescimento foi identificado, motivado pela exportação de açúcar.

Esses eventos históricos, que colaboraram para o aumento da área total cultivada, foram acompanhados por profundas modificações na lavoura de cana-de-açúcar. Um destes avanços se deu na forma de colheita, que até as décadas de 1950 e 1960 era manual, depois de queimar a cana, e o carregamento era mecânico. Neste mesmo período foram importadas as primeiras máquinas da Austrália, porém ainda exigiam a queimada da cana-de-açúcar. Na década de 1980 havia uma indefinição quanto ao processo de colheita da cana-de-açúcar, pois na época existia um tipo de colhedora que colhia a cana picada e outra que cortava a cana em sua base e depois tombava o colmo inteiro na superfície do solo, sendo necessário o recolhimento da mesma do chão, elevando os custos operacionais e o nível de impureza. Essa indefinição só foi resolvida na década seguinte, onde se optou pela colheita da cana picada, em virtude de questões sociais, econômicas e tecnológica, com o intuito de eliminar a operação de carregamento necessária no sistema que manuseia colmos inteiros. Assim, desenvolveu-se o parque de máquinas de colheita com origem na Austrália e em Cuba. Entretanto, ainda se eliminava a palha da forma mais econômica possível, normalmente por meio

da queima, ou, quando a colheita era de cana crua, deixada no campo para conservação do solo (Braunbeck e Magalhães, 2010).

Em 2007 o Protocolo Agroambiental de São Paulo impôs grandes restrições à queima da palha da cana-de-açúcar. Com isso o setor passou a buscar integralmente a colheita da cana crua. O Protocolo Agroambiental de São Paulo foi uma medida legal em defesa do meio ambiente, pois a queima da cana-de-açúcar é uma das grandes responsáveis pela emissão de dióxido de carbono (CO_2) na atmosfera. Além do problema ambiental a queima desencadeou uma série de casos de saúde pública, aumentando o número de doenças respiratórias entre crianças e idosos, principalmente nas cidades mais próximas dos canaviais, gerando infindáveis processos judiciais contra as usinas (ÚNICA, 2007).

O Protocolo previa inicialmente a eliminação da queima nas áreas passíveis da colheita mecanizada para 2021, e 2031 nas áreas para as quais não existe a tecnologia adequada para a mecanização. Porém, esses prazos foram antecipados para 2014 e 2017 respectivamente, acelerando o processo de mecanização das lavouras no estado de São Paulo, que é responsável por aproximadamente 60% da produção de cana-de-açúcar do Brasil.

2.1.3 Mecanização

A colheita mecanizada da cana-de-açúcar já está consolidada no sistema de produção no Brasil. No sistema de colheita mecanizada sem queima, as folhas, bainhas, ponteiros, além de quantidade variável de pedaços de colmo são cortados, triturados e lançados sobre a superfície do solo, formando uma cobertura denominada palhada (SILVA et al, 2009).

Na colheita mecanizada de cana-de-açúcar existem algumas peculiaridades relacionadas às interações solo-máquina-planta, que tem causado preocupações, devido às perdas de cana no campo, redução da qualidade da matéria-prima e redução da longevidade do canavial. Um dos componentes da colhedora que originam esses problemas é o cortador de base (SILVA et al., 2008). Além disso, outros fatores que afetam a colheita de cana-de-açúcar podem ser descritos por meio das condições agronômicas, ambientais, técnicas e do gerenciamento da operação, que influenciam no trabalho realizado pela colhedora e, caso esta não seja executada dentro dos padrões de qualidade estabelecidos pelo fabricante, pode reduzir a produtividade e a longevidade do canavial (RIPOLI; RIPOLI, 2009).

O avanço da colheita mecanizada de cana-de-açúcar possibilita determinados planejamentos operacionais que influenciam na tomada de decisão acerca da qualidade de matéria-prima industrializável. Ramos et al. (2014) constataram danos de até 34% nos rebolos de cana colhidos que estão diretamente relacionados ao aumento da rotação no motor da colhedora, influenciando na qualidade da matéria-prima (deterioração, impurezas e perdas). A regulação dos mecanismos de limpeza e de corte das colhedoras em função das condições operacional diminui tais perdas (MA et al., 2014). Na Figura 1 é possível ver a atual configuração das colhedoras de cana-de-açúcar.

Figura 1. Processo de colheita de cana de açúcar

Inicialmente o despontador realiza o corte das pontas da cana-de-açúcar, em seguida ela é orientada para dentro da máquina pelos divisores de linha (pirulitos). A cana-de-açúcar é cortada na base, rente ao chão, por um disco que é movido por motor hidráulico que também tem a função de orientar o fluxo para os rolos alimentadores. Uma vez dentro da máquina, a cana passa pelos rolos alimentadores e é direcionada até o rolo picador que consiste em dois motores hidráulicos acionando os cilindros de corte que têm as facas ao longo de seus comprimentos. Essas lâminas cortam a cana-de-açúcar em rebolos de aproximadamente 0,2 a 0,3 m. Após essa etapa, aproximadamente 75% da palha e da sujeira é soprada para fora da máquina através do extrator primário e os rebolos são despejados em um cesto que alimenta o elevador, que possui um sistema de taliscas. Este sistema é tipicamente acionado por dois motores hidráulicos, acoplados no topo do elevador, que conduz os rebolos até o veículo de transporte (transbordo), porém antes que os rebolos sejam despejados, um exaustor secundário remove cerca de 10-15% de sujeiras restantes. Com isso entende-se que existem diversas etapas que podem ser utilizadas para extrair dados referentes ao fluxo de massa da colheita, de forma direta ou indireta (Benjamin, 2002), (Cox, 2002).

2.2 AGRICULTURA DE PRECISÃO

2.2.1 Agricultura de precisão na cana-de-açúcar

A AP é um tema amplo e bastante discutido na atualidade, não se limitando a culturas ou regiões. O objetivo principal da AP é o gerenciamento mais detalhado do sistema de produção agrícola, visando analisar condições ideais para o cultivo (clima, solo e relevo) com o intuito de otimizar as práticas culturais em microescala, contemplando a variabilidade espacial intrínseca das lavouras, visando à otimização da produtividade e minimização dos custos, com o consequente aumento do lucro e minimização de impactos ambientais. Segundo Molin et al. (2014) a aplicação dos conceitos de AP visa compreender e atuar sobre a variabilidade espacial e temporal de cultivos agrícolas, com o objetivo de otimizar a lavoura através da gestão da variabilidade e de seus fatores associados.

Segundo MAPA (Ministério da Agricultura, Pecuária e Abastecimento) a Agricultura de Precisão (AP) é um sistema de gerenciamento agrícola baseado na variação espacial e temporal da unidade produtiva e visa o aumento de retorno econômico, a sustentabilidade e a minimização do efeito ao ambiente.

A implementação da AP foi fortemente influenciada pelo advento dos Sistemas Globais de Navegação por Satélite (GNSS, sigla em inglês). Destes, o mais conhecido é o GPS (sigla em inglês, Sistema de Posicionamento Global), desenvolvido nos Estados Unidos a partir do ano de 1978. Segundo Pedersen e Lind (2017), em 1984 foi gerado o primeiro mapa de produtividade com os dados de GPS.

Além do GPS, a agricultura de precisão faz uso de um software específico, conhecido como Sistema de Informação Geográfica (SIG) e a geoestatística, que permitem a análise e organização de dados espacializados e finalmente a geração de mapas que delimitam as áreas onde devem ocorrer as intervenções para a melhor gestão da produção (MIRANDA, 2017). Essas intervenções têm como consequência a otimização da produtividade e a diminuição dos custos, a partir do pressuposto de que se sabe exatamente quais produtos e doses e o local exato onde devem ser usados, além de minimizar os danos ambientais pelo uso de insumos químicos, sendo uma forte ferramenta para a produção sustentável.

Os benefícios da adoção da AP não são de fáceis mensuração pois levam em conta variáveis difíceis de serem gerenciadas, como as características da lavoura (variabilidade do solo, condições naturais diferenciadas, etc.) e os processos adotados pelo produtor. Ou seja, práticas de AP somente têm sentido e os benefícios somente serão percebidos se houver variabilidade na lavoura. Segundo Bernardi e Inamasu (2014), quanto maior for a variabilidade, maior será o retorno econômico percebido. Por exemplo, “se uma propriedade apresenta diferença de produção de duas a dez toneladas por hectare e a aplicação de insumo foi uniforme, então, é fácil entender que em algum ponto está se aplicando excesso de insumo, gerando desperdício e, em outro uma quantidade insuficiente, perdendo a oportunidade de se obter uma produção maior”. Por este motivo, a AP não se aplica a todos os problemas da produção agrícola, visto que se não houver expressiva variabilidade espacial, o retorno econômico pode ser nulo e até negativo.

A aplicação de AP na cultura de cana-de-açúcar tem se limitado as variáveis relacionadas à fertilidade do solo e a avaliação da genética de variedades (OLIVEIRA et al., 2007). Entretanto, o potencial de produção da cultura e a evolução ou presença de falhas no plantio, por exemplo, são pouco investigados (MOLIN e VEIGA, 2016). A decisão de investimento em AP pelos produtores de cana-de-açúcar é associada à percepção das tecnologias empregadas em outros sistemas de produção agrícola. Entretanto, a característica verticalmente integrada da indústria açucareira quanto à qualidade de matéria-prima (brix, pol, etc.) apresenta oportunidades para a elaboração de estratégias que considerem a AP como uma ferramenta de otimização de produção de açúcar e um método de gestão agrônômica da cultura (BRAMLEY, 2009).

A AP é compatível à cultura da cana-de-açúcar, porém sua aplicação ainda é incipiente. A sua adoção pode ser fortemente favorecida com o uso de geotecnologias para a obtenção de respostas cada vez mais rápidas, e precisas diante dos desafios de expansão e tecnificação do setor, visando suprir as demandas interna e externa de etanol, energia e açúcar por meio da otimização da produção de acordo com a variabilidade espacial da lavoura (GREGO et al., 2014).

A cana-de-açúcar é uma cultura promissora para adoção de técnicas de AP (BRAMLEY et al., 1997). Segundo Molin (2008) uma das estratégias de implementação da AP envolve o gerenciamento integrado de entradas e saídas, ou seja, envolve o conceito do gerenciamento localizado da reposição de insumos com base na sua extração e exportação, medida a partir da produtividade de cada porção dos talhões. Isso implica em se medir a produtividade e espacializar essa informação na forma de mapas de produtividade.

2.2.2 Mapas de produtividade

Há diferentes versões para descrever os primeiros movimentos relativos ao mapeamento da produtividade das culturas. Em 1984 a AGCO adquire a empresa Dronningborg e com isso o primeiro medidor de produtividade. Schnug et al. (1991) afirmam que em 1991, na Alemanha, foi gerado o primeiro mapa de produtividade derivado de um monitor de rendimento acoplado ao GPS, na cultura de canola.

De acordo com Sulzbach (2002), o mapa de produtividade é a representação gráfica da quantidade do produto agrícola colhido a cada ponto georreferenciado da lavoura, possuindo como objetivo a determinação da variabilidade espacial da lavoura. Durante a colheita a produtividade local de uma cultura pode ser expressa como uma função da taxa de fluxo de material dentro da colhedora, a velocidade em relação ao solo e a largura de corte (COX, 2002). Como a colheita da cana-de-açúcar é realizada em linha e geralmente é colhida uma ou no máximo duas fileiras, a largura de corte é constante. A velocidade de deslocamento da máquina é função do tempo, e é obtido facilmente pela rede CAN da máquina. Isso deixa o fluxo de material na máquina como a variável final necessária para medir a produtividade da cana-de-açúcar e de acordo com Cox (2002) esta variável é a que apresenta as maiores dificuldades para mensuração.

Os mapas de produtividade têm a função de apresentar a variabilidade das lavouras, com isso auxiliam na abordagem mais correta para a recomendação de adubação do ciclo seguinte. Isso se dá por levar em conta a produtividade da cultura anterior repondo os nutrientes exportados (BALASTREIRE et al., 1997). Segundo Fleming et al. (2000) os mapas de produtividade são a chave para o gerenciamento de lavouras em termos de variação espacial, o histórico dos mapas de produtividade pode auxiliar na identificação de padrões de comportamento temporal das áreas mapeadas. A partir de então se procura caracterizar as regiões que apresentam o mesmo comportamento ao longo do tempo.

Segundo Molin (2009), a medição do fluxo de massa mais as coordenadas geográficas são as informações mais importantes para geração do mapa de produtividade, que por sua vez é a informação mais completa para se visualizar a variabilidade espacial das lavouras. Várias outras ferramentas têm sido propostas para se identificar as manchas existentes em um talhão, como fotografias aéreas, imagens de satélite, videografia e outros. Todas têm seu potencial, porém, o mapa de produtividade materializa a resposta da cultura com a melhor exatidão possível, considerando as tecnologias existentes para a sua mensuração.

Na cultura de grãos, o mapa de produtividade de um talhão é um conjunto de muitos pontos e cada ponto representa uma pequena porção da lavoura. Para se saber qual a quantidade de massa colhidos é utilizado um sensor de fluxo que mede ou estima a massa ou o volume de material colhido. A largura da área colhida é a mesma da plataforma da colheitadeira e o comprimento é a distância percorrida pela máquina durante um período de tempo pré-determinado, normalmente de um a três segundos. A posição do ponto é obtida por meio de um receptor GNSS que dá o posicionamento correto da latitude e longitude da máquina.

Os dados são instantaneamente armazenados em um dispositivo de memória no monitor propriamente dito (computador de bordo dedicado). A forma dos arquivos gerados é particular para cada fabricante e pode ser visualizada como mapa. O mapa é um conjunto de pontos; aqueles pontos delimitados por uma área de alguns metros quadrados composta pela largura da plataforma e a distância percorrida entre duas leituras. A montagem do mapa nada mais é do que o gráfico que contém cada um daqueles pontos num sistema cartesiano, onde o eixo “x” é a longitude e o eixo “y” é a latitude. Basta que se escalonem os pontos em diferentes cores ou tons para diferentes valores de produtividade, obtidos naquela tabela de dados gerados no campo. Um exemplo de mapa pode ser visto na Figura 2.

Figura 2. Exemplo de Mapa de produtividade (Molin, 2013)

Os produtores de cana-de-açúcar sabem a produtividade média do talhão, uma vez que toda cana colhida é pesada na usina. Essa informação não indica a variabilidade que existe dentro do mesmo. Por mais que se conheçam bem suas lavouras e sejam capazes de estimar o desempenho da cultura em diferentes partes do campo, o mapeamento da produtividade transforma essas estimativas em valores quantitativos que podem ser mais facilmente utilizados para a tomada de decisões (OLSEN e HUSSEY, 2015). Para aumentar a produtividade em áreas com alto potencial de produção ou para aumentar a eficiência e maximizar a rentabilidade em áreas onde a produtividade é improvável que aumente, o conhecimento da extensão da variabilidade da produtividade combinado com informações sobre os solos, a elevação e os insumos agrícolas, são essenciais (VANSICHEN e De BAERDEMAEKER, 1993).

2.2.3 Monitor de produtividade

Segundo Molin (2009), no final dos anos 1980 surgiram as primeiras tentativas de se medir o fluxo de grãos em colhedoras de cereais e o primeiro monitor de colheita surgiu no mercado em 1991, na Europa. Já para cana-de-açúcar, embora Pierossi e Hassuani (1997), Earl et al. (1996) e Wheeler et al. (1997) tenham feito as primeiras tentativas de geração de um mapa de produtividade utilizando medidas extraídas de um transbordo, eles utilizaram células de carga, posicionamento por GPS e um sistema de aquisição de dados. Pierossi e Neves (2000) também utilizaram um sistema experimental instalado em um caminhão transbordo para mapear a produtividade.

O primeiro monitor de produtividade dedicado foi obtido por Cox et al. (1998) (Figura 3) que tentaram várias abordagens diferentes como um sistema de medição da pressão hidráulica de acionamento do picador e do elevador para determinar o fluxo de material, mas patentearam uma plataforma de pesagem apoiada por células de carga na parte superior do elevador (Cox et al., 2003; Patente dos EUA n ° 6.508.049 B1).

Figura 3. Sistema de medição da pressão hidrostática (a); sistema de pesagem no elevador (b) (adaptado de Cox et al., 1998)

De acordo com Cox (2002) quatro maneiras para medir o fluxo de cana-de-açúcar na colhedora podem ser utilizados: (1) medir a potência do picador, que é a potência necessária para cortar a cana-de-açúcar em rebolos; (2) medição de potência do elevador, que é potência necessária para elevar a cana-de-açúcar; (3) distância de separação entre os rolos de alimentação, para a medição do volume de cana na entrada do picador; (4) ou medição direta de massa que envolve a pesagem do fluxo de cana-de-açúcar através do elevador da máquina de colheita à medida que passa sobre uma plataforma de pesagem.

Esforço considerável tem sido feito para o desenvolvimento de sistemas de monitoramento da produtividade para cana-de-açúcar, principalmente na última década (BRAMLEY, 2009). Segundo Quaderer e Cash (2015), o monitoramento da produtividade aplicado a cana-de-açúcar e sua produção ainda está na fase inicial, embora a produção anual de dois bilhões de toneladas em nível mundial. Segundo Jensen et al. (2012) já foram testadas várias possibilidades de se obter a produtividade da cana-de-açúcar.

O uso de um monitor de produtividade semelhante, por pesagem no elevador, foi relatado por Pagnano e Magalhães (2001), Cerri e Magalhães (2005), Molin e Menegatti (2004), Magalhães e Cerri (2007) no Brasil, e por Benjamin (2002) nos EUA. De forma geral, todos relatam que o sistema de pesagem apresenta alguns problemas como a compensação de inclinação do elevador, a vibração e a mudança de tara causada pelo solo, sedimento e detritos. Um sistema para monitorar produtividade utilizando uma combinação da pressão no acionamento do corte de base e a torção em uma placa de deflexão no elevador foi patenteado nos EUA (Wendte et al., 2001; Patente dos EUA n.º 6.272.819 B1). Uma abordagem diferente é a utilização de sensores ópticos (Figura 4) para medir a quantidade de cana sobre as taliscas do elevador (Price et al., 2007). Esse princípio também foi testado por Price et al. (2011), que em seus testes de campo obtiveram R^2 ajustado de 0,97. Price et al. (2011) afirmam que o teste indicou que a leitura do ciclo de trabalho não foi influenciada pela variedade de cana-de-açúcar, distância percorrida, velocidade de combinação ou direção de corte, e o erro de rendimento médio foi de 7,5% com um desvio padrão de 6,3% com base nas comparações reais de peso de campo.

Figura 4. Utilização de sensores ópticos (Price et al., 2007)

Outra abordagem foi a instalação de instrumentação para monitorar a abertura dos rolos da esteira de alimentação do picador, feita pelo Hernandez et al. (2003, 2005) e Fernandez et al. (2007) (Figura 5).

Figura 5. Sensor de deslocamento aplicado do sistema de rolos alimentadores

Todos os métodos utilizados para determinação do fluxo de massa, direta ou indiretamente têm vantagens e desvantagens. O modelo baseado em balança tem a vantagem de estar medindo a massa como grandeza direta, não sendo necessária a utilização de nenhuma equação para obtenção da mesma. Já o monitoramento do torque no picador obtém a massa por método indireto, sendo necessária uma boa calibração para que os dados sejam confiáveis e acurados.

Jensen et al. (2012) testaram um monitor de produtividade de cana-de-açúcar composto por um conjunto de sensores que mediam diretamente a massa de cana-de-açúcar por meio de células de carga instaladas no elevador, e indiretamente utilizando sensores de pressão hidráulica do picador, do corte de base e do elevador. Também foi instalado um sensor óptico no elevador e sensores para medir a abertura dos rolos alimentadores para estimar o volume de cana-de-açúcar. A Tabela 1 apresenta um resumo dos trabalhos realizados para a avaliação de monitores de produtividade para colhedoras de cana.

Tabela 1. Sistemas avaliados para medição de produtividade em colhedoras de cana.

Autores	Princípio de medição	Posição do sensor	Avaliação realizada	Erro Médio [%]	R² [%]
Cox et al. 1998	Medição de Pressão	Picador e Elevador	ND	10	95
Benjamin et al. 2001	Balança	Base do Elevador	118 testes	11	96,6
Molin e Menegatti 2004	Balança	Base do Elevador	4 fases 17 Transbordos	3,5	ND
Cerri e Magalhães 2005	Balança	Base do Elevador	1 Ensaio de Campo 11 Transbordos	1,0	66
Price et al. 2011	Sensor de fibra ótica	Base do Elevador	1 Ensaio de Campo 50 Transbordos	7,5	97
Hernandez et al. 2003, 2005	Sensor de deslocamento	Abertura dos rolos	ND	ND	ND

*ND - Não Disponível; EM - erro médio

2.3 FUSÃO DOS SENSORES

Os termos fusão de sensor, fusão de dados, fusão de informação, fusão de dados multisensores e integração multisensores têm sido largamente utilizados na literatura para se referir a uma variedade de técnicas, tecnologias, sistemas e aplicações que usam dados derivados de múltiplas fontes. As aplicações de fusão variam desde a fusão de sensores em tempo real para navegação de robôs móveis até a fusão off-line de dados de inteligência estratégica humana ou técnica (Rothman,1991).

Várias tentativas foram feitas para definir e categorizar termos e técnicas de fusão. Wald (1998) propõe o termo fusão de dados para ser usado como o termo geral para a fusão. No entanto, enquanto o conceito de fusão de dados é fácil de entender, seu significado exato varia de um cientista para outro. O termo fusão de dados é usado nesse sentido pela Geoscience and Remote Sensing Society, pelo Departamento de Defesa dos EUA (DoD, 1991), e em muitos artigos sobre rastreamento de movimento, sensoriamento remoto e robôs móveis. Infelizmente, o termo nem sempre foi usado com o mesmo significado nos últimos anos (Smestad, 2001). Em alguns modelos, fusão de dados é usado para denotar a fusão de dados brutos (Dasarathy, 1997).

Há livros clássicos sobre fusão como o *Multisensor Data Fusion* de Waltz e Llinas (1995) e *Técnicas Matemáticas em Multisensor Data Fusion* de Hall (1992), que propõem um termo estendido, fusão de dados multisensores (Hall, 1992).

Outro termo frequentemente usado é a integração multisensores que se difere do termo fusão de sensores, no sentido em que incluem a combinação real de informações sensoriais em um formato representacional (Singhal,1997; Luo, 1989). A diferença entre fusão de sensores e integração multisensores é descrita na Figura 6. Os círculos S1, S2 e S3 representam sensores físicos que fornecem uma interface para o ambiente de processo. O diagrama de blocos Figura 6 (a) mostra que os dados do sensor são convertidos por um bloco de fusão de sensores em uma representação respectiva das variáveis do ambiente de processo. Esses dados são usados por um aplicativo de controle. Em contraste, a Figura 6 (b) ilustra o significado da integração multisensores, onde os diferentes dados do sensor são processados diretamente pelo aplicativo de controle.

Figura 6. Diagrama de Blocos de fusão de sensores (a) e integração multisensores (b) adaptado de Elmenreich (2002)

2.3.1 Classificação de Técnicas de Fusão de sensores

Segundo Castanedo (2013), a fusão de sensores é uma área multidisciplinar que envolve vários campos e é difícil estabelecer uma classificação clara e rigorosa. Os métodos e técnicas empregados podem ser divididos de acordo com 5 modelos: modelo proposto por Durrant-Whyte (1988), modelo Proposto por Dasarathy (1997), modelo dos Níveis de abstração, modelo definido pelo JDL (Joint Directors of Laboratory) e modelo pelo tipo de arquitetura.

2.3.1.1 Configuração dos sensores – Modelo de Durrant-Whyte

A fusão de sensores pode ser categorizada considerando o tipo de configuração dos sensores (Figura 7), Durrant-Whyte (1988) classifica em três tipos de configurações, complementar, redundante e cooperativa.

A configuração de sensor é chamada complementar se os sensores não são interdependentes, mas podem ser combinados para uma melhor compreensão do fenômeno sob observação. Geralmente, a fusão de dados complementares é fácil, uma vez que os dados de sensores independentes podem ser anexados uns aos outros (BROOKS e IYENGAR, 1998). O sensor S1 e S2 na Figura 7 representam uma configuração complementar, uma vez que cada sensor observa uma parte diferente dos dados de entrada.

Segundo Luo e Kay (1998), a configuração de sensor é chamada redundante ou competitiva se cada sensor fornecer medições independentes da mesma propriedade. Visser e Groen (1999) distinguem duas possíveis configurações redundantes - a fusão de dados de diferentes sensores ou a fusão de medições de um único sensor em diferentes instantes. A configuração redundante é utilizada normalmente em sistema que possuem tolerância a falhas, onde mesmo na falha de algum sensor o sistema continua em operação (Nelson,1990). Além da tolerância a falhas, as configurações redundantes também podem fornecer robustez a um sistema. O sensor S2 e S3 na Figura 7 representam uma configuração redundante, em que ambos os sensores observam, de forma redundante, a mesma propriedade de um conjunto de dados de entrada.

Uma rede de sensores cooperativa usa as informações fornecidas por dois sensores independentes para obter informações que não estariam disponíveis nos sensores individuais. Um exemplo para uma configuração de sensor cooperativo é a visão estereoscópica - combinando imagens bidimensionais de duas câmeras em pontos de vista ligeiramente diferentes, uma imagem tridimensional da cena observada é derivada. De acordo com Brooks e Iyengar (1998), a fusão de sensores cooperativos é a mais difícil de projetar, porque os dados resultantes são sensíveis a imprecisões em todos os sensores utilizados (BROOKS e IYENGAR, 1998). Assim, em contraste com a fusão redundante, a fusão de sensores cooperativos geralmente diminui a precisão e a confiabilidade. O sensor S4 e S5 na Figura 7 representam uma configuração cooperativa. Ambos os sensores observam o mesmo objeto, mas as medições são usadas para formar uma visão emergente do objeto C que não poderia ter sido derivada das medições de S4 ou S5 sozinho.

Figura 7. Classificação baseada no modelo de Whyte (1988) adaptado de Castanedo (2013)

2.3.1.2 Dados de Entrada/Saída – Modelo de Dasarathy

Dasarathy (1997) propôs um modelo de três níveis, ele categoriza os processos de fusão em níveis de abstração dos dados de entrada e saída. Ele teve como premissa abordar a fusão de sensores nas diferentes camadas de abstração, ou seja, decisões que são símbolos ou valores que se acredita, recursos que são os níveis intermediários da informação e dados que são os valores obtidos pelos sensores e descreve o processo de fusão como sendo um processo que pode ocorrer nestes níveis como por exemplo a fusão de dados brutos com recursos do sistema, com isso a Figura 8 apresenta o modelo com os três níveis.

Figura 8. Classificação baseada no modelo de Dasarathy (1997) adaptado de Castanedo (2013)

No nível de dados existem dois tipos de combinação: Entrada e Saída de dados (DAI-DAO), este tipo é o método de fusão de dados mais básico ou elementar que é considerado na classificação e os resultados são tipicamente mais confiáveis ou precisos. A fusão de dados neste nível é realizada imediatamente após os dados serem coletados dos sensores. Entrada de dados e Saída de recursos (DAI-FEO), neste nível, o processo de fusão de dados emprega dados brutos das fontes para extrair recursos ou características que descrevem uma entidade no ambiente;

O nível de recursos também possui dois tipos de combinações: recursos de entrada e saída (FEI-FEO), nesse nível, tanto a entrada quanto a saída do processo de fusão de dados são recursos. Assim, o processo de fusão de dados aborda um conjunto de recursos para melhorar, refinar ou obter novos recursos. Esse processo também é conhecido como fusão de recursos, fusão simbólica, fusão de informações ou fusão de nível intermediário. Entrada de recursos e Saída de Decisões (FEI-DEO), neste nível obtém um conjunto de recursos como entrada e fornece um conjunto de decisões como saída. A maioria dos sistemas de classificação que tomam decisões de acordo com as informações de um sensor se enquadram nessa categoria de classificação.

Por fim o nível de decisões possui um único tipo de estrutura, a entrada e saída de decisões (DEI-DEO), este tipo de classificação é também conhecido como fusão de decisão. Ele funde decisões de entrada para obter decisões melhores ou novas.

2.3.1.3 Modelo de fusão de dados JDL

O modelo conceitual mais popular na comunidade de fusão de dados foi originalmente proposto pela JDL e pelo Departamento de Defesa Americano (DoD) (1991). Essas organizações classificaram o processo de fusão de dados em cinco níveis de processamento, um banco de dados associado e um barramento de informações que conecta os cinco componentes (Figura 9). Esses cinco níveis podem ser agrupados em dois grupos, fusão de baixo nível e fusão de alto nível.

Os componentes de alto nível são as fontes, a interação homem-computador e o sistema de gerenciamento da base de dados; as fontes são responsáveis por fornecer os dados de entrada, tipos diferentes de fontes podem ser empregados, como sensores, informações (referências ou dados geográficos), bancos de dados e entradas humanas; a interação homem-computador (IHC), a IHC é uma interface que permite entradas do sistema a partir dos operadores e produz saídas para os operadores. O IHC inclui consultas, comandos e informações sobre os resultados e alarmes obtidos. E por fim o sistema de gerenciamento de banco de dados, que armazena as informações fornecidas e os resultados da fusão. Esse sistema é um componente crítico devido à grande quantidade de informações altamente diversificadas armazenadas (Waltz e Llinas, 1990).

Figura 9. Classificação baseada no modelo de JDL (1991) adaptado de Castanedo (2013)

Em contraste, os cinco níveis de processamento de dados são definidos da seguinte forma. O nível 0 (zero) tem como função o pré-processamento de fonte, é o nível mais baixo do processo de fusão de dados e inclui fusão nos níveis de sinal dos sensores. No caso de fontes de texto, esse nível também inclui o processo de extração de informações. Este nível reduz a quantidade de dados e mantém informações úteis para os processos de alto nível (Bedworth e O'Brien, 1999).

No nível 1 é realizado o refinamento de objeto, procedimentos comuns desse nível incluem alinhamento espaço-temporal, associação, correlação, agrupamento ou técnicas de agrupamento, estimativa de estado, remoção de falsos positivos, etc. Os resultados de saída deste estágio são a discriminação de objetos (classificação e identificação) e o rastreamento de objetos (estado do objeto e orientação). Este estágio transforma as informações de entrada em estruturas de dados consistentes.

Já no nível 2 é feita uma avaliação da situação, e visa identificar as situações prováveis, dados os eventos observados e os dados obtidos; estabelece relações entre os objetos. As relações (por exemplo, proximidade, comunicação) são valorizadas para determinar a significância das entidades ou objetos em um ambiente específico. A saída é um conjunto de inferências de alto nível;

O nível 3 tem por objetivo avaliar o impacto das atividades detectadas no nível 2 para obter uma perspectiva adequada. A situação atual é avaliada e uma projeção futura é realizada para identificar possíveis riscos, vulnerabilidades e oportunidades operacionais.

Por fim o nível 4, melhora o processo do nível 0 ao nível 3 e fornece gerenciamento de recursos e sensores. O objetivo é obter uma gestão eficiente de recursos, ao mesmo tempo em que conta as prioridades das tarefas, o cronograma e o controle dos recursos disponíveis.

Segundo Castanedo (2013), a fusão de alto nível geralmente começa no nível 2 porque o tipo, a localização, o movimento e a quantidade dos objetos são conhecidos nesse nível. Uma das limitações do método JDL é como a incerteza sobre os resultados anteriores ou subsequentes poderia ser empregada para melhorar o processo de fusão (feedback loop). Llinas et al. (2004) propõem vários refinamentos e extensões para o modelo JDL. Blasch e Plano (2002) propuseram adicionar um novo nível (redefinição do usuário) para suportar um usuário humano no loop de fusão de dados. No entanto, como suas raízes se originam no domínio militar, os termos empregados são orientados para os riscos que comumente ocorrem nesses cenários. O modelo Dasarathy (1997) difere do modelo JDL (1991) em relação à terminologia adotada e abordagem empregada. O primeiro é orientado para as diferenças entre os resultados de entrada e saída, independentemente do método de fusão empregado. Em resumo, o modelo Dasarathy fornece um método para entender as relações entre as tarefas de fusão e os dados empregados, enquanto o modelo JDL apresenta uma perspectiva de fusão apropriada para projetar sistemas de fusão de dados.

2.3.1.4 Modelo baseado no tipo de arquitetura

Uma das principais questões que surgem ao projetar um sistema de fusão de dados é onde o processo de fusão de dados será executado. Com base nesse critério, os seguintes tipos de arquiteturas podem ser identificados (Castanedo, 2013):

Em um modelo de arquitetura centralizada (Figura 10), o nó de fusão reside no processador central que recebe os dados de todas as fontes de entrada. Portanto, todos os processos de fusão são executados em um processador central que usa as medidas brutas fornecidas pelas fontes. Considerando que o alinhamento de dados e a associação de dados são realizados corretamente e que o tempo necessário para transferir os dados não é significativo,

então o esquema centralizado é teoricamente ideal. No entanto, as suposições anteriores normalmente não valem para sistemas reais. Além disso, a grande quantidade de largura de banda necessária para enviar dados brutos através da rede é outra desvantagem para a abordagem centralizada. Esse problema se torna um gargalo quando esse tipo de arquitetura é empregado para a fusão de dados em redes de sensores visuais. Por fim, o tempo de atraso na transferência da informação entre as fontes de diferenças é variável e afeta os resultados no esquema centralizado em maior grau do que em outros esquemas.

Figura 10. Arquitetura Centralizada adaptado de Castanedo (2013)

O modelo de uma arquitetura descentralizada (Figura 11) é composto de uma rede de nós nos quais cada nó possui suas próprias capacidades de processamento e não existe um único ponto de fusão de dados. Portanto, cada nó funde seus dados com os dados recebidos de seus pares. A fusão de dados é realizada de forma autônoma, com cada nó respondendo por seus dados. Os algoritmos de fusão de dados descentralizados normalmente comunicam seus dados usando os métodos de informações de Fisher e Shannon em vez do estado do objeto (Whyte e Stevens, 2001); A principal desvantagem desta arquitetura é a custo de comunicação, que é $O(n^2)$ em cada etapa de comunicação, onde n é o número de nós; além disso, o caso extremo é considerado, no qual cada nó se comunica com todos os seus pares. Assim, esse tipo de arquitetura pode sofrer de problemas de escalabilidade quando o número de nós é aumentado.

Figura 11. Arquitetura Descentralizada adaptado de Castanedo (2013)

Em uma arquitetura distribuída (Figura 12), as medidas de cada nó de origem são processadas independentemente antes que os dados sejam enviados para o nó de fusão; o nó de fusão é responsável pelos dados recebidos dos outros nós. Em outras palavras, a associação de dados e a estimativa de estado são realizadas no nó de origem antes que as informações sejam comunicadas ao nó de fusão. Portanto, cada nó fornece uma estimativa do estado do objeto com base apenas em suas visualizações locais. Este dado é a entrada para o processo de fusão, que

fornece uma visão global fundida. Esse tipo de arquitetura fornece diferentes opções e que variam de apenas um nó de fusão a vários nós de fusão intermediários.

Figura 12. Arquitetura Distribuída adaptado de Castanedo (2013)

A arquitetura hierárquica é uma combinação da arquitetura descentralizada e distribuída, na qual o processo de fusão de dados é executado em diferentes níveis na hierarquia. Em princípio, um sistema de fusão de dados descentralizado é mais difícil de implementar devido aos requisitos de computação e comunicação. No entanto, na prática, não há uma arquitetura única melhor, e a seleção da arquitetura mais apropriada deve ser feita dependendo dos requisitos, demanda, redes existentes, disponibilidade de dados, capacidade de processamento de nós e organização do sistema de fusão de dados (Castanedo, 2013).

Embora exista uma semelhança nas arquiteturas descentralizadas e distribuídas, Castanedo (2013) afirma que as mesmas possuem diferenças significativas (Figura 10, 11 e 12). Primeiro, em uma arquitetura distribuída, um pré-processamento das medições obtidas é realizado, o que fornece um vetor de recursos como resultado (os recursos são fundidos posteriormente). Em contraste, na arquitetura descentralizada, o processo completo de fusão de dados é realizado em cada nó, e cada um dos nós fornece um resultado globalmente fundido.

Em segundo lugar, os algoritmos de fusão descentralizada normalmente comunicam informações, empregando os métodos de informações de Fisher e Shannon. Em contraste, os algoritmos distribuídos normalmente compartilham uma noção comum de estado (posição, velocidade e identidade) com suas probabilidades associadas, que são usadas para realizar o processo de fusão (Manyika, 1988 e Whyte, 1995).

Em terceiro lugar, como os algoritmos de fusão de dados descentralizados trocam dados em vez de estados e probabilidades, eles têm a vantagem de separar facilmente o conhecimento antigo do conhecimento novo. Assim, o processo é aditivo, e o significado associativo não é relevante quando a informação é recebida e fundida. No entanto, nos algoritmos de fusão de dados distribuídos (isto é, distribuído pelo Filtro de Kalman), o estado que será fundido não é associativo, mas sim quanto a relevância de quando e como as estimativas fundidas são computadas. Em contraste com as arquiteturas centralizadas, os algoritmos distribuídos reduzem os custos computacionais e de comunicação necessários porque algumas tarefas são calculadas nos nós distribuídos antes que a fusão de dados seja realizada no nó de fusão.

2.4 INTELIGÊNCIA ARTIFICIAL

A fusão de sensores vem sendo utilizada associada a modelos de inteligência artificial – IA, Segundo Faceli (2001), a escolha do algoritmo de IA, a ser utilizado depende de uma série de fatores, tais como: o nível dos dados a serem fundidos, a aplicação que requer a fusão (o objetivo da fusão), o paradigma em que se baseia a proposta do sistema e a área de atuação dos pesquisadores envolvidos no desenvolvimento do sistema.

Uma descrição dos algoritmos mais comuns é feita por Klein (1999), Luo e Kay (1992 e 1995) e Joshi e Sanderson (1999). Alguns desses métodos são descritos a seguir.

1. Média Ponderada (Luo and Kay, 1992; Luo and Kay, 1995; Joshi and Sanderson, 1999): é o método mais simples e intuitivo e serve para fusão de informações de baixo nível; consiste do cálculo de uma média ponderada das informações redundantes proveniente de um conjunto de sensores.

2. Filtro de Kalman (Kalman filter) (Luo and Kay, 1992; Luo and Kay, 1995; Brooks and Iyengar, 1998; Joshi and Sanderson, 1999): método útil para fusão de dados redundantes e dinâmicos de baixo nível em tempo real; esse algoritmo usa características estatísticas de um modelo de medição para determinar estimativas ótimas para o dado fundido, recursivamente.

3. Método de Dempster-Shafer (Luo and Kay, 1995; Klein, 1999; Joshi and Sanderson, 1999): esse método é baseado em estatística e generaliza a teoria bayesiana para tratar incertezas; proposições (conhecimento dos sensores sobre eventos) são combinadas com a regra de Dempster para encontrar interseções ou conjunções de proposições e suas probabilidades associadas; sua desvantagem está na necessidade de definir o processo em cada sensor.

4. Algoritmos de Agrupamentos (Clusters) (Klein, 1999): nesses algoritmos os dados são agrupados em conjuntos ou agrupamentos naturais, interpretados por um analista que busca por categorias de objetos significativos. Métricas de similaridade ou medidas de associação são usadas para descrever a proximidade de dois vetores de características. Esses algoritmos selecionam dados de amostra, definem o conjunto de variáveis ou características que caracterizam as entidades na amostra, calculam as similaridades entre os dados, usam um método de análise de agrupamento criando grupos de entidades similares e validam a solução encontrada. A natureza heurística desses algoritmos pode levar a resultados tendenciosos. Os resultados podem ser afetados por diferenças de escala nos dados, escolha das métricas de similaridade e algoritmos e até pela ordem de entrada dos dados.

5. Casamentos Paramétricos (Parametric templates) (Klein, 1999): os dados adquiridos durante um período de tempo e de múltiplas fontes são casados com condições pré-selecionadas para determinar se as observações contêm evidências para identificar uma entidade.

6. Redes Neurais Artificiais (Luo and Kay, 1995; Klein, 1999; Pasika, 1999; Brooks and Iyengar, 1998; Joshi and Sanderson, 1999): são sistemas treinados para mapear dados de entrada em categorias de saída selecionadas; é formado por um conjunto de nós altamente interconectados de forma semelhante aos neurônios no cérebro; mais detalhes das redes neurais de interesse para este trabalho são abordados nos métodos.

7. Métodos de Votação (Klein, 1999): esses métodos combinam declarações de múltiplos sensores tratando cada declaração como um voto e usando maioria, pluralidade ou regras de árvores de decisão; pesos nas declarações também podem ser usados.

8. Medidas de Entropia (Klein, 1999; Joshi and Sanderson, 1999): tentam medir a importância de uma informação pela sua probabilidade de ocorrência; dados muito frequentes tem valor baixo enquanto dados raros tem

valores mais altos e, portanto, a função que mede o valor da informação decresce com a probabilidade presente de receber a informação.

9. Figuras de Mérito (Klein, 1999): são métricas que ajudam a estabelecer o grau de associação entre as observações e a identidade do objeto; tentam formular um relacionamento entre diversas variáveis para melhorar a associação ou classificação dos dados.

10. Reconhecimento de Padrões (Klein, 1999): diz respeito à descrição ou classificação dos dados; três abordagens são comuns para o reconhecimento de padrões: estatística, sintáticas e redes neurais artificiais.

11. Medidas de Correlação (Klein, 1999): são derivadas de combinações ponderadas de figuras de mérito e admitem uma medida de comparação para sistemas com muitas dessas figuras.

12. Casamentos Lógicos (Klein, 1999): os dados observados são comparados com padrões pré-determinados e armazenados para se identificar o objeto ou avaliar uma situação; esses casamentos paramétricos podem ser combinados com casamentos lógicos. Incertezas podem ser tratadas pela aplicação de lógica fuzzy.

13. Sistemas Baseados em Conhecimento (Klein, 1999; Joshi and Sanderson, 1999): esses sistemas incorporam regras e conhecimentos de especialistas para automatizar o processo de identificação do objeto; geralmente é composto de uma base de conhecimento que contém fatos, algoritmos e uma representação de regras heurísticas, uma base de dados global que contém dados dinâmicos, uma estrutura de controle ou motor de inferência e uma interface homem/máquina.

14. Teoria dos Conjuntos Fuzzy (Luo and Kay, 1995; Klein, 1999; Joshi and Sanderson, 1999): a lógica fuzzy se aplica em problemas nos quais os limites entre conjuntos de valores não são bem definidos, existe a ocorrência parcial de um evento ou as equações matemáticas específicas não são conhecidas; nos conjuntos fuzzy uma proposição tem um valor de pertinência em uma classe variando de 0 (não pertence a classe) a 1 (definitivamente pertence a classe).

2.5 REDES NEURAIS ARTIFICIAIS

As redes neurais fornecem uma nova abordagem para o problema da estimação de parâmetros de modelos não-lineares. Redes neurais são usadas em muitas áreas, como biologia e informática e engenharia. A ideia básica por trás de uma rede neural é a grande capacidade de processamento de dados do cérebro humano. O poder do cérebro biológico está associado na sua insuperável flexibilidade com alto grau de paralelismo (Pöldaru e Roots, 2003).

Uma grande vantagem das redes neurais é que, quando adequadamente treinadas, elas podem ser consideradas especialistas em relação ao projeto específico para o qual foram projetadas para examinar. Essa estrutura de rede pode até mesmo ser usada para fornecer projeções em situações novas e responder a perguntas do tipo "e se". Além disso, a capacidade de aprendizagem das redes neurais permite que elas se ajustem a ambientes dinâmicos e mutáveis e é uma ferramenta de previsão mais flexível do que os modelos estatísticos tradicionais. Além disso, os sistemas de redes neurais são capazes de detectar padrões e tendências em qualquer conjunto de dados que recebem, incluindo dados altamente desorganizados e variáveis (Ballard, 2003).

As redes neurais são usadas para modelar sistemas complexos que exibem comportamento linear e não linear (Jang et al., 1997). As redes neurais oferecem uma arquitetura altamente estruturada, com capacidades de aprendizagem e generalização, que tentam imitar os mecanismos neurológicos do cérebro. E elas armazenam o conhecimento de maneira distribuída dentro de seus pesos, que são determinados pela aprendizagem (treinamento) com exemplos conhecidos de entrada-saída (ODHIANBO et al., 2001). Existe uma estreita relação entre as técnicas

de redes neurais utilizadas atualmente e as técnicas estatísticas clássicas. Além disso, ambas são frequentemente usadas para resolver problemas semelhantes.

Redes neurais são particularmente adequadas para uso em ambientes altamente não-lineares. Sua capacidade de aprender com exemplos as torna apropriadas para aplicações em que tais exemplos são fácil e abundantemente disponíveis e onde há pouco conhecimento estruturado disponível (SRIRAM, 1997).

As redes neurais apresentam desempenho superior a modelos estatísticos tradicionais, conforme relatados em trabalhos realizados por THAI e SHEWFELT (1991), e TUMBO et al. (2002). A principal vantagem das redes neurais apontadas por ZHANG et al. (2002) é que não precisam de nenhum conhecimento prévio do sistema em estudo para determinar a relação existente entre a entrada e a saída.

HAYKIN (2002) relatou alguns benefícios das redes neurais como a capacidade de trabalhar com não-linearidade. Para ele, uma rede neural formada por neurônios não-lineares tem uma capacidade natural de realizar funções de entrada / saída não-lineares (aproximadas). Outro benefício é o de aproximação universal de funções de entrada-saída (estáticas e dinâmicas) a qualquer grau desejado de precisão, dada uma complexidade computacional adequada. Além disso, utilizando os pesos sinápticos de uma rede neural, a rede pode adaptar-se ao seu ambiente operacional e rastrear variações estatísticas. A tolerância a falhas também é citada por HAYKIN (2002) e a capacidade de desempenho robusto, no sentido de que seu desempenho se degrada gradualmente sob condições operacionais adversas, e por fim ele apresenta a analogia neurobiológica como uma ferramenta de pesquisa para a interpretação de fenômenos neurobiológicos. Da mesma forma, os engenheiros buscam no cérebro humano novas ideias para resolver problemas difíceis.

2.5.1 O Modelo Perceptron

McCulloch & Pitts (1943) propuseram o modelo matemático mais simples de neurônio, e foi a base para o modelo mais conhecido, chamado Perceptron, proposto por Rosenblatt (1958), que representa um só neurônio. O perceptron calcula uma única saída a partir de múltiplas entradas de valor real formando uma combinação linear de acordo com seus pesos de entrada. O neurônio é a unidade de processamento de informações fundamental para o funcionamento de uma rede neural. O diagrama de blocos da Figura 13 mostra um modelo de neurônio que forma a base do projeto de redes neurais, neste diagrama basicamente são mostrados três elementos básicos: os pesos sinápticos, a junção somadora e a função de ativação.

A definição matemática de tal limite de decisão é uma função discriminativa (Equação 2). É uma função que mapeia os recursos de entrada em um espaço de classificação, definindo um plano que separaria os dois clusters. No caso geral, teríamos um hiperplano n -dimensional, onde n é o número de variáveis. Embora a função mais simples que separaria os dois clusters seja uma linha reta, há um número infinito de limites que poderiam ter sido desenhados para separar as duas regiões.

Figura 13. Modelo Perceptron (Haykin, 2001)

As Equações matemáticas de 1 a 3 descrevem o neurônio k.

$$u_k = \sum_{j=1}^n w_{kj} \cdot x_j \quad (1)$$

$$v_k = u_k + b_k \quad (2)$$

A equação 2 descreve a função de discriminação.

A equação 3 apresenta a equação de saída do neurônio.

$$y_k = \varphi(v_k) \quad (3)$$

Onde:

u_k é a saída do combinador linear;

$\varphi(\cdot)$ é a função de ativação;

y_k é o sinal de saída do neurônio;

$x_1, x_2, \dots, x_n$ são os sinais de entrada;

$w_{k1}, w_{k2}, \dots, w_{kn}$ são os respectivos pesos sinápticos.

x_1-x_n = Sinais de entrada, b_k = bias ou o peso limiar, w_k = pesos sinápticos de um neurônio (k), a = parâmetro de inclinação, v_k = potencial de ativação, $x_0 = +1$ (extra sinapse com peso $w_{k0} = b_k$).

A Equação 4 representa a função sigmoide ou função de ativação (Figura 14) e é usada para refinar a saída dos neurônios e é a mais comumente usada em redes neurais.

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (4)$$

Figura 14. Função Sigmoide (Haykin, 2001)

2.5.2 Arquitetura Multicamadas Perceptron

Um Perceptron multicamadas (MLP) consiste em uma rede com pelo menos uma camada oculta de neurônios. As redes MLP são muito versáteis e têm uma ampla variedade de aplicação em quase todas as áreas do conhecimento. Entre as áreas mais utilizadas se destacam a aproximação universal de funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais e a otimização de sistemas (SILVA et al., 2016).

A rede MLP é uma das redes classificadas na arquitetura feedforward de camada múltipla com treinamento supervisionado. Os dados da rede fluem da camada de entrada para camada de saída. Os estímulos (dados) são apresentados à rede na camada de entrada, a camada intermediária (oculta) por sua vez extrai as informações e as codificam por meio dos pesos sinápticos, formando assim sua representação interna do ambiente externo. Por fim a camada de saída recebe os estímulos da camada intermediária, mapeando o padrão de resposta que será a saída da rede conforme apresentado na Figura 15 (Bolt et al, 1992).

Figura 15. Arquitetura Multicamadas Perceptron

A configuração topológica de uma rede MLP, tais como o número de camadas, e o número de neurônios por camada a ser utilizada, dependerá de vários fatores tais como, a distribuição espacial das amostras de treinamento e os valores iniciais atribuídos às matrizes de pesos (SILVA et al., 2016).

O treinamento deste tipo de rede é realizado utilizando-se a regra Delta Generalizada, sendo o algoritmo mais empregado conhecido por backpropagation ou algoritmo de retro propagação do erro por meio do treinamento supervisionado (HAYKIN, 2005). O processo de treinamento é realizado em duas fases bem definidas de aprendizagem (BRAGA et al., 2012; HAYKIN, 2005; SILVA et al., 2010).

A primeira fase é denominada propagação adiante ou forward. Nesta fase os pesos sinápticos e os limiares dos seus neurônios não sofrem alteração, pois o objetivo é obter o resultado da rede levando em consideração os valores dos parâmetros atuais da rede, que posteriormente serão ajustados pelo processo. Assim um conjunto de amostras de treinamento é apresentado à camada de entrada e seus efeitos se propagam até a camada de saída.

Utilizando o treinamento supervisionado, as respostas da rede são comparadas com as respostas esperadas e os erros gerados pela diferença das saídas são calculados e na fase seguinte utilizados para ajustar os pesos e limiares de todos os neurônios. Desta forma, os pesos das sinapses são alterados de acordo com a regra de correção do erro (HAYKIN, 2005), ou seja, a resposta real é subtraída da resposta esperada para produzir um sinal de erro.

A segunda fase é denominada propagação reversa, retro propagação ou backward; é onde o sinal de erro é propagado para trás através da rede. Assim os pesos são ajustados utilizando os valores de erros produzidos na etapa anterior. As execuções sucessivas das duas fases, faz com que os pesos sinápticos sejam ajustados automaticamente em cada iteração. Como consequência ocorre a diminuição dos erros produzidos pelas respostas calculadas em relação às esperadas. Estatisticamente, os pesos sinápticos são ajustados de forma que a resposta da rede se mova para mais próximo da resposta esperada (HAYKIN, 2005).

Vale destacar que o sistema de interconexões utilizado na rede é representado por vetores e matrizes de dados de entrada e pesos sinápticos e geralmente as funções de ativação utilizadas no método backpropagation são a logística ou a tangente hiperbólica.

Utilizando o modelo apresentado na Figura 13 como um neurônio de uma camada de uma rede MLP, tem-se um neurônio (k), pertencente à camada da rede, e cuja função de ativação (ϕ) deve ser contínua e diferenciável em torno do seu domínio. Os sinais de entrada representados por ($x_1, x_2, \dots, x_n$) e os pesos sinápticos por ($w_1, w_2, \dots, w_n$), e a soma ponderada das entradas (Σ) gera a saída do corpo celular artificial (v) após a introdução do limiar de ativação (b).

Analisando apenas um neurônio (k) (Figura 13), temos a Equação 5 para determinar o erro, cuja atribuição é determinar o desvio entre a saída calculada e o valor esperado.

$$e_k = d_k(n) - y_k(n) \quad (5)$$

Em que:

$d_k(n)$ - é o respectivo valor desejado e n é a n -ésima interação.

$e_k(n)$ - é o respectivo erro e n é a n -ésima interação.

$y_k(n)$ - é o respectivo a saída calculada e n é a n -ésima interação

Para determinar o erro total de todos os neurônios da camada de saída aplica-se a Equação 6.

$$E(n) = \frac{1}{2} \sum_{j=1}^n (d_k(n) - y_k(n))^2 \quad (6)$$

Em que:

$E(n)$ - é o respectivo valor do erro total da e n é a n -ésima interação.

$d_k(n)$ - é o respectivo valor desejado e n é a n -ésima interação.

$y_k(n)$ - é o respectivo a saída calculada e n é a n -ésima interação

O ajuste $\Delta w_k(n)$ a ser realizado no peso sináptico $w_k(n)$, a partir do valor da saída da interação, deve ser proporcional à derivada parcial entre o erro total e o peso sináptico utilizado anteriormente (Equação 7), e η é o parâmetro da taxa de aprendizagem do algoritmo e o sinal negativo indica a descida do gradiente no espaço de pesos em procura do menor valor possível para o erro quadrático.

$$\Delta w_k(n) = -\eta \frac{\partial E(n)}{\partial w_k(n)} \quad (7)$$

Em que:

$E(n)$ - é o respectivo valor do erro total da e n é a n -ésima interação.

$w_k(n)$ - é o respectivo valor do peso e n é a n -ésima interação.

η - é o valor da taxa de aprendizagem do algoritmo

Figura 16. Representação geométrica da obtenção do erro. Fonte: Silva et al. (2010)

Silva et al. (2010) explicam, por meio do gráfico (Figura 16) que a convergência para o menor erro possível (w^*) corresponde à representação geométrica das etapas para ajustar os pesos rumo à otimização. Iniciando com w_0 , o valor de w_1 é obtido a partir da direção oposta do vetor de gradiente em relação ao valor da etapa anterior, neste caso, w_0 . Quando o processo converge para w^* , o valor de E é o menor possível em relação a qualquer outro calculado nas etapas anteriores, em um total de n iterações.

Para o ajuste dos pesos das camadas intermediárias (ocultas) não existe uma forma de determinar diretamente o valor esperado da saída dos neurônios destas camadas. Todavia, os ajustes são realizados por meio dos erros da saída produzida pelos neurônios da camada imediatamente posterior, que já foram ajustados. Desta forma, se faz necessário realizar o ajuste da camada de saída que servirá como estimativa do erro para a camada anterior, e assim por diante.

2.5.2.1 Treinando Redes Neurais

Os neurônios individuais que compõem uma rede neural estão interconectados através das sinapses. Essas conexões permitem que os neurônios se sinalizem enquanto a informação é processada. Nem todas as conexões são iguais. Cada conexão recebe um peso de conexão. Esses pesos são os que determinam a saída da rede neural. Portanto, pode-se dizer que os pesos de conexão formam a memória da rede neural (Machado, 2005).

O treinamento é o processo pelo qual esses pesos de conexão são atribuídos. A maioria dos algoritmos de treinamento começa atribuindo números aleatórios à matriz de peso. Então a validade da rede neural é examinada. Em seguida os pesos são ajustados com base na validade da rede neural executada. Esse processo é repetido até que o erro de validação esteja dentro de um limite aceitável (Salazar, 2018).

Os dados de entrada são apresentados à primeira camada e os valores são propagados de cada neurônio para cada neurônio na próxima camada. Os valores são modificados durante a transmissão por pesos. Eventualmente, um resultado é entregue a partir da camada de saída.

Inicialmente, todos os pesos são aleatórios, e as respostas que saem da rede são provavelmente sem sentido. A rede aprende através de treinamento. Exemplos para os quais a saída é conhecida são repetidamente apresentados à rede e as respostas dadas são comparadas com os resultados conhecidos. As informações dessa comparação são repassadas pela rede, alterando gradualmente os pesos. À medida que o treinamento avança, a rede se torna cada vez

mais precisa ao replicar os resultados conhecidos. Uma vez treinada, a rede pode ser aplicada a casos futuros em que o resultado é desconhecido (Salazar, 2018).

As redes neurais são compostas de elementos simples que operam em paralelo. Esses elementos são inspirados nos sistemas nervosos biológicos. Como na natureza, a função de rede é determinada em grande parte pelas conexões entre os elementos. O treinamento da rede neural realiza uma função específica ajustando os valores das conexões (pesos) entre os elementos.

Geralmente as redes neurais são ajustadas ou treinadas, de modo que uma determinada entrada leva a uma saída de destino específica. Tal situação é mostrada na Figura 17. A rede é ajustada, com base em uma comparação entre a saída e o destino, até que a saída da rede corresponda à meta. Tipicamente, muitos desses pares de entrada / destino são usados, neste aprendizado supervisionado, para treinar uma rede (Demuth e Beale, 2000).

Figura 17. Aprendizado supervisionado Silva et al. (2010)

O treinamento em lotes de uma rede prossegue fazendo alterações de peso e polarização com base em um conjunto inteiro (lote) de vetores de entrada. O treinamento incremental altera os pesos e vieses de uma rede conforme necessário após a apresentação de cada vetor de entrada individual. O treinamento incremental é às vezes chamado de treinamento “on-line” ou “adaptativo”. As redes neurais foram treinadas para executar funções complexas em vários campos de aplicação, incluindo reconhecimento de padrões, identificação, classificação, fala, visão e sistemas de controle.

Existem muitas maneiras de treinar redes neurais. Os métodos de treinamento de redes neurais geralmente se enquadram nas categorias de abordagens híbridas supervisionadas, não supervisionadas e diversas. O aprendizado supervisionado é realizado fornecendo à rede neural um conjunto de dados de amostra, juntamente com as saídas previstas de cada uma dessas amostras. O aprendizado supervisionado é a forma mais comum de treinamento em redes neurais. À medida que a aprendizagem supervisionada prossegue, a rede neural é levada por várias iterações, ou épocas, até que a saída real da rede neural corresponda à saída antecipada, com um erro razoavelmente pequeno. Cada uma das épocas passa pelas amostras de treinamento.

Os métodos de aprendizado supervisionado são comumente usados, mas outras redes podem ser obtidas de técnicas de aprendizado não supervisionadas ou de métodos de design direto. Redes não supervisionadas podem ser usadas, por exemplo, para identificar grupos de dados.

A aprendizagem não supervisionada é semelhante à aprendizagem supervisionada, exceto que nenhuma saída antecipada é fornecida. Aprendizado não supervisionado geralmente ocorre quando a rede neural classifica as entradas em vários grupos e o treinamento progride através de muitas épocas (interações), assim como no aprendizado supervisionado.

Existem vários métodos híbridos que combinam vários aspectos do aprendizado supervisionado e não supervisionado. Um desses métodos é chamado de treinamento de reforço. Neste método, a rede neural é fornecida com dados de amostra que não contêm saídas antecipadas, como é feito com aprendizado não supervisionado.

2.5.3 Rede Neural aplicada na Agricultura

Estudos recentes mostraram que modelos de redes neurais são promissores para modelar problemas e cenários agrícolas. Por exemplo, um estudo foi conduzido para determinar a possibilidade de empregar redes neurais na modelagem da produtividade de milho usando variáveis de solo, água e topografia. Uma rede neural tipo backpropagation foi usada para modelar o rendimento do conjunto de dados de entrada. Com base no erro quadrático médio e nos coeficientes de correlação, os resultados indicaram que uma rede neural poderia ser eficientemente usada para modelar o rendimento dos dados de solo, água e topografia. Os resultados indicaram que as redes neurais foram potencialmente uma maneira eficaz de modelar a produção de milho (Diker et al., 2004).

Uma variedade de redes neuronais de alimentação supervisionada foi investigada na tentativa de identificar métodos capazes de relacionar as propriedades do solo e a produtividade das culturas em uma base ponto a ponto, em conjuntos de dados específicos do local. Os resultados para os métodos neurais foram comparados com os resultados para métodos lineares e não lineares, não paramétricos. Em termos de capacidade de generalização, as técnicas neurais consistentemente superaram todos os outros métodos, fornecendo erros mínimos. No entanto, resultados de relativamente poucas observações ou onde o estresse hídrico não era aparente, as melhorias alcançadas pelas redes neurais sobre os métodos lineares foram mínimas. A análise da rede neural dos conjuntos de dados específicos do local mostrou-se promissora (Drummond et al, 2000).

Como em toda regressão, a qualidade da função estimada e, portanto, a qualidade das regras de decisão, depende dos dados de entrada e dos dados de treinamento. Tanto a quantidade como a qualidade dos dados de treinamento determinam a qualidade do resultado. Especialmente para descobrir a influência climática e suas várias dependências em outros recursos, um grande conjunto de dados é necessário (Drummond et al., 2000).

Resultados de Janes et al. (2004) mostraram que os modelos de rede neural tiveram melhor desempenho na modelagem de odor em fazendas de suínos do que os modelos estatísticos não lineares. Eles concluíram que os modelos de redes neurais foram capazes de aprender automaticamente as relações existentes para o parâmetro estudado e, assim, evitaram o problema de selecionar uma relação para representar o sistema.

3. MATERIAL E MÉTODOS

3.1 CONSIDERAÇÕES INICIAIS

O presente trabalho foi conduzido considerando três principais etapas, conforme o fluxo de trabalho apresentado na Figura 18.

Figura 18. Etapas de desenvolvimento do trabalho

Na primeira etapa foi realizada uma ampla revisão bibliográfica na qual foram identificados os principais métodos já utilizados para determinação do fluxo de massa em colhedoras de cana-de-açúcar, uma vez definidos os sensores utilizados nestes métodos, foram definidos os sensores que seriam utilizados neste trabalho bem como novos pontos de instrumentação que foram estudados. Para entender a relação da colhedora, dos sensores e da colheita mecanizada, um primeiro ensaio dinâmico foi elaborado visando a identificação o comportamento dos dados (linearidade, repetitividade, amplitudes, frequência de amostragem, facilidade de instrumentação, etc.) e potencial dos sensores já adquiridos quanto ao fluxo de massa.

Na segunda etapa todos os sensores já estavam disponíveis, e os dados da primeira etapa já haviam sido processados e o comportamento dos sinais dos sensores utilizados compreendido, com isso na segunda etapa o foco foi a correlação entre os sensores, potencial para identificação da variabilidade e de falhas na lavoura, comportamentos dinâmicos dos sensores e obtenção das curvas de calibração para cada sensor. Com os dados da segunda etapa foi possível analisar a correlação dos sensores utilizando modelos de regressão linear múltipla (RLM) e redes neurais artificiais (RNA) com isso definir um modelo matemático com a fusão dos sensores, de modo a obter uma única resposta de fluxo de massa, além disso uma análise dos dados focado em falhas foi realizada, além dessas uma análise dos dados com foco em compreender a possibilidade da auto calibração do sistema.

Na terceira e última etapa, foram realizados ensaios dinâmicos para a validação dos modelos matemáticos gerados na segunda etapa a fim de demonstrar a se os mesmos atendiam a premissa de um erro relativo inferior a 2%.

3.2 ETAPA 1 – QUALIFICAÇÃO DOS SENSORES

3.2.1 Experimentos de campo

O ensaio dinâmico foi realizado na região de Santa Lúcia, SP, em área gerenciada pela usina Santa Cruz (-21.6869825, -48.0914166), em área de primeiro corte, variedade RB985476 com produtividade média 100 t ha⁻¹. A colhedora utilizada foi uma Valtra BE1035 (AGCO, Ribeirão Preto). Para o monitoramento dos dados os foi utilizado um sistema de aquisição da empresa Lynx, modelo ADS2000 com capacidade para leitura de 32 canais e resolução de 16 bits, os sensores utilizados foram:

- Extensômetros unidirecionais de 350 Ω , marca Excel sensores e modelo PA06125AA350L;
- Sensores de pressão de 400 bar, marca Parker, os dados deste sensor foram coletados diretamente do barramento CAN da máquina;
- Sensor de deslocamento tipo potenciométrico - range 0-1000 mm – marca wireSensor, entrada 5 a 12 V e saída de 0 a 10 V;
- Acelerômetro da marca Visong, com sensibilidade 40 mV g⁻¹;
- Receptor GNSS- Topcon sem algoritmo de correção.

Os pontos monitorados são apresentados na Figura 19 e suas regiões ressaltadas em verde.

Figura 19. Pontos monitorados com a instalação de sensores

Os dados de pressão do picador e do corte de base e GNSS foram adquiridos diretamente no barramento CAN (Controller Area Network) da máquina com uma frequência de aquisição de 10 Hz para os sensores e 1Hz para o GNSS. Os dados dos extensômetros, de deslocamento e aceleração, foram obtidos com um sistema de aquisição em paralelo com frequência de aquisição de 400 Hz, porém todos os dados foram coletados utilizando um trigger de sincronismo, para poder avaliar o tempo de entrada até o tempo de saída do fluxo de massa.

A Figura 20 apresenta o sensor de deslocamento do tipo potenciométrico, utilizado para medir o deslocamento do rolo de alimentação posterior ao picador, que foi instalado considerando o movimento angular dos

rolos. Essa medida foi utilizada para calcular o volume de cana inteira que está passando pelos rolos de alimentação, antes de ser picada.

Figura 20. Sensor de deslocamento instalado no rolo transportador móvel

A Figura 21 apresenta um esquema onde é possível entender como é o fluxo de massa ao longo dos rolos alimentadores, com base na dinâmica dos rolos a taxa de fluxo volumétrico, νf [$\text{m}^3 \text{s}^{-1}$], pode ser calculada usando a Equação 8. Juntamente com a separação do rolo de alimentação, s [m], as variáveis adicionais w [m], a largura do feixe de cana e v [m s^{-1}], a velocidade da cana através dos rolos de alimentação, são necessárias. Entretanto, essas duas variáveis são relativamente constantes e não é necessário monitorá-las ao longo do tempo; isso por se tratar do último conjunto de rolos de alimentação antes do picador. Neste ponto o feixe de cana teve tempo de se espalhar por toda a largura dos rolos de alimentação para permitir o processamento uniforme pelo picador. A velocidade da cana através do último conjunto de rolos de alimentação também é relativamente constante devido à ação dos rolos picadores que puxam o feixe a uma taxa uniforme para obter um comprimento dos rebolos constante.

Figura 21. Seção para determinação do volume

$$\nu f = v \cdot w \cdot s \quad (8)$$

$$mf = \nu f \cdot \rho \quad (9)$$

Em que:

νf é a taxa de fluxo volumétrico [$\text{m}^3 \text{s}^{-1}$];

v é a velocidade da cana através dos rolos de alimentação [m s^{-1}];

w é a largura do feixe de cana [m];

s é a separação do rolo de alimentação [m];

ρ é a densidade da cana-de-açúcar [kg m^{-3}];

mf é o fluxo de massa [kg s^{-1}].

Para calcular o fluxo de massa mf [kg s^{-1}] a partir da medição do fluxo volumétrico, é necessário a densidade como mostrado na Equação 9. A densidade da cana-de-açúcar ρ [kg m^{-3}] não é constante e pode variar devido a muitos fatores, incluindo diferenças no nível de matéria estranha, se a cana-de-açúcar é verde ou queimada e a idade da cultura. A variação na densidade pode resultar em uma fonte significativa de erros. Segundo Ridge e Dick (1988), sozinha, a variação de matéria estranha entre a cana queimada e verde pode chegar a 30% em peso e isso resultaria em uma diferença na densidade de magnitude similar.

Para contornar a variável densidade uma simplificação pode ser feita na Equação 9; reescrevendo essa equação obtém-se a equação 10.

$$mf = v \cdot w \cdot \rho \cdot s \quad (10)$$

A equação 10 pode ser simplificada considerando uma constante de calibração c [$(\text{kg s}^{-1})/(\text{m do separador})$] conforme a equação 11.

$$mf = c \cdot s \quad (11)$$

Com isso a variável s pode ser medida com qualquer sensor de deslocamento.

Em virtude da vibração proveniente das esteiras motoras e do elevador, um acelerômetro (Figura 22) foi instalado no centro de massa do elevador com o intuito de se registrar a vibração do mesmo. Essas medições foram utilizadas para eliminar o efeito da vibração do sinal dos extensômetros.

Para a primeira etapa, ao invés de utilizar uma balança no elevador, foram utilizados extensômetros na base ou no cilindro do elevador. Para esse experimento, uma ligação em ponte completa de Wheatstone foi utilizada. A Figura 22 apresenta a posição do acelerômetro e dos extensômetros.

Figura 22. Posição do acelerômetro e dos extensômetros instalados no elevador da máquina

Os extensômetros são sensores comumente utilizados para medição de deformações mecânicas, e são aplicados em células de cargas, sensores de torque e pressão; para a definição dos pontos onde os extensômetros foram instalados, um modelo de elementos finitos foi utilizado (Figura 23). Com base neste modelo foi possível determinar quais regiões no elevador seriam mais sensíveis a pequenas variações de massa.

Figura 23. Elementos finitos - definição dos pontos para monitoramento

A Figura 24 apresenta os quatro pontos instrumentados com os extensômetros para base e para os cilindros. A seleção da utilização de uma ponte completa é para se obter uma medição com maior resolução, pois nessa configuração de quatro extensômetros ativos se tem o valor da soma das deformações, conforme Equação 12.

Figura 24. Pontos de instrumentação com extensômetros

$$\varepsilon = \varepsilon_1 - \varepsilon_2 + \varepsilon_3 - \varepsilon_4 \quad (12)$$

$$mf = c \cdot \varepsilon \quad (13)$$

Onde:

ε é a deformação em cada sensor.

Para transformar a deformação obtida pelos extensômetros em fluxo de massa mf [kg s^{-1}] é necessária uma constante de calibração c [$(\text{kg s}^{-1}) \varepsilon^{-1}$], conforme a Equação 13.

Para a colheita a Usina disponibilizou um treminhão e dois transbordos, que ficaram dedicados às medições, podendo ser pesados individualmente após a colheita. Essa pesagem foi realizada pela própria equipe da usina.

3.2.2 Análise dos sensores

A primeira análise realizada foi a calibração dos extensômetros da base e do cilindro do elevador. Foram realizadas calibrações estáticas conforme Figura 25, aplicando massas no centro de massa, variando de 100 kg em 100 kg até 500 kg, esse range de calibração foi utilizado em função do volume que passa pelas taliscas durante a colheita, variando de 0 kg quando o elevador está rodando em vazio, a aproximadamente 300 kg. Essa calibração tem por finalidade obter a constante de calibração $d[\text{kg } \epsilon^{-1}]$.

Figura 25. Calibração dos extensômetros

A segunda análise foi para avaliação da taxa de amostragem. Foram gerados FFT (*Fast Fourier Transformer*), que possibilitam verificar as frequências mais atuantes em cada grandeza medida. Essa avaliação é importante para determinar a taxa de aquisição dos dados do monitor de produtividade, bem como qual a frequência de corte do filtro passa baixa. A Figura 26 apresenta um sinal aleatório, descrito no tempo, e as ondas senoidais que o compõem.

Figura 26. Funcionamento da FFT

A terceira análise foi a da qualidade do sinal, observando a correlação e defasagem dos sinais em virtude de estarem distribuídos ao longo da máquina.

3.3 ETAPA 2 – CORRELAÇÃO DOS SENSORES

3.3.1 Experimentos de Campo

O ensaio dinâmico da segunda etapa foi realizado na região de Luiz Antônio, SP (-21.510309, -47.832918) (Figura 27), em área gerenciada pela usina Moreno, cana-de-açúcar de segundo corte, variedade RB98769, com produtividade média 90 t ha⁻¹.

Figura 27. Área da colheita em Luiz Antônio, SP

Utilizou-se a mesma colhedora Valtra BE1035 utilizada na etapa 1. Para o monitoramento dos dados os seguintes equipamentos foram utilizados: sistema de aquisição de dados HBM SOMAT; extensômetros Excel sensores – 350 Ω - Unidirecional - PA06125AA350L; sensores de pressão do corte de base – HBM 500 BAR; sensores de pressão do Picador – HBM 500 BAR; sensores de pressão do Elevador – HBM 100 BAR; sensor de deslocamento potenciométrico - range 0-350 mm - wireSensor; acelerômetro - PCB - sensibilidade 100 mV g⁻¹; balança de elevador Simprocana (Enalta, São Carlos); transbordo com cesto instrumentado células de carga modelo BTBI; receptor GNSS-Garmin. Os sensores foram selecionados levando em conta as amplitudes máximas de cada sistema, sendo 350 BAR para o corte de base e picador, 80 BAR para o elevador e 150 mm para os rolos alimentadores. Os pontos monitorados são apresentados da Figura 28.

Figura 28. Pontos monitorados com a instalação de sensores

Para o experimento de campo da etapa dois foram delimitadas algumas condições para avaliação dos sensores, além de utilizar a balança no elevador e o transbordo com células de carga para validar a correlação. Esse experimento serviu para calibração dos sensores por meio de ensaios dinâmicos. Para isso foram colhidas cinco fileiras contínuas sendo a massa registrada continuamente pela balança no elevador e pelo transbordo (Figura 29). Nesta etapa foi avaliada a capacidade de identificar a variabilidade e falhas na lavoura. Para isso foram produzidas falhas de 1,0 m com a ajuda de um operador da própria usina e georeferenciado com um GNSS Garmin, conforme Figura 30 e, da mesma forma, foram colhidas cinco fileiras contínuas sendo a massa registrada continuamente pela balança no elevador e pelo transbordo.

Figura 29. Fileiras de cana colhidas: sem falha (a); com falhas produzidas (b)

Figura 30. Produzindo falhas georeferenciadas

Os ensaios da etapa 2 foram divididos em fileiras, com cada execução definida como a colheita de uma única fila de cana (1,5 m de largura), 600 m de comprimento. Porém, para o processamento foram considerados médias para cada 50 m e os dados obtidos em todas as corridas foram comparados com a massa registradas no transbordo. A área do campo foi selecionada por seu rendimento e uniformidade acima da média local o que permitiu manter taxas de fluxo constantes durante cada execução. Um layout de campo típico é mostrado na Figura 29.

Para calcular a vazão mássica média de cada fileira, a massa total colhida, conforme registrada no transbordo de pesagem, foi dividida pelo tempo de colheita de cada fileira, conforme registrado pelo sistema de aquisição de dados. No geral, dez fileiras foram colhidas, dando um conjunto de dados adequado para comparar as técnicas de medição.

3.3.2 Avaliação de potenciais sensores

Para avaliar o potencial dos sensores, os dados de todos foram adquiridos em um único sistema, com frequência de aquisição de 1 Hz para o GNSS. Os dados dos extensômetros, de deslocamento, das pressões e aceleração, foram obtidos com uma frequência de aquisição de 400 Hz. A balança do elevador possui um sistema independente de monitoramento e a sua frequência de aquisição foi de 1 Hz. O transbordo também possui um sistema independente para aquisição da massa continuamente a uma frequência de aquisição de 10 Hz, porém todos os dados foram coletados utilizando um trigger de sincronismo, para poder avaliar o tempo de entrada até o tempo de saída do fluxo de massa.

O fluxo de massa $\dot{m}[\text{kg s}^{-1}]$ a partir dos dados do sensor de deslocamento dos rolos de alimentação foi avaliada utilizando a Equação 11. O fluxo de massa $\dot{m}[\text{kg s}^{-1}]$ a partir dos dados dos extensômetros foi avaliada utilizando a Equação 13. Foram utilizados sensores de pressão hidráulica para a determinação do fluxo de massa $\dot{m}[\text{kg s}^{-1}]$ em três regiões da máquina: corte de base, que também foi utilizado para observar falhas na cultura; picador; elevador.

A medição do fluxo de massa no picador é determinada considerando que a pressão necessária para cortar a cana-de-açúcar em rebolos é proporcional à taxa de fluxo de massa da cana-de-açúcar através dos picadores (Figura 31).

Figura 31. Funcionamento dos rolos picadores

As pressões foram medidas na entrada p_{in} [bar] e na saída p_{out} [bar] dos motores, de modo a obter uma pressão diferencial p [bar] do picador, conforme Equação 14.

$$p = (p_{in} - p_{out}) - f \quad (14)$$

Onde f [bar] é a pressão do picador rodando em vazio, que foi medido no início de cada colheita.

Porém Cox (2002) ressalta que algumas variáveis (umidade do material, comprimento de corte, velocidade de rotação do cilindro de corte, distância de liberação ou espaço entre as lâminas, facilidade de afiação, ângulo de afiação da faca) influenciam na determinação do fluxo de massa utilizando a pressão hidráulica, e afirma que para esta técnica funcionar, todas essas variáveis teriam que permanecer relativamente constantes e assim manter uma pressão de corte constante. Isso é improvável durante toda uma safra e neste trabalho essa variável é calibrada constantemente, juntamente com os demais sensores obtendo o fluxo de massa m_f [kg s⁻¹] utilizando a Equação 15, onde c [(kg s⁻¹) bar⁻¹] é uma constante de calibração.

$$m_f = c \cdot p \quad (15)$$

A medição do fluxo de massa no elevador é determinada considerando que a pressão necessária para elevar a cana-de-açúcar em rebolos até o transbordo é proporcional à taxa de fluxo de massa da cana-de-açúcar através do elevador. Para isso é importante ressaltar que a pressão gerada nos motores hidráulicos é proveniente da energia necessária para superar a gravidade e a fricção no piso do elevador, à medida que a cana de açúcar é arrastada pelo elevador. A Figura 32 apresenta um modelo simplificado das forças atuantes no elevador.

Figura 32. Modelo simplificado dos carregamentos no elevador

A força $F[N]$ total correspondente ao elevador cheio de cana-de-açúcar, e que atua no motor hidráulico, pode ser representada pela Equação 16.

$$F = \sum_{1}^n P_{yn} + \mu \cdot P_{xn} \quad (16)$$

Reescrevendo a Equação 16 substituindo a força P pela segunda lei de Newton $[m \cdot g]$, obtemos as Equações 17 e 18:

$$F = \sum_{1}^n m_n \cdot g \cdot \sin \theta + \mu \cdot m_n \cdot g \cdot \cos \theta \quad (17)$$

$$F = \sum_{1}^n m_n \cdot (g \cdot \sin \theta + \mu \cdot g \cdot \cos \theta) \quad (18)$$

Em que:

F é a força total para elevação da cana-de-açúcar $[N]$;

n é o número de taliscas ativas no plano de elevação [adimensional];

P_y é a componente da força gravitacional atuante no plano de elevação $[N]$;

P_x é a componente normal ao plano de elevação e representa a força que a cana exerce no plano $[N]$;

m é a massa em cada talisca $[kg]$;

g é a força gravitacional $[m \cdot s^{-1}]$

μ é o coeficiente de atrito [admissional];

θ é o ângulo de inclinação do plano de elevação, ou seja a inclinação do elevador [graus]

Considerando que a pressão no elevador é proporcional ao volume de cana que está sendo transportado, pode-se assumir que existe uma relação entre a força e a pressão exercidas pelo elevador, uma vez obtida a constante de calibração que descreve essa relação, pode-se utilizar a Equação 15 para descrever fluxo de massa $m/[kg \cdot s^{-1}]$.

A medição do fluxo de massa no corte de base é determinada considerando que a pressão necessária para cortar a cana-de-açúcar na base é proporcional à taxa de fluxo de massa da cana-de-açúcar através do corte de base (Figura 33).

Figura 33. Funcionamento do corte de base

As pressões foram medidas na entrada $p_m[bar]$ e na saída $p_{out}[bar]$ do motor, de modo a obter uma pressão diferencial $p[bar]$ do corte de base, conforme Equação 19.

$$p = (p_{in} - p_{out}) - f \quad (19)$$

Em que f [bar] é a pressão do corte de base rodando em vazio.

Assim como foi considerado na formulação do fluxo de massa no picador, algumas variáveis (umidade do material, comprimento de corte, velocidade de rotação do cilindro de corte, distância de liberação ou espaço entre as lâminas, facilidade de afiação, ângulo de afiação da faca) influenciam na determinação do fluxo de massa utilizado a pressão hidráulica. Com isso, neste trabalho, essa variável é calibrada constantemente juntamente com os demais sensores, obtendo o fluxo de massa mf [kg s⁻¹] utilizando a Equação 20, onde c [(kg s⁻¹) bar⁻¹] é uma constante de calibração.

$$mf = c \cdot p \quad (20)$$

Para a balança no elevador, a saída do sistema já é dada em produtividade, podendo ser comparada diretamente com as demais técnicas.

Uma vez definida toda a formulação para determinação do fluxo de massa individualmente em cada sensor, o tópico a seguir apresentará o funcionamento da fusão entre eles.

3.3.3 Síntese dos sensores potenciais

O tópico 3.3.2 discutiu as sete técnicas potenciais para medir a taxa de fluxo de massa através da colhedora de cana-de-açúcar. Aqui são explicados os testes de campo iniciais que foram realizados com cada uma dessas técnicas. O principal objetivo dos ensaios foi comparar o desempenho das sete técnicas de sensoriamento e avaliar suas limitações, problemas e potencial. As sete técnicas foram testadas simultaneamente colocando vários sensores em uma única colhedora e comparando as saídas do sensor com a vazão mássica medida por um transbordo balança.

3.3.3.1 Colhedora e transbordo balança

A mesma colhedora utilizada na etapa 1 foi utilizada para esses ensaios. A máquina foi configurada com vários sensores ao longo da passagem da cana, para representar as sete técnicas de detecção de vazão mássica discutidas no tópico 3.3.2. Os sensores foram conectados a um sistema de aquisição de dados digital, que registrou a saída de cada sensor para posterior análise. As sete técnicas e o sistema de aquisição de dados serão explicados em detalhes na próxima seção.

Um transbordo balança foi usado para medir a massa de cana colhida para cálculos de vazão mássica. Consistia em um transbordo com um cesto de pesagem dentro de um cesto fixo. Esse compartimento era suportado por quatro células de carga WEIGHTECH modelo BTBI (BERMAN, Alemanha) de 3,0 t com o kit de datalogger e indicador de pesagem WEIGHTECH WT3000-I R, com fundo de escala de 1 kg e taxa de amostragem de 10 Hz que mediam a massa da cana via eletrônica relevante e relatavam a massa ao motorista na cabine e ao mesmo tempo registrava os dados através de uma porta serial RS232. A capacidade de pesagem do transbordo era de 12,0 t e o transbordo tinha a capacidade de medição dinâmica, ou seja, continuamente durante a colheita e para uma maior precisão era estacionado ao final de cada fileira colhida para uma medição estática com maior precisão. O transbordo também tinha a função de descarregamento para esvaziar o cesto após ficar cheio.

3.3.3.2 Detalhes dos sensores comerciais utilizados

As sete regiões que foram sensoreadas para obtenção do fluxo de massa ou vazão mássica, que foram discutidas nos tópicos anteriores serão chamados neste tópico conforme sequência de passagem da cana pela colhedora de: pressão no corte de base, separação dos rolos alimentadores, pressão no picador, carga na base do elevador, carga no cilindro do elevador, pressão no elevador e massa na balança do elevador. Os detalhes específicos da implementação de cada um desses sensores para este estudo estão descritos a seguir.

Pressão no corte de base: A pressão no corte de base foi monitorada usando transdutores para medir a pressão hidráulica e um tacômetro para medir a velocidade do motor. Os transdutores de pressão foram HBM IP8C com uma faixa de 0-500 bar, com saída elétrica equivalente de 0 a 10 V. Seu erro de não-linearidade e histerese foi especificado como $\pm 0,1\%$ em escala máxima. Dois transdutores de pressão foram posicionados no circuito hidráulico com um antes e um após o motor do corte de base. A medição da pressão diferencial usando os dois transdutores permitiu que o consumo de energia do corte de base fosse medido separadamente de quaisquer motores hidráulicos acionados por este sistema. Das medições de pressão e velocidade, foram calculadas as curvas de calibração para determinação da constante de calibração que posteriormente foi utilizada na Equação 20 para determinação do fluxo de massa, durante a etapa 2 os dados do sensor do corte de base apresentaram problemas e foram descartados desta fase do processamento, com isso sua avaliação foi feita na etapa 3.

Separação dos rolos de alimentação: Para medir a separação dos rolos de alimentação. O conjunto final de rolos de alimentação no trem de alimentação (antes da caixa do picador) foi instrumentado com um sensor MicroStrain do tipo *stringpot* com capacidade de medir uma faixa de 0 – 350 mm de deslocamento linear, com saída elétrica equivalente de 0 a 10 V. Seu erro de não-linearidade e histerese foi especificado como $\pm 0,1\%$ em escala máxima. A separação perpendicular entre o rolo superior e o inferior foi calibrada.

Pressão no picador: A pressão do picador foi realizada da mesma forma que a medição da potência do corte de base, com dois transdutores de pressão medindo a pressão diferencial do sistema. O transdutor de pressão utilizado foi do mesmo modelo do corte de base. Os dois transdutores de pressão foram posicionados no circuito hidráulico com um antes e um após os motores do picador. Como os motores do picador foram conectados hidráulicamente em paralelo, o transdutor de pressão mediu a queda de pressão em ambos os motores.

Carga na base do elevador: A carga na base do elevador foi medida utilizando quatro extensômetros HBM de 350 Ω modelo 1L11-5/350. Os mesmos foram colados em posição definida por uma simulação de elementos finitos (FEA) e posteriormente ligados de maneira a obter um circuito elétrico de ponte de Wheatstone na configuração de ponte completa, calibrada com pesos padrões aplicados no centro de massa do elevador. A sensibilidade da ponte foi de 2 mV V⁻¹ e com uma saída elétrica equivalente de 0 a 10 V.

Carga no cilindro do elevador: A carga no cilindro do elevador foi medida utilizando os mesmos modelos e calibração do sistema de carga na base do elevador.

Pressão no elevador: A medição da pressão do elevador foi realizada da mesma forma que a medição da potência do picador e no corte de base. A principal diferença foi que apenas um transdutor de pressão foi usado para monitorar a queda de pressão nos motores hidráulicos. Isso foi possível porque a saída dos motores dos elevadores é alimentada no tanque de retorno e, portanto, a pressão nessa linha pode ser considerada como zero ignorando a pequena perda por atrito na linha de retorno. O transdutor de pressão utilizado foi do mesmo modelo utilizado no picador e foi posicionado em frente aos dois motores hidráulicos, que foram conectados em paralelo.

Massa na balança do elevador: A balança Simprocana (Enalta, S. Carlos, SP) é um monitor de produtividade comercial e possui todo o sistema de medição e datalogger próprio e foi utilizada para fins de comparação com as técnicas apresentadas até aqui, para avaliação da necessidade ou não de se manter esse método integrado ao modelo proposto.

Para facilitar análise e apresentação dos dados dos sensores utilizados (variável independente) a Tabela 2 sintetiza as abreviaturas utilizadas.

Tabela 2. Lista de sensores e abreviaturas

Descrição	Abreviatura
Massa no transbordo – Padrão utilizado	MT
Carga na base do elevador – lado direito	CBED
Carga na base do elevador – lado Esquerdo	CBEE
Carga no cilindro do elevador – lado direito	CCED
Carga no cilindro do elevador – lado Esquerdo	CCEE
Deslocamento rolos 1	DR1
Deslocamento rolos 2	DR2
Pressão no corte de base	PB
Pressão no elevador	PE
Pressão no picador	PP
Massa no sistema Simprocana	MS

3.3.3.3 Sistema de aquisição de dados

Para a aquisição dos dados foi utilizado um notebook modelo Dell precision 7520 com processador Intel™ Core™ i7-6920HQ com 1 Tb de disco rígido, 32 Gb de RAM e sistema operacional Windows 10 ligado por uma conexão ethernet a um datalogger com entradas analógicas National Instruments cDaq 9178 com oito módulos, sendo quatro canais de acelerômetro (50k amostras por segundo, resolução de 24 bits), oito canais analógicos corrente/tensão (250k amostras por segundo, resolução de 16 bits) e 12 canais para extensômetros (50 k amostras por segundo, resolução de 24 bits).

Um programa para aquisição dos dados foi escrito no software "Labview" da National Instrument especificamente para controlar o processo de aquisição de dados. O programa controlava o início e o fim da aquisição de dados e escrevia os dados para um arquivo no disco rígido a cada segundo. Com esta configuração de computador e placa de aquisição de dados, a taxa de aquisição para os 13 canais de dados analógicos foi de 400 Hz.

3.4 PROCESSAMENTO DE DADOS

Os dados coletados no campo foram analisados em um computador pessoal. Outro programa foi escrito em "Labview" para realizar esta tarefa. A função deste programa era selecionar os dados apropriados para cada execução e calcular a leitura média de cada sensor durante a execução. Os dados apropriados foram selecionados cortando cada extremidade dos arquivos de dados para remover os dados medidos durante o fluxo de cana. A média foi calculada simplesmente integrando as leituras do sensor ao longo do percurso e dividindo-a pelo tempo para cada

execução. Os dados de saída desse processo foram então transferidos para ambiente Microsoft Excel. Neste, as medições de voltagem e velocidade foram convertidas em pressão do transdutor de pressão. A vazão de óleo dos sensores de velocidade do motor hidráulico, velocidade de avanço do sensor de velocidade e as leituras dos pesos foram convertidos em medições de massa e aceleração. De medições de pressão e vazão de óleo, a potência do picador e do elevador também foi calculada. A vazão mássica média também foi calculada para cada corrida dividindo-se a massa colhida pelo tempo de duração da corrida.

Uma vez os dados filtrados e sincronizados foram compostos 9 tratamentos considerando as 10 fileiras de cana-de açúcar colhidas (Tabela 3) sendo o primeiro composto por todos os sensores medidos (variáveis de entrada) e os seguintes foram estabelecidos retirando-se algum ou alguns destes e em alguns casos somente uma variável, com isso todas as combinações que são relevantes para o trabalho foram cobertas com os 9 tratamentos. Esses modelos foram treinados, testados, e após foi verificado qual deles obteve o melhor desempenho.

Tabela 3. Variáveis independentes de entrada nos modelos computacionais de estimativa de produtividade de cana-de açúcar.

Modelo	Variáveis							
	CBEE	CBED	CCEE	CCED	DR1	DR2	PE	PP
M1	X	X	X	X	X	X	X	X
M2			X	X	X	X	X	X
M3			X	X			X	
M4					X	X		X
M5					X	X		
M6							X	X
M7	X	X	X	X				
M8							X	
M9								X

Desta forma se pode verificar na Tabela 4 as variações entre os modelos de entrada (independentes), a variável de saída (dependente) e métodos de modelagem RLM (Regressão Linear Múltiplas) e RNA (Redes Neurais Artificiais) empregados neste trabalho.

Tabela 4. Nomenclatura dos modelos de predição de produtividade

Modelo	Produtividade	
	RLM	RNA
M1	RLM-1	RNA-1
M2	RLM-2	RNA-2
M3	RLM-3	RNA-3
M4	RLM-4	RNA-4
M5	RLM-5	RNA-5
M6	RLM-6	RNA-6
M7	RLM-7	RNA-7
M8	RLM-8	RNA-8
M9	RLM-9	RNA-9

Conforme apresentado anteriormente os dados utilizados pela RNA foram divididos aleatoriamente em cerca de 70 a 80% para treinamento e 20 a 30 % para validação da mesma. Seguindo indicação de NAGAOKA et al.

(2005), os mesmos grupos de dados foram utilizados para geração das funções com regressão linear múltipla (RLM) e suas respectivas validações, conforme apresentado na Tabela 5.

Tabela 5. Número de amostras utilizadas para predição da produtividade

Fileiras colhidas	Produtividade	
	Nº de amostras de treinamento e teste	Nº de amostras de validação
1	389	69
2	358	63
3	301	53
4	309	55
5	351	62
6	331	58
7	344	61
8	332	59
9	343	60

3.4.1 Aplicação de fusão dos sensores

O principal exemplo usado por muitos autores para explicar a teoria de fusão de dados multisensores é o cérebro humano. O cérebro tem a capacidade de racionalizar antes de derivar diferentes ações, baseadas em uma composição simultânea (fusão) da informação vinda de todos os sentidos. A mesma analogia do cérebro humano, a "abordagem em tempo real com sobreposição de mapas", precisa de uma fusão de sinais diferentes, de diferentes sensores simultaneamente, com dados históricos de diferentes bancos de dados, para processamento antes de derivar uma saída no controlador de campo. Portanto, o algoritmo da RNA que representa a metodologia do cérebro artificial é logicamente uma das melhores maneiras de implementar a fusão de dados multisensor a ser aplicada nesta abordagem.

Uma rede neural treinada pode ser usada como modelo de fusão de dados multisensor alternativo aplicado na abordagem em tempo real (Machado, 2018). O algoritmo de redes neurais executado em um controlador em campo pode fundir diferentes dados de diferentes fontes (dados de sensores e dados históricos), resultando em dados de produtividade confiáveis.

Neste trabalho foi utilizado um algoritmo de rede neural MLP, como formulação alternativa para fusão de dados multisensor e foi implementada nos softwares MATLAB e LABVIEW. Para modelar a produtividade por meio das RNAs, foi organizada uma planilha eletrônica com os dados coletados de todos os sensores, apresentados anteriormente, que podem representar a produtividade de maneira individual ou associado a outro sensor. Essa planilha foi importada para MATLAB para treinamento e aplicação de RNAs.

Além das variáveis de entradas (sensores observados ao longo da colhedora) o banco de dados também possuía uma variável dependente que representa a produtividade da máquina (dados do transbordo) (kg) nas condições medidas.

3.4.1.1 Algoritmo Treinamento das Redes Neurais Artificiais

O fluxograma da Figura 34 apresenta o conceito do algoritmo de fusão dos sensores.

Figura 34. Conceito do monitor de produtividade e da fusão dos sensores

Como é possível observar na Figura 34 o modelo de fusão utilizado foi o modelo com arquitetura centralizada, em que os fatores (pesos) de conversão das variáveis de entradas (sensores) na saída desejada (produtividade) são determinados pelos modelos de predição RLM e RNA apresentados na Tabela 4.

Antes de utilizar as variáveis de entrada, estas foram classificadas quanto a sua correlação com a variável de saída. As variáveis de entrada têm um impacto significativo na variável de saída e para isso existem várias técnicas de seleção das variáveis de entrada para o melhor resultado na determinação da variável de saída.

Segundo Bowden et al (2005) umas das abordagens mais comuns para definição das variáveis de entrada de uma RNA se baseiam no conhecimento de especialistas. Com isso é possível que entradas importantes, se não forem incluídas, podem ser perdidas informações importantes para predição da saída. Entretanto, se entradas com baixa correlação com a saída forem incluídas, pode confundir o processo de treinamento prejudicando o resultado da RNA. Campolo et al., 1999; Jayawardena et al., 1997; Thirumalaiah e Deo, 2000 também apresentam o uso apenas de conhecimento de um especialista para selecionar as variáveis de entrada do modelo RNA, portanto, é muito subjetiva e dependente do caso. O ideal é uma combinação de conhecimentos e uma abordagem analítica (Jayawardena et al., 1998; Maier e Dandy, 1997; Maier et al., 1998).

Algumas abordagens consideradas para avaliação das variáveis de entrada foram a regressão linear múltipla (RLM), a correlação cruzada e a *stepwise*. Os métodos de correlação cruzada representam as técnicas analíticas mais populares para selecionar entradas apropriadas. Maier e Dandy (1997) usaram o método de Haugh e Box (1977), que usa análise de correlação cruzada para determinar a força da relação entre as séries temporais de entrada e as séries temporais de saída. A principal desvantagem associada ao uso de correlação cruzada é que ela só é capaz de detectar dependência linear entre duas variáveis. Portanto, a correlação cruzada é incapaz de capturar qualquer dependência

não-linear que possa existir entre as entradas e a saída e pode resultar na omissão de entradas importantes relacionadas à saída de maneira não-linear.

O método de seleção *stepwise* é uma abordagem de seleção de variáveis de entrada (Mundry e Nunn, 2009) aplicada a modelos lineares e não lineares. Esse método seleciona quais variáveis mais influenciam o conjunto de saída podendo, assim, diminuir o número de variáveis a compor a equação de regressão (Alves et al, 2013).

O método é feito de forma iterativa, adicionando (passo forward) e removendo variáveis (passo backward), a partir de um critério de seleção. Um dos critérios de seleção mais usados é o teste F, mas também pode ser feito com o coeficiente correlação linear múltipla, erro quadrático total, critério de informação de Akaike (1976).

Olhando para a aplicação de metodologias e técnicas aplicadas até agora, observa-se que cada técnica tem seus próprios benefícios e desvantagens. Para esse trabalho, em vez de aplicar uma abordagem específica, utilizou-se de duas abordagens. Primeiro, uma seleção foi feita com base no conhecimento prévio das principais variáveis feitas pelo especialista, depois foi utilizada a regressão linear múltipla associada à correlação linear cruzada.

A Figura 35 apresenta o fluxograma detalhado do algoritmo de fusão utilizando redes neurais para aprendizado e determinação da produtividade de cada sensor. Cada conexão entre as unidades de processamento possui um peso associado. O valor desse peso é determinado no processo de aprendizagem ou treinamento da RNA. O treinamento e definição dos pesos da RNA foi realizado com o auxílio do software MATLAB. No MATLAB foram gerados 9 modelos de redes (Tabela 4), por meio da ferramenta Neural Network Tool, sendo selecionadas as cinco melhores RNAs. O Neural Network Tool permite treinar e testar automaticamente vários tipos de rede, arquiteturas, calcular as estimativas de cada uma e determinar as melhores redes.

Foram treinadas e aplicadas uma arquitetura NARX derivada de uma rede MLP. Para a rede NARX, foram atribuídas uma camada relacionada às entradas da rede, uma camada oculta com a função de ativação das camadas e diferente da MLP a NARX apresenta uma retroalimentação e um atraso. As redes foram treinadas até obterem um RE inferior a 2% e R^2 superior a 95%, sendo selecionada a rede com melhor desempenho.

Figura 35. Detalhe do algoritmo de fusão com RNA

Os dados foram divididos aleatoriamente em dois grupos para realizar o treinamento e generalização das RNAs nos dois softwares. Após a seleção dos dados, os softwares realizam a normalização dos dados, de modo a transformar cada variável numérica em um determinado intervalo de valores, tais como de 0 a 1.

Para o treinamento das redes foi utilizado um conjunto de 70% dos dados escolhidos aleatoriamente. De acordo com Tatibana e Kaetsu (2009), de 50 a 90% do total de dados já são suficientes para o realizar o treinamento. Isso permite que a RNA “aprenda” as regras e não “decore” os dados do treinamento. A outra parte dos dados pode ser utilizada para a generalização da RNA.

3.4.1.2 Generalização das redes neurais artificiais

A generalização corresponde à aplicação da RNA em um conjunto de dados que não estavam presentes no treinamento da rede, ou seja, em um conjunto de dados independente e desconhecido. A generalização das RNAs tem o objetivo de testar a capacidade das redes treinadas em produzir saídas adequadas.

Para generalização (validação) das RNAs foi utilizado um conjunto de dados aleatórios restantes, composto por 30% dos dados.

3.4.1.3 Avaliação da eficiência dos modelos RLM e RNA

Após a fase de treinamento e aplicação dos modelos de RLM e de RNA, a avaliação da eficiência dos modelos RLM e RNA, foi realizada através de estatísticas, análise gráfica dos resíduos, distribuição dos erros e gráficos de valores observados e estimados. As estatísticas empregadas para avaliar as RNAs foram a correlação entre os valores observados coeficiente de correlação de Pearson (R) e o erro quadrático médio (RMSE).

A correlação (r) (Equação 21) indica o relacionamento linear entre os valores observados e estimados, ou seja, indica o grau de associação entre essas duas variáveis. A correlação assume valores entre 0 e 1, sendo que quanto maior for o coeficiente de correlação (próximo de 1), maior é a precisão das estimativas.

$$r_{XY} = \frac{cov(X, Y)}{\sqrt{S^2(X)S^2(Y)}} \quad (21)$$

Em que:

$\hat{r}_{XY}$ = correlação;

cov = covariância;

S^2 = variância.

O coeficiente de correlação pode ser interpretado qualitativamente da seguinte forma: de 0,9 a 1,0, existe uma correlação muito forte; de 0,7 a 0,89, indica uma correlação forte; de 0,4 a 0,69 há uma correlação moderada.

A Equação 22 apresenta o RMSE que é uma soma dos quadrados das diferenças entre os valores estimados e o valor observados, ponderados pelo número de termos. Essa estatística é usualmente utilizada para comparar estimadores e indicar o quão distante, em média, o conjunto de estimativas está do parâmetro a ser estimado. Quanto menor o RMSE, melhor a precisão da estimativa.

$$RMSE = \sqrt{\frac{\sum_{i=0}^n (x_i - \hat{x})^2}{n}} \quad (22)$$

Em que:

$RMSE$ = erro quadráticos médios;

x_i = valores observados;

$\hat{x}$ = valores estimados;

n = número total de observações.

Na análise gráfica, foram elaborados gráficos de dispersão entre os valores observados e estimado para cada rede para os dados de treinamento e generalização, histograma de erros (%) e dispersão dos resíduos (%). O erro relativo de predição (RE) foi calculado pela Equação 23.

$$RE(\%) = \sqrt{\frac{\sum_{i=0}^n \left(\frac{x_i - \hat{x}}{\hat{x}} \right)^2}{n}} * 100 \quad (23)$$

Em que:

x_i = variável observada;

$\hat{x}$ = variável de saída estimada.

3.4.1.4 Aplicação da rede neural artificial

A aplicação de redes neurais teve por objetivo prever a produtividade da cana-de-açúcar. Para isso os dados obtidos com o auxílio de um transbordo instrumentados foram utilizados no aprendizado, validação e predição. Para uma mesma arquitetura foram utilizadas diferentes topologias, sendo realizadas variações nos neurônios da camada de entrada (variáveis independentes). Também foram feitas variações nos neurônios da camada oculta, e por último foram feitas variações nos neurônios de saída (variáveis dependentes).

Em relação à camada oculta, foram testadas variações na quantidade de neurônios, utilizando-se 10, 15, 20, 25 e 30 neurônios, conforme Braga (2014) a fim de verificar qual topologia gerou os melhores resultados.

O treinamento das redes neurais artificiais multicamadas foi realizado com o módulo Neural Network Toolbox, componente do software Matlab (versão R2015) fornecida pela USP, que tem implantado internamente como algoritmo de treinamento o backpropagation e como rotina de otimização a de Bayesian Regularization backpropagation. A regra de treinamento utilizada pelo módulo é o aprendizado por correção de erro.

O treinamento foi realizado alterando as variáveis de entrada e o número de neurônios na camada escondida. As variáveis independentes utilizadas nas RNA foram descritas na Tabela 3. Como os pesos são elementos iniciados com valores aleatórios, para cada treinamento se obtiveram valores diferentes.

Cada rede foi treinada 3, 4, 5, 6, 7, 8, 9, 10, 13, 15, 17, 19, 25 e 30 vezes, visto que segundo Soares (2013) não foram encontradas diferenças expressivas ao se utilizar grandes números de treinamentos. Após a realização dos treinamentos foi escolhida como melhor resultado aquela com o melhor coeficiente de determinação (R^2) entre os dados obtidos na literatura destinados a validação e os dados estimados pela simulação da Rede Neural Artificial.

3.4.2 Geração dos mapas de produtividade

A fim de representar os valores de produtividade interpolados, o modelo matemático utilizado foi a interpolação pelo inverso da distância. A interpolação pelo inverso da distância (IDW) é a mais utilizada por ser a mais simples e adequada para dados de grande densidade. Esse método localiza os pontos que estão dentro do raio utilizado e os usa para calcular o valor de um pixel (neste trabalho foram gerados pixels com 0,5x0,5 metros) e garante que os pontos mais próximos do centro do círculo tenham maior peso do que os mais distantes (GAUMITZ, 2016). A Equação 24 apresenta o modelo matemático IDW.

$$x_0 = \frac{\sum_{i=1}^n x_i \cdot d_i^{-w}}{\sum_{i=1}^n d_i^{-w}} \quad (24)$$

Em que x_0 é o valor de produtividade a ser estimado, x_i é o valor conhecido no local i dentro da vizinhança de n pontos conhecidos, d é a distância de x_0 a x_i , e w (> 0) é o coeficiente de correção expoente IDW. Quando o valor w decresce, os pesos incorporados no cálculo do x_0 são distribuídos mais uniformemente entre n vizinhos. Ao contrário, com alto valor no expoente da ponderação, a estimativa de x_0 é determinada principalmente pelos valores vizinhos próximos de x_i . A potência $w = 2$ é a mais utilizada em aplicações práticas. O interpolador com a potência 2 é um caso particular e é denominado de Inverso do Quadrado da Distância (IQD) (Collins e Bolstad, 1996).

3.5 ETAPA 3 - VALIDAÇÃO DO CONCEITO

3.5.1 Definição do ensaio de campo

O ensaio dinâmico para validação do conceito foi realizado na região de Luiz Antônio, SP (Figura 36), em área gerenciada pela usina Moreno, em três talhões de diferentes produtividades (áreas em vermelho na Figura 36), o talhão 1 com cana-de-açúcar de segundo corte, variedade RB985879 e produtividade média histórica de 100 t ha⁻¹, o talhão 2 com cana-de-açúcar de quinto corte, variedade RB985879 e produtividade média de 60 t ha⁻¹, e por fim o talhão 3 com cana-de-açúcar de primeiro corte, variedade RB985879 e produtividade média de 90 t ha⁻¹. A soma das áreas colhidas é de aproximadamente 49 ha.

Figura 36. Área da colheita em Luiz Antônio, SP

Para a validação do conceito os dados foram colhidos de maneira continua sendo as massas monitoradas pelo transbordo instrumentado.

Como os talhões 1 e 2 são estreitos eles foram segmentados conforme apresentado na Figura 36, o talhão 1 em 3 segmentos (T1a, T1b e T1c) e o talhão dois em dois segmentos (T2a e T2b), aproveitando as estradas que divide o mesmo, com isso tem se uma melhora na análise dos dados com uma imagem mais detalhada, o segmento T1c do talhão 1 foi descartado por se tratar de poucas ruas e final de talhão com muitas falhas.

Foram realizados uma análise estatística descritiva para compreensão dos dados, bem como aplicado o melhor modelo de regressão linear múltiplo (RLM-1) e o melhor modelo de redes neurais artificiais (RNA-1) e gerados mapas de produtividade com interpolação pelo inverso da distância - IDW.

4. RESULTADOS E DISCUSSÕES

4.1 RESULTADOS DA ETAPA 1

A etapa 1 teve os dados coletados no período de 21/06/2015 a 24/06/2015 na região de Santa Lúcia – SP (-21.6870057, -48.0914688). Nesta etapa foram analisados 5 sensores instalados em diferentes pontos da colhedora (pressão no corte de base e picador, deslocamento dos rolos de alimentação posteriores ao picador, carga na base e nos cilindros do elevador) avaliando a correlação que os mesmos possuíam, com isso os resultados que serão apresentados nos tópicos seguintes serviram para nortear a etapa 2.

4.1.1 Calibração dos extensômetros

A calibração foi realizada para determinar a relação de micro-deformação (μStrain) com a carga (kg). Para isso foram aplicadas cargas conhecidas no CG do elevador de 100 em 100 kg até uma carga de 500 kg, conforme Tabela 6.

Tabela 6. Dados da calibração dos sensores do elevador

Massa kg	Carga na base μStrain	Carga no Cilindro -	
		Direito μStrain	Esquerdo μStrain
100	6,9	57,0	43,8
200	13,4	114,1	93,0
300	20,8	169,7	136,8
400	26,9	231,5	186,0
500	34,9	279,7	235,2

A partir dos dados da Tabela 6, por meio destes dados é possível utilizar um fator de conversão de μStrain para massa, neste caso é $14,60 \text{ kg } \mu\text{Strain}^{-1}$ para a carga na base, $1,76 \text{ kg } \mu\text{Strain}^{-1}$ para carga no cilindro direito e $2,18 \text{ kg } \mu\text{Strain}^{-1}$ para a carga no cilindro esquerdo. O gráfico da Figura 37 apresenta as curvas de calibração obtidas com as regressões e as equações da reta.

Figura 37. Curva de calibração carga nos cilindros do elevador (CCED e CCEE) e carga na base do elevador (CB).

4.1.2 Taxa de amostragem

A aquisição dos dados foi feita com uma taxa de amostragem de 400 Hz. Para entender qual a taxa de aquisição necessária para os sensores utilizados, uma análise espectral dos sinais foi realizada. Com essa análise é possível avaliar quais componentes de frequência realmente estão atuando no sinal temporal, permitindo assim a utilização de filtros e re-amostragem do sinal.

No caso dos sinais coletados pode-se observar que todos os eventos significativos, provenientes do fluxo de massa estão abaixo de 5 Hz, conforme FFT da Figura 38b, todas as frequências que representam os fenômenos relacionados ao fluxo de massa estão abaixo de 5 HZ. O gráfico da Figura 38a apresenta um período de um dos sinais temporais coletados nas duas frequências mostrando que não existe perda de informações quando o sinal é amostrado com uma taxa de 5 z.

Essa informação é importante uma vez que o volume de dados coletados está diretamente ligado às necessidades de hardware para o processamento em tempo real para o caso da implementação do monitor de produtividade.

Figura 38. Período de um dos sinais coletados nas duas frequências mostrando a influência da taxa de amostragem, sinal temporal (a) e FFT (b).

4.1.3 Dados obtidos dos extensômetros

Como uma alternativa à utilização da balança, uma instrumentação com extensômetros configurados em ponte completa foi utilizada, pois permite à amplificação do sinal medido. Foram instrumentados o cilindro e a base do elevador, porém os dados da ponte colocada no centro não ficaram confiáveis e no processamento foi descartado. Conforme apresentado na Tabela 6 e na Figura 37, mesmo no caso da base a resolução nesta posição e da forma como foram colocados, ficou muito baixa, de aproximadamente $14,6 \text{ kg } \mu\text{Strain}^{-1}$. Além disso o ruído gerado pela vibração no elevador é muito maior que o sinal da ponte.

Para que esse sinal pudesse ser avaliado, um pós-tratamento foi realizado para remoção da vibração monitorada com um acelerômetro. Com o sinal tratado pode-se perceber (Figura 39) que existe um comportamento similar ao do deslocamento dos rolos de alimentação, o que demonstra uma correlação, porém esse método deve ser minuciosamente explorado. Para a correlação com a massa, quando se utiliza os dados de calibração com o sinal tratado, os valores obtidos não apresentam nenhuma correlação.

Figura 39. Sinais dos extensômetros na base do elevador, acelerômetro e deslocamento dos rolos de alimentação.

4.1.4 Dados de deslocamento dos rolos de alimentação e pressões

Os dados de deslocamento dos rolos de alimentação e das pressões no corte de base e no picador apresentaram correlação visual, como apresentado na Figura 40.

Figura 40. Dados de deslocamento, pressão no picador e pressão no corte de base, respectivamente

Como pode-se observar no sinal temporal da Figura 40 os três sinais Deslocamento (Azul), Pressão no Picador (Vermelho) e Pressão no corte de base (Marron), têm o mesmo comportamento temporal, o que indica uma alta correlação, uma vez que os eventos temporais estão presentes em todos eles. Porém, pode se observar que em alguns instantes o mesmo deslocamento registra diferentes pressões. Essas variações acontecem devido ao volume de massa diferente naquele instante, conforme exemplo apresentado na Figura 41.

Figura 41. Variação de massa em relação ao deslocamento

Como não existe um controle lateral, como o exercido pelos rolos transportadores fixo e móvel, a cana pode assumir infinitos volumes para um mesmo deslocamento relativo entre os rolos. Com isso é natural que o comportamento descrito pelos sinais coletados, demonstrem uma mesma pressão no picador em condições de mesmo deslocamento entre os rolos.

Além da correlação, é possível verificar o tempo em que o fluxo de massa leva do corte de base até o picador, conforme exemplo apresentado na Figura 42, bem como os tempos até a saída do elevador, a correlação destes sensores foi melhor explorada nos ensaios da etapa 2 quando os experimentos foram conduzidos com maior rigor científico e os dados apresentados utilizando estatística descritiva.

Figura 42. Defasagem de tempo do fluxo de massa entre os sensores do corte de base e picador.

4.1.5 Espacialização dos dados monitorados

Além do monitoramento dos sensores, foram coletados os dados de GNSS. Com isso foi possível espacializar os dados para avaliação subjetiva da correlação, bem como para verificação dos dados da pressão no corte de base, afim de avaliar a possibilidade de utilização destes dados para avaliação de falhas na lavoura.

A Figura 43 apresenta os dados espacializados da pressão no picador, corte de base, deslocamento no rolo transportador e micro deformação na base do elevador.

Figura 43. Espacialização dos dados coletados: pressão do picador (a); pressão no acionamento do corte de base (b); deslocamento do rolo (c); e extensômetro base (d)

Por estes mapas é possível notar que as regiões onde houve maior pressão (picador e corte de base), deslocamento e micro deformação, são comuns, refletindo a análise dos dados temporais.

Os resultados obtidos na primeira etapa deste trabalho mostram que cada técnica tem potencial, mas também problemas e limitações inerentes, tais como os sensores de pressão do corte de base e do picador são vulneráveis ao desgaste das lâminas de corte, quanto mais desgastada mais pressão o sistema precisa, com isso afeta a calibração, os sensores de carga instalados no elevador tem seus sinais afetados pela vibração do elevador, além dos impactos contra o transbordo devido a operação, sendo necessário filtrar os dados antes de utilizá-los, os sensores da base do elevador possuem baixa sensibilidade e com isso foram descartados da etapa 2. Os sensores que medem a separação dos rolos de alimentação estão suscetíveis a medição de toda massa de material (cana + terra + palha) que passa antes da limpeza no extrator primário, além disso todas essas são medidas indiretas do fluxo de massa.

4.2 RESULTADOS DA ETAPA 2

Os dados da segunda etapa foram processados e os resultados são apresentados separadamente para cada sensor utilizado. A apresentação é feita em forma de gráficos com os sinais temporais e as curvas de calibração que fornecem as constantes de calibração para a obtenção do fluxo de massa.

Para apresentação dos dados de exemplo foram utilizados os dados da colheita da primeira fileira, com 300 segundos de execução no primeiro dia de teste (12/05/2017). A colheita foi realizada a uma velocidade média variando entre 1,4 e 1,7 m s⁻¹ (5 e 6 km h⁻¹), conforme apresentado no gráfico da Figura 45, com fluxo mássico que variou entre 15 e 30 kg s⁻¹. A Figura 44 mostra que a colhedora inicia o movimento e tem a velocidade de deslocamento aumentando rapidamente para alcançar a velocidade de trabalho 1,7 m s⁻¹ na marca de 14 segundos após o início do movimento. A Figura 44 apresenta também a influência que o sistema hidráulico no sinal. Essa variação é de aproximadamente 25 BAR, valor utilizado para definir a pressão do sistema hidráulico rodando em vazio. Os dados do corte de base apresentados na Figura 44 são da fileira 1, antes de apresentar problemas, com isso esses dados não serão utilizados nas correlações e mapas nesta etapa.

Figura 44. Efeitos que influenciam nos sensores ao longo do tempo e quando a máquina está parada ou em funcionamento

Outro fator importante apresentado é que ao longo da colheita é possível observar o atraso no fluxo de massa causado pelas distâncias que cada sensor possui desde o corte de base até a saída para o transbordo. A Tabela 7 apresenta as distâncias partindo do corte de base como referência, até os principais pontos de monitoramento do fluxo de massa.

Tabela 7. Distâncias entre os sensores

Referência – Corte de base	Distância [m]
Separador dos rolos de alimentação	2,040
Pressão no picador	2,265
Pressão no elevador	6,890

A Tabela 8 e o gráfico da Figura 45 apresentam a influência destas distâncias em função da velocidade de colheita da cana-de-açúcar.

Tabela 8. Atraso entre os sensores

Velocidade [m s^{-1}]	Separador dos rolos de alimentação	Pressão no picador	Pressão no elevador
	[s]	[s]	[s]
0,5	4,1	4,5	13,8
1,0	2,0	2,3	6,9
1,5	1,4	1,5	4,6
2,0	1,0	1,1	3,4
2,5	0,8	0,9	2,8
3,0	0,7	0,8	2,3
3,5	0,6	0,6	2,0

É possível observar que quanto maior a velocidade de colheita, menor é o atraso entre os sinais dos sensores. Deduz-se que o atraso tem comportamento de uma curva exponencial tendendo a zero quando a velocidade tende a infinito.

Figura 45. Efeito da velocidade da máquina que influencia no atraso entre os sinais dos sensores

Os dados coletados na segunda etapa foram tratados utilizando estatística descritiva para compreender a correlação entre os sensores utilizados e determinar uma regressão linear para obtenção da massa de maneira indireta. Através das regressões lineares é possível determinar para cada sensor a curva de calibração, ou seja, a equação linear que determina a constante de calibração c (kg s^{-1}). A Tabela 9 apresenta os resultados médios para cada fileira, medida nas condições sem carga e nas condições colhendo.

Tabela 9. Dados obtidos nas medições de 10 fileiras de cana-de-açúcar

Fileira		MS kg s^{-1}	MT kg s^{-1}	PP Bar s^{-1}	PE Bar s^{-1}	DR1 mm s^{-1}	DR2 mm s^{-1}	CC $\mu\text{S s}^{-1}$	CB $\mu\text{S s}^{-1}$
1	Máquina parada	0,00	0,00	24,50	3,40	1,70	1,80	1,75	0,85
	Média operação	19,49	19,56	57,21	25,69	46,96	53,79	142,28	-70,70
2	Máquina parada	0,00	0,00	23,00	3,80	0,00	0,00	-1,80	-0,15
	Média operação	20,05	19,09	60,75	24,41	51,91	51,85	270,68	-12,18
3	Máquina parada	0,00	0,00	24,30	3,70	0,00	0,00	-2,16	1,47
	Média operação	23,72	24,21	74,39	27,01	39,76	44,66	262,11	-47,29
4	Máquina parada	0,00	0,00	24,80	3,80	0,00	0,00	-2,23	-0,71
	Média operação	25,05	22,14	71,54	26,08	39,38	37,43	168,22	9,18
5	Máquina parada	0,00	0,00	24,70	3,80	0,00	0,00	-1,35	-1,29
	Média operação	16,07	20,53	63,96	25,68	37,64	40,00	146,24	-39,80
6	Máquina parada	0,00	0,00	25,90	3,70	0,00	0,00	2,62	-3,59
	Média operação	17,72	20,42	74,01	25,77	43,38	38,33	85,39	-20,27
7	Máquina parada	0,00	0,00	21,90	3,70	0,00	0,00	-1,02	-2,59
	Média operação	15,67	18,67	58,26	23,84	32,58	24,38	373,70	-51,65
8	Máquina parada	0,00	0,00	25,60	3,90	0,00	0,00	-1,02	-0,55
	Média operação	21,55	19,04	74,41	26,80	54,33	30,63	121,13	29,53
9	Máquina parada	0,00	0,00	24,90	3,90	0,00	0,00	-1,85	-2,58
	Média operação	17,07	18,80	60,16	24,29	57,86	31,96	143,89	-43,33
10	Máquina parada	0	0	21,8	3,4	-	-	-	-3,54
	Média operação	21,68	22,31	74,33	28,01	-	-	-	-58,35

MS – Massa no elevador, MT – massa no transbordo, PP – pressão no picador, PE – pressão no elevador, DR1 – deslocamento no rolo 1, DR2 – deslocamento no rolo 2, CC – carga no cilindro do elevador e CB – carga na base do elevador

Utilizando os dados da Tabela 9 e aplicando uma correlação cruzada é possível compreender quais sensores possuem mais ou menos correlação com a massa e entre si. É possível observar que considerando o valor médio das 10 fileiras medidas a correlação (Tabela 10) entre a variável direta (MS) e das variáveis Indiretas (PP, PE, DR1, DR2) é muito boa em com r maior que 0,95. Já os dados da variável CC ($r=0,836$) tem uma correlação boa, porém conforme apresentado na avaliação dos dados da Etapa 1 a correlação dos dados da carga na base do elevador (CB) a correlação inferior a 0,60.

Tabela 10. Resultados dos valores de r (correlação cruzada)

	MT	MS	PP	PE	DR1	DR2	CC	CB
MT	1,000	0,987	0,984	0,996	0,950	0,952	0,836	-0,575
MS	0,987	1,000	0,980	0,985	0,949	0,946	0,812	-0,487
PP	0,984	0,980	1,000	0,984	0,940	0,912	0,772	-0,467
PE	0,996	0,985	0,984	1,000	0,966	0,951	0,822	-0,560
DR1	0,950	0,949	0,940	0,966	1,000	0,932	0,756	-0,450
DR2	0,952	0,946	0,912	0,951	0,932	1,000	0,775	-0,569
CC	0,836	0,812	0,772	0,822	0,756	0,775	1,000	-0,576
CB	-0,575	-0,487	-0,467	-0,560	-0,450	-0,569	-0,576	1,000

A Figura 46 apresenta os dados brutos obtidos no transbordo durante a coleta de dados da segunda fileira em preto, e os dados filtrados em vermelho sem um ponto por segundo, e uma escala de fluxo de massa no transbordo

em kg s^{-1} , sendo que a taxa média para essa fileira foi de aproximadamente 20 kg s^{-1} , com isso é possível verificar a influência da vibração em função da massa no transbordo, para a aplicação dos modelos de RLM e RNA os dados utilizados foram os dados filtrados.

Figura 46. Sinal temporal do fluxo de massa (kg s^{-1}) no transbordo

A Figura 47a apresenta um sinal temporal típico da medição da pressão no picador e é possível notar que a pressão em vazio (instante 0 s a 50 s), ou seja, sem carga, fica em torno de 20 a 40 bar e que em trabalho durante a colheita a pressão média fica em torno de 60 a 80 bar. Esses dados são claramente observados no gráfico da regressão das médias da colheita Figura 47b, que também apresenta a equação linear com R^2 de 0,968.

Figura 47. Sinal temporal da pressão no picador – dados da Fileira 2 (a); curva de calibração do sensor de pressão do picador – obtida com a média das 10 fileiras medidas (b)

A Figura 48a e c apresenta sinais temporais típicos da medição dos deslocamentos dos rolos de alimentação 1 e 2, respectivamente, e é possível notar que no deslocamento em vazio (instante 0 s a 60 s), sem carga, ficam zerados, pois não há cana passando pelo sistema de alimentação da máquina. Em trabalho, durante a colheita, o deslocamento médio fica em torno de 60 a 80 mm, chegando em alguns instantes a 150 mm, que é a máxima abertura dos rolos.

Esses dados são claramente observados no gráfico da regressão das médias da colheita (Figura 48b e d) que também apresenta, a equação linear dos rolos 1 e 2, respectivamente, com R^2 de 0,902 e 0,907.

Figura 48. Sinal temporal no separador dos rolos alimentadores 1 – dados da Fileira 2 (a); curva de calibração do separador dos rolos alimentadores 1 – obtida com a média das 09 fileiras medidas (b); sinal temporal no separador dos rolos alimentadores 2 – dados da Fileira 2 (c); curva de calibração do separador dos rolos alimentadores 2 – obtida com a média das 09 fileiras medidas (d)

A Figura 49a apresenta um sinal temporal típico da medição da carga no cilindro do elevador e é possível notar que a carga em vazio (instante 0 s a 50 s) fica zerada apenas com o ruído da vibração do elevador e que em trabalho, durante a colheita, a carga média fica em torno de 300 μ strain. Esses dados são claramente observados no gráfico da regressão das médias da colheita (Figura 49b) que também apresenta, a equação linear com R^2 de 0,6984.

Figura 49. Sinal temporal de cargas no cilindro do elevador – dados da Fileira 2 (a); curva de calibração das cargas do cilindro do elevador – obtida com a média das 09 fileiras medidas (b)

A Figura 50a apresenta um sinal temporal típico da medição da pressão no elevador e é possível notar que a pressão em vazio (instante 0 s a 50 s), sem carga, fica em torno de 5 a 10 bar e que em trabalho durante a colheita, a pressão média fica em torno de 20 a 40 bar. Esses dados são claramente observados no gráfico da regressão das médias da colheita (Figura 50b), que também apresenta a equação linear com R^2 de 0,993.

Figura 50. Sinal temporal da pressão no elevador – dados da Fileira 2 (a); curva de calibração da pressão no elevador – obtida com a média das 10 fileiras medidas (b)

A Figura 51a apresenta um sinal temporal típico da medição da massa de cana que passa no elevador. Neste sistema, como os dados foram coletados direto no monitor Simprocana, não são coletados enquanto a máquina está parada ou com o elevador desligado. Com isso, os dados já partem da condição de trabalho e o valor médio fica em torno de 30 a 50 kg, esses dados são claramente observados no gráfico da regressão das médias da colheita (Figura 51b), que também apresenta a equação linear com R^2 de 0,975.

Figura 51. Sinal temporal da balança no elevador – dados da Fileira 2 (a); curva de calibração da balança no elevador – obtida com a média das 10 fileiras medidas (b)

Uma vez apresentado um exemplo do sinal temporal de cada sensor utilizado, bem como sua curva de calibração, a Tabela 11 apresenta uma síntese das curvas. Esses valores apresentados se referem à constante de calibração que foi utilizada para determinação do fluxo de massa em cada ponto de monitoramento da máquina.

Tabela 11. Dados das Regressões Lineares para cada sensor monitorado

Sensor	Equação Linear		
	Intercessão, a	Inclinação, m	R^2
Simprocana	0,287 kg	1,005 kg/ (kg/s)	0,975
Separador dos rolos de alimentação	0,278 mm	1,917 mm/ (kg/s)	0,907
Carga nos cilindros do elevador	0,5345 uS	9,300 uS/ (kg/s)	0,698
Pressão no picador	24,056 Bar	2,097 Bar/ (kg/s)	0,968
Pressão no elevador	3,795 Bar	1,068 Bar/ (kg/s)	0,992

É possível observar na Tabela 11 que os sensores apresentam elevado valor de R^2 , exceto o sensor do cilindro do elevador. Embora esses dados tenham uma boa correlação com a produtividade, variam muito em virtude da calibração. Jensen (2013) cita que a maior dificuldade na utilização isolada destes sensores é que se não forem calibrados frequentemente o erro vai aumentando ao ponto de os dados não serem mais confiáveis. Por isso o objetivo deste trabalho foi utilizar a fusão dos vários sensores que possuem uma boa correlação com a produtividade, associado a uma rede neural treinada para se auto calibrar, minimizando os erros periodicamente, pois as RNA se adaptam e com isso não é necessário o inconveniente do processo de calibração frequente.

4.3 PREDIÇÃO DA PRODUTIVIDADE DA CANA-DE-AÇÚCAR UTILIZANDO RLM

Esta seção apresenta os resultados estimados de produtividade da cana-de-açúcar, obtidos por meio de Regressão Linear Múltiplas (RLM). Para tanto foram testadas nove RLM's, cada uma dessas compostas de diferentes entradas (Tabela 3), tendo como saídas a produtividade da cana-de-açúcar. Para essa avaliação foram utilizados os dados dos sensores medidos na segunda etapa, sendo considerado ponto a ponto de cada sensor do início ao fim da fileira e comparando os dados dos sensores (variáveis independentes) e o fluxo de massa medida no transbordo.

4.3.1 Correlação entre os sensores

Os valores obtidos para indicar as correlações entre os sensores (variáveis independentes ou de entrada nos modelos) e o indicador de fluxo de massa no transbordo (variáveis dependentes) são apresentados na Tabela 12. Estes sensores, instalados em diversas partes da máquina, são influenciados pelo fluxo de massa. Desta forma, suas correlações com a variável dependente, indicam o quanto cada um dos sensores está ligado, de forma linear, no fluxo de massa medida pelo transbordo, que por sua vez está ligado à produtividade de cana-de-açúcar.

Tabela 12. Correlação cruzada (r) entre as variáveis independentes e dependentes

	MT	PP	PE	DR1	DR2	CB	CC
MT	1,000	0,489	0,560	0,278	0,271	0,017	0,138
PP	0,489	1,000	0,484	0,379	0,393	-0,103	0,225
PE	0,560	0,484	1,000	0,177	0,228	-0,042	0,134
DR1	0,278	0,379	0,177	1,000	0,486	-0,082	0,185
DR2	0,271	0,393	0,228	0,486	1,000	-0,116	0,181
CB	0,017	-0,103	-0,042	-0,082	-0,116	1,000	-0,489
CC	0,138	0,225	0,134	0,185	0,181	-0,489	1,000

O coeficiente de correlação de Pearson (r) indica a relação linear (força e direção) entre as duas variáveis e pode variar de 0 a 1 ou 0 a -1, sendo que 0 (zero) indica que não há relação linear, 1 indica uma relação linear perfeita e -1 indica uma relação linear perfeita, porém inversa, ou seja, enquanto uma das variáveis cresce a outra decresce (SILVA, 2003). Sendo assim, quanto mais próximo os valores de r estiverem de 1 e/ou -1, mais forte é a associação linear entre as duas variáveis.

Os dados da Tabela 12 apresentam as correlações dos dados temporais medidos, e é possível notar que os sensores de pressão são os que melhor tem correlação com o fluxo de massa no transbordo (MT), sendo 0,489 e 0,560

para pressão no picador e pressão no elevador. Os demais sensores, isoladamente, apresentam baixa correlação temporal com o fluxo de massa no transbordo (MT), sendo encontrados valores de r abaixo de 0,30, e conforme observado em todas as análises realizadas neste trabalho, o sensor na base do elevador não é representativo, com r de 0,017.

A Tabela 13 apresenta os valores de correlação r para os modelos de RLM simulados e é possível verificar que neste caso a melhor correlação foi encontrada no modelo RLM-1, onde se utiliza todos os sensores, com r de 0,628. Porém o modelo RLM-2, que retira os dados do sensor da base do elevador, apresenta um valor de r de 0,622, a influência dos dados do sensor na base do elevador na correlação linear múltipla é muito pequena, confirmando a hipótese de que ele não contribui para a determinação do fluxo de massa do transbordo e, por sua vez, da produtividade da cana-de-açúcar.

Tabela 13. Coeficiente de correlação r para os modelos de RLM

Modelo	Correlação r
RLM-1	0,628
RLM-2	0,622
RLM-3	0,563
RLM-4	0,502
RLM-5	0,319
RLM-6	0,613
RLM-7	0,169
RLM-8	0,489
RLM-9	0,560

4.3.2 Modelos de RLM

A Tabela 14 apresenta os coeficientes encontrados para cada modelo de RLM para a estimativa do fluxo de massa de cana-de-açúcar observada no transbordo com seus respectivos coeficientes de determinação (R^2). Observa-se que as variáveis com contribuição significativa para a estimativa da MT foram as pressões no picador e no elevador, sendo que a PE foi a variável que apresentou maior contribuição ao modelo, com valor de R^2 individual 0,312. Esse valor está de acordo com o resultado da correlação apresentado na Tabela 12, onde a PE teve correlação superior com o fluxo de massa do transbordo.

Dos nove modelos de RLM propostos, o primeiro (RLM-1) contempla todos os sensores medidos e os modelos seguintes, até o RLM-9, com apenas uma variável. A equação de predição obtida pela RLM que teve o melhor ajuste para o fluxo de massa do transbordo foi para o modelo RLM-1, que utiliza todos os sensores medidos, e apresentou coeficiente de determinação R^2 de 0,386, RMSE de 1,599 kg s⁻¹ e RE de 4,91%. Na Tabela 14, estão apresentadas as constantes e as estimativas dos coeficientes das variáveis formando as respectivas equações. O modelo RLM-2, que retira os dados da carga na base do elevador (CB), apresentou coeficiente de determinação R^2 de 0,380,

RMSE de $1,606 \text{ kg s}^{-1}$ e RE de 4,91%, que é muito próximo do modelo anterior, sendo este o modelo que foi utilizado para validação da RLM.

Entretanto, mesmo com a correlação e o R^2 mostrando haver maior relação entre o modelo que utiliza as variáveis de pressão no picador e no elevador, o valor de R^2 obtido pelo melhor modelo RLM-1 (0,386), é inferior a 50% de determinação. Isso demonstram que o modelo gerado a partir de todo o banco de dados não foi eficiente para estimativa do fluxo de massa observada no transbordo (MT), o que pode ser comprovado pela grande dispersão dos pontos na comparação dos dados medidos e estimados pelo modelo (Figura 52a).

Tabela 14. Coeficientes das equações de regressão linear múltipla e de determinação para estimativa do fluxo de massa observada no transbordo

Modelo	Constante β_0	Coeficientes						R^2 ajustado	RMSE (kg s^{-1})	RE (%)	F SIGN
		PP [bar]	PE [bar]	DR1 [mm]	DR2 [mm]	CB [μStrain]	CC [μStrain]				
RLM-1	-11,529	0,084	0,287	0,010	0,003	0,028	0,011	0,386	1,599	4,91	0,0000
RLM-2	-12,712	0,084	0,289	0,010	0,003	-	0,001	0,380	1,606	4,91	0,0000
RLM-3	-10,462	-	0,379	-	-	-	0,013	0,314	1,690	6,30	0,0000
RLM-4	-6,243	0,155	-	0,009	0,004	-	-	0,247	1,771	5,40	0,0000
RLM-5	3,842	-	-	0,020	0,013	-	-	0,098	1,938	7,25	0,0000
RLM-6	-13,243	0,102	0,290	-	-	-	-	0,373	1,616	5,14	0,0000
RLM-7	4,852	-	-	-	-	0,032	0,040	0,024	2,016	8,80	0,0014
RLM-8	-6,879	0,175	-	-	-	-	-	0,237	1,782	5,66	0,0000
RLM-9	-9,598	-	0,385	-	-	-	-	0,312	1,693	6,50	0,0000

Os modelos RLM-1, RLM-2, RLM-3, RLM-6 e RLM-9 apresentaram R^2 acima de 30% e RMSE menor que 2 kg s^{-1} , porém somente os modelos RLM-1 e RLM-2 apresentaram valor de RE menores que 5%. Já os modelos RLM-4, RLM-5, RLM-7 e RLM-8 tiveram resultados de R^2 muito baixos, com RMSE acima de 2 kg s^{-1} e RE acima de 5%. O pior modelo foi o RLM-7, que utiliza os dados das cargas medidas com extensômetros no cilindro e na base do elevador, com R^2 de 0,024, RMSE $2,016 \text{ kg s}^{-1}$ e RE 8,8%, mostrando que esse modelo não tem relação com o fluxo de massa observada no transbordo. A Equação 24 apresenta a equação do melhor modelo de predição o RLM-1.

$$M_{\text{Testimado}} = -11,529 + 0,084.PP + 0,287.PE + 0,01.DR1 + 0,003.DR2 + 0,028.CB + 0,011.CC \quad (24)$$

Os gráficos da Figura 52 apresentam os valores do fluxo de massa no transbordo observados (medidos) em relação aos estimados por regressão linear múltipla nos modelos propostos. Nestes gráficos é possível verificar que existe uma grande concentração de pontos entre os valores de 0 a 30 kg s^{-1} , e alguns pontos acima dessa faixa, chegando a 60 kg s^{-1} . Esses valores mais altos são valores encontrados em situações em que o elevador está desligado e a máquina inicia a colheita e só após alguns instantes, após o bojo do elevador estar cheio, que o elevador inicia o transporte da cana. Com isso é possível visualizar esse pico no fluxo de massa no transbordo e no sinal da pressão no elevador.

Figura 52. Representação gráfica dos valores do fluxo de massa no transbordo observados (medidos) em relação aos estimados por regressão linear múltipla nos modelos propostos para a primeira fileira.

4.4 TREINAMENTO, TESTE E VALIDAÇÃO DA RNA PARA PREDIÇÃO DA PRODUTIVIDADE DA CANA-DE-AÇÚCAR

Esta seção apresenta os resultados estimados de produtividade da cana-de-açúcar, obtidos através de Redes Neurais Artificiais (RNA). Para tanto foram testadas nove RNA, cada uma dessas composta de diferentes entradas (Tabela 3), tendo como saída a produtividade da cana-de-açúcar. A arquitetura entre elas foi a mesma (Nonlinear Autoregressive with External Input - NARX) com uma camada oculta na rede), sendo modificada somente a topologia dessas redes. Cada topologia utilizada variou além das variáveis independentes de entrada e as variáveis dependentes de saída, além do número de neurônios da camada escondida (10, 15, 20 e 25 neurônios), o algoritmo gerado para a RNA pode ser visto no apêndice A.

A Tabela 15 apresenta a correlação r , o coeficiente de determinação R^2 , o erro RMSE e o erro RE para cada modelo de RNA utilizado para a estimativa do fluxo de massa de cana-de-açúcar observada no transbordo. Dos nove modelos de RNA propostos, sendo o primeiro (RNA-1) o que contempla todas os sensores medidos e os modelos seguintes até o RNA-9, com apenas uma variável, o que teve o melhor ajuste para o fluxo de massa do transbordo com foi o modelo RNA-1. Esse modelo apresentou coeficiente de determinação R^2 de 0,974, RMSE de 0,287 kg s⁻¹ e RE

de 0,73%. O modelo RNA-2 que retira os dados da carga na base do elevador (CB) apresentou coeficiente de determinação R^2 de 0,952, RMSE de 0,413 kg s⁻¹ e RE de 0,82%, sendo o segundo melhor modelo encontrado.

É possível notar que todos os modelos analisados apresentaram R^2 superiores a 80% senão que a maioria superior a 90% de determinação, demonstrando que os modelos gerados a partir de todo o banco de dados, foram eficientes para estimativa do fluxo de massa observada no transbordo (MT), o que pode ser comprovado pela grande dispersão dos pontos na comparação dos dados medidos e estimados pelo modelo (Figura 53).

Tabela 15. Coeficientes r , determinação R^2 , erro quadráticos médios (RMSE) e erro relativo (RE) das RNA

Modelo	Correlação r	R^2 ajustado	RMSE (kg s ⁻¹)	RE (%)
RNA-1	0,987	0,974	0,287	0,73
RNA-2	0,975	0,952	0,413	0,82
RNA-3	0,957	0,917	0,522	2,38
RNA-4	0,966	0,933	0,460	1,27
RNA-5	0,955	0,911	0,528	1,00
RNA-6	0,970	0,942	0,425	1,62
RNA-7	0,933	0,870	0,671	1,21
RNA-8	0,946	0,894	0,568	1,23
RNA-9	0,937	0,878	0,610	2,45

De acordo com a Tabela 15, a rede que apresentou os melhores parâmetros estatísticos foi a RNA-1, que contém seis variáveis de entrada, 15 neurônios na camada oculta e um neurônio de saída (fluxo de massa no transbordo - MT). Nesta RNA 98,7% dos resultados do fluxo de massa são explicados pelas variáveis independentes contidas no modelo, com baixos valores de erro. Foram testadas redes variando o número de neurônios da camada oculta e se observou que se aumentar muito o número de neurônios, o coeficiente de determinação é reduzido e os valores de erro são aumentados, ou seja, quando o número de neurônios na camada oculta é variado, reduz-se a precisão da previsão e o erro desta aumenta, gerando valores não representativos bem como aumentando o tempo computacional. A adição da camada oculta torna a rede capaz de extrair estatísticas de ordem elevada, ou seja, a rede adquire uma perspectiva global (BISHOP, 2008), porém o número de nós por camada só é obtido por meio de várias tentativas e verificação dos parâmetros estatísticos.

A Figura 53 apresenta os gráficos de dispersão dos nove modelos de RNA. É possível notar que todos os modelos testados são determinísticos, podendo prever o fluxo de massa de cana-de-açúcar que está passando pela máquina, favorecendo a fusão dos sensores em conjunto com os modelos de redes neurais para determinação do fluxo de massa e posteriormente da produtividade. Outro fator importante observado é que mesmo com sensores pouco significativos o sistema se adapta e a predição é confiável como se vê no modelo da RNA-2, em que o sensor da base do elevador é suprimido e a predição permanece com um erro RE de 0,82%. Essa flexibilidade da junção de fusão de sensores mais redes neurais artificiais possibilita que o sistema se auto ajuste e calcule o fluxo de massa independente de ter todos os sensores funcionando, sendo este suprimido da interação quando apresentar erro superior a 2%, conforme proposto no conceito apresentado na Figura 34, é importante notar que neste caso o algoritmo da RNA elimina os 3 primeiros valores para o cálculo de *feedback*.

Figura 53. Representação gráfica dos valores do fluxo de massa no transbordo observados (medidos) em relação aos estimados pela RNA nos modelos propostos para a primeira fileira.

4.5 IDENTIFICAÇÃO DE FALHAS NA LAVOURA DE CANA-DE-AÇÚCAR

Conforme apresentado na Figura 29, outra avaliação realizada na etapa 2 foi a verificação da capacidade de se identificar falhas na lavoura utilizando os mesmos sensores testados para produtividade. Com isso quatro falhas ao longo da fileira com comprimento de aproximadamente um metro, as mesmas foram produzidas manualmente em cinco fileiras (Figura 30) e georreferenciadas conforme pontos amarelos apresentados na Figura 54.

Figura 54. Falhas georreferenciadas – Pontos amarelos

Para a verificação da presença dessas falhas foram avaliados os sinais temporais, buscando padrões de baixa nos valores medidos pelos sensores, bem como a relação espacial dos dados medidos com as coordenadas das falhas. Para essa avaliação o sensor do corte de base é um dos principais para a identificação dessas falhas, uma vez que o mesmo está ligado ao primeiro contato que a máquina tem com a soqueira, e a pressão medida neste sistema está diretamente ligada com o volume de massa que o mesmo está cortando.

Os demais sensores funcionaram normalmente e é possível visualizar na Figura 55 todos os sinais medidos plotados juntos (ênfase no quadrado verde separando duas falhas que são identificadas pelas duas elipses verdes), e a presença de quatro pontos bem definidos de queda nos valores medidos para níveis próximos aos encontrados quando o sistema está em vazio. Isso demonstra que existe uma relação entre os sinais e as falhas produzidas. A Figura 55a apresenta os sinais dos sensores de pressão do picador e do elevador e como base o fluxo de massa obtida no transbordo, que também apresenta uma queda no incremento do fluxo de massa nestes instantes. Já a Figura 55b apresenta os dados dos sensores de deslocamento dos rolos que tem os mesmos pontos presentes nos sensores de pressão e transbordo. A Figura 55c apresenta os dados dos sensores de carga na base do elevador e nos cilindros. O sinal do cilindro apresenta as falhas já o sinal da base do elevador só apresenta duas das quatro falhas produzidas, devido à baixa sensibilidade deste sensor a pequenas variações no fluxo de massa.

Figura 55. Sinais temporais da primeira fileira com falhas produzidas manualmente comparando os dados do transbordo (MT) com os sensores de pressão do picador (PP) e do elevador (PE) (a); sensores de deslocamento dos rolos (DR1 e DR2) (b); sensores de carga na base (CB) do elevador e nos cilindros (CE) (c)

Uma vez identificado a existência das falhas nos sinais temporais foi feita a análise espacial para verificar se esses eventos estão localizados nas mesmas coordenadas das falhas georreferenciadas. É possível visualizar na Figura

56 as cinco fileiras com os dados do fluxo de massa obtida no transbordo e os pontos das falhas. Já a Figura 57 apresenta os dados obtidos pelos diferentes sensores.

Figura 56. Mapa dos pontos medidos e falhas

É possível observar que os pontos de baixa identificados no sinal temporal (Figura 55) estão diretamente relacionadas às falhas georreferenciadas. Com isso é possível determinar e registrar as falhas na lavoura com o auxílio destes sensores.

Figura 57. Mapa de falhas por sensor: dados do fluxo de massa do transbordo (a); dados da pressão no picador (b); dados da pressão no elevador (c); dados dos deslocamentos nos rolos de alimentação 1 (d); dados dos deslocamentos nos rolos de alimentação 2 (e); dados de carga na base do elevador (f); dados das cargas no cilindro do elevador (g)

4.6 MAPAS DE PRODUTIVIDADE – COMPARATIVO DOS MODELOS DE PREDIÇÃO

Para fins de comparação somente foram apresentados e discutidos os mapas de produtividade para os modelos que apresentaram melhores resultados nos métodos de predição apresentados anteriormente os demais mapas gerados pelos demais modelos e para os sensores individuais foram colocados no apêndice B. A Figura 58 apresenta os mapas gerados utilizando a interpolação IDW, para os dados obtidos do transbordo (Figura 58a), produtividade calculada pelo modelo de regressão linear múltipla RLM-1 (Figura 58b), produtividade calculada pelo modelo de

regressão linear simples RLM-8 que utiliza somente os dados de pressão do picador (PP) (Figura 58c), produtividade calculada pelo modelo de regressão linear simples RLM-9 que utiliza somente os dados de pressão do elevador (PE) (Figura 58d) e pôr fim a produtividade calculada utilizando o modelo RNA-1 (Figura 58e). É possível notar que em todos os modelos as falhas produzidas são visualizadas, sendo mais acentuadas nos modelos RLM-1 e RNA1. No entanto, o mapa de pontos representa as falhas de forma mais adequada preservando a resolução original dos dados.

Figura 58. Mapas de produtividade comparando os modelos de predição com dados obtidos do transbordo (a); produtividade calculada pelo modelo de regressão linear múltipla RLM-1 (b); produtividade calculada pelo modelo de regressão linear simples RLM-8 (c); produtividade calculada pelo modelo de regressão linear simples RLM-9(d) e a produtividade calculada utilizando o modelo RNA-1 (e)

Para entender a eficiência dos modelos aplicados nos mapas da Figura 58 foram gerados mapas que representam o erro relativo (RE) entre os modelos de predição e a produtividade do transbordo, que é apresentado na Figura 59. É possível observar que os modelos RLM apresentam erros RE superiores a 2%.

Figura 59. Erro relativo (RE) entre os modelos de predição e a produtividade do transbordo, sendo mapa do modelo RNA-1 (a); mapa do modelo RLM-1 (b); mapa do modelo RLM-8 (c) e mapa do modelo RLM-9 (d)

4.7 RESULTADOS DA ETAPA 3

A etapa 3 foi utilizada para validação dos modelos desenvolvidos na etapa 2, com isso os três talhões colhidos foram submetidos aos três tratamentos simulando o processamento do monitor de produtividade. A Figura 60 apresenta o mapa de produtividade gerado com os dados do transbordo. É possível notar que os talhões 1 e 3 por se tratarem de talhões novos de segundo e primeiro corte respectivamente, tem a produtividade mais homogênea. Já o talhão 2 por se tratar de um talhão de quinto corte apresenta bastante falhas e uma produtividade baixa.

Figura 60. Mapas de produtividade dos três talhões colhidos na etapa 3, sendo talhão 1 – T1a (a), talhão 1 – T1b (b), talhão 2 – T2a (c), talhão 2 – T2b (d) e talhão 3 (e)

A Tabela 16 apresenta os dados estatísticos referentes aos dados dos três talhões, com base nas medições do transbordo.

Tabela 16. Estatística descritiva dos dados de produtividade para os três talhões

Dados	n	Média	Mín.	Med.	Máx.	Desvio	Variância	CV %	Ass.	Cur.
Mg ha ⁻¹										
Área 1										
MT	8684	79,00	38,70	79,20	209,00	11,13	123,85	14,09	0,59	12,26
RLM1	8684	73,50	43,69	73,29	102,25	3,27	10,72	4,45	-0,96	15,63
RNA1	8684	78,99	31,16	79,18	225,17	10,84	117,47	13,72	0,73	15,18
Área 2										
MT	12159	44,05	0,27	44,34	104,69	14,13	199,69	32,08	-0,31	0,04
RLM1	12159	43,14	7,81	43,84	74,11	8,82	77,78	20,02	0,05	-0,22
RNA1	12159	43,98	0,65	44,30	100,46	13,41	179,74	30,44	-0,43	0,01
Área 3										
MT	22224	61,11	2,60	62,40	126,10	12,42	154,16	20,32	-0,31	0,81
RLM1	22224	65,26	16,00	66,00	96,00	9,16	83,86	14,03	-0,59	1,08
RNA1	22224	61,09	10,67	60,55	119,32	6,62	43,85	10,84	0,38	0,60

n – número de pontos; Mín. – valor mínimo; Med. – valor da mediana; Máx. – valor máximo; Desvio - desvio padrão; CV – coeficiente de variação; Ass. – assimetria; Cur. – curtose. MT – dados do transbordo; RLM-1 – dados da regressão linear múltipla; RNA-1 – dados da rede neural artificial.

É possível notar que o coeficiente de variação indica que os dados apresentados nas áreas 1 e 3 são homogêneos, e os dados da área 2 que é a área com maior variabilidade na produtividade, por se tratar de um talhão mais antigo de baixa produtividade.

Já a Tabela 17 apresenta os dados dos modelos propostos RLM-1 e RNA-1 e os erros RSME e RE comparando os dados do transbordo.

Tabela 17. Erros entre os modelos comparando com a produtividade a partir do transbordo

Área	Modelo	RMSE (Mg ha ⁻¹)	RE (%)
1	RLM-1	13,075	1,80
	RNA-1	3,720	0,54
2	RLM-1	11,041	15,72
	RNA-1	4,481	1,61
3	RLM-1	6,804	1,65
	RNA-1	10,544	1,78

É possível notar que nas áreas em que a produtividade é mais homogênea os dois modelos apresentaram RE menor que 2%, já na área 2 o modelo RLM-1 ficou com o RE de 15,72% enquanto o modelo RNA-1 manteve o erro menor que 2% na predição da produtividade da área.

Os mapas apresentados na Figura 61 são referentes à produtividade do talhão 1 para os dados do transbordo e calculada pelos modelos propostos RNA-1 e RLM-1. É possível notar nas Figura 61b e Figura 61e o modelo RLM-1 não apresenta os dados de baixa produtividades das bordas do talhão, apresenta uma faixa de alta produtividade que não é apresentada nos dados do transbordo. Já o modelo RNA-1 (Figura 61c e Figura 61f) reproduz a produtividade e as falhas encontradas no talhão 1, refletindo o baixo valor do erro RE apresentado na Tabela 17.

Figura 61. Produtividade do talhão T1a (a, b e c), sendo os dados obtidos do transbordo (a); produtividade calculada pelo modelo de regressão linear múltipla RLM-1 (b); produtividade calculada utilizando o modelo RNA-1 (c); Produtividade do talhão T1b (d, e e f); sendo os dados obtidos do transbordo (d pelo modelo de regressão linear múltipla RLM-1 (e) e a produtividade calculada utilizando o modelo RNA-1 (f)

O talhão dois possui uma grande variabilidade da produtividade, apresentando manchas de baixa produtividade conforme apresentado na Figura 62a. Esse comportamento ocorre em virtude de ser um talhão de quinto corte ele possui muitas falhas; também, devido a um incêndio acidental no lado direito do talhão a cana-de-açúcar estava queimada. Os mapas apresentados na Figura 62 são referentes à produtividade do talhão 2 para os dados do transbordo é calculada pelos modelos propostos RNA-1 e RLM-1. No talhão 2 é possível notar o mesmo comportamento do talhão 1. O modelo de regressão linear múltipla ressalta uma alta produtividade na Figura 62b que não consta nos dados originais do transbordo, bem como suprime falhas de baixa produtividade na Figura 62e. O modelo RNA-1 apresenta algumas suaves divergências quando se observa a Figura 62f acentuando as falhas, comparado com o mapa do transbordo da Figura 62d.

Os mapas apresentados na Figura 63 são referentes à produtividade do talhão 3 para os dados do transbordo, calculada pelos modelos propostos RNA-1 e RLM-1. No talhão 3 o modelo RLM-1 apresentou uma boa correlação assim como o modelo RNA-1. Os dois modelos apresentaram erro RE menor que 2% e pela Figura 63 é possível ver que os modelos não apresentaram grandes discrepâncias como as observadas no talhão 1 e 2.

Figura 62. Produtividade do talhão T2a (a, b e c), sendo os dados obtidos do transbordo (a); produtividade calculada pelo modelo de regressão linear múltipla RLM-1 (b); produtividade calculada utilizando o modelo RNA-1 (c); Produtividade do talhão T2b (d, e e f); sendo os dados obtidos do transbordo (d pelo modelo de regressão linear múltipla RLM-1 (e) e a produtividade calculada utilizando o modelo RNA-1 (f)

Figura 63. Produtividade do talhão T3, sendo os dados obtidos do transbordo (a); produtividade calculada pelo modelo de regressão linear múltipla RLM-1 (b); produtividade calculada utilizando o modelo RNA-1 (c)

Os resultados obtidos no presente trabalho mostram a capacidade de predição da produtividade da cana-de-açúcar utilizando diversos tipos de sensores ao longo da colhedora, e que esses sensores individualmente têm

potencial de predição, porém com limitações, de forma que os modelos baseados na fusão de vários sensores para obtenção da produtividade foram os que tiveram os melhores resultados. Além da fusão dos modelos analisados (RLS, RLM e RNA), os modelos baseados em rede neurais (RNA) apresentaram os melhores resultados de predição, se mostrando uma promissora abordagem de análise de dados de diversos sensores. Existem outros tipos de algoritmos de predição como por exemplo a lógica Fuzzy, que não foram aqui analisados, mas que em estudos aplicados em outras culturas também apresentaram bons resultados de predição.

De maneira geral esse trabalho trouxe uma nova abordagem quanto aos dados de produtividade bem como do processamento destes dados para uma nova geração de monitores de produtividade, inclusive com o registro de patente de uma solução proposta para a AGCO em julho de 2018, sob o número 62698338.

5. CONCLUSÃO

Observa-se que existem diversas alternativas para se instrumentar e obter dados de forma indireta, que estão diretamente ligados ao fluxo de massa de uma colhedora de cana-de-açúcar. Em particular, os sensores utilizados neste trabalho são facilmente encontrados no mercado local. Dos sete pontos instrumentados, cinco já foram estudados anteriormente e alguns já possuem propostas comerciais em monitores de produtividade. Somente os sensores de carga na base do elevador e nos cilindros do elevador ainda não haviam sido utilizados em pesquisas anteriores. Desses dois sensores de carga instalados na base e no cilindro do elevador, o que apresentou melhor correlação com o fluxo de massa foi o do cilindro, que tem potencial de integrar o sistema para compor o monitor de produtividade. Os sensores de pressão nos três pontos avaliados e os sensores de deslocamento têm boa correlação com o fluxo de massa.

Esses sensores isoladamente não seriam boas fontes de predição de produtividade, embora tenham dado origem a mapas que expressam, de forma geral, a variabilidade presente nos talhões. Porém, quando utilizado o método de fusão associado à inteligência artificial, com os métodos de redes neurais, obteve-se modelos que resultam em erros inferiores a 2%.

Além da produtividade constatou-se que é possível identificar as falhas na lavoura através dos dados coletados e das falhas produzidas manualmente. Todos os sensores medidos apresentaram queda nos valores nas mesmas coordenadas das falhas, porém os de carga no elevador não ofereceram sensibilidade suficiente para essa identificação.

Com relação aos modelos implementados e utilizados, aqueles baseados em regressão linear múltipla não apresentaram potencial na integração e predição da produtividade satisfatórios, ou seja, com os valores de erros superiores aos definidos nas premissas do trabalho que é inferior a 2%. Além disso os mapas gerados com esses modelos tiveram algumas discrepâncias quanto ao aumento da produtividade em algumas áreas e extração das falhas existentes. Já o modelo de fusão utilizando redes neurais artificiais apresentou uma excelente alternativa para predição da produtividade. Uma vez que a rede é treinada, pelo menos com os dados de colheita de uma fileira, apresentou erros inferiores a 2% em todos os mapas gerados.

REFERÊNCIAS

- Alves, M. F., Lotufo, A. D. P.; Lopes, M. L. M. (2013). Seleção de variáveis stepwise aplicadas em redes neurais artificiais para previsão de demanda de cargas elétricas in Proceeding Series of the Brazilian Society of Applied and Computational Mathematics (SBMAC 2013), Vol. 1, N. 1, 2013.
- Akaike, H. (1974). A new look at the statistical model identification. IEEE Transactions on Automatic Control, 19, 716-723. <http://dx.doi.org/10.1109/TAC.1974.1100705>.
- Aude, M. I. S. (1993). Estádios de desenvolvimento da cana-de-açúcar e suas relações com a produtividade. Ciência Rural, v.23, p.241-248.
- Balastreire, L. A., Elias, A. I., Amaral, J. D. (1997) Agricultura de precisão: mapeamento da produtividade da cultura do milho. Revista de Engenharia Rural, 8, 97-111.
- Ballard, R. J. (2003). Forecasting with neural networks – A review. NSSJ, 20(2): 21-29.
- Barros, F. F. (2008) A melhoria contínua no processo de plantio da cana-de-açúcar. 78 f. Dissertação (Mestrado em Agronomia) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba –SP.
- Bedworth, M. D., O'Brien. J. (1999). The omnibus model: A new architecture for data fusion? In Proceedings of the 2nd International Conference on Information Fusion (FUSION'99), Helsinki, Finland, July 1999.
- BEN (2017) Balanço Energético Nacional, Relatório Síntese - ano base 2016, Rio de Janeiro: EPE, 26p.
- Benjamin, C. E. (2002). Sugar cane yield monitoring system. MSc thesis, Louisiana State University.
- Benjamin, C. E., Price, R. R., Mailander, M. P. (2001). Sugar Cane Monitoring System. Paper No. 011189, ASAE, St. Joseph, MI, USA.
- Bernardi, A. C. C.; Inamasu, R. Y. (2014). Adoção da Agricultura de Precisão No Brasil. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. (Ed.). Agricultura de precisão: resultados de um novo olhar. Brasília, DF: Embrapa, 2014. p. 559-577.
- Blasch, E. P. and Plano, S. (2002). “JDL level 5 fusion model “user refinement” issues and applications in group tracking,” in Proceedings of the Signal Processing, Sensor Fusion, and Target Recognition XI, pp. 270–279, April 2002.
- Bolt G. R. (1992) Fault tolerance in artificial neural networks - Are Neural Networks Inherently Fault Tolerant?. 200 f. Tese (Doutorado) - University of York, Department of Computer Science. Heslington, York, YO1 5DD, U.K.
- Bolt G. R., Austin J., Morgan G., (1992). Fault Tolerant Multi-Layer Perceptron Networks, Technical Report: YCS 180, Advanced Computer Architecture Group Department of Computer Science, University of York, Heslington, York, YO1 5DD, U.K.
- Bowden G.J., Dandy G.C., Maier H.R. (2005). Input determination for neural network models in water resources applications. Part 1– background and methodology, J. Hydrol., 301 (1–4) (2005), pp. 75–92

Braga, A. P.; Carvalho, A. C. P. L. F.; Ludemir, T. B. (2012). Redes neurais artificiais: Teoria e Aplicações. 2. ed. Rio de Janeiro: LTC, 2012.

Brambilla, W. P. (2013) Estudo da fisiologia de gemas laterais de cana-de-açúcar durante o armazenamento. 36 f. Dissertação (mestrado) - Universidade Estadual Paulista Júlio de Mesquita Filho, Instituto Biociências de Botucatu.

Bramley, R. G. V. (2009). Lessons from nearly 20 years of Precision Agriculture research, development, and adoption as a guide to its appropriate application. *Crop & Pasture Science*, 60(3), 197-217.

Bramley, R.G.V., Cook S.E., McMahon G.G. (1997) Precision Agriculture - What can it offer the Australian sugar industry? Proceedings of a workshop held in Townsville. (CSIRO Land and Water: Townsville). ISBN 0643060480.

Bramley, R.G.V., Trengove, S. (2013) Precision Agriculture in Australia: present status and recent developments. *Engenharia Agrícola*, 33, 575-588.

Braunbeck, O. A.; Magalhães P. S. G. (2010) Avaliação tecnológica da mecanização da cana-de-açúcar. In: Cortez, L. A. B. (Org.). Bioetanol de Cana-de-Açúcar, P&D para Produtividade e Sustentabilidade. São Paulo. Blucher, p. 451-464, 2010.

Brooks, R. R; Iyengar, S. S. (1998) Multi-Sensor Fusion: Fundamentals and Applications. Prentice Hall, New Jersey.

Camellini, J. H. (2013). Agricultura de Precisão para Cana-de-açúcar: Expressão Local de um Processo Global. XIV EGAL (Encontro de Geógrafos da América Latina). Peru, 2013.

Campolo, M., Soldati, A., Andreussi, P., (1999). Forecasting river flow rate during low-flow periods using neural networks. *Water Resources Research* 35 (11), 3547–3552.

Casagrande, A.A. (1991) Tópicos de morfologia e fisiologia da cana-de-açúcar. Jaboticabal: Funep. 157p.

Castanedo, F. (2013). “A review of data fusion techniques,” *Scientific World J.*, vol. 2013, article 704504, Oct. 2013

Cavalcante, D.S. (2011) Estudos com sensores para a mensuração de falhas nas fileiras de cana-de-açúcar (*Saccharum SSP.*). 75p. Dissertação (Mestrado) Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba.

Cerri, G. P; Magalhaes, P. G. (2005) Sugar Cane Yield Monitor. Paper No. 051154, ASAE, St. Joseph, MI, USA.

Collins, F.C., and P.V. Bolstad (1996). A Comparison of Spatial Interpolation Techniques in Temperature Estimation (USA: NCGIA - National Center for Geographic Information and Analysis)

CONAB (2018) Acompanhamento de safra brasileira: cana-de-açúcar. Primeiro levantamento, Brasília: Conab, 17.p.

Cox, G. J; Harris, H. D, Cox, D. R, (1998). Application of Precision Agriculture to Sugar Cane. Proceedings of the Fourth International Conference on Precision Agriculture. ASA-CSSA-SSSA, St. Paul, MN, USA.

Cox, G. J. (2002). A yield mapping system for sugar cane chopper. PhD thesis, University Of Southern Queensland, 2002.

- Dasarathy, B. V. (1997). Sensor fusion potential exploitation-innovative architectures and illustrative applications. *Proceedings of the IEEE*, 85:24-38, January 1997.
- U. S. Department of Defense (DoD), Data Fusion Subpanel of the Joint Directors of Laboratories, Technical Panel for C3. *Data Fusion Lexicon*, 1991.
- Demuth, H; Beale, M. (2000), *Neural Network Toolbox for Use with MATLAB® User's Guide*, version 4, sixth printing revised for version 4 (Release 12), copyright 1992 - 2000 by the mathworks, inc.
- Diker, K., Heermann, D.F., Buchleiter, G.W. W., Bausch, C., Farahani, H. (2004). Modeling Yield by Neural Network. *Seventh International Conference on Precision Agriculture*, July 25-28, Minneapolis, MN.
- Dinardo-Miranda, L. L., Vasconcelos, A. C. M., Landell, M.A.G. (2010) *Cana-de-açúcar*. Campinas: Instituto Agrônomo, 882p.
- Diola, V., Santos, F. (2010) *Fisiologia*. In: Santos, F., Borém, A., Caldas, C. (Eds.) *Cana-de-açúcar: Bioenergia, açúcar e álcool – Tecnologias e perspectivas*. Viçosa. 577 p.
- Drummond, S.T., Sudduth, K.A., and Joshi, A., (2000). Predictive Ability of Neural Networks for Site-Specific Yield Estimation, paper presented at 2nd International Geospatial Information in Agriculture and Forestry Conference, Lake Buena Vista, Florida 2000.
- Earl R; Wheeler P N, Blackmore B S, Godwin R J (1996) Precision farming—the management of variability. *The Journal of the Institution of Agricultural Engineers*, 51(4), 18–23
- Elmenreich, W. (2002) *An Introduction to Sensor Fusion - Research Report*, Vierende neurala University of Technology, Austria, 2002.
- Faceli, K. (2001). *Combinação de métodos de inteligência artificial para fusão de sensores*. 174p. Dissertação (mestrado). Universidade de São Paulo – São Carlos.
- FAO. (2011) *Faostat*, Food and Agriculture Organization. Available at: <http://faostat.fao.org>. Acessado em maio de 2018.
- Fernandez, F, Hernandez, B, Esquivel, M, Marrere, S, Ponce, E, Quintana, L (2007) Yield mapping sugarcane in Australia. In *Proceedings of the 6th European Conference on Precision Agriculture*. Skiathos Greece, 3–6 June 2007.
- Fleming, K. L., Westfall, D. G., Wiens, D. W., & Brodahl, M. C. (2000). Evaluating farmer defined management zone maps for variable rate fertilizer application. *Precision Agriculture*, 2(2), 201-215.
- Gaumitz, B. C. (2016) *Precision agriculture and gis: evaluating the use of yield maps combined with lidar data*. California. 81p. Dissertação (Mestrado) – Faculty Of The USC Graduate School, University Of Southern California.
- Grego, C. R., Araujo, L. S. de, Vicente, L. E., Nogueira, S. F., Magalhães, P. S. G., Vicente, A. K., et al. (2014). Agricultura de precisão em cana-de-açúcar. *Agricultura de precisão: Resultados de um novo olhar*. Empresa Brasileira de Pesquisa Agropecuária (Embrapa), Brasília. Revisão Perenes, p. 442-457.
- Hall, D. L., Llinas, J. (1997). An introduction to multidata sensor fusion. *Proceedings of IEEE*, vol. 85, no. 1, 1997.
- Hall, D. L. (1992). *Mathematical Techniques in Multisensors Data Fusion*. Artech House, Norwood, Massachusetts, 1992.

- Haykin S, (2001). Redes neurais: princípios e prática. 2a Edição, Editora Bookman, 2001.
- Haykin, S. (2002). Lectures on Neural networks presented at NCAR, September 9–11, Boulder, Colorado.
- Haykin, S. (2005). Neural network: A Comprehensive Foundation. 2. ed. Ontario: Pearson Prentice Hall, 2005.
- Haugh, L.D., Box, G.E.P., (1977). Identification of dynamic regression (distributed lag) models connecting two time series. *Journal of the American Statistical Association* 72 (397), 121–130.
- Hernandez, B, Fernandez, F, Ponce, E, Quintana, L, Esquivel, M, Rodriguez, J (2003) Sugarcane yield mapping from the harvester biomass input flux. In 'Proceedings of the 4th European Conference on Precision Agriculture.' Berlin, Germany, 16–19 June 2003.
- Hernandez, B, Fernandez, F, Ponce, E, Esquivel, M, Rodriguez, J, Quintana, L, Interian, S, Alvarez, R (2005) Application of precision farming technologies for sugarcane crop. In Proceedings of the 5th European Conference on Precision Agriculture. Uppsala, Sweden, 9–12 June 2005. (Ed. JV Stafford) (Wageningen Academic Publishers: The Netherlands).
- Jadoski, C. J., Toppa, E. V. B., Julianetti, A., Hulshof, T., Ono, E. O., Rodrigues, J. D. (2010) Fisiologia do desenvolvimento do estágio vegetativo da cana-de-açúcar (*Saccharum officinarum* L.). *Pesquisa Aplicada e Agrotecnologia*, v.3, p.169-176.
- Jang, J., Sun, C. and Mizutani, E. (1997). Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence. Prentice-Hall, Englewood Cliffs, NJ.
- Janes, K.R., Yang, S.X. and Hacker, R.R. (2004). Single-component modeling of pig farm odour with statistical methods and neural networks. *Biosystems Engineering*.
- Jayawardena, A.W., Fernando, D.A.K., Zhou, M.C., (1997). Comparison of multilayer perceptron and radial basis function networks as tools for flood forecasting IAHS Publication (International Association of Hydrological Sciences) (239) 1997.
- JDL, Data Fusion Lexicon. Technical Panel For C3, F.E. White, San Diego, Calif, USA, Code 20, 1991.
- Jensen, T., Baillie, C., Bramley, R., DiBella, L., Whiteing, C., Davis, R. (2010) Assessment of sugarcane yield monitoring technology for precision agriculture. *Proceedings of the Australian Society of Sugar Cane Technologists* 32, 410–423.
- Jensen, T. A; Baillie, C, Bramley, R. G. V; Panitz, J. H; Schroeder, B. L; (2012) An assessment of sugarcane yield monitoring concepts and techniques from commercial yield monitoring systems. *Proceedings of the Australian Society of Sugar Cane Technologists* 34, (electronic format) 8 pp.
- Jensen, T. A, Baillie, C, Bramley, R.G.V. (2013) Sugarcane yield monitoring: a protocol for yield map interpolation and key considerations in the collection of yield data. *Proceedings of the Australian Society of Sugar Cane Technologists* 35, (electronic format) 12 pp.
- Joshi, R. and Sanderson, A. C. (1999). Multisensor Fusion: A Minimal Representation Framework. World Scientific.
- Junqueira, A.A.B; Dantas, B. A. (1964) cana-de-açúcar no Brasil, in: *Cultura e adubação da cana-de-açúcar*. Ed. Instituto Brasil. De Potassa, 1964
- Klein, L. A. (1999). Sensor and Data Fusion Concepts and Applications. SPIE Press.

- Krutman, S. (1966) O grande período de variedades de cana. *Pesquisa Agropecuária Brasileira*. Brasília, v. 11, p. 395-400.
- Luo, R. C; Kay, M. (1989) Multisensor integration and fusion in intelligent systems. *IEEE Transactions on Systems, Man, and Cybernetics*, 19(5):901-930, September-October 1989.
- Luo, R. C. and Kay, M. G. (1992). *Data Fusion and Sensor Integration: State-of-the-art 1990s*, Chapter 2, pages 7-135.
- Luo, R. C. and Kay, M. G., editors (1995). *Multisensor Integration and Fusion for Intelligent Machine and Systems*. Ablex Publishing Corporation.
- Luo, R. C; Yih, C.-C; and Su, K. L; (2002). "Multisensor fusion and integration: approaches, applications, and future research directions," *IEEE Sensors Journal*, vol. 2, no. 2, pp. 107–119, 2002.
- Llinas, J; Bowman, C; Rogova, G; Steinberg, A; Waltz, E; and White, F; (2004). "Revisiting the JDL data fusion model II," Technical Report, DTIC Document, 2004.
- Ma, S.; Karkee, M.; Scharf, P. A.; Zhang, Q. (2014). Sugarcane harvester technology: A critical overview. *Applied Engineering in Agriculture*, v.30, p.727-739, 2014.
- Macedo, I.C. (org). In PaeS, D. Luiz, A.A. (2005) *Energia da Cana-de-açúcar – Doze estudos sobre a agroindústria da cana-de-açúcar no Brasil e a sua sustentabilidade*. São Paulo: Berlendis & Vertecchia: ÚNICA- União da Agroindústria Canavieira do Estado de São Paulo. Cap. 6, pag. 125 a 133, 2005.
- Machado, P. (2005). *Investigations on Multisensor Data Fusion Algorithms for Implementation of "Real-time approach with map overlay" for N-fertilization*, Tese Pós-Doutorado, Technische Universitaet Muenchen, Munique - Alemanha, 2005.
- Magalhães, A. C. N. (1987) Ecofisiologia da cana-de-açúcar: aspectos do metabolismo do carbono na planta. In Castro, P. R. C., Ferreira, S. O., Yamada, T. (Ed.). *Ecofisiologia da produção agrícola*. Piracicaba: Potafós, p 113-118.
- Magalhães, P.S.G., Cerri, D.G.P. (2007) Yield monitoring of sugar cane. *Biosystems Engeneering*, London, v. 96, n. 1, p. 1-6.
- Maier, H.R; Dandy, G.C. (1997). Determining inputs for neural network models of multivariate time series. *Computer- Aided Civ. Infrastruct. Eng.*, 12 (5) (1997)
- Maier, H.R., Dandy, G.C., Burch, M.D., (1998). Use of artificial neural networks for modelling cyanobacteria *Anabaena* spp. in the River Murray, South Australia. *Ecological Modelling* 105, 257–272.
- Mailander, M., Benjamin, C., Price, R., Hall, S. (2010) Sugar cane yield monitoring system. *Applied Engineering in Agriculture*, 26(6), 965.
- Manyika J. and Durrant-Whyte, H. (1995). *Data Fusion and Sensor Management: A Decentralized Information-Theoretic Approach*, Prentice Hall, Upper Saddle River, NJ, USA, 1995.
- MAPA, MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. (2017). Usinas e destilarias cadastradas. Disponível em: www.agricultura.gov.br. Acesso: dezembro de 2017.

- Marchiori, L. F. S. (2004) Influência da época de plantio e corte na produtividade da cana-de-açúcar. Tese (Doutorado), Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba.
- Marques, T. A., Serra, G. E., Marques, P. A. A. (2006) Desenvolvimento de um programa computacional para implantação econômica de lavouras canavieiras. *Revista brasileira engenharia agrícola e ambiental*, Campina Grande, v. 10, n. 2, p. 289-293.
- Matsuoka, S., Arizono, H., Bassinello, A. I., Gheller, A. C. A., Hoffmann, H. P., Matsuda, Y. (1995) Variedades superprecoces de cana-de-açúcar. *Álcool & Açúcar*, São Paulo, v.15, n.78, p.22-29.
- Mcculloch, W. S. & Pitts, W. (1943), A Logical Calculus of the Ideas Imminent in Nervous Activity. *Bulletin of Mathematical Biophysics*, 5, p.115-133, 1943.
- Miranda, A. C. C.; Veríssimo, A. M.; Ceolin, A. C. (2017) *Revista Gestão.Org*, v. 15, Edição Especial, 2017. p. 129-137 ISSN 1679-1827.
- Missio, C. (2016) Qualidade do plantio mecanizado de cana-de-açúcar. Dissertação (Mestrado em Engenharia agrícola). Universidade Federal da Grande Dourados. Dourados, MS: UFGD. 51f.
- Molin J.P., Menegatti, L.A.A. (2004) Field-testing of a sugar cane yield monitor in Brazil. Paper presented to 2003 ASAE Annual International Meeting, Las Vegas USA, 27–30 July 2003.
- Molin, J. P. (2008) Agricultura de precisão em cana-de-açúcar é mais do que uma realidade. ESALQ, USP. *Revista Coplana*.
- Molin, J. P., Fontana, R. V., Guimaraes, F. R., Costa, M. B. (2004) Elaboração de mapa de produtividades de cana-de-açúcar em corte manual com queima previa. *Anais do Congresso Brasileiro de Agricultura de Precisão ConBAP*. ESALQ/USP. p. 1-7.
- Molin, J. P., Veiga, S. J. P., Cavalcante, D.S. (2014) Measuring And Mapping Sugarcane Gaps. In: 12th International Conference on Precision Agriculture, 2014, Sacramento. Proceedings of the 12th International Conference on Precision Agriculture. Monticello: ISPA.
- Molin, J. P., & Veiga, J. P. S. (2016). Spatial variability of sugarcane row gaps: measurement and mapping. *Ciência e Agrotecnologia*, 40(3), 347-355.
- Molin, J.P. (2001) Agricultura de precisão: o gerenciamento da variabilidade. Piracicaba: O Autor, 83p.
- Molin, J.P., Frasson, F.R., Amaral, L.R., Povh, F.P., Salvi, J.V. (2010) Capacidade de um sensor ótico em quantificar a resposta da cana-de-açúcar a doses de nitrogênio. *Revista Brasileira de Engenharia Agrícola e Ambiental*, Campina Grande, v. 14, n. 12, p. 1345– 1349.
- Mundry, R. and Nunn, C. L. (2009). Stepwise model fitting and statistical inference: turning noise into signal pollution *The American Naturalist*, vol. 173, no. 1, pp. 119–123, 2009.
- Nagaoka, M. E. et al. (2005). Um método para estimar densidade de solo utilizando redes neurais artificiais. *Energia na Agricultura*, vol. 20, p.53-68, 2005
- Nastari, P. M. (1983). The role of sugar in Brazil’s history and economy. 1983. 311p. Tese (Doutorado em Economia) – Agricultural Economics – Iowa State University, Ames.
- Nelson. V. P. (1990) Fault-tolerant computing: Fundamental concepts. *IEEE Computer*, 23(7):19{25, July 1990.

- Odhambo, L.O., Yoder, R.E., Yoder, D.C. and Hines, J.W. (2001). Optimization of fuzzy evapotranspiration model through neural training with input-output examples. *Trans. of ASAE*, 44(6): 1625-1633.
- Oliveira, R. A. de, Daros, R., Zambom, J. L. C., Weber, H., Ido, O. T., Bespalhok-Filho, J. C. (2007). Área foliar em três cultivares de cana-de-açúcar e sua correlação com a produção de biomassa. *Pesquisa Agropecuária Tropical*, 37(2), 71-76.
- Olsen, S., Hussey, B. (2015). Precision Agriculture for the sugarcane industry.
- Pagnano NB, Magalhaes PSG (2001) Sugarcane yield measurement. In 'ECPA 2001 – 3rd European Conference on Precision Agriculture' Vol 2. Montpellier, France, 18–20 June 2001. (Eds S Blackmore, G Grenier) pp. 839–843. (Agro Montpellier, Ecole Nationale Supérieure Agronomique de Montpellier: Montpellier, France.
- Pasika, H. J. C. (1999). Neural Network Sensor Fusion Engines for Remote Sensing. PhD thesis, McMaster University
- Pedersen, M. S., Lind, KM. K. (2017) Precision Agriculture: Technology and Economic Perspectives, Springer International Publishing.
- Pierossi, M. A., Hassuani, S. J. (1997). Caçamba instrumentada para pesagem de cana picada. Em: Seminário Copersucar de Tecnologia Agrônômica, Piracicaba, Brasil, Copersucar, p. 263-265.
- Pierossi, M. A., Neves, J. L. M. (2000). Mapeamento de produtividade de cana-de-açúcar. In: BALASTREIRE, L.A. O estado da arte da agricultura de precisão no Brasil. Piracicaba: O autor. p. 124-128.
- Plana, R., Domini, M. E., Espinosa, R. (1987) Influencia de las precipitaciones y la temperatura sobre la brotación de dos variedades de caña de azúcar (*Saccharum* sp híbrido) plantadas em diferentes meses. *Cultivos Tropicales*. V.9, n.3, p. 19-24.
- Põldaru, R., Roots, J. (2003). Perspectives of Teaching And Training New Data Analysis Procedures, EFITA 2003 Conference, Estonian Agricultural University, Estonia
- Price, R. R., Johnson, R. M., Viator, RP, Larsen, J, Peters, A, (2011). Fiber Optic Yield Monitor for a Sugarcane Harvester. *Transactions of the ASABE*, Vol 54(1), 31-39.
- Price, R. R., Larsen, J., Peters, A. (2007) Development of an optical yield monitor for sugar cane harvesting. Paper presented to 2007 ASABE Annual International Meeting, Minneapolis USA, 17–20 June 2007.
- Quaderer, J. G., Cash, M. F. (2015). Sugarcane Yield Mapping. U.S. Patents No. 8,955,402. Washington, DC: U.S. Patents and Trademarks Office.
- Ramos, C. R. G.; Lanças, K. P.; Lyra, G. A.; Millani, T. M. (2014). Qualidade da colheita mecanizada de cana-de-açúcar em função da velocidade de deslocamento e rotação do motor da colhedora. *Revista Energia na Agricultura*, v.29, p.87-94, 2014.
- Ridge, D.R.; Dick, R.G. (1988) Current research on green cane harvesting and dirt rejection by harvesters. *Proceedings of Australian Society of Sugar Cane Technologists*, Mackay, v.10, p.19-25, 1988.
- Ripoli, T. C. C.; Ripoli, M. L. C. (2009). Biomassa de cana-de-açúcar: colheita, energia e ambiente Piracicaba: Escola Superior de Agricultura “Luiz de Queiroz”, 2009 333 p.

- Rocha, A. M. C. (1984). Emergência, perfilhamento e produção da cana-de-açúcar (*Saccharum spp.*) em função das épocas de plantio no estado de São Paulo. Piracicaba. 138p. Dissertação (Mestrado) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo.
- Rosenblatt, F. (1958). The perceptron, a probabilistic model for information storage and organization in the brain, *Psychol. Rev.* 62, 386–408 (1958)
- Rothman, P. L.; Denton, R. V. (1991). Fusion or confusion: Knowledge or nonsense? *SPIE Data Structures and Target Classification*, 1470:2-12, 1991.
- Salazar, P. (2018). Monitoramento em tempo real da estabilidade de tensão usando redes neurais artificiais. 2018. 108f. Dissertação (Mestrado em Ciências). Universidade de São Paulo – Escola Politécnica - USP, São Paulo, 2018.
- Santos, E. P. (2008). Rebrotas de duas variedades de cana-de-açúcar colhida crua sob dois níveis de desgaste das facas do mecanismo de corte basal. 2008. 40 f. Monografia (Graduação em Agronomia) - Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista, Jaboticabal, 2008.
- Schneider, C. F., Schulz, D. G., Lima, P. R., Júnior, A. C. G. (2013) Formas de gestão e aplicação de resíduos da cana-de-açúcar visando redução de impactos ambientais. *Revista Verde de Agroecologia e Desenvolvimento Sustentável*, 7(5), 08-17.
- Schnug, E.; Haneklaus, S.; Lamp, J. Continuous large scale yield mapping in oilseed rape fields and application of yield maps to CAF. *Oilseeds*, v. 9, p. 13-14, 1991.
- Silva, M. L. M. (2010). Redes Neurais Artificiais Para Prognose Da Produção De Povoamentos Não Desbastados De Eucalipto. 2010. 54f. Dissertação (Mestrado em Ciência Florestal). Universidade Federal de Viçosa - UFV, Viçosa. 2010.
- Silva, R. P. et al. (2008). Controle estatístico aplicado ao processo de colheita mecanizada de cana-de-açúcar. *Engenharia Agrícola*, v. 28, n. 2, p. 292-304, 2008.
- Silva, I. N.; Spatti, D. H.; Flauzino, R. A. (2016). Redes neurais artificiais para engenharia e ciências aplicadas. São Paulo: Artliber Editora. 2016.
- Singhal, A. (1997). Issues in autonomous mobile robot navigation. Survey paper towards partial fulfillment of MS degree requirements, Computer Science Department, University of Rochester, Rochester, NY 14627-0226, May 1997.
- Smestad, T. (2001). Data fusion - for humans, computers or both? Translated article from Mikroskopet, Norwegian Defence Research Establishment, February 2001.
- Soares, F. C. (2013). Uso de diferentes metodologias na geração de funções de pedotransferência para a retenção de água em solos do Rio Grande do Sul. 2013. 200 p. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Santa Maria, Santa Maria, 2013.
- Spekken, M., Molin, J. P., Romanelli, T. L. (2015) Cost of boundary maneuvers in sugarcane production. *Biosystems Engineering*, v. 129, p. 112-126.
- Sriram, R. D. (1997). *Intelligent Systems for Engineering*, Springer-Verlag, Berlin Heidelberg New York.
- Sulzbach, L. (2002) Tecnologia de agricultura de precisão: estudo de caso: integração de modelos digitais de atributos químicos do solo e modelos digitais de culturas agrícolas. Santa

- Maria, RS. 168f. Dissertação (Mestrado em Engenharia Agrícola)- Universidade Federal de Santa Maria.
- UNICA, (2018). União da Indústria de cana-de-açúcar-Brasil. Union of the Brazilian sugarcane industry. <http://www.unicadata.com.br/>. Accessed 15 maio 2018.
- Vansichen, R., de Baerdemaker, J. (1993) A measurement technique for yield mapping of corn silage. *Journal of Agricultural Engineering Research*, Vol 55, 1-10.
- Visser, A., Groen, F. C. A. (1999) Organization and design of autonomous systems. Textbook, Faculty of Mathematics, Computer Science, Physics and Astronomy, University of Amsterdam, Kruislaan 403, NL-1098 SJ Amsterdam, August 1999.
- Tatibana, C. Y. e Kaetsu, D. Y. (2009). Uma Introdução às Redes Neurais. Universidade Estadual de Maringá-UEM, Departamento de Informática. Maringá. 2009
- Thai, C.N., Shewfelt, R.L. (1991). Modeling sensory color quality of tomato and peach: neural networks and statistical regression. *Trans. of ASAE*, 34(3): 950-955.
- Thirumalaiah, K., Deo, M.C., (2000). Hydrological forecasting using neural networks. *Journal of Hydrologic Engineering* 5 (2), 180–189.
- Tumbo, S. D., Wagner, D. G., and Heinemann, P. H. (2002). Hyperspectral-based neural network for predicting chlorophyll status in corn. *Trans. of ASAE*, 45(3): 825-832.
- Wald, L. (1998). A European proposal for terms of reference in data fusion. *International Archives of Photogrammetry and Remote Sensing*, XXXII, Part 7:651-654, 1998.
- Waltz, E., Llinas. J. (1990) *Multisensor Data Fusion*. Artech House, Norwood, Massachusetts, 1990.
- Wendte, K.W., A. Skotnikov, & Thomas, K.K., (2001). Sugar Cane Yield Monitor. United States Patent No. 6272819. August 14, 2001
- Wheeler, P. N., Godwin, R. J., Watt, C. D., Blackmore, B. S. (1997) Trailer based yield mapping.
- In: *European Conference On Precision Agriculture*, 1997. Warwick, p. 9.
- Whyte, H. F. D; (1988) “Sensor models and multisensor integration,” *International Journal of Robotics Research*, vol. 7, no. 6, pp. 97–113, 1988.
- Whyte, D. H. F. and Stevens, M. (2001). “Data fusion in decentralized sensing networks,” in *Proceedings of the 4th International Conference on Information Fusion*, pp. 302–307, Montreal, Canada, 2001.
- Zhang, Q., Yang, S.X., Mittal, G.S. and Yi, S.J. (2002). Prediction of performance indices and optimal parameters of rough rice drying with neural networks. *Biosystems Engineering*, 83(3): 281-290.

APÊNDICES

APÊNDICE A.

Algoritmo da rede neural artificial NARX gerado no MATLAB

```
% Algoritmo Autoregression Problem with External Input with a NARX Neural Network
% Script generated by Neural Time Series app
% Created 18-Nov-2018 21:41:21
% Definição das variáveis:
X = tonndata(rna1,false,false); % rna1 - matrix de dados RNA-1.
T = tonndata(transbordo,false,false); % transbordo - Dados do transbordo para predição.

% Função de treinamento
trainFcn = 'trainbr'; % Bayesian Regularization backpropagation.

% Criação da Rede neural NARX
inputDelays = 1:3; % definição dos incrementos de atraso
feedbackDelays = 1:3; % definição da função de realimentação
hiddenLayerSize = 15; %definição do numero de neuronios na camada oculta
%configuração da RNA
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize,'open',trainFcn);

% Preparação dos dados para treinamento
[x,xi,ai,t] = preparets(net,X,{},T);
% divisão dos dados para o treinamento, validação e teste da rede neural
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Treinamento da RNA
[net,tr] = train(net,x,t,xi,ai);

% Teste da RNA
y = net(x,xi,ai);
e = gsubtract(t,y);
performance = perform(net,t,y)

% Vizualização dos resultados
view(net)

% Loop para rodar varios dados de entradas
netc = closeloop(net);
netc.name = [net.name ' - Closed Loop'];
view(netc)
[xc,xic,aic,tc] = preparets(netc,X,{},T);
yc = netc(xc,xic,aic);
closedLoopPerformance = perform(net,tc,yc)
```

APÊNDICE B.

A Figura 64 apresenta os demais gráficos dos modelos RLM.

Figura 64. Mapas de produtividade dos modelos de predição com dados obtidos pelo modelo de regressão linear múltipla RLM-2 (a); produtividade calculada pelo modelo de regressão linear múltipla RLM-3 (b); produtividade calculada pelo modelo de regressão linear simples RLM-4 (c); produtividade calculada pelo modelo de regressão linear simples RLM-5(d), a produtividade calculada pelo modelo de regressão linear simples RLM-6(e) e a produtividade calculada pelo modelo de regressão linear simples RLM-7(f)

A Figura 65 apresenta os demais gráficos dos modelos RNA.

Figura 65. Mapas de produtividade dos modelos de predição com dados obtidos pelo modelo de redes neurais RNA-2 (a); produtividade calculada pelo modelo de redes neurais RNA-3 (b); produtividade calculada pelo modelo de redes neurais RNA-4 (c); produtividade calculada pelo modelo de redes neurais RNA-5 (d), a produtividade calculada pelo modelo de redes neurais RNA-6(e) , a produtividade calculada pelo modelo de redes neurais RNA-7(f) e , a produtividade calculada pelo modelo de redes neurais RNA-8 (g) e a produtividade calculada pelo modelo de redes neurais RNA-9 (h)

A Figura 66 apresenta os mapas gerados a partir dos dados dos sensores individualmente.

Figura 66. Mapa dos dados do sensor PP (a); mapa dos dados do sensor PE (b); mapa dos dados do sensor DR1 (c); mapa dos dados do sensor DR2 (d), mapa dos dados do sensor CB (e) e o mapa dos dados do sensor CC (d)