

UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE ENGENHARIA DE BAURU
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Saulo Silva Coelho

**APLICAÇÃO DE SISTEMAS NEURO-*FUZZY* E ESPECTROMETRIA NO
INFRAVERMELHO PRÓXIMO PARA A IDENTIFICAÇÃO EM TEMPO
REAL DO TEOR DE NITROGÊNIO FOLIAR EM CANA-DE-AÇÚCAR**

BAURU
2014

Saulo Silva Coelho

**APLICAÇÃO DE SISTEMAS NEURO-FUZZY E ESPECTROMETRIA NO
INFRAVERMELHO PRÓXIMO PARA A IDENTIFICAÇÃO EM TEMPO
REAL DO TEOR DE NITROGÊNIO FOLIAR EM CANA-DE-AÇÚCAR**

Dissertação apresentada como requisito
à obtenção do título de mestre em
Engenharia Elétrica, pelo Programa de
Pós-Graduação em Engenharia Elétrica,
da Faculdade de Engenharia de Bauru da
Universidade Estadual Paulista.

Orientador: Prof. Dr. José Alfredo
Covolan Ulson

BAURU

2014

Coelho, Saulo Silva.

Aplicação de sistemas neuro-fuzzy e espectrometria no infravermelho próximo para a identificação do teor de Nitrogênio foliar em cana-de-açúcar. / Saulo Silva Coelho, 2014

152 f.: il.

Orientador: José Alfredo Covolan Ulson


Dissertação (Mestrado)-Universidade Estadual Paulista. Faculdade de Engenharia, Bauru, 2014

1. Análise de Nitrogênio. 2. Infravermelho. 3. Sistema neuro-fuzzy. I. Universidade Estadual Paulista. Faculdade de Engenharia. II. Título.

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE SAULO SILVA COELHO, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DO(A) FACULDADE DE ENGENHARIA DE BAURU.

Aos 22 dias do mês de julho do ano de 2014, às 10:00 horas, no(a) Anfiteatro da Seção Técnica de Pós-graduação da Faculdade de Engenharia de Bauru, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos seguintes membros: Prof. Dr. JOSE ALFREDO COVOLAN ULSON do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru, Prof. Dr. RICARDO AUGUSTO SOUZA FERNANDES do(a) Departamento de Engenharia Elétrica/UFSCar, Prof. Dr. ANDRÉ LUIZ ANDREOLI do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru, sob a presidência do primeiro, a fim de proceder a arguição pública da DISSERTAÇÃO DE MESTRADO de SAULO SILVA COELHO, intitulado "APLICAÇÃO DE SISTEMAS NEURO-FUZZY E ESPECTROMETRIA NO INFRAVERMELHO PRÓXIMO PARA A IDENTIFICAÇÃO EM TEMPO REAL DO TEOR DE NITROGÊNIO FOLIAR EM CANA-DE-AÇÚCAR". Após a exposição, o discente foi arguido oralmente pelos membros da Comissão Examinadora, tendo recebido o conceito final: _ _ _ _

APROVADO. Nada mais havendo, foi lavrada a presente ata, que, após lida e aprovada, foi assinada pelos membros da Comissão Examinadora.


Prof. Dr. JOSE ALFREDO COVOLAN ULSON


Prof. Dr. RICARDO AUGUSTO SOUZA FERNANDES


Prof. Dr. ANDRÉ LUIZ ANDREOLI

AGRADECIMENTOS

Agradeço em primeiro lugar aos meus pais, Izabel Cristina Silva Coelho e Walcir Cunha Coelho, e minha irmã, Simony Silva Coelho pelo incentivo e apoio de sempre continuar estudando.

Agradeço ao meu orientador Dr. José Alfredo Covolan Ulson, pelos conselhos, paciência e tempos gastos em nossas conversas sobre o trabalho para eu pudesse terminar este trabalho, ao professor Dr. Fernando de Souza Campos e aos alunos Guilherme Marabezi e Bruno Albuquerque de Castro.

À toda família Senai João Martins Coube, ao diretor da escola Ademir Redondo, ao orientador técnico Tiago Ferreira, ao orientador pedagógico Valdir Mateus, e ao orientador de práticas profissionais Benedito Aparecido Bautz Martins, pela ajuda e entendimento neste período. Aos instrutores e assistente de apoio técnico do setor da eletroeletrônica por me substituir sempre que necessário.

Uma dedicatória a minha namorada e revisora deste trabalho, Luane Thomazini de Almeida, que corrigiu inúmeras versões. À prof^a. Michele que me ajudou com as revisões de citações e referências.

Agradeço também à Máquinas Agrícolas Jacto S/A, por ter cedido os dados para que este trabalho pudesse ser realizado.

Não posso deixar de agradecer a Deus por ter colocado todas essas pessoas em meu caminho e por me dar a vida.

RESUMO

O Brasil possui um grande potencial no setor do agronegócio e a associação desse setor com o desenvolvimento tecnológico deu origem à Agricultura de Precisão. Nesse contexto, o uso de sensores de Nitrogênio foliar de tempo real, especificamente os que utilizam como princípio de funcionamento a espectrometria, em conjunto com sistemas inteligentes computacionais, tem contribuído de forma decisiva para o incremento da produtividade no campo, evitando a aplicação excessiva de insumos e, assim, preservando o meio ambiente. Um insumo comumente aplicado na cultura de cana-de-açúcar é o Nitrogênio que, apesar de ter grande contribuição econômica, impõe grande impacto ao meio ambiente, principalmente na poluição de aquíferos e mananciais. Dessa maneira, a quantidade aplicada desse nutriente é de grande importância, pois sua falta limita o crescimento da cultura e seu excesso polui o meio ambiente. A determinação da quantidade de Nitrogênio pode ser feita por meio do uso de sensores espectrométricos na faixa do infravermelho próximo visando a cobertura verde da cultura. Entretanto, no estágio inicial de crescimento, a cobertura verde não é plena, de forma que o sensor detecta, além da cobertura verde, o solo e cobertura morta, acrescentando ruído à medida da refletância usada para a estimação do teor de Nitrogênio na planta. Nesse cenário, este trabalho tem o objetivo de mapear a relação entre os valores fornecidos pelo sensor N-SENSOR ALS do fabricante norueguês YARA e os teores reais de Nitrogênio na planta medidos em laboratório. Mais especificamente, sistema de inferência neuro-*fuzzy* adaptativo (ANFIS), redes neurais artificiais do tipo *Perceptron* de Múltiplas Camadas (PMC) e *General Regression Neural Network* (GRNN) serão empregados visando a identificação e o aprendizado da relação entre os valores medidos pelo sensor N-SENSOR ALS e os valores reais obtidos em laboratório, eliminando os ruídos impostos pela cobertura não verde e pelas perturbações externas como a variação da luz ambiente. Os resultados obtidos indicam que a abordagem neuro-*fuzzy* apresenta desempenho superior às redes neurais e pode ser utilizada para a correção da medida dos sensores de Nitrogênio foliar em tempo real.

Palavras-chave: Sistemas inteligentes, identificação de sistemas, agricultura de precisão, teor de Nitrogênio, espectrometria.

ABSTRACT

Brazil has a great potential in the agribusiness sector and the association of this sector with technological development gave rise to precision agriculture. In this context, the use of soil sensors for real-time, specifically those using operating principle as spectrometry, together with computational intelligent systems are contributing decisively to increasing productivity in the field, avoiding excessive use of inputs and thus preserving the environment. An ingredient commonly used in the cultivation of sugar cane is the nitrogen that, despite great economic contribution, imposes great impact on the environment, especially in aquifers and fountains pollution. Thus, the applied amount of this nutrient is of great importance, since the lack of limits crop growth and excess pollute the environment. The determination of the nitrogen content can be made through the use of spectrometric sensors in the near-infrared aiming the green cover crop. However, in the initial stage of growth the green coverage is not complete, so the sensor "sees" beyond the green cover, soil and mulch, adding noise to the measurement of reflectance used to estimate the percentage of nitrogen in plant. In this scenario, this paper aims to map the relationship between the values provided by the sensor N-SENSOR ALS Norwegian YARA manufacturer and the actual levels of nitrogen in the plant measured in the laboratory. More specifically, systems of inference adaptive neuro-fuzzy (ANFIS), artificial neural network Multilayer Perceptron type (MLP) and General Regression Neural Network (GRNN) are employed in order to identify learning and the relationship between the values measured by the sensor N-SENSOR ALS and actual obtained in the laboratory, eliminating the noise imposed by non-green roof and external disturbances such as the variation of ambient light. The results indicate that the neuro-fuzzy approach has superior performance and neural networks can be used to correct the measured foliar nitrogen sensors in real time.

Keywords: Intelligent systems, identification systems, agriculture precision, nitrogen content, spectrometry.

LISTA DE FIGURAS

Figura 1.1: Ciclo da agricultura de precisão.	22
Figura 2.1: Eletrodo de detecção de amônia do fabricante HANNA.....	26
Figura 2.2: Eletrodo seletivo de nitrato.	27
Figura 2.3: Estimativas do índice de SPAD e do teor de Nitrogênio da folha da batata.	29
Figura 2.4: Sensor N-SENSOR ALS.....	30
Figura 3.1: Assinaturas espectrais.	32
Figura 3.2: Os campos que formam uma radiação eletromagnética.....	33
Figura 3.3: As regiões da radiação eletromagnética.	34
Figura 3.4: Tipos de alterações na ligação.	35
Figura 3.5: Sistema massa mola representando a rigidez das vibrações.....	36
Figura 3.6: Moléculas lineares e não lineares.	37
Figura 4.1: Organização dos sistemas inteligentes.	42
Figura 4.2: Modelo geral do neurônio artificial.....	44
Figura 4.3: Função degrau.	45
Figura 4.4: Função degrau (bipolar).....	46
Figura 4.5: Função rampa.	46
Figura 4.6: Função sigmóide.....	47
Figura 4.7: Função tangente hiperbólica.	47
Figura 4.8: Diagrama esquemático da rede <i>Perceptron</i> multicamadas.	49
Figura 4.9: Operações com conjuntos <i>Fuzzy</i>	56
Figura 4.10: Função de pertinência triangular.....	57
Figura 4.11: Função de pertinência trapezoidal.	57
Figura 4.12: Função de pertinência gaussiana.	58
Figura 4.13: Função de pertinência sigmóide.....	58
Figura 4.14: Função de pertinência unitária.	59
Figura 4.15: Modelo <i>Fuzzy</i>	60
Figura 4.16: Arquitetura típica do sistema ANFIS.	61
Figura 5.1: Talhão georreferenciado.	65
Figura 5.2: Trator modelo Uniport NPK com o sensor instalado.	65
Figura 5.3: Vista traseira da área de leitura da refletância do sensor.....	66
Figura 5.4: Vista superior da área de leitura da refletância do sensor.	66

Figura 5.5: Diagrama esquemático do sensor N- SENSOR ALS da YARA.	68
Figura 5.6: Critério utilizado para nomear as colunas.	70
Figura 5.7: Trator Uniport NPK aplicando o fertilizante no campo.	73
Figura 5.8: Cana-de-açúcar no estágio inicial do crescimento.	73
Figura 5.9: Esquema geral proposto para correção do sensor YARA.	76
Figura 6.1: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.	84
Figura 6.2: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.	85
Figura 6.3: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.	85
Figura 6.4: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.	86
Figura 6.5: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.	86
Figura 6.6: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.	87
Figura 6.7: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.	87
Figura 6.8: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.	88
Figura 6.9: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.	88
Figura 6.10: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.	89
Figura 6.11: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.	89
Figura 6.12: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.	90
Figura 6.13: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.	90
Figura 6.14: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.	91

Figura 6.15: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.....	91
Figura 6.16: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.....	92
Figura 6.17: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.	92
Figura 6.18: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.....	93
Figura 6.19: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.....	93
Figura 6.20: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.....	94
Figura 6.21: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.	94
Figura 6.22: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.....	95
Figura 6.23: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.....	95
Figura 6.24: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.....	96
Figura 6.25: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.	96
Figura 6.26: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.....	97
Figura 6.27: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.....	97
Figura 6.28: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.....	98
Figura 6.29: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.	98
Figura 6.30: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.....	99

Figura 6.31: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.....	99
Figura 6.32: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.....	100
Figura 6.33: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.	100
Figura 6.34: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.....	101
Figura 6.35: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.....	101
Figura 6.36: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.....	102
Figura 6.37: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.....	104
Figura 6.38: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.....	105
Figura 6.39: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.	105
Figura 6.40: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.....	106
Figura 6.41: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.....	106
Figura 6.42: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.	107
Figura 6.43: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.....	107
Figura 6.44: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.....	108
Figura 6.45: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.	108
Figura 6.46: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.....	109

Figura 6.47: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.....	109
Figura 6.48: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.	110
Figura 6.49: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.....	110
Figura 6.50: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.....	111
Figura 6.51: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.	111
Figura 6.52: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.....	112
Figura 6.53: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.	112
Figura 6.54: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.	113
Figura 6.55: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.....	113
Figura 6.56: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.	114
Figura 6.57: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.	114
Figura 6.58: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.....	115
Figura 6.59: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.	115
Figura 6.60: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.	116
Figura 6.61: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.....	116
Figura 6.62: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo pela GRNN.	117

Figura 6.63: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.	117
Figura 6.64: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.	120
Figura 6.65: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.	121
Figura 6.66: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.	121
Figura 6.67: Comportamento do erro quadrático médio em função do número de épocas.	122
Figura 6.68: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.	122
Figura 6.69: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.	123
Figura 6.70: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.	123
Figura 6.71: Comportamento do erro quadrático médio em função do número de épocas.	124
Figura 6.72: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.	124
Figura 6.73: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.	125
Figura 6.74: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.	125
Figura 6.75: Comportamento do erro quadrático médio em função do número de épocas.	126
Figura 6.76: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.	126
Figura 6.77: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.	127
Figura 6.78: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.	127

Figura 6.79: Comportamento do erro quadrático médio em função do número de épocas.....	128
Figura 6.80: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.....	128
Figura 6.81: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.	129
Figura 6.82: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.....	129
Figura 6.83: Comportamento do erro quadrático médio em função do número de épocas.....	130
Figura 6.84: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.	130
Figura 6.85: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.	131
Figura 6.86: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.....	131
Figura 6.87: Comportamento do erro quadrático médio em função do número de épocas.....	132
Figura 6.88: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.	132
Figura 6.89: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.	133
Figura 6.90: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.....	133
Figura 6.91: Comportamento do erro quadrático médio em função do número de épocas.....	134
Figura 6.92: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.	134
Figura 6.93: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.	135
Figura 6.94: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.....	135

Figura 6.95: Comportamento do erro quadrático médio em função do número de épocas.....	136
Figura 6.96: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.....	136
Figura 6.97: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.	137
Figura 6.98: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.....	137
Figura 6.99: Comportamento do erro quadrático médio em função do número de épocas.....	138

LISTA DE TABELAS

Tabela 3.1: Graus de liberdade para moléculas com N átomos.	38
Tabela 5.1: Oito primeiras colunas, referentes aos dados do GPS e valores obtidos em laboratório.	69
Tabela 5.2: Valores de refletância para cada comprimento de onda, medidos pelo conjunto da esquerda com e sem luz artificial.	70
Tabela 5.3: Valores de refletância para cada comprimento de onda, medidos pelo conjunto da direita com e sem luz artificial.....	71
Tabela 5.4:Arquiteturas utilizadas para validação.	77
Tabela 5.5: Configurações da RNA PMC.	78
Tabela 5.6: Configurações do sistema ANFIS.....	79
Tabela 6.1: Comportamento das RNAs PMC com o melhor desempenho para cada um dos treinamentos na validação cruzada.....	83
Tabela 6.2: Erros relativos para cada amostra de validação em cada treinamento.	84
Tabela 6.3: Comportamento das RNAs GRNN com o melhor desempenho para cada um dos treinamentos na validação cruzada.....	103
Tabela 6.4: Erros relativos produzidos de GRNN para cada amostra de validação em cada treinamento.....	104
Tabela 6.5: Comportamento dos sistemas de inferência neuro- <i>fuzzy</i> adaptativo (ANFIS) com o melhor desempenho para cada um dos treinamentos na validação cruzada.....	119
Tabela 6.6: Erros relativos produzidos ANFIS para cada amostra de validação em cada treinamento.....	120

LISTA DE ABREVIATURAS E SIGLAS

ALS	<i>Active Light Source</i> (Fonte de Luz Ativa)
ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i> (Sistema de Inferência Neuro-Fuzzy Adaptativo)
AP	Agricultura de Precisão
DGPS	<i>Differential Global Positioning System</i> (Sistema de Posicionamento Global Diferencial)
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
EAM	Erro Absoluto Médio
EQM	Erro Quadrático Médio
ERM	Erro Relativo Médio
FIS	<i>Fuzzy Inference System</i> (Sistema de inferência Fuzzy)
GPS	<i>Global Positioning System</i> (Sistema de Posicionamento Global)
GRNN	<i>Generalized Regression Neural Network</i> (Redes Neurais de Regressão Generalizada)
ISFET	<i>Ion Selective Field Effect Transistor</i> (Transistor de Efeito de Campo Sensível a Íons)
N ₂	Nitrogênio
NIR	<i>Near Infra-Red</i> (Infravermelho Próximo)
PMC	<i>Perceptron</i> Multicamadas
REQM	Raiz do Erro Quadrático Médio
RNA	Redes Neurais Artificiais
SPAD	<i>Soil Plant Analysis Development</i> (Clorofilômetro)

SUMÁRIO

CAPÍTULO 1: INTRODUÇÃO.....	20
1.1 MOTIVAÇÃO E JUSTIFICATIVA	23
1.2 OBJETIVO	23
1.3 CONTRIBUIÇÃO	24
1.4 PUBLICAÇÕES RELACIONADAS.....	24
CAPÍTULO 2: IDENTIFICAÇÃO DO TEOR DE NITROGÊNIO EM AMBIENTES AGRÍCOLAS.....	25
2.1 ELETRODOS DE DETECÇÃO DE AMÔNIA	25
2.2 ELETRODO SELETIVO DE NITRATO	26
2.3 <i>ION SELECTIVE FIELD EFFECT TRANSISTOR</i> (ISFET)	27
2.4 SENSORES DE INFRAVERMELHO PRÓXIMO	28
CAPÍTULO 3: ESPECTROSCOPIA.....	32
3.1 ABSORÇÕES NO ESPECTRO INFRAVERMELHO	34
3.1.1 MODOS DE VIBRAÇÃO	37
3.2 REGIÕES DO ESPECTRO INFRAVERMELHO	38
3.2.1 INFRAVERMELHO PRÓXIMO.....	39
3.2.2 INFRAVERMELHO MÉDIO	40
3.2.3 INFRAVERMELHO DISTANTE.....	41
CAPÍTULO 4: FUNDAMENTOS DE SISTEMAS INTELIGENTES.....	42
4.1 ASPECTOS GERAIS	42
4.2 REDES NEURAIS ARTIFICIAIS	43
4.2.1 O NEURÔNIO ARTIFICIAL	43
4.2.2 REDES <i>PERCEPTRON</i> DE MULTIPLAS CAMADAS (PMC).....	47
4.2.3 ALGORITMO DE LEVENBERG-MARQUARDT	51
4.2.4 REDES <i>GENERAL REGRESSION NEURAL NETWORK</i> (GRNN)	53
4.2.5 SISTEMAS NEBULOSOS	54
4.2.5.1 OS CONJUNTOS <i>FUZZY</i> E FUNÇÕES DE PERTINÊNCIA	55
4.2.5.2 O SISTEMA DE INFERÊNCIA <i>FUZZY</i>	59
4.2.5.3 SISTEMA DE INFERÊNCIA <i>FUZZY</i> NEURO ADAPTATIVO (ANFIS)	60
CAPÍTULO 5: METODOLOGIA PROPOSTA.....	64
5.1 MATERIAIS.....	64

5.1.1 COLETA DE DADOS.....	64
5.1.2 SENSOR N SENSOR ALS DO FABRICANTE YARA	67
5.1.3 BANCO DE DADOS	69
5.1.4 RECURSOS COMPUTACIONAIS	71
5.2 MÉTODOS	72
5.2.1 ASPECTOS GERAIS.....	72
5.2.2 ABORDAGEM DE INTELIGÊNCIA COMPUTACIONAL PARA A CORREÇÃO DA RESPOSTA DO N-SENSOR ALS	74
5.2.3 RNA DO TIPO PMC.....	76
5.2.4 RNA DO TIPO GRNN	78
5.2.5 SISTEMA HÍBRIDO <i>ADAPTIVE NEURAL-FUZZY INFERENCE SYSTEM</i> (ANFIS)	78
5.2.6 VALIDAÇÃO DAS ABORDAGENS.....	79
CAPÍTULO 6: RESULTADOS E DISCUSSÃO.....	82
6.1 VALIDAÇÃO DAS REDES NEURAIAS ARTIFICIAIS PERCEPTRON DE MULTIPLAS CAMADAS.....	82
6.1.1 TREINAMENTO 1:.....	84
6.1.2 TREINAMENTO 2:.....	86
6.1.3 TREINAMENTO 3:.....	88
6.1.4 TREINAMENTO 4:.....	90
6.1.5 TREINAMENTO 5:.....	92
6.1.6 TREINAMENTO 6:.....	94
6.1.7 TREINAMENTO 7:.....	96
6.1.8 TREINAMENTO 8:.....	98
6.1.9 TREINAMENTO 9:.....	100
6.2 VALIDAÇÃO DAS REDES NEURAIAS ARTIFICIAIS GRNN.....	102
6.2.1 TREINAMENTO 1:.....	104
6.2.2 TREINAMENTO 2:.....	106
6.2.3 TREINAMENTO 3:.....	107
6.2.4 TREINAMENTO 4:.....	109
6.2.5 TREINAMENTO 5:.....	110
6.2.6 TREINAMENTO 6:.....	112
6.2.7 TREINAMENTO 7:.....	113

6.2.8 TREINAMENTO 8:.....	115
6.2.9 TREINAMENTO 9:.....	116
6.3 VALIDAÇÃO DO SISTEMA <i>ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM</i> (ANFIS). 118	
6.3.1 TREINAMENTO 1:.....	120
6.3.2 TREINAMENTO 2:.....	122
6.3.3 TREINAMENTO 3:.....	124
6.3.4 TREINAMENTO 4:.....	126
6.3.5 TREINAMENTO 5:.....	128
6.3.6 TREINAMENTO 6:.....	130
6.3.7 TREINAMENTO 7:.....	132
6.3.8 TREINAMENTO 8:.....	134
6.3.9 TREINAMENTO 9:.....	136
CAPÍTULO 7: CONCLUSÕES	139
REFERÊNCIAS	141
APÊNDICE A – ALGORITMO ANFIS	145
APÊNDICE B – DADOS PARA VALIDAÇÃO E TREINAMENTO	148
APÊNDICE C – ALGORITMO GRNN.....	149
APÊNDICE D – ALGORITMO RNA PMC.....	151

CAPÍTULO 1: INTRODUÇÃO

A maximização da produção de uma cultura e o uso correto e responsável de adubos e fertilizantes são problemas abordados e têm sido foco de vários estudos. (McBRATNEY *et al.*, 2005). Segundo McBratney *et al* (2005), a solução para muitos problemas na agricultura consiste em uma mudança na forma de gerenciamento do plantio.

O sistema de controle da produção agrícola utilizado nos dias de hoje, basicamente reflete o gerenciamento de forma homogênea das grandes áreas de produção. Assim emprega-se o conceito de valores médios necessários para a aplicação dos insumos, fertilizantes e defensivos em toda a área de plantio. Como esse conceito não leva em conta os valores de necessidades específicas de cada subárea produtiva, esse processo tem como retorno lavouras cuja produtividade não é uniforme (DOMINGUES, 2011).

O preço acessível dos receptores do *Global Positioning System* (GPS) ou Sistema de Posicionamento Global, junto ao avanço de sistemas operacionais, permitiu um avanço em pesquisas. Com possibilidade de melhorar os equipamentos atuais ou de até mesmo criar novos, essas pesquisas foram aplicadas na agricultura, dando origem a máquinas que são capazes de extrair informações do solo metro a metro e tratá-lo de forma pontual, diferente do método tradicional que aplica no solo um insumo uniformemente. A esse novo método de manejo do solo, foi dado o nome de Agricultura de Precisão (AP), que está diretamente relacionado à sustentabilidade, englobando ecologia, sociologia e economia (BONGIOVANI e LOWENBERG-DEBOER, 2004). No Brasil, estabeleceu-se um senso comum de que a AP é uma área do conhecimento relacionada à sofisticação das máquinas agrícolas por meio de eletrônicas embarcadas e

sistemas computacionais complexos, objetivando a sustentabilidade do agronegócio (INAMASU *et al.*, 2011).

O termo Agricultura de Precisão ainda não é bem definido por ser um tema multidisciplinar e abrangente. Assim, Auernhammer, em 1994, a definiu como uma nova forma de produzir por meio de conceitos antigos. Stafford (2000) conclui que a AP é um termo de gerenciamento de lavoura. Segundo McBratney (2005), uma definição genérica para a Agricultura de Precisão é: um tipo de agricultura que aumenta a eficiência da cultura, ou seja, um aumento de produção, por unidade de área de terra em um mesmo período, com uma rede de benefícios associada.

O processo da AP inicia-se na leitura da variável a ser controlada e fatores que interferem na análise (palha, solo, luz ambiente, etc.), identificando os parâmetros que determinam o resultado do processo, a fim de que a variável de interesse (quantidade de Nitrogênio) seja posicionada dentro de uma faixa desejada, ou seja, o denominado ciclo da AP, como mostra a Figura 1.1 (BERNARDI; FRAGALLE; INAMASU, 2011).

Figura 1.1: Ciclo da agricultura de precisão¹.



No Brasil, a Agricultura de Precisão tem sido estimulada pelo MAPA - Ministério da Agricultura, Pecuária e Abastecimento, com a missão de promover o desenvolvimento sustentável e a competitividade do agronegócio em benefício da sociedade brasileira (FILHO, 2011).

Dentro deste contexto, o Nitrogênio é um nutriente de extrema importância para o cultivo da cana-de-açúcar. Quando aplicado na quantidade correta pode acelerar o processo de crescimento da plantação, porém, o manejo incorreto desse elemento pode causar a poluição do solo e de mananciais (GAUTAM e PANIGRAHI, 2003). Identificar a quantidade correta para aplicação não é uma tarefa trivial, pois nos modelos atuais de tratamento dessa variável é assumida uma dispersão homogênea no solo (ULSON, *et al.*, 2001). O campo é dividido em pequenos setores (*grid*) e amostras de solo são retiradas para análise em laboratório. O resultado dessa análise é utilizado para

¹ Fonte: Inamassu, 2011.

gerar um mapa de fertilidade. Contudo, a variabilidade temporal pode impor erros no mapa anteriormente gerado.

1.1 MOTIVAÇÃO E JUSTIFICATIVA

O manejo correto dos nutrientes do solo, além de evitar gastos excessivos com os fertilizantes e reduzir a poluição, aumenta a quantidade de produção por hectare de uma área de plantio. Portanto, esses objetivos vão ao encontro da Agricultura de Precisão que propõe uma nova ótica, um novo modelo de tratamento das variáveis do solo com o uso de sensores que possibilitam o estudo do solo imediatamente após a aquisição de dados como, por exemplo, as tecnologias de estudo do espectro no infravermelho próximo, podendo oferecer ao produtor, em conjunto com sistemas inteligentes, a quantidade exata do nutriente em um determinado ponto. Deste modo, pode-se utilizar as informações coletadas segundo a particularidade de pequenas subáreas estudadas no universo geral da área de plantio e, assim, aplicar quantidades de fertilizantes específicas para aquele determinado ponto. Com esse novo modelo de tratamento será desnecessária a retirada e o envio das amostras de solo para laboratórios, levando em conta o longo intervalo de tempo entre a coleta e o recebimento das análises químicas das amostras coletadas.

1.2 OBJETIVO

O objetivo deste trabalho é estabelecer uma relação não paramétrica, por meio de sistemas inteligentes, que permita o correto mapeamento entre os dados obtidos pelo sensor N-SENSOR ALS do fabricante norueguês YARA, projetado para a cultura de milho, e o real teor de Nitrogênio foliar, obtidos em laboratório, na cultura de cana-de-açúcar no estágio inicial do crescimento. Para tanto, serão utilizados sistemas neuro-fuzzy, redes neurais artificiais do tipo *Perceptron* de Múltiplas Camadas (PMC) e *Generalized Regression Neural Network* (GRNN) para estabelecer o mapeamento a

partir das medições oriundas diretamente do sensor N-SENSOR ALS utilizado no campo e dos teores reais de Nitrogênio obtidos em laboratório, permitindo que os sensores utilizados neste trabalho possam ser utilizados nas condições específicas da cultura de cana-de-açúcar para o qual ele não foi projetado.

1.3 CONTRIBUIÇÃO

A partir dos resultados deste trabalho ter-se-á uma ferramenta para a identificação em tempo real do teor de Nitrogênio em cana-de-açúcar. Desta forma, a contribuição será econômica, ambiental e social, visto que reduzirá a quantidade de insumos aplicados na cultura de cana-de-açúcar, evitando poluição de mananciais e rios, e reduzindo o custo de produção desta cultura.

1.4 PUBLICAÇÕES RELACIONADAS

Coelho, S.S.; Ulson, J.A.C.; Campos, F.S.; Domingues, E.D. **Identification of the amount of nitrogen in sugar cane crops using intelligent systems and near-infrared spectroscopy.** XXXV Congress of the Commission Internationale de l'Organisation Scientifique du Travail en Agriculture (CIOSTA), Billund, Dinamarca, 2013.

CAPÍTULO 2: IDENTIFICAÇÃO DO TEOR DE NITROGÊNIO EM AMBIENTES AGRÍCOLAS

Existem várias técnicas disponíveis para se determinar a quantidade de Nitrogênio mineral no solo ou foliar. Sah (1994) realizou uma revisão detalhada da bibliografia correlata, sendo que a maioria das técnicas de laboratório não é aplicável para a rápida determinação da concentração do teor de nitrato. Pode-se citar como exemplo: eletrodos de detecção de amônia, medida da resistividade elétrica do solo, método dielétrico, coloração da folha, raios gama, eletrodo seletivo de nitrato, *Ion Selective Field Effect Transistor* (ISFET) e infravermelho próximo. Segundo Sibley (2010), durante os últimos 20 anos, as pesquisas para o desenvolvimento de uma abordagem que permita determinar a quantidade de nitrato em tempo real têm se baseado somente nas três últimas técnicas supramencionadas. Dentre as técnicas citadas por Sah (1994) e por Sibley (2010), que oferecem resultados promissores em aplicações na agricultura de precisão devido à sua característica de resposta rápida, pode-se destacar as seguintes seções:

2.1 ELETRODOS DE DETECÇÃO DE AMÔNIA

Este equipamento é uma célula potenciométrica que contém um eletrodo de referência de prata/cloreto de prata (Ag/AgCl), bem como um elemento de medição de pH. Esses elementos são acomodados dentro de um recipiente termoplástico em um eletrólito que contém íon-cloreto e são isolados da amostra por uma membrana permeável a gás construída de politetrafluoretileno (PTFE).

O gás dissolvido na solução de amostragem se dispersa através da membrana e altera o seu pH. A difusão continua até que a pressão parcial do gás na amostra e a fina membrana fiquem iguais. A mudança no pH é proporcional à concentração de gás dissolvida na solução de amostra. A Figura 2.1 mostra o sensor do fabricante HANNA.

Figura 2.1: Eletrodo de detecção de amônia do fabricante HANNA.²



2.2 ELETRODO SELETIVO DE NITRATO

Eletrodos de íon seletivos são sensores que permitem a detecção potenciométrica da atividade de uma espécie iônica na presença de outros íons. Um trabalho pioneiro neste sentido foi o relatado por Sokalski *et al.* (1997), onde pela primeira vez um limite de detecção em nível picomolar foi apresentado para o íon Pb^{2+} com eletrodo íon-seletivo de contato líquido. A partir deste trabalho, foi possível o desenvolvimento de outros sensores de íon seletivo com baixos limites de detecção. Desta forma, pode-se encontrar ISEs para K^+ , NH_4^+ , Ca^{2+} , Cd^+ entre outros. Em decorrência da impressionante melhora no limite de detecção de diversos sensores de íon seletivo, também foi possível a aplicação destes em amostras ambientais, que requerem baixos limites de detecção (TORRES *et al.* 2006).

² Retirado do site: <http://www.splabor.com.br/eletrodos/eletrodo-on-seletivo/eletrodos-on-seletivo-amonia-brometo-cadmio.html>

Figura 2.2: Eletrodo seletivo de nitrato.³



Dentro do contexto da agricultura de precisão, este princípio foi utilizado no protótipo do Adsett e Zoerb (EHSANI *et al.*, 1991),

um sistema de monitoramento de nitrato. Este protótipo tinha um sensor com velocidade de operação de 3km/h e atuava em uma profundidade de até 15 cm, com uma taxa de 24 segundos por amostra. Os testes em laboratórios indicaram que o sensor obteve uma boa resposta quanto a velocidade e precisão, tendo como desvantagem seu processo de calibração que é complexo e lento.

2.3 ION SELECTIVE FIELD EFFECT TRANSISTOR (ISFET)

Segundo Jain e Garg (2010), ISFET

é um transistor de efeito de campo utilizado para medir a concentração do íon em uma solução e que possui em seu *gate* uma membrana que responde aos íons de nitrato. Quando a concentração do íon se altera, a corrente que atravessa o transistor irá se alterar na mesma proporção.

Este dispositivo é recente e possui algumas vantagens em relação ao seu predecessor (eletrodo seletivo de nitrato), tais como: a velocidade de resposta, baixa

³ Retirado do site: <http://datasheets.globalspec.com/ds/309/FisherScientific/CFA78DDE-CF4A-47D5-B619-9323B32DAFFE>

taxa de ruído, baixa impedância de saída, tamanho reduzido (EHSANI *et al.* 1999, p. 219).


2.4 SENSORES DE INFRAVERMELHO PRÓXIMO

Este tópico irá abordar apenas os sensores que utilizam o infravermelho próximo para determinação da quantidade de Nitrogênio foliar.

É conhecido e já consagrado que existem técnicas de medição do teor de Nitrogênio foliar em laboratórios, seja ele intrusivo ou não intrusivo. Com um correto monitoramento e diagnóstico dos nutrientes das plantas, pode-se parametrizar corretamente o programa de adubação nitrogenada da cultura (HUETT *et al.*, 1997).

O tempo gasto entre a obtenção das amostras e dos resultados se torna um ponto fraco no processo da análise foliar, que anda na contra mão da proposta da agricultura de precisão, tornando necessário o uso de sensores de tempo real. Com o avanço e aperfeiçoamento dos medidores portáteis, esta avaliação da quantidade de clorofila pode ser feita de forma fácil e com baixo custo (BLACKMER E SCHEPERS, 1995; GUIMARÃES *et al.*, 1999). Como exemplo de análise intrusiva, podemos citar o medidor SPAD 502 (*Soil Plant Analysis Development*). Esse medidor analisa as folhas verdes da plantação, permitindo a utilização diretamente no campo. O índice de SPAD está diretamente correlacionado ao teor da clorofila na folha (MARKWELL *et al.*, 1995; GUIMARÃES *et al.*, 1999), como pode ser notado na Figura 2.3.

Figura 2.3: Estimativas do índice de SPAD e do teor de Nitrogênio da folha da batata.⁴



O instrumento SPAD-502 avalia quantitativamente a intensidade do verde da folha, medindo as transmissões de luz a 650 nm, onde ocorre absorção de luz pela molécula de clorofila; e a 940 nm, onde não ocorre absorção (GIL *et al*,2002). Com estes dois valores o medidor calcula o índice de SPAD.

Em relação aos métodos não intrusivos, existem basicamente três tecnologias comerciais que podem ser utilizadas em um sistema *on board* para determinar o teor do Nitrogênio foliar e regular a quantidade de adubo em tempo real. A saber: YARA N-SENSOR/FIELDSCAN, GREENSEEKER e CROP CIRCLE.

O YARA PASSIVE N-SENSOR/FIELDSCAN (YARA International ASA, Oslo, Noruega, 2004) consiste em dois espectrômetros feitos a partir de arranjos de diodos que são montados diretamente no trator. O primeiro é utilizado para realizar a leitura da plantação com quatro lentes oblíquas em ambos os lados do trator. Já o segundo, é utilizado para medir a iluminação do ambiente e realizar uma correção na leitura feita pelo primeiro espectrômetro, uma vez que a quantidade de luz incidente altera as condições de radiação (ZILLMAN *et al.*, 2006). A quantidade de Nitrogênio foliar é estabelecida medindo a característica da refletância na plantação, na região entre

⁴ Fonte: GIL *et al*. 2002.

450 nm e 900 nm. O resultado dessa medição é enviado ao equipamento que realiza a adubagem e controla, em tempo real, a quantidade de Nitrogênio que é colocada no solo (LINK *et al.*,2002). Em 2005 o fabricante YARA SENSORS colocou no mercado um novo modelo chamado de ALS (*Active Light Source*) que possui uma luz própria tornando a leitura independente da luminosidade do ambiente, podendo trabalhar vinte e quatro horas por dia (LINK e REUSCH,2006). A Figura 2.4 mostra o sensor N-SENSOR ALS.

Figura 2.4: Sensor N-SENSOR ALS⁵.



Já o GREENSEEKER da NTech Industries, Inc., Estados Unidos, (2009) é um sensor ótico integrado ao sistema de controle da taxa de aplicação de Nitrogênio no solo, que ajusta este valor de acordo com a necessidade da plantação, utilizando os dados do sensor. Utiliza luz vermelha (650 nm) e NIR (770 nm). A energia é emitida de dois arranjos de diodos que ligam e desligam alternadamente. (Schepers, 2008)

O CROP CIRCLE ACS-210 (Holland Scientific, Estados Unidos) é um sensor de luz similar ao GREENSEEKER, com apenas algumas características óticas


⁵ Retirado do site: <http://www.agricon.de/en/products/sensors-agronomy/basic-technical-information>

diferentes. A tecnologia da fonte de luz usada no CROP CIRCLE, chamada de POLYSOURCE , utiliza duas fontes de luz simultaneamente, uma na região visível (590 nm) e outra NIR (880 nm), ambas provenientes do mesmo LED. A iluminação cobre a mesma área para as duas regiões do comprimento de onda. Diferentemente do GREENSEEKER o CROP CIRCLE possui dois sistemas de detecção de luz, que eliminam a interferência das ondas e reduzem a histerese do sensor.

CAPÍTULO 3: ESPECTROSCOPIA


A espectroscopia no infravermelho é a forma mais importante que os cientistas possuem nos dias de hoje para fazer a análise de uma amostra. Baseada nas vibrações dos átomos das moléculas, essa técnica pode analisar qualquer tipo de material, desde líquidos e soluções, até gases, incluindo pastas e pós. Equipamentos que utilizam a espectroscopia começaram a ser fabricados em escala comercial em meados de 1940, mas foi com a Transformada de Fourier que essa técnica obteve um salto nas aplicações. A Transformada de Fourier na espectrometria infravermelha (FTIR) permitiu uma melhor análise do espectro, aumentando a qualidade das medições e diminuindo o tempo necessário para se obter uma resposta. Um espectro infravermelho pode ser obtido passando uma radiação infravermelha através de uma amostra e medindo a quantidade de energia que foi absorvida pela amostra. Os picos que aparecem no espectro correspondem à frequência de vibração de uma parte das moléculas da amostra, esses picos formam uma assinatura espectral, servindo como base para determinação dos elementos que compõem a amostra. A Figura 3.1 mostra a assinatura espectral para uma folha verde (curva a), seca (curva b) e para o solo (curva c) nas regiões da cor azul, vermelha, verde e infravermelha, respectivamente. Pode-se notar um pico na região infravermelha da folha verde.

Figura 3.1: Assinaturas espectrais⁶.



⁶ Retirado do site: <http://www.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>

De acordo com a teoria clássica de Maxwell, a radiação é considerada como um campo elétrico e um campo magnético perpendiculares entre si, oscilando em um único plano, ou seja, uma onda eletromagnética que abrange todas as frequências possíveis. Esses campos estão em fase entre si, como uma onda senoidal. A Figura 3.2 representa esses campos em seus planos, e as letras B e E indicam a amplitude das ondas do campo magnético e elétrico respectivamente (STUART, 2005).




Uma importante descoberta realizada é que o produto do comprimento de onda, λ (distância consecutiva entre dois picos) e frequência ν (número de ciclos em um segundo) é igual à velocidade da luz c , que vale $2,99 \times 10^8 \text{ [m/s]}$, sendo constante em todas as regiões do espectro. A unidade de medida para comprimento de onda é o metro, m, e seus submúltiplos, por exemplo, o μm (lê-se micrometro) (STUART, 2005).

$$c = \lambda * \nu \quad (3.1)$$

⁷ Fonte: STUART, 2005

O espectro eletromagnético visível é a radiação que o olho humano pode detectar. Porém, existem outras faixas do espectro além da radiação visível, e são classificados como onda de rádio, micro-ondas, infravermelho, ultravioleta, raios X e raios gama. A Figura 3.3 mostra essas regiões, bem como a quantidade de energia de cada uma delas (STUART, 2005).

Figura 3.3: As regiões da radiação eletromagnética⁸.




A radiação no espectro infravermelho é a radiação localizada nos comprimentos de ondas mais longos (baixas frequências) que a luz vermelha, possuindo uma frequência da ordem de 1000nm (ATKINS, 2001).

3.1 ABSORÇÕES NO ESPECTRO INFRAVERMELHO

Todas as moléculas apresentam uma vibração característica das ligações entre os átomos que as compõem. As ligações entre apenas dois átomos vibram, podendo se afastar ou se aproximar e a este movimento dá-se o nome de deformação axial ou estiramento. Para moléculas compostas de mais de dois átomos, chamadas de poliatômicas esta vibração pode apresentar além do movimento de estiramento,

⁸ Fonte: LEITE *et al*, 2012

deformação angular ou dobramento, que é referente à alteração entre os ângulos das ligações, conforme apresentado na Figura 3.4 (ATKINS, 2001).



Essa frequência de vibração está diretamente relacionada à massa dos átomos que encontra-se nas extremidades das ligações. De forma geral, moléculas que apresentam átomos leves e ligações fortes possuem frequência vibracional mais alta em relação às que possuem átomos pesados unidos por ligações baixas, ou seja, as primeiras absorvem frequências mais altas. Em relação ao dobramento, este movimento tende a ser menos rígido quando comparado com o estiramento e, por este motivo, o dobramento absorve mais energia em frequências mais baixas em relação ao estiramento (ATKINS, 2001).


A rigidez da ligação pode ser comparada a um sistema massa-mola, Figura 3.5, respeitando a lei de Hooke, conforme a equação 3.2:

⁹ Fonte: STUART, 2005

$$Força = -k * deslocamento \quad (3.2)$$

onde k, é a constante de força da mola.

Figura 3.5: Sistema massa mola representando a rigidez das vibrações¹⁰.



A frequência vibracional do sistema, ν , depende da massa efetiva do sistema, (μ), e da constante de força da mola, k, como pode ser observado na equação 3.3:

$$\nu = \left(\frac{1}{2\pi}\right) * \sqrt{\frac{k}{\mu}} \quad (3.3)$$

A massa efetiva do sistema ou massa reduzida, (μ), é descrita pela equação 3.4 e depende das massas dos átomos que estão na extremidade da ligação, onde m_a representa a massa do átomo A e m_b representa a massa do átomo B.

$$\mu = \frac{m_a * m_b}{m_a + m_b} \quad (3.4)$$

A frequência de vibração é maior para ligações fortes (k alto) e massa efetiva baixa (μ pequeno), ou seja, pode-se saber a força das ligações entre os átomos, medindo as frequências de vibração que a molécula absorve na radiação infravermelha. Para isto,

¹⁰ Fonte: ELDIN,2011

usa-se um espectrômetro de infravermelho. O resultado deste espectro chama-se assinatura espectral e é característico de cada molécula, como já citado na introdução deste capítulo.


A molécula apenas absorve a radiação infravermelha quando a frequência da radiação for exatamente a mesma de uma das frequências fundamentais de vibração. Isto significa que uma pequena parte da molécula sofre um aumento na frequência de vibração, enquanto que o restante permanece inalterado.

3.1.1 MODOS DE VIBRAÇÃO

A quantidade dos tipos de vibração presentes em uma molécula depende da sua geometria e da quantidade de átomos que estão na sua estrutura. Quanto à sua geometria ela pode ser linear ou não linear. As moléculas são lineares quando o ângulo entre as ligações é de 180° , ou seja, estas ligações estão em um mesmo plano. Como exemplo, pode-se citar o gás carbônico (CO_2). As moléculas não lineares são caracterizadas por ângulos entre as ligações diferentes de 180° , ou seja, essas ligações estão em planos diferentes, é o caso da água (H_2O). A Figura 3.6 representa as ligações destas moléculas. Cada modo que a molécula pode vibrar é chamado de modo normal de vibração.

Figura 3.6: Moléculas lineares e não lineares.

A imagem a. representa uma molécula linear, e b. representa uma molécula não linear.



Uma molécula diatômica apresenta três graus de liberdade de translação e dois graus de liberdade de rotação. Os átomos de uma molécula podem se mover em relação ao outro, ou seja, os comprimentos das ligações podem variar. Os movimentos de estiramento e compressão das ligações definem o termo vibrações. Para uma molécula de apenas dois átomos, apenas um grau de liberdade corresponde ao estiramento ou compressão da ligação.

Para moléculas que contém N átomos, existirão 3 graus de liberdade. Todavia, para moléculas com três átomos existem duas situações possíveis: linear ou não linear. Um exemplo desses grupos é a água (H_2O) e o gás carbônico (CO_2), ambos possuem três graus de liberdade de translação, porém, a água possui três graus de liberdade de rotação e a molécula linear do dióxido de carbono apenas dois, pois não há energia de rotação envolvida ao redor das ligações. Os graus de liberdade de uma molécula com N átomos estão descritos na Tabela 3.1 (STUART, 2005).

Tabela 3.1: Graus de liberdade para moléculas com N átomos¹¹.

Tipos de graus de liberdade	Linear	Não linear
Translação	3	3
Rotação	2	3
Vibração	$3N-5$	$3N-6$
Total	$3N$	$3N$

3.2 REGIÕES DO ESPECTRO INFRAVERMELHO

Devido ao fato das faixas que aparecem poderem geralmente ser associadas à uma característica particular da molécula, correlacionar estes dados a um elemento

¹¹ Fonte: STUART, 2005

químico se torna uma tarefa simples, gerando o que é conhecido como grupo de frequências. Esse grupo é dividido em três, a saber: Infravermelho próximo (NIR - *near infra red*), infravermelho distante (FIR – *far infra red*), e infravermelho médio (MIR – *mid infra red*) (STUART, 2005).

3.2.1 INFRAVERMELHO PRÓXIMO

De acordo com Eldin, (2011), “NIR (*near infrared*) está localizada logo após a região visível do espectro, entre 750 e 3000nm”. A grande maioria dos materiais orgânicos possui uma boa transmitância ou refletância nesta faixa. De forma geral, uma análise feita na região NIR pode especificar e caracterizar, funcionalidades específicas do espectro com o uso de métodos estatísticos.

A absorção nesta faixa é devida à combinação de faixas primárias alongadas, que estão comumente relacionadas às ligações entre Carbono e Hidrogênio, Nitrogênio e Hidrogênio e Oxigênio e Hidrogênio. Os resultados são geralmente fracos em termos de intensidade e, por serem geralmente sobrepostos, são menos utilizados que o infravermelho médio.

Segundo Eldin (2011) a maior vantagem do infravermelho próximo em relação aos outros dois grupos (infravermelho médio e distante) é a pouca ou nenhuma preparação da amostra para análise em tempo real. Ao contrário, os métodos de análises convencionais na região NIR são rápidos, não destrutivos, não utilizam produtos químicos e não geram resíduos que necessitem de descarte apropriado, podendo determinar simultaneamente vários constituintes ou parâmetros e serem facilmente transportados para quase todos os ambientes, ou serem portáteis para o campo de trabalho. Os instrumentos que utilizam NIR são de simples operação, podendo ser facilmente operados por pessoas que não são da área química, sem exaustores, drenos ou outras instalações. Outra vantagem do NIR sobre MID-IR e o FAR-IR é o ruído

térmico. Todos os componentes eletrônicos do MID ou FAR são fontes de ruídos térmicos, entretanto, estas fontes não atrapalham as leituras dos sensores NIR.

Em uma análise NIR, a maioria do espectro é formada por uma combinação de harmônicas que são mais sutis que a fundamental da região MID-IR e FAR-IR. (ELDIN,2011).

Eldin (2011) também afirma que, como a NIR é uma tecnologia que não pode ser utilizada sozinha, este se torna um ponto fraco. Calibrações separadas são necessárias para cada novo parâmetro de uma amostra até então desconhecida, somando assim mais uma desvantagem desta técnica.

A técnica de espectroscopia NIR é rápida e fornece o resultado da amostra em menos de um minuto. A parte que consome mais tempo é a etapa de calibração do equipamento, onde químico tentam encontrar uma relação entre o espectro no infravermelho próximo, lido com a característica ou propriedade de interesse a ser medida.

3.2.2 INFRAVERMELHO MÉDIO

Essa região do espectro está entre $4000\text{--}400\text{ cm}^{-1}$ e pode ser dividida em quatro regiões. A natureza de um grupo de frequências pode ser geralmente determinada pela região em que se localiza. As regiões são classificadas da seguinte forma:

- Região de alongamento de X – H ($4000\text{--}2500\text{ cm}^{-1}$);
- Região da tripla ligação ($2500\text{--}2000\text{ cm}^{-1}$);
- Região da dupla ligação ($2000\text{--}1500\text{ cm}^{-1}$);
- Região da impressão digital ($1500\text{--}600\text{ cm}^{-1}$).

Como já foi dito, cada faixa no espectro do infravermelho próximo pode estar associada a uma deformação particular da molécula, do movimento de um grupo de átomos ou pela flexão/alongamento das ligações. Isto é possível para várias faixas de

frequência, principalmente para vibrações de múltiplas ligações que os comprimentos de onda observados na refletância não se alteram. Entretanto, nem todas as moléculas possuem essa característica, e os comprimentos de ondas observados no espectro podem variar por centenas de nanômetros, inclusive para moléculas similares. O espectro de uma molécula pode ter centenas de faixa de absorções, porém, não é necessário assimilar a grande maioria delas. O espectro pode ser considerado como a impressão digital da molécula, essa região do espectro é referida como região da impressão digital.

3.2.3 INFRAVERMELHO DISTANTE


A região do infravermelho distante é definida como a região entre 400 e 100 cm^{-1} . Essa região é mais limitada que a região do infravermelho médio e fornece informações relacionadas às moléculas que contém átomos pesados e vibrações da estrutura da molécula. Estas informações das vibrações de átomos pesados podem ser importantes para caracterizar átomos compostos de halogêneos, organometálicos e compostos inorgânicos.

CAPÍTULO 4: FUNDAMENTOS DE SISTEMAS INTELIGENTES

4.1 ASPECTOS GERAIS

Segundo Charniak e McDermott (1985), inteligência computacional ou artificial é o estudo das faculdades mentais através do uso de modelos computacionais. A partir da segunda guerra mundial e com o avanço no desenvolvimento tecnológico dos computadores, essa área de conhecimento sofreu grande desenvolvimento e, atualmente, os sistemas inteligentes estão organizados de acordo com a Figura 4.1.

Figura 4.1: Organização dos sistemas inteligentes.



Dentre as ferramentas de inteligência computacional mais difundidas estão:

- a.) Sistemas de produção: busca-se caracterizar a heurística e os conhecimentos de especialistas humanos por meio da aplicação de conceitos de lógica;

- b.) Lógica nebulosa: busca-se considerar as incertezas inerentes à representação humana dos fenômenos da natureza, refletida nas expressões verbais empregadas corriqueiramente;
- c.) Redes neurais artificiais: busca-se mimetizar o cérebro humano por meio de elementos processadores simples denominados neurônios;
- d.) Computação evolutiva: busca-se simular o processo de seleção natural, descrito por Charles Darwin em “A origem das espécies” visando a solução de problemas complexos.

Neste trabalho serão utilizados dois modelos de inteligência artificial: redes neurais artificiais e sistemas nebulosos, apresentados nas próximas seções.

4.2 REDES NEURAIS ARTIFICIAIS


4.2.1 O NEURÔNIO ARTIFICIAL

Os sistemas com Redes Neurais Artificiais (RNA) são compostos por elementos processados e interconectados, denominados nós ou neurônios artificiais, tendo eles a capacidade de resolver problemas complexos e não lineares, tais como: extração de características, classificação de padrões e filtragem adaptativa.

A combinação ou agrupamento dos neurônios artificiais e os algoritmos que processam o tráfego de informações entre eles são semelhantes ao funcionamento dos neurônios biológicos, executando sua principal função de receber e transmitir informações.

O modelo de neurônio artificial mais simples que engloba as principais características neurais biológicas, paralelismo e alta conectividade, foi proposto por McCulloch e Pitts (1943) e está ilustrado na Figura 4.2.

Figura 4.2: Modelo geral do neurônio artificial.



As equações 4.1 e 4.2 descrevem o comportamento do neurônio artificial:

$$u = \sum_{i=1}^N w_i \cdot x_i + b \quad (4.1)$$

$$y = g(u) \quad (4.2)$$

onde:

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

$w_1, w_2, \dots, w_N$ são os pesos ou conexões sinápticas;

b_N é o limiar de ativação do neurônio;

u_N é a saída do combinador linear;

$g(u)$ é a função de ativação (limita a saída do neurônio);

y é o sinal de saída do neurônio.

A função de ativação é escolhida de acordo com o problema em que se encontra a rede. Do ponto de vista funcional, a função de ativação $g(\cdot)$ processa o conjunto de

entradas recebidas e o transforma em estado de ativação. Normalmente, o estado de ativação do neurônio pode assumir valores binários (0 e 1), bipolares (-1 e 1) e reais.

As funções de ativação mais típicas são:


a.) Função degrau

Nesse tipo de ativação, mostrado na Figura 4.3, tem-se:

$$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad (4.3)$$

A saída do neurônio assumirá o valor 1 se o nível de atividade interna total do neurônio for não negativo, caso contrário a saída do neurônio assumirá o valor 0.

Figura 4.3: Função degrau.




b.) Função degrau (bipolar)

Nesse tipo de ativação, mostrado na Figura 4.4, tem-se:

$$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ -1 & \text{se } u < 0 \end{cases} \quad (4.4)$$


A saída do neurônio assumirá o valor 1 se o nível de atividade interna total do neurônio for não negativo, caso contrário, a saída do neurônio assumirá o valor -1.

Figura 4.4: Função degrau (bipolar).

c.) Função rampa

Nesse tipo de ativação, mostrado na Figura 4.5, tem-se:

$$g(u) = \begin{cases} 1 & \text{se } u \geq a \\ u & \text{se } -a < u < a \\ -1 & \text{se } u \leq -a \end{cases} \quad (4.5)$$


Figura 4.5: Função rampa.

Para essa função de ativação, a saída do neurônio pode assumir valores positivos e negativos no domínio de -1 a 1, e no intervalo definido entre $\{-a, a\}$, a saída assume o valor da função $g(u)=u$.

d.) Função sigmóide

Para a função sigmóide, ilustrada na Figura 4.6, tem-se:

$$g(u) = \frac{1}{1 + e^{(-\beta u)}} \quad (4.6)$$


Figura 4.6: Função sigmóide.

Na equação 4.6, β é o parâmetro que define a inclinação (ganho) da função sigmóide. Nesse tipo de função, a saída do neurônio assumirá valores reais entre 0 e 1.

e.) Função tangente hiperbólica

Para a função do tipo tangente hiperbólica Figura 4.7, tem-se:

$$g(u) = \tanh(u) = \frac{1 - e^{-u}}{1 + e^{-u}} \quad (4.7)$$

Figura 4.7: Função tangente hiperbólica.

Para essa função de ativação, a saída do neurônio pode assumir valores reais (negativos e positivos) no domínio de -1 a 1.

4.2.2 REDES *PERCEPTRON* DE MULTIPLAS CAMADAS (PMC)

As redes *perceptron* de múltiplas camadas (PMC) representam uma generalização do *perceptron* de camada única e são constituídas por: i) uma camada de entrada; ii) pelos menos uma camada de neurônios escondida; iii) uma camada neural de saída.

Existem diversos tipos de algoritmos de aprendizagem, cada qual específico para uma determinada arquitetura de rede. Esses algoritmos diferem entre si principalmente pelo modo como os pesos são ajustados.

O treinamento supervisionado de Redes Neurais Artificiais do tipo *Perceptron* de múltiplas camadas é comumente treinado utilizando no algoritmo *backpropagation*. Durante o treinamento com o algoritmo *backpropagation*, a rede opera em uma sequência de dois passos:

1. Passo para a frente (propagação):


Um padrão de treinamento é apresentado à camada de entrada da rede. Realiza-se a computação, camada por camada, até que a resposta seja produzida pela camada de saída.

2. Passo para trás (retro propagação):

A saída obtida é comparada à saída desejada para esse padrão particular. Se essa não estiver correta, o erro é calculado. O erro é então retropropagado a partir da camada de saída até a camada de entrada e os pesos das conexões das unidades das camadas internas sofrem modificações conforme o erro é retropropagado (HAYKIN, 1999). Esse processo é repetido para todos os vetores de entrada da rede até que o erro quadrático médio das saídas alcance um valor aceitável.

A derivação do algoritmo *backpropagation*, para redes *Perceptron* com uma única camada escondida é realizada conforme a notação apresentada na Figura 4.8.

Figura 4.8: Diagrama esquemático da rede *Perceptron* multicamadas.



A partir da Figura 4.8, adota-se a seguinte convenção:

- O parâmetro N especifica o número de variáveis que constitui cada vetor de entrada;
- O parâmetro $N1$ especifica a quantidade de neurônios utilizados na camada neural escondida;
- O parâmetro $N2$ especifica o número de variáveis que constituem cada vetor de saída, e também indica a quantidade de neurônios utilizados na camada neural de saída;
- O vetor $x = [x_1, x_2, \dots, x_N]^T$ denota o vetor de entrada da rede;
- O vetor $y = [y_1, y_2, \dots, y_{N2}]^T$ denota o vetor de saída da rede;
- O símbolo $w1_{ji}$ fornece o valor do peso sináptico conectando o j -ésimo neurônio da camada (1) ao i -ésimo neurônio da camada (1-1);
- O símbolo $I1_j$ fornece o valor correspondente à entrada ponderada do j -ésimo neurônio da camada (1), ou seja:

$$I1_j = \sum_{i=0}^N w1_{ji} x_i ; j = 1, \dots, N1 \quad (4.8)$$

$$I2_j = \sum_{i=0}^N w2_{ji} y1_i ; j = 1, \dots, N2 \quad (4.9)$$

O símbolo $y1_j$ fornece o valor correspondente à saída do j -ésimo neurônio da camada (1), ou seja:

$$y1_j = g(I1_j); j = 1, \dots, N1 \quad (4.10)$$

$$y2_j = g(I2_j); j = 1, \dots, N2 \quad (4.11)$$

As funções erro quadrático $E(k)$ e erro quadrático médio E_M , as quais são utilizadas como índices de desempenho e critérios de parada do processo de treinamento, são definidas por:

a) **Erro quadrático**

Essa função fornece o valor instantâneo da soma dos erros quadráticos (em relação ao k -ésimo padrão de treinamento) de todos os neurônios da camada de saída da rede, ou seja:

$$E(k) = \frac{1}{2} \sum_{j=1}^{N2} (d_j(k) - y2_j(k))^2 \quad (4.12)$$

onde, $d_j(k)$ é o valor da saída desejada no neurônio j em relação ao k -ésimo padrão de entrada.

b) Erro quadrático médio

O erro quadrático médio, ou energia média do erro quadrático médio, é obtido a partir da soma dos erros quadráticos relativos a todos os padrões de entrada utilizados no conjunto de treinamento da rede, ou seja:

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k) \quad (4.13)$$

onde o parâmetro p especifica o número de padrões de treinamento ou a quantidade de vetores de entrada.

Para um dado conjunto de treinamento, E_M representa a função de custo como uma medida de desempenho do aprendizado. Assim, o objetivo do processo de aprendizagem, utilizando o algoritmo *backpropagation*, consiste em ajustar as matrizes de pesos **W1** e **W2** da rede a fim de minimizar a função de custo E_M .

4.2.3 ALGORITMO DE LEVENBERG-MARQUARDT

O algoritmo *backpropagation* ajusta os valores das matrizes de pesos **W1** e **W2** em relação à direção oposta do gradiente da função erro quadrático. Entretanto, a utilização desse algoritmo na prática tende a convergir muito lentamente, exigindo assim um elevado esforço computacional. Para contornar esse problema, várias técnicas de otimização têm sido incorporadas ao algoritmo *backpropagation* a fim de reduzir o seu tempo de convergência e diminuir o esforço computacional exigido pelo mesmo. Dentre as técnicas mais utilizadas para esse propósito destaca-se o algoritmo de Levenberg-Marquardt (HAGAN e MENHAJ, 1994).

O algoritmo de Levenberg-Marquardt é uma técnica baseada no método dos mínimos quadrados para modelos não-lineares que pode ser incorporada ao algoritmo *backpropagation* a fim de aumentar a eficiência do processo de treinamento.

Assim como os métodos quasi-Newton, o algoritmo de Levenberg-Marquardt implementa um treinamento de segunda ordem sem computar a matriz Hessiana ($\mathbf{H}$). Lembrando que:

$$\mathbf{w}(n+1) = \mathbf{w}(n) - \mathbf{H}^{-1}(n)\nabla\mathbf{e}[\mathbf{w}(n)] \quad (4.14)$$

Como a função custo é função de um somatório do quadrado do erro, a matriz Hessiana pode ser aproximada por:

$$\tilde{\mathbf{H}}(n) = \mathbf{J}^T(n)\mathbf{J}(n) \quad (4.15)$$

onde, $\mathbf{J}$ é a matriz jacobina e é composta das derivadas parciais dos erros da rede em relação aos pesos.

Portanto, do método de Newton obtém-se o método de Gauss-Newton:

$$\mathbf{w}(n+1) = \mathbf{w}(n) - (\mathbf{J}^T(n)\mathbf{J}(n))^{-1}\mathbf{J}^T(n)\mathbf{e}(n) \quad (4.16)$$

Entretanto, a matriz produto $(\mathbf{J}^T\mathbf{J})$ deve ser singular. Para assegurar que tal matriz produto seja não singular, as n linhas da matriz Jacobina devem ser linearmente independentes. Para assegurar essa condição, adiciona-se uma matriz diagonal matriz $(\mathbf{J}^T\mathbf{J})$.

$$\mathbf{w}(n+1) = \mathbf{w}(n) - (\mathbf{J}^T(n)\mathbf{J}(n) + \mu\mathbf{I})^{-1}\mathbf{J}^T(n)\mathbf{e}(n) \quad (4.17)$$

Quando $\mu=0$, tem-se o método de Newton. Se μ é grande tem-se o método do gradiente descendente com passo pequeno. Na implementação computacional, μ é feito

variável, aumentando quando a função custo diminui em interações sucessivas e diminuídas quando a função custo aumenta. Esse algoritmo apresenta um resultado cerca de 10 a 1000 vezes mais rápido que o algoritmo *backpropagation* básico.

4.2.4 REDES *GENERAL REGRESSION NEURAL NETWORK* (GRNN)

As redes GRNN foram descritas pela primeira vez por Specht (1991). São implementações neurais de passo único dos estimadores de Parzen (1962) com um ou dois parâmetros a serem ajustados, o que as tornam relativamente rápidas.

A rede GRNN é uma variação das *Radial Base Function* (RBF). Apresenta grande capacidade de generalização, sendo bastante utilizada na aproximação de funções. Seu funcionamento é semelhante ao da rede PNN (*Probabilistic Neural Network*), que determina limites de decisão entre padrões, embora a GRNN resulte em valores contínuos (SPECHT, 1991).

Cada neurônio da unidade padrão é um centro de agrupamento, sendo que o número de neurônios dessa camada é igual ao número de exemplares utilizados durante o treinamento. Quando um novo padrão é apresentado à rede, é calculada a distância entre este novo padrão e os exemplares previamente armazenados. O valor absoluto dessas diferenças é somado e multiplicado pelo *bias*, sendo então enviados a uma função de ativação não linear. Uma exponencial é utilizada como função de ativação, sendo o *bias* ajustado para $0.8326/spread$, onde o *spread* é o espalhamento, ou a abertura da exponencial utilizada, demonstrada na equação 4.18. Sendo $\mathbf{X}$ um vetor de variáveis aleatórias e y uma variável aleatória escalar, tem-se que:

$$\mathbf{D}_i^2 = (\mathbf{X} - \mathbf{X}^i)^T (\mathbf{X} - \mathbf{X}^i) \quad (4.18)$$

$$Y'_i = \frac{\sum_{i=1}^n y^i e^{-\frac{D_i^2}{2\sigma^2}}}{\sum_{i=1}^n e^{-\frac{D_i^2}{2\sigma^2}}} \quad (4.19)$$

Dessa forma, o parâmetro σ pode ser visualizado como um parâmetro de suavização. Se σ possuir um valor grande a densidade estimada é forçada a ser suave e no limite torna-se uma multivariável gaussiana com covariância σ^2 . Porém, se σ conter um valor pequeno, permite à densidade estimada assumir formas não gaussianas. Assim, em muitos casos a rede GRNN torna-se mais vantajosa que PMC com dados ruidosos ou esparsos.

4.2.5 SISTEMAS NEBULOSOS

A teoria da lógica nebulosa é uma abordagem da inteligência artificial que se consiste na resolução de problemas complexos mediante mecanismos que tratem informações imprecisas. Na teoria clássica de conjuntos, um elemento pertence a um determinado conjunto segundo uma função característica que mapeia um conjunto universo segundo critérios que fornecem respostas discretas baseadas em fronteiras e conjuntos bem definidos. Como exemplo, seja um conjunto universo U e um subconjunto S , tal que S esteja contido em U , e x um elemento pertencente a S . Define-se uma função característica sendo uma função $\mu : U \rightarrow \{0,1\}$ com:

$$\mu(x) = \begin{cases} 0, & \text{se } x \notin S \\ 1, & \text{se } x \in S \end{cases} \quad (4.20)$$

Observa-se que a função $\mu(x)$ define dois conjuntos assumindo valores discretos e mapeando o universo U .

A teoria dos conjuntos *fuzzy*, introduzida no ano de 1965 por Zadeh, surgiu mediante a necessidade de manipulação de dados imprecisos. São conjuntos cuja característica se dá por não possuir fronteiras bem delimitadas como na teoria clássica.

A abordagem proposta se deu pela generalização da função característica, que pode assumir infinitos valores entre 0 e 1, sugerindo que alguns elementos são mais pertinentes que os outros. Deu-se então a definição de grau de pertinência que representa valores entre 0 e 1, sendo o nível 0 usado para representar total impertinência e 1, total pertinência de uma dada classe (BENINI, 2007).

Na teoria proposta por Zadeh, a ideia de função de inclusão é flexibilizada, indicando que um elemento possa pertencer mais a um determinado conjunto que outro elemento. Por conseguinte, definiu-se a função de pertinência de um determinado conjunto *fuzzy*, que pondera as características oriundas aos elementos em estudo. Sendo assim, a lógica *fuzzy* pode ser aplicada em problemas com alto grau de complexidade e exatidão, como também em problemas em que resultados aproximados são aceitáveis (BENINI, 2007).


Sendo uma ferramenta de inteligência artificial, a lógica nebulosa possui mecanismos de modelagem de conhecimento de senso comum e ambíguo, robustez e tolerância à falhas. Diferentemente das redes neurais artificiais, um sistema puramente nebuloso não possui técnicas de aprendizado. E a definição de pertinência é baseada na avaliação do projetista.

4.2.5.1 OS CONJUNTOS FUZZY E FUNÇÕES DE PERTINÊNCIA

Um conjunto *fuzzy* F de um discurso U é representado por uma função pertinência $\mu : U \rightarrow [0,1]$, que associa um elemento $x \in U$, a um número $\mu(x)$, cujo intervalo varia de 0 a 1, continuamente, e também representa o grau de pertinência de x em F . As operações básicas entre os conjuntos fuzzy são a de complemento, união e intersecção (Figura 4.9). As funções pertinentes se caracterizam por uma classe restrita de funções tais como: linear por partes (triangular, Figura 4.10 e trapezoidal, Figura


4.11), sigmóide (Figura 4.12), gaussiana (Figura 4.13) e *singleton* (Figura 4.14) .
(MOZELLI, 2008).

Figura 4.9: Operações com conjuntos Fuzzy.




Dado um universo U , tem-se uma função de pertinência $\mu(x)$, em que a , b , m pertencem ao conjunto U com $a \leq m \leq b$, definida por:

$$\mu(x) = \begin{cases} 0; & \text{se } x \leq a \\ \frac{x-a}{m-a}; & \text{se } x \in [a, m] \\ \frac{b-x}{b-m}; & \text{se } x \in [m, b] \\ 0; & \text{se } x \geq b \end{cases} \quad (4.21)$$

Figura 4.10: Função de pertinência triangular.


Dado um universo U , tem-se uma função de pertinência $\mu(x)$, em que a, b, m e x pertencem ao conjunto U com $a \leq m, n \leq b$ e $m \leq n$ definida por:

$$\mu(x) = \begin{cases} 0; & \text{se } x < a \\ \frac{x-a}{m-a}; & \text{se } x \in [a, m] \\ 1; & \text{se } x \in [m, n] \\ \frac{b-x}{b-n}; & \text{se } x \in [n, b] \\ 0; & \text{se } x > b \end{cases} \quad (4.22)$$

Figura 4.11: Função de pertinência trapezoidal.


A equação que rege a função de pertinência gaussiana é dada, para k maior que 1, por:

$$\mu(x) = e^{-k(x-m)^2} \quad (4.23)$$

Figura 4.12: Função de pertinência gaussiana.

A função sigmóide, sendo m , o ponto médio entre o intervalo $[a,b]$, é dada segundo a equação abaixo:


$$\mu(x) = \begin{cases} 0; & \text{se } x \leq a \\ 2 \cdot \left(\frac{x-a}{b-a}\right)^2; & \text{se } x \in [a, m] \\ 1 - 2 \cdot \left(\frac{x-a}{b-a}\right)^2; & \text{se } x \in [m, b] \\ 1; & \text{se } x \geq b \end{cases} \quad (4.24)$$

Figura 4.13: Função de pertinência sigmóide.

A função pertinência *singleton*, ou unitária, é dada por:

$$\mu(x) = \begin{cases} h, & \text{se } x = m \\ 0, & \text{caso contrário} \end{cases} \quad (4.25)$$

Figura 4.14: Função de pertinência unitária.



4.2.5.2 O SISTEMA DE INFERÊNCIA FUZZY

Os sistemas de inferência mapeiam as entradas de dados e as convertem em saídas precisas. São baseados em um conjunto de regras *fuzzy* que possui quatro componentes principais: o “fuzzyficador”, a base de conhecimento, o método de inferência e o “defuzzyficador”. A primeira etapa deste processo, o “fuzzyficador”, coloca os padrões nas entradas do sistema nebuloso, gerados pelas variáveis linguísticas. Estas variáveis são os conceitos de um dado problema e definidas pelo próprio projetista do sistema *fuzzy*. A função de pertinência traduz as variáveis linguísticas para o sistema. Já a base de conhecimento, consiste em um conjunto de regras que condensam o conjunto de funções de pertinência e declarações linguísticas definidas por projetistas ou retiradas do próprio conglomerado de pertinências. Fornecem uma descrição qualitativa do sistema em estudo.

O conhecimento é baseado em regras compostas pelos termos antecedente e consequente, como também pelas operações nebulosas. O antecedente é composto por um conjunto envolvendo variáveis *fuzzy* e expressões linguísticas que, quando satisfeitas, mesmo que parcialmente, determinam o processamento da parte consequente através da inferência *fuzzy* (MOZELLI, 2008). O método da inferência aplica o

raciocínio *fuzzy* para obter-se uma saída. Já o “defuzzyficador” traduz a saída para um valor numérico (BENINI, 2007).


Figura 4.15: Modelo *Fuzzy*.



4.5.2.3 SISTEMA DE INFERÊNCIA *FUZZY* NEURO ADAPTATIVO (ANFIS)

Os sistemas neuro-*fuzzy*, propostos por Jang (1993), combinam a capacidade das redes neurais artificiais, que tem a capacidade de aprendizado com os padrões de treinamento, juntamente com a capacidade *fuzzy* de interpretação linguística. Como exemplo, a arquitetura ANFIS é composta por cinco camadas, conforme exemplifica a Figura 4.16.

Figura 4.16: Arquitetura típica do sistema ANFIS.



Na primeira camada do sistema ANFIS, os nós são constituídos pelos conjuntos fuzzy A_i^j e associados às entradas x_i . A saída de cada nó é a pertinência do valor x_i no conjunto *fuzzy*. Esses nós podem ser ajustados e as funções de pertinência podem ser definidas desde que elas sejam diferenciáveis (BENINI, 2007).

Na segunda camada, os nós não são adaptativos e não podem ser ajustados, tendo como saída o produto dos sinais de entrada da primeira camada. Conforme mostra a Figura 4.16, cada saída w_j corresponde à intensidade do disparo de uma regra (BENINI, 2007). Deste modo, a saída se caracteriza pela equação 4.26 a seguir:

$$w_j = \prod_{i=1}^2 \mu_i^j, \text{ para } j = 1, 2 \quad (4.26)$$

Para a terceira camada, a saída desse nó é normalizada para um pré-processamento de “defuzzyficação” do sistema. A saída é definida pelo quociente entre

a intensidade de disparo da j -ésima regra e a soma dos disparos de todas as outras regras (BENINI, 2007), conforme equação 4.27.

$$\overline{w_j} = \frac{w_j}{\sum_{i=1}^2 w^i} = \frac{w_j}{w_1 + w_2}, \text{ para } j = 1, 2 \quad (4.27)$$

A camada de número 4 é adaptativa e seus parâmetros p , q e r correspondem a parte consequente de cada regra do modelo. Deste modo, as saídas $f_j = f_j(\overline{w_j}, x_1, x_2, p_j, q_j, r_j)$ são o produto das normalizações da terceira camada com o valor do consequente da regra (BENINI, 2007).

$$f_j = \overline{w_j}(p_j x_1 + q_j x_2 + r_j) \quad (4.28)$$

Para a camada de número 5, constituída por um único nó não adaptativo, calcula-se a saída do sistema e promove a “defuzzificação”. A saída é definida como a soma de todas as saídas parciais (BENINI, 2007).

$$f = \sum_{j=1}^2 f_j \quad (4.29)$$

A aprendizagem do sistema ANFIS tem dois conjuntos que devem ser treinados: os parâmetros do antecedente, que são as constantes que caracterizam as funções descendentes, e os parâmetros do consequente, que são os parâmetros lineares da saída do modelo de inferência. Essa aprendizagem emprega algoritmos do gradiente descendente para aperfeiçoar o antecedente, e se vale do método dos mínimos quadrados para determinar os parâmetros lineares dos consequentes. Sendo assim, o treinamento é realizado em duas etapas. Na primeira, os parâmetros dos antecedentes permanecem fixos e utiliza-se o método dos mínimos quadrados para a regra. Na

segunda, com os consequentes constantes e fixos, se utiliza o algoritmo *backpropagation* sobre o parâmetro do precedente.

CAPÍTULO 5: METODOLOGIA PROPOSTA

O objetivo deste trabalho foi o desenvolvimento de uma abordagem de inteligência computacional para a identificação da necessidade de Nitrogênio na cultura de cana-de-açúcar no estágio inicial de crescimento, a partir de uma medida de refletância imprecisa obtida por um sensor de Nitrogênio YARA que opera por meio da refletância de ondas eletromagnéticas na faixa do infravermelho próximo. Dessa forma, este trabalho foi realizado em duas etapas:

Etapa 1: Foi realizado um conjunto de medições em campo e em laboratório de análises de solo para a geração de um banco de dados adequado ao treinamento dos sistemas inteligentes utilizados no trabalho em questão.

Etapa 2: Ocorreu nas dependências do Departamento de Engenharia Elétrica da Faculdade de Engenharia de Bauru – UNESP. Foram estudados e desenvolvidos os algoritmos computacionais para o tratamento dos dados e utilização das abordagens de inteligência computacional.

5.1 MATERIAIS

5.1.1 COLETA DE DADOS

A coleta de dados foi realizada na usina de açúcar Santa Fé, em Nova Europa - SP, por meio de uma campanha de coletas de dados. Estes dados foram utilizados para treinamento e validação dos sistemas inteligentes utilizados.

Para tanto, foram coletadas 121 amostras da cana-de-açúcar com tamanhos entre 20 e 35 cm. A Figura 5.1 mostra o talhão georreferenciado com os 121 pontos.

Figura 5.1: Talhão georreferenciado.



Os dados foram coletados com o sensor N-SENSOR ALS do fabricante YARA, montado em um trator modelo Uniport NPK da empresa Máquinas Agrícolas Jacto S/A, conforme a Figura 5.2, utilizando sistema pneumático para aplicação do adubo.

Figura 5.2: Trator modelo Uniport NPK com o sensor instalado.



O sensor cobre uma área de forma semelhante a uma elipse de aproximadamente 50m^2 . A Figura 5.3 mostra a vista traseira da área de leitura da refletância do sensor e a Figura 5.4 mostra a vista superior. A medida A vale 3m, e a medida B vale 24m.

Figura 5.3: Vista traseira da área de leitura da refletância do sensor.





Figura 5.4: Vista superior da área de leitura da refletância do sensor.



5.1.2 SENSOR N SENSOR ALS DO FABRICANTE YARA


O sensor N-SENSOR ALS do fabricante YARA, sediado na Noruega, disponibiliza, dentre seu portfólio de produtos, sensores para determinar a quantidade de Nitrogênio absorvido pelas plantas, utilizando a medição de refletâncias das plantas. Os modelos N-SENSOR e N-SENSOR ALS (*Active Light Source* ou Fonte de Luz Ativa) são dois tipos de sensores disponíveis para instalar em máquinas agrícolas que aplicam insumos, inclusive o Nitrogênio, para medir e controlar a quantidade de Nitrogênio que está sendo aplicada.

Segundo o manual de instruções N-SENSOR (2004), as principais diferenças entre os sensores N-SENSOR ALS e o modelo anterior N-SENSOR são as frequências em que os sensores ópticos operam e os períodos possíveis de uso dos equipamentos nas medições das plantas. O N-SENSOR utiliza a reflexão da luz do dia para medir a reflexão nas plantas, limitando seu uso durante o dia com uma elevação mínima de 25 graus do sol em relação ao horizonte, já o N-SENSOR ALS tem uma fonte de luz própria para iluminar as plantas que estão sendo medidas, permitindo seu uso em qualquer hora do dia e da noite.

A fonte de luz própria é composta de uma lâmpada especial que emite radiação na faixa do infravermelho (600 a 1100 nm), tem o foco ajustado por lentes e filtros ópticos e seu acionamento é controlado de maneira a permitir a leitura da refletância das plantas com e sem a iluminação. Esta técnica permite atenuar as interferências das variações da luz natural e melhorar a precisão das leituras. A radiação refletida é focada por um conjunto de lentes e filtros ópticos. Após o acondicionamento óptico, a radiação atinge os sensores ópticos ajustados para a faixa do infravermelho próximo. São 4 canais de leitura da refletância, o primeiro canal ajustado para a faixa de 730 nm, o segundo canal ajustado para a faixa de 760 nm, o terceiro canal ajustado para a faixa de

960 nm e o quarto canal ajustado para a faixa de 900 nm. Os sensores ópticos fazem a leitura da radiação refletida nas plantas com e sem a iluminação da lâmpada. A temperatura ambiente dentro do equipamento é monitorada e registrada para ajustes do sistema de leitura de refletância. O processamento das informações de leitura dos sensores determina um índice de refletância que pode ser transformado em medidas da quantidade de Nitrogênio absorvido pelas plantas. A Figura 5.5 apresenta a unidade de processamento, realizando o controle das medições com e sem a luz artificial. O controle da luz artificial é feito com uma modulação de 10hz. As quatro lentes são responsáveis por captar a refletância, que logo após passa por um filtro, que esta ajustado para os quatro comprimentos de ondas (730nm, 760nm, 970nm, 900nm). O equipamento possui um sensor de temperatura ambiente e o sinal de saída se dá pela comunicação serial com protocolo RS-232.

Figura 5.5: Diagrama esquemático do sensor N- SENSOR ALS da YARA.



5.1.3 BANCO DE DADOS

Os dados coletados pelo sensor foram organizados em uma planilha no software Excel, com 122 linhas e 25 colunas, sendo que as seis primeiras colunas são referentes aos dados do GPS, como latitude, longitude e altitude, e valores de Nitrogênio obtidos em laboratório, bem como a refletância processada final, conforme Tabela 5.1.

Tabela 5.1: Oito primeiras colunas, referentes aos dados do GPS e valores obtidos em laboratório.

Sequência (ADM)	Latitude (°)	Longitude (°)	Altitude (m)	N₂ lab. Kg/ha	RPF (Kg/ha)
1	-21,7921	-48,5896	533,5	25,26	30,23
2	-21,7925	-48,5896	533,6	23,56	33,7
3	-21,7929	-48,5897	533,4	19,89	28,1
4	-21,7932	-48,5897	533,9	37,37	27,25


Na Tabela 5.1 tem-se:

- Sequência: Referência da ordem que as amostras foram colhidas;
- Latitude: latitude do GPS em graus;
- Longitude: longitude do GPS em graus;
- Altitude: Altitude do GPS em metros;
- N₂ lab (Kg/ha): Quantidade de Nitrogênio foliar medido em laboratório;
- RPF (Kg/ha): Refletância processada final. Este valor refere-se à quantidade de Nitrogênio foliar calculada pelo sensor.

Para nomear as demais colunas foi adotado o seguinte critério: a primeira letra indica qual conjunto de lentes foi utilizada pelo sensor, a letra E indica o conjunto da

esquerda e a letra D indica o conjunto da direita. Os números do meio indicam o comprimento de onda que pode ser 730nm, 760nm, 900nm e 970nm, e a letra L, ao final, é usada para indicar que esta medida foi realizada utilizando a luz artificial. A ausência dessa letra significa que esta medição foi feita sem a utilização da luz artificial. A Figura 5.6 representa o critério utilizado para formar o nome de cada coluna.

Figura 5.6: Critério utilizado para nomear as colunas.



A Tabela 5.2 mostra os valores de refletância nos comprimentos de ondas de 730nm, 760nm, 970nm e 900nm com e sem a luz artificial, obtidos pelo conjunto de lente montados à esquerda do trator, e a Tabela 5.3 mostra os valores de refletâncias nos mesmos comprimentos de ondas com e sem a luz artificial, obtidos pelo conjunto de lentes montado à direita do trator.

Tabela 5.2: Valores de refletância para cada comprimento de onda, medidos pelo conjunto da esquerda com e sem luz artificial.

Sequência	E730	E760	E970	E900	E730L	E760L	E970L	E900L
(ADM)								
1	5961	10333	7361	6955	6388	10935	8094	7515
2	6412	10146	7436	6839	6810	10667	8087	7330
3	6457	9631	7163	6490	6853	10117	7780	6947
4	1616	3110	1458	2150	2117	3808	2274	2770

Na Tabela 5.2 tem-se:

- Sequência: Referência da ordem que as amostras foram colhidas;
- As demais colunas são valores referentes às refletâncias de cada comprimento de onda individual com e sem a luz artificial, obtidos pelo conjunto da esquerda do trator.

Tabela 5.3: Valores de refletância para cada comprimento de onda, medidos pelo conjunto da direita com e sem luz artificial.

Sequência	D730	D760	D970	D900	D730L	D760L	D970L	D900L
(ADM)								
1	4871	8471	4943	5523	5316	9074	5517	6049
2	4742	8577	4936	5587	5183	9204	5524	6130
3	5072	7728	4575	4973	5530	8284	5115	5455
4	1682	3427	1637	2409	2203	4230	2089	3084

Na Tabela 5.3 tem-se:

- Sequência: Referência da ordem que as amostras foram colhidas;
- As demais colunas são valores referentes às refletâncias de cada comprimento de onda individual com e sem a luz artificial, obtidos pelo conjunto da direita do trator.

5.1.4 RECURSOS COMPUTACIONAIS

O tratamento dos dados e a implementação das abordagens propostas foram realizadas por meio de:

- Plataforma MatLab do fabricante MathWorks;
- Computador tipo PC, processador I5, Intel, memória 4GB.

5.2 MÉTODOS

5.2.1 ASPECTOS GERAIS

Conforme abordado nos capítulos anteriores, a aplicação de insumos de forma homogênea ao longo de um talhão pode acarretar na poluição de mananciais e rios pelo excesso de Nitrogênio, ou acarretar no desperdício caso seja aplicado um valor abaixo do necessário.

Assim, recentemente, foram propostas técnicas de aplicação a taxas variáveis (ATV) cujo objetivo é aplicar a quantidade correta de insumos de maneira localizada e no momento correto. Essa estratégia implica em sistemas de controle em malha fechada para que se tenha um controle eficiente no que tange a precisão do valor a ser dosado. O valor a ser dosado advém de um mapa de aplicação previamente elaborado e ou um sensor *on-the-go*, este último o foco deste trabalho. Como já mencionado, a técnica do uso de mapas de aplicação decorre em inconvenientes, como a variabilidade temporal e espacial, além do custo para a sua elaboração. Dessa maneira, a utilização de sensores *on-the-go* traz muitas vantagens. A Figura 5.7 mostra um modelo Uniport NPK aplicando fertilizante granulado em uma cultura de cana-de-açúcar no estágio inicial de crescimento.

Figura 5.7: Trator Uniport NPK aplicando o fertilizante no campo.¹²



A quantidade de Nitrogênio foliar está diretamente relacionada à cor verde da folha e, por esse motivo, o espectro que o sensor recebe torna-se distorcido pela refletância imposta pelo solo e pela palha que, no estágio inicial de crescimento da cana-de-açúcar, é maioria, como pode ser notado na Figura 5.8. Assim, as distorções podem inviabilizar o emprego do referido sensor neste tipo de cultura.

Figura 5.8: Cana-de-açúcar no estágio inicial do crescimento.¹³



Nesse contexto, visando corrigir os erros de leitura do sensor N-SENSOR ALS, sistemas inteligentes computacionais fazem um mapeamento matemático entre os índices de refletância oriundos do sensor N-SENSOR ALS e os valores reais de

¹² Fonte: Máquinas Agrícolas Jactos S/A.

¹³ Fonte: PORTZ, 2011.

necessidade de Nitrogênio. Mais especificamente, redes neurais artificiais (RNA) e sistemas nebulosos (sistemas *fuzzy*) foram empregados e suas eficácias foram avaliadas para tornar viável o emprego do referido sensor em culturas nacionais.

5.2.2 ABORDAGEM DE INTELIGÊNCIA COMPUTACIONAL PARA A CORREÇÃO DA RESPOSTA DO N-SENSOR ALS

Neste trabalho, foram propostas três abordagens de inteligência computacional para a solução do problema e, então, comparadas a fim de verificar qual seria a mais adequada. Os sistemas propostos são:


- a) Redes Neurais Artificiais do tipo Perceptron Multicamadas (PMC): essa arquitetura de redes neurais é uma das mais empregadas para o mapeamento entrada-saída de problemas complexos cujos valores desejados estão disponíveis (aprendizado é supervisionado). Apresenta grande capacidade de generalização e os algoritmos de aprendizado têm grande velocidade de convergência, tornando-a uma opção natural na busca da solução para o problema em questão;
- b) Redes Neurais Artificiais do tipo *Generalized Regression Neural Network* (GRNN): ao contrário da rede PMC, esse tipo de rede tem o aprendizado de sua camada oculta não supervisionado. Já na camada de saída o aprendizado é supervisionado. As aplicações deste tipo de rede são semelhantes às da rede PMC, contudo, difere no método de treinamento. Além desse aspecto, quando o parâmetro de suavização σ é convenientemente ajustado, a rede GRNN torna-se mais vantajosa que a PMC quando os dados de treinamento são dados ruidosos ou esparsos;

- c) Sistema de inferência nebulosa do tipo *Adaptive Neural-Fuzzy Inference Systems* (ANFIS): enquanto as redes neurais exploram o paradigma conexionista, os sistemas nebulosos exploram o paradigma simbolista, ou seja, o tratamento da informação é realizado por meio de variáveis subjetivas permitindo manipular o grau de incerteza nas informações coletadas, além de ser uma abordagem que vem sendo amplamente utilizada nas áreas de engenharia e agronomia pela sua capacidade de tratar sistemas complexos e não lineares.

Nesse cenário, de maneira a ilustrar a composição do sistema como um todo, o esquema geral para a correção de leitura do sensor N-SENSOR ALS é apresentado na Figura 5.9. Ressalta-se que o treinamento de cada sistema é “off-line” e independente um do outro.

Os três sistemas foram treinados e validados com os mesmos dados, a fim de ter uma melhor comparação entre os índices de desempenho. Para tanto, um segundo banco de dados foi montado (APÊNDICE-B).

Figura 5.9: Esquema geral proposto para correção do sensor YARA.



5.2.3 RNA DO TIPO PMC

Com o objetivo de encontrar uma arquitetura neural adequada e que exigisse o mínimo esforço computacional (APÊNDICE – D), foram empregadas as arquiteturas constantes na Tabela 5.4 nos treinamentos. Deve ser lembrado que não existe um método determinístico que permita conhecer de antemão o número de neurônios e o número de camadas escondidas para mapear um determinado problema. Dessa forma, há a necessidade de avaliar o desempenho de várias arquiteturas que estão indicadas na Tabela 5.5:

Tabela 5.4:Arquiteturas utilizadas para validação.

Número de entradas.	Treinamento	Configuração
1	1	RPF
2	2	MEsl + MDsl
	3	MEcl + MDcl
3	4	MEsl + MDsl + RPF
	5	MEcl + MDcl + RPF
4	6	MTsl
	7	MTcl
5	8	MTsl + RPF
	9	MTcl + RPF

Na Tabela 5.4 tem-se:

- Número de entradas: Refere-se à quantidade de entrada fornecida para o sistema inteligente;
- Treinamento: Índice utilizado para a configuração;
- Configuração: Configuração dos padrões de entrada. Para essa coluna foi adotado a seguinte nomenclatura:
 - a.) RPF: Refletância processada final. Esse valor refere-se à quantidade de Nitrogênio foliar calculada pelo sensor;
 - b.) MEsl: Média aritmética dos comprimentos de ondas refletidos no conjunto de lentes da esquerda, sem a luz artificial;
 - c.) MDsl: Média aritmética dos comprimentos de ondas refletidos no conjunto de lentes da direita, sem a luz artificial;
 - d.) MEcl: Média aritmética dos comprimentos de ondas refletidos no conjunto de lentes da esquerda, com a luz artificial;
 - e.) MDcl: Média aritmética dos comprimentos de ondas refletidos no conjunto de lentes da direita, com a luz artificial;
 - f.) MTsl: Média aritmética de todos os comprimentos de ondas refletidos nos conjuntos de lentes sem a luz artificial;

g.) MTcl: Média aritmética de todos os comprimentos de ondas refletidos nos conjuntos de lentes com a luz artificial.

Tabela 5.5: Configurações da RNA PMC.

Número de entradas	Neurônios na camada escondida			Número de saídas	Critério de parada	Algor. de treinamento
1, 2,3, 4, 5 (ver Tabela 5.4)	1 ^a	2 ^a	3 ^a	01 (estimativa do teor Nitrogênio)	EQM ou n° de épocas	Levenberg-Marquardt (obs: funções de ativação do tipo ‘logística’)
	5	0	0			
	10	5	0			
	10	10	5			
	15	10	5			
	20	15	5			
	20	20	10			

5.2.4 RNA DO TIPO GRNN

No caso das redes GRNN, basicamente tem-se que encontrar o parâmetro spread que traz a melhor generalização. Para tal serão realizados ensaios com *spread* com valores 0.1, 1.0, 10 e 100. (APÊNDICE – C)

5.2.5 SISTEMA HÍBRIDO ADAPTIVE NEURAL-FUZZY INFERENCE SYSTEM (ANFIS)

O modelo ANFIS trata-se de uma ferramenta para a construção de um sistema de inferência *fuzzy* do tipo Takagi-Sugeno quando não se conhecem as características funções de pertinência de entrada e saída e suas respectivas quantidades bem como o agrupamento ótimo para a geração da base de regras. Assim, quando da utilização do ANFIS, há a necessidade de alimentar o algoritmo (APÊNDICE – A) “a priori” com o tipo de função de pertinência e sua quantidade, bem como o método de agrupamento para o ajuste das funções de pertinência e da base de dados. Neste trabalho o ANFIS foi caracterizado conforme mostra a Tabela 5.6:

Tabela 5.6: Configurações do sistema ANFIS.

Descrição	Configuração
Tipo de sistema <i>fuzzy</i>	Takagi-Sugeno
Número de entradas	1,2,3, 4 ou 5 (ver Tabela 5.4)
Número de saída	01 (teor de Nitrogênio estimado)
Função de pertinência	Gaussiana
Número de funções de pertinência	03; 04 e 05
Particionamento	<i>Grid partition</i>
Método “AND”	Prod
Método “OR”	Max
Método de implicação	Prod
Método de agregação	Max
“Defuzzificação”	<i>weighted average</i>

5.2.6 VALIDAÇÃO DAS ABORDAGENS

Como validação das abordagens, foram considerados quatro índices de desempenho. Índices de desempenho são ferramentas que utilizam índices estatísticos e são aplicados na validação do resultado de um experimento. São eles:

- a.) Raiz do erro quadrático médio (REQM): Este índice mostra, em unidades da variável que está sob análise, a dispersão média dos valores das amostras reais e estimadas ao redor da linha de regressão. Quanto menor o valor do REQM, melhor é a qualidade da previsão feita pelo sistema inteligente. O REQM é calculado pela fórmula 5.1:

$$REQM = \sqrt{\frac{\sum_{i=1}^n (r_n - e_n)^2}{n}} \quad (5.1)$$

onde r_n refere-se ao valor real ou observado para uma determinada amostra e e_n refere-se ao valor estimado para a mesma amostra e n é o número de amostras.

b.) Erro absoluto médio (EAM):

$$EAM = \frac{\sum_{i=1}^n |r_n - e_n|}{n} \quad (5.2)$$

c.) Erro relativo médio (ERM%):

$$ERM = 100 \frac{\sum_{i=1}^n |r_n - e_n|}{|e_n|} \quad (5.3)$$

d.) Desvio padrão do erro relativo médio (DpERM%): Este índice mostra o quanto de variação ou "dispersão" existe em relação à média (ou valor esperado). Um baixo desvio padrão indica que os dados tendem a estar próximos da média; um desvio padrão alto indica que os dados estão espalhados por uma gama de valores. O desvio padrão é calculado pela equação 5.4:

$$DpERM = \sqrt{\frac{\sum_{i=1}^n (r_n - \bar{r})^2}{n - 1}} \quad (5.4)$$

onde r_n refere-se ao valor real para uma determinada amostra, $\bar{r}$ refere-se à média dos valores reais das amostras e n é o número de amostras.

e.) Coeficiente de determinação (R^2): O coeficiente de determinação (R^2) é o quadrado do coeficiente de correlação linear (R) e pode ser definido como o grau de ajuste da reta estimada ao conjunto de dados. O coeficiente de correlação linear (R) é utilizado para verificar o grau de linearidade entre os

valores estimados pelo sistema inteligente e os valores reais medidos em laboratório, sendo calculado pela equação 5.5:

$$R = \frac{\sum_{i=1}^n (r_n - \bar{r})(e_n - \bar{e})}{\sqrt{(\sum_{i=1}^n (r_n - \bar{r})^2 \sum_{i=1}^n (e_n - \bar{e})^2)}} \quad (5.5)$$

onde r_n refere-se ao valor real para uma determinada amostra, $\bar{r}$ refere-se à média dos valores reais das amostras, e_n refere-se ao valor estimado para uma determinada amostra, $\bar{e}$ refere-se à média dos valores estimados e n é o número de amostras. Os resultados dos coeficientes de determinação próximo de 1 indicam uma qualidade melhor do grau de ajuste da reta estimada ao conjunto de dados.

CAPÍTULO 6: RESULTADOS E DISCUSSÃO.

Os resultados obtidos e as observações realizadas tiveram como objetivo validar as abordagens de inteligência computacional para a identificação da necessidade de Nitrogênio na cultura de cana-de-açúcar no estágio inicial de crescimento, a partir de uma medida de refletância imprecisa informada por um sensor de Nitrogênio foliar N-SENSOR ALS que opera por meio da refletância de ondas eletromagnéticas na faixa do infravermelho próximo. Para tal, cada um dos sistemas inteligentes propostos neste trabalho foi treinado com dados pré-processados, conforme indicado na Tabela 5.4 e os fatores de desempenho foram calculados. Por fim, uma análise comparativa foi realizada de maneira a justificar a abordagem proposta.

6.1 VALIDAÇÃO DAS REDES NEURAIS ARTIFICIAIS PERCEPTRON DE MULTIPLAS CAMADAS

As redes neurais artificiais foram estruturadas e treinadas, conforme indicado na Tabela 5.5 e validadas com os dados pré-processados de acordo com a Tabela 5.4. O critério de parada foi ajustado em um número máximo de épocas que a um erro quadrático médio de treinamento igual a 10^{-3} . Foram empregados 80% dos dados para treinamento e 20% para a validação cruzada.

A Tabela 6.1 resume o comportamento das RNAs PMC que tiveram o melhor desempenho para cada uma das configurações de entrada da Tabela 5.4. Para cada configuração de entrada, o número de neurônios e camadas escondidas variou conforme a Tabela 5.5. Para cada configuração neural, foram realizados 5 treinamentos, perfazendo 30 treinamentos para cada configuração de entrada. Então, foi escolhida a configuração neural com menor erro relativo médio porcentual (ERM%) e menor desvio padrão do erro relativo médio porcentual (DpERM%).

Pode-se observar que as redes *Perceptron* de múltiplas camadas não tiveram um bom desempenho, visto que o ERM% e seu respectivo desvio padrão para todas as configurações de entrada foram elevados, sendo incompatíveis com as operações de fertilização agrícola. As Figuras 6.1 a 6.36 apresentam, na forma gráfica, o desempenho das melhores RNAs PMC, mostradas na Tabela 6.1. Verifica-se que todas as redes apresentaram um baixo desempenho, pois, além dos erros relativos médios, a dispersão manteve-se elevada em todos os casos. Na Tabela 6.2 têm-se os erros relativos obtidos para cada uma das amostras ensaiadas.

Tabela 6.1: Comportamento das RNAs PMC com o melhor desempenho para cada um dos treinamentos na validação cruzada.

Trn	PMC					
	Neurônios	REQM	EAM	ERM (%)	DpERM (%)	R2
1	10-10-5	12,73	8,10	30,56	30,16	0,79
2	10-10-5	18,55	13,63	72,86	79,71	0,44
3	10-10-5	18,93	15,58	78,16	65,94	0,51
4	10-10-5	11,09	7,53	31,70	32,46	0,83
5	10-10-5	12,17	8,14	38,47	50,27	0,78
6	10-10-5	13,59	10,04	47,13	45,01	0,82
7	10-10-5	10,90	8,40	42,86	46,85	0,87
8	20-20-5	9,00	6,44	27,54	25,79	0,93
9	20-20-5	10,32	6,50	26,92	30,70	0,88

Tabela 6.2: Erros relativos para cada amostra de validação em cada treinamento.

AMOSTRA	TEOR OBSERVADO (kg/hect)	TEOR ESTIMADO pelo PMC (Kg/hect)									ERRO RELATIVO %								
		Treinamento									Treinamento								
		1	2	3	4	5	6	7	8	9	1	2	3	4	5	6	7	8	9
1	25,63	20,64	43,61	27,91	17,81	17,45	34,46	33,76	30,66	31,38	19,46	70,16	8,90	30,49	31,91	34,47	31,75	19,64	22,45
2	30,30	61,92	7,27	5,17	17,50	29,49	62,20	46,57	54,85	39,54	104,32	76,01	82,94	42,24	2,68	105,24	53,68	81,00	30,48
3	16,25	12,38	25,50	20,72	14,80	15,68	26,50	26,61	14,61	14,05	23,80	56,96	27,53	8,92	3,51	63,08	63,77	10,06	13,51
4	28,59	38,21	2,55	58,30	23,53	24,50	33,96	32,53	26,36	31,36	33,66	91,09	103,95	17,69	14,30	18,79	13,81	7,77	9,69
5	26,07	26,64	26,17	16,48	44,46	45,65	39,47	34,37	31,43	33,06	2,17	0,38	36,79	70,52	73,09	51,39	31,81	20,33	26,79
6	4,75	5,60	8,18	11,91	3,73	5,79	10,29	13,46	5,796	4,73	17,91	72,27	150,80	21,53	21,94	116,72	183,40	22,06	0,36
7	2,21	4,37	10,31	6,75	4,86	5,21	5,51	5,75	4,608	4,75	97,86	366,45	205,32	119,78	135,56	149,18	160,11	108,51	114,75
8	24,63	34,49	8,79	13,04	24,70	19,59	21,13	20,14	19,52	20,76	40,03	64,32	47,06	0,30	20,44	14,22	18,23	20,74	15,72
9	23,86	19,24	25,45	47,03	18,50	19,04	26,13	33,20	13,77	15,32	19,36	6,68	97,12	22,46	20,19	9,54	39,15	42,28	35,79
10	85,49	59,93	34,44	49,29	70,01	52,22	67,00	68,89	97,57	78,05	29,90	59,72	42,34	18,10	38,92	21,62	19,42	14,14	8,70
11	14,03	12,35	13,70	16,69	12,84	12,96	33,05	25,14	13,78	13,22	12,00	2,32	18,95	8,50	7,59	135,61	79,19	1,77	5,79
12	14,67	12,76	6,16	7,03	14,44	13,61	12,04	12,08	12,13	13,82	12,99	58,00	52,09	1,58	7,20	17,95	17,67	17,33	5,81
13	11,02	9,27	8,28	3,68	9,28	12,49	11,13	11,14	10,31	10,46	15,83	24,86	66,58	15,78	13,36	0,99	1,07	6,40	5,09
14	32,41	60,79	38,51	60,55	60,18	48,45	46,93	43,10	49,64	65,43	87,54	18,81	86,81	85,66	49,46	44,77	32,97	53,14	101,86
15	28,91	19,98	64,91	53,91	18,77	21,15	57,61	45,70	39,45	32,99	30,89	124,56	86,50	35,06	26,83	99,28	58,11	36,49	14,14
16	25,40	24,83	27,87	13,70	52,68	48,75	44,32	33,44	37,07	41,43	2,25	9,72	46,04	107,41	91,93	74,51	31,67	45,93	63,11
17	21,89	17,26	25,72	40,11	15,82	16,75	26,53	24,15	17,41	16,56	21,16	17,51	83,24	27,75	23,47	21,17	10,33	20,48	24,38
18	12,39	12,28	7,03	5,40	11,01	12,93	12,37	12,32	11,8	11,62	0,89	43,25	56,43	11,11	4,39	0,19	0,56	4,74	6,24
19	12,06	12,56	36,06	17,34	11,81	12,83	11,57	11,64	12,17	11,51	4,19	199,14	43,87	2,06	6,39	4,00	3,48	0,98	4,51
20	76,96	62,39	45,97	46,75	61,36	52,41	67,35	65,86	70,45	67,01	18,93	40,27	39,26	20,28	31,91	12,48	14,42	8,47	12,93
21	10,27	12,25	24,73	16,08	13,27	12,93	9,66	10,81	12,38	12,30	19,31	140,79	56,59	29,18	25,93	5,94	5,27	20,56	19,81
22	10,98	8,66	25,29	45,44	7,93	12,34	9,75	10,15	9,354	9,75	21,11	130,41	313,98	27,71	12,39	11,17	7,49	14,79	11,19
23	35,60	64,24	30,15	21,17	48,32	52,85	58,76	62,21	52,53	62,11	80,45	15,31	40,55	35,71	48,45	65,05	74,74	47,54	74,46
24	27,04	22,33	43,14	49,23	27,32	24,48	41,56	47,71	36,7	32,06	17,42	59,56	82,08	1,03	9,47	53,72	76,45	35,72	18,59

6.1.1 TREINAMENTO 1:

Figura 6.1: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.




Figura 6.2: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.




Figura 6.3: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.





Figura 6.4: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.



6.1.2 TREINAMENTO 2:

Figura 6.5: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.




Figura 6.6: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.




Figura 6.7: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.





Figura 6.8: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.



6.1.3 TREINAMENTO 3:

Figura 6.9: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.




Figura 6.10: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.




Figura 6.11: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.





Figura 6.12: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.



6.1.4 TREINAMENTO 4:

Figura 6.13: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.




Figura 6.14: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.




Figura 6.15: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.





Figura 6.16: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.



6.1.5 TREINAMENTO 5:

Figura 6.17: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.




Figura 6.18: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.




Figura 6.19: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.





Figura 6.20: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.



6.1.6 TREINAMENTO 6:

Figura 6.21: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.




Figura 6.22: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.




Figura 6.23: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.





Figura 6.24: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.



6.1.7 TREINAMENTO 7:

Figura 6.25: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.




Figura 6.26: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.




Figura 6.27: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.





Figura 6.28: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.



6.1.8 TREINAMENTO 8:

Figura 6.29: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.




Figura 6.30: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.




Figura 6.31: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.





Figura 6.32: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.



6.1.9 TREINAMENTO 9:

Figura 6.33: Comportamento do conjunto de validação entre os dados observados e estimados pelo PMC.




Figura 6.34: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo PMC.




Figura 6.35: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo PMC.





Figura 6.36: Comportamento dos erros de treinamento e validação entre os dados observados e estimados pelo PMC.



Nota-se que, para o treinamento 3, segundo a Figura 6.9, os resultados apresentaram altos valores para ERM% e para o DpERM%, sendo o treinamento que apresentou os piores resultados, 78,16% e 65,94% respectivamente. A Figura 6.10 mostra que a regressão linear (R^2) é igual a 0,51, e a Figura 6.11 mostra os erros dos treinamentos.

Analisando o treinamento 9, pode-se perceber que foi o que apresentou os melhores resultados para o ERM% e para o DpERM%, 26,92% e 30,70% respectivamente, segundo Figura 6.33. A Figura 6.34 mostra que a regressão linear (R^2) é igual a 0,88, e a Figura 6.35 mostra os erros dos treinamentos. Porém, mesmo sendo o treinamento com melhores resultados, esses valores ainda não são satisfatórios para a Agricultura de Precisão.

6.2 VALIDAÇÃO DAS REDES NEURAIS ARTIFICIAIS GRNN

De maneira similar às redes PMC, as redes neurais artificiais GRNN foram estruturadas e treinadas com *spread* de valores 0.1, 1.0, 10 e 100 e com os dados pré-

processados conforme indicado na Tabela 5.4. Foram empregados 80% dos dados para treinamento e 20% para a validação cruzada.

A Tabela 6.3 resume o comportamento das RNAs GRNN que tiveram o melhor desempenho para cada uma das configurações de entrada da Tabela 5.4. Para cada configuração de entrada, o *spread* variou segundo os valores 0.1, 1.0, 10 e 100. Para cada configuração neural foram realizados 5 treinamentos, perfazendo 20 treinamentos para configuração de entrada. Então, foi escolhida configuração neural com o melhor desempenho e com o menor erro relativo médio porcentual (ERM%).

Pode-se observar que as redes GRNN apresentaram um desempenho ainda pior do que as redes PMC, pois apesar do ERM% estar numericamente próximo aos valores das redes PMC, o desvio padrão é substancialmente maior, inviabilizando o uso dessa abordagem neural para o propósito em questão. As Figuras 6.37 a 6.63 apresentam, na forma gráfica, o desempenho das melhores RNAs GRNN e a Tabela 6.4 mostra os erros relativos obtidos para cada uma das amostras ensaiadas.

Tabela 6.3: Comportamento das RNAs GRNN com o melhor desempenho para cada um dos treinamentos na validação cruzada.

Trn	GRNN					
	<i>Spread</i>	REQM	EAM	ERM(%)	DpERM (%)	R2
1	1	10,97	7,80	31,17	25,02	0,83
2	100	14,30	98,37	54,30	61,85	0,75
3	100	15,12	10,16	45,89	47,14	0,64
4	10	11,09	6,40	28,19	42,22	0,83
5	10	10,17	6,20	28,12	41,76	0,86
6	10	11,30	8,23	60,07	113,05	0,82
7	10	15,88	9,10	51,00	81,30	0,65
8	10	8,93	6,16	29,89	38,00	0,89
9	10	9,65	6,46	29,88	37,14	0,87

Tabela 6.4: Erros relativos produzidos de GRNN para cada amostra de validação em cada treinamento.

AMOSTRA	TEOR OBSERVADO (kg/hect)	TEOR ESTIMADO pela GRNN(kg/hect)									ERRO RELATIVO %								
		Treinamento									Treinamento								
		1	2	3	4	5	6	7	8	9	1	2	3	4	5	6	7	8	9
1	25,63	20,18	23,69	24,98	24,12	27,82	29,45	26,22	29,07	30,62	21,27	7,56	2,52	5,88	8,57	14,93	2,31	13,42	19,47
2	30,30	42,86	9,37	8,619	32,53	26,41	25,39	37,37	37,89	35,84	41,44	69,08	71,56	7,36	12,84	16,21	23,32	25,02	18,27
3	16,25	12,79	20,04	19,89	17,04	17,29	22,23	31,26	17,49	17,52	21,31	23,32	22,41	4,87	6,44	36,79	92,42	7,67	7,85
4	28,59	40,01	19,79	20,34	34,23	38,73	26,6	26,04	29,78	31,55	39,96	30,78	28,85	19,75	35,50	6,93	8,91	4,19	10,38
5	26,07	34,6	9,84	9,839	37,2	39,82	27,22	26,22	27,21	28,3	32,72	62,26	62,26	42,69	52,71	4,41	0,56	4,37	8,33
6	4,75	5,977	9,69	9,868	7,896	7,758	20,54	7,281	7,767	7,444	25,86	104,11	107,81	66,28	63,36	332,62	53,33	63,56	56,75
7	2,21	4,543	5,94	5,782	6,825	6,782	12,71	8,02	6,336	6,217	105,55	168,73	161,61	208,83	206,88	475,23	262,90	186,67	181,31
8	24,63	39,97	15,02	15,02	29,89	28,61	18,92	20,02	20,58	20,79	62,29	39,02	39,02	21,35	16,16	23,18	18,72	16,42	15,58
9	23,86	19,66	19,91	53,15	30,85	29,1	28,18	19,56	28,74	26,67	17,61	16,56	122,78	29,31	21,96	18,11	18,03	20,46	11,77
10	85,49	63,87	70,89	48,76	47,5	51,35	55,42	45,53	57,67	55,36	25,29	17,08	42,96	44,44	39,93	35,17	46,74	32,54	35,25
11	14,03	12,67	21,28	13,99	12,99	12,82	37,93	44,99	23,27	23,76	9,72	51,70	0,28	7,38	8,60	170,36	220,71	65,84	69,34
12	14,67	13,14	9,57	10,14	14,38	14,28	11,37	12,59	11,38	11,43	10,43	34,76	30,87	1,96	2,64	22,51	14,18	22,41	22,08
13	11,02	9,352	16,53	15,85	11,44	11,45	11,38	10,44	10,49	10,49	15,12	50,03	43,89	3,82	3,88	3,29	5,21	4,83	4,81
14	32,41	60,92	36,55	48,53	42,24	41,46	23,06	30,57	42,14	41,87	87,94	12,75	49,71	30,31	27,90	28,86	5,70	30,00	29,17
15	28,91	18,92	74,94	31,28	28,49	28,98	38,81	31,28	32,86	32,49	34,55	159,26	8,22	1,46	0,25	34,25	8,22	13,68	12,41
16	25,40	31,91	26,69	22,37	31,56	30,67	35,67	70,35	38,36	37,58	25,63	5,09	11,93	24,24	20,77	40,44	176,99	51,03	47,96
17	21,89	16,79	19,21	23,96	24,69	23,93	33,89	18,13	26,14	24,11	23,31	12,23	9,47	12,80	9,33	54,81	17,19	19,39	10,13
18	12,39	11,07	9,57	11,86	11,91	11,93	11,4	11,67	10,8	10,83	10,62	22,79	4,27	3,86	3,72	8,02	5,80	12,85	12,61
19	12,06	11,23	43,29	26,45	12,44	12,44	11,56	10,00	10,66	10,66	6,83	259,14	119,41	3,22	3,22	4,08	17,03	11,58	11,59
20	76,96	59,26	70,93	48,76	46,83	51,98	56,7	70,93	59,09	56,35	23,01	7,84	36,64	39,15	32,47	26,33	7,84	23,23	26,78
21	10,27	12,68	10,51	9,713	14,06	14,01	11,56	10,63	10,74	10,69	23,46	2,39	5,42	36,92	36,43	12,56	3,47	4,58	4,05
22	10,98	8,506	16,35	10,99	11,11	11,1	11,15	9,851	10,33	10,31	22,51	48,92	0,15	1,17	1,15	1,56	10,25	5,93	6,08
23	35,60	56,58	49,75	34,99	45,39	46,04	42,92	55,69	45,22	49,06	58,92	39,74	1,71	27,49	29,32	20,54	56,42	27,03	37,80
24	27,04	26,33	42,75	58,82	35,68	35,4	40,7	38,98	40,75	42,51	2,62	58,09	117,54	31,97	30,92	50,53	44,18	50,71	57,21

6.2.1 TREINAMENTO 1:

Figura 6.37: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.




Figura 6.38: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.





Figura 6.39: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.



6.2.2 TREINAMENTO 2:

Figura 6.40: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.




Figura 6.41: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.





Figura 6.42: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.



6.2.3 TREINAMENTO 3:

Figura 6.43: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.




Figura 6.44: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.





Figura 6.45: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.



6.2.4 TREINAMENTO 4:

Figura 6.46: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.




Figura 6.47: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.





Figura 6.48: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.



6.2.5 TREINAMENTO 5:

Figura 6.49: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.




Figura 6.50: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.





Figura 6.51: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.



6.2.6 TREINAMENTO 6:

Figura 6.52: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.




Figura 6.53: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.





Figura 6.54: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.



6.2.7 TREINAMENTO 7:

Figura 6.55: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.




Figura 6.56: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.





Figura 6.57: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.



6.2.8 TREINAMENTO 8:

Figura 6.58: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.




Figura 6.59: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.





Figura 6.60: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.



6.2.9 TREINAMENTO 9:

Figura 6.61: Comportamento do conjunto de validação entre os dados observados e estimados pela GRNN.




Figura 6.62: Gráfico de dispersão e de regressão entre os dados observados e estimados pela GRNN.





Figura 6.63: Histograma de erros de treinamento e validação entre os dados observados e estimados pela GRNN.



Nota-se que para treinamento 6, segundo Figura 6.52, os resultados apresentaram altos valores para ERM% e para o DpERM%, sendo o que apresentou os piores resultados, 60,07% e 113,05%, respectivamente. A Figura 6.53 mostra que a

regressão linear (R^2) é igual a 0,82, e a Figura 6.54 mostra os erros dos treinamentos. Analisando o treinamento 5, segundo Figura 6.49, pode-se perceber que foi o que apresentou os melhores resultados para o ERM% e para o DpERM%, 28,12% e 41,76% respectivamente. A Figura 6.50 mostra que a regressão linear (R^2) é igual a 0,86 e a Figura 6.51 mostra os erros dos treinamentos. Porém, mesmo sendo o treinamento com melhores resultados, esses valores também não são satisfatórios para a Agricultura de Precisão.

6.3 VALIDAÇÃO DO SISTEMA ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM (ANFIS)

O sistema híbrido ANFIS utilizado foi treinado com os dados pré-processados, conforme indicado na Tabela 5.4. O critério de parada empregado foi o número máximo de épocas ajustado em 200. Foi empregado 80% dos dados para treinamento e 20% para a validação. Os demais parâmetros de configuração estão dispostos na Tabela 5.6.

A Tabela 6.5 resume o comportamento dos sistemas de inferência neuro-fuzzy adaptativo que tiveram o melhor desempenho para cada uma das configurações de entrada da Tabela 5.4. Para cada configuração de entrada, o número de funções de pertinência variou segundo os valores 3, 4 e 5. Ensaaios preliminares indicaram que a função pertinência mais adequada era a *sino-gaussiana*, motivo da adoção da mesma. Assim, foi escolhido como o melhor ANFIS aquele que apresentou o menor erro relativo médio porcentual (ERM%).

Conforme nota-se na Tabela 6.5, os sistemas de inferência neuro-fuzzy adaptativo (ANFIS) apresentaram o melhor desempenho dentre as abordagens propostas. Observa-se que à medida que o número de entradas aumenta, o erro relativo médio (ERM%) e erros relativos para cada amostra decaem (Tabela 6.6), indicando a plena viabilidade dessa abordagem no que tange a um mecanismo de correção de leitura

para o sensor N-SENSOR ALS para o uso em cana-de-açúcar no estágio inicial de crescimento.

Cabe salientar que a abordagem ANFIS apresenta vantagem sobre as redes neurais quando da utilização em um sistema embarcado, devido à simplicidade da implementação computacional após as funções e regras devidamente ajustadas, fato esse de suma importância na aplicação em questão. As Figuras 6.64 a 6.99 apresentam, na forma gráfica o desempenho dos melhores sistemas de inferência neuro-*fuzzy* adaptativo abordados.

Tabela 6.5: Comportamento dos sistemas de inferência neuro-*fuzzy* adaptativo (ANFIS) com o melhor desempenho para cada um dos treinamentos na validação cruzada.

Trn	Função pertinência	FIS				
		REQM	EAM	ERM (%)	DpERM (%)	R2
1	Gauss. (3)	8,23	3,84	12,18	17,76	0,903
2	Gauss. (3)	15,71	0,84	57,71	12,48	0,997
3	Gauss. (3)	1,44	0,83	5,19	9,32	0,997
4	Gauss. (3)	0,01	0,01	0,05	0,04	1,000
5	Gauss. (3)	0,03	0,02	0,12	0,16	1,000
6	Gauss. (3)	0,02	0,01	0,06	0,07	1,000
7	Gauss. (3)	0,03	0,02	0,11	0,14	1,000
8	Gauss. (3)	0,04	0,02	0,10	0,13	1,000
9	Gauss. (3)	0,03	0,02	0,08	0,09	1,000

Tabela 6.6: Erros relativos produzidos ANFIS para cada amostra de validação em cada treinamento.

AMOSTRA	TEOR OBSERVADO (kg/hect)	TEOR ESTIMADO pelo ANFIS (kg/hect)									ERRO RELATIVO %								
		Treinamento									Treinamento								
		1	2	3	4	5	6	7	8	9	1	2	3	4	5	6	7	8	9
1	25,63	27,21	26,44	26,26	25,65	25,64	25,66	25,72	25,53	25,60	6,19	3,18	2,47	0,08	0,04	0,12	0,36	0,40	0,09
2	30,30	26,31	30,28	30,40	30,29	30,34	30,31	30,27	30,37	30,31	13,19	0,09	0,30	0,04	0,10	0,02	0,09	0,23	0,04
3	16,25	15,51	16,50	16,99	16,22	16,24	16,25	16,29	16,20	16,25	4,53	1,54	4,59	0,17	0,04	0,00	0,26	0,29	0,02
4	28,59	28,75	27,18	27,39	28,57	28,63	28,60	28,61	28,71	28,52	0,57	4,91	4,18	0,04	0,16	0,04	0,09	0,44	0,23
5	26,07	26,88	25,70	25,37	26,05	26,11	26,09	26,10	26,14	26,05	3,10	1,44	2,70	0,07	0,14	0,08	0,12	0,25	0,08
6	4,75	5,58	4,76	4,73	4,75	4,77	4,74	4,78	4,75	4,75	17,54	0,17	0,32	0,03	0,45	0,12	0,60	0,03	0,01
7	2,21	2,01	2,23	2,22	2,21	2,22	2,21	2,21	2,21	2,21	9,21	0,98	0,48	0,05	0,62	0,04	0,13	0,06	0,00
8	24,63	26,62	24,44	24,47	24,64	24,67	24,64	24,68	24,65	24,59	8,09	0,77	0,64	0,03	0,18	0,05	0,21	0,09	0,14
9	23,86	24,02	23,87	23,86	23,85	23,90	23,85	23,85	23,86	23,87	0,69	0,06	0,00	0,03	0,15	0,03	0,02	0,02	0,04
10	85,49	77,45	85,75	85,12	85,47	85,49	85,54	85,45	85,51	85,41	9,41	0,31	0,43	0,02	0,01	0,06	0,04	0,03	0,09
11	14,03	12,84	11,63	13,29	14,01	14,09	13,98	14,01	14,03	13,98	8,48	17,07	5,27	0,13	0,45	0,36	0,10	0,02	0,34
12	14,67	15,91	14,34	14,21	14,68	14,65	14,67	14,68	14,67	14,66	8,46	2,24	3,16	0,07	0,12	0,01	0,09	0,00	0,03
13	11,02	10,93	10,88	9,82	11,02	11,02	11,01	11,01	10,99	11,04	0,84	1,27	10,88	0,02	0,01	0,03	0,11	0,22	0,19
14	32,41	60,08	32,41	32,42	32,41	32,46	32,41	32,41	32,41	32,41	85,35	0,00	0,01	0,00	0,13	0,00	0,00	0,01	0,00
15	28,91	26,98	29,84	29,59	28,90	28,90	28,92	28,93	28,92	28,92	6,68	3,24	2,37	0,02	0,02	0,06	0,08	0,05	0,06
16	25,40	27,02	24,99	25,70	25,42	25,39	25,39	25,39	25,40	25,40	6,37	1,62	1,18	0,08	0,05	0,05	0,03	0,02	0,02
17	21,89	19,92	22,02	21,88	21,89	21,88	21,89	21,88	21,89	21,84	9,00	0,56	0,07	0,01	0,05	0,00	0,07	0,01	0,25
18	12,39	11,97	13,01	13,22	12,39	12,38	12,38	12,39	12,39	12,39	3,37	5,03	6,69	0,04	0,07	0,05	0,03	0,01	0,02
19	12,06	12,03	9,71	17,42	12,05	12,05	12,05	12,05	12,06	12,06	0,19	19,42	44,53	0,05	0,06	0,05	0,03	0,03	0,03
20	76,96	50,48	76,90	77,61	76,95	76,94	76,96	76,99	76,95	76,97	34,41	0,08	0,84	0,01	0,02	0,01	0,04	0,01	0,01
21	10,27	13,12	16,36	8,68	10,27	10,26	10,26	10,27	10,27	10,28	27,75	59,29	15,44	0,02	0,06	0,06	0,02	0,06	0,06
22	10,98	10,01	11,89	11,92	10,97	10,97	10,97	10,98	10,98	10,98	8,78	8,29	8,64	0,06	0,03	0,05	0,05	0,01	0,01
23	35,60	42,59	33,24	32,33	35,62	35,60	35,59	35,60	35,58	35,62	19,64	6,63	9,19	0,06	0,00	0,04	0,00	0,05	0,05
24	27,04	27,18	26,95	27,01	27,04	27,04	27,04	27,04	27,04	27,05	0,52	0,33	0,10	0,00	0,01	0,01	0,01	0,00	0,05

6.3.1 TREINAMENTO 1:

Figura 6.64: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.




Figura 6.65: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.




Figura 6.66: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.





Figura 6.67: Comportamento do erro quadrático médio em função do número de épocas.



6.3.2 TREINAMENTO 2:

Figura 6.68: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.




Figura 6.69: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.




Figura 6.70: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.





Figura 6.71: Comportamento do erro quadrático médio em função do número de épocas.



6.3.3 TREINAMENTO 3:

Figura 6.72: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.




Figura 6.73: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.




Figura 6.74: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS





Figura 6.75: Comportamento do erro quadrático médio em função do número de épocas.



6.3.4 TREINAMENTO 4:

Figura 6.76: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.




Figura 6.77: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.




Figura 6.78: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.





Figura 6.79: Comportamento do erro quadrático médio em função do número de épocas.



6.3.5 TREINAMENTO 5:

Figura 6.80: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.




Figura 6.81: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.




Figura 6.82: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.





Figura 6.83: Comportamento do erro quadrático médio em função do número de épocas.



6.3.6 TREINAMENTO 6:

Figura 6.84: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.




Figura 6.85: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.




Figura 6.86: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.





Figura 6.87: Comportamento do erro quadrático médio em função do número de épocas.



6.3.7 TREINAMENTO 7:

Figura 6.88: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.




Figura 6.89: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.




Figura 6.90: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.





Figura 6.91: Comportamento do erro quadrático médio em função do número de épocas.



6.3.8 TREINAMENTO 8:

Figura 6.92: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.




Figura 6.93: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.




Figura 6.94: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.





Figura 6.95: Comportamento do erro quadrático médio em função do número de épocas.



6.3.9 TREINAMENTO 9:

Figura 6.96: Comportamento do conjunto de validação entre os dados observados e estimados pelo ANFIS.




Figura 6.97: Gráfico de dispersão e de regressão entre os dados observados e estimados pelo ANFIS.




Figura 6.98: Histograma de erros de treinamento e validação entre os dados observados e estimados pelo ANFIS.





Figura 6.99: Comportamento do erro quadrático médio em função do número de épocas.



Após os treinamentos, pode-se perceber que o ANFIS obteve excelentes resultados. O treinamento 4 foi o que retornou os melhores valores possíveis de todas as abordagens, apresentando um ERM (%) de 0,05% e com desvio padrão de 0,04%. Entretanto, para o treinamento 4, segundo a Tabela 5.4, foram utilizadas três entradas, exigindo maior esforço computacional, quando da implementação em um sistema embarcado, se comparado com o treinamento 3.

O treinamento 3 apresentou um ERM(%) de 5,19% e desvio padrão de 9,32%, valores que são aceitáveis para a atividade de fertilização agrícola e, segundo a Tabela 5.4, para esse treinamento foram utilizadas apenas duas entradas, configuração esta que exige um menor esforço computacional.

CAPÍTULO 7: CONCLUSÕES

O objetivo deste trabalho foi propor uma abordagem de inteligência computacional que permitisse a correção das medidas do teor de Nitrogênio foliar oriundos do sensor N-SENSOR ALS operando na cultura de cana-de-açúcar no estágio inicial de crescimento. Os índices utilizados para determinar qual abordagem conseguiu realizar uma melhor correção foram o Erro Relativo Médio (ERM(%)) e o desvio padrão do ERM (DpERM(%)), que são, respectivamente, o quanto o sistema errou em média e qual foi a dispersão deste erro em relação à variável observada. Neste contexto, dentre as abordagens estudadas, a RNA PMC que apresentou os melhores resultados foi a utilizada no treinamento 9 (ver Tabela 6.1) com um ERM(%) igual a 26,92% e DpERM% igual a 30,70% valores estes que são altos para uma aplicação em campo. A RNA GRNN teve um desempenho ainda pior que as RNA PMC pois, apesar de apresentar um ERM(%) menor, apresentou um DpERM(%) maior, o que significa que os valores estimados pela rede ficaram muitos dispersos em relação ao observado em laboratório. A melhor configuração para essa rede foi a utilizada no treinamento 4 (ver Tabela 6.3) com em ERM(%) igual a 28,12% e DpERM(%) igual a 41,76%. A abordagem que mais se tornou viável foi o sistema adaptativo de inferência neuro-fuzzy (ANFIS), que apesar da melhor configuração apresentar um ERM(%) igual a 0,05% e um DpERM(%) igual a 0,04%, não foi a configuração escolhida, pois essa configuração requer um maior processamento dos dados. O treinamento 3 obteve um ERM(%) igual a 5,19% e DpERM(%) de 9,32%, valores estes aceitáveis para atividade de fertilização agrícola, sendo a configuração escolhida como a melhor. Essa abordagem fornece uma solução sistemática para a identificação do conteúdo de Nitrogênio em cana-de-açúcar nos estágios iniciais de crescimento, conseguindo correlacionar as medições imprecisas oriundas do sensor N-SENSOR ALS com as medições realizadas em laboratório.

Os resultados demonstraram que a abordagem ANFIS é uma alternativa eficiente frente aos métodos convencionais que são normalmente utilizados para a identificação na área agrônômica.

As principais vantagens na utilização da abordagem proposta são:

- a) Simplicidade de implementação, uma vez que não há nenhuma inferência estatística;
- b) Simplicidade de implementação em hardware, uma vez que a identificação é obtida por meio de operações matemáticas simples;
- c) Pode ser usado para aplicação de fertilizantes em tempo real evitando erros decorrentes da “distância” temporal do método da elaboração de mapas de aplicação por meio de amostras georreferenciadas;
- d) O *differential global position system* (DGPS) torna-se desnecessário, fazendo com que os equipamentos agrícolas fiquem mais baratos;
- e) Como se pode aplicar o insumo de forma variável de acordo com a necessidade da cultura, o impacto ambiental é reduzido.

Para trabalhos futuros relacionados com o tema sugerimos uma comparação entre a abordagem ANFIS e uma técnica estatística, a análise multivariada, além de avaliar a abordagem proposta em operações em campo.

REFERÊNCIAS

- ATKINS, P.; JONES, L. **Princípios de Química**: Questionando a vida moderna e o meio ambiente. Porto Alegre: Bookman, 2001.
- AUERNHAMMER, H. (Ed). Special Issue: **Global Positioning Systems in Agriculture**. Computers and Electronics in Agriculture, v. 11, n. 1, 1994.
- BENINI, L. C. **Estimação da densidade de solos utilizando sistemas de inferência fuzzy**. 2007. 194 f. Tese (Doutorado em Energia da Agricultura). Faculdade de Ciências Agrônomicas, Universidade Estadual Paulista. Botucatu, Brasil. 2007.
- BERNARDI, A. C. de C.; FRAGALLE, E. P.; INAMASU, R.Y. Inovação tecnológica em agricultura de precisão. **In: Agricultura de precisão: um novo olhar**. 1ª edição. São Carlos – SP: Embrapa Instrumentação, p. 297-302, 2011.
- BLACKMER, T.M. E SCHEPERS, J.S. Use of achlorophyll meter to monitor nitrogen status and schedule fertigation for corn. **Journal Production Agriculture**, v. 8, p. 56-60, 1995.
- BONGIOVANNI, R. E LOWENBERG-DEBOER, J. **Precision Agriculture and Sustainability**. In: Precision Agriculture, 5. 359–387, Kluwer Academic Publishers. Manufactured in The Netherlands, 2004.
- CHARNIAK, E.A E MCDERMOTT, D.V. **Introduction to Artificial Intelligence**. Addison-Wesley Publishing Company, Reading, MA, 1985.
- DOMINGUES, E. L. **Identificação do teor de Nitrogênio foliar em cana-de-açúcar no estágio inicial de crescimento utilizando infravermelho próximo e sistemas inteligentes**. 2011. 130 f. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Faculdade de Engenharia de Bauru, Universidade Estadual Paulista, Bauru, 2011.
- EHSANI, M. R.; UPADHYAYA, S.K.; SLAUGHTER, D.; SHAFII, S.; PELLETIER, M. **A NIR technique for rapid determination of soil mineral nitrogen**. Precision agriculture, v. 1, n. 2, p. 219-236, 1999.
- ELDIN, A.B. **Near Infra Red Spectroscopy**, Wide Spectra of Quality Control, Dr. Isin Akyar (Ed.), ISBN: 978-953-307-683-6, InTech, 2011.
- FILHO, I. de C. Agricultura de Precisão como ferramenta para promoção da sustentabilidade e competitividade do agronegócio brasileiro. **In: Agricultura de precisão: um novo olhar**. 1ª edição. São Carlos – SP: Embrapa Instrumentação, p. 328-331, 2011.

GAUTAM, R. K. E PANIGRAHI, S. **Image Processing Techniques and Neural Network Models for Predicting Plant Nitrate Using Aerial Images.** Neural Networks, 2003. Proceedings of the International Joint Conference on. Vol. 2. IEEE,p. 1031-1036, 2003.

GIL, P.T.; FONTES, P.C.R.; CECOM, P.R.; FERREIRA, F.A. **Índice SPAD para o diagnóstico do estado de nitrogênio e para o prognóstico da produtividade da batata.** Horticultura Brasileira, Brasília, v. 20, n. 4, p. 611-615, dezembro 2002.

GUIMARÃES. T.G.; FONTES, P.C.R.; PEREIRA, P.R.G.; ALVAREZ V., V.H.; MONNERAT, P.H. **Teores de clorofila determinados por medidor portátil e sua relação com formas de nitrogênio em folhas de tomateiro cultivado em dois tipos de solo.** *Bragantia*, Piracicaba, v. 58, n. 1, p. 209-216, 1999.

HAGAN, M. T.; MENHAJ M. B., Training Feedforward Networks with the Marquardt Algorithm. IEEE TRANSACTIONS ON NEURAL NETWORKS, VOL. 5, NO. 6, NOVEMBER 1994.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation.** Ontario, Canada: Pearson, 1999.

HUETT, D.O.; MAIER, N.A.; SPARROW, L.A.;PIGGOTT,T.J. Vegetables. In: REUTER, D.J.; ROBINSON, J.B. Eds. **Plant Analysis: an interpretation manual.** Second edition. Collingwood, Australia: CSIRO, p. 385-464, 1997

INAMASU,R.Y.;BERNARDI,A.C.de C.; VAZ,C.M.P.; NAIME,J.de M.; QUEIROS,L.R.; RESENDE,A.V.; VILEA,M.de F.; JORGE,L,A, de C.; BASSOI,L.H.; PEREZ,N.B.; FRAGALLE,E.P. Agricultura de Precisão para a sustentabilidade de sistemas produtivos do agronegócio brasileiro. **In: Agricultura de precisão: um novo olhar.** 1ª edição. São Carlos – SP: Embrapa Instrumentação, p. 14-26. 2011.

JAIN, A; GARG, A. Microfluidic Design of Neuron-MOSFET Based on ISFET,**In: Proceedings of the COMSOL Conference**, India, 2010.

JANG, J.S.R., “ANFIS: Adaptive-Network-based Fuzzy Inference Systems,” **IEEE Transactions on Systems, Man, and Cybernetics**, Vol. 23, No. 3, pp. 665-685, Maio 1993

LEITE, D. O.; PRADO, R. J. Espectroscopia no infravermelho: uma apresentação para o Ensino Médio. **Revista Brasileira de Ensino de Física**, v. 34, n. 2, 2504, 2012.

LINK, A., M. PANITZKI.; S. REUSCH. 2002. Hydro N-sensor: Tractor-mounted remote sensing for variable nitrogen fertilization. p. 1012–1018. **In P.C. Robert (ed.) Precision agriculture** [CD-ROM]. Proc. Int. Conf. on Precision Agric., 6th, Minneapolis, MN. 14–17 July 2002. ASA, CSSA, and SSSA, Madison, WI.

LINK, A. E S. REUSCH. 2006. Implementation of site-specific nitrogen application-Status and development of the YARA N-Sensor. p. 37–41. In **NJF Seminar 390, Precision Technology in Crop Production Implementation and Benefits**. Lillehammer, Norway. Norsk Jernbaneforbund, Stockholm, Sweden, 7–8 Nov. 2006.

MÁQUINAS AGRÍCOLAS JACTO S/A. Disponível em: <site www.jacto.com.br>. Acesso 16 jun. 2014.

MARKWELL, J.; OSTERMAN, J.C.; MITCHELL, J.L. Calibration of the Minolta SPAD-502 leaf chlorophyll meter. **Photosynthesis Research**, v. 46, p. 467-472, 1995.

McCYLLOCH, W, S; PITTS, W. A logical calculus of the ideas immanent in nervous activity, **Bulletin of Mathematical Biophysics**, v. 5 p 115-133, 1943

McBRATNEY, A.; WHELAN, B.; ANCEV, T. **Future Directions of Precision Agriculture**. In: Precision Agriculture. Proceedings Springer Science+Business Media Inc., v.6, p.7-23, 2005.

MOZELLI, L. A. **Controle fuzzy para sistemas Takagi-Sugeno: condições aprimoradas e aplicações**. 2008. 194 f. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal de Minas Gerais. Belo Horizonte, Brasil. 2008.

NTECH INDUSTRIES. NTech Industries: **GreenSeeker frequently asked questions, chlorophyll sensors perform variable rate fertilizing of wheat and corn crops**. NTech Industries, Ukiah, California. 2009.

PARZEN, E. On estimation of a probability density function and mode.', *Annals of Mathematics and Statistics* 33, 1065-1076. 1962.

PORTZ, G. **Obtenção de algoritmo agrônomo para sensor foto ativo de refletância vegetal visando à aplicação da adubação nitrogenada na cultura de cana-de-açúcar**. 2011. 121 f. Dissertação (Mestrado em Ciências) – Engenharia de Sistemas Agrícolas, Universidade de São Paulo – Escola Superior de Agricultura “Luiz de Queiroz”, Piracicaba, 2011.

SAH, R. N. **Nitrate-nitrogen determination—a critical review**. Communications in Soil Science & Plant Analysis, v. 25, n. 17-18, p. 2841-2869, 1994.

SCHEPERS, J.S. 2008. Active sensor tidbits. Disponível em http://www.isafarmnet.com/08OFNConfPresent/Nitrogen/Nitrogen_Sensors_Handout.pdf. Acesso em 14 jul. 2014.

SIBLEY, Kevin J. *et al.* In-field measurement of soil nitrate using an ion-selective electrode. **Advances in measurement systems**. InTechOpen, p. 1-27, 2010.

SOKALSKI, T.; CERESA, A.; ZWICKL, T.; PRETSCH, E. Large Improvement of the Lower Detection Limit of Ion-Selective Polymer Membrane Electrodes, **In: J. Am. Chem. Soc.** 119, 11347, 1997.

SPECHT, D.F. A general regression neural network, *IEEE Transactions on Neural Networks* 2(6), 568-576. 1991.

STAFFORD, J. V. Implementing Precision Agriculture in the 21st Century (Keynote address for the scientific session on Precision Agriculture, presented at AgEng 2000, 2). **Journal of Agricultural Engineering Research**, n. 76, p. 267-275, 2000.

STUART, B. **Infrared spectroscopy**. John Wiley & Sons, Inc., 2005.

TORRES, K. Y. C.; MARZAL,P.C.;KUBOTA,L.T;BAKKER,E.. Recentes avanços e novas perspectivas dos eletrodos íon-seletivos. **Química Nova**, v. 29, n. 5, p. 1094-1100, 2006.

ULSON, J. A. C.; BENEZ,S.H.; SILVA da I.N.;SOUZA de, A.N. **Nitrogen content identification in crop plants using spectral reflectance and artificial neural networks**.Neural Networks, Proceedings. IJCNN'01. International Joint Conference on. Vol. 3. IEEE, 2001.p. 2088-2092, 2001.

YARA GmbH & Co. KG. Operation Manual for the N-Sensor, 90 p, 2004.

YARA GmbH & Co. KG. Operation Manual for the Yara N-Sensor Software Release 3.300,66 p, 2010.

ZILLMAN, E. S.; GRAEFF., J.; LINK, W.D.; BATCHELOR, W.; CLAUPEIN. **Assessment of cereal nitrogen requirements derived by optical on-the-go sensors on heterogeneous soils**. Agron. J. 98:682–690. . 2006

APÊNDICE A – ALGORITMO ANFIS

```
% DEPARTAMENTO DE ENGENHARIA ELÉTRICA - FEB - UNESP
% Pos-graduação em Engenharia Elétrica
% Correção da aplicação de nitrogênio com sensor YARA
% ANFIS
% Versão 2
%
*****

clear all          % libera alocação para as variáveis
clc;               % limpa command window
close all          % limpa gráficos
disp('TREINAMENTO DE SISTEMA ANFIS')
disp('...')

% leitura dados da planilha via .mat

cd D:\MATLAB\Nitrogênio
xTreino=load('xTreino.mat');
xTeste=load('xTeste.mat');
dTreino=load('dTreino.mat');
dTeste=load('dTeste.mat');

% xTreino=xTreino.xTreino(:, [1]);
% xTeste=xTeste.xTeste(:, [1]);

% xTreino=xTreino.xTreino(:, [18,19]);
% xTeste=xTeste.xTeste(:, [18,19]);

% xTreino=xTreino.xTreino(:, [20,21]);
% xTeste=xTeste.xTeste(:, [20,21]);

% xTreino=[xTreino.xTreino(:, [18,19]) xTreino.xTreino(:, [1])] ;
% xTeste=[xTeste.xTeste(:, [18,19]) xTeste.xTeste(:, [1])];

% xTreino=[xTreino.xTreino(:, [20,21]) xTreino.xTreino(:, [1])] ;
% xTeste=[xTeste.xTeste(:, [20,21]) xTeste.xTeste(:, [1])];

% xTreino=xTreino.xTreino(:, [22,23,24,25]);
% xTeste=xTeste.xTeste(:, [22,23,24,25]);

% xTreino=xTreino.xTreino(:, [26,27,28,29]);
% xTeste=xTeste.xTeste(:, [26,27,28,29]);

% xTreino=[xTreino.xTreino(:, [22,23,24,25]) xTreino.xTreino(:, [1])] ;
% xTeste=[xTeste.xTeste(:, [22,23,24,25]) xTeste.xTeste(:, [1])];

% xTreino=[xTreino.xTreino(:, [26,27,28,29]) xTreino.xTreino(:, [1])] ;
% xTeste=[xTeste.xTeste(:, [26,27,28,29]) xTeste.xTeste(:, [1])];

dTreino=dTreino.dTreino;
dTeste=dTeste.dTeste;
xdTreino=[xTreino dTreino];
xdTeste=[xTeste dTeste];
```

```

% ANFIS
num_epocas = 200;
erro=0;

in_fis = genfis1([xTreino dTreino],3,'gaussmf');
[out_fis,trnErro] = anfis([xTeste dTeste],in_fis,[num_epocas erro
0.01]);

% calculo do erro quadrático médio
y1=evalfis(xTeste,out_fis);
REQM=sqrt(sum((dTeste-y1).^2)/length(dTeste));

% calculo do erro relativo médio
ER=(abs(dTeste-y1)./dTeste);
ERM=100*mean(ER);
DpERM=100*std(ER);

% calculo do erro abosluto médio
EAM=mean((abs(dTeste-y1)));

% mostra gráfico do TREINAMENTO: valores reais x valores estimados
figure
y2=evalfis(xTreino,out_fis);
eixoXtrn= 1:1:length(dTreino);
plot(eixoXtrn,dTreino,'ob',eixoXtrn,abs(y2),'*r')
xlabel('Amostras','FontWeight','bold','FontSize',11.5)
ylabel('Dosagem N (kg/hect)', 'FontWeight','bold','FontSize',11.5)
legend('Valores Observados','Valores Estimados')

% mostra gráfico do TESTE valores: reais x valores estimados
figure
eixoX= 1:1:length(dTeste);
plot(eixoX,dTeste,'ob',eixoX,y1,'*r')
xlabel('Amostras','FontWeight','bold','FontSize',11.5)
ylabel('Dosagem N (kg/hect)', 'FontWeight','bold','FontSize',11.5)
legend('Valores Observados','Valores Estimados')
title(['Dosagens Observadas x Estimadas: ERM(%)= ', num2str(ERM,3), ', ',
DP(%)= ', num2str(DpERM,3)], 'FontWeight','bold','FontSize',11.5)

% mostra gráfico de correlação entre valores reais x valores estimados
figure
plotregression(dTeste,y1,'Regressão Linear');
[r,m,b] = regression(dTeste,y1,'one');
legend('Observados=Estimados','Melhor ajuste','Dados')
xlabel('Dosagem Observada (kg/hect)', 'FontWeight','bold','FontSize',10.5)
ylabel(['Dosagem Estimada ~ = ',num2str(m,3), '*Observado + ',
num2str(b,3), ' (kg/hect)'], 'FontWeight','bold','FontSize',10.5);

% mostra gráfico de histograma
figure
erroTeste=dTeste-y1;
erroTreino=dTreino-evalfis(xTreino,out_fis);
ploterrhist(erroTreino,'Treinamento',erroTeste,'Teste','bins',20)
ylabel('Instancias','FontWeight','bold','FontSize',11.5)
title(['Histograma de Erros'], 'FontWeight','bold','FontSize',11.5)

% mostra gráfico de erro de treinamento

```

```

figure
plot(trnErro)
grid
title(['Erro de Treinamento'],'FontWeight','bold','FontSize',11.5)
xlabel('Número de Epocas','FontWeight','bold','FontSize',11.5)
ylabel('Raiz quadrada do EQM','FontWeight','bold','FontSize',11.5)

% mostra gráfico de superfície
figure
u=out_fis;
gensurf(u);
grid;
title(['Gráfico de Superfície'],'FontWeight','bold','FontSize',11.5)

% mostra resultado no command window

disp('      REQM      EAM      ERM      DpERM      R2')
disp([REQM,EAM,ERM,DpERM,r])

```

APÊNDICE B – DADOS PARA VALIDAÇÃO E TREINAMENTO

```
clear all          % libera alocação para as variáveis
clc;              % limpa command window
close all;

% leitura dos dados
cd D:\MATLAB\Nitrogênio

x=xlsread('Data_Spectro.xls',2,'I2:AK122');
d=xlsread('Data_Spectro.xls',2,'D2:D122');

% separa os 20% dos dados para validação cruzada
[linhas,colunas]=size(x);
[trainInd,valInd,testInd] = dividerand(linhas,0.8,0.0,0.2);
xTreino=x(trainInd,:);
dTreino=d(trainInd);
xTeste=x(testInd,:);
dTeste=d(testInd);

xdTreino=[xTreino dTreino];
xdTeste=[xTeste dTeste];

% salva arquivos .mat
save('xTreino','xTreino')
save('xTeste','xTeste')
save('dTreino','dTreino')
save('dTeste','dTeste')
save('Indices.mat','trainInd','valInd','testInd')
```

APÊNDICE C – ALGORITMO GRNN

```
% DEPARTAMENTO DE ENGENHARIA ELÉTRICA - FEB - UNESP
% Pos-graduação em Engenharia Elétrica
% Correção da aplicação de nitrogênio com sensor YARA
% Rede Generalized Regression Neural Network - GRNN
% Algoritmo de treinamento: Clustering/LMS
% Versão 2
%
*****
**

clear all          % libera alocação para as variáveis
clc;               % limpa command window
close all          % limpa gráficos
disp('TREINAMENTO DE RNA GRNN')
disp('...')

% leitura dos dados
cd D:\MATLAB\Nitrogênio
xTreino=load('xTreino.mat');
xTeste=load('xTeste.mat');
dTreino=load('dTreino.mat');
dTeste=load('dTeste.mat');

% vetores de treinamento
% xTreino=xTreino.xTreino(:, [1])./100;
% xTeste=xTeste.xTeste(:, [1])./100;

% xTreino=xTreino.xTreino(:, [18,19])./100;
% xTeste=xTeste.xTeste(:, [18,19])./100;

% xTreino=xTreino.xTreino(:, [20,21])./100;
% xTeste=xTeste.xTeste(:, [20,21])./100;

% xTreino=[xTreino.xTreino(:, [18,19])./100 xTreino.xTreino(:, [1])] ;
% xTeste=[xTeste.xTeste(:, [18,19])./100 xTeste.xTeste(:, [1])];

% xTreino=[xTreino.xTreino(:, [20,21])./100 xTreino.xTreino(:, [1])] ;
% xTeste=[xTeste.xTeste(:, [20,21])./100 xTeste.xTeste(:, [1])];

% xTreino=xTreino.xTreino(:, [22,23,24,25])./100;
% xTeste=xTeste.xTeste(:, [22,23,24,25])./100;

% xTreino=xTreino.xTreino(:, [26,27,28,29])./100;
% xTeste=xTeste.xTeste(:, [26,27,28,29])./100;

% xTreino=[xTreino.xTreino(:, [22,23,24,25])./100
xTreino.xTreino(:, [1])] ;
% xTeste=[xTeste.xTeste(:, [22,23,24,25])./100 xTeste.xTeste(:, [1])];

% xTreino=[xTreino.xTreino(:, [26,27,28,29])./100
xTreino.xTreino(:, [1])] ;
% xTeste=[xTeste.xTeste(:, [26,27,28,29])./100 xTeste.xTeste(:, [1])];

dTreino=dTreino.dTreino;
```

```

dTeste=dTeste.dTeste;
xdTreino=[xTreino dTreino];
xdTeste=[xTeste dTeste];

% arquitetura da RNA

net = newgrnn(xTreino',dTreino',10);

%calculo do RMSE

y1=net(xTeste');
y2=net(xTreino');
REQM=sqrt(sum((dTeste'-y1).^2)/length(dTeste));

% calculo do erro relativo médio
ER=(abs(dTeste'-y1)./dTeste');
ERM=100*mean(ER);
DpERM=100*std(ER);

% calculo do erro abosluto médio
EAM=mean(abs(dTeste'-y1));

% mostra gráfico do TESTE valores: reais x valores estimados
figure
eixoX= 1:length(dTeste);
plot(eixoX,dTeste','ob',eixoX,y1,'*r')
xlabel('Amostras','FontWeight','bold','FontSize',11.5)
ylabel('Dosagem N (kg/hect)', 'FontWeight','bold','FontSize',11.5)
legend('Valores Observados','Valores Estimados')
title(['Dosagens Observadas x Estimadas: ERM(%)=', num2str(ERM,3), ', ',
DP(%)=', num2str(DpERM,3)], 'FontWeight','bold','FontSize',11.5)
%
figure
plotregression(dTeste',y1,'Regressão Linear');
[r,m,b] = regression(dTeste',y1,'one');
legend('Observados=Estimados','Melhor ajuste','Dados')
xlabel('Dosagem Observada
(kg/hect)', 'FontWeight','bold','FontSize',10.5)
ylabel(['Dosagem Estimada ~=', num2str(m,3), '*Observado + ',
num2str(b,3), ' (kg/hect)'], 'FontWeight','bold','FontSize',10.5);

% mostra gráfico de histograma
figure
erroTeste=dTeste'-y1;
erroTreino=dTreino'-y2;
ploterrhist(erroTreino,'Treinamento',erroTeste,'Teste','bins',20)
ylabel('Instancias','FontWeight','bold','FontSize',11.5)
title(['Histograma de Erros'],'FontWeight','bold','FontSize',11.5)

% mostra resultado no command window

disp('      REQM      EAM      ERM      DpERM      R2')
disp([REQM,EAM,ERM,DpERM,r])

```

APÊNDICE D – ALGORITMO RNA PMC

```

% DEPARTAMENTO DE ENGENHARIA ELÉTRICA - FEB - UNESP
% Pos-graduação em Engenharia Elétrica
% Correção da aplicação de nitrogênio com sensor YARA
% Rede perceptron multicamadas - PMC
% Algoritmo de treinamento: Levenberg-Marquardt
% Versão 3
%
*****
**

clear all          % libera alocação para as variáveis
clc;               % limpa command window
close all          % limpa gráficos
disp('TREINAMENTO DE RNA PMC')
disp('...')

% leitura dos dados
cd D:\MATLAB\Nitrogênio
x=xlsread('Data_Spectro.xls',2,'I2:AK122');
d=xlsread('Data_Spectro.xls',2,'D2:D122');
load('Indices.mat');

% vetores de treinamento
%x=x(:,1);
%x=x(:,[18,19])./100;
%x=x(:,[20,21])./100;
%x=[x(:,[18,19])./100 x(:,1)]
%x=[x(:,[20,21])./100 x(:,1)]
% x=x(:,[22,23,24,25])./100;
% x=x(:,[26,27,28,29])./100;
x=[x(:,[22,23,24,25])./100 x(:,1)];
%x=[x(:,[26,27,28,29])./100 x(:,1)];

% arquitetura da RNA
net = newff(x,d',[20 20 5],{'logsig' 'logsig' 'logsig'},'trainlm')

% parametros da RNA
net.divideFcn = 'divideind';
net.divideParam.trainInd = trainInd;
net.divideParam.valInd = [ ];
net.divideParam.testInd = testInd;
net.trainParam.showWindow=1          %show training GUI
net.trainParam.epochs=10             % maximum number of epochs
to train
net.trainParam.goal=0.1;              %Performance goal
net.trainParam.max_fail=20;           %Maximum validation failure
net.trainParam.time=inf;              %Maximum time to train in
seconds

% parametros de treinamento
[net,tr]=train(net,x',d');

%calculo do RMSE
xTreino=x(tr.trainInd,:);
xTeste=x(tr.testInd,:);
dTreino=d(tr.trainInd);
dTeste=d(tr.testInd);

```

```

y1=net(xTeste');
y2=net(xTreino');
REQM=sqrt(sum((dTeste'-y1).^2)/length(dTeste));

% calculo do erro relativo médio
ER=(abs(dTeste'-y1)./dTeste');
ERM=100*mean(ER);
DpERM=100*std(ER);

% calculo do erro absoluto médio
EAM=mean((abs(dTeste'-y1)));

% mostra gráfico do TESTE valores: reais x valores estimados
figure
eixoX= 1:length(dTeste');
plot(eixoX,dTeste','ob',eixoX,y1,'*r')
xlabel('Amostras','FontWeight','bold','FontSize',11.5)
ylabel('Dosagem N (kg/hect)', 'FontWeight','bold','FontSize',11.5)
legend('Valores Observados','Valores Estimados')
title(['Dosagens Observadas x Estimadas: ERM(%)=', num2str(ERM,3), ', ',
DP(%)=' ', num2str(DpERM,3)], 'FontWeight','bold','FontSize',11.5)

% mostra grafico de regressão
figure
plotregression(dTeste',y1,'Regressão Linear');
[r,m,b] = regression(dTeste',y1,'one');
% legend('Observados=Estimados','Melhor ajuste','Dados')
xlabel('Dosagem Observada (kg/hect)', 'FontWeight','bold','FontSize',10.5)
ylabel(['Dosagem Estimada ~=' ,num2str(m,3), '*Observado + ', num2str(b,3), ' (kg/hect)'], 'FontWeight','bold','FontSize',10.5);

% mostra gráfico de histograma de erro
figure
erroTeste=dTeste'-y1;
erroTreino=dTreino'-y2;
ploterrhist(erroTreino,'Treinamento',erroTeste,'Teste','bins',20)
ylabel('Instancias','FontWeight','bold','FontSize',11.5)
title(['Histograma de Erros'],'FontWeight','bold','FontSize',11.5)

% Mostra gráfico Erro de treinamento x épocas
figure
plotperform(tr);
title(['Erro de Treinamento'],'FontWeight','bold','FontSize',11.5)
xlabel('Número de Epocas','FontWeight','bold','FontSize',11.5)
ylabel('Raiz quadrada do EQM','FontWeight','bold','FontSize',11.5)

% mostra resultado no command window

disp('      REQM      EAM      ERM      DpERM      R2')
disp([REQM,EAM,ERM,DpERM,r])

```