

**UNIVERSIDADE ESTADUAL PAULISTA  
FACULDADE DE ENGENHARIA DE BAURU**

**EDSON LUCIO DOMINGUES**

**IDENTIFICAÇÃO DO TEOR DE NITROGÊNIO FOLIAR EM CANA-DE-AÇÚCAR  
NO ESTÁGIO INICIAL DE CRESCIMENTO UTILIZANDO INFRAVERMELHO  
PRÓXIMO E SISTEMAS INTELIGENTES**

**BAURU  
2011**

**EDSON LUCIO DOMINGUES**

**IDENTIFICAÇÃO DO TEOR DE NITROGÊNIO FOLIAR EM CANA-DE-AÇÚCAR  
NO ESTÁGIO INICIAL DE CRESCIMENTO UTILIZANDO INFRAVERMELHO  
PRÓXIMO E SISTEMAS INTELIGENTES**

Dissertação apresentada como requisito á 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. Alfredo Covolan Ulson

**BAURU  
2011**

Domingues, Edson Lucio.

Identificação do teor de nitrogênio foliar em cana-de-açúcar no estágio inicial de crescimento utilizando infravermelho próximo e sistemas inteligentes / Edson Lucio Domingues, 2011

128 f. : Il.

Orientador: Alfredo Covolan Ulson

Dissertação (Mestrado)-Universidade Estadual Paulista. Faculdade de Engenharia, Bauru, 2011

1. Análise de nitrogênio. 2. Sensor óptico. 3. Redes neurais artificiais. I. Universidade Estadual Paulista. Faculdade de Engenharia. II. Título.



**ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE Mestrado DE EDSON LUCIO DOMINGUES, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DO(A) FACULDADE DE ENGENHARIA DE BAURU.**

Aos 15 dias do mês de dezembro do ano de 2011, às 14:00 horas, no(a) ANFITEATRO DA SEÇÃO DE PÓS-GRADUAÇÃO DA FACULDADE DE ENGENHARIA, 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 - UNESP, Prof. Dr. ROGÉRIO ANDRADE FLAUZINO do(a) Departamento de Engenharia Elétrica / Universidade de São Paulo - USP, Prof. Dr. PAULO JOSE AMARAL SERNI do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, sob a presidência do primeiro, a fim de proceder a arguição pública da DISSERTAÇÃO DE Mestrado de EDSON LUCIO DOMINGUES, intitulado "IDENTIFICAÇÃO DO TEOR DE NITROGÊNIO FOLIAR EM CANA DE AÇÚCAR NO ESTÁGIO INICIAL DE CRESCIMENTO UTILIZANDO INFRAVERMELHO PRÓXIMO E SISTEMAS INTELIGENTES". 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. ROGÉRIO ANDRADE FLAUZINO

  
Prof. Dr. PAULO JOSE AMARAL SERNI

## **AGRADECIMENTOS**

Agradeço a Deus pelas oportunidades que me foram dadas na vida.

Não posso deixar de agradecer aos meus pais Jorge e Rosa, sem os quais não estaria aqui.

Ao meu orientador Prof. Dr. Alfredo Covolan Ulson e ao Prof. Dr. Paulo José Amaral Serni, pelos ensinamentos, apoio e também pelas boas conversas que tivemos durante as correções.

Uma dedicatória especial ao meu grande amigo e companheiro de turma Evandro Sergio Marconato, pelo apoio e ajuda para vencer mais esta etapa da minha vida.

Dedico também este trabalho a minha esposa Maria Stela, e aos meus três filhos Eduardo Matheus e Lucas pela paciência e compreensão por todas as minhas ausências nos momentos de convívio em família.

Agradeço a todos os amigos que também me auxiliaram neste trabalho, principalmente o Denis Yukio Sakuma, o Cristiano Pontelli e o Marcos Ikeguchi Ohira.

Finalizo com agradecimentos a Maquinas Agrícolas Jacto S/A, e todos os envolvidos na empresa pelo apoio para realizar este trabalho.

## RESUMO

A busca por novas soluções que estimulem o crescimento da produção agrícola para atender o aumento do consumo mundial de produtos agrícolas, sem aumentar o impacto ambiental, desperta o interesse pelo desenvolvimento de novas técnicas de controle e aplicação de insumos nas plantações, visando uma melhor precisão no gerenciamento das quantidades de nutrientes necessários nas áreas agrícolas. No Brasil a cultura da cana-de-açúcar esta se destacando no segmento agrícola e o aumento do interesse mundial no mercado de açúcar e álcool têm incrementado o aumento de investimentos no setor em todo o país. A cultura de cana-de-açúcar tem grande necessidade de controle na aplicação de fertilizantes nitrogenados e esta necessidade estimula as pesquisas por novas soluções que permitam o monitoramento da quantidade de nitrogênio absorvida nas plantas, respeitando sua variabilidade espacial, para melhorar a eficiência no uso dos fertilizantes nitrogenados, aumentando a produtividade, reduzindo custos e os impactos ambientais. O uso dos sensores ópticos como ferramenta para medir a quantidade de nitrogênio absorvida pelas plantas através da refletância vem despertando o interesse dos pesquisadores e a utilização desta técnica em plantas de cana-de-açúcar no estágio inicial do crescimento precisa ser aprimorada. Esta dissertação pesquisou novas técnicas de processamento em tempo real utilizando sistemas inteligentes aplicados à ambientes agrícolas baseados em redes neurais artificiais, para melhorar a precisão das correlações das medições de refletâncias de um sensor óptico utilizado para estimar a quantidade de nitrogênio nas plantas de cana-de-açúcar no estágio inicial do crescimento. Os resultados obtidos pelas redes neurais artificiais apresentaram precisão melhor na correlação das refletâncias oferecendo a possibilidade de utilizar sistemas embarcados com melhor precisão nos resultados da estimação de nitrogênio em tempo real.

**Palavras-chave:** Análise de Nitrogênio. Sensor óptico. Redes neurais artificiais.

## **ABSTRACT**

The search for new solutions that stimulate the agricultural production growth in order to meet the world food consumption increase, without further environmental impact, motivates the development of new crops inputs use and control techniques, aiming to improve the accuracy on amounts management of needed nutrients in agricultural areas. In Brazil, the sugar cane cultivation has been highlighted in the agricultural sector and increased global interest in the sugar and alcohol has spurred increased investment in the sector throughout the country. The cultivation of sugar cane is in great need to control the use of nitrogen fertilizers and this need stimulates researches for new solutions allowing the monitoring of the amount of absorbed nitrogen in plants, consistent with their spatial variability, to improve the efficiency of nitrogen fertilizers use, increasing productivity, reducing costs and environmental impacts. The use of optical sensors as a tool for measuring the amount of nitrogen absorbed by plants through reflectance has stimulated the interest of researchers and the use of said technique on sugar cane plants during the early stages of growing is still to be enhanced. This dissertation researched new real-time processing techniques using intelligent systems applied to agricultural environments based on artificial neural networks in order to improve the accuracy of the correlations of the measurements of reflectance of an optical sensor in order to estimate the amount of nitrogen in sugar cane plants in the early stages of growing. The results presented by the artificial neural networks show the possibility of using embedded systems with better accuracy in the results of real time nitrogen estimation.

Keywords: Nitrogen Analysis. Optical Sensor. Neural Networks.

## LISTA DE FIGURAS

Figura 1 - Ciclo das tecnologias e máquinas envolvidas na Agricultura de Precisão.....	23
Figura 2 - Gráfico da assinatura espectral .....	27
Figura 3 - N-Sensor Yara .....	30
Figura 4 - N-Sensor ALS Yara .....	30
Figura 5 - Diagrama Esquemático do N-Sensor ALS .....	31
Figura 6 - Espectro de refletâncias do trigo versus nitrogênio com N-Sensor ALS .....	32
Figura 7 - Vista superior da área de leitura da refletância do N-Sensor ALS .....	33
Figura 8 - Vista traseira da área de leitura da refletância do N-Sensor ALS .....	33
Figura 9 - Diagrama Esquemático das interfaces do N-Sensor ALS.....	34
Figura 10 - Uniport NPK.....	41
Figura 11 - Uniport NPK montado com o sensor N-Sensor ALS .....	43
Figura 12 - Vista traseira da montagem do N-Sensor ALS no Uniport NPK .....	43
Figura 13 - Vista lateral da montagem do N-Sensor ALS no Uniport NPK .....	44
Figura 14 - Vista frontal da montagem do N-Sensor ALS no Uniport NPK .....	44
Figura 15 - Foto do talhão utilizado no ensaio com o sensor óptico .....	45
Figura 16 - Gráfico dos pontos georreferenciados do talhão utilizado no ensaio.....	45
Figura 17 - Correlação da refletância S1 com nitrogênio kg. ha <sup>-1</sup> Laboratório - Bd121 .....	48
Figura 18 - Correlação da refletância S1 com nitrogênio kg. ha <sup>-1</sup> Laboratório - Bd100 .....	49
Figura 19 - Maiores valores de R <sup>2</sup> do método 1 - PMC - Bd121 - 1 camada oculta .....	84
Figura 20 - Maiores valores de R <sup>2</sup> do método 1 - PMC - Bd121 - 2 camadas ocultas .....	84
Figura 21 - Maiores valores de R <sup>2</sup> do método 1 - PMC - Bd121 - 3 camadas ocultas .....	85
Figura 22 - Maiores valores de R <sup>2</sup> - método 3 - RBF - Bd121 – 3 índices spread .....	85
Figura 23 - Maiores valores de R <sup>2</sup> do método 2 - PMC - Bd100 - 1 camada oculta .....	87
Figura 24 - Maiores valores de R <sup>2</sup> do método 2 - PMC - Bd100 - 2 camadas ocultas .....	87
Figura 25 - Maiores valores de R <sup>2</sup> do método 2 - PMC - Bd100 - 3 camadas ocultas .....	88
Figura 26 - Maiores valores de R <sup>2</sup> do método 4 - RBF – Bd100 – 3 índices spread .....	88
Figura 27 - Gráfico do Treinamento da rede PMC - seqüência 1E2 - 4 .....	91
Figura 28 - Gráfico da Regressão linear do Treinamento da rede - seqüência 1E2 - 4 .....	92
Figura 29 - Gráfico da Regressão linear da Validação da rede - seqüência 1E2 - 4.....	92
Figura 30 - Gráfico da Validação da base de dados - seqüência 1E2 - 4.....	93
Figura 31 - Gráfico do Treinamento da rede PMC - seqüência 2L3 - 1 .....	94
Figura 32 - Gráfico da Regressão linear do Treinamento da rede - seqüência 2L3 - 1.....	95
Figura 33 - Gráfico da Regressão linear da Validação da rede - seqüência 2L3 - 1.....	95
Figura 34 - Gráfico da Validação da base de dados - seqüência 2L3 - 1 .....	96
Figura 35 – Arquitetura dos dados aplicados nas redes neurais. ....	97
Figura 36 - Modelo de McCulloch-Pitts.....	104
Figura 37 - Função de ativação degrau .....	105
Figura 38 - Função de ativação degrau .....	106
Figura 39 - Função de ativação rampa .....	106
Figura 40 - Função de ativação sigmóide.....	107
Figura 41 - Função de ativação tangente hiperbólica.....	107
Figura 42 - Diagrama esquemático da rede Perceptron multicamadas .....	109
Figura 43 – Amostra da base de dados Bd121.....	117
Figura 44 – Amostra da base de dados Bd100.....	118

## LISTA DE TABELAS

Tabela 1 - Descrição das informações do sistema GPS da base de dados .....	46
Tabela 2 - Descrição das informações de refletâncias da base de dados .....	47
Tabela 3- Descrição das correlações das bases de dados Bd121 e Bd100 .....	50
Tabela 4 – Configuração da rede neural dos métodos 1A a 1L.....	52
Tabela 5 – Configuração da rede neural dos métodos 2A a 2L.....	52
Tabela 6 – Configuração da rede neural dos métodos 3A a 3C e 4A a 4C.....	53
Tabela 7 - Resultados - rede PMC - 1 camada oculta - Bd121 - EQM $1e^{-2}$ .....	56
Tabela 8 - Resultados - rede PMC - 1 camada oculta - Bd121 - EQM $9e^{-3}$ .....	56
Tabela 9 - Resultados - rede PMC - 1 camada oculta - Bd121 - EQM $7e^{-3}$ .....	57
Tabela 10 - Resultados - rede PMC - 1 camada oculta - Bd121 - EQM $5e^{-3}$ .....	57
Tabela 11 - Resultados - rede PMC - 1 camada oculta - Bd121 - EQM $3e^{-3}$ .....	58
Tabela 12 - Resultados - rede PMC - 1 camada oculta - Bd121 - EQM $1e^{-3}$ .....	58
Tabela 13 - Resultados - rede PMC - 2 camadas ocultas - Bd121 - EQM $1e^{-2}$ .....	59
Tabela 14 - Resultados - rede PMC - 2 camadas ocultas - Bd121 - EQM $9e^{-3}$ .....	59
Tabela 15 - Resultados - rede PMC - 2 camadas ocultas - Bd121 - EQM $7e^{-3}$ .....	60
Tabela 16 - Resultados - rede PMC - 2 camadas ocultas - Bd121 - EQM $5e^{-3}$ .....	60
Tabela 17 - Resultados - rede PMC - 2 camadas ocultas - Bd121 - EQM $3e^{-3}$ .....	61
Tabela 18 - Resultados - rede PMC - 2 camadas ocultas - Bd121 - EQM $1e^{-3}$ .....	61
Tabela 19 - Resultados - rede PMC - 3 camadas ocultas - Bd121 - EQM $1e^{-2}$ .....	62
Tabela 20 - Resultados - rede PMC - 3 camadas ocultas - Bd121 - EQM $9e^{-3}$ .....	62
Tabela 21 - Resultados - rede PMC - 3 camadas ocultas - Bd121 - EQM $7e^{-3}$ .....	63
Tabela 22 - Resultados - rede PMC - 3 camadas ocultas - Bd121 - EQM $5e^{-3}$ .....	63
Tabela 23 - Resultados - rede PMC - 3 camadas ocultas - Bd121 - EQM $3e^{-3}$ .....	64
Tabela 25 - Resultados - rede PMC - 1 camada oculta - Bd100 - EQM $1e^{-2}$ .....	65
Tabela 26 - Resultados - rede PMC - 1 camada oculta - Bd100 - EQM $9e^{-3}$ .....	66
Tabela 27 - Resultados - rede PMC - 1 camada oculta - Bd100 - EQM $7e^{-3}$ .....	66
Tabela 28 - Resultados - rede PMC - 1 camada oculta - Bd100 - EQM $5e^{-3}$ .....	67
Tabela 29 - Resultados - rede PMC - 1 camada oculta - Bd100 - EQM $3e^{-3}$ .....	67
Tabela 30 - Resultados - rede PMC - 1 camada oculta - Bd100 - EQM $1e^{-3}$ .....	68
Tabela 31 - Resultados - rede PMC - 2 camadas ocultas - Bd100 - EQM $1e^{-2}$ .....	68
Tabela 32 - Resultados - rede PMC - 2 camadas ocultas - Bd100 - EQM $9e^{-3}$ .....	69
Tabela 33 - Resultados - rede PMC - 2 camadas ocultas - Bd100 - EQM $7e^{-3}$ .....	69
Tabela 34 - Resultados - rede PMC - 2 camadas ocultas - Bd100 - EQM $5e^{-3}$ .....	70
Tabela 35 - Resultados - rede PMC - 2 camadas ocultas - Bd100 - EQM $3e^{-3}$ .....	70
Tabela 36 - Resultados - rede PMC - 2 camadas ocultas - Bd100 - EQM $1e^{-3}$ .....	71
Tabela 37 - Resultados - rede PMC - 3 camadas ocultas - Bd100 - EQM $1e^{-2}$ .....	71
Tabela 38 - Resultados - rede PMC - 3 camadas ocultas - Bd100 - EQM $9e^{-3}$ .....	72
Tabela 39 - Resultados - rede PMC - 3 camadas ocultas - Bd100 - EQM $7e^{-3}$ .....	72
Tabela 40 - Resultados - rede PMC - 3 camadas ocultas - Bd100 - EQM $5e^{-3}$ .....	73
Tabela 41 - Resultados - rede PMC - 3 camadas ocultas - Bd100 - EQM $3e^{-3}$ .....	73
Tabela 42 - Resultados - rede PMC - 3 camadas ocultas - Bd100 - EQM $1e^{-3}$ .....	74
Tabela 43 - Resultados - rede RBF - Bd121 – EQM $1e^{-2}$ .....	75
Tabela 44 - Resultados - rede RBF - Bd121 – EQM $9e^{-3}$ .....	76
Tabela 45 - Resultados - rede RBF - Bd121 – EQM $7e^{-3}$ .....	76
Tabela 46 - Resultados - rede RBF - Bd121 – EQM $5e^{-3}$ .....	77
Tabela 47 - Resultados - rede RBF - Bd121 – EQM $3e^{-3}$ .....	77
Tabela 48 - Resultados - rede RBF - Bd121 – EQM $1e^{-3}$ .....	78
Tabela 49 - Resultados - rede RBF - Bd100 – EQM $1e^{-2}$ .....	79

Tabela 50 - Resultados - rede RBF - Bd100 – EQM $9e^{-3}$ .....	80
Tabela 51 - Resultados - rede RBF - Bd100 – EQM $7e^{-3}$ .....	80
Tabela 52 - Resultados - rede RBF - Bd100 – EQM $5e^{-3}$ .....	81
Tabela 53 - Resultados - rede RBF - Bd100 – EQM $3e^{-3}$ .....	81
Tabela 54 - Resultados - rede RBF - Bd100 – EQM $1e^{-3}$ .....	82
Tabela 55 - Maiores resultados - PMC e RBF - Bd121 e resultado do sensor óptico .....	89
Tabela 56 - Maiores resultados - PMC e RBF - Bd100 e resultado do sensor óptico .....	90

## LISTA DE ABREVIATURAS E SIGLAS

ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i> (Sistema de Inferência <i>Neuro-Fuzzy</i> Adaptativo)
AP	Agricultura de Precisão
CONAB	Companhia Nacional de Abastecimento
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
EQM	Erro Quadrático Médio
GPS	<i>Global Positioning System</i> (Sistema de Posicionamento Global)
IAC	Instituto Agronômico de Campinas
N <sub>2</sub>	Nitrogenio
NIR	<i>Near Infra Red</i> (Infravermelho Próximo)
PMC	<i>Perceptron</i> Multicamadas
RBF	<i>Radial Basis Function</i> (Função de Base Radial)
RMSE	<i>Root Mean Square Error</i> (Raiz do Erro Quadrático Médio)
RNA	Redes Neurais Artificiais
USB	Universal Serial Bus (barramento serial universal)

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>12</b>
1.1	MOTIVAÇÃO .....	14
1.2	OBJETIVO .....	18
1.3	ESTRUTURA DA DISSERTAÇÃO .....	19
<b>2</b>	<b>INVESTIGAÇÃO TÉCNICO-CIENTÍFICA</b> .....	<b>21</b>
2.1	AGRICULTURA DE PRECISÃO .....	21
2.2	NITROGÊNIO NA CULTURA DA CANA-DE-AÇÚCAR .....	24
2.3	ESPECTROSCOPIA .....	26
2.4	SENSOR ÓPTICO PARA IDENTIFICAÇÃO DO TEOR DE NITROGÊNIO .....	29
2.5	SISTEMAS INTELIGENTES APLICADOS À AMBIENTES AGRÍCOLAS .....	35
2.6	ÍNDICES DE DESEMPENHO .....	38
<b>3</b>	<b>MATERIAIS E MÉTODOS</b> .....	<b>40</b>
3.1	EQUIPAMENTOS .....	40
3.2	FERRAMENTAS COMPUTACIONAIS .....	42
3.3	BASE DE DADOS .....	42
3.4	METODOLOGIA .....	50
3.4.1	Descrição dos métodos utilizados nos ensaios .....	52
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b> .....	<b>55</b>
4.1	RESULTADOS DOS TESTES DO MÉTODO 1 .....	55
4.2	RESULTADOS DOS TESTES DO MÉTODO 2 .....	65
4.3	RESULTADOS DOS TESTES DO MÉTODO 3 .....	75
4.4	RESULTADOS DOS TESTES DO MÉTODO 4 .....	79
4.5	COMPARAÇÕES DOS RESULTADOS DOS TESTES .....	83
4.6	GRÁFICOS DOS TESTES DA REDE PMC, SEQUÊNCIA 1E2 - 4 .....	91
4.7	GRÁFICOS DOS TESTES DA REDE PMC, SEQUÊNCIA 2L3 - 1 .....	94
<b>5</b>	<b>CONCLUSÕES E RECOMENDAÇÕES</b> .....	<b>97</b>
	<b>BIBLIOGRAFIAS</b> .....	<b>100</b>
	<b>APÊNDICE A – REDES NEURAIS ARTIFICIAIS</b> .....	<b>104</b>
A1.	O NEURÔNIO ARTIFICIAL .....	104
A2.	TREINAMENTO DE REDES NEURAIS ARTIFICIAIS .....	107
A3.	ALGORITMO <i>BACKPROPAGATION</i> .....	108
A4.	ALGORITMO DE <i>LEVENBERG-MARQUARDT</i> .....	111
A5.	ALGORITMO DE LEVENBERG REGULARIZADO .....	113
A6.	FUNÇÕES DE BASE RADIAL .....	114
A7.	REDES NEURAIS COM FUNÇÕES DE ATIVAÇÃO DE BASE RADIAL .....	114
A8.	COMPARAÇÃO ENTRE REDES RBF E PMC .....	115
	<b>APÊNDICE B - BASE DE DADOS BD121</b> .....	<b>116</b>
	<b>APÊNDICE C - SOFTWARE PMC_BD121_BD100_123_CAMADAS.M</b> .....	<b>119</b>
	<b>APÊNDICE D - SOFTWARE RBF_BD121_BD100.M</b> .....	<b>125</b>

## 1 INTRODUÇÃO

A busca por novas soluções que estimulam o crescimento da produção agrícola para atender o aumento do consumo mundial é uma grande preocupação de todos os envolvidos com a agricultura. Esta busca constante pelo aumento da produção agrícola tem causado danos ao meio ambiente e segundo Pontelli (2007), grandes áreas de florestas naturais foram derrubadas para ceder lugar às empresas agrícolas de produção de alimentos sem nenhuma orientação técnica conservacionista, explorando desordenadamente os espaços agricultáveis, solo e recursos hídricos. Este crescimento desordenado da agricultura vem provocando um enorme desequilíbrio entre flora e fauna, com alterações no meio ambiente gerada pelo aumento das áreas de baixa fertilidade do solo e o aparecimento de agentes nocivos à planta cultivada.

O interesse pelo aumento da produção dos produtos agrícolas despertou o interesse dos pesquisadores pelo desenvolvimento de novas técnicas para melhorar a fertilidade do solo. Com os resultados das pesquisas surgiram os fertilizantes químicos como uma nova solução tecnológica para a solução do problema. Após o aparecimento dos fertilizantes químicos, surgiram as divulgações e promoções para o uso desses novos recursos tecnológicos e as empresas agrícolas passaram a produzir quantidades maiores de alimentos se comparados com a mesma área de produção sem o uso dos fertilizantes. (NISHIMURA, 1995).

Porém, por falta de informações técnicas ou pelo interesse capitalista e sem pensar nas conseqüências para o meio ambiente, o uso desses novos recursos tecnológicos na produção agrícola contribuiu de forma efetiva para a contaminação do ar, solo, água e alimentos. A contaminação do meio ambiente através da utilização dos fertilizantes pode ser causada pelo uso em excesso do produto, porque nem sempre o produtor agrícola sabe usar as quantidades recomendadas e uma das conseqüências da contaminação do meio ambiente através do uso em excesso dos fertilizantes é o aumento do número de doenças causadas por intoxicações provenientes da contaminação das reservas de água do lençol freático no país (PRETTY J., 2003).

Como exemplo, pode-se citar o nitrogênio (N<sub>2</sub>) aplicado à cultura de beterrabas. Segundo PURQUERIO LFV, et al. (2009), quando o nitrogênio é aplicado em doses

inferiores às recomendadas, não se tem o ganho agrônômico; quando aplicado em excesso tem-se o crescimento exagerado do fruto sem o correspondente aumento da sacarose, além de ter-se a parcela não absorvida de nitrogênio um elemento poluidor do meio ambiente.

Os resultados das pesquisas que indicam o aumento da poluição do meio ambiente causado pelo uso dos fertilizantes químicos é um dos grandes problemas e também um grande desafio dos produtores agrícolas atualmente para encontrar uma solução que permite o uso dos fertilizantes de modo sustentado para aumentar a sua produtividade, garantindo a manutenção dos recursos de produção e também evitando a sua degradação. Para atingir esse grande objetivo, o agricultor precisará empregar nas lavouras novas tecnologias de controle das reais necessidades de nutrientes e fertilizantes para uma aplicação de precisão, protegendo o meio ambiente que está a sua volta.

As novas tecnológicas que oferecem os recursos tecnológicos para melhorar a precisão no manejo dos insumos agrícolas, aumentando a produção e também reduzindo os impactos ambientais, são conhecidas como Agricultura de Precisão. Neste cenário a Agricultura de Precisão tem se destacado como uma nova ferramenta disponível para os agricultores melhorarem o controle do uso dos fertilizantes com a utilização de sensores e softwares de análises dos resultados coletados, planejando as recomendações das quantidades das doses necessárias para cada área de produção. O tema Agricultura de Precisão é usado como referencia nesta dissertação e esta detalhado no capítulo 2.

## 1.1 Motivação

Dentre os diversos insumos agrícolas rotineiramente utilizados e pesquisados nos temas da Agricultura de Precisão, o nitrogênio ( $N_2$ ) é um dos que desperta maiores atenções por parte de produtores agrícolas e pesquisadores em todo o mundo. Esse interesse também é acentuado nos países em desenvolvimento devido aos custos relativamente elevados dos fertilizantes nitrogenados e da resposta variável das culturas para as quantidades deste fertilizante, sendo que o nitrogênio é também um dos fertilizantes que freqüentemente sofrem má utilização, devido à variabilidade dos processos de mineralização, lixiviação, desnitrificação e absorção pela cultura (AMARAL LUCAS RIOS DO, 2010).

O processo da mineralização do nitrogênio consiste na conversão de formas orgânicas de nitrogênio em formas inorgânicas, respectivamente (BLACK C. A, 1968) e é influenciada pelos fatores que controlam o crescimento e atividade dos microrganismos, tais como a qualidade e quantidade de resíduos culturais no solo. A imobilização que é o inverso da mineralização depende também muito do estado de atividade da biomassa microbiana do solo.

A lixiviação do nitrogênio é uma das maneiras que o nitrogênio é perdido. Apesar de presente no solo, o nitrogênio só poderá ser absorvido pelas plantas se estiver na forma solúvel. É exatamente esse nitrogênio que poderá ser perdido quando a água de chuva ou irrigação atravessa a superfície para as camadas mais profundas do solo. Thomas et al. (1973) e Muzilli (1983) atribuíram este fato à movimentação descendente da água através do solo, ocasionando a lixiviação de nitrato para as camadas mais profundas do solo.

A desnitrificação do nitrogênio é o processo que o nitrogênio volta à atmosfera em forma de gás ( $N_2$ ). Este processo ocorre através de algumas espécies de bactérias e em ambientes anaeróbico.

Diante dos possíveis problemas relatados que podem ocorrer com a má utilização do nitrogênio, o manejo adequado deste fertilizante nas áreas de produção agrícola é de grande importância para evitar o uso de quantidades acima das doses realmente necessárias. Como exemplo segundo Dias et al. (1996), em países onde é comum utilizar doses elevadas de nitrogênio nos cultivos, as leis ambientais exigem o controle dos índices de poluição da água.

No Brasil um segmento agrícola que está se destacando é a cultura da cana-de-açúcar e o aumento no interesse mundial no mercado de açúcar e álcool têm estimulado o aumento de investimentos no setor em todo o país, e segundo dados da Companhia Nacional de Abastecimento – CONAB (2010), a lavoura de cana-de-açúcar continua crescendo no Brasil. Na cultura de cana-de-açúcar existe uma grande necessidade de controle na aplicação de fertilizantes nitrogenados e as doses deste fertilizante normalmente utilizado durante as fases de desenvolvimento da cana-de-açúcar estão entre 30 a 120 kg. ha<sup>-1</sup>.

Portanto o aumento do interesse por soluções que permitem o monitoramento da quantidade de nitrogênio absorvida nas culturas de cana-de-açúcar, respeitando sua variabilidade espacial, possibilita um incremento na eficiência de uso dos fertilizantes nitrogenados, podendo aumentar a produtividade, reduzindo custos e os impactos ambientais.

O método utilizado normalmente nas culturas de cana-de-açúcar no Brasil para análise das quantidades de nutrientes no solo é o clássico, que utiliza somente uma amostra de solo por cada área de produção e este método não fornece todas as informações necessárias para melhorar a qualidade das análises e recomendações de doses dos fertilizantes propostos nos estudos de Agricultura de Precisão.

O desenvolvimento de novas pesquisas na Agricultura de Precisão despertou o interesse dos pesquisadores pelas novas técnicas de recomendações das quantidades necessárias de fertilizantes em cada área de produção agrícola, as quais permitem melhorar a qualidade da produção e a diminuição dos impactos ambientais provenientes do uso desses tipos de insumos.

Estas técnicas propostas na Agricultura de Precisão utilizam um conjunto maior de amostras de solo das áreas analisadas e a partir dos dados brutos dos resultados das análises das amostras georreferenciadas no campo realiza-se um processo estruturado de análise, a fim de permitir que os diversos atributos e fatores possam ser correlacionados gerando informações para a tomada de decisão. Estas técnicas podem ser citadas como uma robusta ferramenta, que permite o levantamento preciso das quantidades de nutrientes e propriedades químicas dos solos fornecendo as informações necessárias para a melhoria do gerenciamento dos recursos e aplicações durante as fases do cultivo.

O elevado custo dessas novas técnicas de análise de solo escala proposta nas ferramentas da Agricultura de Precisão desestimulou as empresas agrícolas que cultivam a

cana-de-açúcar; porque considerando que os parâmetros do solo não são estáticos nem homogêneos no espaço e no tempo, o número de amostras necessárias e os curtos espaços de tempo disponível para realizar as análises tornaram-se muitas vezes o fator limitante para a abordagem da variabilidade espacial do solo; especialmente em aplicações de grande escala (PLANT R. E., 2001).

Estas limitações despertaram nos pesquisadores o interesse por novas técnicas que facilitem o uso das informações das propriedades físico-químicas do solo e também ofereçam economia de recursos, porque segundo Schepers e Francis (1998), novas tecnologias desenvolvidas com o sucesso dessas pesquisas que permitam monitorar os nutrientes do solo com menor custo, rapidamente serão adotadas pelos agricultores e existe uma grande demanda na busca por soluções de novas técnicas de monitorização do solo que harmonizem a relação entre velocidade dos resultados da análise, a precisão e o custo (Shepherd e Walsh, 2002).

Como exemplo, podemos citar que segundo Schung et al. (1998), o atual método de desenvolvimento dos mapas das propriedades físico-químicas do solo, que utilizam as técnicas de grades de amostragem para coletar amostras e analisar as variações do solo, dispensa grande tempo e mão de obra, sendo um dos principais fatores limitantes para o monitoramento contínuo das propriedades do solo.

Como exemplo, podemos citar que segundo a Fundação Shunji Nishimura de Tecnologia (2011), os custos das análises em laboratório de material foliar para medir a quantidade de nitrogênio são de R\$ 36,00 por amostra e o tempo necessário para entregar os resultados é de 10 a 15 dias; no custo total da análise é necessário acrescentar o custo da coleta, armazenamento e transporte das amostras, esses custos não foram considerados nesta dissertação.

Observando este cenário exposto, que mostra uma grande preocupação em encontrar novas soluções que permitam popularizar os medidores de nitrogênio nas culturas agrícolas principalmente nas culturas de cana-de-açúcar, podemos citar que o uso de sensores ópticos vem sendo estudado por pesquisadores, como uma alternativa aos métodos tradicionais de análise das quantidades de nitrogênio.

Esta técnica utiliza as medições da refletância de comprimentos de ondas nas plantas para determinar a quantidade de nitrogênio absorvido e pode ser utilizada como uma nova

ferramenta que atende as necessidades de monitoramento contínuo das propriedades e nutrientes dos solos e plantas, oferecendo uma melhor relação entre velocidade dos resultados da análise, a precisão e o custo. Como exemplo podemos citar o uso das técnicas de medição da reflexão para obter informações sobre a bioquímica e as propriedades das folhas e da estrutura das plantas (LIANG, 2004) e também que as propriedades ópticas da reflexão dos tecidos foliares determinam os parâmetros ópticos da copa (ASNER, 1998).

Os sensores ópticos que utilizam essa tecnologia para medir as quantidades de nitrogênio absorvidas pelas plantas, parte do princípio de medir a refletância da luz solar e também a refletância de uma luz gerada por uma lâmpada especial com espectro na faixa de 700 a 1100 nm. O espectro refletido é condicionado por filtros e lentes e aplicado a sensores ópticos e a leitura das refletâncias das folhas apresentam alta correlação com as informações de absorção de nitrogênio da planta.

No entanto, os resultados das informações desses modelos de sensores aplicados em culturas de cana-de-açúcar no estágio inicial do crescimento apresentam possibilidades de falhas devido à grande parte das informações serem da refletância de palha existente no solo considerando à pequena área foliar das plantas neste estágio de crescimento.

## **1.2 Objetivo**

O principal objetivo desta dissertação é propor uma nova abordagem baseada em sistemas inteligentes aplicados à ambientes agrícolas utilizando Redes Neurais Artificiais para melhorar a precisão dos resultados das correlações das medidas de refletâncias de sensores ópticos para estimar os valores da quantidade de nitrogênio absorvida pelas plantas de cana-de-açúcar no estágio inicial de crescimento. Esta nova abordagem técnica disponibiliza uma alternativa com melhor precisão para o monitoramento e controle em tempo real das aplicações de nitrogênio nas culturas de cana-de-açúcar.

### 1.3 Estrutura da Dissertação

Para atingir os objetivos propostos, esta dissertação foi organizada em 5 capítulos, listada abaixo:

- ✓ O capítulo 1 mostra uma introdução sobre a importância da agricultura no mundo e a importância das operações de aplicação de insumos nas lavouras, principalmente os fertilizantes. Aborda também as técnicas atuais para mapear as propriedades e nutrientes do solo e das plantas, a medição do teor de nitrogênio nas plantas utilizando sensores ópticos que medem a refletância de luz e a proposta gerada pela motivação de uma abordagem baseada em sistemas inteligentes aplicados à ambientes agrícolas utilizando Redes Neurais Artificiais para o processamento em tempo real dos dados resultantes da medição do teor nitrogênio por refletância em plantas de cana-de-açúcar no estágio inicial do crescimento.
  
- ✓ O capítulo 2 apresenta as revisões sobre as pesquisas dos assuntos abordados nesta dissertação. A primeira revisão é uma abordagem sobre o tema Agricultura de Precisão. A segunda revisão mostra os assuntos relacionados ao nitrogênio nas culturas de cana-de-açúcar. A terceira revisão aborda os assuntos pesquisados sobre a espectroscopia e a aplicação desta técnica nas medições da refletância para a medição das propriedades e características das plantas. A quarta revisão detalha os sensores ópticos para identificação do teor nitrogênio utilizados nesta dissertação. A quinta revisão aborda os assuntos sobre os sistemas inteligentes aplicados à ambientes agrícolas utilizando as redes neurais artificiais e a sexta e ultima revisão aborda sobre os índices de desempenho.
  
- ✓ O capítulo 3 detalha as informações da base de dados de refletância coletadas, utilizados nessa dissertação e os métodos utilizados para processar os resultados da base de dados, detalhando os métodos de processamento para calcular as correlações das análises de laboratório referenciadas com uma

calibração versus a resposta das refletâncias dos comprimentos de onda analisados.

- ✓ O capítulo 4 trata o resultado das simulações com os algoritmos de testes que tem como objetivo melhorar a interpretação da base de dados de refletância e como consequência os resultados das correlações com o teor de nitrogênio absorvido pelas plantas.
- ✓ O capítulo 5 descreve as conclusões deste trabalho e as recomendações para trabalhos futuros.
- ✓ O apêndice apresenta algumas informações adicionais sobre Redes Neurais Artificiais, amostra das planilhas com as bases de dados e os programas desenvolvidos em MATLAB, que foram utilizados na dissertação.

## 2 INVESTIGAÇÃO TÉCNICO-CIENTÍFICA

### 2.1 Agricultura de Precisão

O sistema de controle da produção agrícola utilizado atualmente é basicamente o gerenciamento de forma homogênea das grandes áreas de produção, aplicando o conceito de valores médios necessários para a aplicação dos insumos, fertilizantes e defensivos para toda a área, atendendo apenas as necessidades médias e desprezando, desta forma, os valores de necessidades específicas de cada parte do campo, causando como resultado uma lavoura com produtividade não uniforme.

Os desenvolvimentos das tecnologias GPS (*Global Positioning System* ou Sistema de Posicionamento Global) e dos sistemas de informações permitiram o avanço das pesquisas de novas ferramentas para o gerenciamento da produção agrícola com objetivo de reduzir as perdas e o impacto ambiental. Essas novas ferramentas de controle da produção agrícola ficaram popularmente conhecidas com Agricultura de Precisão e como exemplo podemos citar que o termo Agricultura de Precisão (AP) engloba o uso de tecnologias atuais para o manejo de solo, insumos culturais, de modo adequado às variações espaciais e temporais em fatores que afetam a produtividade das mesmas (EMBRAPA, 1997).

A Agricultura de Precisão tem como principal objetivo aumentar a eficiência com base no manejo diferenciado de áreas na agricultura utilizando as informações reais e com comprovação estatística da precisão e se complementa com decisões exatas, oferecendo uma nova maneira de gerir um campo produtivo metro a metro, levando em conta o fato de que cada pedaço da fazenda tem propriedades diferentes. Esta tecnologia não consiste simplesmente na habilidade em aplicar tratamentos que variam de local para local, porém, ela deve ser considerada com a habilidade em monitorar e acessar a atividade agrícola, precisamente em um nível local, tanto que as técnicas de Agricultura de Precisão devem ser compreendidas como uma forma de manejo sustentável, na qual as mudanças ocorrem sem prejuízos para as reservas naturais, ao mesmo tempo em que os danos ao meio ambiente são minimizados. Além de útil à Agricultura de Precisão, esta definição engloba a idéia de compromisso no uso da terra, relativamente às gerações futuras (TSCHIEDEL e FERREIRA, 2002)

Conforme citado por Antuniassi (1998), o gerenciamento do sistema produtivo através do mapeamento detalhado dos fatores de produção e o controle da aplicação localizada de insumos são os princípios básicos da Agricultura de Precisão e os itens que mais se destacam nas técnicas de Agricultura de Precisão são:

- melhorar os rendimentos de colheita e lucros;
- fornecer informações para tomar decisões de manejo mais embasadas;
- prover registros detalhados e úteis;
- reduzir custos dos insumos;
- reduzir a poluição.

A Figura 1 ilustra o ciclo completo de gerenciamento da produção agrícola utilizando as técnicas de Agricultura de Precisão. O gráfico representado pelo círculo maior mostra os ciclos de planejamento e manejo das fases da produção agrícola. Observando este gráfico é possível observar que o ciclo da produção agrícola começa com a análise das informações de colheita e das informações coletadas durante as fases de preparação do solo, plantio, adubação e pulverização de insumos.

O círculo menor no centro da figura representa o gráfico do ciclo das informações durante todas as fases de produção agrícola. A primeira fase processa a análise das informações para tomada das decisões. A segunda fase mostra a transferência de dados para os equipamentos de preparação do solo, plantio, adubação e pulverização. A terceira fase coleta os dados do resultado das operações agrícolas durante a aplicação dos insumos, para servir como base de dados na tomada de decisões para o próximo ciclo de produção agrícola. A quarta fase coleta os resultados finais da colheita que serão utilizados junto com os resultados coletados na terceira fase.



Figura 1 - Ciclo das tecnologias e máquinas envolvidas na Agricultura de Precisão  
 Fonte: AGCO (2005)

## 2.2 Nitrogênio na Cultura da Cana-de-açúcar

O nitrogênio é um nutriente absorvido em grandes quantidades pelas plantas. Sua absorção proporciona grandes incrementos no crescimento vegetativo, com folhas verdes mais intensas. Ele também atua como regulador de diversos processos do metabolismo vegetal, possuindo considerável influência na utilização de outros nutrientes tais como o potássio e o fósforo (CANTARELLA et al. 2007) e a utilização correta das quantidades de nitrogênio e também dos demais nutrientes necessários orientadas por métodos de análise das quantidades de nutrientes nos solos e ou plantas, ajudam a acelerar o desenvolvimento das culturas (TISDALE et al. 1993).

Os manejos incorretos dos insumos nas lavouras causam grandes perdas econômicas para toda a cadeia produtiva de alimentos e as aplicações de fertilizantes nitrogenados com doses acima do necessário para as culturas geram perdas econômicas e um excesso que é perdido por deslocamento superficial e pela lixiviação, aumentando a chance de contaminar ecossistemas aquáticos e o lençol freático (WOOD et al. 1993).

A capacidade de resposta da cana-de-açúcar ao nitrogênio apresenta-se como variável importantíssima a ser considerada na recomendação e aplicação de nitrogênio durante a safra, permitindo o estudo de estratégias no manejo deste insumo para melhorar a produção (AMARAL LUCAS RIOS DO, 2010).

Segundo informações do Instituto Agrônomo de Campinas - IAC, as recomendações de adubação para cana-de-açúcar indicam aplicações de 30 kg. ha<sup>-1</sup> de nitrogênio no plantio e 30 a 60 kg. ha<sup>-1</sup> de nitrogênio em cobertura nos 30 a 60 dias após o plantio. Para cana-soca a recomendação é de 60 a 120 kg. ha<sup>-1</sup> de nitrogênio, dependendo da produtividade esperada.

Com o aumento do interesse das empresas agrícolas por novas tecnologias para monitorar a quantidade de nitrogênio disponível nas plantas, surgiram novas pesquisas de técnicas para medir a quantidade de nitrogênio das plantas com maior rapidez e menor custo, sendo que uma das propostas para medir a quantidade de nitrogênio absorvido pelas plantas é através da medição dos tecidos vegetais, mas para a cultura da cana-de-açúcar esta técnica de medição ainda não se encontra consolidada (CANTARELLA, 1998).

Uma solução equivalente para medições da quantidade de nitrogênio absorvido pelas plantas diretamente é através da utilização de medidores portáteis de clorofila nas folhas, utilizando técnicas de refletância de luz e a correlação estudada entre o teor de clorofila da folha e o teor de nitrogênio na planta indicam que é possível utilizar este processo para medir o teor de nitrogênio (SCHADCHINA; DMITRIEVA, 1995).

Uma solução alternativa é o uso dos equipamentos de sensoriamento remoto, seja por meio de imagens de fotos de satélites ou local através de sensores de refletância montados em dispositivos acoplados nas máquinas que normalmente são utilizadas para mecanização das culturas. Essa solução utiliza o princípio que a quantidade de nitrogênio altera as propriedades das ondas refletidas nas folhas (BLACKMER et al. 1996), sendo que esta solução propõe um modo para simplificar a medição de grandes áreas de culturas agrícolas (SOLARI, 2006).

Diante do exposto acima, podemos concluir que a utilização de soluções com sensores ópticos que medem a refletância das folhas das plantas disponibiliza uma nova técnica de estimar a quantidade de nitrogênio das culturas e melhorar a recomendação de aplicação de fertilizantes em tempo real, diminuindo as perdas por falta ou excesso na aplicação.

### 2.3 Espectroscopia

Segundo Riffel R. A. (2005), a espectroscopia é o estudo da luz através de suas componentes, que aparecem quando a luz passa através de um prisma ou de uma rede de difração e quase todas as informações sobre as propriedades físicas de um objeto podem ser obtidas a partir de seu espectro e a medida das características de refletância de um determinado material utilizando sensores ópticos constitui-se em uma técnica rápida e não-destrutiva para avaliar suas propriedades (ADAMCHUK et al. 2008).

Podemos citar também que Segundo Steffen C. A. (2009), um objeto exposto à radiação pode refletir ou absorver ou mesmo transmitir a radiação (no caso de objetos transparentes). Em geral a parte absorvida é transformada em calor ou em algum outro tipo de energia e a parte refletida se espalha pelo espaço. A refletância indica o fator que mede a quantidade de energia que reflete no objeto, a absorbância indica a capacidade de absorver energia radiante do objeto e a transmitância indica a capacidade de transmitir energia radiante que atravessa o objeto.

Medindo a refletância de um objeto exposto a diversos tipo de radiação que compõe o espectro eletromagnético é possível perceber que a refletância pode ser diferente para cada tipo de comprimento de onda. Esta diferença de resposta denominada assinatura espectral, depende das propriedades de refletância absorbância e transmitância de cada objeto (SANTOS, 1999).

A Figura 2 mostra a assinatura espectral de três objetos que recebem quatro comprimentos de onda. A curva **a** mostra a assinatura espectral da folha verde onde pode ser observado que a elevada refletância na banda infravermelha esta relacionada com os aspectos fisiológicos da folha e as variações estão relacionadas com o conteúdo de água na estrutura celular superficial e pode ser um forte indicador de sua natureza, estágio de desenvolvimento, sanidade, etc. e a aparência verde esta relacionada com a maior refletância na banda verde (G). A curva **b** mostra a assinatura espectral de uma folha seca com pouca intensidade de refletância na banda infravermelha. A assinatura espectral de uma amostra de solo contendo ferro e pouca matéria orgânica é apresentada na curva **c**.

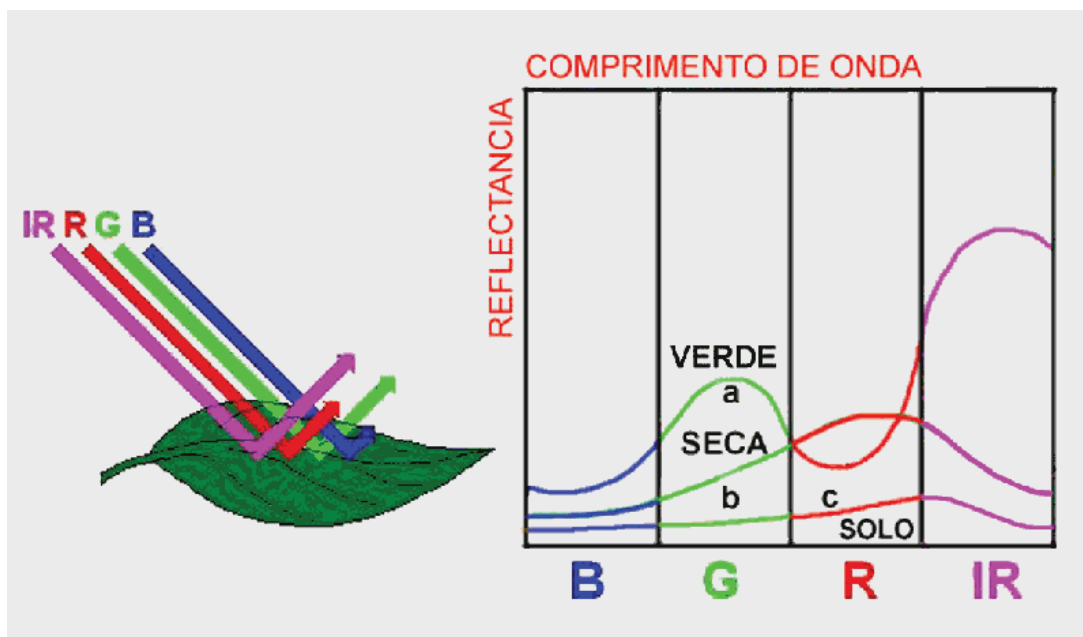


Figura 2 - Gráfico da assinatura espectral  
 Fonte: site agr.feis.unesp.br (2009)

A radiação solar que interage com os tecidos das plantas ou com a copa das plantas geram três componentes espectrais. Uma componente é a luz refletida, outra componente é a luz absorvida e após é transmitida e a última componente é a luz que atravessa as folhas e não tem refletância imediata. As características espectrais dos três componentes podem ser citadas como o nível de absorção foliar e espalhamento e representam algumas características das plantas (NARENDA S. G., 2003).

Experimentos mostraram que a quantidade de refletância das folhas de plantas na faixa visível do espectro entre 400 a 700 nm é baixa, devido à grande absorção pelos pigmentos fotossintéticos foliares, enquanto na faixa do infravermelho próximo entre 700 a 1100 nm a refletância é alta devido à baixa absorção de luz pelo tecido do mesófilo e na faixa de ondas curtas de infravermelho entre 1000 a 2500 nm, a refletância é fortemente afetada pela quantidade de água nos tecidos vegetais (CURRAN, 1989). Estes experimentos comprovam a possibilidade de utilizar os princípios da refletância de comprimentos de ondas nas plantas, para estimar o teor de nitrogênio absorvido pelas mesmas.

A cobertura vegetal com estresse hídrico tende a absorver menos radiação solar, aumentando sua refletância no espectro visível e a absorver mais no infravermelho próximo,

decrecendo a diferença entre as duas refletâncias quanto maior o nível de estresse hídrico da cobertura vegetal. As alterações nas amplitudes refletidas de cada comprimento de onda permitem a utilização dos sensores de refletância para medir as características das plantas.

## 2.4 Sensor Óptico para Identificação do Teor de Nitrogênio.

O avanço das pesquisas dos métodos que utilizam sensores ópticos para a determinação da quantidade de nitrogênio das plantas em tempo real sem contato e de maneira não destrutiva tem avançado e como consequência também aumentou o interesse da utilização desta nova tecnologia na agricultura.

Os sensores ópticos que apresentam os melhores resultados no uso em ambientes agrícolas para a determinação da quantidade de nitrogênio das plantas, em geral utilizam o princípio da espectroscopia e o princípio do funcionamento se baseia no processamento das correlações das proporções de radiação refletida pelas plantas em diversos comprimentos de ondas para determinar a quantidade de nitrogênio absorvido.

A empresa *YARA International ASA*, sediada na Noruega, disponibiliza dentre seu portfólio de produtos, sensores ópticos desenvolvidos para aplicações nos ambientes agrícolas, indicados para determinar o teor de nitrogênio absorvido pelas plantas, utilizando as técnicas de medição de refletâncias de comprimentos de ondas. Os dois modelos de sensores ópticos N-SENSOR e N-SENSOR ALS (*Active System Light* ou Sistema de Luz Ativa) são indicados para operações em máquinas agrícolas que aplicam insumos inclusive o nitrogênio, para medir e controlar a quantidade de nitrogênio que esta sendo aplicada (Figuras 3 e 4).

Segundo o manual de operação do sensor N-Sensor (YARA, 2004), as principais diferenças entre os sensores ópticos N-SENSOR ALS e o modelo anterior N-SENSOR são os ajustes das faixas de comprimentos de ondas dos sensores ópticos e os períodos diários possíveis de uso dos equipamentos no campo. Sobre o período de trabalho indicado pelo fabricante, O sensor óptico N-SENSOR que utiliza a incidência da luz do dia para medir a reflexão nas plantas, tem o período de uso limitando durante o dia com uma elevação mínima de 25 graus do sol em relação ao horizonte e o sensor óptico N-SENSOR ALS, que tem uma fonte de luz para iluminar a área de leitura das refletâncias das plantas que estão sendo medidas, permitindo seu uso em qualquer hora do dia e da noite.



Figura 3 - N-Sensor Yara  
 Fonte: site effizientduengen.de (2011)



Figura 4 - N-Sensor ALS Yara  
 Fonte: site: w3. ufsm.br (2011)

Durante o funcionamento dos sensores ópticos, os valores de leitura das refletâncias podem ser armazenados em arquivos para posterior análise e também podem ser utilizados para controlar em tempo real os equipamentos de aplicação de nitrogênio nas plantas. O recurso disponível neste equipamento para aplicar em dose variável a quantidade de nitrogênio nas plantas contribui diretamente na redução de custos da produção agrícola e na redução dos impactos ambientais.

Uma lâmpada especial que emite radiação na faixa do infravermelho (600 a 1100 nm) tem o foco ajustado por lentes e filtros ópticos e recebe uma modulação de 10 Hz. através

do sistema de controle para 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 e após o acondicionamento óptico a radiação atinge os sensores ópticos ajustados para a faixa do infravermelho próximo. São 4 sensores de leitura da refletância: o primeiro sensor esta ajustado para a faixa de 730 nm, o segundo sensor ajustado para a faixa de 760 nm, o terceiro sensor ajustado para a faixa de 960 nm e o quarto sensor ajustado para a faixa de 900 nm. Os sensores ópticos fazem as medições das radiações refletidas nas plantas sincronizadas com a comutação da lâmpada, obtendo assim as medições com e sem as refletâncias das ondas geradas pela iluminação da lâmpada. A temperatura ambiente dentro do equipamento é monitorada e registrada para ajustes do sistema de leitura das refletâncias e os processamentos das informações das medições dos sensores determinam um índice de refletância que pode ser correlacionado com as medidas do teor de nitrogênio absorvido pelas plantas (figura 5).

O Sensor óptico N-SENSOR ALS completo é composto por 2 conjuntos de leitura como citado anteriormente, um é montado do lado esquerdo e o outro do lado direito do equipamento para as leituras de refletância. O conjunto completo pode ser montado em máquinas agrícola ou veículos que ao se deslocarem nas áreas plantadas medem os valores de nitrogênio disponível nas plantas.

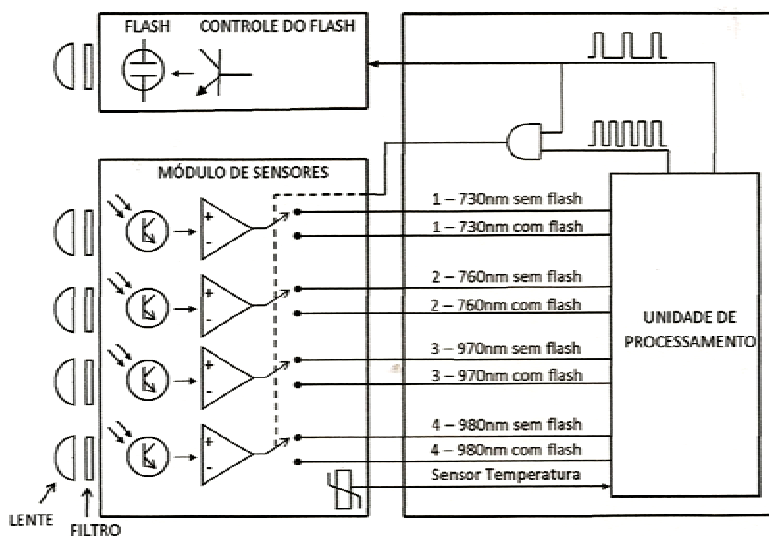


Figura 5 - Diagrama Esquemático do N-Sensor ALS

Fonte: adaptado de informações do manual técnico do sensor N-Sensor ALS YARA

Como exemplo pode-se citar a Figura 6, que mostra o gráfico de refletância medidas no trigo em 1994 com 3 valores de nitrogênio aplicado (60, 120 e 200 kg. ha<sup>-1</sup>). O ponto **A** mostra a faixa visível na cor verde e a redução da reflexão do trigo com o aumento da taxa de nitrogênio aplicado, devido ao aumento da clorofila presente nas folhas. O ponto **B** mostra o aumento da amplitude com o aumento da taxa de nitrogênio aplicado, devido ao aumento da biomassa das plantas que receberam mais nitrogênio e a faixa de radiação da transição de amplitudes com o aumento da sensibilidade esta situada entre 730 e 760 nm. Estes comprimentos de ondas podem ser medidos pelos sensores 1 e 2 do sensor óptico descrito anteriormente.

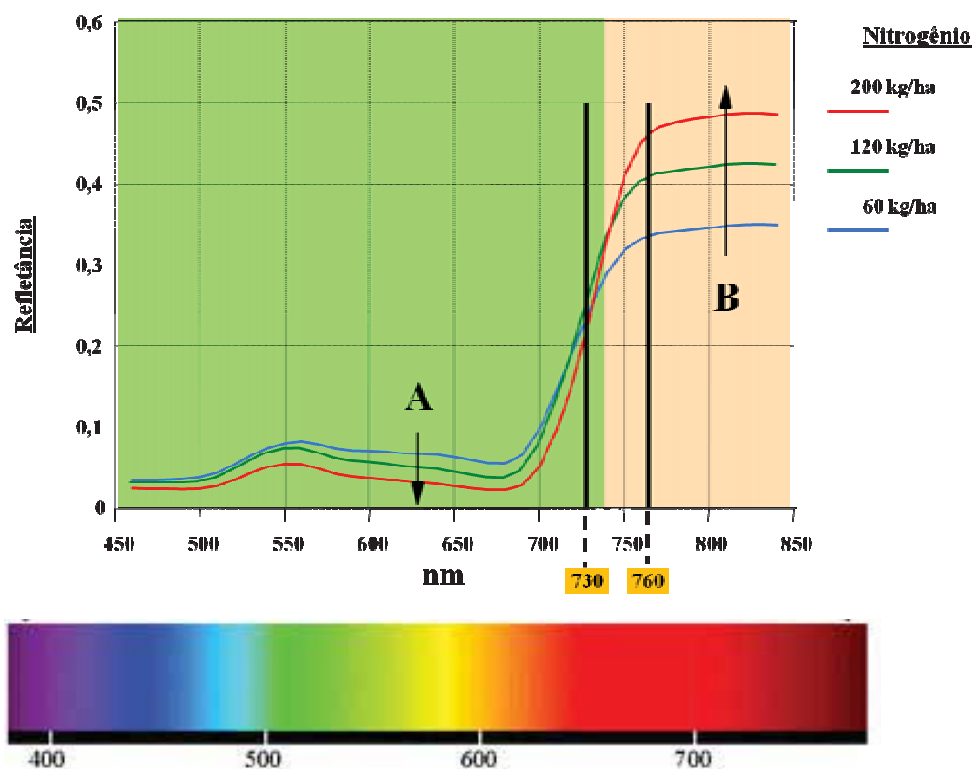


Figura 6 - Espectro de refletâncias do trigo versus nitrogênio com N-Sensor ALS  
Fonte: adaptado do site [www.njf.nu](http://www.njf.nu) - Lantbruk (2011)

O sensor óptico descrito anteriormente mede as reflexões dos comprimentos de onda em uma área de aproximadamente 3 metros de largura de cada lado do sensor. A forma

geométrica da leitura da refletância é de uma elipse. Nas Figuras 7 e 8 estão ilustradas as áreas de leitura das radiações refletidas pelas plantas. A medida **A** é aproximadamente 3 metros e a medida **B** é aproximadamente 24 metros.




Figura 7 - Vista superior da área de leitura da refletância do N-Sensor ALS  
Fonte: site Agri Con - Basic technical information. mht (2011)




Figura 8 - Vista traseira da área de leitura da refletância do N-Sensor ALS  
Fonte: site topconpa.com. br (2011)

O equipamento N-SENSOR ALS completo é composto de uma unidade de leitura com sensores ópticos, uma unidade de processamento e controle com display, teclas e interfaces USB e serial, cabos e suportes. O equipamento permite a instalação de um receptor GPS através da interface serial e os dados de latitude, longitude, altitude e da qualidade do sinal GPS podem ser agrupados aos dados de leitura do nitrogênio das plantas, disponibilizando dados georreferenciados das leituras de nitrogênio. A interface serial também pode ser utilizada para comunicação com o controlador da máquina que aplica o insumo, para o controle em tempo real da dose que esta sendo aplicada (Figura 9).

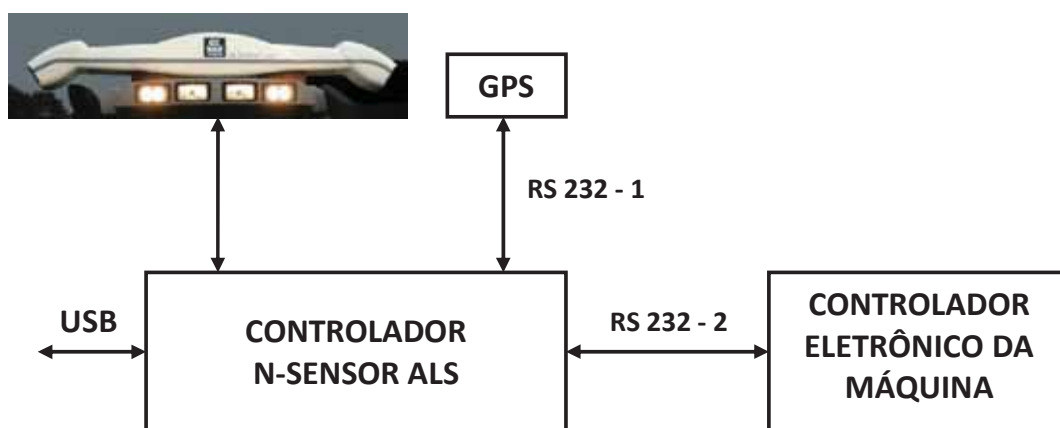


Figura 9 - Diagrama Esquemático das interfaces do N-Sensor ALS  
Fonte: adaptado de informações do manual técnico do sensor N-Sensor ALS YARA.

## 2.5 Sistemas Inteligentes Aplicados à Ambientes Agrícolas

Um sistema baseado em Redes Neurais Artificiais (RNA) que utiliza a computação numérica para o aprendizado e o posterior reconhecimento de padrões aplicados em métodos de inteligência computacional é considerada como uma poderosa ferramenta para os sistemas inteligentes.

A interação entre os valores de saída e o ajuste dos valores dos pesos demonstra uma capacidade de aprender através de exemplos (padrões), e de generalizar (fornecer respostas adequadas para dados que não estão no conjunto de exemplos) é o principal atrativo das redes neurais artificiais (BRAGA et al., 2000). Uma rede neural possibilita com isso, solucionar problemas complexos sem a necessidade de definições explícitas entre dados de entradas e saídas. Existem diversas arquiteturas de rede e técnicas de treinamento, bem como várias funções de ativação da rede, mudando apenas o modo de aprendizado.

A rede neural *Perceptron* Multicamadas (PMC) é uma das redes que permite a solução de problemas onde os conjuntos são não separáveis de forma linear, porque é possível adicionar camadas ocultas no sistema de processamento e usar uma função de ativação não linear, geralmente a sigmóide.

Um dos métodos de aprendizagem mais difundidos para a rede PMC é o *backpropagation*. Este método funciona pelo aprendizado de padrões que são inseridos e processados por todas as camadas configuradas na rede, gerando uma resposta no neurônio de saída, que é comparado com a resposta desejada e o erro, depois de calculado é retro propagado da camada de saída para a camada de entrada e para cada ciclo de retro propagação do erro, os pesos são ajustados e o processamento é repetido até obter o erro mínimo desejado. O método *backpropagation* é computacionalmente lento e um método que é consideravelmente rápido para realizar o sistema de aprendizado é o Levenberg-Marquardt.

Segundo Ferrari (2006), a rede neural que utiliza o modelo de Função de Base Radial (RBF) é composta pela camada de saída e pela camada oculta de neurônios. Cada neurônio da camada de saída representa a soma ponderada das saídas da camada oculta e os neurônios da camada oculta formam uma combinação linear das funções básicas que produz uma resposta local de acordo com os sinais de entrada.

Como exemplos das aplicações das redes neurais artificiais em ambientes agrícolas, podemos citar alguns exemplos que estão listados a seguir, iniciando com uma comparação dos resultados para o estudo do desempenho de classificadores estatísticos com classificadores por redes neurais utilizando dados simulados foi realizada por Huang e Lippmann (1987). A conclusão dos estudos mostrou que os classificadores por redes neurais apresentaram desempenho igual ou superior aos classificadores estatísticos. Também foi possível observar que o desempenho dos classificadores por redes neurais foi superior quando a distribuição dos dados se afastou da normalidade ou havia a presença de dados discrepantes.

Mengbo Li e Yost (2000) desenvolveram um modelo computacional com técnicas da inteligência artificial com redes neurais, para otimizar o manejo de nitrogênio na cultura do milho. O modelo tinha como principais objetivos minimizar o nitrato lixiviado e maximizar a produção e foi testado em simuladores. Concluíram que o modelo encontrou uma solução ótima de manejo do nitrogênio para cultura de milho. Apesar dos resultados promissores encontrados com dados simulados, os autores recomendam que o modelo seja futuramente testado com dados experimentais.

Tumbo et al. (2002) utilizou as técnicas de inteligência artificial com redes neurais para desenvolver e comparar os resultados de três modelos para estimar a concentração de clorofila em plantas de milho. Concluiu que o modelo com base em redes neurais estimou valores com um coeficiente de determinação de 0,91, enquanto que, os modelos de regressão com base nos índices de vegetação não apresentaram bons resultados ( $R^2 = 0,56$  e  $0,80$  respectivamente) e a aplicação de redes neurais artificiais no processamento de bases de dados com algumas características de solos, oferecendo uma melhor otimização na classificação final dos solos foi utilizado por Nagaoka et al. (2005).

Outros exemplos podem ser citados e demonstram através dos seus conteúdos e resultados que os algoritmos de processamento baseados nas redes neurais artificiais vêm sendo aplicados nas mais diversas áreas como base para sistemas inteligentes, tais como reconhecimento de padrões (WIDROW, 1990), processamento e interpretação de imagens aplicados em sistemas de controle (NARENDRA, 1996), algoritmos específicos para robótica (VAN DER SMAGT; KROSE, 1991) e identificação de sistemas (NARENDRA; PARTHASARATHY, 1990). Na área agrícola, ambiental e no controle da aplicação de

insumos, podem-se citar os trabalhos desenvolvidos por Hashimoto et al. (2001), Ulson et al. (2000), Ulson et al. (2001), e Ulson et. Al. (2002).

Um aprofundamento sobre o tema pode ser visto no Anexo desta dissertação.

## 2.6 Índices de Desempenho

Os índices de desempenho são ferramentas que utilizam índices estatísticos e pode ser aplicado na avaliação dos resultados de experimentos. Alguns índices estatísticos foram utilizados para avaliar o desempenho dos resultados dos sistemas inteligentes utilizando Redes Neurais desenvolvidos nesta dissertação e descritos a seguir.

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 pela rede neural e os valores reais medidos em laboratório, sendo calculado por:

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

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.

Outro índice utilizado nesta dissertação para a análise de desempenho é o erro quadrático médio (RMSE – *root mean square error*). 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 RMSE, melhor é a qualidade da previsão feita pela rede neural. O RMSE é calculado da seguinte forma:

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

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

Os melhores resultados dos experimentos são os que apresentam o índice de determinação ( $R^2$ ) mais próximo de 1 e o menor índice RMSE.

### 3 MATERIAIS E MÉTODOS

Os materiais e equipamentos que foram utilizados nesta dissertação e os métodos aplicados nos ensaios da base de dados coletados durante os ensaios, os resultados e as conclusões finais estão descritos neste capítulo.

#### 3.1 Equipamentos

Relação dos equipamentos utilizados durante o desenvolvimento desta dissertação:

- ✓ 01 sensor óptico N-Sensor ASL – *Yara International ASA*;
- ✓ 01 Automotriz Uniport NPK – Jacto S/A;
- ✓ Amostras de material foliar georreferenciadas para análise do teor de nitrogênio.
- ✓ Computador *HP COMPAQ 6530b*, para processamento de dados;
- ✓ Impressora *HP C4480*, para imprimir resultados;
- ✓ Software MATLAB 2010.

A usina de açúcar e álcool Santa Fé em Nova Europa-SP, foi escolhida pela equipe de engenharia da empresa Máquinas Agrícola Jacto S/A como local de testes funcionais do equipamento automotriz Uniport NPK montado com o sensor óptico N-Sensor ALS, durante uma demonstração comercial do equipamento.

Segundo informações do site da empresa Máquinas Agrícolas Jactos S/A, (2011) o equipamento Uniport NPK é montado com motor diesel 6 cilindros, o peso total da máquina vazia é de 9900 kg., com capacidade de carga de adubo de 3000 kg, 13,5 metros de largura da faixa de aplicação e velocidade de trabalho indicada de 18 Km/h. O sistema de aplicação de adubo é pneumático (Figura 10).



Figura 10 - Uniport NPK  
Fonte: Máquinas Agrícolas Jacto S/A (2007)

### 3.2 Ferramentas Computacionais

O software MATLAB 2010 foi a principal ferramenta de apoio para os desenvolvimentos e testes dos algoritmos de inteligência computacional utilizando redes neurais.

### 3.3 Base de Dados

A base de dados utilizada nesta dissertação foi coletada durante testes funcionais e demonstração técnica da máquina Uniport NPK montada com o sensor óptico na usina Santa Fé localizada em Nova Europa, estado de São Paulo e o talhão escolhido foi indicado pelos técnicos da usina, com plantas novas de cana-de-açúcar e aproximadamente 20 a 35 cm de altura, para verificar a precisão do equipamento Uniport NPK e do sensor óptico nas aplicações de fertilizantes em plantas novas com pouca área foliar. Os testes foram conduzidos pela equipe de engenharia da empresa Jacto, e os resultados serviram de referência para futuras indicações técnicas do equipamento e base de dados comparativos para novos estudos.

Uma grade com 121 pontos de referências para coleta de amostras foi ajustado no desenho do talhão escolhido e o sensor óptico foi utilizado junto com a máquina Uniport NPK para encontrar os locais e marcar com pequenas estacas, para a retirada de amostras de material foliar depois da leitura do sensor óptico.

Após os procedimentos de ajustes e calibração do sensor óptico, um operador dirigiu a máquina no talhão com o sensor de nitrogênio coletando informações da quantidade de nitrogênio medida referenciadas por um equipamento de GPS.

O arquivo gerado com as informações das leituras do sensor e do equipamento GPS foi disponibilizado e o material foliar foi enviado para testes em laboratório, para medir a quantidade de nitrogênio.

Após o ensaio o sensor óptico foi desmontado da máquina, permitindo a continuação da demonstração técnica no equipamento, que aplicou nitrogênio no mesmo talhão que foi realizado as medições.

A Figura 11 apresenta a máquina Uniport NPK montada com o sensor óptico e nas Figuras 12, 13 e 14 é possível observar detalhes da instalação do referido sensor. O talhão que

foi utilizado para o ensaio é apresentado na Figura 15 e a Figura 16 apresenta as coordenadas dos pontos que foram retirados as amostras de material foliar no talhão.



Figura 11 - Uniport NPK montado com o sensor N-Sensor ALS  
Fonte: Máquinas Agrícolas Jacto S/A (2009)



Figura 12 - Vista traseira da montagem do N-Sensor ALS no Uniport NPK  
Fonte: Máquinas Agrícolas Jacto S/A (2009)



Figura 13 - Vista lateral da montagem do N-Sensor ALS no Uniport NPK  
Fonte: Máquinas Agrícolas Jacto S/A (2009)



Figura 14 - Vista frontal da montagem do N-Sensor ALS no Uniport NPK  
Fonte: Máquinas Agrícolas Jacto S/A (2009)



Figura 15 - Foto do talhão utilizado no ensaio com o sensor óptico  
Fonte: Máquinas Agrícolas Jacto S/A (2009)



Figura 16 - Gráfico dos pontos georreferenciados do talhão utilizado no ensaio.

As informações da base de dados foram ajustadas na forma de planilha Microsoft Excel pela equipe da Jacto responsável pelo desenvolvimento e testes do Uniport NPK e disponibilizada para ser utilizada nesta dissertação. A planilha completa com todos os dados coletados no ensaio recebeu o nome Bd121 e outra planilha que foi gerada com os dados da planilha Bd121, eliminando manualmente 21 dados que apresentaram saturação das medições de refletâncias com o sensor óptico para valores de nitrogênio maiores que 40 kg. ha<sup>-1</sup>, recebeu o nome Bd100 e não foi investigado o motivo da saturação das medições nessa dissertação. Os dados das duas planilhas estão no Apêndice dessa dissertação. A Tabela 1 apresenta a descrição das colunas dos dados gerais e das informações do sistema GPS e a Tabela 2 apresenta a descrição das colunas de dados de refletâncias disponíveis na planilha referentes ao ensaio com o sensor óptico e estas informações do formato e tipo de dados foram obtidas do manual de operação Yara *Operation Manual for the Yara N-Sensor Software Release 3.300* (2010).

Tabela 1 - Descrição das informações do sistema GPS da base de dados

<b>Nome da coluna</b>	<b>Formato</b>	<b>Descrição</b>
Seqüência	números	Seqüência numérica.
Latitude	graus	Latitude do GPS.
Longitude	graus	Longitude do GPS.
Nitrogênio Lab. kg. ha-1	kg. ha-1	Valor de quilos por hectare das amostras de material foliar analisada em laboratório.
Altitude	metros	Altitude do GPS.
Quantidade Satélites GPS	números	Quantidade de Satélites GPS disponível.
Qualidade Sinal GPS	números	1 = sinal GPS    2 = sinal DGPS.
Validade Sinal GPS	números	< 1 = sinal GPS valido.

Tabela 2 - Descrição das informações de refletâncias da base de dados

<b>Nome da coluna</b>	<b>Formato</b>	<b>Descrição</b>
S1	números	Refletância processada final
R21dL	números	Refletância 730 nm sem iluminação da lâmpada Lado Esquerdo
R12dL	números	Refletância 760 nm sem iluminação da lâmpada Lado Esquerdo
R21dL	números	Refletância 970 nm sem iluminação da lâmpada Lado Esquerdo
R22dL	números	Refletância 900 nm sem iluminação da lâmpada Lado Esquerdo
R11sL	números	Refletância 730 nm com iluminação da lâmpada Lado Esquerdo
R12sL	números	Refletância 760 nm com iluminação da lâmpada Lado Esquerdo
R21sL	números	Refletância 970 nm com iluminação da lâmpada Lado Esquerdo
R22sL	números	Refletância 900 nm com iluminação da lâmpada Lado Esquerdo
R11dR	números	Refletância 730 nm sem iluminação da lâmpada Lado Direito
R12dR	números	Refletância 760 nm sem iluminação da lâmpada Lado Direito
R21dR	números	Refletância 970 nm sem iluminação da lâmpada Lado Esquerdo
R22dR	números	Refletância 900 nm sem iluminação da lâmpada Lado Direito
R11sR	números	Refletância 730 nm com iluminação da lâmpada Lado Direito
R12sR	números	Refletância 760 nm com iluminação da lâmpada Lado Direito
R21sR	números	Refletância 970 nm com iluminação da lâmpada Lado Direito
R22sR	números	Refletância 900 nm com iluminação da lâmpada Lado Direito

Na Figura 17 é apresentada a correlação dos 121 dados da planilha Bd121 com as leituras de refletâncias do sensor óptico comparado com os valores de nitrogênio medidos nas amostras de material foliar e na Figura 18 a mesma correlação dos 100 dados da planilha

Bd100. A escala dos dados S1 é ajustada internamente no sensor óptico e representa a intensidade das refletâncias. A Tabela 3 mostra os valores de correlação e o índice de determinação  $R^2$  dos dados disponíveis na base de dados Bd121 e Bd100.




Figura 17 - Correlação da refletância S1 com nitrogênio  $\text{kg. ha}^{-1}$  Laboratório - Bd121




Figura 18 - Correlação da refletância S1 com nitrogênio kg. ha<sup>-1</sup> Laboratório - Bd100

Tabela 3- Descrição das correlações das bases de dados Bd121 e Bd100

Base de dados	Quantidade de dados	RMSE kg.ha	R <sup>2</sup>
Bd121	121	13,70	0,69
Bd100	100	4,26	0,84

### 3.4 Metodologia

Para atingir os objetivos propostos na seção 1.2, foram desenvolvidas metodologias de testes com a base de dados Bd121 e Bd100 do ensaio citado na seção 3.3. Dois conjuntos de métodos foram desenvolvidos com algoritmos de processamento baseados em dois tipos de redes neurais com o objetivo de encontrar a correlação entre os 16 valores de refletâncias coletados pelo sensor óptico e os resultados da análise de nitrogênio do material foliar coletado. Um conjunto utilizou algoritmos baseados na rede neural artificial *Perceptron Multicamadas* (PMC) e outro conjunto de métodos utilizou a Função de Base Radial (RBF – *Radial Base Function*). Tais arquiteturas de redes neurais são as mais adequadas para o mapeamento de problemas de estimação e reconhecimento de padrões.

Os métodos do conjunto que utilizou os algoritmos baseados em redes PMC foram planejados e implementados com um neurônio na camada de saída e a função de ativação linear saturada. Foram utilizadas uma duas e três camadas ocultas com cinco, dez, quinze e vinte neurônios em cada camada. Para as camadas ocultas foi escolhida a função de ativação tangente hiperbólica sigmoidal. No treinamento da rede PMC foi utilizado o algoritmo de aprendizagem *backpropagation*, o valor de 150 para o número máximo de épocas, e 6 valores para o valor do erro quadrático médio no aprendizado (EQM) conforme descritos:  $1 e^{-2}$ ,  $9 e^{-3}$ ,  $7 e^{-3}$ ,  $5 e^{-3}$ ,  $3 e^{-3}$  e  $1 e^{-3}$ . Para cada valor atingido do erro médio quadrático, foi executada a simulação da rede com os valores de aprendizado e de validação.

No conjunto dos métodos que utilizaram os algoritmos baseados nas redes RBF foi utilizado um neurônio na camada de saída e a função de ativação linear saturada e nas camadas ocultas a função de ativação Gaussiana de base radial. Foi utilizado o valor 150 para o número máximo de neurônios, e 6 valores para o valor do erro quadrático médio no

aprendizado conforme descritos:  $1 e^{-2}$ ,  $9 e^{-3}$ ,  $7 e^{-3}$ ,  $5 e^{-3}$ ,  $3 e^{-3}$  e  $1 e^{-3}$ . Para cada valor atingido do erro médio quadrático, foi executada a simulação da rede com os valores de aprendizado e de validação.

As descrições detalhadas das metodologias estão apresentadas a seguir e as diferenças das quantidades de neurônios e das quantidades de camadas ocultas dos métodos planejados com as redes PMC e as diferenças dos valores do índice spread nos métodos planejados com as redes RBF se devem pela tentativa de atingir uma taxa de precisão melhor.

Os algoritmos foram desenvolvidos e simulados utilizando a linguagem de programação M e o MATLAB 2010 e estão no Anexo desta dissertação.

### 3.4.1 Descrição dos métodos utilizados nos ensaios.

As tabelas 4 e 5 apresentam as configurações das redes neurais e a base de dados utilizados nos ensaios dos métodos 1A a 1L e 2A a 2L.

Tabela 4 – Configuração da rede neural dos métodos 1A a 1L.

Banco de Dados	Rede Neural	Método	Quantidade de camadas ocultas	Quantidade de neurônios nas camadas ocultas
BD121	PMC	1A	1	5
		1B	1	10
		1C	1	15
		1D	1	20
		1E	2	5 - 5
		1F	2	10 - 10
		1G	2	15 - 15
		1H	2	20 - 20
		1I	3	5 - 5 - 5
		1J	3	10 - 10 - 10
		1K	3	15 - 15 - 15
		1L	3	20 - 20 - 20

Tabela 5 – Configuração da rede neural dos métodos 2A a 2L.

Banco de Dados	Rede Neural	Método	Quantidade de camadas ocultas	Quantidade de neurônios nas camadas ocultas
BD100	PMC	2A	1	5
		2B	1	10
		2C	1	15
		2D	1	20
		2E	2	5 - 5
		2F	2	10 - 10
		2G	2	15 - 15
		2H	2	20 - 20
		2I	3	5 - 5 - 5
		2J	3	10 - 10 - 10
		2K	3	15 - 15 - 15
		2L	3	20 - 20 - 20

A tabela 6 apresenta as configurações das redes neurais e a base de dados utilizados nos ensaios dos métodos 3A a 3C e 4A a 4C.

Tabela 6 – Configuração da rede neural dos métodos 3A a 3C e 4A a 4C.

Banco de Dados	Rede Neural	Método	Spread
BD121	RBF	3A	0,1
		3B	1
		3C	10
BD100	RBF	4A	0,1
		4B	1
		4C	10

A seguir é apresentada a descrição da seqüência dos métodos 1A a 1L, 2A a 2L, 3A a 3C, 4A a 4C e durante a implementação foram executados 5 repetições nos itens 4 a 10 para cada valor do erro quadrático médio no treinamento:

- 1) Leitura na base de dados do método em execução ( BD121 ou BD100) de todos os dados das quantidades de nitrogênio analisados no laboratório, coluna D;
- 2) Leitura na base de dados do método em execução ( BD121 ou BD100) de todos os dados dos 16 tipos de refletâncias, colunas J a Y;
- 3) Normalização dos valores de leitura dos itens 1 e 2, no intervalo [-1,+1];
- 4) Geração de números aleatórios para serem utilizados como índices de busca no conjunto de refletâncias e dos os dados do resultado da análise em laboratório da quantidade de nitrogênio (sorteio de índices);
- 5) Utilização dos índices de busca sorteados no item anterior para separação de 70% das amostras de refletâncias e respectivos valores do resultado da análise em laboratório da quantidade de nitrogênio para treinamento e 30% restantes para validação;
- 6) Gerar a rede neural PMC do método em execução. As entradas da rede são os valores de refletâncias e respectivos valores do resultado da análise em

laboratório da quantidade de nitrogênio e a saída é o valor estimado do nitrogênio absorvido pelas plantas;

- 7) Treinamento da rede neural com o conjunto de treinamento até encontrar o erro determinado e se atingir o número máximo de épocas durante o treinamento o sistema é reiniciado no item 1;
- 8) Simulação da rede neural com o conjunto de treinamento;
- 9) Simulação da rede neural com o conjunto de validação;
- 10) Exibição e armazenamento dos gráficos de desempenho do treinamento e validação.

## **4 RESULTADOS E DISCUSSÕES**

Nesse capítulo são apresentados os resultados obtidos com as simulações dos sistemas inteligentes implementados com os algoritmos que utilizam as redes neurais PMC e RBF e posterior discussão dos resultados apresentados.

### **4.1 Resultados dos Testes do Método 1**

O método 1 utilizou a rede PMC, com a base de dados Bd121 e as Tabelas 7 a 12 apresentam os resultados dos testes com a metodologia delineada para os métodos 1A a 1D com uma camada oculta de neurônios e os 6 valores escolhidos do erro quadrático médio para o aprendizado. As Tabelas 13 a 18 apresentam os resultados dos testes com a metodologia delineada para os métodos 1E à 1H com duas camadas ocultas de neurônios e os 6 valores escolhidos do erro quadrático médio para o aprendizado. As Tabelas 19 a 24 apresentam os resultados dos testes com a metodologia delineada para os métodos 1I à 1L com três camadas ocultas de neurônios e os 6 valores escolhidos do erro quadrático médio para o aprendizado. A identificação do mesmo método para cada um dos 6 valores do erro quadrático médio é através do número após a letra que indica o método.

Tabela 7 - Resultados - rede PMC - 1 camada oculta - Bd121 - EQM 1e-2

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camada ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
1	1 e <sup>-2</sup>	5	1A1 - 1	0,93	13,10	0,67	0,72
			1A1 - 2	0,94	14,55	0,56	
			1A1 - 3	0,94	10,88	0,72	
			1A1 - 4	0,95	20,69	0,41	
			1A1 - 5	0,95	14,76	0,54	
		10	1B1 - 1	0,95	18,48	0,57	0,73
			1B1 - 2	0,93	16,09	0,68	
			1B1 - 3	0,95	14,14	0,54	
			1B1 - 4	0,95	16,09	0,50	
			1B1 - 5	0,93	13,90	0,73	
		15	1C1 - 1	0,97	20,24	0,60	0,62
			1C1 - 2	0,93	10,54	0,62	
			1C1 - 3	0,93	17,57	0,44	
			1C1 - 4	0,94	15,03	0,59	
			1C1 - 5	0,94	15,12	0,62	
		20	1D1 - 1	0,95	15,98	0,58	0,70
			1D1 - 2	0,94	10,92	0,80	
			1D1 - 3	0,94	15,46	0,67	
			1D1 - 4	0,93	15,10	0,59	
			1D1 - 5	0,94	13,86	0,70	

Tabela 8 - Resultados - rede PMC - 1 camada oculta - Bd121 - EQM 9e-3

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camada ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
1	9 e <sup>-3</sup>	5	1A2 - 1	0,94	13,42	0,67	0,74
			1A2 - 2	0,94	15,71	0,49	
			1A2 - 3	0,95	12,54	0,74	
			1A2 - 4	0,95	12,90	0,59	
			1A2 - 5	0,94	14,97	0,63	
		10	1B2 - 1	0,95	12,42	0,69	0,73
			1B2 - 2	0,95	16,95	0,62	
			1B2 - 3	0,96	17,20	0,57	
			1B2 - 4	0,93	12,14	0,73	
			1B2 - 5	0,94	20,68	0,60	
		15	1C2 - 1	0,95	9,63	0,68	0,68
			1C2 - 2	0,94	14,77	0,59	
			1C2 - 3	0,95	10,99	0,68	
			1C2 - 4	0,95	14,40	0,63	
			1C2 - 5	0,95	15,40	0,59	
		20	1D2 - 1	0,95	18,75	0,46	0,71
			1D2 - 2	0,93	14,55	0,71	
			1D2 - 3	0,96	19,86	0,55	
			1D2 - 4	0,99	20,53	0,43	
			1D2 - 5	0,94	15,85	0,54	

Tabela 9 - Resultados - rede PMC - 1 camada oculta - Bd121 - EQM 7e-3

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camada ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
1	7 e <sup>-3</sup>	5	1A3 - 1	0,95	16,19	0,47	0,57
			1A3 - 2	0,96	14,31	0,57	
			1A3 - 3	0,95	22,20	0,42	
			1A3 - 4	0,94	18,05	0,53	
			1A3 - 5	0,94	19,54	0,44	
		10	1B3 - 1	0,96	16,81	0,57	0,74
			1B3 - 2	0,95	18,29	0,45	
			1B3 - 3	0,98	24,26	0,43	
			1B3 - 4	0,96	11,09	0,71	
			1B3 - 5	0,97	11,34	0,74	
		15	1C3 - 1	0,97	15,93	0,45	0,58
			1C3 - 2	0,95	15,05	0,58	
			1C3 - 3	0,97	18,12	0,43	
			1C3 - 4	0,96	19,94	0,56	
			1C3 - 5	0,95	14,36	0,48	
		20	1D3 - 1	0,96	15,00	0,50	0,56
			1D3 - 2	0,96	15,86	0,56	
			1D3 - 3	0,96	15,78	0,52	
			1D3 - 4	0,97	28,26	0,53	
			1D3 - 5	0,96	27,14	0,43	

Tabela 10 - Resultados - rede PMC - 1 camada oculta - Bd121 - EQM 5e-3

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camada ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
1	5 e <sup>-3</sup>	5	1A4 - 1	0,97	21,36	0,43	0,69
			1A4 - 2	0,98	16,34	0,48	
			1A4 - 3	0,97	11,19	0,69	
			1A4 - 4	0,98	12,48	0,63	
			1A4 - 5	0,97	19,06	0,45	
		10	1B4 - 1	0,98	17,43	0,50	0,57
			1B4 - 2	0,97	15,26	0,57	
			1B4 - 3	0,97	16,62	0,40	
			1B4 - 4	0,98	15,97	0,46	
			1B4 - 5	0,97	20,13	0,42	
		15	1C4 - 1	0,97	15,09	0,75	0,75
			1C4 - 2	0,97	18,52	0,40	
			1C4 - 3	0,98	16,91	0,51	
			1C4 - 4	0,98	21,21	0,42	
			1C4 - 5	0,98	15,30	0,54	
		20	1D4 - 1	0,96	12,97	0,67	0,72
			1D4 - 2	0,97	17,64	0,43	
			1D4 - 3	0,97	13,24	0,72	
			1D4 - 4	0,97	16,33	0,53	
			1D4 - 5	0,97	16,84	0,42	

Tabela 11 - Resultados - rede PMC - 1 camada oculta - Bd121 - EQM  $3e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camada ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
1	$3e^{-3}$	5	1A5 - 1	0,98	23,74	0,41	0,67
			1A5 - 2	0,98	16,36	0,42	
			1A5 - 3	0,98	21,43	0,51	
			1A5 - 4	0,98	16,45	0,67	
			1A5 - 5	0,97	15,33	0,61	
		10	1B5 - 1	0,99	15,54	0,64	0,70
			1B5 - 2	0,98	18,54	0,44	
			1B5 - 3	0,99	18,28	0,70	
			1B5 - 4	0,99	17,63	0,51	
			1B5 - 5	0,99	17,94	0,42	
		15	1C5 - 1	0,99	23,20	0,47	0,51
			1C5 - 2	0,99	19,34	0,42	
			1C5 - 3	0,99	23,83	0,51	
			1C5 - 4	0,99	16,88	0,46	
			1C5 - 5	0,99	19,23	0,47	
		20	1D5 - 1	0,98	17,82	0,51	0,61
			1D5 - 2	0,97	21,64	0,42	
			1D5 - 3	0,97	20,20	0,61	
			1D5 - 4	0,98	23,90	0,44	
			1D5 - 5	0,98	17,16	0,56	

Tabela 12 - Resultados - rede PMC - 1 camada oculta - Bd121 - EQM  $1e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios na camada oculta	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
1	$1e^{-3}$	5	1A6 - 1	0,98	17,11	0,63	0,65
			1A6 - 2	0,99	22,52	0,61	
			1A6 - 3	0,98	18,50	0,42	
			1A6 - 4	0,98	18,04	0,46	
			1A6 - 5	0,98	12,97	0,65	
		10	1B6 - 1	0,99	16,68	0,50	0,70
			1B6 - 2	0,99	24,61	0,43	
			1B6 - 3	0,99	20,66	0,70	
			1B6 - 4	0,99	16,38	0,46	
			1B6 - 5	0,99	25,88	0,42	
		15	1C6 - 1	0,99	18,19	0,50	0,54
			1C6 - 2	0,99	19,81	0,54	
			1C6 - 3	0,99	20,63	0,44	
			1C6 - 4	0,99	19,90	0,51	
			1C6 - 5	0,99	16,45	0,50	
		20	1D6 - 1	0,99	19,49	0,41	0,63
			1D6 - 2	0,99	19,10	0,63	
			1D6 - 3	0,99	13,26	0,55	
			1D6 - 4	0,99	21,10	0,59	
			1D6 - 5	0,99	20,68	0,41	

Tabela 13 - Resultados - rede PMC - 2 camadas ocultas - Bd121 - EQM  $1e^{-2}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
2	$1e^{-2}$	5 -5	1E1 - 1	0,94	16,97	0,50	0,77
			1E1 - 2	0,94	19,66	0,62	
			1E1 - 3	0,94	15,57	0,47	
			1E1 - 4	0,95	17,54	0,69	
			1E1 - 5	0,94	10,13	0,77	
		10 -10	1F1 - 1	0,95	19,26	0,48	0,60
			1F1 - 2	0,95	14,25	0,59	
			1F1 - 3	0,94	15,63	0,59	
			1F1 - 4	0,95	15,77	0,49	
			1F1 - 5	0,97	13,19	0,60	
		15 -15	1G1 - 1	0,94	15,49	0,60	0,65
			1G1 - 2	0,95	13,66	0,63	
			1G1 - 3	0,95	18,14	0,65	
			1G1 - 4	0,94	15,45	0,60	
			1G1 - 5	0,94	26,95	0,49	
		20 -20	1H1 - 1	0,95	17,68	0,50	0,71
			1H1 - 2	0,96	17,60	0,64	
			1H1 - 3	0,95	13,10	0,71	
			1H1 - 4	0,97	16,77	0,48	
			1H1 - 5	0,97	13,84	0,56	

Tabela 14 - Resultados - rede PMC - 2 camadas ocultas - Bd121 - EQM  $9e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
2	$9e^{-3}$	5 -5	1E2 - 1	0,95	14,41	0,69	0,86
			1E2 - 2	0,96	15,18	0,50	
			1E2 - 3	0,96	16,86	0,53	
			1E2 - 4	0,98	6,67	0,86	
			1E2 - 5	0,96	12,59	0,49	
		10 -10	1F2 - 1	0,94	17,26	0,55	0,66
			1F2 - 2	0,94	18,72	0,48	
			1F2 - 3	0,95	13,60	0,62	
			1F2 - 4	0,94	16,40	0,66	
			1F2 - 5	0,95	17,39	0,52	
		15 -15	1G2 - 1	0,96	16,87	0,70	0,68
			1G2 - 2	0,96	10,54	0,68	
			1G2 - 3	0,95	17,91	0,50	
			1G2 - 4	0,96	17,14	0,49	
			1G2 - 5	0,95	13,09	0,61	
		20 -20	1H2 - 1	0,95	12,33	0,74	0,75
			1H2 - 2	0,97	12,58	0,62	
			1H2 - 3	0,94	12,50	0,73	
			1H2 - 4	0,95	12,05	0,75	
			1H2 - 5	0,96	19,49	0,53	

Tabela 15 - Resultados - rede PMC - 2 camadas ocultas - Bd121 - EQM  $7e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
2	$7e^{-3}$	5 - 5	1E3 - 1	0,95	14,97	0,64	0,77
			1E3 - 2	0,97	17,76	0,73	
			1E3 - 3	0,95	13,51	0,74	
			1E3 - 4	0,97	15,68	0,61	
			1E3 - 5	0,95	13,04	0,77	
		10 - 10	1F3 - 1	0,96	13,35	0,69	0,73
			1F3 - 2	0,97	12,30	0,64	
			1F3 - 3	0,96	15,15	0,63	
			1F3 - 4	0,95	14,51	0,73	
			1F3 - 5	0,97	12,27	0,67	
		15 - 15	1G3 - 1	0,97	11,83	0,66	0,75
			1G3 - 2	0,97	11,81	0,75	
			1G3 - 3	0,97	11,42	0,70	
			1G3 - 4	0,97	11,80	0,64	
			1G3 - 5	0,97	13,86	0,61	
		20 - 20	1H3 - 1	0,97	9,80	0,67	0,69
			1H3 - 2	0,95	15,05	0,62	
			1H3 - 3	0,96	13,23	0,65	
			1H3 - 4	0,97	14,15	0,63	
			1H3 - 5	0,97	11,07	0,69	

Tabela 16 - Resultados - rede PMC - 2 camadas ocultas - Bd121 - EQM  $5e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
2	$5e^{-3}$	5 - 5	1E4 - 1	0,97	13,06	0,76	0,84
			1E4 - 2	0,97	11,86	0,74	
			1E4 - 3	0,97	13,78	0,74	
			1E4 - 4	0,97	9,32	0,84	
			1E4 - 5	0,97	9,16	0,79	
		10 - 10	1F4 - 1	0,97	8,85	0,79	0,80
			1F4 - 2	0,97	13,13	0,78	
			1F4 - 3	0,98	9,91	0,73	
			1F4 - 4	0,97	11,10	0,72	
			1F4 - 5	0,97	9,28	0,80	
		15 - 15	1G4 - 1	0,99	16,80	0,70	0,85
			1G4 - 2	0,98	11,94	0,74	
			1G4 - 3	0,98	14,20	0,85	
			1G4 - 4	0,98	10,91	0,74	
			1G4 - 5	0,97	13,09	0,61	
		20 - 20	1H4 - 1	0,98	12,03	0,73	0,75
			1H4 - 2	0,97	12,94	0,75	
			1H4 - 3	0,97	14,76	0,75	
			1H4 - 4	0,97	13,50	0,74	
			1H4 - 5	0,96	19,49	0,53	

Tabela 17 - Resultados - rede PMC - 2 camadas ocultas - Bd121 - EQM  $3e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
2	$3e^{-3}$	5 - 5	1E5 - 1	0,98	13,12	0,78	0,78
			1E5 - 2	0,98	16,01	0,71	
			1E5 - 3	0,98	13,14	0,65	
			1E5 - 4	0,98	13,50	0,70	
			1E5 - 5	0,98	24,66	0,70	
		10 - 10	1F5 - 1	0,99	18,73	0,66	0,71
			1F5 - 2	0,98	16,21	0,65	
			1F5 - 3	0,99	12,75	0,71	
			1F5 - 4	0,98	13,87	0,69	
			1F5 - 5	0,99	12,69	0,69	
		15 - 15	1G5 - 1	0,98	13,21	0,71	0,71
			1G5 - 2	0,98	13,34	0,68	
			1G5 - 3	0,98	13,51	0,68	
			1G5 - 4	0,97	13,73	0,70	
			1G5 - 5	0,98	13,51	0,69	
		20 - 20	1H5 - 1	0,98	14,61	0,65	0,67
			1H5 - 2	0,98	13,30	0,65	
			1H5 - 3	0,98	12,06	0,67	
			1H5 - 4	0,96	14,57	0,65	
			1H5 - 5	0,98	15,31	0,65	

Tabela 18 - Resultados - rede PMC - 2 camadas ocultas - Bd121 - EQM  $1e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
2	$1e^{-3}$	5 - 5	1E6 - 1	0,99	15,37	0,69	0,74
			1E6 - 2	0,99	19,91	0,65	
			1E6 - 3	0,99	13,88	0,68	
			1E6 - 4	0,99	10,63	0,74	
			1E6 - 5	0,99	10,91	0,65	
		10 - 10	1F6 - 1	0,99	16,17	0,65	0,70
			1F6 - 2	0,99	13,51	0,70	
			1F6 - 3	0,99	13,45	0,70	
			1F6 - 4	0,99	11,78	0,69	
			1F6 - 5	0,99	15,63	0,68	
		15 - 15	1G6 - 1	0,99	13,40	0,64	0,73
			1G6 - 2	0,99	16,62	0,66	
			1G6 - 3	0,99	14,88	0,65	
			1G6 - 4	0,99	12,80	0,73	
			1G6 - 5	0,99	12,99	0,72	
		20 - 20	1H6 - 1	0,99	15,39	0,65	0,70
			1H6 - 2	0,99	11,63	0,70	
			1H6 - 3	0,99	16,06	0,66	
			1H6 - 4	0,99	18,54	0,66	
			1H6 - 5	0,99	8,60	0,66	

Tabela 19 - Resultados - rede PMC - 3 camadas ocultas - Bd121 - EQM  $1e^{-2}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
3	$1e^{-2}$	5 -5 -5	1I1 - 1	0,95	14,07	0,55	0,75
			1I1 - 2	0,94	14,71	0,48	
			1I1 - 3	0,94	14,79	0,55	
			1I1 - 4	0,94	16,17	0,56	
			1I1 - 5	0,95	9,32	0,75	
		10 -10 -10	1J1 - 1	0,95	13,78	0,58	0,67
			1J1 - 2	0,94	13,79	0,67	
			1J1 - 3	0,95	14,11	0,60	
			1J1 - 4	0,95	11,25	0,67	
			1J1 - 5	0,97	17,22	0,63	
		15 -15 -15	1K1 - 1	0,94	13,60	0,64	0,64
			1K1 - 2	0,95	12,10	0,61	
			1K1 - 3	0,95	15,30	0,56	
			1K1 - 4	0,95	14,98	0,59	
			1K1 - 5	0,96	11,49	0,56	
		20 -20 -20	1L1 - 1	0,94	11,85	0,72	0,72
			1L1 - 2	0,94	15,47	0,67	
			1L1 - 3	0,94	17,36	0,55	
			1L1 - 4	0,94	17,51	0,47	
			1L1 - 5	0,93	16,47	0,50	

Tabela 20 - Resultados - rede PMC - 3 camadas ocultas - Bd121 - EQM  $9e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
3	$9e^{-3}$	5 -5 -5	1I2 - 1	0,95	15,58	0,59	0,71
			1I2 - 2	0,96	10,44	0,71	
			1I2 - 3	0,94	19,35	0,43	
			1I2 - 4	0,94	18,34	0,50	
			1I2 - 5	0,94	10,44	0,70	
		10 -10 -10	1J2 - 1	0,96	17,03	0,51	0,83
			1J2 - 2	0,93	20,56	0,51	
			1J2 - 3	0,97	10,82	0,83	
			1J2 - 4	0,94	15,28	0,55	
			1J2 - 5	0,94	15,61	0,74	
		15 -15 -15	1K2 - 1	0,93	14,36	0,56	0,82
			1K2 - 2	0,93	12,43	0,82	
			1K2 - 3	0,97	16,77	0,61	
			1K2 - 4	0,96	17,37	0,46	
			1K2 - 5	0,97	8,45	0,80	
		20 -20 -20	1L2 - 1	0,95	12,61	0,71	0,75
			1L2 - 2	0,95	15,14	0,75	
			1L2 - 3	0,93	13,16	0,70	
			1L2 - 4	0,96	23,42	0,41	
			1L2 - 5	0,95	16,49	0,56	

Tabela 21 - Resultados - rede PMC - 3 camadas ocultas - Bd121 - EQM 7e-3

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
3	7 e <sup>-3</sup>	5 -5 -5	1I3 - 1	0,96	14,53	0,54	0,79
			1I3 - 2	0,96	12,18	0,62	
			1I3 - 3	0,94	10,29	0,79	
			1I3 - 4	0,97	15,30	0,62	
			1I3 - 5	0,95	19,78	0,40	
		10 -10 -10	1J3 - 1	0,98	12,55	0,50	0,71
			1J3 - 2	0,95	14,29	0,56	
			1J3 - 3	0,96	18,78	0,47	
			1J3 - 4	0,96	13,29	0,71	
			1J3 - 5	0,97	16,73	0,46	
		15 -15 -15	1K3 - 1	0,97	16,10	0,56	0,73
			1K3 - 2	0,97	13,68	0,58	
			1K3 - 3	0,95	17,16	0,67	
			1K3 - 4	0,98	9,48	0,73	
			1K3 - 5	0,95	18,08	0,57	
		20 -20 -20	1L3 - 1	0,96	16,08	0,58	0,63
			1L3 - 2	0,96	14,81	0,54	
			1L3 - 3	0,96	16,08	0,63	
			1L3 - 4	0,93	16,32	0,46	
			1L3 - 5	0,94	15,18	0,52	

Tabela 22 - Resultados - rede PMC - 3 camadas ocultas - Bd121 - EQM 5e-3

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
3	5 e <sup>-3</sup>	5 -5 -5	1I4 - 1	0,97	16,82	0,46	0,82
			1I4 - 2	0,97	16,11	0,63	
			1I4 - 3	0,97	16,58	0,55	
			1I4 - 4	0,97	10,41	0,82	
			1I4 - 5	0,97	13,23	0,72	
		10 -10 -10	1J4 - 1	0,97	11,22	0,65	0,65
			1J4 - 2	0,97	23,31	0,44	
			1J4 - 3	0,98	11,40	0,59	
			1J4 - 4	0,97	15,51	0,63	
			1J4 - 5	0,98	20,18	0,65	
		15 -15 -15	1K4 - 1	0,98	20,08	0,48	0,74
			1K4 - 2	0,97	15,97	0,71	
			1K4 - 3	0,96	15,55	0,61	
			1K4 - 4	0,97	14,29	0,67	
			1K4 - 5	0,98	9,67	0,74	
		20 -20 -20	1L4 - 1	0,97	18,27	0,48	0,68
			1L4 - 2	0,97	16,06	0,49	
			1L4 - 3	0,97	14,68	0,68	
			1L4 - 4	0,97	13,24	0,48	
			1L4 - 5	0,98	18,70	0,57	

Tabela 23 - Resultados - rede PMC - 3 camadas ocultas - Bd121 - EQM  $3e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
3	$3e^{-3}$	5 -5 -5	1I5 - 1	0,98	20,18	0,45	0,75
			1I5 - 2	0,98	9,58	0,75	
			1I5 - 3	0,98	17,61	0,75	
			1I5 - 4	0,98	17,21	0,67	
			1I5 - 5	0,98	15,42	0,72	
		10 -10 -10	1J5 - 1	0,98	14,76	0,56	0,60
			1J5 - 2	0,98	15,06	0,50	
			1J5 - 3	0,98	15,42	0,53	
			1J5 - 4	0,98	17,31	0,60	
			1J5 - 5	0,98	15,78	0,53	
		15 -15 -15	1K5 - 1	0,98	13,79	0,62	0,64
			1K5 - 2	0,98	18,74	0,62	
			1K5 - 3	0,95	22,03	0,64	
			1K5 - 4	0,98	13,99	0,61	
			1K5 - 5	0,98	17,24	0,50	
		20 -20 -20	1L5 - 1	0,99	12,31	0,68	0,74
			1L5 - 2	0,99	14,86	0,55	
			1L5 - 3	0,98	16,11	0,74	
			1L5 - 4	0,98	11,97	0,51	
			1L5 - 5	0,99	14,63	0,60	

Tabela 24 - Resultados - rede PMC - 3 camadas ocultas - Bd121 - EQM  $1e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
3	$1e^{-3}$	5 -5 -5	1I6 - 1	0,99	13,47	0,56	0,59
			1I6 - 2	0,99	25,19	0,45	
			1I6 - 3	0,99	18,02	0,59	
			1I6 - 4	0,99	15,65	0,43	
			1I6 - 5	0,99	17,66	0,57	
		10 -10 -10	1J6 - 1	0,99	15,25	0,60	0,75
			1J6 - 2	0,99	15,90	0,75	
			1J6 - 3	0,99	14,93	0,57	
			1J6 - 4	0,99	16,52	0,47	
			1J6 - 5	0,99	20,20	0,43	
		15 -15 -15	1K6 - 1	0,99	10,32	0,77	0,77
			1K6 - 2	0,99	16,60	0,44	
			1K6 - 3	0,99	16,88	0,56	
			1K6 - 4	0,97	14,71	0,74	
			1K6 - 5	0,99	14,20	0,62	
		20 -20 -20	1L6 - 1	0,99	19,56	0,50	0,57
			1L6 - 2	0,99	16,07	0,57	
			1L6 - 3	0,99	23,10	0,41	
			1L6 - 4	0,99	21,90	0,56	
			1L6 - 5	0,99	22,28	0,43	

## 4.2 Resultados dos Testes do Método 2

O método 2 utilizou a rede PMC, com a base de dados Bd100 e as Tabelas 25 a 30 apresentam os resultados dos testes com a metodologia delineada para os métodos 2A a 2D com uma camada oculta de neurônios e os 6 valores escolhidos do erro quadrático médio para o aprendizado. As Tabelas 31 a 36 apresentam os resultados dos testes com a metodologia delineada para os métodos 2E às 2H com duas camadas ocultas de neurônios e os 6 valores escolhidos do erro quadrático médio para o aprendizado. As Tabelas 37 a 42 apresentam os resultados dos testes com a metodologia delineada para os métodos 2I à 2L com três camadas ocultas de neurônios e os 6 valores escolhidos do erro quadrático médio para o aprendizado.

Tabela 25 - Resultados - rede PMC - 1 camada oculta - Bd100 - EQM  $1e^{-2}$

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
1	1 e <sup>-2</sup>	5	2A1 - 1	0,95	4,57	0,81	0,89
			2A1 - 2	0,96	4,23	0,89	
			2A1 - 3	0,95	9,22	0,41	
			2A1 - 4	0,97	5,11	0,80	
			2A1 - 5	0,97	7,06	0,52	
		10	2B1 - 1	0,96	4,90	0,74	0,90
			2B1 - 2	0,96	4,17	0,85	
			2B1 - 3	0,95	4,42	0,82	
			2B1 - 4	0,95	3,89	0,90	
			2B1 - 5	0,97	4,85	0,78	
		15	2C1 - 1	0,97	4,55	0,81	0,88
			2C1 - 2	0,95	4,62	0,81	
			2C1 - 3	0,96	4,37	0,78	
			2C1 - 4	0,95	3,71	0,88	
			2C1 - 5	0,95	4,44	0,84	
		20	2D1 - 1	0,96	4,22	0,85	0,91
			2D1 - 2	0,96	5,16	0,77	
			2D1 - 3	0,94	4,46	0,87	
			2D1 - 4	0,95	4,15	0,91	
			2D1 - 5	0,96	3,88	0,86	

Tabela 26 - Resultados - rede PMC - 1 camada oculta - Bd100 - EQM  $9e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
1	$7e^{-3}$	5	2A3 - 1	0,98	2,46	0,92	0,92
			2A3 - 2	0,97	3,18	0,87	
			2A3 - 3	0,97	4,02	0,80	
			2A3 - 4	0,97	4,44	0,79	
			2A3 - 5	0,96	4,88	0,81	
		10	2B3 - 1	0,96	3,72	0,88	0,88
			2B3 - 2	0,97	4,19	0,84	
			2B3 - 3	0,96	4,39	0,87	
			2B3 - 4	0,97	6,40	0,73	
			2B3 - 5	0,97	4,25	0,84	
		15	2C3 - 1	0,97	4,96	0,65	0,90
			2C3 - 2	0,97	4,68	0,80	
			2C3 - 3	0,97	4,65	0,80	
			2C3 - 4	0,97	3,47	0,90	
			2C3 - 5	0,97	7,20	0,51	
		20	2D3 - 1	0,97	6,88	0,58	0,90
			2D3 - 2	0,97	5,23	0,76	
			2D3 - 3	0,97	3,37	0,83	
			2D3 - 4	0,97	3,91	0,90	
			2D3 - 5	0,97	4,95	0,76	

Tabela 27 - Resultados - rede PMC - 1 camada oculta - Bd100 - EQM  $7e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
1	$7e^{-3}$	5	2A3 - 1	0,98	2,46	0,92	0,92
			2A3 - 2	0,97	3,18	0,87	
			2A3 - 3	0,97	4,02	0,80	
			2A3 - 4	0,97	4,44	0,79	
			2A3 - 5	0,96	4,88	0,81	
		10	2B3 - 1	0,96	3,72	0,88	0,88
			2B3 - 2	0,97	4,19	0,84	
			2B3 - 3	0,96	4,39	0,87	
			2B3 - 4	0,97	6,40	0,73	
			2B3 - 5	0,97	4,25	0,84	
		15	2C3 - 1	0,97	4,96	0,65	0,90
			2C3 - 2	0,97	4,68	0,80	
			2C3 - 3	0,97	4,65	0,80	
			2C3 - 4	0,97	3,47	0,90	
			2C3 - 5	0,97	7,20	0,51	
		20	2D3 - 1	0,97	6,88	0,58	0,90
			2D3 - 2	0,97	5,23	0,76	
			2D3 - 3	0,97	3,37	0,83	
			2D3 - 4	0,97	3,91	0,90	
			2D3 - 5	0,97	4,95	0,76	

Tabela 28 - Resultados - rede PMC - 1 camada oculta - Bd100 - EQM  $5e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
1	$5e^{-3}$	5	2A4 - 1	0,97	5,70	0,90	0,90
			2A4 - 2	0,97	4,47	0,84	
			2A4 - 3	0,98	5,32	0,75	
			2A4 - 4	0,98	4,69	0,77	
			2A4 - 5	0,98	5,36	0,75	
		10	2B4 - 1	0,98	4,11	0,82	0,84
			2B4 - 2	0,98	4,40	0,73	
			2B4 - 3	0,98	4,93	0,83	
			2B4 - 4	0,98	4,43	0,84	
			2B4 - 5	0,98	4,59	0,79	
		15	2C4 - 1	0,98	4,73	0,84	0,84
			2C4 - 2	0,99	4,87	0,75	
			2C4 - 3	0,98	5,34	0,77	
			2C4 - 4	0,98	4,33	0,78	
			2C4 - 5	0,99	6,61	0,62	
		20	2D4 - 1	0,98	3,88	0,85	0,89
			2D4 - 2	0,97	3,88	0,89	
			2D4 - 3	0,97	5,43	0,78	
			2D4 - 4	0,98	4,83	0,77	
			2D4 - 5	0,98	4,26	0,85	

Tabela 29 - Resultados - rede PMC - 1 camada oculta - Bd100 - EQM  $3e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
1	$3e^{-3}$	5	2A5 - 1	0,99	4,63	0,82	0,82
			2A5 - 2	0,99	6,92	0,65	
			2A5 - 3	0,99	5,38	0,80	
			2A5 - 4	0,99	5,33	0,79	
			2A5 - 5	0,99	3,53	0,88	
		10	2B5 - 1	0,99	5,35	0,80	0,80
			2B5 - 2	0,99	4,77	0,79	
			2B5 - 3	0,99	6,26	0,65	
			2B5 - 4	0,99	5,61	0,77	
			2B5 - 5	0,99	6,80	0,76	
		15	2C5 - 1	0,99	5,34	0,76	0,90
			2C5 - 2	0,99	5,79	0,70	
			2C5 - 3	0,99	5,55	0,81	
			2C5 - 4	0,99	4,24	0,86	
			2C5 - 5	0,99	4,45	0,90	
		20	2D5 - 1	0,98	5,54	0,76	0,83
			2D5 - 2	0,98	9,31	0,43	
			2D5 - 3	0,98	4,34	0,83	
			2D5 - 4	0,98	10,04	0,43	
			2D5 - 5	0,99	9,24	0,64	

Tabela 30 - Resultados - rede PMC - 1 camada oculta - Bd100 - EQM  $1e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios na camada oculta	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
1	$1e^{-3}$	5	2A6 - 1	0,99	17,11	0,63	0,65
			2A6 - 2	0,99	22,52	0,61	
			2A6 - 3	0,99	18,50	0,42	
			2A6 - 4	0,99	18,04	0,46	
			2A6 - 5	0,99	12,97	0,65	
		10	2B6 - 1	0,99	16,68	0,50	0,70
			2B6 - 2	0,99	24,61	0,43	
			2B6 - 3	0,99	20,66	0,70	
			2B6 - 4	0,99	16,38	0,46	
			2B6 - 5	0,99	25,88	0,42	
		15	2C6 - 1	0,99	18,19	0,50	0,54
			2C6 - 2	0,99	19,81	0,54	
			2C6 - 3	0,99	20,63	0,44	
			2C6 - 4	0,99	19,90	0,51	
			2C6 - 5	0,99	16,45	0,50	
		20	2D6 - 1	0,99	19,49	0,41	0,59
			2D6 - 2	0,99	19,10	0,63	
			2D6 - 3	0,99	13,26	0,55	
			2D6 - 4	0,99	21,10	0,59	
			2D6 - 5	0,99	20,68	0,41	

Tabela 31 - Resultados - rede PMC - 2 camadas ocultas - Bd100 - EQM  $1e^{-2}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
2	$1e^{-2}$	5-5	2E1 - 1	0,97	5,99	0,81	0,88
			2E1 - 2	0,95	6,61	0,67	
			2E1 - 3	0,96	5,43	0,81	
			2E1 - 4	0,96	3,14	0,88	
			2E1 - 5	0,95	4,47	0,83	
		10-10	2F1 - 1	0,96	4,10	0,80	0,89
			2F1 - 2	0,96	4,97	0,84	
			2F1 - 3	0,96	4,01	0,86	
			2F1 - 4	0,97	4,90	0,85	
			2F1 - 5	0,95	3,53	0,89	
		15-15	2G1 - 1	0,95	5,37	0,62	0,88
			2G1 - 2	0,95	5,17	0,81	
			2G1 - 3	0,97	3,39	0,88	
			2G1 - 4	0,96	7,27	0,59	
			2G1 - 5	0,96	3,38	0,91	
		20-20	2H1 - 1	0,96	3,61	0,88	0,92
			2H1 - 2	0,96	4,16	0,92	
			2H1 - 3	0,97	4,46	0,81	
			2H1 - 4	0,97	3,83	0,90	
			2H1 - 5	0,96	3,84	0,87	

Tabela 32 - Resultados - rede PMC - 2 camadas ocultas - Bd100 - EQM  $9e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
2	$9e^{-3}$	5 -5	2E2 - 1	0,96	3,80	0,84	0,87
			2E2 - 2	0,97	5,65	0,75	
			2E2 - 3	0,96	3,96	0,87	
			2E2 - 4	0,96	4,27	0,84	
			2E2 - 5	0,96	6,67	0,63	
		10 -10	2F2 - 1	0,96	5,54	0,70	0,85
			2F2 - 2	0,97	5,69	0,80	
			2F2 - 3	0,96	4,10	0,85	
			2F2 - 4	0,96	4,49	0,82	
			2F2 - 5	0,96	4,67	0,83	
		15 -15	2G2 - 1	0,94	4,23	0,86	0,90
			2G2 - 2	0,97	3,68	0,89	
			2G2 - 3	0,97	5,16	0,84	
			2G2 - 4	0,97	3,70	0,90	
			2G2 - 5	0,96	3,77	0,83	
		20 -20	2H2 - 1	0,98	4,53	0,81	0,90
			2H2 - 2	0,98	2,99	0,90	
			2H2 - 3	0,96	3,42	0,87	
			2H2 - 4	0,98	4,01	0,87	
			2H2 - 5	0,97	4,90	0,83	

Tabela 33 - Resultados - rede PMC - 2 camadas ocultas - Bd100 - EQM  $7e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
2	$7e^{-3}$	5 -5	2E3 - 1	0,96	5,16	0,76	0,84
			2E3 - 2	0,96	5,98	0,68	
			2E3 - 3	0,96	4,31	0,84	
			2E3 - 4	0,97	4,17	0,83	
			2E3 - 5	0,97	5,51	0,71	
		10 -10	2F3 - 1	0,97	4,18	0,85	0,87
			2F3 - 2	0,97	3,58	0,84	
			2F3 - 3	0,97	4,82	0,87	
			2F3 - 4	0,96	4,27	0,85	
			2F3 - 5	0,97	5,46	0,86	
		15 -15	2G3 - 1	0,98	6,60	0,80	0,84
			2G3 - 2	0,97	5,32	0,75	
			2G3 - 3	0,97	3,94	0,84	
			2G3 - 4	0,98	6,62	0,73	
			2G3 - 5	0,97	4,54	0,81	
		20 -20	2H3 - 1	0,97	7,68	0,55	0,85
			2H3 - 2	0,98	4,04	0,85	
			2H3 - 3	0,98	5,45	0,83	
			2H3 - 4	0,97	4,52	0,84	
			2H3 - 5	0,97	5,48	0,74	

Tabela 34 - Resultados - rede PMC - 2 camadas ocultas - Bd100 - EQM  $5e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
2	$5e^{-3}$	5 -5	2E4 - 1	0,97	5,78	0,78	0,84
			2E4 - 2	0,98	6,57	0,66	
			2E4 - 3	0,97	5,08	0,84	
			2E4 - 4	0,97	3,83	0,84	
			2E4 - 5	0,98	4,23	0,84	
		10 -10	2F4 - 1	0,97	4,66	0,81	0,91
			2F4 - 2	0,98	4,08	0,86	
			2F4 - 3	0,98	3,12	0,91	
			2F4 - 4	0,98	3,73	0,90	
			2F4 - 5	0,98	3,44	0,89	
		15 -15	2G4 - 1	0,98	5,62	0,62	0,87
			2G4 - 2	0,97	3,84	0,88	
			2G4 - 3	0,98	3,64	0,87	
			2G4 - 4	0,98	5,67	0,68	
			2G4 - 5	0,98	3,74	0,88	
		20 -20	2H4 - 1	0,98	4,48	0,82	0,88
			2H4 - 2	0,98	5,44	0,88	
			2H4 - 3	0,98	5,29	0,74	
			2H4 - 4	0,98	4,35	0,85	
			2H4 - 5	0,98	4,18	0,86	

Tabela 35 - Resultados - rede PMC - 2 camadas ocultas - Bd100 - EQM  $3e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
2	$3e^{-3}$	5 -5	2E5 - 1	0,98	4,76	0,86	0,87
			2E5 - 2	0,98	5,91	0,84	
			2E5 - 3	0,98	4,06	0,87	
			2E5 - 4	0,98	4,56	0,87	
			2E5 - 5	0,98	3,95	0,84	
		10 -10	2F5 - 1	0,99	4,51	0,84	0,93
			2F5 - 2	0,98	4,57	0,84	
			2F5 - 3	0,99	3,35	0,93	
			2F5 - 4	0,98	3,61	0,88	
			2F5 - 5	0,98	3,87	0,84	
		15 -15	2G5 - 1	0,98	4,76	0,90	0,91
			2G5 - 2	0,98	4,96	0,84	
			2G5 - 3	0,98	3,85	0,86	
			2G5 - 4	0,98	3,55	0,87	
			2G5 - 5	0,98	3,26	0,91	
		20 -20	2H5 - 1	0,99	4,14	0,88	0,89
			2H5 - 2	0,98	3,84	0,88	
			2H5 - 3	0,99	3,58	0,87	
			2H5 - 4	0,98	4,30	0,87	
			2H5 - 5	0,98	3,90	0,89	

Tabela 36 - Resultados - rede PMC - 2 camadas ocultas - Bd100 - EQM  $1e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
2	$1e^{-3}$	5-5	2E6 - 1	0,99	5,37	0,84	0,88
			2E6 - 2	0,99	4,14	0,88	
			2E6 - 3	0,99	4,81	0,84	
			2E6 - 4	0,99	4,64	0,84	
			2E6 - 5	0,99	5,66	0,82	
		10-10	2F6 - 1	0,99	4,36	0,80	0,85
			2F6 - 2	0,99	3,84	0,85	
			2F6 - 3	0,99	4,52	0,81	
			2F6 - 4	0,99	4,97	0,80	
			2F6 - 5	0,99	4,82	0,82	
		15-15	2G6 - 1	0,99	4,27	0,85	0,88
			2G6 - 2	0,99	4,86	0,84	
			2G6 - 3	0,98	5,25	0,88	
			2G6 - 4	0,99	5,17	0,82	
			2G6 - 5	0,99	4,66	0,87	
		20-20	2H6 - 1	0,99	4,51	0,83	0,86
			2H6 - 2	0,99	4,14	0,84	
			2H6 - 3	0,99	4,83	0,79	
			2H6 - 4	0,98	5,42	0,86	
			2H6 - 5	0,99	4,85	0,88	

Tabela 37 - Resultados - rede PMC - 3 camadas ocultas - Bd100 - EQM  $1e^{-2}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
3	$1e^{-2}$	5-5-5	2I1 - 1	0,96	9,33	0,48	0,86
			2I1 - 2	0,96	5,55	0,77	
			2I1 - 3	0,95	3,85	0,85	
			2I1 - 4	0,96	3,42	0,86	
			2I1 - 5	0,96	5,16	0,84	
		10-10-10	2J1 - 1	0,96	2,88	0,91	0,92
			2J1 - 2	0,96	3,39	0,92	
			2J1 - 3	0,97	4,77	0,77	
			2J1 - 4	0,95	4,25	0,80	
			2J1 - 5	0,99	3,54	0,84	
		15-15-15	2K1 - 1	0,95	4,07	0,84	0,88
			2K1 - 2	0,99	4,65	0,82	
			2K1 - 3	0,96	3,52	0,88	
			2K1 - 4	0,97	5,87	0,73	
			2K1 - 5	0,96	6,88	0,51	
		20-20-20	2L1 - 1	0,96	4,48	0,80	0,90
			2L1 - 2	0,95	3,47	0,90	
			2L1 - 3	0,96	4,24	0,87	
			2L1 - 4	0,96	4,46	0,72	
			2L1 - 5	0,96	4,31	0,77	

Tabela 38 - Resultados - rede PMC - 3 camadas ocultas - Bd100 - EQM  $9e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
3	$9e^{-3}$	5 -5 -5	2I2 - 1	0,96	4,91	0,82	0,89
			2I2 - 2	0,96	5,24	0,75	
			2I2 - 3	0,95	5,15	0,78	
			2I2 - 4	0,96	3,88	0,88	
			2I2 - 5	0,97	3,87	0,89	
		10 -10 -10	2J2 - 1	0,96	3,96	0,86	0,88
			2J2 - 2	0,98	4,35	0,88	
			2J2 - 3	0,96	4,70	0,82	
			2J2 - 4	0,96	9,48	0,62	
			2J2 - 5	0,97	5,14	0,79	
		15 -15 -15	2K2 - 1	0,98	8,78	0,49	0,87
			2K2 - 2	0,96	4,32	0,87	
			2K2 - 3	0,96	4,12	0,80	
			2K2 - 4	0,97	4,69	0,80	
			2K2 - 5	0,96	5,81	0,75	
		20 -20 -20	2L2 - 1	0,96	4,47	0,77	0,81
			2L2 - 2	0,95	5,48	0,75	
			2L2 - 3	0,96	5,07	0,77	
			2L2 - 4	0,96	5,67	0,73	
			2L2 - 5	0,96	4,49	0,81	

Tabela 39 - Resultados - rede PMC - 3 camadas ocultas - Bd100 - EQM  $7e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
3	$7e^{-3}$	5 -5 -5	2I3 - 1	0,97	5,71	0,64	0,86
			2I3 - 2	0,97	5,85	0,72	
			2I3 - 3	0,97	4,22	0,86	
			2I3 - 4	0,96	5,20	0,75	
			2I3 - 5	0,97	5,61	0,71	
		10 -10 -10	2J3 - 1	0,98	6,04	0,89	0,89
			2J3 - 2	0,98	5,92	0,75	
			2J3 - 3	0,97	3,58	0,86	
			2J3 - 4	0,98	5,48	0,79	
			2J3 - 5	0,96	4,92	0,75	
		15 -15 -15	2K3 - 1	0,98	5,98	0,70	0,89
			2K3 - 2	0,97	6,75	0,64	
			2K3 - 3	0,96	7,87	0,56	
			2K3 - 4	0,97	3,35	0,89	
			2K3 - 5	0,96	4,05	0,86	
		20 -20 -20	2L3 - 1	0,99	3,04	0,94	0,94
			2L3 - 2	0,94	4,90	0,92	
			2L3 - 3	0,96	6,34	0,76	
			2L3 - 4	0,96	4,56	0,82	
			2L3 - 5	0,96	4,10	0,83	

Tabela 40 - Resultados - rede PMC - 3 camadas ocultas - Bd100 - EQM  $5e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
3	$5e^{-3}$	5 -5 -5	2I4 - 1	0,98	4,41	0,82	0,87
			2I4 - 2	0,97	5,43	0,80	
			2I4 - 3	0,97	5,83	0,80	
			2I4 - 4	0,98	5,13	0,87	
			2I4 - 5	0,98	6,07	0,74	
		10 -10 -10	2J4 - 1	0,98	6,37	0,57	0,77
			2J4 - 2	0,98	4,98	0,75	
			2J4 - 3	0,98	4,89	0,77	
			2J4 - 4	0,98	8,58	0,51	
			2J4 - 5	0,97	6,01	0,70	
		15 -15 -15	2K4 - 1	0,98	3,59	0,87	0,88
			2K4 - 2	0,99	3,81	0,84	
			2K4 - 3	0,97	5,51	0,78	
			2K4 - 4	0,98	4,59	0,84	
			2K4 - 5	0,98	4,54	0,88	
		20 -20 -20	2L4 - 1	0,98	4,27	0,81	0,93
			2L4 - 2	0,98	3,65	0,93	
			2L4 - 3	0,97	6,87	0,75	
			2L4 - 4	0,98	4,28	0,84	
			2L4 - 5	0,98	5,06	0,75	

Tabela 41 - Resultados - rede PMC - 3 camadas ocultas - Bd100 - EQM  $3e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
3	$3e^{-3}$	5 -5 -5	2I5 - 1	0,99	5,68	0,73	0,88
			2I5 - 2	0,98	8,00	0,49	
			2I5 - 3	0,98	5,27	0,88	
			2I5 - 4	0,98	4,94	0,76	
			2I5 - 5	0,98	6,30	0,84	
		10 -10 -10	2J5 - 1	0,99	4,84	0,83	0,93
			2J5 - 2	0,98	4,29	0,93	
			2J5 - 3	0,98	5,67	0,67	
			2J5 - 4	0,98	4,79	0,78	
			2J5 - 5	0,99	8,12	0,53	
		15 -15 -15	2K5 - 1	0,98	5,62	0,71	0,88
			2K5 - 2	0,98	3,86	0,84	
			2K5 - 3	0,98	5,15	0,80	
			2K5 - 4	0,99	2,93	0,88	
			2K5 - 5	0,99	3,99	0,85	
		20 -20 -20	2L5 - 1	0,98	5,06	0,70	0,81
			2L5 - 2	0,98	5,79	0,66	
			2L5 - 3	0,99	4,76	0,81	
			2L5 - 4	0,98	6,58	0,66	
			2L5 - 5	0,99	6,78	0,57	

Tabela 42 - Resultados - rede PMC - 3 camadas ocultas - Bd100 - EQM  $1e^{-3}$ 

Quantidade de camadas ocultas	Erro quadrático médio	Quantidade de neurônios nas camadas ocultas	Conjunto de Treinamento		Conjunto de Validação		
			Seqüência	R <sup>2</sup>	RMSE Kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
3	1 e <sup>-3</sup>	5 -5 -5	2I6 - 1	0,99	3,91	0,78	0,71
			2I6 - 2	0,99	5,29	0,64	
			2I6 - 3	0,99	6,07	0,71	
			2I6 - 4	0,99	9,16	0,42	
			2I6 - 5	0,99	5,49	0,68	
		10 -10 -10	2I6 - 1	0,99	6,48	0,65	0,86
			2I6 - 2	0,99	9,57	0,47	
			2I6 - 3	0,99	5,59	0,73	
			2I6 - 4	0,99	4,53	0,82	
			2I6 - 5	0,99	3,38	0,86	
		15 -15 -15	2K6 - 1	0,99	6,11	0,70	0,84
			2K6 - 2	0,99	4,27	0,83	
			2K6 - 3	0,99	5,36	0,71	
			2K6 - 4	0,99	4,88	0,82	
			2K6 - 5	0,99	4,43	0,84	
		20 -20 -20	2L6 - 1	0,99	6,16	0,68	0,82
			2L6 - 2	0,99	6,11	0,70	
			2L6 - 3	0,99	6,85	0,70	
			2L6 - 4	0,99	5,21	0,82	
			2L6 - 5	0,99	6,26	0,72	

### 4.3 Resultados dos Testes do Método 3

O método 3 utilizou a rede RBF, com a base de dados Bd121 e as Tabelas 43 a 48 apresentam os resultados dos testes com a metodologia delineada para métodos 3A à 3C com os 3 valores escolhidos para o índice spread e os 6 valores escolhidos do erro quadrático médio para o aprendizado.

Tabela 43 - Resultados - rede RBF - Bd121 – EQM  $1e^{-2}$

Erro quadrático médio	Spread	Conjunto de Treinamento		Conjunto de Validação		
		Seqüência	R <sup>2</sup>	RMSE kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
$1 e^{-2}$	0,1	3A1 - 1	1	22,14	0,27	0,36
		3A1 - 2	1	25,05	0,22	
		3A1 - 3	1	22,44	0,36	
		3A1 - 4	1	23,24	0,33	
		3A1 - 5	1	25,35	0,22	
	1	3B1 - 1	1	21,64	0,46	0,47
		3B1 - 2	1	20,05	0,24	
		3B1 - 3	1	39,42	0,32	
		3B1 - 4	1	18,05	0,47	
		3B1 - 5	1	21,65	0,45	
	10	3C1 - 1	1	33,91	0,49	0,49
		3C1 - 2	1	37,79	0,31	
		3C1 - 3	1	38,95	0,27	
		3C1 - 4	1	20,35	0,44	
		3C1 - 5	1	30,79	0,21	

Tabela 44 - Resultados - rede RBF - Bd121 – EQM  $9e^{-3}$ 

Erro quadrático médio	Spread	Conjunto de Treinamento		Conjunto de Validação		
		Seqüência	R <sup>2</sup>	RMSE kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
$9 e^{-3}$	0,1	3A2 - 1	1	23,94	0,31	0,31
		3A2 - 2	1	27,23	0,22	
		3A2 - 3	1	25,26	0,20	
		3A2 - 4	1	26,93	0,21	
		3A2 - 5	1	24,14	0,24	
	1	3B2 - 1	1	19,83	0,51	0,54
		3B2 - 2	1	21,61	0,54	
		3B2 - 3	1	34,14	0,26	
		3B2 - 4	1	27,67	0,22	
		3B2 - 5	1	22,09	0,28	
	10	3C2 - 1	1	20,32	0,59	0,59
		3C2 - 2	1	36,50	0,20	
		3C2 - 3	1	40,15	0,45	
		3C2 - 4	1	43,22	0,31	
		3C2 - 5	1	36,72	0,21	

Tabela 45 - Resultados - rede RBF - Bd121 – EQM  $7e^{-3}$ 

Erro quadrático médio	Spread	Conjunto de Treinamento		Conjunto de Validação		
		Seqüência	R <sup>2</sup>	RMSE kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
$7 e^{-3}$	0,1	3A3 - 1	1	24,33	0,24	0,29
		3A3 - 2	1	24,85	0,27	
		3A3 - 3	1	25,81	0,24	
		3A3 - 4	1	24,95	0,29	
		3A3 - 5	1	24,74	0,27	
	1	3B3 - 1	1	17,75	0,49	0,49
		3B3 - 2	1	21,30	0,36	
		3B3 - 3	1	31,69	0,32	
		3B3 - 4	1	19,91	0,48	
		3B3 - 5	1	21,46	0,41	
	10	3C3 - 1	1	31,32	0,46	0,48
		3C3 - 2	1	21,05	0,41	
		3C3 - 3	1	21,62	0,48	
		3C3 - 4	1	24,45	0,23	
		3C3 - 5	1	22,55	0,38	

Tabela 46 - Resultados - rede RBF - Bd121 – EQM  $5e^{-3}$ 

Erro quadrático médio	Spread	Conjunto de Treinamento		Conjunto de Validação		
		Seqüência	R <sup>2</sup>	RMSE kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
$5 e^{-3}$	0,1	3A4 - 1	1	26,16	0,28	0,36
		3A4 - 2	1	22,14	0,27	
		3A4 - 3	1	25,05	0,22	
		3A4 - 4	1	22,44	0,36	
		3A4 - 5	1	22,61	0,33	
	1	3B4 - 1	1	21,68	0,56	0,56
		3B4 - 2	1	30,54	0,45	
		3B4 - 3	1	29,15	0,41	
		3B4 - 4	1	24,14	0,30	
		3B4 - 5	1	32,07	0,24	
	10	3C4 - 1	1	33,91	0,49	0,49
		3C4 - 2	1	37,79	0,31	
		3C4 - 3	1	38,95	0,27	
		3C4 - 4	1	20,35	0,44	
		3C4 - 5	1	24,07	0,27	

Tabela 47 - Resultados - rede RBF - Bd121 – EQM  $3e^{-3}$ 

Erro quadrático médio	Spread	Conjunto de Treinamento		Conjunto de Validação		
		Seqüência	R <sup>2</sup>	RMSE kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
$3 e^{-3}$	0,1	3A5 - 1	1	26,28	0,23	0,24
		3A5 - 2	1	25,26	0,20	
		3A5 - 3	1	26,41	0,21	
		3A5 - 4	1	24,18	0,24	
		3A5 - 5	1	24,90	0,22	
	1	3B5 - 1	1	20,05	0,52	0,54
		3B5 - 2	1	21,44	0,54	
		3B5 - 3	1	34,63	0,26	
		3B5 - 4	1	23,81	0,31	
		3B5 - 5	1	22,03	0,33	
	10	3C5 - 1	1	21,33	0,58	0,58
		3C5 - 2	1	36,50	0,20	
		3C5 - 3	1	40,15	0,45	
		3C5 - 4	1	45,72	0,35	
		3C5 - 5	1	36,23	0,22	

Tabela 48 - Resultados - rede RBF - Bd121 – EQM  $1e^{-3}$ 

Erro quadrático médio	Spread	Conjunto de Treinamento		Conjunto de Validação		
		Seqüência	R <sup>2</sup>	RMSE kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
$1 e^{-3}$	0,1	3A6 - 1	1	22,91	0,29	0,29
		3A6 - 2	1	15,57	0,21	
		3A6 - 3	1	24,05	0,21	
		3A6 - 4	1	23,56	0,26	
		3A6 - 5	1	24,64	0,20	
	1	3B6 - 1	1	27,90	0,65	0,65
		3B6 - 2	1	18,93	0,39	
		3B6 - 3	1	22,43	0,39	
		3B6 - 4	1	18,68	0,47	
		3B6 - 5	1	20,56	0,25	
	10	3C6 - 1	1	21,91	0,50	0,50
		3C6 - 2	1	29,42	0,24	
		3C6 - 3	1	46,63	0,21	
		3C6 - 4	1	23,59	0,28	
		3C6 - 5	1	32,59	0,22	

#### 4.4 Resultados dos Testes do Método 4

O método 4 utilizou a rede RBF, com a base de dados Bd100 e as Tabelas 49 a 54 apresentam os resultados dos testes com a metodologia delineada para métodos 4A a 4C com os 3 valores escolhidos para o índice spread e os 6 valores escolhidos do erro quadrático médio para o aprendizado.

Tabela 49 - Resultados - rede RBF - Bd100 – EQM  $1e^{-2}$

Erro quadrático médio	Spread	Conjunto de Treinamento		Conjunto de Validação		
		Seqüência	R <sup>2</sup>	RMSE kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
$1 e^{-2}$	0,1	4A1 - 1	1	7,68	0,44	0,44
		4A1 - 2	1	11,31	0,22	
		4A1 - 3	1	7,94	0,43	
		4A1 - 4	1	8,08	0,36	
		4A1 - 5	1	9,37	0,27	
	1	4B1 - 1	1	8,30	0,67	0,80
		4B1 - 2	1	8,78	0,55	
		4B1 - 3	1	6,42	0,79	
		4B1 - 4	1	5,64	0,69	
		4B1 - 5	1	5,46	0,80	
	10	4C1 - 1	1	16,16	0,49	0,70
		4C1 - 2	1	11,11	0,38	
		4C1 - 3	1	11,19	0,31	
		4C1 - 4	1	7,53	0,70	
		4C1 - 5	1	16,97	0,22	

Tabela 50 - Resultados - rede RBF - Bd100 – EQM  $9e^{-3}$ 

Erro quadrático médio	Spread	Conjunto de Treinamento		Conjunto de Validação		
		Seqüência	R <sup>2</sup>	RMSE kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
$9 e^{-3}$	0,1	4A2 - 1	1	10,06	0,34	0,38
		4A2 - 2	1	8,63	0,37	
		4A2 - 3	1	8,84	0,26	
		4A2 - 4	1	8,64	0,38	
		4A2 - 5	1	8,95	0,20	
	1	4B2 - 1	1	9,81	0,58	0,69
		4B2 - 2	1	8,23	0,64	
		4B2 - 3	1	5,39	0,69	
		4B2 - 4	1	34,69	0,48	
		4B2 - 5	1	7,85	0,69	
	10	4C2 - 1	1	19,87	0,56	0,59
		4C2 - 2	1	14,55	0,25	
		4C2 - 3	1	10,84	0,39	
		4C2 - 4	1	9,04	0,42	
		4C2 - 5	1	8,76	0,59	

Tabela 51 - Resultados - rede RBF - Bd100 – EQM  $7e^{-3}$ 

Erro quadrático médio	Spread	Conjunto de Treinamento		Conjunto de Validação		
		Seqüência	R <sup>2</sup>	RMSE kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
$7 e^{-3}$	0,1	4A3 - 1	1	9,14	0,29	0,49
		4A3 - 2	1	8,53	0,49	
		4A3 - 3	1	9,69	0,32	
		4A3 - 4	1	10,92	0,28	
		4A3 - 5	1	8,86	0,32	
	1	4B3 - 1	1	6,42	0,73	0,73
		4B3 - 2	1	7,35	0,66	
		4B3 - 3	1	7,15	0,71	
		4B3 - 4	1	6,08	0,66	
		4B3 - 5	1	16,66	0,28	
	10	4C3 - 1	1	6,31	0,65	0,65
		4C3 - 2	1	13,09	0,44	
		4C3 - 3	1	24,15	0,26	
		4C3 - 4	1	31,49	0,25	
		4C3 - 5	1	17,65	0,28	

Tabela 52 - Resultados - rede RBF - Bd100 – EQM  $5e^{-3}$ 

Erro quadrático médio	Spread	Conjunto de Treinamento		Conjunto de Validação		
		Seqüência	R <sup>2</sup>	RMSE kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
$5 e^{-3}$	0,1	4A4 - 1	1	9,75	0,38	0,46
		4A4 - 2	1	8,37	0,46	
		4A4 - 3	1	9,56	0,25	
		4A4 - 4	1	9,77	0,24	
		5A4 - 5	1	8,71	0,26	
	1	4B4 - 1	1	6,85	0,74	0,75
		4B4 - 2	1	10,31	0,49	
		4B4 - 3	1	7,65	0,75	
		4B4 - 4	1	9,51	0,42	
		4B4 - 5	1	9,17	0,51	
	10	4C4 - 1	1	38,07	0,46	0,46
		4C4 - 2	1	11,19	0,35	
		4C4 - 3	1	16,17	0,21	
		4C4 - 4	1	10,58	0,46	
		4C4 - 5	1	19,60	0,41	

Tabela 53 - Resultados - rede RBF - Bd100 – EQM  $3e^{-3}$ 

Erro quadrático médio	Spread	Conjunto de Treinamento		Conjunto de Validação		
		Seqüência	R <sup>2</sup>	RMSE kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
$3 e^{-3}$	0,1	4A5 - 1	1	8,79	0,27	0,46
		4A5 - 2	1	9,27	0,20	
		4A5 - 3	1	9,54	0,31	
		4A5 - 4	1	7,98	0,46	
		4A5 - 5	1	8,95	0,32	
	1	4B5 - 1	1	5,90	0,78	0,83
		4B5 - 2	1	4,06	0,83	
		4B5 - 3	1	5,58	0,73	
		4B5 - 4	1	7,89	0,53	
		4B5 - 5	1	7,42	0,65	
	10	4C5 - 1	1	11,45	0,47	0,57
		4C5 - 2	1	15,01	0,46	
		4C5 - 3	1	17,91	0,25	
		4C5 - 4	1	8,24	0,57	
		4C5 - 5	1	11,00	0,54	

Tabela 54 - Resultados - rede RBF - Bd100 – EQM  $1e^{-3}$ 

Erro quadrático médio	Spread	Conjunto de Treinamento		Conjunto de Validação		
		Seqüência	R <sup>2</sup>	RMSE kg. ha <sup>-1</sup>	R <sup>2</sup>	R <sup>2</sup> máximo
$1e^{-3}$	0,1	4A6 - 1	1	8,00	0,40	0,40
		4A6 - 2	1	9,67	0,32	
		4A6 - 3	1	9,30	0,24	
		4A6 - 4	1	9,71	0,40	
		4A6 - 5	1	9,28	0,35	
	1	4B6 - 1	1	7,29	0,63	0,67
		4B6 - 2	1	24,47	0,33	
		4B6 - 3	1	8,46	0,58	
		4B6 - 4	1	7,22	0,67	
		4B6 - 5	1	6,48	0,58	
	10	4C6 - 1	1	15,69	0,53	0,53
		4C6 - 2	1	26,70	0,21	
		4C6 - 3	1	9,18	0,40	
		4C6 - 4	1	19,51	0,20	
		4C6 - 5	1	22,11	0,24	

#### 4.5 Comparações dos Resultados dos Testes

As comparações entre os resultados dos testes com as redes PMC e RBF com as bases de dados Bd121 e Bd100 são descritas a seguir. Foram utilizados os valores máximos do coeficiente de determinação  $R^2$  como critério da escolha do método que estima a melhor correlação entre os valores calculados das quantidades de nitrogênio absorvido pelas plantas através do processamento das refletâncias pelos algoritmos das redes neurais, comparados com os valores da quantidade de nitrogênio medidos nas amostras de material foliar, para cada configuração da rede neural utilizada.

As Figuras 19, 20, 21 e 22 apresentam as comparações dos valores máximos do índice de determinação  $R^2$  encontrados nos testes que utilizaram a base de dados Bd121. Os testes com a rede PMC, utilizando 1 camada oculta de neurônios e os 6 valores escolhidos do erro quadrático médio para o aprendizado estão apresentados na Figura 19 e o maior valor do índice de determinação  $R^2$  (0,75) foi encontrado no teste com 10 neurônios e com o valor  $5 \times 10^{-3}$  para o EQM.

A Figura 20 apresenta os resultados dos maiores valores do índice de determinação  $R^2$  encontrados durante os testes com a base de dados Bd121 e a rede PMC com 2 camadas ocultas de neurônios e os 6 valores escolhidos do erro quadrático médio para o aprendizado. O maior valor do índice de determinação  $R^2$  (0,86) foi encontrado no teste com 5 neurônios em cada uma das 2 camadas ocultas e com o valor  $5 \times 10^{-3}$  para o EQM.

A Figura 21 apresenta os resultados dos maiores valores do índice de determinação  $R^2$  encontrados durante os testes com a base de dados Bd121 e a rede PMC com 3 camadas ocultas de neurônios e os 6 valores escolhidos do erro quadrático médio para o aprendizado. O maior valor do índice de determinação  $R^2$  (0,83) foi encontrado no teste com 10 neurônios em cada uma das 3 camadas ocultas e com o valor  $9 \times 10^{-3}$  para o EQM.

A Figura 22 apresenta os resultados dos maiores valores do índice de determinação  $R^2$  encontrados durante os testes com a base de dados Bd121 e a rede RBF. Nas repetições dos testes foram utilizados 3 valores para o índice spread (0,1 – 1 – 10) e os 6 valores escolhidos do erro quadrático médio para o aprendizado. O maior valor do índice de determinação  $R^2$  (0,65) foi encontrado no teste com 1 no valor do índice spread e com o valor  $1 \times 10^{-3}$  para o EQM.




Figura 19 - Maiores valores de  $R^2$  do método 1 - PMC - Bd121 - 1 camada oculta




Figura 20 - Maiores valores de  $R^2$  do método 1 - PMC - Bd121 - 2 camadas ocultas




Figura 21 - Maiores valores de  $R^2$  do método 1 - PMC - Bd121 - 3 camadas ocultas




Figura 22 - Maiores valores de  $R^2$  - método 3 - RBF - Bd121 - 3 índices spread

As Figuras 23, 24, 25 e 26 apresentam as comparações dos valores máximos do índice de determinação  $R^2$  encontrados nos testes que utilizaram a base de dados Bd100. Os testes com a rede PMC, utilizando 1 camada oculta de neurônios e os 6 valores escolhidos do erro quadrático médio para o aprendizado estão apresentados na Figura 23 e o maior valor do índice de determinação  $R^2$  (0,92) foi encontrado no teste com 5 neurônios e com o valor  $7 \times 10^{-3}$  para o EQM.

A Figura 24 apresenta os resultados dos maiores valores do índice de determinação  $R^2$  encontrados durante os testes com a base de dados Bd100 e a rede PMC com 2 camadas ocultas de neurônios e os 6 valores escolhidos do erro quadrático médio para o aprendizado. O maior valor do índice de determinação  $R^2$  (0,93) foi encontrado no teste com 10 neurônios em cada uma das 2 camadas ocultas e com o valor  $3 \times 10^{-3}$  para o EQM.

A Figura 25 apresenta os resultados dos maiores valores do índice de determinação  $R^2$  encontrados durante os testes com a base de dados Bd100 e a rede PMC com 3 camadas ocultas de neurônios e os 6 valores escolhidos do erro quadrático médio para o aprendizado. O maior valor do índice de determinação  $R^2$  (0,94) foi encontrado no teste com 20 neurônios em cada uma das 3 camadas ocultas e com o valor  $7 \times 10^{-3}$  para o EQM.

A Figura 26 apresenta os resultados dos maiores valores do índice de determinação  $R^2$  encontrados durante os testes com a base de dados Bd100 e a rede RBF. Nas repetições dos testes foram utilizados 3 valores para o índice spread (0,1 – 1 – 10) e os 6 valores escolhidos do erro quadrático médio para o aprendizado. O maior valor do índice de determinação  $R^2$  (0,83) foi encontrado no teste com 1 no valor do índice spread e com o valor  $3 \times 10^{-3}$  para o EQM.

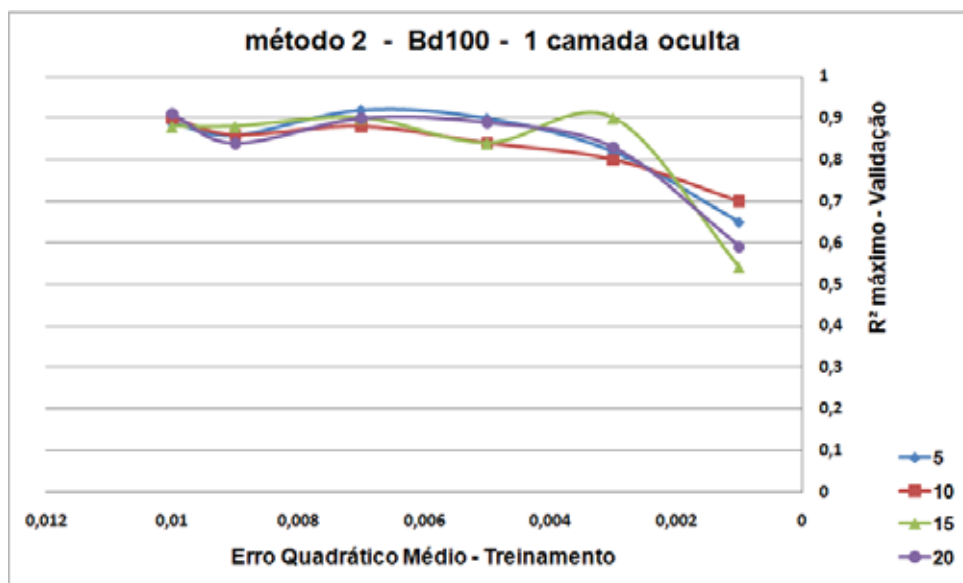


Figura 23 - Maiores valores de  $R^2$  do método 2 - PMC - Bd100 - 1 camada oculta




Figura 24 - Maiores valores de  $R^2$  do método 2 - PMC - Bd100 - 2 camadas ocultas




Figura 25 - Maiores valores de  $R^2$  do método 2 - PMC - Bd100 - 3 camadas ocultas

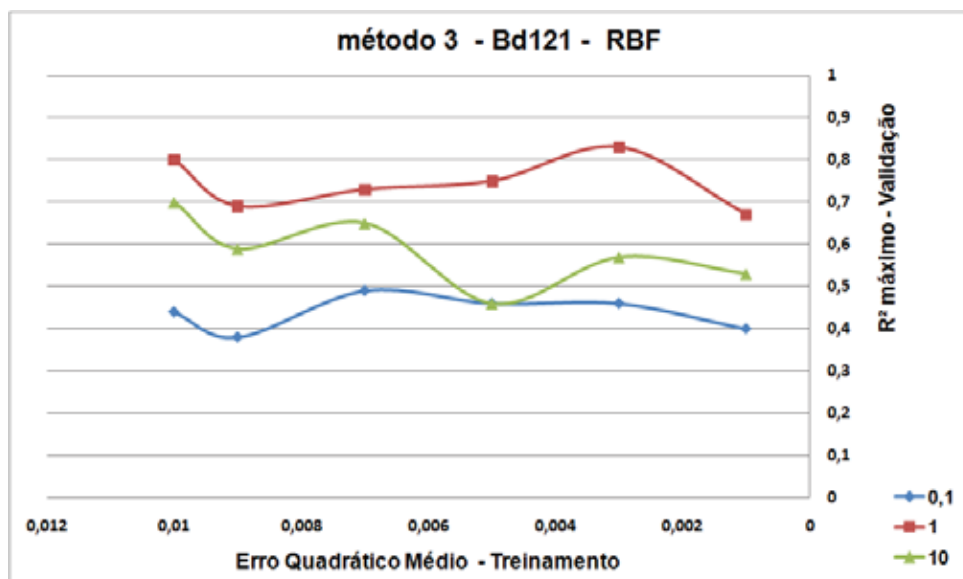


Figura 26 - Maiores valores de  $R^2$  do método 4 - RBF - Bd100 - 3 índices spread

A Tabela 55 apresenta as comparações entre os melhores resultados do coeficiente de determinação  $R^2$  de cada configuração de rede neural testadas com a base de dados Bd121 e o resultado da quantidade de nitrogênio absorvido pelas plantas calculado diretamente no sensor óptico. O teste com a rede neural PMC do método 1, seqüência 1E2 – 4, com 5 neurônios em cada uma das 2 camadas ocultas apresentou o maior resultado do índice de determinação  $R^2$  com o valor de 0,86 entre os valores dos índices testados com a base de dados Bd121. Este valor é maior que o valor 0,69 obtido diretamente nos resultados da base de dados Bd121 e indica uma melhor correlação nos resultados obtidos com o sensor óptico para medir a quantidade de nitrogênio absorvido pelas plantas, comparando os resultados obtidos pelo sensor com os resultados obtidos nas amostras de material foliar medidas em laboratório. A configuração de rede neural da seqüência 1E2 – 4 também apresentou o valor RMSE 6,67 e os dados da base de dados Bd121 apresentaram o valor RMSE 13,70 conforme a Tabela 3.

Tabela 55 - Maiores resultados - PMC e RBF - Bd121 e resultado do sensor óptico

Método	Sensor óptico com rede neural				Sensor óptico direto		
	Rede	Camadas ocultas	Seqüência	RMSE kg. ha-1	$R^2$ Validação	RMSE kg. ha-1	$R^2$
1	PMC	1	1C4 - 1	15,09	0,75		
1	PMC	2	1E2 - 4	6,67	0,86		
1	PMC	3	1J2 - 3	10,92	0,83	13,70	0,69
3	RBF	-	3B6 - 1	27,90	0,65		

A Tabela 56 apresenta as comparações entre os melhores resultados do coeficiente de determinação  $R^2$  de cada configuração de rede neural testadas com a base de dados Bd100 e o resultado da quantidade de nitrogênio absorvido pelas plantas calculado diretamente no sensor óptico. O resultado apresentado dos testes com a rede neural PMC utilizando o método 2, seqüência 2L3 – 1, com 3 camadas ocultas de 20 neurônios em cada uma das camadas apresentou o maior resultado entre os valores do índice de determinação  $R^2$  com o valor de 0,94. Este valor é maior que o valor 0,84 obtido diretamente nos resultados da base de dados Bd100 e indica a correlação do sensor óptico para medir a quantidade de nitrogênio absorvido pelas plantas, comparando os resultados obtidos pelo sensor com os resultados obtidos nas amostras de material foliar medidas em laboratório. Esta configuração de rede também

apresentou o valor RMSE 3,04 e os dados da base de dados Bd100 apresentaram o valor RMSE 4,26 conforme a Tabela 3.

Tabela 56 - Maiores resultados - PMC e RBF - Bd100 e resultado do sensor óptico

Método	Sensor óptico com rede neural				Sensor óptico direto		
	Rede	Camadas ocultas	Seqüência	RMSE kg. ha-1	R <sup>2</sup> Validação	RMSE kg. ha-1	R <sup>2</sup>
1	PMC	1	2A3 - 1	2,46	0,92		
1	PMC	2	2F5 - 3	6,67	0,93		
1	PMC	3	2L3 - 1	3,04	0,94	4,26	0,84
3	RBF	-	4B5 - 2	4,06	0,83		

#### 4.6 Gráficos dos Testes da Rede PMC, Seqüência 1E2 - 4

A Figura 27 apresenta o gráfico do resultado do treinamento realizado no teste pela rede PMC com 2 camadas ocultas e com a base de dados Bd121 na seqüência 1E2 - 4, que apresentou na Tabela 57 o maior resultado do coeficiente de determinação ( $R^2 = 0,86$ ). O gráfico que mostra a regressão linear dos valores obtidos no treinamento da rede com os valores estimados de nitrogênio através da refletância e dos valores de nitrogênio medido em laboratório são apresentados na Figura 28 e os dados de nitrogênio calculado estão normalizados entre os valores -1 e 1. A Figura 29 mostra o gráfico da regressão linear dos valores obtidos na validação da rede e a escala dos dados de nitrogênio calculado e laboratório estão ajustados para  $\text{kg. ha}^{-1}$ . O gráfico 30 mostra a comparação entre os valores da base de dados e os valores calculados durante a validação e a escala dos valores de nitrogênio normalizados estão ajustados para -1 e 1.




Figura 27 - Gráfico do Treinamento da rede PMC - seqüência 1E2 - 4




Figura 28 - Gráfico da Regressão linear do Treinamento da rede - seqüência 1E2 - 4




Figura 29 - Gráfico da Regressão linear da Validação da rede - seqüência 1E2 - 4

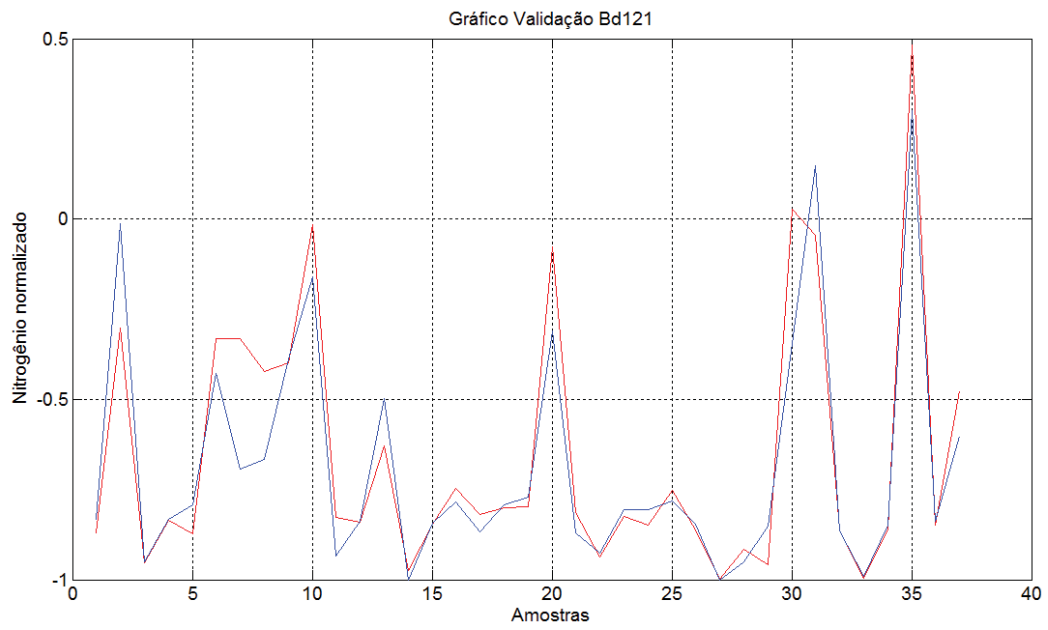


Figura 30 - Gráfico da Validação da base de dados - seqüência 1E2 - 4

#### 4.7 Gráficos dos Testes da Rede PMC, Seqüência 2L3 - 1

A Figura 31 apresenta o gráfico do resultado do treinamento realizado no teste pela rede PMC com 3 camadas ocultas e com a base de dados Bd100, que apresentou na Tabela 56 o maior resultado do coeficiente de determinação ( $R^2 = 0,94$ ) na seqüência 2L3-1. O gráfico que mostra a regressão linear dos valores obtidos no treinamento da rede com os valores estimados de nitrogênio através da refletância medida e dos valores de nitrogênio medido em laboratório são apresentados na Figura 32 e os dados de nitrogênio calculado estão normalizados entre os valores -1 e 1. A Figura 33 mostra o gráfico da regressão linear dos valores obtidos na validação da rede e a escala dos dados de nitrogênio calculado e laboratório estão ajustados para  $\text{kg. ha}^{-1}$ . O gráfico 34 mostra a comparação entre os valores da base de dados e os valores calculados durante a validação e a escala dos valores de nitrogênio normalizados estão ajustados para -1 e 1.

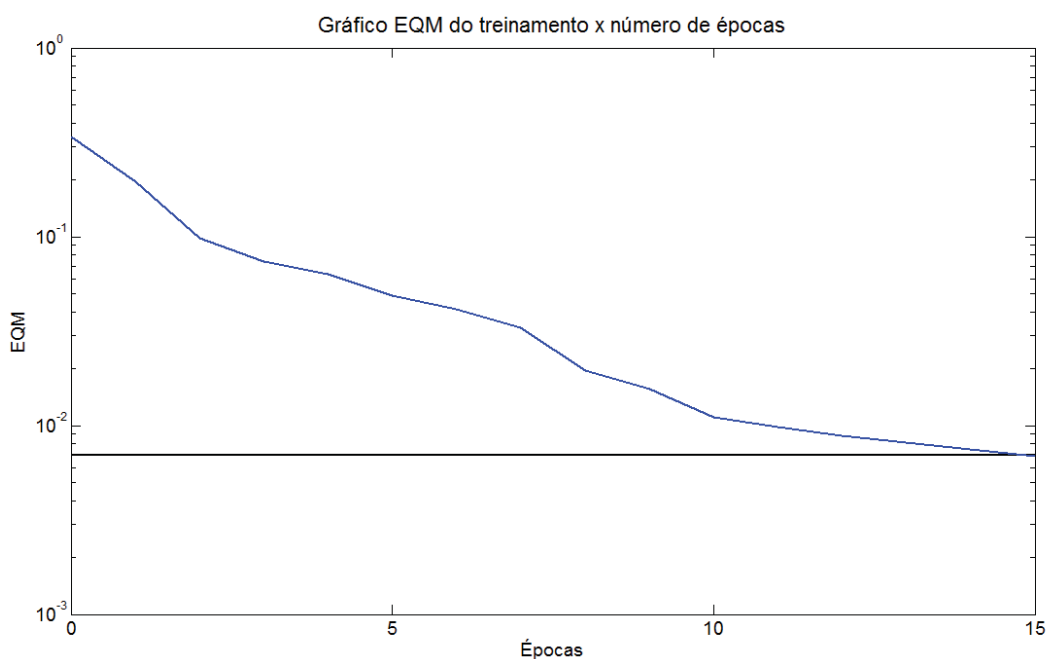


Figura 31 - Gráfico do Treinamento da rede PMC - seqüência 2L3 - 1

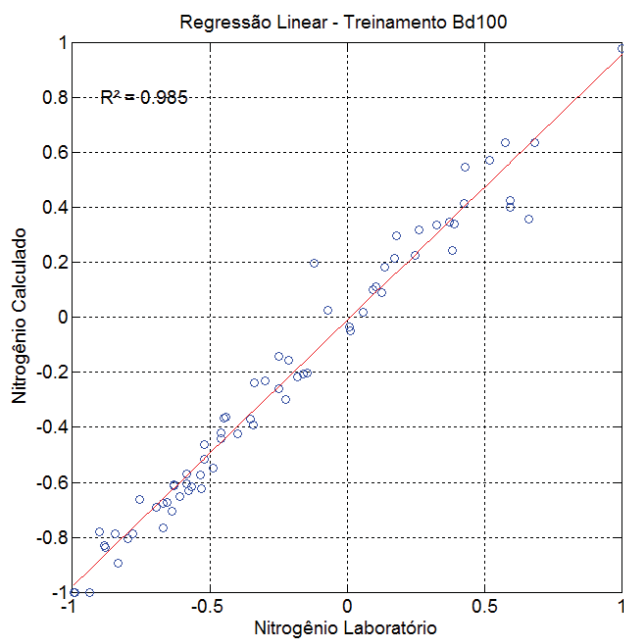


Figura 32 - Gráfico da Regressão linear do Treinamento da rede - seqüência 2L3 - 1

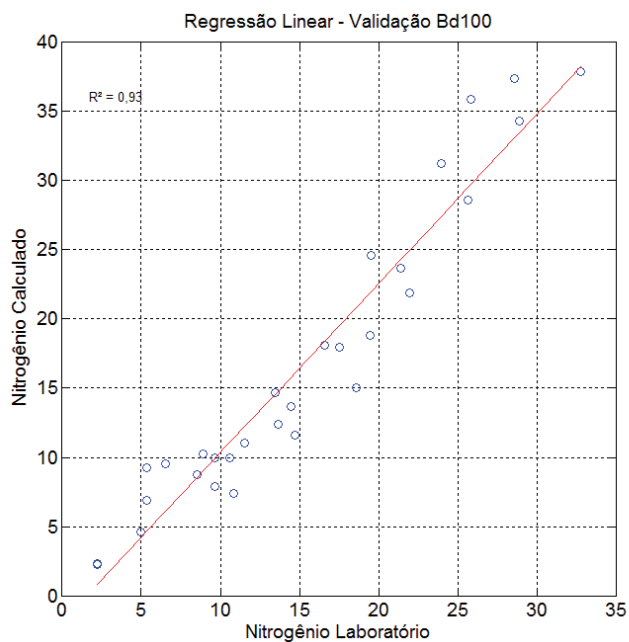


Figura 33 - Gráfico da Regressão linear da Validação da rede - seqüência 2L3 - 1

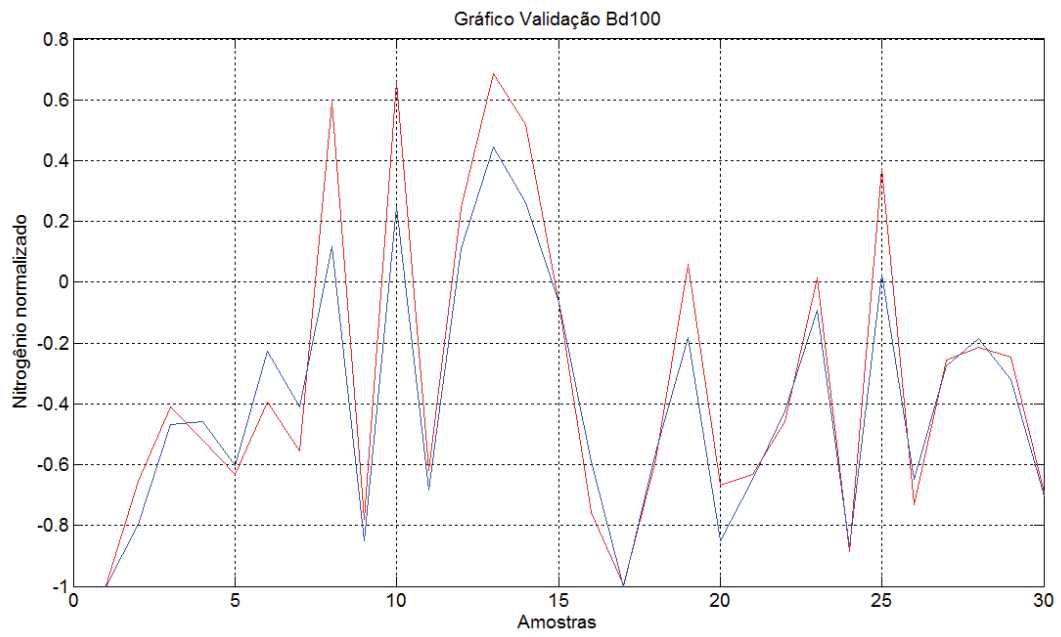


Figura 34 - Gráfico da Validação da base de dados - seqüência 2L3 - 1

## 5 CONCLUSÕES E RECOMENDAÇÕES

As pesquisas realizadas durante esta dissertação compararam os dados de leitura de refletância das folhas da cana-de-açúcar no estágio inicial de crescimento obtido diretamente com o sensor óptico com os dados das análises de laboratório que mediram a quantidade de nitrogênio nas amostras de material foliar e também os dados dos valores de refletância obtidos na saída do sensor óptico referentes a 4 comprimentos de onda com e sem a iluminação da lâmpada flash de cada lado do sensor (esquerdo e direito) totalizando as 16 amostras para cada posição georeferenciada. Os dados foram processados com algoritmos baseados em dois tipos de redes neurais com o objetivo de encontrar uma melhor correlação entre os 16 valores de refletâncias coletados pelo sensor óptico e os resultados da análise de nitrogênio do material foliar coletado; a arquitetura dos dados aplicados nas redes neurais esta apresentada na figura 35. Os resultados obtidos com o processamento das redes neurais foram superiores aos resultados obtidos diretamente no sensor óptico, apesar da quantidade de amostras ter sido reduzida.

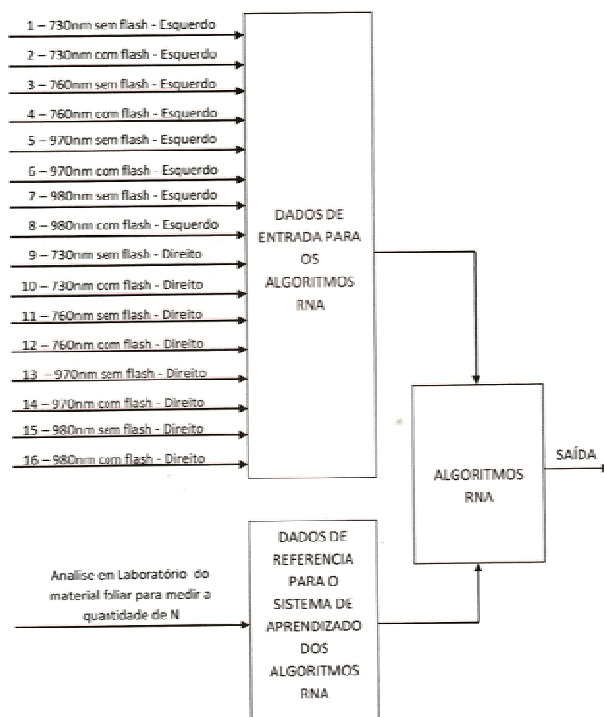


Figura 35 – Arquitetura dos dados aplicados nas redes neurais.

As conclusões obtidas durante as pesquisas, testes e a elaboração desta dissertação estão descritas a seguir.

1 - O valor de 0,86 do índice de determinação  $R^2$  obtido no método 1 dos testes com a rede PMC com 2 camadas ocultas de 5 neurônios cada uma é maior que o valor 0,69 obtido pelo cálculo do índice de determinação  $R^2$  dos dados da base de dados Bd121 com 121 dados georreferenciados que apresentou saturação na leitura de refletâncias para 21 valores de nitrogênio maiores que  $40 \text{ kg. ha}^{-1}$ , indicando que é possível correlacionar com melhor precisão os dados obtidos diretamente do sensor óptico.

2 - Para a base de dados Bd100 que utilizou os dados da base de dados Bd121 e foi eliminado manualmente 21 dados que apresentaram saturação da leitura do sensor óptico para valores de nitrogênio maiores que  $40 \text{ kg. ha}^{-1}$  o valor calculado do índice de determinação  $R^2$  foi de 0,84. O valor de 0,94 do índice de determinação  $R^2$  obtido através dos testes com a rede PMC no método 2 com 3 camadas ocultas de 20 neurônios em cada uma é maior que o valor 0,84 e indica que é possível obter uma melhor precisão na correlação dos dados de refletância para os valores de nitrogênio medido nas plantas.

3 - As Figuras 19 a 22 e 23 a 26 mostram que é possível obter resultados melhores com as redes neurais simulando valores diferentes para o erro quadrático médio durante o treinamento das redes.

4 - Os resultados dos coeficientes de determinação  $R^2$  indicam que para o conjunto de dados utilizados nos testes, os modelos de redes neurais PMC obtiveram melhor desempenho se comparado com os resultados das redes RBF.

5 - As pesquisas realizadas durante a elaboração desta dissertação utilizando a base de dados coletadas durante um ensaio de campo utilizando o sensor óptico N-Sensor e os resultados obtidos nos testes com os métodos 1 a 4 propõem que pode ser melhorado a precisão dos resultados fornecidos pelo sensor óptico utilizado para a medição em tempo real do teor de nitrogênio por refletância em plantas de cana-de-açúcar no estágio inicial do crescimento, aplicando uma nova abordagem baseada em sistemas inteligentes aplicados à ambientes agrícolas utilizando Redes Neurais Artificiais.

Para trabalhos futuros relacionados com os sensores ópticos que medem as refletâncias das plantas para correlacionar com os valores de nitrogênio absorvido pelas plantas, sugerimos estudos sobre a saturação encontrada nos valores de refletância durante as

leituras das plantas de cana-de-açúcar no estágio inicial do crescimento e testes com sistemas inteligentes que utilizam modelos de inferência *neuro-fuzzy* ANFIS para melhorar as correlações dos valores de refletância com os valores estimados de nitrogênio absorvido pelas plantas de cana-de-açúcar.

## BIBLIOGRAFIAS

- ADAMCHUCK, V.I., Development of on-the-go soil sensor systems. **In: Proceedings of the First Global Workshop on High Resolution Digital Soil Sensing and Mapping**, Volume I, Sydney, Australia, 5-8 February 2008. Sydney, Australia: University of Sydney, 2008. 12 p.
- AMARAL, L. R. do. **Sensor ótico no auxílio à recomendação de nitrogênio para a cultura de cana-de-açúcar**. 2010. Dissertação (Mestrado em Ciências Agrárias) - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 2010. 81 p.
- ANTUNIASSI, U.R. Agricultura de precisão: aplicação localizada de agrotóxicos. In: GUEDES, J.V.C.; DORNELES, S.H.B. (Org.) **Tecnologia e segurança na aplicação dos agrotóxicos - novas tecnologias**. Santa Maria: **Departamento de Defesa Fitossanitária; Sociedade de Agronomia de Santa Maria**, 1998. p. 53-63.
- ASNER, G.P. Biophysical and biochemical sources of variability in canopy reflectance. **Remote Sensing of Environment**, 1998. v.64, p. 234-253.
- BLACK, C.A. **Soil-plant relationships**. New York: John Wiley, 1968. 792 p.
- BRAGA, A. P. et al. **Redes neurais artificiais: Teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2000. 262 p.
- CANTARELLA, H. Aplicação de nitrogênio em sistema de cana crua. **STAB – Açúcar, Álcool e Sub-Produtos, Piracicaba**, 1998. v. 16, p. 21-22.
- CANTARELLA, H.; TRIVELLIN, P.C.O.; VITTI, A.C. **Nitrogênio e enxofre na cultura da cana-de-açúcar**. In: YAMADA, T; ABDALLA, S.R.S.; VITTI, G.C. (Ed.). **Nitrogênio e enxofre na agricultura Brasileira**. Piracicaba: International plant nutrition institute, 2007. p. 355-413.
- CONAB, Companhia Nacional do Abastecimento. Avaliação da safra agrícola de cana-de-açúcar. **Ministério da Agricultura, Pecuária e Abastecimento**, 2010. 14 p.
- CURRAN, P.J. Remote sensing of foliar chemistry. **Remote Sensing of Environment**, 1989. v29, p. 271-278.
- DORNELES, S.H.B. (Org.) **Tecnologia e segurança na aplicação dos agrotóxicos - novas tecnologias**. Santa Maria: **Departamento de Defesa Fitossanitária; Sociedade de Agronomia de Santa Maria**, 1998. p.53-63.
- DIAS, L.E.; BARROS, N.F.; FRANCO, A.A. **Curso de fertilidade e manejo do solo: módulo 06 – Nitrogênio**. Viçosa: ABEAS/UFV, 1996. 80 p.
- EMBRAPA. **Amostragem de solos: A base para aplicação de corretivos e fertilizantes**. Disponível em: <[http://www.cnpms.embrapa.br/publicacoes/milho\\_6\\_ed/feramostra.htm](http://www.cnpms.embrapa.br/publicacoes/milho_6_ed/feramostra.htm)>. Acesso em: 26 jun. 2011.
- FERRARI H. V. Uma comparação entre Redes Neurais Wavelet, LMS, PMC e RBF para classificação de DPOC. **Congresso de Matemática e suas Aplicações**, 2006. p. 68-72.

FUNDAÇÃO SHUNJI NISHIMURA DE TECNOLOGIA. Disponível em <site www.fsnt.com.br> Acesso em: 23 jun. 2011.

HASHIMOTO, Y., MURASE, H., MORIMOTO, T., and TORU TORII, T. Intelligent systems for agriculture in Japan. **IEEE Control Systems Magazine**, 2001. v. 21, p. 71-85.

HUANG, W.Y.; LIPPMANN, R.P. **Comparisons** between neural net and conventional classifiers. **IEEE International Conference on Neural Networks**. San Diego. Lexington, MA: MIT Lincoln Laboratory, 1987, v.4, p. 485-493.

IAC – Instituto Agrônomo de Campinas. Disponível em: < http://www.iac.br, 2011>. Acesso em 29 jun. 2011.

LIANG, S.: **Canopy reflectance modeling, in: Quantitative remote sensing of land surfaces**, edited by: Hoboken, N. J., Wiley-Interscience, 2004. p. 76-142.

MÁQUINAS AGRÍCOLAS JACTO S/A. Disponível em: <site www.jacto.com.br, 2011>. Acesso 12 jun. 2011.

MENGBO LI, R. S. YOST. **Management-oriented modeling: optimizing nitrogen management with artificial intelligence**. *Agricultural Systems*, n. 65, 2000, p. 1-27.

MUZZILI, O. A influência do sistema de plantio direto, comparado ao convencional, sobre a fertilidade da camada arável do solo. **Revista Brasileira Ciência do Solo**, 1983. Campinas, v.7,n.1, p. 95-102.

NAGAOKA, M. E. Um método para estimar densidade de solo utilizando redes neurais artificiais. **Revisa Energ. Agric., Botucatu**, 2005. vol. 20, n. 4, p. 53-58.

NARENDA, K.; PARTHASARATHY, K. Identification and control of dynamical systems using neural networks. **IEEE Trans. on Neural Networks**, 1990. v. 1 , n. 1, p. 4-27.

NARENDA, K. Neural networks for control: theory and practice. **Proceedings of the IEEE**, 1996. v. 84, n. 10, p. 1385-1406.

NARENDA S. G., TOBY G. **Estimation of canopy parameters for inhomogeneous vegetation canopies from reflectance data: III. Trim: A model for radiative transfer in heterogeneous three-dimensional canopies**. Department of Systems Science, State University of New York, 2003.

NISHIMURA, JULIO. Vamos aprender tudo sobre Agrotóxicos: Desenvolvimento agrícola sustentado e o uso de produtos fitossanitários ( Manual do Instrutor). **Serviço Nacional de aprendizagem Rural ( SENAR/PR)**, 1995. Curitiba: G.M. Editora Paranaense, 29 p.

PLANT, R.E. Site-specific management, The application of information technology to crop production. **Comp Eletron Agric**, 2001. v.30, p. 9-29.

PRETTY J., J.I.L. MORISON AND R. E. HINE (2003b). Reducing food poverty by increasing agricultural sustainability in developing countries. **Agriculture, Ecosystems & Environment**, 2003. v. 95, p. 217–234.

PONTELLI, CRISTIANO OKADA. **Comportamento Dinâmico de suspensões passivas de barra para pulverizadores**. Dissertação (Mestrado), UNESP Universidade de São Paulo, 2007. 126 p.

PURQUERIO LFV; FACTOR TL; LIMA JR S; TIVELLI SW; TRANI PE; BRENDA JR JM; ROCHA MAV. 2009. Produtividade e qualidade de beterraba cultivada em plantio direto em função do nitrogênio e molibdênio. **Horticultura Brasileira**, 2009. V. 27: p.366-372.

RIFFEL, ROGEMAR A.; RIFFEL, R. A. ; STORCHI-BERGMANN, T. ; Winge, C. . GNIRS Integral Field Spectroscopy of the Seyfert galaxy ESO 428-G 14. In: XI IAU Regional Latin American Meeting of Astronomy, 2005, Pucon. **Revista Mexicana de Astronomía y Astrofísica (Serie de Conferencias)**, 2005. v. 26. 206 p.

ROZA, D. Novidade no campo: Geotecnologias renovam a agricultura. **Revista InfoGEO**, n 11 - jan/fev, 2000. Disponível na Internet. [http://www.infogeo.com.br/Revista/materia\\_11.htm](http://www.infogeo.com.br/Revista/materia_11.htm) em 21 Mai. 2000.

SANTOS, V. M. N. **Escola, cidadania e novas tecnologias: investigação sobre experiências de ensino com o uso de sensoriamento remoto**. Dissertação (Mestrado). Faculdade de Educação da Universidade de São Paulo, 1999. 150 p.

SCHADCHINA, T. M.; DMITRIEVA, V. V. Leaf chlorophyll content as a possible diagnostic mean for the evaluation of plant nitrogen uptake from the soil. **Journal of Plant Nutrition, New York**, 1995. v.18, n.6, p.1427-1437.

SHEPHERD KD, WALSH MG. 2002. Development of reflectance spectra libraries for characterization of soil properties. **Soil Sci Soc Am J**, 2002, v. 66, p. 988-998.

SCHEPERS, J. S., and D. D. FRANCIS. 1998. Precision agriculture: What's in our future. **Communications in Soil Science and Plant Analysis**, 1998. v. 29, p.1463-1469.

SCHUNG E., PANTEN K., HANEKLAUS S. Haneklaus S. Sampling and nutrient recommendations\_The future. **Communications in Soil Science and Plant Analysis**, 1998. v.29, p. 1455-1462.

SOLARI, F. **Developing a crop based strategy for on-the-go nitrogen management in irrigated cornfields**. 2006. Thesis (PhD) – University of Nebraska, Lincoln, 2006. 157 p.

STEFFEN C. A. **Introdução ao sensoriamento remoto**.

Disponível em <<http://www.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>.2009>. Acessado em: 29 jul. 2011.

TISDALE S.L., NELSON W.L., BEATON J.D. and HAVLIN J.L. **Soil Fertility and Fertilizers**. 5th edition. Macmillan Publishing Company, 1993. 634 p.

TSCHIEDEL, M.; FERREIRA, M. F. Introdução à agricultura de precisão: conceitos e vantagens. **Ci. Rural**, 2002, v. 32, n. 1, p. 159-163.

THOMAS, G.W. et al. Effects of a killed sod mulch on nitrate movement and corn yield. **Agronomy Journal, Madison**, 1973. v.65, p.736-739.

TUMBO, D. S.; WAGNER, D. G.; HEINEMANN, P. H. Hyperspectral characteristics of corn plants under different chlorophyll levels. **Transactions of the ASAE**, St. Joseph, 2002. v.45, p.815-823.

ULSON, J. A. C. ; SILVA, IVAN NUNES DA; BENEZ, SÉRGIO HUGO; VILLAS BOAS, R. L. . An Adaptive System Based on Artificial Neural Networks for NPK Fluid Fertilizer Application. **In: XI IFAC International Workshop on Control**, St. Petersburg. Proceedings of XI IFAC international Workshop on Control, 2000. p. 352-356.

ULSON, J. A. C. ; BENEZ, SERGIO HUGO; SILVA, IVAN NUNES DA. Identification in Crop Plants Using Spectral Reflectance and Artificial Neural Networks. **In: IEEE/INNS International Joint Conference on Neural Networks**, Washington. Proceedings of the IEEE/INNS International Joint Conference on Neural Networks, 2001. p. 2088-2092.

ULSON, J. A. C. **Desenvolvimento de um sistema de controle inteligente para aplicação de fertilizantes líquidos em taxas variáveis**. Botucatu, Tese de Doutorado. Faculdade de Ciências Agrônomicas – UNESP, 2002. 149p.

VAN DER SMAGT, P. P. and KROSE, B. J. A. A real-time learning neural robot controller. In **Proceedings of the 1991 International Conference on Artificial Neural Networks**, 1991. v. 1, pages 351-356.

VISCARRA-ROSSEL, R.A. ParleS: Software for chemometric analysis of spectroscopy data. **Chemomet Intel Lab Sys**, 2007. v.90, p.72-83.

WOOD, C.W.; REEVES, D.W.; HIMELRICK, D.G., Relationship between chlorophyll meter readings and leaf chlorophyll concentration, N status, and crop yield: a review. **In: Proceedings of the Agronomy Society of New Zealand**, 1993. v.23, p. 1-9.

WINDROW, B., and M. A. LEHR, “30 years of adaptative neural networks: Perceptron, madaline, and backpropagation”. **Proceedings of Institute of Electrical and Electronics Engineers**, 1990. v.78, p. 1415 -1442.

YARA GmbH & Co. KG. **Operation Manual for theN-Sensor**, 2004. 90 p.

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

## APÊNDICE A – REDES NEURAIS ARTIFICIAIS

### A1. O Neurônio Artificial

Os sistemas com redes neurais (RNA) são compostos de elementos de processamento interconectados chamados nós ou neurônios artificiais e oferecem grande capacidade de resolver problemas não-lineares e complexos, tais como extração de características, classificação de padrões e filtros adaptativos não-lineares.

A combinação ou agrupamento dos neurônios artificiais e os algoritmos que processam as informações trafegadas entre eles são semelhantes ao funcionamento dos neurônios biológicos e executam a principal função de receber e transmitir informações.

O modelo de *McCulloch-Pitts* interpreta o funcionamento do neurônio como sendo um circuito binário simples que combina várias entradas e gera um sinal de saída. A Figura 36 apresenta a lógica de um neurônio artificial de *McCulloch-Pitts*.




Figura 36 - Modelo de McCulloch-Pitts

As equações que descrevem o comportamento do neurônio artificial são dadas por:

$$u = \sum_{i=1}^N w_i \cdot x_i + b \quad (3)$$

$$y = g(u) \quad (4)$$

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.

As funções de ativação são escolhidas em função do problema que a rede esteja tratando. Do ponto de vista funcional, a função de ativação  $g(.)$  processa o conjunto de entradas recebidas e o transforma em estado de ativação. O estado de ativação da saída do neurônio pode assumir os valores binários (0 e 1) e os valores bipolares (-1 e 1) e reais.

Tipos de funções de ativação:

a) Função degrau

Nesse tipo de ativação, apresentado na Figura 37, tem-se:

$$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad (5)$$




Figura 37 - Função de ativação degrau

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

b) Função degrau (bipolar)

Nesse tipo de ativação, mostrado na Figura 38, tem-se:

$$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ -1 & \text{se } u < 0 \end{cases} \quad (6)$$

A saída do neurônio assumirá o valor 1 se o nível de atividade interna total do neurônio for positivo e o valor -1 se o nível de atividade interna total for negativo.




Figura 38 - Função de ativação degrau

## c) Função de ativação rampa

Nesse tipo de função de ativação, apresentado na Figura 39, tem-se:

$$g(u) = \begin{cases} 1 & \text{se } u \geq a \\ u & \text{se } -a < u < a \\ -1 & \text{se } u \leq -a \end{cases} \quad (7)$$




Figura 39 - Função de ativação 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 em  $\{-a, a\}$ , a saída assume o valor da função  $g(u)=u$ .

## d) Função de ativação sigmóide

Para a função de ativação sigmóide, ilustrada na Figura 40, tem-se:

$$g(u) = \frac{1}{1 + e^{(-\beta u)}} \quad (8)$$




Figura 40 - Função de ativação sigmóide

Na função anterior,  $\beta$  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 de ativação tangente hiperbólica

Para a função de ativação do tipo tangente hiperbólica apresentada na Figura 41, tem-se:

$$g(u) = \tanh(u) = \frac{1 - e^{-u}}{1 + e^{-u}} \quad (9)$$




Figura 41 - Função de ativação tangente hiperbólica

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

## A2. Treinamento de redes neurais artificiais

A caracterização de um sistema como rede neural geralmente implica na capacidade de aprender. Aprendizado é o processo pelo qual uma rede neural adquire a habilidade de responder corretamente a estímulos, através do ajuste de parâmetros internos de acordo com algum esquema de aprendizado. O aprendizado ocorre quando a rede neural atinge uma

solução generalizada para uma classe de problemas. 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.

### **A3. Algoritmo *backpropagation***

O algoritmo *backpropagation* é utilizado para o treinamento de Redes *Perceptron* Multicamadas (PMC). Baseia-se no Aprendizado supervisionado por correções de constituído de:

#### 1 - Propagação:

Depois de apresentado o padrão de entrada, a resposta de uma unidade é propagada como entrada para as unidades na camada seguinte, até a camada de saída, onde é obtida a resposta da rede e o erro é calculado;

#### 2 - Retropropagação ("*backpropagation*"):

Desde a camada de saída até a camada de entrada, são feitas alterações nos pesos sinápticos. Durante a fase treinamento devemos apresentar um conjunto formado pelo par: entrada para a rede e valor desejado para resposta a entrada. A saída será comparada ao valor desejado e será computado o erro global da rede, que influenciará na correção dos pesos no passo de retropropagação. Apesar de não haver garantias que a rede forneça uma solução ótima para o problema, este processo é muito utilizado por apresentar uma boa solução para o treinamento de *Perceptrons* Multi - Camadas. A derivação do algoritmo "*backpropagation*", para redes "*Perceptron*" com uma única camada escondida é realizada conforme a notação apresentada na Figura 42.




Figura 42 - Diagrama esquemático da rede Perceptron multicamadas

Os parâmetros são descritos a seguir:

- 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 constitui 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 ( $I$ ) ao  $i$ -ésimo neurônio da camada ( $I-1$ );
- O símbolo  $I1_j$  fornece o valor correspondente à entrada ponderada do  $j$ -ésimo neurônio da camada ( $I$ ), ou seja:

$$I1_j = \sum_{i=0}^N w1_{ji} \cdot x_i; j = 1, \dots, N1 \quad (10)$$

$$I2_j = \sum_{i=0}^N w2_{ji} y1_i; j = 1, \dots, N2 \quad (11)$$

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

$$y1_j = g(I1_j); j = 1, \dots, N2 \quad (12)$$

$$y2_j = g(I2_j); j = 1, \dots, N2 \quad (13)$$

As funções erro quadrático  $E(k)$  e erro quadrático médio  $E_M$ , as quais são utilizadas como critérios de desempenho e 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:

$$E(k) = \frac{1}{2} \sum_{j=1}^{N2} (d_j(k) - y2_j(k))^2 \quad (14)$$

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

Para obter o erro quadrático médio calcula-se a diferença entre o valor estimado ( $x_e$ ) e o valor real ( $x_r$ ) elevada ao quadrado ( Figura 14) de todas as estimativas e dividimos pelo número total de medidas.

$$(x_e - x_r)^2 \quad (15)$$

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:

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k) \quad (16)$$

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  $E_M$ .

#### A4. Algoritmo de *Levenberg-Marquardt*

O algoritmo de *Levenberg-Marquardt* foi desenvolvido para resolver iterativamente problemas de minimização de funções não-lineares pelo método de mínimos quadrados. Ele é o algoritmo de otimização mais utilizado hoje em dia, superando outros algoritmos em uma grande variedade de problemas.

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.

Nesse algoritmo, as funções erro quadrático e erro quadrático médio fornecidas respectivamente nas equações (13) e (15) podem ser expressas conjuntamente por:

$$\begin{aligned}
 V &= \frac{1}{2p} \cdot \sum_{k=1}^p \sum_{j=1}^{N2} [d_j(k) - y2_j(k)]^2 \\
 V &= \frac{1}{2p} \sum_{k=1}^p (d(k) - y2(k))^T \cdot (d(k) - y2(k)) \\
 V &= \frac{1}{2p} \sum_{k=1}^p e^T(k) \cdot e(k)
 \end{aligned} \tag{17}$$

onde o termo  $e(k) = d(k) - y2(k)$  denota o vetor erro em relação ao  $k$ -ésimo padrão de treinamento. Para um padrão  $k$  específico o erro é dado por:

$$V = \frac{1}{2} e^T(k) \cdot e(k) \tag{18}$$

Dessa forma, enquanto o algoritmo “*backpropagation*” é um método de descida no gradiente da função erro quadrático, o algoritmo de *Levenberg-Marquardt* é uma aproximação do Método de *Newton*.

## A5. Algoritmo de Levenberg Regularizado

Um dos problemas que ocorrem durante o treinamento de redes *Perceptron* multicamadas é o fenômeno denominado *overfitting*. Quando acontece o *overfitting*, o erro quadrático médio dos padrões de treinamento é muito pequeno, mas quando novos padrões são apresentados a rede, o erro relativo torna-se muito grande. Esse fato ocorre porque a rede memorizou apenas os padrões de treinamento, mas não conseguiu generalizar novas situações, ou seja, a rede funciona apenas como uma tabela que relaciona as entradas com as saídas.

A generalização é influenciada por três fatores:

- a) a disponibilidade de dados para treinamento da rede;
- b) o nível de representatividade do processo pelos dados de treinamento;
- c) a arquitetura da rede neural e
- d) complexidade do problema em questão.

Observa-se que não se tem controle sobre o último fator. Os outros três fatores são controláveis desde que se tenha acesso a aquisição dos dados e concepção da rede neural.

## A6. Funções de Base Radial

As funções de base radial (RBF) são uma classe especial de funções. São caracterizadas por uma resposta que decresce ou cresce monotonicamente com a distância a um ponto central. Os parâmetros mais importantes a serem definidos em uma função de base radial são o centro e a taxa de crescimento, ou decrescimento, da função. Uma função de base radial típica é a Gaussiana. Para o caso de uma entrada escalar, a Gaussiana é dada pela expressão (18):

$$h(x) = \frac{\sqrt{r^2 + (x - c)^2}}{r} \quad (19)$$

A RBF Gaussiana é monotonicamente decrescente com a distância do centro. Um exemplo de RBF monotonicamente crescente típica, para o caso de uma entrada escalar, é dada pela expressão:

$$h(x) = \frac{\sqrt{r^2 + (x - c)^2}}{r} \quad (20)$$

Nas funções mostradas acima, o parâmetro  $c$  corresponde ao centro e o parâmetro  $r$  é uma medida de abertura. As redes RBF do tipo Gaussiana são mais usadas e apresentam uma resposta significativa somente nas vizinhanças do centro e as redes RBFs do tipo multiquadráticas apresentam resposta global.

## A7. Redes Neurais com Funções de Ativação de Base Radial

As redes com Funções de Base Radial (RBF - *Radial Basis Functions*) são redes neurais multicamadas, com neurônios ocultos não lineares e tem apenas uma única camada oculta, cujos neurônios possuem função de ativação gaussiana.

As redes RBF podem ser usadas como funções base em qualquer tipo de modelo de regressão não-linear, linear ou não-linear nos parâmetros, e como função de

ativação em qualquer tipo de rede multicamada. Para o caso de uma única saída  $y = f(x)$ , o mapeamento entrada-saída é dado por:

$$y = \sum_{j=1}^m w_j h_j(\vec{x}) \quad (21)$$

O modelo de regressão resultante pode ser linear ou não-linear nos parâmetros. Se os centros e as aberturas das funções de ativação forem fixos e apenas os pesos da camada de saída forem ajustáveis, o modelo será linear nos parâmetros. Caso os centros e as aberturas sejam ajustáveis, o modelo será não-linear nos parâmetros.

#### **A8. Comparação entre Redes RBF e PMC**

As redes RBF apresentam algumas diferenças em relação às redes PMC. A mais óbvia é que os neurônios da camada intermediária das redes RBF têm apenas funções de ativação de base radial, ao contrário dos PMC, que apresentam funções sigmoidais ou outras. As redes RBF sempre apresentam uma única camada intermediária, ao invés das múltiplas camadas do PMC. Os neurônios de saída das redes RBF são sempre lineares. Mas a principal diferença está na forma como as entradas são processadas pelos neurônios na camada intermediária. A ativação interna de cada neurônio é obtida a partir da norma euclidiana ponderada da diferença entre o vetor de entradas e o vetor de centros. No caso de uma RBF decrescente, por exemplo, quanto maior a distância entre a entrada e o centro, menor a ativação do neurônio. Nas redes PMC, a ativação é dada pelo produto escalar entre o vetor de entradas e o vetor de pesos.

## **APÊNDICE B - BASE DE DADOS BD121**

As Figuras 43 e 44 apresentam respectivamente uma amostra dos dados da planilha Bd121 e Bd100 com os dados georreferenciados com resultados da quantidade de nitrogênio da amostra de material foliar medidos em laboratório e respectivos valores de refletância medidos pelo sensor óptico.



Seqüência	Latitude	Longitude	Nitrogênio Lab. Kg por hectare	Altitude	Quantidade satélites	Qualidade 3min tops	Validade 3min tops	S1	R1L0L	R1L2L	R2Z1L	R2Z2L	R1L1L	R1L3L	R2Z1R	R2Z2R	R1L1R	R1L3R	R2Z1R	R2Z2R	R1L1R	R1L3R	R2Z1R	R2Z2R
1	-21,792133	-48,593608	20,46	333,5	9	1	0,52	3323	3361	10333	7861	5955	8094	7815	4871	6471	4093	5523	5315	8924	5517	6849		
2	-21,792458	-48,590843	23,36	333,6	9	1	0,52	3337	3412	10146	7839	5839	8033	7300	4742	6577	4946	5477	5133	9204	5524	6139		
3	-21,792872	-48,590699	13,36	333,4	9	1	0,66	284	6517	9011	7163	6090	6810	10117	7203	6047	5272	7778	4875	4979	5300	3284	5113	2495
4	-21,791199	-48,595743	37,37	333,9	9	1	0,30	321	1116	1310	1310	1221	3303	3294	3276	1683	3427	3397	2409	2203	4230	2099	3094	
5	-21,793487	-48,598784	31,50	333,5	9	1	0,30	314	1324	2677	1272	1046	2030	3326	2300	2888	818	3514	713	1062	1490	2528	1637	1792
6	-21,793687	-48,598337	29,86	332,8	9	1	0,30	224	1635	3646	1657	2635	3240	4185	2886	3236	1072	2240	908	1071	1955	3041	1663	1930
7	-21,794163	-48,596881	26,63	332,3	9	1	0,52	372	1331	1039	7637	7131	5956	3546	3546	3546	3546	3546	3546	3546	3546	3546	3546	3546
8	-21,794579	-48,595942	0,74	331,1	8	1	0,52	173	3172	7085	3138	1066	3531	4326	3760	3516	2113	1789	2600	2745	3294	4173	3110	1132
9	-21,795009	-48,596292	30,30	330,3	8	1	0,30	793	2727	5793	2110	1166	3531	4326	3760	3516	2113	1789	2600	2745	3294	4173	3110	1132
10	-21,794704	-48,596272	30,30	330,3	9	1	0,30	89	1079	1104	1169	1343	1447	1788	1727	1436	2724	3695	2950	2609	3294	3900	3099	2911
11	-21,794692	-48,59922	3,39	331,2	9	1	0,30	89	1079	1104	1169	1343	1447	1788	1727	1436	2724	3695	2950	2609	3294	3900	3099	2911
12	-21,794692	-48,59922	3,39	331,2	9	1	0,30	89	1079	1104	1169	1343	1447	1788	1727	1436	2724	3695	2950	2609	3294	3900	3099	2911
13	-21,794692	-48,59922	3,39	331,2	9	1	0,30	89	1079	1104	1169	1343	1447	1788	1727	1436	2724	3695	2950	2609	3294	3900	3099	2911
14	-21,793399	-48,596071	3,70	331,5	10	1	0,43	638	3186	3044	3382	2306	3618	4301	4372	3368	2082	2663	1981	1994	2322	3122	2495	2393
15	-21,793399	-48,596071	3,70	331,5	10	1	0,43	638	3186	3044	3382	2306	3618	4301	4372	3368	2082	2663	1981	1994	2322	3122	2495	2393
16	-21,793399	-48,596071	3,70	331,5	10	1	0,43	638	3186	3044	3382	2306	3618	4301	4372	3368	2082	2663	1981	1994	2322	3122	2495	2393
17	-21,793399	-48,596071	3,70	331,5	10	1	0,43	638	3186	3044	3382	2306	3618	4301	4372	3368	2082	2663	1981	1994	2322	3122	2495	2393
18	-21,793399	-48,596071	3,70	331,5	10	1	0,43	638	3186	3044	3382	2306	3618	4301	4372	3368	2082	2663	1981	1994	2322	3122	2495	2393
19	-21,793399	-48,596071	3,70	331,5	10	1	0,43	638	3186	3044	3382	2306	3618	4301	4372	3368	2082	2663	1981	1994	2322	3122	2495	2393
20	-21,793399	-48,596071	3,70	331,5	10	1	0,43	638	3186	3044	3382	2306	3618	4301	4372	3368	2082	2663	1981	1994	2322	3122	2495	2393
21	-21,793399	-48,596071	3,70	331,5	10	1	0,43	638	3186	3044	3382	2306	3618	4301	4372	3368	2082	2663	1981	1994	2322	3122	2495	2393
22	-21,793399	-48,596071	3,70	331,5	10	1	0,43	638	3186	3044	3382	2306	3618	4301	4372	3368	2082	2663	1981	1994	2322	3122	2495	2393
23	-21,793399	-48,596071	3,70	331,5	10	1	0,43	638	3186	3044	3382	2306	3618	4301	4372	3368	2082	2663	1981	1994	2322	3122	2495	2393
24	-21,793399	-48,596071	3,70	331,5	10	1	0,43	638	3186	3044	3382	2306	3618	4301	4372	3368	2082	2663	1981	1994	2322	3122	2495	2393
25	-21,794275	-48,59517	19,63	329,5	6	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
26	-21,794042	-48,595660	28,49	329,7	6	1	0,36	171	4377	3359	4019	4301	4792	6543	5636	4731	6113	9367	5163	5916	6520	9363	5648	6341
27	-21,794042	-48,595660	28,49	329,7	6	1	0,36	171	4377	3359	4019	4301	4792	6543	5636	4731	6113	9367	5163	5916	6520	9363	5648	6341
28	-21,794042	-48,595660	28,49	329,7	6	1	0,36	171	4377	3359	4019	4301	4792	6543	5636	4731	6113	9367	5163	5916	6520	9363	5648	6341
29	-21,794042	-48,595660	28,49	329,7	6	1	0,36	171	4377	3359	4019	4301	4792	6543	5636	4731	6113	9367	5163	5916	6520	9363	5648	6341
30	-21,794042	-48,595660	28,49	329,7	6	1	0,36	171	4377	3359	4019	4301	4792	6543	5636	4731	6113	9367	5163	5916	6520	9363	5648	6341
31	-21,794042	-48,595660	28,49	329,7	6	1	0,36	171	4377	3359	4019	4301	4792	6543	5636	4731	6113	9367	5163	5916	6520	9363	5648	6341
32	-21,794042	-48,595660	28,49	329,7	6	1	0,36	171	4377	3359	4019	4301	4792	6543	5636	4731	6113	9367	5163	5916	6520	9363	5648	6341
33	-21,794042	-48,595660	28,49	329,7	6	1	0,36	171	4377	3359	4019	4301	4792	6543	5636	4731	6113	9367	5163	5916	6520	9363	5648	6341
34	-21,794042	-48,595660	28,49	329,7	6	1	0,36	171	4377	3359	4019	4301	4792	6543	5636	4731	6113	9367	5163	5916	6520	9363	5648	6341
35	-21,794042	-48,595660	28,49	329,7	6	1	0,36	171	4377	3359	4019	4301	4792	6543	5636	4731	6113	9367	5163	5916	6520	9363	5648	6341
36	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
37	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
38	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
39	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
40	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
41	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
42	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
43	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
44	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
45	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
46	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
47	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
48	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
49	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
50	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
51	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	5652
52	-21,79377	-48,590736	11,16	329,5	7	1	0,32	247	5337	3716	3975	2423	6783	10196	7173	6865	4967	7055	4403	3006	4072	8529	5130	

## APÊNDICE C - SOFTWARE PMC\_BD121\_BD100\_123\_CAMADAS.M

Este apêndice apresenta a listagem com a programação do software utilizado nas pesquisas com a rede neural PMC com 1, 2 e 3 camadas ocultas. O software foi planejado para ser configurado no início com perguntas sobre a base de dados que será utilizado (Bd121 ou Bd100), o valor do EQM que deve ser utilizado, a quantidade camadas ocultas que devera ser gerada e a quantidade de neurônios em cada camada oculta. Segue abaixo a listagem completa.

```

% ##### PMC_Bd121_Bd100_123_camadas #####
% ##### RNA PMC com 1 ou 2 ou 3 camadas ocultas #####

clear all;
clc;
clf reset;
close all;
Bd_dados = 0;
while ((Bd_dados ~= 1) & (Bd_dados ~= 2))
    Bd_dados = input('Escolha a base de dados - 1=BD121 e 2=Bd100: ');
    % escolha Base de dados
End

erroEQM = 0;
while (erroEQM <= 0)
    erroEQM = input('Digite o erro máximo para o treinamento da rede: ');
    %Escolha valor do EQM
end

camadasOc = 0;
neuronioCamada_1 = 0;
neuronioCamada_2 = 0;
neuronioCamada_3 = 0;

while ((camadasOc ~= 1) & (camadasOc ~= 2) & (camadasOc ~= 3))
    camadasOc = input('Digite o número de camadasOc escondidas (1 - 2 ou
3): ');
    % escolha qtde camadas ocultas.
end

if (camadasOc == 1)
    while (neuronioCamada_1 <= 0)
        neuronioCamada_1 = input('Digite o número de neurônios da camada
escondida 1: ');
        % escolha qtde neuronios camada oculta 1
    end
end

```

```

if (camadasOc == 2)
    while (neuronioCamada_1 <= 0)
        neuronioCamada_1 = input('Digite o número de neurônios da camada
        escondida 1: '); % escolha qtde neuronios camada oculta 1
    end

    while (neuronioCamada_2 <= 0)
        neuronioCamada_2 = input('Digite o número de neurônios da camada
        escondida 2: '); % escolha qtde neuronios camada oculta 2
    end
end

if (camadasOc == 3)
    while (neuronioCamada_1 <= 0)
        neuronioCamada_1 = input('Digite o número de neurônios da camada
        escondida 1: '); % escolha qtde neuronios camada oculta 1
    end

    while (neuronioCamada_2 <= 0)
        neuronioCamada_2 = input('Digite o número de neurônios da camada
        escondida 2: '); % escolha qtde neuronios camada oculta 2
    end
    while (neuronioCamada_3 <= 0)
        neuronioCamada_3 = input('Digite o número de neurônios da camada
        escondida 3: '); % escolha qtde neuronios camada oculta 3
    end
end

if (Bd_dados == 1) % se base de dados = Bd121

    tabRefletancias = xlsread('Bd_121_100',1,'J2:Y122');
        % Leitura na tabela de dados Bd121
        % das refletancias
        % individuais .

    análiseLab = xlsread('Bd_121_100',1,'D2:D122')';
        % Leitura na tabela os dados
        % da análise qtde de nitrogenio
        % das amostras de material
        % foliar em laboratório.

else % se base de dados = Bd100

    tabRefletancias = xlsread('Bd_121_100',2,'J2:Y101');
        % Leitura na tabela de dados Bd100
        % das refletância individuais .

    análiseLab = xlsread('Bd_121_100',2,'D2:D101')';
        % Leitura na tabela os dados
        % da análise qtde de nitrogenio
        % das amostras de material
        % foliar em laboratório.

end

```

```

dadosRefletancias = [tabRefletancias];
                                %normaliza todas as refletâncias no intervalo [-1,+1]
dadosRef_maximo = max(max(dadosRefletancias));
dadosRef_minimo = min(min(dadosRefletancias));

for i=1:size(dadosRefletancias,1)
    for j=1:size(dadosRefletancias,2)
        dadosRefletNormalizado(i,j) = -1 + (2*((dadosRefletancias(i,j)-
            dadosRef_minimo))/(dadosRef_maximo-dadosRef_minimo));
    end
end

if (Bd_dados == 1)

    rand = randperm(121);
                                % gera 121 numeors aleatorios
                                % para sorteio da tabela Bd_121.
                                % 84 para treinamento
                                % 37 para validacao.

    tabTreina=[];
    for i=1:84
        tabTreina=[tabTreina;dadosRefletNormalizado(rand(i),:)];
    end

    tabValida=[];
    for i=85:121
        tabValida=[tabValida;dadosRefletNormalizado(rand(i),:)];
    end

else

    rand = randperm(100);
                                % gera 100 numeors aleatorios
                                % para sorteio da tabela Bd_100.
                                % 70 para treinamento
                                % 30 para validacao.

    tabTreina=[];
    for i=1:70
        tabTreina=[tabTreina;dadosRefletNormalizado(rand(i),:)];
    end

    tabValida=[];
    for i=71:100
        tabValida=[tabValida;dadosRefletNormalizado(rand(i),:)];
    end

end

dadosTreinamento = tabTreina'; %Treinamento
dadosValidacao = tabValida'; %Validação

%Agrupa os dados

dadosAnáliseLab = [análiseLab];

%Normaliza os dados no intervalo [-1,+1]
dadosAnaLabmax = max(dadosAnáliseLab);
dadosAnaLabmin = min(dadosAnáliseLab);

```

```

for i=1:size(dadosAnáliseLab,2)
    dadoS1Normalizado(i) = -1 + (2*((dadosAnáliseLab(i)-
        dadosAnaLabmin))/(dadosAnaLabmax-dadosAnaLabmin));
end

%Monta o conjunto de treinamento baseado nas amostras aleatórias utilizadas

if (Bd_dados == 1)

    dadoTreinaNormalizado=[];
    for i=1:84
        dadoTreinaNormalizado=[dadoTreinaNormalizado da
            doS1Normalizado(rand(i))];
    end

    %Monta o conjunto de validação aleatório com o restante das amostras

    dadoValidaNormalizado=[];
    for i=85:121
        dadoValidaNormalizado=[dadoValidaNormalizado da
            doS1Normalizado(rand(i))];
    end
else
    dadoTreinaNormalizado=[];
    for i=1:70
        dadoTreinaNormalizado=[dadoTreinaNormalizado da
            doS1Normalizado(rand(i))];
    end
    %Monta o conjunto de validação aleatório com o restante das amostras
    dadoValidaNormalizado=[];
    for i=71:100
        dadoValidaNormalizado=[dadoValidaNormalizado da
            doS1Normalizado(rand(i))];
    end
end

%Gera a rede neural PMC
%Camada(s) escondida(s) = função de ativação = tangente hiperbólica sigmoidal
%Camada saída = função de ativação = linear

if (camadasOc == 1)
    net =
        newff(minmax(dadosTreinamento),[neuronioCamada_1,1],{'tansig','satlins'
            },'trainlm');
end
if (camadasOc == 2)
    net =
        newff(minmax(dadosTreinamento),[neuronioCamada_1,neuronioCamada_2,1],{'
            tansig','tansig','satlins'},'trainlm');
end

if (camadasOc == 3)

```

```

net =
    newff(minmax(dadosTreinamento),[neuronioCamada_1,neuronioCamada_2,neuro
        nioCamada_3,1],{'tansig','tansig','tansig','satlins'},'trainlm');
end
%Parâmetros de treinamento Levenberg-Maquardt

net.trainParam.show = 10;
net.trainParam.epochs = 150;
net.trainParam.goal = erroEQM;
tic

%Treina a rede PMC

[net,tr] = train(net,dadosTreinamento,dadoTreinaNormalizado);
toc

%Simula a rede treinada para as entradas de amplitude do treinamento
%para verificar qualidade do treinamento

calculaTreina = sim(net,dadosTreinamento);

%Valida a rede

calculaValida = sim(net,dadosValidacao);

%Prepara apresentação das informações

m_est=(mean(dadoValidaNormalizado.*calculaValida)-
mean(dadoValidaNormalizado)*mean(calculaValida))/
(mean(dadoValidaNormalizado.^2)-(mean(dadoValidaNormalizado).^2));

q_est=mean(calculaValida)-m_est*mean(dadoValidaNormalizado);
a=(mean(dadoValidaNormalizado.*calculaValida)- mean(dadoValidaNormalizado)*
mean(calculaValida)).^2;

b=(mean(dadoValidaNormalizado.^2)-
(mean(dadoValidaNormalizado).^2)*(mean(calculaValida.^2)-
(mean(calculaValida).^2)));

Rsquare=sqrt(a/b)*100; % R
RsquareQuad=(a/b)*100 % R2 % apresenta R2

figure;
plot(1:length(dadoTreinaNormalizado),dadoTreinaNormalizado,'r',1:length(cal
culaTreina),calculaTreina,'b');grid;title('Treinamento Calculado x Labora-
tório ');
ylabel('N');xlabel('Amostras');
set(legend('Nitrogênio Normalizado','Nitrogênio Calcula-
do',2),'Interpreter','none');

figure;
postreg(calculaTreina,dadoTreinaNormalizado);grid;title(' Regressão Linear
- Treinamento ');
ylabel('Calculado');xlabel('Laboratório');

figure;

```

```

plot(1:length(dadoValidaNormalizado),dadoValidaNormalizado,'r',1:length(cal
culaValida),calculaValida,'b');grid;title('Validação Calculado x Laboratio
');
ylabel('N');xlabel('Amostras');
set(legend('Laboratório','Calculado',2),'Interpreter','none');

figure;
postreg(dadoValidaNormalizado,calculaValida);grid;title(' Regressão Linear
- Validacao ');
ylabel('Calculado');xlabel('Laboratório');

% calcula RMSE
if (Bd_dados == 1)
    dadosEstimado=[];
    for i=1:size(calculaValida,2)
        dadosEstimado(i) = 0.5*((calculaValida(i)*(dadosAnaLabmax-
dadosAnaLabmin))+(dadosAnaLabmax+dadosAnaLabmin));
    end
    dadosReal=[];
    for i=85:121
        dadosReal=[dadosReal dadosAnáliseLab(rand(i))];
    end
else
    dadosEstimado=[];
    for i=1:size(calculaValida,2)
        dadosEstimado(i) = 0.5*((calculaValida(i)*(dadosAnaLabmax-
dadosAnaLabmin))+(dadosAnaLabmax+dadosAnaLabmin));
    end
    dadosReal=[];
    for i=71:100
        dadosReal=[dadosReal dadosAnáliseLab(rand(i))];
    end
end

Press = sum((dadosReal(:)- dadosEstimado(:)).^2);
soma = 0;
for i=1: numel(dadosReal)
    soma = soma + dadosReal(i)^2;
end

Rmse = sqrt(Press/numel(dadosReal)) % Apresenta RMSE
Rmsep = sqrt(Press/soma);

figure;
postreg(dadosReal,dadosEstimado);grid; %%%title('REAL X ESTIMADO');

```

## APÊNDICE D - SOFTWARE RBF\_BD121\_BD100.M

Este anexo apresenta a listagem com a programação do software utilizado nas pesquisas com a rede neural RBF. O software foi planejado para ser configurado no início com perguntas sobre a base de dados que será utilizada ( Bd121 ou Bd100), o valor do EQM que deve ser utilizado e o valor do índice spread que deverá ser utilizado. Segue abaixo a listagem completa.

```

% ##### RBF_Bd121_Bd100 #####
% ##### RNA RBF #####

clear all;
clc;
clf reset;
close all;
Bd_dados = 0;

while ((Bd_dados ~= 1) & (Bd_dados ~= 2))
    Bd_dados = input('Escolha a base de dados - 1=Bd121 e 2=Bd100: ');
    % escolha Base de dados
end
erroEQM = 0;
while (erroEQM <= 0)
    erroEQM = input('Digite o erro máximo para o treinamento da rede: ');
    % Escolha valor do EQM
end

spread = 0;
while (spread <= 0)
    spread = input('Digite o valor do spread da função de base radial: ');
end

if (Bd_dados == 1) % se base de dados = Bd121

    tabRefletancias = xlsread('Bd_121_100',1,'J2:Y122');
    % Leitura na tabela de dados Bd121
    % das refletancias individuais .

    análiseLab = xlsread('Bd_121_100',1,'D2:D122');
    % Leitura na tabela os dados
    % da análise qtde de nitrogenio
    % das amostras de material
    % foliar em laboratório.
else
    % se base de dados = Bd100

    tabRefletancias = xlsread('Bd_121_100',2,'J2:Y101');
    % Leitura na tabela de dados Bd100
    % das refletancias individuais .

```

```

    análiseLab = xlsread('Bd_121_100',2,'D2:D101');
                                                    % Leitura na tabela os dados
                                                    % da análise qtde de nitrogenio
                                                    % das amostras de material
                                                    % foliar em laboratório.
end

dadosRefletancias = [tabRefletancias];

%normaliza todas as refletâncias no intervalo [-1,+1]

dadosRef_maximo = max(max(dadosRefletancias));
dadosRef_minimo = min(min(dadosRefletancias));

for i=1:size(dadosRefletancias,1)
    for j=1:size(dadosRefletancias,2)
        dadosRefletNormalizado(i,j) = -1 + (2*((dadosRefletancias(i,j)-
            dadosRef_minimo))/(dadosRef_maximo-dadosRef_minimo));
    end
end

if (Bd_dados == 1)

    rand = randperm(121);
                                                    % gera 121 numeors aleatorios
                                                    % para sorteio da tabela Bd_121.
                                                    % 84 para treinamento
                                                    % 37 para validacao.

    tabTreina=[];
        for i=1:84
            tabTreina=[tabTreina;dadosRefletNormalizado(rand(i),:)];
        end

    tabValida=[];
        for i=85:121
            tabValida=[tabValida;dadosRefletNormalizado(rand(i),:)];
        end
else

    rand = randperm(100);
                                                    % gera 100 numeors aleatorios
                                                    % para sorteio da tabela Bd_100
                                                    % 70 para treinamento
                                                    % 30 para validacao.

    tabTreina=[];
        for i=1:70
            tabTreina=[tabTreina;dadosRefletNormalizado(rand(i),:)];
        end

    tabValida=[];
        for i=71:100
            tabValida=[tabValida;dadosRefletNormalizado(rand(i),:)];
        end
end

dadosTreinamento = tabTreina'; %Treinamento
dadosValidacao = tabValida'; %Validação

```

**%Agrupa os dados**

```
dadosAnáliseLab = [análiseLab];
%Normaliza os dados no intervalo [-1,+1]
dadosAnaLabmax = max(dadosAnáliseLab);
dadosAnaLabmin = min(dadosAnáliseLab);

for i=1:size(dadosAnáliseLab,2)
    dadoS1Normalizado(i) = -1 + (2*((dadosAnáliseLab(i)-
        dadosAnaLabmin))/(dadosAnaLabmax-dadosAnaLabmin));
end
```

**%Monta o conjunto de treinamento baseado nas amostras aleatórias utilizadas**

```
if (Bd_dados == 1)

    dadoTreinaNormalizado=[];
    for i=1:84
        dadoTreinaNormalizado=[dadoTreinaNormalizado da-
            doS1Normalizado(rand(i))];
    end
```

**%Monta o conjunto de validação aleatório com o restante das amostras**

```
    dadoValidaNormalizado=[];
    for i=85:121
        dadoValidaNormalizado=[dadoValidaNormalizado da-
            doS1Normalizado(rand(i))];
    end
else
    dadoTreinaNormalizado=[];
    for i=1:70
        dadoTreinaNormalizado=[dadoTreinaNormalizado da-
            doS1Normalizado(rand(i))];
    end
```

**%Monta o conjunto de validação aleatório com o restante das amostras**

```
    dadoValidaNormalizado=[];
    for i=71:100
        dadoValidaNormalizado=[dadoValidaNormalizado da-
            doS1Normalizado(rand(i))];
    end
end
```

**% Gera a rede neural RBF**

```
eg = erroEQM;
sc = spread;
nmax = length(dadosTreinamento);
df = 1;
```

```
%erro máximo de treinamento
%spread da função de base radial
%número máximo de neurônios
%passo de incremento no número de
%neurônios para exibição na tela
```

```

tic

%Monta a rede RBF

net = newrb(dadosTreinamento,dadoTreinaNormalizado,eg,sc,nmax,df);
toc

%Simula a rede treinada para as entradas de amplitude do treinamento
%para verificar qualidade do treinamento

calculaTreina = sim(net,dadosTreinamento);

%Valida a rede

calculaValida = sim(net,dadosValidacao);

%Prepara apresentação das informações

m_est=(mean(dadoValidaNormalizado.*calculaValida)-
mean(dadoValidaNormalizado)*mean(calculaValida))/
(mean(dadoValidaNormalizado.^2)-(mean(dadoValidaNormalizado).^2));

q_est=mean(calculaValida)-m_est*mean(dadoValidaNormalizado);
a=(mean(dadoValidaNormalizado.*calculaValida)- mean(dadoValidaNormalizado)*
mean(calculaValida)).^2;

b=(mean(dadoValidaNormalizado.^2)-
(mean(dadoValidaNormalizado)).^2)*(mean(calculaValida.^2)-
(mean(calculaValida)).^2));

Rsquare=sqrt(a/b)*100; % R
RsquareQuad=(a/b)*100 % R2 - apresenta R2

figure;
plot(1:length(dadoTreinaNormalizado),dadoTreinaNormalizado,'r',1:length(cal
culaTreina),calculaTreina,'b');grid;title('Treinamento Calculado x Labora-
tório ');
ylabel('N');xlabel('Amostras');
set(legend('Nitrogênio Normalizado','Nitrogênio Calcula-
do',2),'Interpreter','none');

figure;
postreg(calculaTreina,dadoTreinaNormalizado);grid;title(' Regressão Linear
- Treinamento ');
ylabel('Calculado');xlabel('Laboratório');

figure;
plot(1:length(dadoValidaNormalizado),dadoValidaNormalizado,'r',1:length(cal
culaValida),calculaValida,'b');grid;title('Validação Calculado x Laboratio
');
ylabel('N');xlabel('Amostras');
set(legend('Laboratório','Calculado',2),'Interpreter','none');

```

```

figure;
postreg(dadoValidaNormalizado,calculaValida);grid;title(' Regressão Linear
- Validacao ');
ylabel('Calculado');xlabel('Laboratório');

% Calcula Rmse

if (Bd_dados == 1)

    dadosEstimado=[];
    for i=1:size(calculaValida,2)
        dadosEstimado(i) = 0.5*((calculaValida(i)*(dadosAnaLabmax-
        dadosAnaLabmin)))+(dadosAnaLabmax+dadosAnaLabmin));
    end
    dadosReal=[];

    for i=85:121
        dadosReal=[dadosReal dadosAnáliseLab(rand(i))];
    end

else

    dadosEstimado=[];
    for i=1:size(calculaValida,2)
        dadosEstimado(i) = 0.5*((calculaValida(i)*(dadosAnaLabmax-
        dadosAnaLabmin)))+(dadosAnaLabmax+dadosAnaLabmin));
    end

    dadosReal=[];
    for i=71:100
        dadosReal=[dadosReal dadosAnáliseLab(rand(i))];
    end
end

Press = sum((dadosReal(:)- dadosEstimado(:)).^2);

soma = 0;
for i=1:numel(dadosReal)
    soma = soma + dadosReal(i)^2;
end

Rmse = sqrt(Press/numel(dadosReal)) % apresenta Rmse
Rmsep = sqrt(Press/soma);

figure;
postreg(dadosReal,dadosEstimado);grid; %%%title('REAL X ESTIMADO');

```