

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**SISTEMA NEURAL ARTIFICIAL PARA IDENTIFICAÇÃO DE
PERDAS NÃO TÉCNICA EM CONSUMIDORES RURAIS**

TESE DE DOUTORADO

Maicon Coelho Evaldt

Santa Maria, RS, Brasil.

2018

SISTEMA NEURAL ARTIFICIAL PARA IDENTIFICAÇÃO DE PERDAS NÃO TÉCNICA EM CONSUMIDORES RURAIS

Maicon Coelho Evaldt

Tese apresentada ao Curso de Doutorado do Programa de Pós-Graduação em Engenharia Elétrica Área de Concentração em Processamento de Energia, Centro de Excelência em Energia e Sistemas de Potência (CEESP), da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de **Doutor em Engenharia Elétrica.**

Orientadora: Prof^a. Dr^a. Alzenira da Rosa Abaide
Coorientador: Prof. Dr. Luciano Lopes Pfitscher

Santa Maria, RS, Brasil.

2018

ESPAÇO DESTINADO À FICHA CATALOGRÁFICA

**Universidade Federal de Santa Maria
Centro de Tecnologia
Programa de Pós-Graduação em Engenharia Elétrica**

A Comissão Examinadora, abaixo assinada,
aprova a Tese de Doutorado

**SISTEMA NEURAL ARTIFICIAL PARA IDENTIFICAÇÃO DE
PERDAS NÃO TÉCNICA EM CONSUMIDORES RURAIS**

elaborada por
Maicon Coelho Evaldt

como requisito parcial para obtenção do grau de
Doutor em Engenharia Elétrica

COMISSÃO EXAMINADORA:

Alzenira da Rosa Abaide, Dr^a. (UFSM/RS)
(Presidente/Orientadora)

Hans Helmut Zürn, Dr. (UFSC/SC)

Rodrigo Marques de Figueiredo, Dr. (UNISINOS/RS)

Luciane Neves Canha, Dr^a. (UFSM/RS)

Felix Alberto Farret, Dr. (UFSM/RS)

Santa Maria, 19 de Dezembro de 2018.

"A ciência consiste em substituir o saber que parecia seguro por uma teoria. "

José Ortega y Gasset

AGRADECIMENTOS

Na vida se agrega muito do que as pessoas lhe oferecem; o conhecimento é só um deles e este é apenas uma consequência da permissão divina e do amor das pessoas que estão de alguma maneira presente nos momentos mais importantes da vida. Algumas destas cito aqui:

A meu querido pai, Sr. Antônio José Evaldt (em memória), minha mãe Sra. Maria Eponina Coelho Evaldt, meu irmão Márcio Coelho Evaldt, minha tia Sra. Maria das Graças Porto Coelho e demais familiares. Obrigado por estarem comigo e entenderem muitos momentos de ausência em prol desta causa.

À minha esposa e amor da minha vida Daiane Calheiro Evaldt, pelo companheirismo e responsável por nossas maiores conquistas, Alice Calheiro Evaldt, nossa amada filha de apenas 4 anos e seu irmão caçula que irá chegar em alguns meses, o (Léo) Leonardo Calheiro Evaldt, que apesar de ter tornado muito maior o desafio desta caminhada, são as maiores motivações de ir em frente nesta jornada.

Aos meus sogros e avós da Alice e do Leonardo que estão sendo decisivos com o carinho e cuidado com nossa filha quando nos obrigamos a encarar turnos de reclusão por conta deste trabalho.

À professora Dr^a. Alzenira da Rosa Abaide, orientadora desta Tese, pelas inúmeras orientações, incentivo, compreensão e motivação.

Ao professor Luciano Lopes Pfitscher, coorientador, grande amigo e “pai” acadêmico, com quem aprendi muito para chegar até aqui.

Aos amigos da Unisinos e colegas do CEESP pelo companheirismo e carinho de forma acentuada ao amigo Enoque Dutra Garcia por sua colaboração com inúmeros dados utilizados neste trabalho.

Enfim, a todos com participações e intensidades diferentes me ajudaram nesta trajetória que me levou à conquista do Doutorado.

RESUMO

Tese de Doutorado
Programa de Pós-Graduação em Engenharia Elétrica
Universidade Federal de Santa Maria

SISTEMA NEURAL ARTIFICIAL PARA IDENTIFICAÇÃO DE PERDAS NÃO TÉCNICA EM CONSUMIDORES RURAIS

AUTOR: MAICON COELHO EVALDT
ORIENTADORA: ALZENIRA DA ROSA ABAIDE
COORIENTADOR: LUCIANO LOPES PFITSCHER
Data e Local da Defesa: Santa Maria, 19 de dezembro de 2018.

Perdas não técnicas possuem impacto significativo em redes elétricas de distribuição e estão entre as grandes preocupações dos agentes envolvidos no sistema elétrico de potência. Particularmente, em redes elétricas rurais, consumidores com sistemas de irrigação de lavouras caracterizam situações de difícil detecção de perdas não técnicas para as concessionárias de energia, considerando os diferentes processos de irrigação existentes, características climáticas e dificuldades de inspeção local. Este trabalho apresenta uma proposta para a identificação de perdas não técnicas em alimentadores rurais contendo sistemas de bombeamento para irrigação de lavouras de arroz. A metodologia proposta é baseada na correlação dos padrões de consumo de energia elétrica, das características da área irrigada e das condições climáticas do período de irrigação. A metodologia emprega um Sistema Neural Artificial constituído de Redes Neurais Artificiais, e utiliza como entradas: precipitação pluviométrica, temperatura, incidência solar, umidade do ar, carga instalada, área irrigada, tipo de solo, altura do levante, nível de automação e método de irrigação do cultivo de arroz. Os resultados finais indicam, para cada consumidor analisado, o risco percentual de perdas não técnicas. O Sistema Neural Artificial possibilita a análise de lavouras de arroz irrigado em qualquer região do Brasil, independentemente das características da lavoura, do solo e do ambiente. Os resultados do trabalho foram obtidos e validados a partir de uma base de dados reais de safras do período entre 2009 e 2014, de lavouras do Estado do Rio do Grande do Sul.

Palavras-chave:, Perdas não técnicas, Sistema Neural Artificial, consumidores rurais.

ABSTRACT

Doctoral Course Thesis
Post Graduation Program in Electrical Engineering
Universidade Federal de Santa Maria

ARTIFICIAL NEURAL SYSTEM FOR IDENTIFICATION OF NON-TECHNICAL LOSSES IN RURAL CONSUMERS

AUTHOR: MAICON COELHO EVALDT
ADVISER: ALZENIRA DA ROSA ABAIDE
CO ADVISER: LUCIANO LOPES PFITSCHER
Defense Place and Date: Santa Maria, December 19, 2018.

Non-technical losses have a significant impact on power distribution networks, and they are among the major concerns of the agents involved in power systems. Particularly in rural distribution networks, consumers with crop irrigation systems characterize situations of difficult detection of non-technical losses for power utilities, considering different existing irrigation processes, climatic characteristics and difficulties of local inspection. This work presents a proposal for the identification of non-technical energy losses in rural feeders containing pumping systems for irrigation of rice crops. The proposed methodology is based on the correlation of the electric energy consumption patterns, the characteristics of the irrigated area and the climatic conditions of the irrigation period. The methodology uses an Artificial Neural System composed by Artificial Neural Networks, and it uses as inputs: rainfall, temperature, solar incidence, air humidity, installed power load, irrigated area, soil type, soil elevation height, level off automation and irrigation methodology of the rice cultivation. The final results indicate, for each analyzed consumer, the percentage risk of non-technical losses. The Artificial Neural System allows the analysis of irrigated rice crops in any region of Brazil, independently of the characteristics of the crop, soil and environment. The results of the work were obtained and validated from a real data base of harvests from the period between 2009 and 2014, for crops of the State of Rio Grande do Sul.

Index Terms: Non-technical Losses, Artificial Neural System, Rural Consumers.

LISTA DE FIGURAS

Figura 2.1 – Sistema de automação proposto e interface de supervisão e controle do usuário	28
Figura 2.2 – Distribuição e tipos de solo do Brasil.....	29
Figura 2.3 – Bombas de irrigação – Início do levante para lavouras de arroz.	31
Figura 2.4 – Desague: etapa final do levante lavouras de arroz	32
Figura 2.5 – Lavoura sistematizada em nível.....	33
Figura 2.6 – Lavoura sistematizada em desnível.....	34
Figura 2.7 – Percentual das perdas elétricas globais de concessionárias de energia em 2015.....	38
Figura 2.8 – Percentuais de perdas técnicas e não técnicas de concessionárias de energia no período de 2000 a 2015 sobre o total gerado.....	38
Figura 2.9 – Esquema de uma rede elétrica com perdas técnicas e não técnicas.....	42
Figura 2.10 – Rede Neural Artificial – Estrutura de Kohonen	50
Figura 2.11 – Rede Neural Artificial – Estrutura Multilayer Perceptron	50
Figura 3.1 – Fluxograma geral da metodologia proposta.	57
Figura 3.2 – Dados de Entrada e Saída do Sistema Proposto	58
Figura 3.3 – Entradas do modelo relacionadas as Informações da UC.....	60
Figura 3.4 – Visão da modelagem formando o Sistema Neural Artificial - SNA	62
Figura 3.5 – Distribuição de Estações Meteorológicas no Brasil	63
Figura 3.6 – Consumo de energia elétrica em um sistema de irrigação obtido com o programa Elo50	64
Figura 3.7 – Unidade consumidora UC-1.....	65
Figura 3.8 – Unidade consumidora UC-2.....	65
Figura 3.9 – Unidade consumidora UC-3.....	65
Figura 3.10 – Identificação tipo de solo no Brasil	66
Figura 3.11 – Rede Neural Artificial proposta	68
Figura 3.12 – Validação Cruzada com $K = 10$	70
Figura 3.13 – Três redes treinadas com Validação Direta.....	71
Figura 4.1 – Resultado da Regressão Stepwise para UC-3/ Safra 13-14.....	77
Figura 4.2 – Relação entre número de neurônios na camada intermediária e o erro de treinamento da RNA 1.....	79
Figura 4.3 – Resultado da RNA com Validação Cruzada (1º conjunto de dados)	80
Figura 4.4 – Resultado da RNA com Validação Cruzada (2º conjunto de dados)	80
Figura 4.5 – Resultado da RNA com Validação Cruzada (3º conjunto de dados)	81
Figura 4.6 – Resultado da análise de UC-1 com RNA e Validação Direta.....	82

Figura 4.7 – Detalhe do resultado da análise de um mês de UC-1 com RNA e Validação Direta.....	82
Figura 4.8 – Resultado da análise de UC-2 com RNA e Validação Direta.....	83
Figura 4.9 – Detalhe do resultado da análise de um mês de UC-2 com RNA e Validação Direta.....	83
Figura 4.10 – Resultado da análise de UC-3 com RNA e Validação Direta.....	84
Figura 4.11 – Detalhe do resultado da análise de um mês de UC-3 com RNA e Validação Direta.....	84
Figura 4.12 – Rede Neural Artificial 8 do SNA.....	90
Figura 4.13 – Relação entre número de neurônios na camada intermediária e o erro de treinamento da RNA 8 do SNA.....	91
Figura 4.14 – Resultado da análise do estudo I para a lavoura UC-1 safra 2009/2010 com Validação Direta da RNA 8 do SNA.....	91
Figura 4.15 – Resultado da análise do estudo I para a lavoura UC-1 para 30 dias da RNA 8 do SNA.....	92
Figura 4.16 – Rede Neural Artificial 16 do SNA.....	94
Figura 4.17 – Relação entre número de neurônios na camada intermediária e o erro de treinamento da RNA 16 do SNA.....	95
Figura 4.18 – Resultado da análise do estudo para a lavoura UC-2 safra 09/10 com Validação Direta da RNA 16 do SNA.....	95
Figura 4.19 – Resultado da análise do estudo II para a lavoura UC-2 para 30 dias da RNA 16 do SNA.....	96
Figura 4.20 – Rede Neural Artificial 7 do SNA.....	98
Figura 4.21 – Relação entre número de neurônios na camada intermediária e o erro de treinamento da RNA 7 do SNA.....	99
Figura 4.22 – Resultado da análise do estudo III para a lavoura UC-3 safra 09/10 com Validação Direta da RNA 7 do SNA.....	99
Figura 4.23 – Resultado da análise do estudo III para a lavoura UC-3 para 30 dias da RNA 7 do SNA.....	100
Figura 4.24 – Resultado da simulação de falha na medição de UC-3.....	102
Figura 4.25 – Detalhe do resultado da simulação de falha na UC-3, Safra 09-10..	103

LISTA DE QUADROS

Quadro 2.1 – Classificação dos solos quanto ao seu nível de drenagem....	30
Quadro 2.2 – Dados gerais de levante para arroz irrigado	31
Quadro 2.3 – Sistematização do solo em nível: vantagens e desvantagens	34
Quadro 2.4 – Sistematização do solo em desnível - vantagens e desvantagens.....	35
Quadro 2.5 – Percentual de perdas não técnicas das concessionárias de energia brasileiras em 2016.....	40
Quadro 2.6 – Perdas técnicas típicas em redes elétricas no Brasil	43
Quadro 2.7 – Relação de trabalhos que empregam Estimação de Estados no Sistema de Distribuição	46
Quadro 2.8 – Fatores que podem influenciar na curva de carga de um consumidor	48
Quadro 2.9 – Síntese de aspectos relevantes de parâmetros aplicados à Tese	54
Quadro 3.1 – Escolha da Rede Neural relacionada as Informações da Lavoura.....	61
Quadro 3.2 – Dados gerais das lavouras.....	67
Quadro 3.3 – Índice de possibilidade de perdas não técnicas.....	73
Quadro 4.1 – Análise de correlação pelo Coeficiente de Pearson / UC-1 2009/2010.....	75
Quadro 4.2 – Análise de correlação do consumo de energia com clima para UC-1	76
Quadro 4.3 – Resumo da análise de UC-1 modelada com RNA e Validação Direta.....	85
Quadro 4.4 – Resumo da análise de UC-2 modelada com RNA e Validação Direta.....	85
Quadro 4.5 – Resumo da análise de UC-3 modelada com RNA e Validação Direta.....	85
Quadro 4.6 – Fator de redução do consumo aplicado com dados Complementares.....	86
Quadro 4.7 – Redução simulada de consumo nas RNAs.....	87
Quadro 4.8 – Escolha da Rede Neural relacionada as informações Inferidas (RNA 8).	89
Quadro 4.9 – Informações complementares para UC-1 RNA 8.....	89
Quadro 4.10 – Informações complementares para UC-2 RNA 16.....	93
Quadro 4.11 – Escolha da Rede Neural relacionada as informações Inferidas (RNA 16).	93
Quadro 4.12 – Informações complementares para UC-2 RNA 7.....	97

Quadro 4.13 – Escolha da Rede Neural relacionada as informações inferidas (RNA 7).....	97
Quadro 4.14 – Resumo da análise de UC-1 RNA 8 do SNA modelada com Validação Direta.	101
Quadro 4.15 – Resumo da análise de UC-2 RNA 16 do SNA modelada com Validação Direta..	101
Quadro 4.16 – Resumo da análise de UC-3 RNA 7 do SNA modelada com Validação Direta..	101
Quadro 4.17 – Resumo da análise de UC-3 com simulação de falha de medição.....	103

LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
BT	Baixa Tensão
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
DNU	Dia Não Útil
DU	Dia Útil
I	Corrente (A)
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
P	Potência ativa (W)
p.u.	Por unidade
PRODIST	Procedimento de Distribuição do Setor Elétrico Nacional
RNA	Redes Neurais Artificiais
RSME	<i>Root Mean Square Error</i>
SNA	Sistema Neural Artificial
SEP	Sistema Elétrico de Potência
T	Temperatura (°C)

LISTA DE APÊNDICES

APÊNDICE A – FUNDAMENTAÇÃO TEÓRICA DO MÉTODO APLICADO	115
APÊNDICE B – INFORMAÇÕES BASE PARA O SNA.....	128
APÊNDICE C – REDE NEURAL ARTIFICIAL DESENVOLVIDA EM PYTHON®.....	130
APÊNDICE D – RESULTADOS DE CORRELAÇÃO ENTRE CONSUMO DE ENERGIA E VARIÁVEIS CLIMÁTICAS	132
APÊNDICE E – CÓDIGO PARA ANÁLISE DE REGRESSÃO <i>STEPWISE</i> E RESULTADOS PARA UC-3.....	135
APÊNDICE F – FERRAMENTA DE VISUALIZAÇÃO DE ANÁLISE DE PERDAS DESENVOLVIDA EM VISUAL BASIC.....	145

SUMÁRIO

1. INTRODUÇÃO	20
1.1 Justificativa.....	21
1.2 Metodologia.....	21
1.3 Objetivos	22
1.4 Contribuições Inovadoras	23
1.5 Estrutura do trabalho.....	24
2. REVISÃO BIBLIOGRÁFICA	25
2.1 Caraterísticas das lavouras de arroz irrigado.....	25
2.2 Métodos de irrigação empregados em lavouras de arroz	26
2.3 Automação em lavouras de arroz irrigado	27
2.4 Caraterísticas de solos em lavouras de arroz	29
2.5 Características do Levante	30
2.6 Características de Sistematização e Nivelamento do Solo	32
2.6.1 Sistematização do solo em nível	33
2.6.2 Sistematização do solo em desnível	34
2.7 Particularidades do consumo de energia em áreas rurais	35
2.8 Perdas não técnicas em Sistemas de Potência	37
2.9 Detecção de perdas não técnicas	41
2.9.1 Estimação de perdas não técnicas a partir das perdas globais e técnicas	41
2.9.2 Estimação de perdas a partir de Estimadores de Estado das Redes de Distribuição	45
2.9.3 Detecção de perdas não técnicas a partir dos perfis de consumidores	47
2.9.4 Monitoramento de perdas com medidores eletrônicos	51
2.10 Considerações finais do capítulo	53
3. METODOLOGIA PROPOSTA	56
3.1 Fluxograma geral proposto para identificação de perdas não técnicas	56
3.2 Aquisição e tratamento de dados.....	57
3.3 Modelagem, análise e validação	59
3.4 Descrição do conjunto de dados para teste e validação	62
3.4.1 Dados climatológicos.....	63
3.4.2 Características de energia elétrica relacionada as lavouras	64
3.4.3 Características das lavouras	64
3.5 Implementação e Análise por Redes Neurais Artificiais.....	67
3.6 Treinamento com Validação Cruzada K-Fold	69
3.7 Treinamento com Validação Direta	70
3.8 Indicativo de perdas elétricas não técnicas.....	71
4. RESULTADOS E DISCUSSÃO	74
4.1 Correlação entre consumo de energia elétrica e clima	74
4.2 Análise por Regressão Stepwise	76
4.3 Análise da Rede Neural Artificial Base do SNA (RNA 1)	78
4.3.1 Validação Cruzada K-Fold	79
4.3.2 Validação Direta.....	81
4.4 Análise do Sistema Neural Artificial	86
4.4.1 Características, treinamento e escolha da rede no SNA.....	86
4.4.2 Análise da RNA 8 aplicada à UC-1	88

4.4.3	Análise da RNA 16 aplicada à UC-2.....	92
4.4.4	Análise da RNA 7 aplicada à UC-3.....	96
4.5	Resumo dos Resultados para RNA 8, RNA 16 e RNA 7.	100
4.6	Resultados de simulação de uma situação de perda não técnica	102
5. CONSIDERAÇÕES FINAIS		104
Sugestões de Continuidade		106
REFERÊNCIAS BIBLIOGRÁFICAS		107
APÊNDICE A – FUNDAMENTAÇÃO TEÓRICA DO MÉTODO APLICADO		115
APÊNDICE B – INFORMAÇÕES BASE PARA O SNA.....		128
APÊNDICE C – REDE NEURAL ARTIFICIAL DESENVOLVIDA EM PYTHON®.....		130
APÊNDICE D – RESULTADOS DE CORRELAÇÃO ENTRE CONSUMO DE ENERGIA E VARIÁVEIS CLIMÁTICAS		132
APÊNDICE E – CÓDIGO PARA ANÁLISE DE REGRESSÃO <i>STEPWISE</i> E RESULTADOS PARA UC-3.....		135
APÊNDICE F – FERRAMENTA DE VISUALIZAÇÃO DE ANÁLISE DE PERDAS DESENVOLVIDA EM VISUAL BASIC.....		145

1. INTRODUÇÃO

A energia elétrica é um recurso utilizado nos diversos setores de transformação e na sociedade contemporânea e relaciona-se diretamente à disponibilidade e qualidade de indicadores do desenvolvimento social e econômico de um país ou região. Nesse sentido, na expectativa de aumento da demanda de energia, torna-se indispensável o acompanhamento de estudos e planejamento de expansão do Sistema Elétrico de Potência.

Por outro lado, quando a energia elétrica produzida não é devidamente aproveitada, entende-se que o sistema é ineficiente do ponto de vista energético e que os investimentos em ampliação da capacidade de produção de energia não são plenamente usufruídos. É o que acontece, por exemplo, em um sistema com elevados índices de perdas elétricas.

De modo geral, as perdas elétricas nos Sistemas de Potência podem ser divididas em dois grandes grupos: as perdas inerentes aos sistemas elétricos, devidas aos fenômenos físicos envolvidos na geração, transmissão e distribuição de energia elétrica, e que são usualmente referidas como *perdas técnicas*; e as perdas relacionadas ao processo de faturamento das concessionárias distribuidoras de energia, conhecidas como *perdas não técnicas*. Entre os exemplos mais comuns relacionados a perdas não técnicas destacam-se o furto de energia e fraudes no sistema de medição.

No Brasil, as perdas não técnicas implicam em prejuízos na faixa de bilhões de Reais (ANEEL, 2016), no contexto global das Concessionárias de Energia. Para ilustrar um exemplo, a AME, (Amazonas Distribuidora de Energia S/A), registrou em 2016 mais de um terço (1/3) de perdas não técnicas dentre a sua produção e distribuição anual de energia.

Além da questão econômica, as perdas não técnicas impactam no próprio planejamento e operação da rede, uma vez que investimentos em expansão e equipamentos podem ser necessários para suprir um consumo não previsto e /ou não faturado, e que consumidores ilegais podem interferir na segurança e qualidade de energia da rede.

1.1 Justificativa

Diante do contexto apresentado, essa Tese aborda o problema das perdas não técnicas em sistemas de distribuição de energia. O escopo do trabalho envolve alimentadores com consumidores rurais e caracterizados pela utilização de sistemas de bombeamento de água para irrigação de lavouras de arroz, conhecidos como levantes.

A definição desse escopo levou em consideração a forte característica de produção agrícola de arroz irrigado no Brasil, em especial no Estado do Rio Grande do Sul, e as carências de estudos sobre perdas não técnicas nesse tipo de consumidores de energia elétrica.

Em geral, os sistemas de irrigação de grandes lavouras de arroz possuem potência instalada na faixa de algumas centenas de kVA, o que ressalta a relevância desse tipo de consumidor na rede elétrica. Além disso, devido a grandes distâncias envolvidas e dificuldade de acesso em algumas situações, a fiscalização e identificação de fraudes acaba sendo limitada, por parte das Concessionárias de Energia, o que torna o sistema mais susceptível ao problema das perdas não técnicas.

1.2 Metodologia

A proposta dessa Tese é desenvolver um sistema que auxilie na identificação de possíveis situações de perdas não técnicas, baseado em históricos e padrões de consumo, e considerando características próprias das lavouras e registros climatológicos.

A metodologia proposta emprega um conjunto de Redes Neurais Artificiais (RNAs), treinadas com dados reais de lavouras de arroz com diferentes características de irrigação. O Sistema Neural Artificial - SNA - desenvolvido emprega a RNA *Perceptron* de múltiplas camadas, e utiliza informações básicas de entrada, como localização, dimensões da lavoura e potência instalada, e informações complementares, como altura do levante e nível de automação da

lavoura. As informações básicas compreendem dados que podem ser obtidos sem a necessidade de vistoria *in loco*.

A saída do SNA é uma indicação do consumo de energia esperado, o qual pode ser comparado com o consumo faturado. A partir do consumo de energia determinado pelo Sistema Neural Artificial, e do consumo de energia faturado, é definido um índice de possibilidade de ocorrência de perdas não técnicas na lavoura analisada.

De posse dos índices de possibilidade de perdas não técnicas, as concessionárias poderão traçar planos de prevenção e combate a fraudes de maneira mais eficiente e econômica, focando seus esforços onde a probabilidade de prejuízo encontra-se mais evidente.

As RNAs desenvolvidas nesse trabalho foram construídas em linguagem de programação Python®, utilizando bibliotecas específicas de redes neurais, que auxiliam no desenvolvimento de uma solução para a aplicação apresentada.

1.3 Objetivos

O objetivo geral desse trabalho é:

- Desenvolver uma metodologia para identificar situações de ocorrência de perdas não técnicas em redes elétricas com sistemas de irrigação de lavouras de arroz, por meio da verificação das relações entre consumo de energia elétrica e características das lavouras de arroz e de variáveis climáticas, empregando Redes Neurais Artificiais.

Para atender ao objetivo geral, o mesmo foi desmembrado nos seguintes objetivos específicos:

- Analisar a relação entre consumo de energia elétrica, características das lavouras, e informações climatológicas.

- Desenvolver um Sistema Neural Artificial para determinação do consumo de energia esperado nas lavouras, empregando um processo de seleção de dados para treinamento e validação.

- Desenvolver uma ferramenta que avalie os resultados de análise e indique a possibilidade de perda não técnica em cada caso, para lavouras com diferentes características, a partir de delimitações do usuário.

1.4 Contribuições Inovadoras

A literatura técnica apresenta diversos trabalhos que tratam da previsão de consumo de energia elétrica utilizando Redes Neurais Artificiais. No entanto, quando se considera um sistema que possa suportar uma grande variação de dados de entradas, a quantidade diminui sensivelmente, pois grande parte das redes encontradas trabalha basicamente com histórico de consumo e características de clima, neste último, especialmente variação de temperatura.

Uma proposta focada em perdas não técnicas rurais utilizando Redes Neurais Artificiais tem um caráter inovador e com grande possibilidade de aplicação, tendo em vista a ausência de estudos similares e o interesse no tema, por parte de agentes do setor elétrico.

Essa Tese busca responder às seguintes perguntas:

- É possível identificar perdas não técnicas em consumidores rurais irrigantes, empregando um sistema de Redes Neurais Artificiais?
- Para estimação de consumo de energia elétrica empregando Redes Neurais Artificiais, a quantidade de dados de entradas do sistema tende a melhorar os resultados?

Assim, esse trabalho pretende contribuir com originalidade nos seguintes itens:

- Desenvolvimento de uma metodologia de detecção de perdas não técnicas em alimentadores rurais com sistemas de irrigação de lavouras de arroz, que emprega dados disponíveis (como consumo de energia e dados climáticos) sem a necessidade de inspeção em campo e/ou utilização de equipamentos específicos para tal;
- Desenvolvimento de um sistema com capacidade de estimar o consumo de energia em lavouras de arroz irrigado, com múltiplas entradas de dados, e que seja auto adaptável ao tipo de informação disponível sobre as lavouras;

- Elaboração de uma ferramenta que possa ser utilizada em Centros de Operações de Concessionárias ou Cooperativas de energia, para obter indicativos de fraude.

1.5 Estrutura do trabalho

Esse trabalho foi dividido em cinco capítulos, conforme segue:

- Capítulo 1: nesse capítulo, introdutório, é feita a contextualização do tema abordado na Tese, e são definidos os objetivos do trabalho.
- Capítulo 2: apresenta a revisão bibliográfica do trabalho, dividida em duas partes principais: caracterização dos sistemas de irrigação de lavouras de arroz e caracterização e detecção de perdas não técnicas.
- Capítulo 3: apresenta a metodologia desenvolvida para detecção de perdas não técnicas em lavouras de arroz irrigado, em particular, o Sistema Neural Artificial.
- Capítulo 4: nesse capítulo, são apresentados os resultados desta Tese.
- Capítulo 5: Nesse capítulo são apresentadas considerações finais e proposta de continuidade deste trabalho.

Os Apêndices apresentam informações complementares desenvolvidas na Tese, entre as quais uma revisão teórica de Redes Neurais Artificiais, e a descrição dos programas (códigos de programação, telas supervisórios) e outros resultados obtidos além dos apresentados no Capítulo 4.

2. REVISÃO BIBLIOGRÁFICA

Neste capítulo é apresentada uma síntese da revisão bibliográfica realizada sobre características das lavouras de arroz irrigado, perdas não técnicas, e ferramentas para modelagem e análise relacionadas a esse tema. A abordagem foi dividida em duas partes principais: caracterização do ambiente de aplicação (lavouras de arroz irrigado), e detecção de perdas em Sistemas de Potência. Ao final do capítulo, são feitas considerações que embasam a metodologia empregada nessa Tese.

2.1 Características das lavouras de arroz irrigado

O escopo dessa Tese abrange consumidores rurais com sistemas de irrigação para lavouras de arroz.

Segundo o Instituto Rio Grandense do Arroz (IRGA 2016), os produtores de arroz do Rio Grande do Sul (RS), em 2016, plantaram cerca de 1,1 milhões de hectares. Isso representa 22 vezes a área da cidade de Porto Alegre, capital do Estado, e 3,1% do território do RS. No Brasil a área de produção aproxima-se de 2 milhões de hectares.

A irrigação corresponde a 5,28% do custo de produção de arroz irrigado. Para o ano de 2016, o custo total foi na faixa de 6.715 R\$/ha, o que representa, neste ano, R\$ 710 milhões envolvidos nesta etapa do plantio.

Observa-se que os custos apresentados estão muito relacionados às características intrínsecas desta cultura, que necessita de água em maior quantidade quando comparada com outras culturas. Porém, uma parcela considerável do custo deve-se ao tradicional regime de irrigação utilizado, onde as bombas de levante permanecem ligadas aproximadamente 21 horas por dia, sendo desligadas apenas nos horários de ponta. Além disso, alguns fatores podem aumentar a necessidade de energia para o bombeamento de água, como o nivelamento do terreno, altura do levante e tipo de solo.

Destaca-se que o percentual de custo associado à irrigação poderia ser significativamente reduzido se houvesse a implementação de automação nas

lavouras. Porém, atualmente a aplicação desta tecnologia ainda não é difundida, e praticamente reduzida a alguns projetos pilotos, exemplificados nesse capítulo.

2.2 Métodos de irrigação empregados em lavouras de arroz

O consumo de água no planeta pode ser resumido para três principais finalidades: doméstico, industrial e agrícola, objeto de estudo indireto nesta Tese.

MOLDEN et al. (2007) aponta que em torno de 60% da utilização das águas que derivam de canais e cursos d'água no Brasil são utilizados com finalidade agrícola, mais especificamente irrigação.

Devido à relevância destes dados, deve-se estimular um manejo racional da irrigação e a otimização dos equipamentos elétricos utilizados, com a finalidade de tornar a utilização da água e da energia elétrica mais eficientes.

Mantovani et al. (2016), considera que há um processo de modernização nos sistemas de irrigação, mas que a imprecisão técnica de manejo, sistemas e métodos inadequados de irrigação podem ocasionar duas consequências: falta de água, que leva à perda total da região atingida, e, mais comumente, o excesso de água, que resulta em perdas como diminuição de nutrientes, erosões e ineficiência no uso da água e energia elétrica.

Nas lavouras de arroz irrigado observa-se uma crescente preocupação com o manejo de água, por diversos motivos. Segundo Martins et al. (2010), o uso de forma racional da água em processos de irrigação deve acontecer pelo viés da eficiência dos equipamentos e sistemas de irrigação, consequentemente resultando na diminuição do consumo de água e energia elétrica.

Para a produção de arroz são utilizadas tradicionalmente três modalidades de irrigação;

- **Irrigação contínua:** utiliza um grande volume de água e com baixa eficiência energética, pois o sistema de irrigação fica permanentemente ligado (Corrêa et al. 1997);

- **Inundação estática:** Preserva-se a lâmina de água entre 5 e 10 cm, porém com comunicação entre os diversos quadros da lavoura. No subitem 2.6 detalha-se a metodologia de terrenos sistematizados em desnível com diversos quadros.

- **Solo saturado:** Nesse tipo de sistema, o solo é mantido encharcado, com uma lâmina mínima de água.

Em 2011, a Universidade Federal do Pampa (UNIPAMPA, RS), em um projeto de eficiência energética com a Concessionária AES Sul (atualmente, RGE Sul), implementou um sistema de automação com o objetivo de controlar e monitorar a lâmina d'água em lavouras de arroz irrigado (PFITSCHER et al., 2012). Nesta pesquisa identificou-se uma diferença de consumo de energia elétrica bastante expressiva com a automação dos métodos de irrigação supracitados.

Yang et al. (2006) identifica a mesma linha de eficiência em lavouras que utilizam métodos de irrigação com menos recursos hídricos, e que possuem algum nível de automação.

2.3 Automação em lavouras de arroz irrigado

Encontra-se na literatura trabalhos propostos para implantação de automação da irrigação em lavouras de arroz. De maneira geral propõe-se a redução da utilização de água e, conseqüentemente, de energia elétrica.

Em PFITSCHER et al. (2012), apresentou-se a automação de uma lavoura de arroz irrigado com base no monitoramento e controle do nível d'água. O sistema possui interface com o usuário, controle de vazão através da variação da frequência dos motores das bombas, por meio de inversores de frequência, e sensoriamento remoto com comunicação sem fio. Os resultados do projeto apresentaram a diminuição de até 85% do consumo de água, e de até 81% do consumo de energia elétrica, dependendo da metodologia de irrigação e do nível de sensoriamento da área, quando comparado com o sistema tradicional de irrigação contínua e sem automação.

A Figura 2.1 apresenta uma visão geral do sistema proposto e interface de supervisão e controle do usuário, implementado em um sistema SCADA (*Supervisory Control and Data Acquisition*). Nessa figura, a primeira parcela¹ da lavoura representa o sistema convencional, em que a bomba de irrigação fica

¹ Em lavouras de arroz, o termo "parcela" compreende uma divisão da lavoura, normalmente determinada pelo nivelamento do terreno e delimitada por um volume de terra que represa a água naquela área.

permanentemente ligada. As demais parcelas possuem sensores de nível da lâmina de água e o acionamento das bombas de irrigação é feito de acordo com a técnica de irrigação testada.




Figura 2.1 – sistema proposto e interface de supervisão e controle do usuário

Fonte: PFITSCHER, 2012

O trabalho de Behrens (2013) apresenta uma descrição de técnicas de sistematização do solo e irrigação das lavouras, com ênfase na automação e eficiência energética do sistema elétrico de alimentação das bombas de irrigação. O autor propõe uma metodologia de monitoramento das condições climáticas para acionar as bombas com rotação variável, de acordo com índices pluviométricos e previsão de clima.

Na automação dos canais de irrigação, as vazões podem ser previamente programadas e automaticamente mantidas utilizando reguladores eletromecânicos, por meio dos níveis identificados nos pontos de sensoriamento de água (LITRICO et al., 2015).

Na Austrália, MAREELS et al. (2005), faz um comparativo de lavouras que utilizam comportas com regulagem automática, frente ao processo de controle de nível feito manualmente por aguadores (pessoas que trabalham na lavoura, abrindo e fechando os pontos de entradas e saídas de água em cada quadro). Este tipo de automação atinge índices de eficiência na utilização de água de até 20%,

dependendo da metodologia de plantio e das características gerais das lavouras, como o tipo de solo.

2.4 Características de solos em lavouras de arroz

Pode-se definir o solo como um conjunto de corpos naturais formados por partes sólidas, líquidas e gasosas (EMBRAPA, 2006).

Para o plantio de arroz irrigado (SOSBAI, 2012), algumas características são fundamentais para a produtividade e eficiência de recursos naturais e energéticos, como: ausência de solos arenosos, pedregosos e compostos de argila expansiva (causadora de degradação do solo), baixas declividade e irregularidade superficiais do terreno, e capacidade de drenagem do solo baixa ou nula.

STONE (2005) apresenta um conjunto de exemplos relacionando perdas com a textura do solo em lavouras de arroz. Estes estudos demonstram que as perdas em volume de água por percolação (infiltração de água no solo) e fluxo lateral (através das parcelas) são da ordem de 35,5%.

Segundo (EMBRAPA, 2013), no Sistema Brasileiro de Classificação de Solos, existem treze classes de solos atuais para o primeiro nível categórico de classificação, distribuídos e relacionados conforme Figura 2.2.




Figura 2.2 – Distribuição e tipos de solo do Brasil

Fonte: Embrapa, (2013)

Para estabelecer uma relação de perdas com os diferentes tipos de solos de primeiro nível do Brasil, considerou-se como aspecto fundamental o nível de drenagem de cada tipo, conforme o quadro 2.1.

Quadro 2.1 – Classificação dos solos quanto ao seu nível de drenagem.

Tipos de Solo	Drenagem Boa	Drenagem Media	Drenagem Ruim	Drenagem Muito Ruim
Argissolos	X	X		
Cambissolos		X		
Nitossolos	X			
Neossolos	X			
Chernossolos		X		
Luvissolos			X	
Gleissolos			X	X
Plintossolos			X	
Planossolos			X	
Organossolos				X
Vertissolos			X	
Latossolos	X			
Espodossolos	X	X		

Fonte: Adaptado de Resende (1986).

Com os dados de drenagem por tipo de solo, pode-se atribuir qualitativamente o nível de necessidade de irrigação da lavoura e uma tendência de perdas nesse sistema.

2.5 Características do Levante

Esse tipo de sistema é conhecido como a primeira etapa de irrigação da lavoura, que consiste no bombeamento da água de reservatórios, rios ou lagos, e distribuição para a lavoura através de canais (Mahar e Singh 2014).

Segundo IRGA (2011), a irrigação na lavoura é uma das etapas mais importantes de um processo produtivo, considerando aspectos fundamentais como volume de água por hectare, tempo de irrigação, altura da lâmina d'água, entre outras características, apresentadas na Quadro 2.2.

Quadro 2.2 – Dados gerais de levante para arroz irrigado.

Dados de irrigação	Grandezas e Unidades	
Volume por ha (total)	8.000 m ³ (mínimo)	14.000 m ³ (máximo)
Volume por ha oriundo do levante	4.200 m ³ (mínimo)	7.0000 m ³ (máximo)
Volume por ha oriundo de precipitação	7.000 m ³ (mínimo)	9.800 m ³ (máximo)
Vazão por ha no início da irrigação	3 L/s/ha (mínimo)	5 L/s/ha (máximo)
Vazão por ha para manutenção da irrigação	1 L/s/ha (mínimo)	1,5 L/s/ha (máximo)
Tempo de irrigação	80 dias (mínimo)	100 dias (máximo)
Espessura da lâmina	2,5 mm (mínimo)	10 mm (máximo)
Altura de Levante*	< 0 Natural (gravidade)	50 m (máximo)

Fonte: IRGA (2011) e *IRGA (2016)

As Figuras 2.3 e 2.4 mostram dois típicos sistemas de levante para irrigação de lavouras de arroz.



Figura 2.3 – Bombas de irrigação – Início do levante para lavouras de arroz

Fonte: AES SUL (2006)

Os motores elétricos utilizados nesses sistemas de irrigação são motores de indução trifásicos, em instalações com potências que variam tipicamente entre 100 e 300 CV (AES SUL 2006).

Depois de bombeada, a água chega por meio de dutos até os canais de irrigação, a partir dos quais será transferida para as parcelas da lavoura através de dutos secundários e aberturas entre as parcelas.



Figura 2.4 – Desague no canal de irrigação – Fim do levante em lavouras de arroz

Fonte: IRGA (2011)

Na maioria das vezes, a dispersão da água na lavoura é feita com manejo manual e utilizando a declividade do terreno previamente preparado (IRGA 2011).

2.6 Características de Sistematização e Nivelamento do Solo

Conceitualmente, a declividade de um solo é a diferença entre dois pontos com o plano horizontal. Pode-se obter a mesma em graus ou percentualmente. Para a plantação de arroz irrigado, é fundamental considerar esta variável por conta da necessidade do controle do nível d'água, do monitoramento do escoamento na lavoura, e conseqüentemente, do uso eficaz do recurso hídrico (IRGA 2011).

Destaca-se que, mesmo antes do plantio do arroz efetivamente, algumas medidas são indispensáveis para garantir a eficiência da lavoura e do uso responsável do solo. Entre estas medidas pode-se citar o projeto de sistematização

da área e construção de canais de irrigação e drenagem. Esta projeção também deve incluir a criação de um sistema de manejo funcional com abertura de estradas internas, e preparação da superfície do solo, independentemente do método de plantio (em nível ou desnível), descritos na sequência.

2.6.1 Sistematização do solo em nível

A sistematização em nível consiste em subdividir uma área em diversas áreas menores, geralmente em retângulos que possuem o tamanho definido pelo desnivelamento (quanto maior o desnível, menor o retângulo) ou pelo plano de manejo previamente definido, considerando outros aspectos como nível de drenagem, comportamento do escoamento da água, taipas e acessos de trabalho (Sosbai – 2012). A Figura 2.5 apresenta um exemplo de lavoura sistematizada em nível.



Figura 2.5 – lavoura sistematizada em nível.

Fonte: NUNES, 2007

Observam-se algumas vantagens e desvantagens nesta metodologia de sistematização em nível, elencadas no Quadro 2.3.

Quadro 2.3 – Sistematização do solo em nível - vantagens e desvantagens

Vantagens	Distribuição eficiente da água
	Controle de plantas daninhas
	Redução da incidência de pragas e doenças
Desvantagens	Dificuldade de alternância com outras culturas
	Drenagem superficial
	Custo inicial do nivelamento

Fonte: (Sosbai – 2012)

Um aspecto fundamental para projeção do consumo de água em lavouras com sistematização em nível é a declividade média. Pode-se considerar uma declividade baixa quando a mesma se encontra entre 0 e 3%, média entre 3 e 6% e grande de acima de 6% (IRGA 2016). Quanto maior o declive, maior é o volume de água necessário e menor é o tamanho do quadro.

2.6.2 Sistematização do solo em desnível

Neste sistema busca-se manter o nivelamento com várias cotas manejando os solos do nível mais elevado para os de níveis mais baixos. Observa-se que a declividade natural é preservada e a irrigação é feita a partir da cota mais elevada, passando entre as taipas da parcela mais elevada, até o nível de drenagem final (SOSBAI – 2012). A Figura 2.6 apresenta um exemplo de lavoura sistematizada em desnível.



Figura 2.6 – lavoura sistematizada em desnível.

Fonte: NUNES, 2007

Esta metodologia de sistematização também apresenta algumas vantagens e desvantagens, elencadas na Quadro 2.4.

Quadro 2.4 – Sistematização do solo em desnível - vantagens e desvantagens

Vantagens	Menor movimento de terra
	Menor custo de preparação
	Melhor drenagem superficial
Desvantagens	Maior volume de água utilizado
	Dificuldades no controle de plantas daninhas
	Inviabilidade de alternância com semeadura em solo seco.

Fonte: (Sosbai – 2012)

2.7 Particularidades do consumo de energia em áreas rurais

As redes elétricas que atendem consumidores em áreas rurais têm características bastante diferenciadas das redes localizadas em centros urbanos.

No nível residencial, a utilização da energia elétrica nas áreas rurais é primordialmente para iluminação e uso de eletrodomésticos.

Além do sistema de bombeamento de água para irrigação, a eletricidade é utilizada no meio agroindustrial em equipamentos utilizados para tratamento após a colheita, como ventiladores para aeração em silos, elevadores de carga, esteiras transportadoras, compressores para refrigeração, entre outros. No entanto, o tratamento do arroz após a colheita é normalmente realizado em agroindústrias, e raramente na propriedade de cultivo.

De modo geral, as principais características das redes elétricas rurais, considerando o sistema brasileiro, são:

- Maiores extensões de rede, podendo chegar a dezenas de quilômetros, com baixa densidade populacional por quilômetro de rede;
- Sazonalidade das curvas de cargas, impactadas especialmente em regiões com intensa atividade agrícola e agroindustrial; isso reflete em um baixo fator de carga dos transformadores. A Eletrobrás, por exemplo, considera o fator de carga

igual a 0,2 em áreas rurais, considerando inclusive as grandes propriedades rurais que possuem maior consumo de energia;

- Dificuldade de manutenção de padrões de qualidade de energia, sendo necessária, em muitos casos, a utilização de equipamentos para compensação das quedas de tensão nos longos trechos de rede.

Ressalta-se, também, que as redes rurais são mais susceptíveis a falhas, devido a uma série de fatores, como dificuldade de monitoramento das condições físicas da rede, limitação de investimentos em equipamentos, maior extensão de rede, entre outros. Além disso, algumas soluções implementadas em redes urbanas são impraticáveis nas redes rurais, como a transferência de cargas para isolar uma determinada falha.

Kersting e Phillips (1992) e Freeman et al. (2009) apresentam algumas considerações sobre redes rurais nos Estados Unidos, mencionando alguns aspectos e problemas similares encontrados no Brasil.

Em áreas rurais, existe uma grande dispersão de consumidores, variando de 0,1 a 5,0 consumidores por quilômetro de rede (RIBEIRO et al, 2012). Segundo a COELBA (2012), de 120.166 domicílios atendidos pelo programa Luz no Campo, 61,8% estavam situados no raio de um quilômetro da rede existente, enquanto 25,7% estavam localizados entre um e cinco quilômetros da rede de energia.

Quando se trata de produção agrícola, especificamente, o cultivo de arroz irrigado é de grande relevância no sistema elétrico brasileiro. Apesar de ser produzido em muitos Estados do Brasil, o cultivo é predominante nos Estados do Rio Grande do Sul, Santa Catarina e Mato Grosso. O Rio Grande do Sul atualmente é responsável por cerca de 50% da produção nacional, segundo dados do IBGE 2016 – Instituto Brasileiro de Geografia e Estatística. No Estado do Rio Grande do Sul, a maior quantidade de área cultivada situa-se nas áreas de concessão das empresas CPFL ENERGIA (Fronteira Oeste, Campanha e Centro) e CEEE (Litoral).

2.8 Perdas não técnicas em Sistemas de Potência

As perdas elétricas em Sistemas de Potência podem ser classificadas em três tipos:

- i) Perdas globais, que envolvem todos os tipos de perdas de energia no sistema;
- ii) Perdas técnicas, que são referentes principalmente a perdas de dissipação de potência (efeito Joule) nos condutores e equipamentos, desde a geração até o ponto final de entrega de energia e;
- iii) Perdas não técnicas, que são a soma de fraudes, desvios e diversas falhas no processo de faturamento das concessionárias responsáveis pela distribuição da energia elétrica.

Desenvolver métodos precisos para identificação e mitigação de perdas não técnicas contribui com a qualidade e a segurança da distribuição de energia elétrica, uma vez que elas impactam diretamente na operação do sistema, causando problemas como sobrecarga e níveis de tensão abaixo dos limites aceitáveis.

Para ilustrar um panorama da dimensão das perdas nos Sistemas de Potência em redes elétricas brasileiras, as Figuras 2.7 e 2.8 apresentam percentuais de perdas globais, técnicas e não técnicas, de diversas concessionárias de energia, a partir de um estudo desenvolvido pela Associação Brasileira de Distribuidoras de Energia Elétrica (ABRADEE, 2012). Na Figura 2.7 observam-se as perdas globais individualizadas por concessionária, e na Figura 2.8 observa-se um histórico de perdas técnicas e não técnicas (no gráfico, apresentadas como perdas comerciais) no período de 10 anos, para um conjunto de 64 concessionárias. Ressalta-se que os índices apresentados se referem ao total da energia elétrica injetada na rede pelas concessionárias. Esses elevados índices implicam na preocupação das concessionárias no combate às perdas e cumprimento de metas definidas pela ANEEL, uma vez que o montante de energia não faturada equivale a diversas usinas de porte considerável operando apenas para suprir perdas (ANEEL, 2016).




Figura 2.7 – Percentual das perdas elétricas globais de concessionárias de energia em 2015.

Fonte: Sistema de Informação para Gestão, ABRADDEE.




Figura 2.8 – Percentuais de perdas técnicas e não técnicas de 64 concessionárias de energia no período de 2000 a 2015 sobre o total gerado.

Fonte: Sistema de Informação para Gestão, ABRADDEE.

As perdas não técnicas, objeto de estudo nessa Tese, são geralmente associadas a fatores sociais e econômicos. No Brasil, a meta de perdas não técnicas a ser alcançada pelas concessionárias de energia é definida pela ANEEL, a partir de modelos econométricos que medem a complexidade socioeconômica de cada região de concessão. Observa-se que a questão socioeconômica é relevante também em outros países, em especial naqueles com alta população e grande extensão territorial, como Índia, Malásia e Estados Unidos.

Chauhan e Rajvanshi (2013) apresentam uma revisão sobre perdas não técnicas em Sistemas de Potência, e relacionam as suas principais causas no sistema de distribuição:

- Adulteração de medidores de energia;
- Conexão ilegal à rede (no Brasil, popularmente conhecida como “gato”);
- Erros ou falsas leituras de consumo;
- Suprimento de energia não medido devido a falhas no registro de consumidores ou no processo de faturamento.

A maioria dos furtos de energia ocorre através de desvios ou ligações clandestinas, como perfuração de eletrodutos ou ganchos de rede para ligação *bypass* de energia elétrica, desvios de energia com acionamento remoto, entre outros (REIS, 2005).

Fraudes significativas podem ocorrer também nos equipamentos do sistema de distribuição, em especial nos medidores de energia. Muitas vezes os defeitos nesses equipamentos podem parecer naturais e são registrados como perdas técnicas, mas na verdade podem ter sido provocados de forma voluntária, com o objetivo de reduzir o consumo de energia medido (CALILI, 2005).

Segundo a ANEEL (2016), no Brasil as perdas não técnicas são responsáveis por um prejuízo de aproximadamente R\$ 8,1 bilhões por ano. A região com maior índice de consumo irregular é a região Norte, com 20% da energia distribuída, seguida de Sudeste, com 10% e de Nordeste, com 9%. No Centro-Oeste, o percentual é de 5%, e no Sul, de 3%. O Quadro 2.5 apresenta um *ranking* das concessionárias mais atingidas pelas perdas não técnicas, de acordo com a ANEEL (2015).

Quadro 2.5 – Percentual de perdas não técnicas das concessionárias de energia brasileiras em 2016.

Posição	Concessionária	Perdas não técnicas
1	AME	37,45%
2	CELPA	19,07%
3	CEAL	18,26%
4	ELETROACRE	13,80%
5	CEEE	11,90%
6	CERON	11,34%
7	CEMAR	8,02%
8	CELPE	7,03%
9	ESCELSA	6,86%
10	ENERSUL	5,90%
11	BOAVISTA	4,49%
12	COELBA	4,42%
13	CELTINS	4,24%
14	BANDEIRANTE	3,94%
15	ELFSM	3,84%

Fonte: ANEEL (2016)

Este tipo de perda, bastante comum no Brasil, ocorre também em grande parte do mundo, incluindo países mais desenvolvidos. Nos Estados Unidos, por exemplo, o valor com o furto de energia é em torno de U\$ 1,6 bilhões por ano, enquanto o Canadá tem perda anual menor, mas ainda significativa, de aproximadamente U\$ 100 milhões por ano (DEPURU, 2012).

Apesar de não ser um problema apenas de países subdesenvolvidos, nestes locais a ocorrência é mais evidenciada. A Malásia, por exemplo, atingiu um recorde de perda por furto de energia elétrica em 2004. Este recorde negativo custou à companhia Tenaga Nasional Berhad cerca de U\$ 229 Milhões. A Índia se compara ao valor de perdas não técnicas do Brasil, atingindo um valor na faixa de U\$ 4,5 bilhões por ano (DEPURU, 2012).

A redução das perdas não técnicas tem um incentivo natural relacionado ao aumento de receita, por parte das concessionárias. No entanto, o impacto das perdas no sistema elétrico pode ser ainda mais relevante. Para o sistema elétrico, as

perdas não técnicas implicam na imprudência no consumo de energia, uma vez que o consumidor que não paga a energia que consome não tem compromisso com a racionalidade do seu uso. Indiretamente, o uso irracional leva a uma necessidade cada vez mais crescente da disponibilidade do recurso energético, com a construção de novas usinas e a ampliação da capacidade das redes. Além disso, existe o impacto na qualidade de energia, tendo em vista que o consumo irregular pode ocasionar sobrecarga nos transformadores e linhas de distribuição, interrupções nos circuitos dos alimentadores, e queda de tensão para os consumidores adimplentes.

2.9 Detecção de perdas não técnicas

Embora a pesquisa relacionada a perdas não técnicas não seja recente, ela tem ganhado um novo viés com o aumento da disponibilidade de recursos tecnológicos e computacionais.

O procedimento mais elementar para detecção de perdas não técnicas é a inspeção local. No entanto, há uma série de fatores limitantes a essa prática. Destaca-se o custo com equipes de inspeção, o tempo necessário para inspecionar grandes áreas e a própria dificuldade de inspeção, uma vez que as situações irregulares nem sempre são perceptíveis com uma simples inspeção visual.

Devido a essas dificuldades, são propostas alternativas para auxiliar equipes de inspeção, limitando as regiões de buscas e, em alguns casos, indicando consumidores suspeitos de fraudes. A seguir, são apresentadas algumas técnicas utilizadas para diagnóstico das perdas não técnicas encontradas na literatura.

2.9.1 Estimação de perdas não técnicas a partir das perdas globais e técnicas

Devido ao fato das perdas não técnicas não serem medidas diretamente nos locais em que ocorrem, o seu montante deve ser estimado. Uma possibilidade é a estimação a partir de uma análise dos alimentadores de distribuição, conhecendo-se seu modelo elétrico (impedâncias da rede e cargas de consumidores regulares) e os totais de energia suprida e faturada.

Da diferença entre a energia suprida e faturada, obtém-se uma indicação das perdas globais, e a partir do modelo elétrico da rede, pode-se obter uma indicação aproximada das perdas técnicas. As perdas não técnicas podem, então, ser estimadas pela diferença entre as perdas globais e as perdas técnicas. A Figura 2.9 ilustra esse conceito. A comparação entre energia suprida e faturada é usualmente conhecida como balanço de energia.

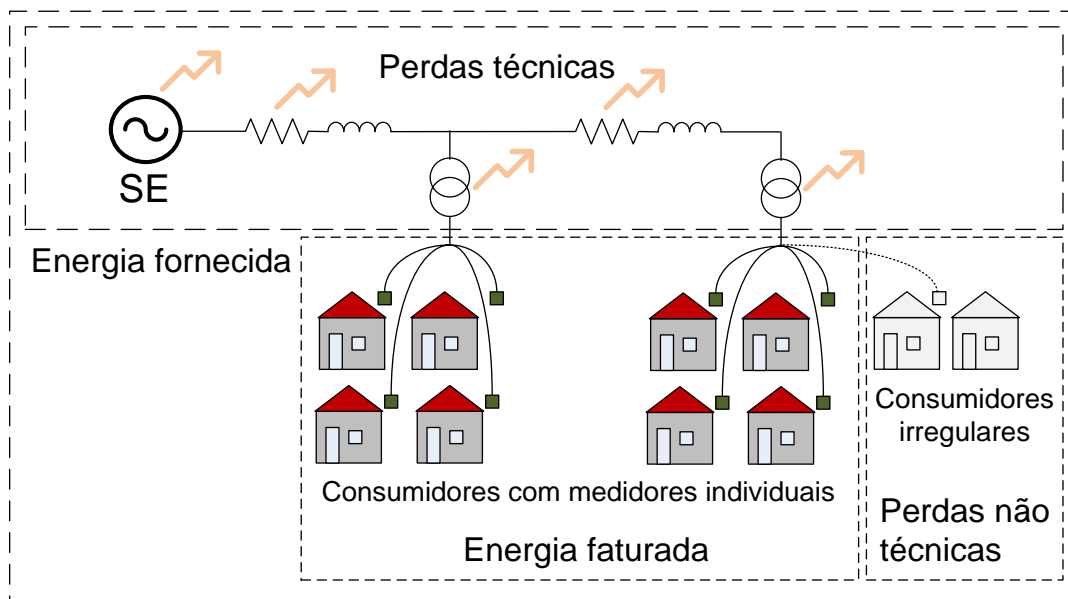


Figura 2.9 – Esquema de uma rede elétrica com perdas técnicas e não técnicas

Fonte: Elaborado pelo autor

Essa metodologia necessita que as perdas técnicas da rede sejam conhecidas. Essas perdas são intrínsecas ao Sistema de Distribuição e devidas principalmente à resistência de condutores elétricos, que transforma a energia elétrica em calor quando a corrente flui através deles. As perdas de energia decorrentes da dissipação de calor em redes elétricas (linhas, cabos, transformadores e outros elementos) são normalmente referida como perdas Joule.

As perdas técnicas variam de acordo com o nível de utilização da capacidade e qualidade da rede, ou seja, a quantidade de energia a ser transmitida e distribuída. Em particular, elas são proporcionais ao quadrado da corrente. As redes de distribuição em tensões mais baixas estão sujeitas a um nível mais elevado de perdas, pois a corrente é mais elevada nesses trechos. Além disso, as perdas técnicas também são dependentes do comprimento e da seção transversal da linha de rede (ERGEG, 2008).

Oliveira et al. (2014) apresentam uma metodologia para cálculo de perdas técnicas nos sistemas de distribuição, que consiste na separação dos sistemas em segmentos, cada qual com um procedimento específico para determinação de perdas. Por exemplo, para perdas em medidores de energia, foi adotado um valor fixo, de acordo com o tipo de medidor; para o cálculo de perdas na rede de baixa tensão, foi utilizado o cálculo do fluxo de potência para diferentes patamares de carga da curva diária de demanda e a determinação das perdas nos trechos de rede, de acordo com a resistência dos condutores. A partir do balanço de energia, sugere-se a possibilidade de se determinar perdas não técnicas. O Quadro 2.6 apresenta valores típicos de perdas técnicas por segmentos em redes elétricas brasileiras, de acordo com os autores.

Quadro 2.6 – Perdas técnicas típicas em redes elétricas no Brasil

Segmento	Perda técnica típica
Subtransmissão	2,0 – 3,0 %
Subestação de Distribuição	0,5 – 2,0 %
Rede primária	0,5 – 2,5 %
Transformadores de Distribuição	1,0 – 2,0 %
Rede secundária	0,5 – 2,0 %
Conexões dos consumidores	0,05 – 0,15 %
Medidores de energia	0,2 – 0,4 %
Outros	0,2 – 0,8 %

Fonte: Oliveira et al. (2014)

A metodologia proposta por Méffe (2002) considera a utilização de dados de medições na rede para reajustar uniformemente as curvas de cargas típicas dos alimentadores, de forma a calcular perdas técnicas com maior precisão.

Celik (1999) destaca a importância de se considerar as características reais dos alimentadores, como potências ativa e reativa, tensão e corrente. Com isto, o resultado do cálculo do fluxo de potência se torna mais confiável.

Esse sistema também permite a obtenção de curvas de perdas ao longo de um determinado período e para um determinado componente, aumentando a precisão da obtenção de índices de perdas técnicas.

Para que seja possível estimar as perdas técnicas de maneira satisfatória, é importante que a base de dados seja detalhada e confiável, o que nem sempre é possível. Com isso, se faz necessário buscar métodos que necessitem de uma quantidade menor de dados. Segundo Dortolina (2005), existem basicamente três tipos de métodos de análise:

- *Bottom-Up*: utilizado em situações que se conhece o sistema de maneira completa, possuindo informações detalhadas da rede. Neste método existe uma maior precisão nos cálculos, através de simulação do fluxo de potência.

- *Top-Down*: utilizado quando não se possui muitos dados, realizando a estimativa das perdas através de comparação com outros sistemas. Tende a produzir estimativas mais rápidas, porém com um grau mais elevado de incertezas.

- Sistema Híbrido: como sugere o nome, é uma mescla dos dois métodos anteriores. Parte do pressuposto que existam dados suficientes para algumas regiões do sistema, enquanto que para outros não. A principal vantagem desta abordagem é que ela leva menos tempo do que a abordagem *bottom-up* e é mais precisa do que a abordagem *top-down*. Tem como desvantagem requerer informações mais detalhadas do que os métodos *top-down*, porém produzindo um resultado menos preciso que os métodos *bottom-up*.(DORTOLINA, 2005).

A estimação das perdas não técnicas a partir da diferença entre perdas globais e técnicas é uma maneira clássica de se obter um indicativo da ocorrência do problema na rede. Ela não evita, contudo, o alto custo com equipes para percorrer os trechos de rede, fiscalizando e identificando os locais irregulares. Além disso, há que se considerar a dificuldade do cálculo preciso das perdas técnicas na rede, incluindo, por exemplo, perdas em reguladores de tensão, isoladores, conexões da rede, bancos de capacitores, etc. Algumas técnicas são empregadas para melhorar os resultados dessa análise primária, destacando-se métodos baseados em Estimação de Estados, em perfis típicos de consumo, e no investimento em equipamentos de monitoramento, conforme apresentado a seguir.

2.9.2 Estimação de perdas a partir de Estimadores de Estado das Redes de Distribuição

Nos trabalhos de detecção de perdas em sistemas de potência, a estimação de estados é utilizada como parte de um processo que visa obter um modelo da rede mais aproximado da realidade. Na forma mais básica, calcula-se o fluxo de potência na rede e ajusta-se linearmente as demandas com base em valores medidos.

Méffe (2002) propõe uma metodologia que inclui as perdas técnicas como parte do fator de correção da demanda em um estimador de estados.

Cruz, Quintero e Pérez (2006) apresentam uma metodologia baseada na estimação de estados para detecção das perdas não técnicas. A estimação é feita em tempo real, para cada ponto com transformador considerado relevante na rede primária. A análise parte de um macro balanço de energia, para detecção de regiões afetadas por perdas não técnicas. A potência estimada fornecida em cada transformador é calculada a partir de um modelo matemático, que inclui consumo faturado, perdas técnicas, e um fator de comportamento, de acordo com o tipo de consumidor, entre outras variáveis. A metodologia empregada pelos autores é baseada na modelagem de carga para estimação de estados apresentada por Ghosh, Lubkeman e Jones (1997).

Donadel et al. (2009) utilizam a estimação de perdas não técnicas para o refinamento do cálculo de perdas técnicas. As perdas não técnicas são calculadas utilizando três procedimentos: inspeções por amostragem, seleção de grupos de consumidores para ajustes de consumo e aplicação de um fator de correção para ajuste de consumo. Os três procedimentos combinados, produzem uma curva de demanda ajustada para os grupos de consumidores, e então é aplicado o método apresentado por Oliveira et al. (2001), descrito na seção anterior.

Métodos estatísticos são aplicados para refinar os resultados dos estimadores, entre os quais se destaca o método dos Mínimos Quadrados Ponderados, cuja solução é buscada de forma recursiva e através do algoritmo iterativo de Gauss-Newton. A base teórica desse método aplicada a Sistemas de Potência é apresentada nos trabalhos de Schweppe (1970 a,b,c). Ferreira Neto (2011) emprega essa metodologia e introduz pseudomedidas a partir de dados de faturamento dos consumidores, para estimar o estado da rede em um sistema de

detecção de perdas não técnicas. O autor divide o estimador de estados em três submodelos, sendo um para cada fase da rede trifásica.

Outras técnicas estatísticas, apresentadas por Zarco P. e Expósito A.G., (2001), incluem o estimador de estado de Mínimo Erro Absoluto Ponderado e da Mínima Mediana Ponderada de Quadrado dos Resíduos. Esses métodos são propostos para sistemas em que ocorrem erros grosseiros de medições.

Métodos heurísticos e de inteligência artificial também são empregados para estimação de estados, destacando-se os sistemas Fuzzy e as Redes Neurais. Os sistemas Fuzzy caracterizam-se pela capacidade de representação numérica da informação descrita em uma linguagem naturalmente imprecisa ou incerta (SARIC e CIRIC, 2003). As Redes Neurais estão detalhadas no Apêndice A desta Tese.

O Quadro 2.7 apresenta uma síntese de trabalhos que empregam a Estimação de Estados no Sistema de Distribuição, e os respectivos métodos/técnicas utilizados pelos autores.

Quadro 2.7 – Relação de trabalhos que empregam Estimação de Estados no Sistema de Distribuição.

Método / Técnica	Referência
Estatístico – Básico	Deng, He e Zangh (2002); Méffe (2002)
Estatístico – Mínimos Quadrados Ponderados	Monticelli (2000); Ferreira Neto (2011); Lo, Huang e Lu (2012, 2013)
Estatístico – Mínimo Erro Absoluto Ponderado	Kotyuga e Vidyasagar (1982); Falcão e Assis (1988); Ramírez e Barocio (2000)
Estatístico – Mínima Mediana Ponderada de Quadrado dos Resíduos	Nanni (2009)
Redes Neurais	Abbasy e Hassawy (1996); Antonio (2001); Shafiu (2005); Rakpenthai (2005)
Fuzzy	Zimmerman (1984); Saric e Siric (2003);
Híbridos e Outros	Kennedy e Eberhart (1995); Naka (2001); Naka, Genji e Fukuyama (2003);

Fonte: Elaborado pelo autor

2.9.3 Detecção de perdas não técnicas a partir dos perfis de consumidores

A partir de um determinado padrão de consumo de energia, é possível identificar situações discrepantes, que podem levar à identificação de fraudes ou erros de medições. Nessa metodologia, é bastante usual o emprego de técnicas estatísticas e de inteligência artificial, que são utilizadas como parte do processo de identificação de perdas, para diferentes finalidades; destacam-se, entre essas, a mineração de dados e a classificação.

A determinação de um perfil padrão de consumo deve levar em conta diversos aspectos, sendo as características da curva de demanda o principal deles. No entanto, os hábitos de consumo estão sujeitos a variações, dependendo do dia da semana, período do ano, clima, região, entre outros. Por isso, são necessárias técnicas de seleção dos dados que influenciam no consumo, seleção de clientes e classificação dos perfis das curvas de demanda. Em um conjunto grande de dados, por exemplo, a seleção de clientes pode ser interpretada como um filtro, que pode ter como objetivos excluir clientes repetidos, sem consumo ou que foram cadastrados após o início das análises.

Nizar, Zhao e Dong (2006) apresentam uma metodologia para detectar e estimar perdas não técnicas baseadas no desvio de comportamento dos consumidores e a partir das curvas de cargas típicas. Para determinação do perfil de carga e caracterização dos consumidores, os autores avaliam diferentes ferramentas de seleção e tratamento de dados.

As técnicas de seleção de recursos têm como objetivo eliminar variáveis ou atributos irrelevantes de maneira a melhorar o desempenho dos algoritmos de modelagem ou aprendizagem. Entre as técnicas, pode-se citar: busca completa, busca heurística, algoritmos genéticos, busca randômica e busca gradual (CELIK e LIU, (1999). A caracterização dos consumidores consiste em agrupar perfis típicos de carga de acordo com índices pré-determinados (*a priori*, como tipo de atividade econômica e demanda contratada) ou de campo (geralmente a partir das curvas de carga diárias). Para Nizar, Zhao e Dong (2006), uma curva de carga diária está sujeita a variações de acordo com diferentes condições. Os autores ainda

consideram outras características para caracterização dos consumidores, como fator de carga e período do dia (manhã, tarde e noite).

A partir da classificação, os autores (id. 2009) analisaram diferentes consumidores, e propuseram a identificação de perdas não técnicas a partir de anormalidades nas curvas de demanda, estabelecendo limites máximos e mínimos para as diferentes situações, conforme apresentado no Quadro 2.8.

Quadro 2.8 – Fatores que podem influenciar na curva de carga de um consumidor

Condição a ser considerada	Classe
Tipo de consumidor	Residencial Comercial Industrial
Local	Urbana Rural
Nível de tensão	Baixa Média/Alta
Clima	Temperatura Precipitação pluviométrica Umidade Pressão atmosférica Velocidade do vento Visibilidade
Tipo de dia	Dia útil Sábado Domingo / Feriado

Fonte: Nizar, Zhao e Dong (2006)

Nagi et al. (2008) utilizam uma técnica baseada em inteligência artificial, denominada Máquina Vetorial de Apoio (do inglês, *Support Vector Machine (SVM)*) onde os padrões de consumo são obtidos a partir de mineração de dados e métodos estatísticos. A técnica SVM é baseada na teoria de aprendizagem estatística, e tem aplicação em ferramentas de classificação. O algoritmo utilizado pelos autores classifica os consumidores em uma de quatro classes: suspeito de

fraude confirmado, suspeito de fraude não confirmado, suspeito de regular confirmado e suspeito de regular não confirmado. O sistema desenvolvido foi testado em redes reais de uma concessionária de energia da Malásia, e os resultados mostram que o programa alcançou uma taxa de acerto de 53%.

Méffe e Oliveira (2002) propõem a utilização de medições para correção de cálculos de perdas técnicas. Eles analisam a origem de discrepâncias entre valores reais e estimados pela metodologia proposta. Algumas situações podem impactar significativamente os resultados, destacando-se: a reconfiguração da rede, erros na classificação dos consumidores (comercial, residencial ou industrial), e diferenças entre períodos de leitura para faturamento. Os autores apresentam um fator de correção para essas situações.

Ramos et al. (2013) introduzem a técnica OPF – *Optimum-path forest*, para identificação de perdas não técnicas. Essa técnica é baseada em grafos e é utilizada para reconhecimento de padrões. Os autores comparam o desempenho do método proposto com outras técnicas (SVM e RNA) e demonstram precisão e rapidez de processamento dos resultados usando OPF.

Monedero et al (2006) apresentam um projeto, denominado MIDAS, no qual são empregadas Redes Neurais Artificiais e também métodos estatísticos para detecção de perdas não técnicas. As RNAs e os métodos estatísticos são empregados para mineração de dados. Foram utilizadas Redes Kohonen, que permitem o agrupamento de dados em mapas auto organizáveis, como mostra a Figura 2.10. As variáveis de entrada utilizadas no projeto foram:

- valores máximos e mínimos da conta de energia do consumidor, no ano anterior;
- consumo médio de energia, a partir das tarifas, no ano anterior;
- diferença entre as médias de consumo de energia, entre os consumidores analisados;
- diferença entre o consumo de um mês, para um consumidor, e o consumo médio e máximo do mês dos consumidores analisados; e
- relação entre consumo e demanda contratada.

Os métodos estatísticos usados no projeto têm como objetivo identificar discrepâncias e fornecer uma lista de consumidores atípicos, usando como referência um consumidor geral padrão.

Os dois métodos empregados pelos autores (id. 2006) foram testados em uma rede real, e alcançaram uma taxa de acerto de 50%.

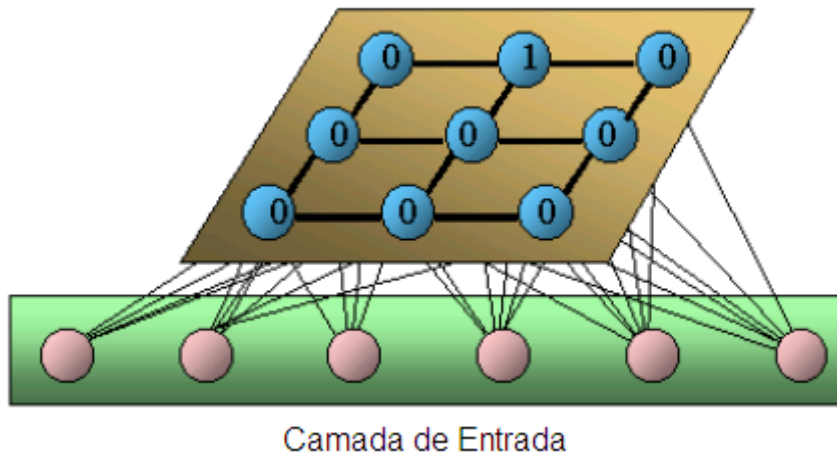


Figura 2.10 – Rede Neural Artificial – Estrutura de Kohonen

Fonte: Monedero et al (2006)

Pereira et al (2013) utilizam Redes Neurais *Multilayer Perceptron*, Figura 2.11, detalhada no Apêndice A, para classificação, combinadas com uma técnica denominada Busca por Sistema de Cargas (CSS – *Charged System Search*), que é baseada no conceito de interação entre partículas eletricamente carregadas.

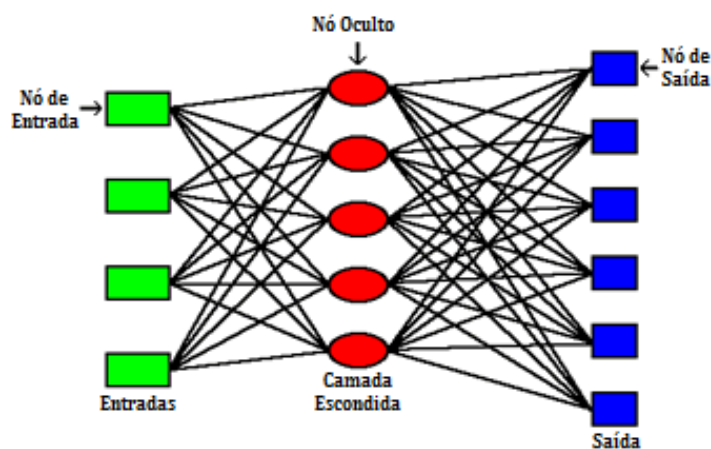


Figura 2.11 – Rede Neural Artificial – Estrutura Multilayer Perceptron

Fonte: Pereira et al (2013)

Guerrero et al (2010) empregam RNA e métodos estatísticos para identificar perfis de consumos considerados anormais, em um grupo de mais de 50.000 consumidores com demanda contratada superior a 15 kW, em Andaluzia (Espanha). O processo de aprendizagem é alimentado com informações utilizando processamento de linguagem natural (NPL – *Natural Language Processing*), que inclui dados geográficos, datas e comentários de inspetores e de equipes de medição.

Alguns trabalhos relacionam o consumo de energia elétrica com as condições climáticas, embora não seja dada ênfase ao aspecto das perdas de energia. Altran (2005) demonstra em seu trabalho a influência de fatores climáticos como temperatura, nebulosidade, velocidade do vento, entre outros, para a modelagem da previsão de carga. O autor menciona que a influência de tais fatores é fundamental na representação do comportamento da carga, utilizando esses dados como entrada dos algoritmos de previsão, que empregam RNAs.

Fatores climáticos, como temperatura, umidade relativa do ar, velocidade do vento e nível de luminosidade possuem influência nas previsões de curto prazo, sendo a temperatura o principal fator. A distribuidora de energia elétrica deve conhecer cada região da sua concessão para então avaliar as influências da temperatura sobre a demanda solicitada ao seu sistema.

O sucesso da aplicação dos métodos baseados nos perfis de consumo depende da correta modelagem das curvas de demanda, considerando a diversidade de influências a que essas curvas estão sujeitas. No nível da curva de demanda de um alimentador, um consumidor irregular pode passar despercebido; mas no nível individual, considerando, por exemplo, os históricos das faturas de energia elétrica, os métodos baseados no perfil de consumo podem indicar pontualmente consumidores fora dos padrões esperados, o que pode ser um indicativo de ocorrência de perdas não técnicas.

2.9.4 Monitoramento de perdas com medidores eletrônicos

Com o avanço das Redes Elétricas Inteligentes, a utilização de medidores eletrônicos inteligentes e estruturas avançadas de medição (AMI – *Advanced Metering Infrastructure*) tende a ser mais comum. Esses equipamentos e

tecnologias podem ser utilizados para a detecção de perdas técnicas e não técnicas nas redes de distribuição.

No trabalho de Alves et al. (2006), a solução proposta para a redução das perdas não técnicas é baseada na modernização dos sistemas de medição e gerenciamento das faturas de energia elétrica. Os autores destacam que, em muitos casos, as perdas não técnicas são devidas a equipamentos obsoletos e à ineficiência dos serviços relacionados ao faturamento.

Paruchuri e Dubey (2012) propõem a utilização de medição inteligente (do inglês, *smart metering*) no nível residencial e em equipamentos da rede, como relés e transformadores. Com a medição, é possível um balanço contínuo de energia entre pontos da rede e consumidores. Um sinal de verificação com frequência específica é injetado na rede, entre os equipamentos com medição, e deve ser anulado por medidores regulares. No caso de furto de energia ou mau funcionamento de medidores, é possível identificar o ponto de ocorrência, pelo sinal de verificação.

A instalação de medidores de totalização (macro medidores ou medidores coletivos) é mencionada por Agüero (2012), como uma alternativa para a identificação e redução de perdas não técnicas. Com os medidores, é possível fazer a comparação entre energia fornecida e faturada (balanço de energia) em trechos menores dos alimentadores, diminuindo, dessa forma, a região de busca por fraudes. Esse recurso é utilizado no trabalho apresentado por Gonzalez-Urdaneta (2010), que mostra ações feitas por uma concessionária de energia da Venezuela para identificação e redução de perdas não técnicas.

Lo, Huang e Lu (2012, 2013) combinam a técnica de Estimadores de Estados com Mínimos Quadrados Ponderados, apresentada na Seção 2.11, com a utilização de AMIs para ajuste do estimador da rede.

No trabalho de Faria et al. (2013), a identificação de perdas não técnicas é feita através de dispositivos de Resposta da Demanda (DR – *Demand Response*), um recurso que permite o monitoramento local de cargas dos consumidores, e que também está incluído nos conceitos das Redes Elétricas Inteligentes.

A implantação de medidores eletrônicos e estruturas de medição avançadas implica na necessidade de investimentos para a modernização dos sistemas de medição e faturamento das concessionárias de energia. O planejamento desses investimentos deve ser cuidadosamente elaborado, para obter a melhor relação

custo-benefício. Ribeiro et al. (2012) apresentam uma metodologia para otimização dos investimentos em medidores totalizadores e AMIs em uma região atendida pela Light (Rio de Janeiro). Eles consideram restrições como número mínimo de consumidores por transformador e número máximo de inspeções locais permitidas pelo orçamento disponível.

2.10 Considerações finais do capítulo

Nessa Tese é proposto um método para identificação de perdas não técnicas em consumidores rurais com sistemas de irrigação. No sistema proposto, utiliza-se um Sistema Neural Artificial (SNA) formado por um conjunto de RNAs baseados na caracterização do perfil de consumo de energia de cada consumidor, tendo em vista que um dos objetivos do trabalho é a identificação pontual de perdas não técnicas.

Na revisão bibliográfica apresentada nesse capítulo foram relacionados métodos de identificação de perdas não técnicas nos sistemas de distribuição de energia elétrica. De modo geral, os métodos podem ser divididos em quatro categorias, com as seguintes características:

1) Inspeção Local: maior custo com recursos humanos e dificuldade de execução.

2) Baseados em Estimção de Estados: fortemente dependentes da correta modelagem da rede; as perdas não técnicas são estimadas indiretamente, a partir das perdas técnicas; não há indicação pontual de consumidores irregulares, mas sim de regiões com ocorrência de problemas.

3) Baseados no Perfil de Consumo: sujeitos a fatores que afetam o comportamento da curva de demanda, como local, clima e sazonalidade; permitem a identificação pontual de consumidores atípicos.

4) Baseados na Instalação de Medidores: prática que tende a se tornar mais comum, com o avanço da tecnologia e das redes inteligentes; necessidade de investimentos e modernização de equipamentos.

Ressalta-se que é possível uma solução híbrida, que utilize elementos de dois ou mais métodos simultaneamente.

Com o objetivo de identificar os principais fatores que influenciam no consumo de energia elétrica em sistemas de bombeamento de água para irrigação de

lavouras de arroz, também foi apresentada uma revisão bibliográfica e teórica sobre o tema. As principais características dos sistemas de irrigação e relações entre dados da lavoura, dados climatológicos e consumo de energia estão resumidas no Quadro síntese 2.9.

Quadro 2.9 – Síntese de aspectos relevantes de parâmetros aplicados na Tese.

Aspectos Considerados	Parâmetro	Observações
Clima: Dados diretamente relacionados à necessidade de irrigação.	Precipitação pluviométrica	Possibilidade de redução do consumo de energia na fase de levante e desligamento das bombas na fase de manutenção da irrigação.
	Insolação e Evaporação	Relacionados diretamente entre si, sendo que o aumento da insolação leva ao aumento de evaporação e necessidade de água para irrigação.
	Umidade relativa	Quanto maior a umidade relativa menor a necessidade de irrigação e menor o consumo de água.
	Temperatura	Quanto maior a temperatura, maior a necessidade de irrigação e consumo de água.
Características Energia Elétrica: Dados que mostram possíveis inconsistências de consumo.	Carga Instalada - kVA	A análise permite busca de inconsistências na relação de carga instalada com área irrigada.
	Consumo de Energia Faturada	Permite análise de incoerências no histórico de consumo da unidade. Por exemplo: diminuição do perfil do consumo com a mesma carga instalada e área de plantio.
Característica Lavoura; Dados relacionados ao consumo diretamente na altura do levante e indiretamente através d consumo de água nas demais classes.	Altura de Levante	Quanto maior a altura, maior a potência elétrica e o consumo de energia para bombeamento.
	Automação	Quanto maior o nível de automação, maior a possibilidade de aplicar técnicas de eficiência energética na irrigação, e menor o consumo de água e energia elétrica.
	Área irrigada	Relação direta com consumo de energia elétrica.
	Tipo de Solo	Considera-se o nível de drenagem. Quanto maior a drenagem, maior o consumo de energia elétrica
	Declividade Média	Quanto maior a declividade, maior o consumo de energia elétrica.
	Sistematização do Solo	Quanto maior o desnível maior o consumo de energia elétrica
	Metodologia de Plantio.	Dividida em três níveis de consumo, do maior para o menor Irrigação contínua, Inundação Estática e Solo Saturado

Fonte: Elaborado pelo autor

Na revisão bibliográfica, constata-se que a utilização de Redes Neurais Artificiais e métodos estatísticos têm grande aplicação como parte de processos das metodologias de detecção de perdas baseadas em estimadores de estado e em perfis de consumo. Entre as finalidades das RNAs nesses sistemas, destacam-se a mineração de dados, a seleção de variáveis e a classificação. O próximo capítulo apresenta a metodologia de detecção de perdas não técnicas utilizando o Sistema Neural Artificial desenvolvido nessa Tese.

3. Metodologia Proposta

Nesse Capítulo é apresentada a metodologia proposta para identificar a possibilidade de ocorrência de perdas não técnicas no suprimento de energia de consumidores rurais, caracterizados pelo uso de levantes para irrigação de lavouras de arroz. O Capítulo está dividido em duas seções principais, sendo que na primeira seção são apresentadas considerações gerais sobre a proposta, e na segunda seção é apresentada uma metodologia baseada em um Sistema Neural Artificial utilizando Redes Neurais Artificiais.

3.1 Fluxograma geral proposto para identificação de perdas não técnicas

A metodologia geral proposta para identificação de perdas não técnicas em consumidores rurais segue o fluxograma geral apresentado na Figura 3.1. A proposta consiste em determinar o consumo esperado de energia elétrica em uma lavoura, obtida a partir do Sistema Neural Artificial (SNA) e compará-lo com o consumo real.

É necessário que o SNA represente satisfatoriamente o consumo da lavoura, de modo que a metodologia possa ser empregada com assertividade em qualquer região do Brasil e em lavouras distintas, independentemente do clima, tipo de solo, níveis de automação, entre outras características.

O SNA é formado por um conjunto de RNAs que atuarão para apresentar uma estimativa satisfatória de energia consumida. Estes valores de consumo serão comparados com os valores reais medidos nas unidades consumidoras. A partir desta comparação, define-se um índice que representa a possibilidade de perdas não técnicas que apresentam os padrões observados em diferentes lavouras e safras analisadas.

As principais etapas do fluxograma, e a descrição do conjunto de dados utilizados para testes nessa Tese são detalhadas na sequência.

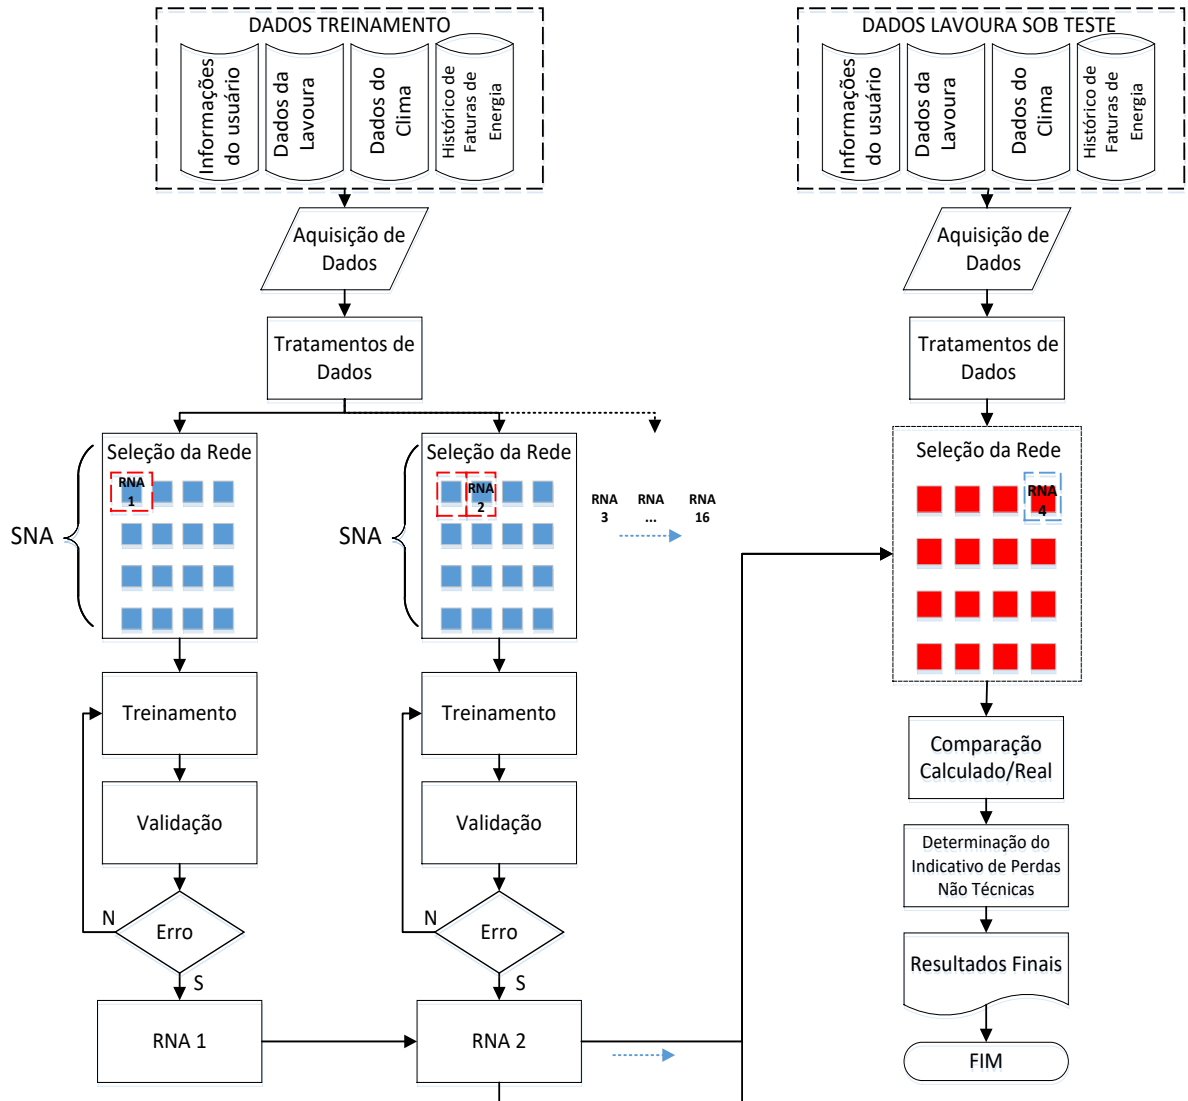


Figura 3.1 - Fluxograma geral da metodologia proposta

Fonte: Elaborado pelo autor

3.2 Aquisição e tratamento de dados

A primeira etapa da metodologia consiste em adquirir um conjunto de dados de lavouras de características, regiões e safras diferentes. Estas servirão para modelagem do sistema. Esse conjunto é provido por bases distintas de dados, como históricos e medições de consumo de energia, disponíveis nas concessionárias de energia, dados climatológicos, obtidos a partir de estações meteorológicas e características das lavouras, fornecidas como entrada de dados pelo usuário do sistema, conforme detalhado a seguir.

As entradas estão divididas em dados relacionados a: Energia Elétrica, Lavoura e Clima. Estas entradas estão ilustradas na figura 3.2

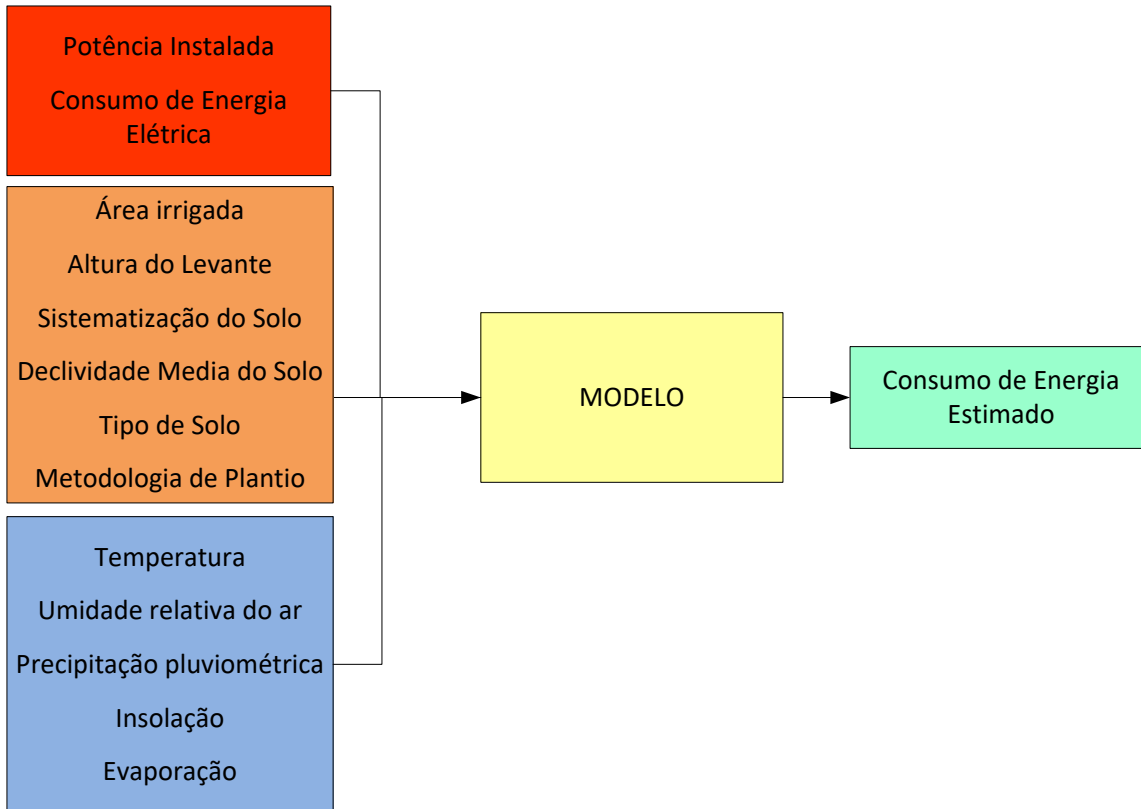


Figura 3.2 - Dados de Entrada e Saída do Sistema Proposto.

Fonte: Elaborado pelo autor

O Sistema Neural Artificial desenvolvido possui um conjunto de RNAs que atuam individualmente, sendo sua seleção relacionada ao conjunto de informações disponível sobre a lavoura (entrada de dados). Essas informações estão divididas em dois grupos: dados obrigatórios e dados complementares.

As seguintes informações básicas são obrigatórias na etapa de aquisição de dados:

- Período (tempo) do histórico de dados;
- Localização da lavoura (coordenadas geográficas).

A partir dessas informações, alguns dados da Figura 3.2 podem ser automaticamente obtidos com o uso de ferramentas computacionais que buscam dados disponíveis em páginas de agências oficiais na internet, ou no próprio banco de dados da concessionária de energia. Entre os dados obrigatórios destacam-se os dados climatológicos obtidos a partir da estação meteorológica mais próxima da

localidade da lavoura, e os dados de consumo de energia, obtidos a partir das faturas de energia do consumidor.

Normalmente, a base de tempo dos registros dessas fontes não é a mesma, sendo necessária uma seleção e tratamento de dados. Essa seleção também serve para excluir registros inconsistentes, por exemplo, que caracterizam outras medições no mesmo medidor (como silos de secagem, galpões, residência e etc.) ou erros grosseiros nas medições.

Os dados complementares compreendem informações que dependem de inspeção local ou da resposta do proprietário da lavoura a um questionário, conforme proposto no Apêndice B. Entre os dados complementares estão informações sobre altura do levante e o método de irrigação.

Todos os dados numéricos utilizados no sistema são normalizados em relação aos respectivos valores máximos de cada variável, conforme Equação 3.1.

$$x_i^* = \frac{x_i}{x_{max}} \quad (3.1)$$

Sendo:

x_i^* = valor normalizado de x_i ;

x_{max} = valor máximo da variável x , no conjunto total de dados.

Além disso, para a entrada das redes neurais foi realizada a média diária dos dados climáticos e de consumo de energia elétrica.

3.3 Modelagem, análise e validação

Conforme apresentado na seção anterior, o SNA desenvolvido baseia-se no conjunto de informações disponíveis para a seleção da RNA que melhor represente o consumo de energia da lavoura em questão. Estas informações balizam o treino e aplicação de cada RNA do sistema. Na Figura 3.3, observa-se uma representação do modelo amplo do sistema, com suas respectivas entradas divididas em Informações Obrigatórias e Informações Complementares, a serem respondidas pelo usuário do sistema.

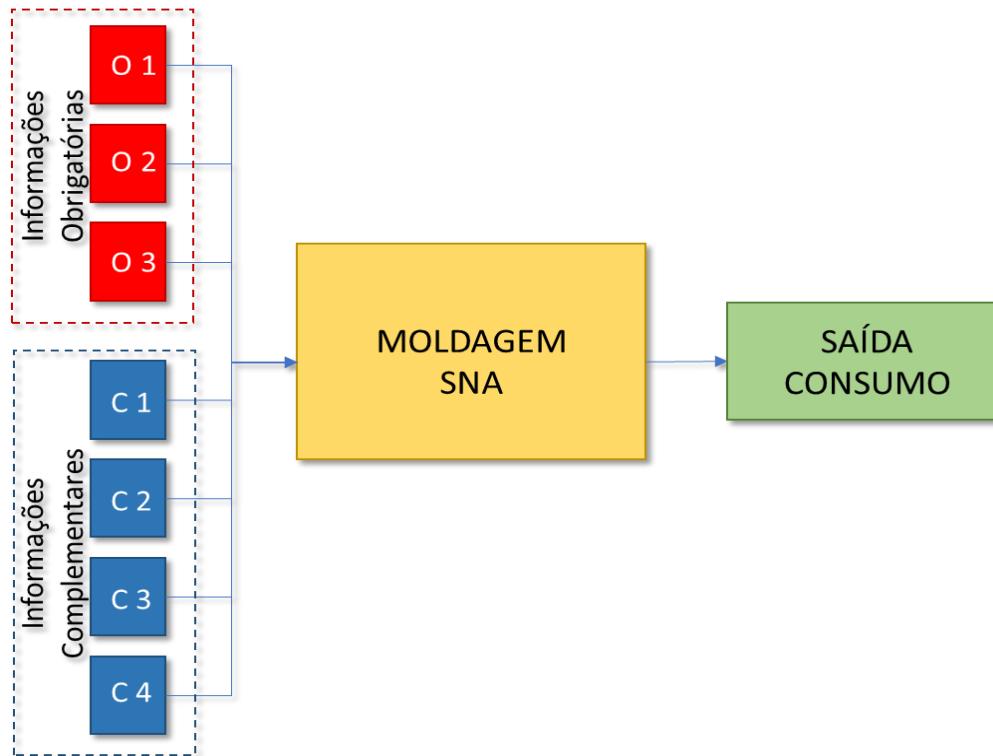


Figura 3.3 – Entradas do modelo relacionadas as Informações da UC.

Fonte: Elaborado pelo autor

O número de RNAs do sistema depende do conjunto de informações (dados) complementares, em uma relação de 2^n , onde n é o número de informações complementares.

Os dados obrigatórios são usados como entradas em todas as RNAs do sistema. Já os dados complementares determinam a RNA a ser selecionada, com base no conjunto de questionamentos respondidos.

O Quadro 3.1. ilustra um sistema com quatro informações complementares, que posteriormente será demonstrado na seção de resultados desse trabalho. O número de RNAs, nesse caso, é dezesseis.

Quadro 3.1 – Escolha da Rede Neural relacionada as Informações da Lavoura.

RNA	Informações Disponíveis (Obrigatórios e Complementares)				
	Obrigatórias: 1,2,3	Compl. 1	Compl. 2	Compl. 3	Compl. 4
RNA 1	X	-	-	-	-
RNA 2	X	-	-	-	X
RNA 3	X	-	-	X	-
RNA 4	X	-	-	X	X
RNA 5	X	-	X	-	-
RNA 6	X	-	X	-	X
RNA 7	X	-	X	X	-
RNA 8	X	-	X	X	X
RNA 9	X	X	-	-	-
RNA 10	X	X	-	-	X
RNA 11	X	X	-	X	-
RNA 12	X	X	-	X	X
RNA 13	X	X	X	-	-
RNA 14	X	X	X	-	X
RNA 15	X	X	X	X	-
RNA 16	X	X	X	X	X

Fonte: Elaborado pelo autor

Com as informações disponíveis definidas, a rede é selecionada automaticamente pelo SNA para realizar a projeção de consumo, com refinamento necessário para a obtenção de resultados adequados às diversas características da lavoura em questão. A Figura 3.4 ilustra o processo de seleção da RNA.

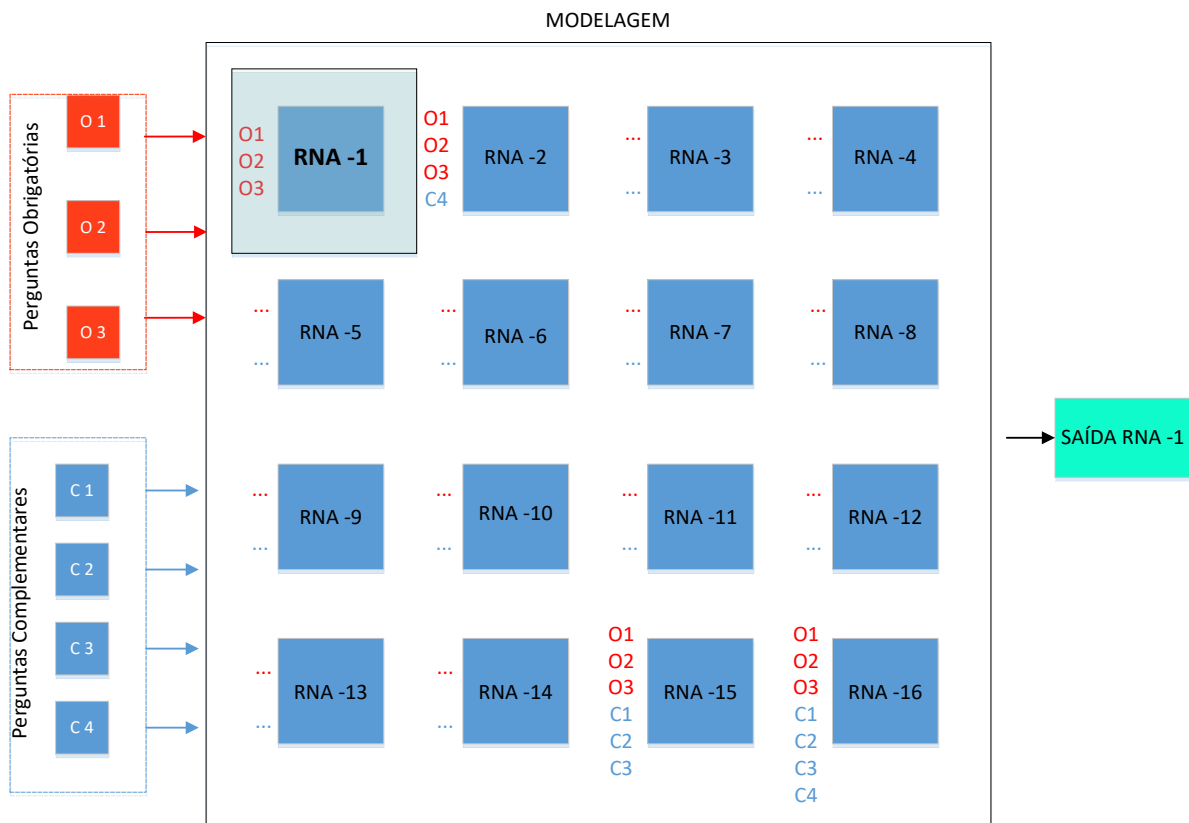


Figura 3.4 – Visão da modelagem formando o Sistema Neural Artificial - SNA.

Fonte: Elaborado pelo autor

No sistema desenvolvido, as RNAs são treinadas individualmente, conforme o conjunto de dados considerado disponível para cada uma delas. Assim, por exemplo, a RNA 1 é treinada apenas com os dados obrigatórios, a RNA 2 é treinada com os dados obrigatórios e as respostas da pergunta complementar 1 (C1 – Compl.1), e sucessivamente, conforme o Quadro 3.1.

3.4 Descrição do conjunto de dados para teste e validação

Nas próximas seções é apresentado um detalhamento dos dados utilizados como entradas das RNAs nessa Tese. Eles foram divididos em três grupos: dados climatológicos, consumo de energia e características da lavoura. Em particular, são demonstradas as formas de obtenção dos dados, com uma proposta de estender a aplicabilidade da metodologia, para implementação real do sistema desenvolvido pelas partes interessadas, como exemplo, cooperativas e concessionárias de energia.

3.4.1 Dados climatológicos

Os dados climatológicos são obtidos a partir de uma estação meteorológica do Centro de Previsão de Tempo e Estudos Climáticos (CPTEC/ INPE). Estas estações meteorológicas automáticas são compostas por diversos sensores que exibem parâmetros meteorológicos como precipitação, pressão atmosférica, temperatura radiação solar, direção e velocidade do vento, umidade relativa, entre outros.

Os dados são armazenados desde o início de operação de cada estação, o que possibilita a obtenção de históricos relevantes para a comparação com outras variáveis deste trabalho.

Para o estudo desta Tese utilizou-se dados de uma estação meteorológica localizada aproximadamente a 40 km do local das lavouras. No entanto, o CPTEC/INPE, possui mais de 500 estações meteorológicas, que cobrem satisfatoriamente todo o território do nacional como observa-se na Figura 3.5.

A maioria dos dados é disponibilizada com intervalos de 15 minutos. No entanto, algumas medições, como a precipitação pluviométrica, são integralizadas durante um dia. Desta forma, considerando esta característica da coleta de dados climatológicos, optou-se por trabalhar com dados diários nessa Tese.



Figura 3.5 – Distribuição de Estações Meteorológicas no Brasil

Fonte: (CPTEC/INPE - 2016)

3.4.2 Características de energia elétrica relacionada as lavouras

A maior parte das lavouras possuem medidores eletrônicos exclusivos para irrigação, instalados em média tensão. Os dados adquiridos pelos medidores são normalmente registrados a cada 30 minutos, e posteriormente são extraídos através de *software* específico. A Figura 3.6 ilustra um exemplo de gráfico extraído do programa ELO50, com os dados de consumo em uma das lavouras utilizadas como base nessa Tese.




Figura 3.6 - Consumo de energia elétrica em um sistema de irrigação obtido com o programa Elo50.

Fonte: Elaborado pelo autor

A carga instalada é outro aspecto fundamental e pode revelar inconsistências quanto ao nível de consumo por hectare. Quando o consumo medido é muito inferior à capacidade de carga instalada há um forte indicativo de perdas não técnicas. As cargas instaladas das lavouras utilizadas no SNA desenvolvido nessa Tese são descritas a seguir.

3.4.3 Características das lavouras

Para demonstrar a metodologia apresentada nessa Tese foi utilizado um conjunto de cinco safras de três lavouras distintas, formando um total de quinze blocos de dados. As unidades consumidoras são identificadas pelas siglas UC-1, UC-2 e UC-3, apresentadas nas Figuras 3.7 a 3.9.



Figura 3.7 - Unidade consumidora UC-1.
Fonte: Adaptado de Google Earth® (2016)



Figura 3.8 - Unidade consumidora UC-2.
Fonte: Adaptado de Google Earth® (2016)



Figura 3.9 - Unidade consumidora UC-3.
Fonte: Adaptado de Google Earth® (2016)

As Figuras 3.7 a 3.9 apresentam imagens de satélite, obtidas através do Google Earth®, que mostram as três lavouras utilizadas nos treinamentos e validação das RNAs.

O período de irrigação nas culturas de arroz é geralmente compreendido entre os meses de setembro a março do ano. Para este estudo utilizou-se como parâmetro o início de registro dos medidores de energia e as safras de 2009/2010 até 2015/2016.

Com a informação obrigatória da localização da lavoura, torna-se possível determinar a característica do tipo de solo para estas ou quaisquer outras lavouras sob análise.

Através do SOMA Brasil pode-se avaliar diversas características locais da agricultura no país, como logística, hídricas, físicas e geográficas. Entre estas informações, estão o tipo de solo de todo o país, obtido através da busca por município ou coordenadas geográficas.

Na figura 3.10 ilustra-se o mapa do Brasil e sua divisão por tipo de solo e a busca pela cidade. Como exemplo, está ilustrado o local onde estão sendo analisadas as lavouras para testes iniciais da metodologia desta Tese, indicando o tipo de solo primário da região da lavoura.

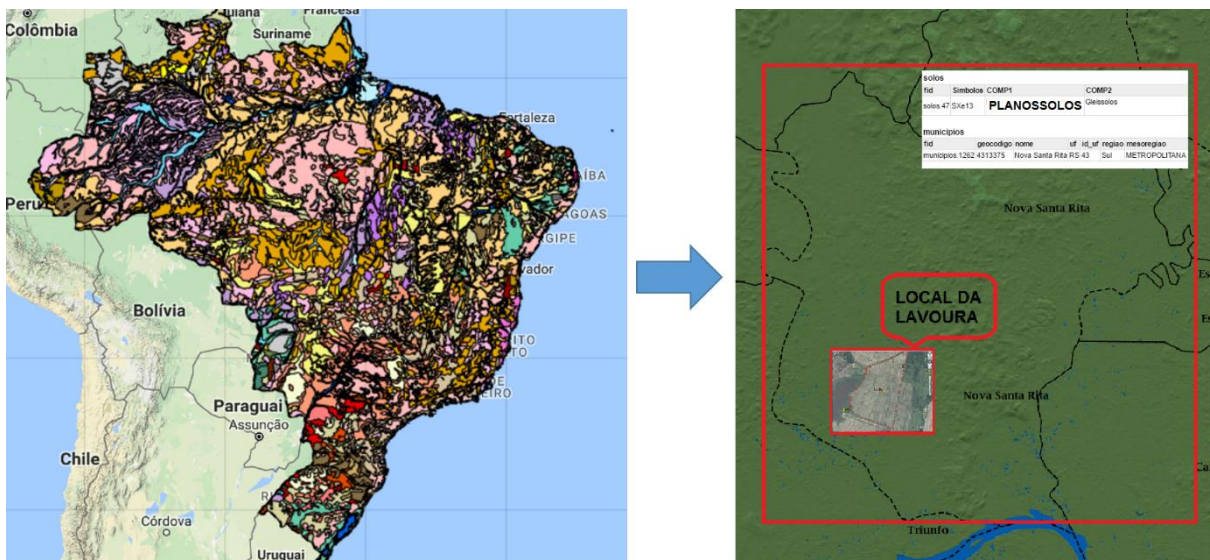


Figura 3.10 – Identificação tipo de solo no Brasil

Fonte: Adaptado de SOMA BRASIL - Embrapa (2016)

No caso específico do exemplo da Figura 3.10, o sistema aponta como solo primário o “Planossolos”. Esta informação é cruzada com o Quadro 2.1, onde observa-se que este tipo de solo é classificado como “Drenagem Ruim”.

Os demais dados de lavora, já citados anteriormente, são dependentes da resposta do usuário. Com isto diminui-se a dependência de cruzamento de dados e esforço computacional, mas admite-se o risco de apresentar inconsistência de dados na entrada da SNA, podendo eventualmente gerar respostas imprecisas.

No Quadro 3.2 apresenta-se um resumo das informações gerais das lavouras utilizadas no trabalho.

Quadro 3.2 – Dados gerais das lavouras

Unidade Consumidora	Área irrigada aproximada	Potência instalada	Característica do Solo
UC-1	90 ha	112,5 kVA	Drenagem Ruim
UC-2	300 ha	300 kVA	Drenagem Ruim
UC-3	50 ha	75 kVA	Drenagem Ruim

Fonte: Elaborado pelo autor

3.5 Implementação e Análise por Redes Neurais Artificiais

O Sistema Neural Artificial desenvolvido para estimar o consumo de energia elétrica nas lavouras utiliza 16 Redes Neurais Artificiais, cujas características individuais são apresentadas na figura 3.11. Esta figura representa a RNA-1 do Sistema Neural Artificial, que consiste na rede que possui apenas as entradas de dados obrigatórias. Na seção 4.4, nas análises de resultados, são apresentadas outras redes do SNA.

O programa do SNA foi desenvolvido em linguagem Python®, com a biblioteca de Redes Neurais denominada *PyBrain*. Esta biblioteca é fechada, só havendo interação com o usuário no momento do treinamento e no momento da validação, sob a forma de entrega dos padrões de entrada e saída esperados. Neste pacote não há a possibilidade de extração dos pesos dados para cada conexão

entre os neurônios da RNA por ele produzida. Isto pode ser feito a *posteriori* com o uso de redes *bayesianas*.

Para automatizar e sistematizar a seleção, treinamento e manipulação dos dados, foram criadas funções, também em Python, para extração dos dados dos arquivos em formato MS Excel®, normalização, automatização dos testes e verificação dos resultados por meio de testes de erro.

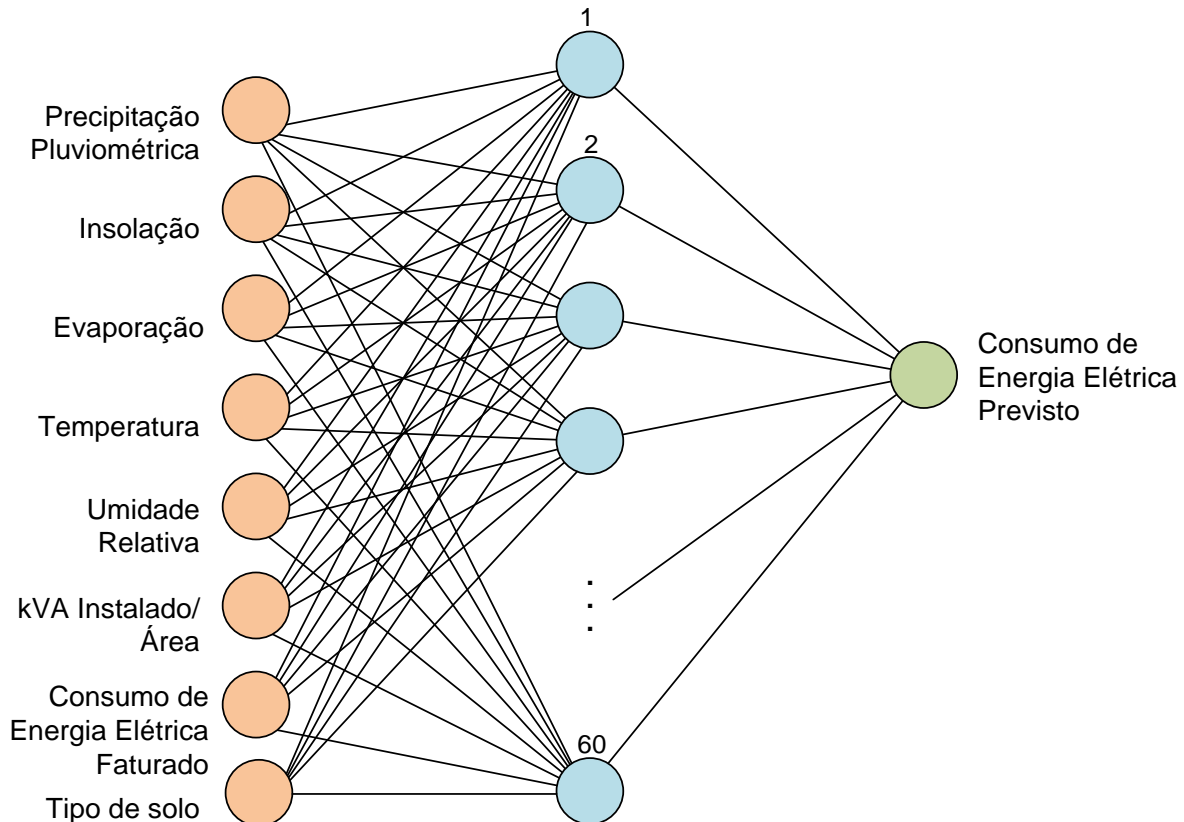


Figura 3.11 - Rede Neural Artificial proposta

Fonte: Elaborado pelo autor

A automatização do treinamento e da validação foi realizada para que os resultados pudessem ser avaliados e as RNAs reconfiguradas (em número de neurônios na camada escondida e número de épocas de treinamento) até se atingir valores pré-definidos. No caso desta Tese, o erro máximo aceitável foi definido como 10%, em termos absolutos. A avaliação do erro é realizada por um módulo também desenvolvido para este trabalho, detalhado na seção 3.8. O código do programa está apresentado no Apêndice C.

Os dados devem ser normalizados, para que todos tenham o mesmo peso matemático dentro do cálculo dos pesos da rede. Para aplicação em RNAs, as normalizações podem ser dadas de -1 a 1 ou de 0 a 1, dependendo da função de ativação a ser utilizada. No caso da função de ativação utilizada nesta Tese (função sigmóide - Equação A.2, Figura A.3 do Apêndice A) a normalização definida foi com intervalo de 0 a 1, permitindo que os processos matemáticos ocorram dentro da faixa de operação da função de ativação.

Realizam-se treinamentos, validações e análises da RNA proposta de duas maneiras, que são distintas pelo método de validação. Para um conjunto de 3 ou mais lavouras similares, pode-se aplicar a técnica de Validação Direta. Para conjunto de dados menores, é sugerido a validação *K-Fold*. Para as lavouras testes, foram empregados os dois métodos, detalhados nas duas seções que seguem.

3.6 Treinamento com Validação Cruzada K-Fold

Na Validação Cruzada *K-Fold*, a massa de dados é dividida em K partes e um processo iterativo é realizado K vezes, sendo que em cada vez, uma fração da massa de dados é removida para validação, e o restante é usado para treinamento da rede.

Nesse trabalho, utiliza-se $K = 10$, que é um valor usual em RNAs e que designa o método conhecido como *Ten-Fold Cross Validation*. A Figura 3.12 ilustra o procedimento em uma das etapas do ciclo de treinamento. Os blocos de dados representados na figura correspondem a toda a massa de dados disponíveis de cada conjunto de dados.

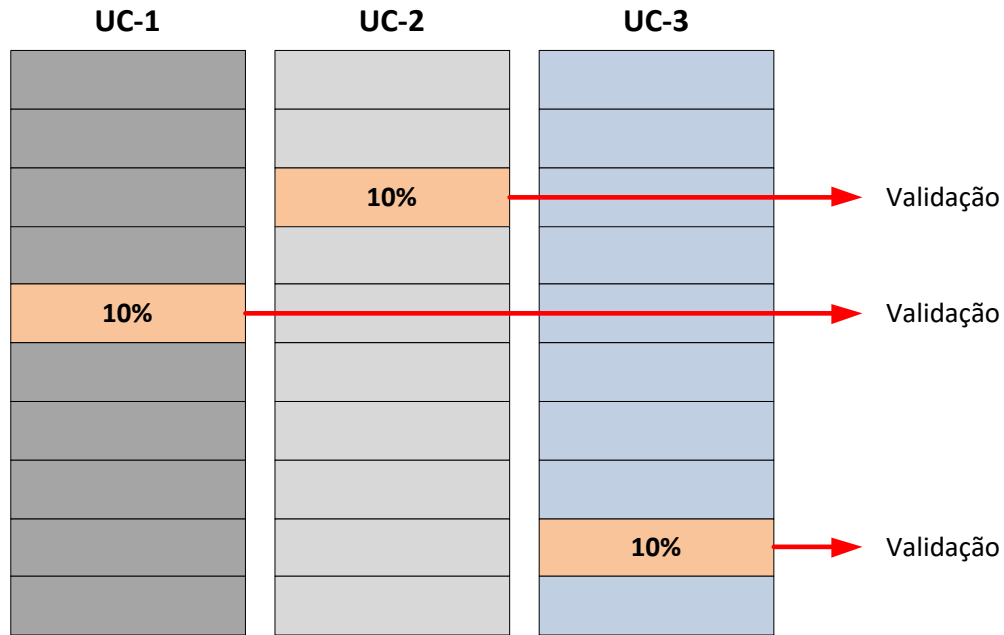


Figura 3.12 - Validação Cruzada com $K = 10$

Fonte: Elaborado pelo autor

Quando se utiliza o *Ten-Fold Cross Validation* é eliminada a influência temporal da série de dados, pois os dados estão apresentados de maneira aleatória para a RNA.

3.7 Treinamento com Validação Direta

No treinamento com Validação Direta, o conjunto total de dados disponíveis é simplesmente dividido em duas partes, sendo uma para treinamento e outra para validação, sem cruzamento de dados.

Nesse trabalho são treinadas redes com “n” lavouras para determinar o resultado da lavoura em que se deseja analisar.

No caso das lavouras testes, em cada rede foram utilizados os dados de duas lavouras para treinamento, e os dados da terceira lavoura para validação e resultados. Esse processo está ilustrado na Figura 3.13.

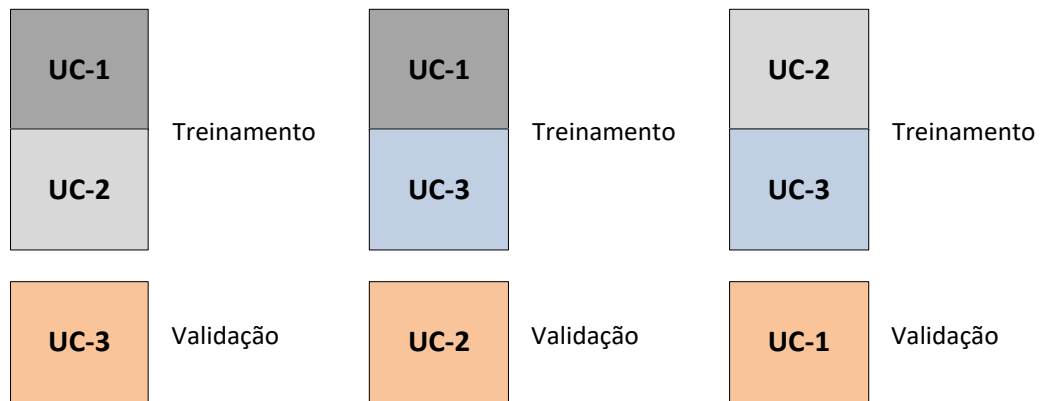


Figura 3.13 - Três redes treinadas com Validação Direta

Fonte: Elaborado pelo autor

A questão temporal é considerada pelo uso dos dados consecutivos apresentados à RNA, em seu treinamento e validação de maneira direta. Os dados são apresentados com uma sequencialidade temporal que permite à RNA reconhecer as tendências sazonais da série de dados.

3.8 Indicativo de perdas elétricas não técnicas

A possibilidade de ocorrência de perdas elétricas não técnicas nos consumidores analisados é determinada a partir da comparação entre os valores de consumo de energia, calculados pelo modelo desenvolvido, e os valores reais de consumo, obtidos a partir das medições disponíveis. O resultado é fornecido de forma qualitativa, considerando o erro médio percentual obtidos através das Equações 3.2 e 3.3 e comparando-os com o Quadro 3.3.

A Equação 3.2 mostra como a métrica é determinada.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| = \frac{1}{N} \sum_{i=1}^N e_i \quad (3.2)$$

Sendo:

N = número total de dados;

y_i = saída prevista pelo modelo;

\hat{y}_i = saída esperada;

e_i = erro absoluto.

Dentre as medidas mais utilizadas na análise de desempenho dos modelos estão o Erro Médio Absoluto (MAE – *Mean Absolute Error*) e a Raiz do Erro Médio Quadrático (RMSE – *Root Mean Square Error*), que foram empregados nessa Tese.

A análise a partir do erro médio absoluto é feita de forma linear, confrontando-se os valores estimados com os valores reais, um a um, e calculando-se a média dos resultados.

Já o erro médio quadrático consiste, basicamente, no desvio padrão da diferença entre os resultados calculados pelo modelo e os resultados previstos, ou seja, o desvio padrão do erro. Ele pode ser determinada a partir da Equação 3.3.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (3.3)$$

O termo sob a raiz quadrada é definido como o erro médio quadrático, que é uma medida da variância do erro.

O erro admitido nessa análise parte do pressuposto de que as lavouras têm características distintas e o consumo de energia elétrica tem variações importantes dependendo das características na cultura do arroz irrigado, práticas de irrigação diferenciadas, automação de equipamentos e da própria lavoura.

Dessa forma, como proposta inicial, optou-se por utilizar faixas de erros de 15% para as Redes Neurais que foram treinadas apenas com os dados obrigatórios para o funcionamento do sistema (questões obrigatórias do Apêndice B). A cada resposta complementar, aumentou-se a precisão em 2% nos níveis de risco Alto e Médio (considerando o possível refinamento da rede a cada resposta). Para riscos baixos vale a mesma regra até chegar a 10%, índice que a literatura sugere salvaguardar para inconsistências das RNAs. No quadro 3.3 são apresentados os índices de possibilidade de perdas não técnicas.

Quadro 3.3 – Índice de possibilidade de perdas não técnicas

Referência	Faixa de erro	Possibilidade de perdas não técnicas
Apenas dados obrigatórios (RNA1)	Erro \leq 15%	Baixa
	15 < Erro \leq 30%	Média
	Erro > 30%	Alta
Dados obrigatórios + 1 complementar	Erro \leq 13%	Baixa
	13 < Erro \leq 28%	Média
	Erro > 28%	Alta
Dados obrigatórios + 2 complementares	Erro \leq 11%	Baixa
	11 < Erro \leq 26%	Média
	Erro > 26%	Alta
Dados obrigatórios + 3 complementares	Erro \leq 10%	Baixa
	10 < Erro \leq 24%	Média
	Erro > 24%	Alta
Dados obrigatórios + 4 complementares	Erro \leq 10%	Baixa
	10 < Erro \leq 22%	Média
	Erro > 22%	Alta

Fonte: Elaborado pelo autor

Salienta-se que estes índices podem ser alterados dependendo da evolução do sistema, com um número maior de lavouras e conseqüentemente uma maior precisão de treinamento e de resultado das redes do SNA.

O resultado final fornecido pelo sistema proposto servirá de apoio às equipes de inspeção, que poderão dedicar mais atenção aos casos com alta possibilidade de perdas não técnicas, e planejar vistorias *in loco*.

4. RESULTADOS E DISCUSSÃO

Esse capítulo apresenta os resultados da aplicação da metodologia do Sistema Neural Artificial desenvolvido para detecção de perdas não técnicas em redes elétricas rurais, especificamente para consumidores com sistemas irrigantes de lavouras de arroz.

A revisão bibliográfica e a metodologia desenvolvida fazem referência ao uso de variáveis climatológicas para a estimação do consumo de energia esperado no sistema de irrigação. Diante disso, a primeira parte desse capítulo de resultados apresenta um estudo de correlação entre as variáveis de clima e consumo de energia nas lavouras analisadas, para embasar e justificar a utilização das variáveis de clima nas RNAs desenvolvidas.

Posteriormente, na segunda parte do capítulo, são apresentados e discutidos os resultados do SNA.

4.1 Correlação entre consumo de energia elétrica e clima

Para análise da correlação entre dados de consumo de energia elétrica nos sistemas de irrigação e o clima, inicialmente foi realizado um estudo de correlação entre as variáveis, aplicando a estatística do Coeficiente de Pearson. Este coeficiente de correlação tem valores entre -1 e $+1$, sendo negativo quando uma variável diminui com o aumento da outra variável, e positivo quando uma variável aumenta com o aumento da outra. O coeficiente de correlação de Pearson, r , é determinado pela Equação 4.1.

$$r = \frac{\sum(x - \bar{x}) \cdot (y - \bar{y})}{(n - 1) \cdot \sigma_x \cdot \sigma_y} \quad (4.1)$$

onde:

x, y : variáveis a serem correlacionadas;

\bar{x}, \bar{y} : média do conjunto de cada variável;

σ_x, σ_y : desvio padrão do conjunto de cada variável;

n : número de dados do conjunto analisado.

Na estatística clássica, a significância da correlação é testada através do valor- p para as hipóteses nula e alternativa:

H0: $r = 0$, não há correlação

H1: $r = 1$, há correlação.

A rejeição da hipótese nula pode ser determinada de acordo com o seguinte critério:

$0,5 < p \leq 1,0$: H0 é fracamente rejeitada;

$0,1 < p \leq 0,5$: H0 é moderadamente rejeitada;

$p \leq 0,1$: H0 é fortemente rejeitada.

Dessa forma, além do coeficiente de correlação, pode-se obter uma indicação do grau de correlação de uma variável com outra.

A técnica foi aplicada a um conjunto de dados da UC-1, e os resultados da Safra 2009/2010 são apresentados na Quadro 4.1. Para obtenção desses resultados foi utilizado o programa MiniTab®, que possui recursos específicos para análise estatística. O Quadro 4.2 apresenta os resultados de correlação das variáveis com o consumo de energia elétrica, das cinco safras disponíveis de UC-1. Os resultados completos fornecidos pelo programa são apresentados no Apêndice D.

Quadro 4.1 – Análise de correlação pelo Coeficiente de Pearson / UC-1 2009/2010

		Consumo Energia	Precipit. Pluviom.	Insolação	Evapor.	Temperatura	Umidade Relativa
Precipit. Pluviom.	r	0,063	-	*	*	*	*
	p	0,381					
Insolação	r	0,077	-0,386	-	*	*	*
	p	0,286	0,000				
Evaporação	r	-0,060	-0,357	0,276	-	*	*
	p	0,402	0,000	0,000			
Temperatura	r	0,026	-0,325	0,247	0,405	-	*
	p	0,720	0,000	0,000	0,000		
Umidade Relativa	r	-0,036	0,344	-0,780	-0,265	-0,179	-
	p	0,617	0,000	0,000	0,000	0,012	

r : Coeficiente de Pearson; p : Valor- p

* Os valores das células assinaladas com “*” repetem-se em relação ao mesmo par de variáveis indicado nas demais células.

Fonte: Elaborado pelo autor

Quadro 4.2 – Análise de correlação do consumo de energia com clima para UC-1

		2009-2010	2010-2011	2011-2012	2012-2013	2013-2014
Precipitação Pluviom.	r	0,063	-0,037	-0,147	-0,122	-0,155
	p	0,381	0,607	0,155	0,161	0,119
Insolação	r	0,077	0,092	0,072	0,136	0,247
	p	0,286	0,196	0,491	0,117	0,012
Evaporação	r	-0,060	0,142	0,101	0,123	0,355
	p	0,402	0,045	0,331	0,158	0,000
Temperatura	r	0,026	0,003	0,059	0,092	0,383
	p	0,720	0,970	0,573	0,288	0,000
Umidade Relativa	r	-0,036	-0,112	-0,155	-0,101	-0,371
	p	0,617	0,115	0,133	0,244	0,000

Fonte: Elaborado pelo autor

Nos Quadros 4.1 e 4.2 pode-se observar que existe uma correlação entre as variáveis climáticas, porém a correlação dessas com o consumo de energia elétrica é fraca. A hipótese H0 é moderadamente ou fracamente rejeitada na maior parte dos dados do Quadro 4.2, e os coeficientes de correlação são, em sua maioria, menores que 0,3.

Apesar dos valores obtidos nesse teste indicarem relações fracas entre as variáveis, especialmente em relação ao consumo de energia elétrica, que é a variável de interesse nesse trabalho, a análise estatística foi aprofundada, com a implementação do método de Regressão *Stepwise*.

4.2 Análise por Regressão Stepwise

O método de Regressão Stepwise foi aplicado em diferentes conjuntos de dados, considerando a disponibilidade de quinze safras para análise. O programa utilizado foi o Matlab®, que possui a função específica (*stepwise*), para essa aplicação.

Os resultados apresentaram grandes discrepâncias entre os valores de consumo de energia previstos pelo método e os valores de consumo reais, reforçando a conclusão, previamente indicada pela análise de correlação, de que não existe uma relação linear direta entre as variáveis de entrada e a saída.

Para exemplificar, é apresentado o resultado da análise de UC-1 / Safra 2013-2014.

A equação determinada para o conjunto de dados dessa safra é dada por:

$$Y = -3,6196 - 0,03843x_1 + 0,07323x_2 + 0,3215x_3 + 0,0009x_4 - 0,0048x_5 - 0,0067x_6 \quad (4.2)$$

sendo: Y – consumo de energia elétrica previsto; x_1 - precipitação pluviométrica, x_2 - evaporação, x_3 - umidade relativa do ar, $x_4 = x_1^2$, $x_5 = x_2^2$ e $x_6 = x_3^2$.

A Figura 4.1 ilustra as curvas de consumo da safra, evidenciando que os valores reais e previstos diferem significativamente, tanto em escala quanto em forma.




Figura 4.1 - Resultado da Regressão *Stepwise* para UC-3/ Safra 2013-2014.

Fonte: Elaborado pelo autor.

Os resultados das análises das demais safras foram igualmente inconsistentes e podem ser observados no Apêndice E.

4.3 Análise da Rede Neural Artificial Base do SNA (RNA 1)

Os resultados dos métodos estatísticos apresentados nas seções anteriores corroboram para a necessidade de se testar uma metodologia que apresente uma melhor aproximação entre os valores calculados e medidos, partindo do pressuposto que as variáveis climáticas de fato influenciam no consumo de energia elétrica, conforme discutido na revisão bibliográfica. Diante disso, foi desenvolvido o modelo para estimar o consumo de energia elétrica nas lavouras de arroz utilizando o Sistema Neural Artificial, constituído por um conjunto de Redes Neurais Artificiais. Nesse trabalho, o SNA é constituído de 16 RNAs, sendo que o que diferencia uma RNA de outra é o conjunto de dados de entrada disponível, conforme apresentado na Seção 3.5.

A rede básica do SNA desenvolvido é a RNA 1 (Quadro 3.1 e Figura 3.4). Esta rede tem a característica de conter em suas camadas de entrada apenas os neurônios associados aos dados obrigatórios.

Com o objetivo de demonstrar e validar a metodologia, utilizou-se o conjunto de 3 lavouras (UC-1, UC-2 e UC-3), com as características apresentadas na seção 3.4.3, e considerando os conjuntos de dados obrigatórios e complementares disponíveis. Todas as redes neurais do Sistema Neural Artificial foram treinadas com os dados obrigatórios de base, com informações gerais de área, clima e características de consumo das lavouras, das quais se obteve junto à concessionária responsável a memória de dados de consumo de quatro anos (2009 a 2014).

O SNA foi desenvolvido em linguagem Python®, conforme descrito na Seção 3.5, sendo que o código base está disponível no Apêndice C.

Em uma análise inicial, utilizando a metodologia de validação apresentada na Seção 3.7, foi verificado o número de neurônios na camada oculta que apresentasse o menor erro de treinamento (RMSE) para cada rede do SNA, com 1000 épocas. O resultado da RNA 1 está ilustrado na Figura 4.2. O erro de treinamento com 60 neurônios foi o mais baixo entre as alternativas testadas, sendo inferior a 1,5%.

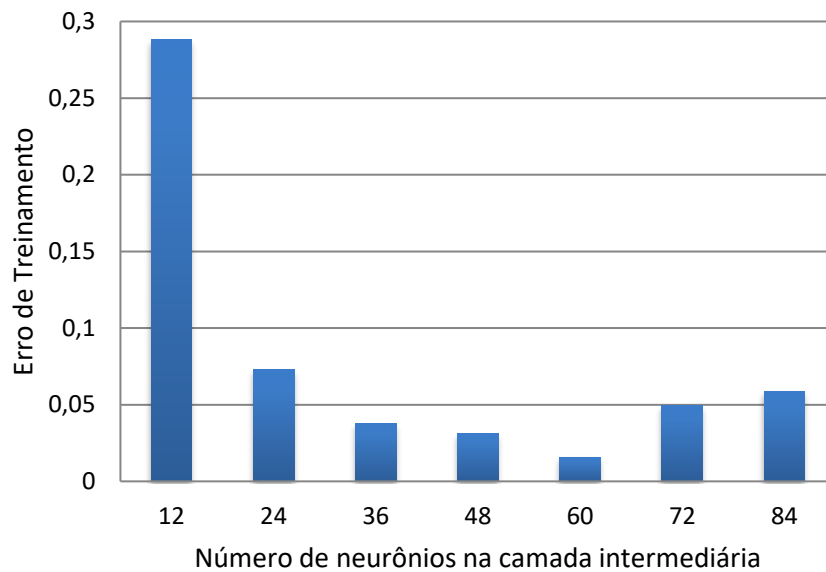


Figura 4.2 – Relação entre número de neurônios na camada intermediária e o erro de treinamento da RNA 1.

Fonte: Elaborado pelo autor

Os treinamentos, validações e análises da rede neural base (RNA 1) deste Sistema Neural Artificial foram realizados de duas maneiras, que são distintas pelo método de validação. Inicialmente, foram realizados testes com a *Validação K-Fold*, e posteriormente foram realizados testes com *Validação Direta*. Os procedimentos e resultados obtidos são apresentados nas duas seções que seguem.

4.3.1 Validação Cruzada K-Fold

Conforme mencionado anteriormente, quando se utiliza o *Ten-Fold Cross Validation* é eliminada a influência temporal da série de dados, pois os dados estão apresentados de maneira aleatória para a RNA.

Para facilitar a visualização dos resultados na forma gráfica, foram selecionados aleatoriamente três períodos do conjunto total de dados, que estão apresentados nas Figuras 4.3 a 4.5.

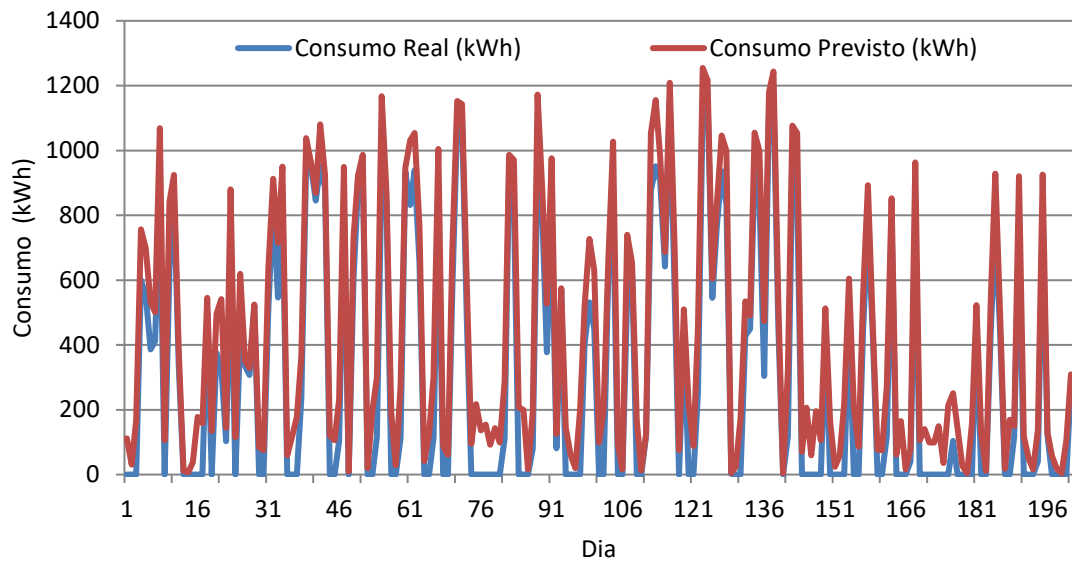


Figura 4.3 - Resultado da RNA com Validação Cruzada (1º conjunto de dados)

Fonte: Elaborado pelo autor




Figura 4.4 - Resultado da RNA com Validação Cruzada (2º conjunto de dados)

Fonte: Elaborado pelo autor

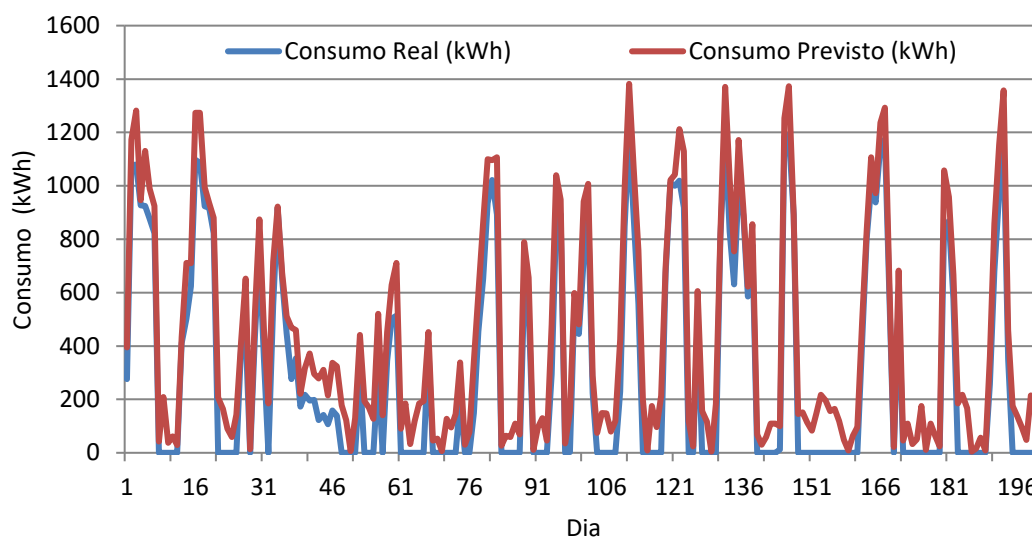


Figura 4.5 - Resultado da RNA com Validação Cruzada (3º conjunto de dados)

Fonte: Elaborado pelo autor

Através da análise gráfica, pode-se verificar que o consumo previsto com a RNA treinada possui boa aproximação do consumo real, apresentando pequenas discrepâncias, principalmente nos pontos de consumo abaixo de 100 kWh. Essas discrepâncias resultam em diferenças percentuais elevadas nesses pontos, superiores a 100% e, para efeito de análise, podem ser consideradas como erros grosseiros – por estarem muito acima do padrão dos demais resultados.

Os erros médios percentuais nos resultados finais de cada conjunto selecionado e apresentado nas Figuras 4.3 a 4.5 foram, respectivamente: 24.86%, 24.15% e 23.45%. O erro total de todo o conjunto de dados testado foi 19,35%.

4.3.2 Validação Direta

Nesse caso, os dados são apresentados com uma sequencialidade temporal que permite à RNA reconhecer as tendências sazonais da série de dados.

Os resultados gráficos da análise da RNA 1 com Validação Direta são apresentados nas Figuras 4.6 a 4.10.

Os Quadros 4.3 a 4.5 resumem os resultados globais de cada unidade consumidora e de cada safra analisada para a RNA 1. Pode-se constatar, nesses Quadros, que a possibilidade de ocorrência de perdas não técnicas é baixa, em todas as situações simuladas.

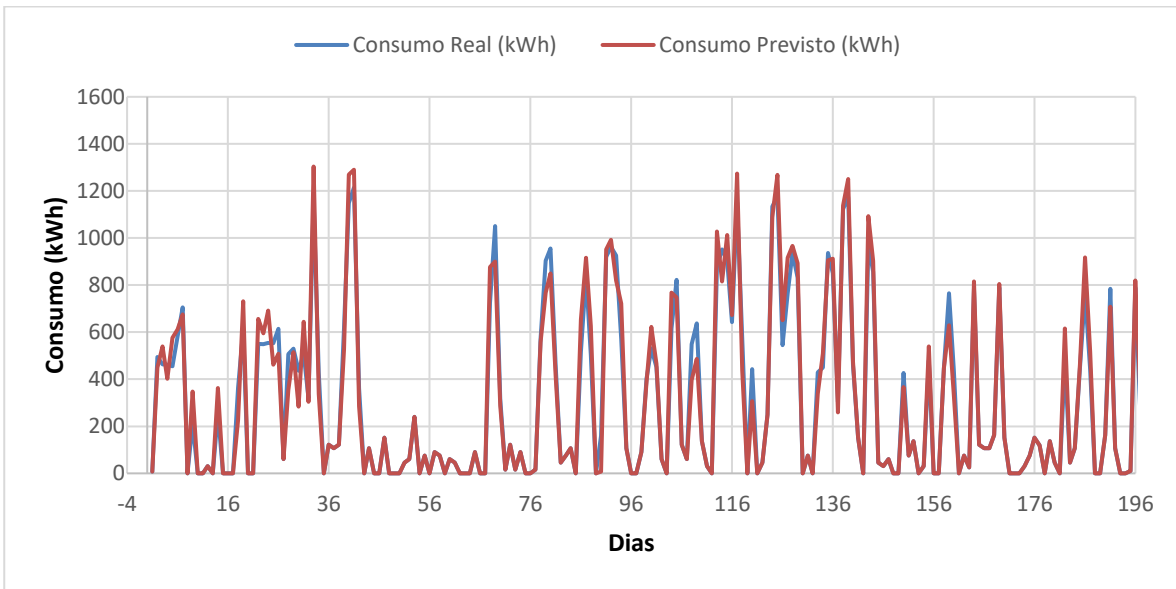


Figura 4.6 - Resultado da análise de UC-1 com RNA e Validação Direta

Fonte: Elaborado pelo autor




Figura 4.7 - Detalhe do resultado da análise de um mês de UC-1 com RNA e Validação Direta

Fonte: Elaborado pelo autor




Figura 4.8 - Resultado da análise de UC-2 com RNA e Validação Direta

Fonte: Elaborado pelo autor




Figura 4.9 - Detalhe do resultado da análise de um mês de UC-2 com RNA e Validação Direta

Fonte: Elaborado pelo autor

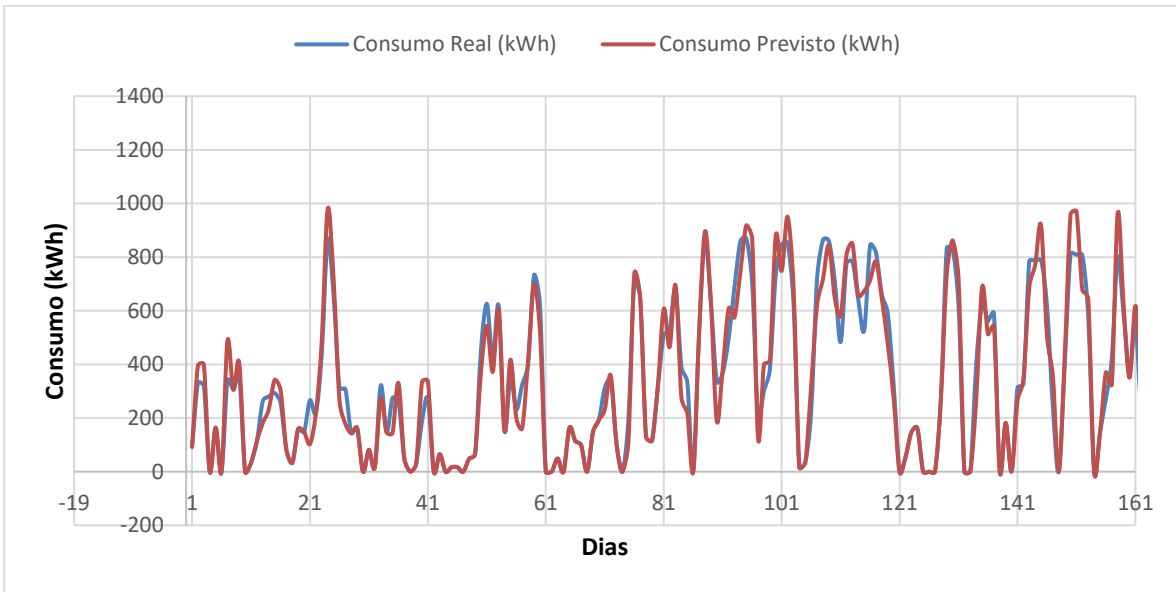


Figura 4.10 - Resultado da análise de UC-3 com RNA e Validação Direta

Fonte: Elaborado pelo autor




Figura 4.11 - Detalhe do resultado da análise de um mês de UC-3 com RNA e Validação Direta

Fonte: Elaborado pelo autor

Quadro 4.3 – Resumo da análise de UC-1 modelada com RNA e Validação Direta.

Safra	Consumo médio diário real (kWh)	Consumo médio diário previsto (kWh)	Erro %	Erro Médio Absoluto %
2009-2010	309,25	313,66	1,43 %	6,75%
2010-2011	353,10	354,09	0,28 %	6,68%
2011-2012	306,66	302,19	-1,46 %	6,04%
2012-2013	318,70	320,74	0,64 %	7,92%
2013-2014	418,99	427,10	1,93 %	5,79%

Fonte: Elaborado pelo autor

Quadro 4.4 – Resumo da análise de UC-2 modelada com RNA e Validação Direta.

Safra	Consumo médio diário real (kWh)	Consumo médio diário previsto (kWh)	Erro	Erro Médio Absoluto %
2009-2010	928,06	905,61	-2,42 %	20,03%
2010-2011	550,78	544,14	-1,21 %	3,31%
2011-2012	728,37	709,23	-2,63 %	12,91%
2012-2013	1.372,90	1.365,87	-0,51 %	21,70%
2013-2014	1.296,44	1.287,79	-0,67 %	11,29%

Fonte: Elaborado pelo autor

Quadro 4.5 – Resumo da análise de UC-3 modelada com RNA e Validação Direta.

Safra	Consumo médio diário real (kWh)	Consumo médio diário previsto (kWh)	Erro	Erro Médio Absoluto %
2009-2010	315,11	311,78	-1,06%	11,02%
2010-2011	201,22	201,88	0,33%	6,70%
2011-2012	312,58	321,68	2,91%	11,27%
2012-2013	338,07	337,95	-0,04%	8,79%
2013-2014	307,90	310,76	1,01%	10,44%

Fonte: Elaborado pelo autor

4.4 Análise do Sistema Neural Artificial

Nessa seção são apresentados os testes e resultados da aplicação do SNA com a utilização de outras Redes Neurais do sistema, além da RNA 1. Estas redes são previamente treinadas e posteriormente utilizadas para a realização da previsão de consumo e conseqüentemente a análise da possibilidade de perdas não técnicas.

4.4.1 Características, treinamento e escolha da rede no SNA

A seleção de uma rede neural no SNA é realizada conforme o conjunto de informações disponíveis (Seção 3.3). Para treinamento e validação das Redes Neurais considerando informações complementares foi aplicado um fator de redução nos valores reais de consumo de cada lavoura estudada, simulando o efeito do parâmetro analisado, conforme o Quadro 4.6. Por exemplo, em uma rede com a entrada de dados complementares 1 (nível de automação) foi aplicado um fator de redução de 10% no consumo real da lavoura se o nível de automação for baixo, e 30% se for alto. Esse procedimento foi adotado devido à limitação de dados reais disponíveis, que permitisse simular todas as combinações possíveis de respostas às informações complementares propostas.

Quadro 4.6 – Fator de redução do consumo aplicado com dados complementares

Dado complementar	Característica	Redução de Consumo
Dado complementar 1 Nível de automação	Baixo	10 %
	Médio	20 %
	Alto	30 %
Dado complementar 2 Altura do levante	Baixa	30 %
	Média	20 %
	Alta	10 %
Dado complementar 3 Declividade do solo	Pequena	30 %
	Média	20 %
	Grande	10 %
Dado complementar 4 Método de irrigação	Solo saturado	30 %
	Lâmina d'água constante	20 %
	Lâmina d'água intermitente	10 %

Fonte: Elaborado pelo autor

Nas redes em que mais de um dado complementar de entrada foi simulado, os fatores de redução são sobrepostos, conforme Equação 4.3, onde R_i é o fator de redução individual de cada dado complementar.

$$\text{Redução} = (1 - R_1) \cdot (1 - R_2) \cdot \dots \cdot (1 - R_n) \quad (4.3)$$

O Quadro 4.7 apresenta os percentuais mínimos e máximos de redução de consumo em cada RNA do SNA desenvolvido, considerando os valores apresentados no Quadro 4.6 aplicados à Equação 4.3.

Quadro 4.7 – Redução simulada de consumo nas RNAs

RNA do SNA	Redução Simulada de Consumo	
	Mínima	Máxima
RNA 1	-	-
RNA 2	10%	30%
RNA 3	10%	30%
RNA 4	19%	51%
RNA 5	10%	30%
RNA 6	19%	51%
RNA 7	19%	51%
RNA 8	27,1%	65,7%
RNA 9	10%	30%
RNA 10	19%	51%
RNA 11	19%	51%
RNA 12	27,1%	65,7%
RNA 13	19%	51%
RNA 14	27,1%	65,7%
RNA 15	27,1%	65,7%
RNA 16	34,4%	76%

Fonte: Elaborado pelo autor

Quando a resposta a uma pergunta complementar implicar na anulação do efeito da entrada, o sistema é auto redirecionado para a rede equivalente sem aquela entrada. Por exemplo, considerando o seguinte caso:

- Dados disponíveis: Obrigatórios + Complementar 1 + Complementar 3 → (RNA 11)

Se a resposta à pergunta Complementar 1 – nível de automação – for “automação inexistente”, então o SNA considera que o respectivo neurônio de entrada da rede não deve ser ativado, e a rede se torna:

- Dados disponíveis: Obrigatórios + Complementar 3 → (RNA 3)

Seguindo o mesmo padrão de treinamento da RNA 1, rede base para o SNA, o treinamento definido para as RNA's utilizadas nos estudos desta Tese foram treinadas através da validação direta, observando a temporalidade dos dados e os resultados atingidos na rede base.

Nas próximas seções são apresentados os resultados obtidos com três RNAs diferentes da RNA 1 apresentada na Seção 4.3, nas quais são consideradas as entradas relacionadas aos dados complementares: RNA 8, RNA 16 e RNA 7.

4.4.2 Análise da RNA 8 aplicada à UC-1

Conforme apresentado no Quadro 3.1, a RNA 8 considera as respostas relacionadas às informações complementares número 2 (altura do levante), 3 (declividade média do solo) e 4 (método de irrigação), além dos dados obrigatórios.

Para testes, foram utilizados os dados da lavoura UC-1. Para as condições inferidas para essa lavoura, tem-se a características de respostas das questões complementares e da expectativa de redução de consumo observadas no Quadro 4.8. O fator de redução de consumo aplicado aos dados reais da lavoura é de 49,6%, conforme a Equação 4.3. A rede, então, é treinada aplicando-se esse fator.

Quadro 4.8 – Escolha da Rede Neural relacionada as informações Inferidas (RNA 8).

Dados complementares RNA 8			
Compl. 1 Automação	Compl. 2 Altura Levante	Compl. 3 Declividade do solo	Compl. 4 Método de irrigação
Inexistente	Média	Baixa	Intermitente
0	20%	30%	10%
Redução de Consumo = 49,6 %			

Fonte: Elaborado pelo autor

O Quadro 4.9 apresenta as informações utilizadas para seleção e treinamento da rede, relacionadas às informações complementares do SNA. Os dados referentes às informações obrigatórias são os mesmos utilizados na Seção 4.3, no treinamento da RNA 1.

Quadro 4.9 – Informações complementares para UC-1 RNA 8

Lavoura / RNA do SNA	Pergunta complementar	Acesso à informação	Resposta	Entrada no Neurônio
UC-1 RNA 8	Compl. 1 Nível de automação	Sim	Inexistente (0)	-
	Compl. 2 Altura do levante	Sim	Média	0,333
	Compl. 3 Declividade do solo	Sim	Baixa	0,666
	Compl. 4 Método de irrigação	Sim	Intermitente	1,0

Fonte: Elaborado pelo autor

A Figura 4.12 representa a RNA selecionada, na qual se observa que a entrada referente à pergunta complementar 1 (nível de automação) é anulada.

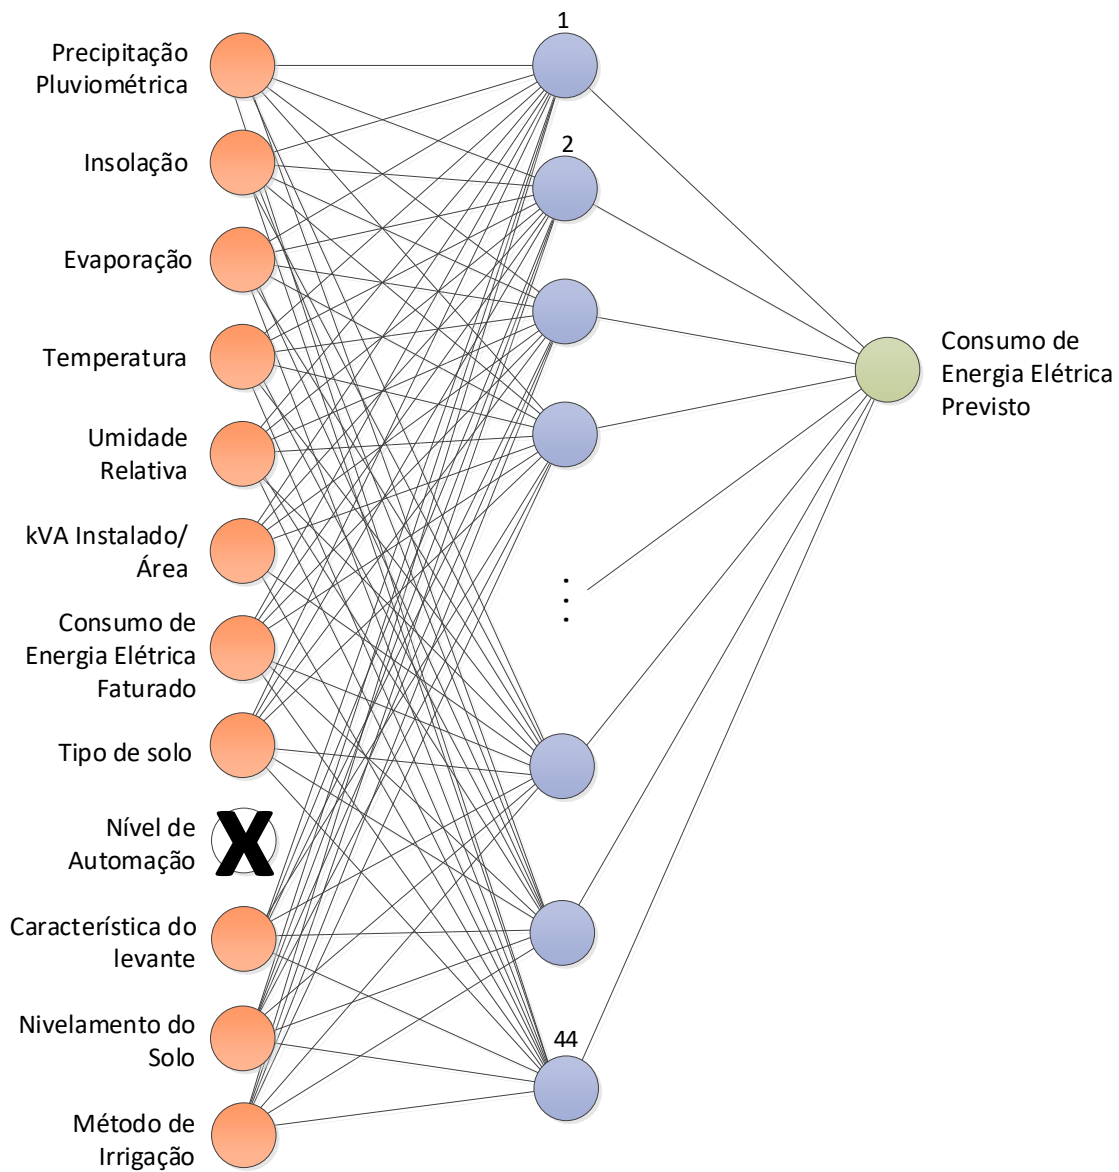


Figura 4.12 - Rede Neural Artificial 8 do SNA

Fonte: Elaborado pelo autor

Utilizando o treinamento com validação direta (Seção 3.7) foi verificado que a rede com 44 neurônios na camada oculta foi a que apresentou menor erro de treinamento, inferior a 2%, conforme mostra a Figura 4.13.




Figura 4.13 – Relação entre número de neurônios na camada intermediária e o erro de treinamento da RNA 8 do SNA.

Fonte: Elaborado pelo autor

Os resultados gráficos para um período de análise (safra 2009/2010) da RNA 8 são apresentados nas Figuras 4.14 e 4.15.




Figura 4.14 – Resultado da análise do estudo I para a lavoura UC-1 safra 2009/2010 com Validação Direta da RNA 8 do SNA.

Fonte: Elaborado pelo autor

Na figura 4.14, comparando com os resultados da RNA 1 (Figura 4.7), pode-se observar que o consumo foi aplicado o fator de redução de consumo. A faixa de erro é parecida, porém o erro é ligeiramente maior do que o observado na RNA-1 deste sistema.

O gráfico da figura 4.15 apresenta um período de 30 dias da safra em questão, para uma observação mais detalhada das informações.




Figura 4.15 – Resultado da análise do estudo I para a lavoura UC-1 para 30 dias da RNA 8 do SNA.

Fonte: Elaborado pelo autor

Observa-se através dos resultados da RNA 8, que o erro obtido foi praticamente o mesmo observado para a RNA 1 e que, para este caso, não se confirmou a expectativa de diminuir o erro com o acréscimo de informações da lavoura (neurônios de entrada). No entanto, a rede apresenta um erro aceitável, dentro do esperado nesta metodologia, ou seja, menor que 10%. Isso implica que o resultado final da análise leva a um índice de baixa probabilidade de perdas não técnicas.

4.4.3 Análise da RNA 16 aplicada à UC-2

O procedimento apresentado na seção anterior foi repetido com uma safra da UC-2, simulando-se dados correspondentes às quatro informações complementares,

além dos dados obrigatórios. Considerando que os dados disponíveis contemplam as quatro Informações complementares, o SNA seleciona a RNA 16.

O Quadro 4.10 apresenta as respostas às informações complementares, e o fator de redução aplicado ao consumo real da rede, para fins de testes.

Quadro 4.10 – Informações complementares para UC-2 RNA 16

Dados complementares RNA 16			
Compl. 1 Automação	Compl. 2 Altura Levante	Compl. 3 Declividade do solo	Compl. 4 Método de irrigação
Baixa	Baixa	Pequena	Intermitente
10%	30%	30%	10%
Redução de Consumo = 60,31 %			

Fonte: Elaborado pelo autor

Com estas informações, realiza-se o treinamento da rede com o índice de redução de 60,31% no consumo de energia. No quadro 4.11 são apresentadas as informações obtidas para esta lavoura e os valores de cada uma destas entradas, recebidas pelos neurônios da camada de entrada.

Quadro 4.11 – Escolha da Rede Neural relacionada as informações Inferidas (RNA 16).

Lavoura / RNA do SNA	Pergunta complementar	Acesso à informação	Resposta	Entrada no Neurônio
UC-2 RNA 16	Compl. 1 Nível de automação	Sim	Baixa	0,333
	Compl. 2 Altura do levante	Sim	Pequena	0,333
	Compl. 3 Declividade do solo	Sim	Declividade Pequena	0,333
	Compl. 4 Método de irrigação	Sim	Intermitente	1,0

Fonte: Elaborado pelo autor

Para a RNA 16, todos as entradas receberam informações em relação à lavoura UC 2. Com isto a rede foi treinada com todos os neurônios de entrada. Na figura 4.16, observa-se a rede com todas os dados obrigatórios e complementares.

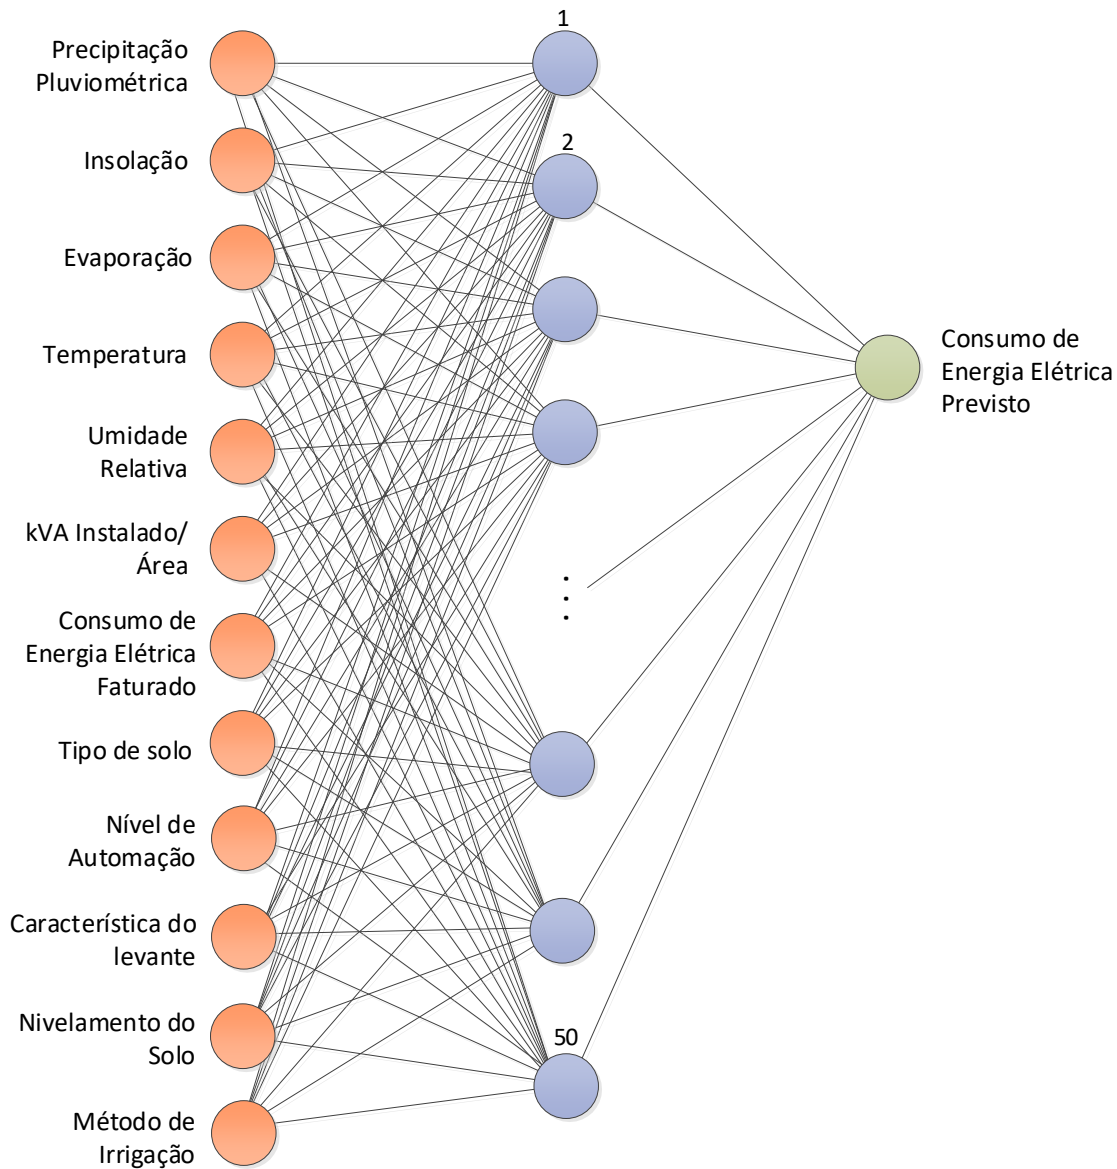


Figura 4.16 - Rede Neural Artificial 16 do SNA

Fonte: Elaborado pelo autor

A validação para a RNA 16, seguiu o procedimento apresentado na seção 4.4.2. O resultado deste treinamento foi um erro de 2,5%, para 50 neurônios na camada oculta, a melhor alternativa entre as opções testadas, conforme a figura 4.17.




Figura 4.17 – Relação entre número de neurônios na camada intermediária e o erro de treinamento da RNA 16 do SNA.

Fonte: Elaborado pelo autor

Os resultados gráficos da análise da RNA 16 são apresentados nas Figuras 4.18 e 4.19.




Figura 4.18 – Resultado da análise do estudo para a lavoura UC-2 safra 2009/2010 com Validação Direta da RNA 16 do SNA.

Fonte: Elaborado pelo autor

O gráfico apresentado na figura 4.17 apresenta o conjunto de dados de uma safra completa e apresenta um erro médio de 10,92%. Somente com os dados obrigatórios, a RNA 1 apresentou um erro de 13,66% para a mesma safra estudada, conforme Figura 4.9. Neste caso, percebe-se que a redução percentual do erro é significativa.

Na figura 4.19 apresenta-se um período de 30 dias para o mês de dezembro de 2009 da lavoura em questão.




Figura 4.19 – Resultado da análise do estudo II para a lavoura UC-2 para 30 dias da RNA 16 do SNA.

Fonte: Elaborado pelo autor

4.4.4 Análise da RNA 7 aplicada à UC-3

Seguindo o mesmo procedimento das seções anteriores, os dados da UC-3 foram testados considerando-se o acréscimo de duas informações complementares (altura do levante e declividade do solo), levando à seleção da RNA 7 do SNA.

O Quadro 4.12 apresenta o fator de redução de consumo aplicado aos dados reais da lavoura, considerando a expectativa de redução em função das respostas complementares disponíveis.

Quadro 4.12 – Informações complementares para UC-3 RNA 7

Dados complementares RNA 7			
Compl. 1 Automação	Compl. 2 Altura Levante	Compl. 3 Declividade do solo	Compl. 4 Método de irrigação
-	Média	Grande	-
-	20%	10%	-
Redução de Consumo = 28 %			

Fonte: Elaborado pelo autor

O quadro 4.13 temos as informações obtidas para a lavoura UC-3 e o nível de cada uma das entradas inferidas aos neurônios de entrada.

Quadro 4.13 – Escolha da Rede Neural relacionada as informações inferidas (RNA 7)

Lavoura / RNA do SNA	Pergunta complementar	Acesso à informação	Resposta	Entrada no Neurônio
UC-3 RNA 7	Compl. 1 Nível de automação	Não	-	-
	Compl. 2 Altura do levante	Sim	Média	0,666
	Compl. 3 Declividade do solo	Sim	Grande	0,333
	Compl. 4 Método de irrigação	Não	-	-

Fonte: Elaborado pelo autor

A Figura 4.20 apresenta o modelo da RNA 7, com os respectivos neurônios de entrada ativados.

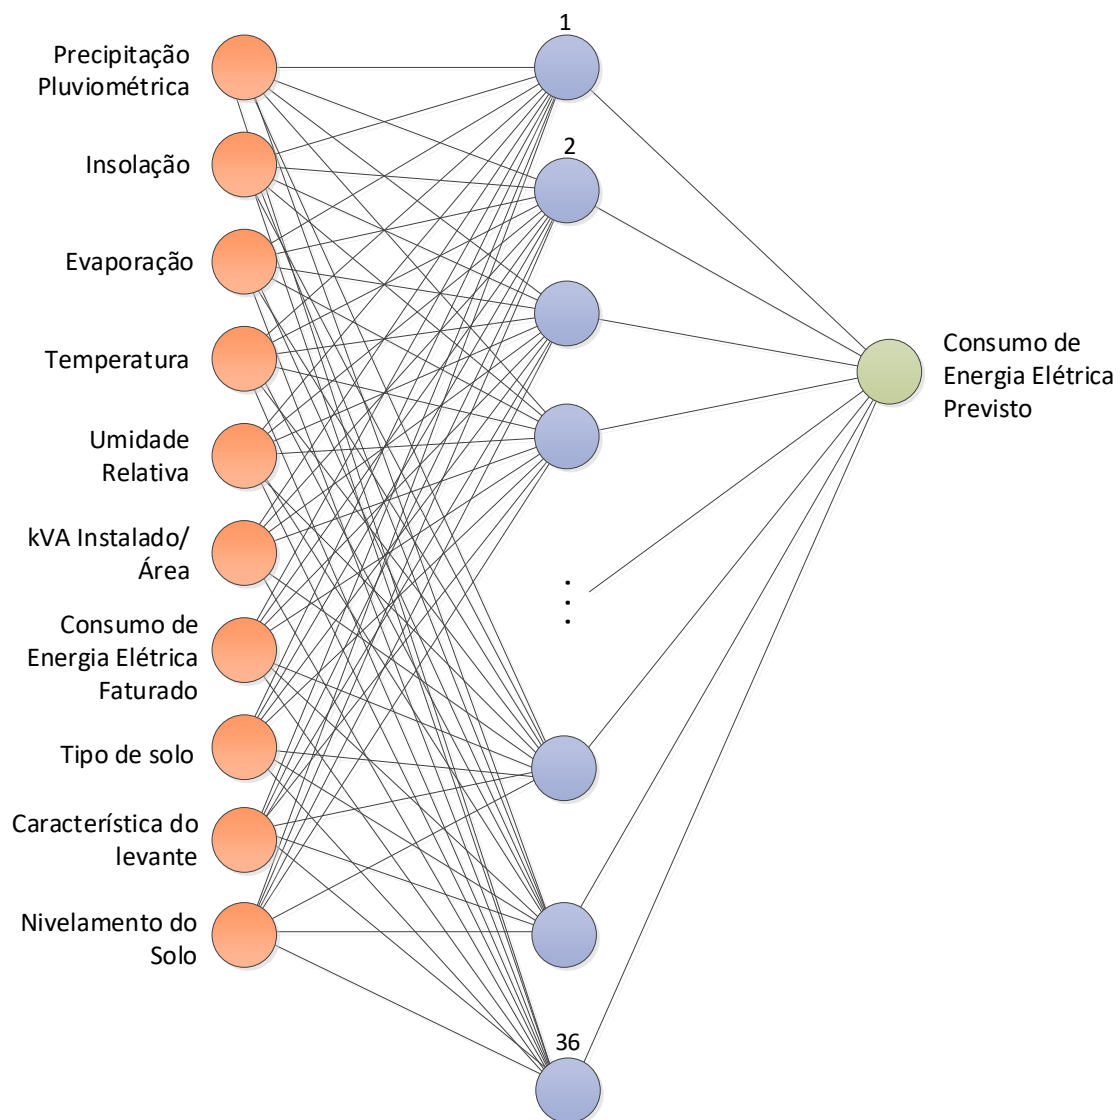


Figura 4.20 - Rede Neural Artificial 7 do SNA

Fonte: Elaborado pelo autor

O treinamento dessa rede apresentou o menor erro percentual (igual a 1,78%) com 36 neurônios na camada oculta, conforme Figura 4.21.




Figura 4.21 – Relação entre número de neurônios na camada intermediária e o erro de treinamento da RNA 7 do SNA.

Fonte: Elaborado pelo autor

Os resultados gráficos da análise da RNA 7 são apresentados nas Figuras 4.22 e 4.23.




Figura 4.22 – Resultado da análise do estudo III para a lavoura UC-3 safra 2009/2010 com Validação Direta da RNA 7 do SNA.

Na figura 4.23 temos um detalhamento de 30 dias de dezembro de 2009.




Figura 4.23 – Resultado da análise do estudo III para a lavoura UC-3 para 30 dias da RNA 7 do SNA.

Fonte: Elaborado pelo autor

Pode-se constatar, nesses resultados, que a possibilidade de ocorrência de perdas não técnicas é baixa, em todas as situações simuladas.

O Sistema Neural Artificial, proporciona uma melhor aproximação quando se utilizam mais informações a respeito da lavoura, como pode ser observado no resumo dos resultados apresentados a seguir.

4.5 Resumo dos Resultados para RNA 8, RNA 16 e RNA 7.

Essa seção apresenta um resumo dos resultados obtidos com os testes nas três lavouras, para as cinco safras disponíveis (2009 a 2014), e com as respectivas RNAs utilizadas pelo SNA: RNA 8 (UC-1), RNA 16 (UC-2) e RNA 7 (UC-3). Os quadros 4.14 a 4.16 apresentam esses resultados.

Quadros 4.14 – Resumo da análise de UC-1 RNA 8 do SNA modelada com Validação Direta.

Safra	Consumo médio diário real (kWh)	Consumo médio diário previsto (kWh)	Erro %	Erro Médio Absoluto %
2009-2010	145,2122	143,9854	0,84%	7,13%
2010-2011	168,6996	164,8941	2,26%	6,98%
2011-2012	144,4139	145,9255	-1,05%	5,56%
2012-2013	151,0263	144,8321	4,10%	7,01%
2013-2014	203,1862	203,6549	-0,23%	5,45%

Fonte: Elaborado pelo autor

Quadros 4.15 – Resumo da análise de UC-2 RNA 16 do SNA modelada com Validação Direta.

Safra	Consumo médio diário real (kWh)	Consumo médio diário previsto (kWh)	Erro %	Erro Médio Absoluto %
2009-2010	336,022	348,3496	-3,67%	10,92%
2010-2011	181,0918	182,9795	-1,04%	8,35%
2011-2012	252,6364	253,3458	-0,28%	9,47%
2012-2013	530,1653	502,3578	5,25%	17,03%
2013-2014	500,4267	518,5889	-3,63%	10,32%

Fonte: Elaborado pelo autor

Quadros 4.16 – Resumo da análise de UC-3 RNA 7 do SNA modelada com Validação Direta.

Safra	Consumo médio diário real (kWh)	Consumo médio diário previsto (kWh)	Erro %	Erro Médio Absoluto %
2009-2010	191,2462	202,4618	-5,86%	10,67%
2010-2011	155,817	152,1827	2,33%	6,87%
2011-2012	191,6353	198,1665	-3,41%	10,53%
2012-2013	292,8376	298,4124	-1,90%	9,01%
2013-2014	271,5075	276,759	-1,93%	10,95%

Fonte: Elaborado pelo autor

4.6 Resultados de simulação de uma situação de perda não técnica

Nessa seção, são apresentados os resultados obtidos com o modelo de RNA desenvolvido na Seção 4.3.1, para uma situação em que foi aplicada uma falha intencional no sistema de medição de energia de uma das lavouras.

O conjunto de dados apresentado à RNA 1, nessa simulação, desconsidera a potência de uma das fases da rede, simulando, por exemplo, uma falha ou fraude em um transformador de corrente do sistema de medição. Nesse caso, a energia faturada pela concessionária de energia seria menor que a energia real fornecida.

As Figuras 4.24 e 4.25 ilustram os resultados obtidos através da RNA com Validação Direta, após a aplicação da falha intencional nos dados de consumo da lavoura UC-3.




Figura 4.24 - Resultado da simulação de falha na medição de UC-3.

Fonte: Elaborado pelo autor




Figura 4.25 - Detalhe do resultado da simulação de falha na UC-3, Safra 2009-2010.

Fonte: Elaborado pelo autor

Os resultados numéricos das análises de simulação de falha estão resumidos no Quadros 4.17.

Quadros 4.17 – Resumo da análise de UC-3 com simulação de falha de medição

Safra	Consumo médio diário real (kWh)	Consumo médio diário previsto (kWh)	Erro
2009-2010	263,52	378,04	43,46 %
2010-2011	172,57	285,59	65,49 %
2011-2012	229,00	413,23	80,45 %
2012-2013	153,55	270,66	76,26 %
2013-2014	276,98	397,56	32,83 %

Fonte: Elaborado pelo autor

Como pode ser verificado no Quadro 4.16, e considerando os critérios estabelecidos no Quadros 4.1, os resultados da análise indicam forte possibilidade de ocorrência de perdas não técnicas nas cinco safras analisadas, refletindo o efeito da simulação de falha intencional aplicada aos dados de consumo dessa lavoura.

O Apêndice F apresenta algumas telas com comparações de possibilidade de fraude, desenvolvido em Visual Basic para essa Tese e que tem por finalidade a apresentação dos resultados ao operador.

5. CONSIDERAÇÕES FINAIS

Essa Tese abordou o problema das perdas não técnicas nos sistemas de distribuição de energia, tendo como escopo a análise de consumidores rurais que utilizam sistemas de irrigação para lavouras de arroz. O trabalho foi motivado pela relevância desse tipo de consumidor nos sistemas de potência, pela dificuldade de fiscalização e identificação de fraudes nas linhas de distribuição rurais e pela carência de estudos que abordam esse problema.

O objetivo geral do trabalho foi o desenvolvimento de uma metodologia que permita identificar possíveis situações de perdas não técnicas, baseado em padrões de consumo e características próprias das lavouras, associados a registros climatológicos.

Para atingir esse objetivo, desenvolve-se um Sistema Neural Artificial que emprega Redes Neurais Artificiais *Perceptron* de múltiplas camadas, treinadas com um conjunto de dados reais de lavouras de arroz irrigado do Rio Grande do Sul. O conjunto de entradas utilizado compreende dados obrigatórios: potência instalada por área irrigada, consumo faturado de energia elétrica, tipo de solo, precipitação pluviométrica, temperatura, umidade relativa do ar, insolação e evaporação, e dados complementares, cuja disponibilidade pode variar de uma lavoura para outra: nível de automação, altura do levante, declividade média do solo e método de irrigação. A disponibilidade dos dados complementares é o que define a rede neural do SNA a ser selecionada para análise. A rede neural que contém apenas as informações obrigatórias é definida como a rede de base do sistema.

A saída do SNA indica o consumo de energia previsto para a lavoura. A validação pode ser realizada de duas maneiras: utilizando a técnica de Validação Cruzada *Ten-Fold*, e utilizando a técnica de Validação Direta, dependendo da quantidade de dados disponíveis e da aderência dos resultados.

Com os resultados finais do SNA é possível concluir que a metodologia é válida e que o acréscimo de informações sobre as lavouras em análise tende a aumentar a precisão dos resultados, diminuindo erros das redes e, em uma última análise, aumentando a eficácia da inspeção dos consumidores em questão. Estes objetivos foram alcançados com uma amostra de 4 RNAs (RNA 1, RNA 8, RNA 16 e RNA 7) e com dados reais de consumo e clima para 3 lavouras de arroz irrigado.

A tendência é que a realimentação das RNAs com um maior volume de dados reais, de lavouras com diferentes características e contemplando um maior número de combinações de entradas leve a uma melhor aproximação dos resultados. Considerando que o erro médio considerado como válido em muitos sistemas com RNAs é em torno de 10%, pode-se concluir que os resultados obtidos são válidos. Nos casos em que não se percebeu uma melhoria de resultados em relação à rede de base, uma das justificativas é o fato de que os dados de entradas testados – especialmente a sobreposição de fatores de redução de consumo de energia – podem não ser coerentes com a realidade da lavoura em questão.

Em comparação aos sistemas atuais de detecção de perdas não técnicas, esta metodologia apresenta uma possibilidade de assertividade similar, porém com a vantagem de poder analisar individualmente o cliente, com dados remotos e com indicativos consistentes para uma abordagem eficiente. O SNA desenvolvido com RNAs pode ser utilizado como mecanismo de apoio à identificação de possíveis perdas não técnicas, por parte das concessionárias de energia elétrica. Diferentemente de métodos baseados em balanços de energia, ele apresenta a característica de identificar pontualmente as unidades consumidoras suspeitas. Também apresenta a vantagem de não utilizar equipamentos e recursos tecnológicos exclusivos para a identificação de perdas. Por outro lado, é necessária uma grande quantidade de dados para a modelagem das RNAs, e os dados - no caso desse trabalho - são oriundos de fontes diferentes.

A partir de uma simulação de falha no sistema de medição de uma das lavouras analisadas - na qual a potência em uma das fases da rede não foi computada no cálculo de consumo de energia – pôde-se demonstrar que a RNA desenvolvida foi capaz de identificar a situação anômala, indicando forte possibilidade de ocorrência de perdas não técnicas.

Destaca-se, por fim, que essa Tese apresenta pioneirismo no estudo de perdas não técnicas em consumidores com sistemas de irrigação de grande porte. Isso é constatado pela ausência de publicações técnicas sobre o tema. Nesse sentido, a metodologia aqui proposta pode ser considerada promissora em termo de aplicação prática e com possibilidade de aperfeiçoamento, considerando as sugestões de continuidade apresentadas a seguir.

Sugestões de Continuidade

Com o objetivo de melhorar o desempenho e expandir as possibilidades da metodologia desenvolvida nesta Tese, as seguintes possibilidades são sugeridas para continuidade do trabalho:

- Aprofundar a análise estabelecendo uma relação entre consumo real esperado (resultado obtido conceitualmente levado em conta as características de lavoura e da rede elétrica) utilizando técnicas de RNA, e o consumo real esperado aplicando conceitos clássicos de análise do SEP, como balanço de energia e análise do fluxo de potência;
- Integrar a metodologia proposta com tecnologias de inspeção remotas como, por exemplo, a utilização de imagens de satélite para verificação da área irrigada;
- Desenvolver uma metodologia empregada com o viés da eficiência energética, nos casos em que o erro percentual obtido seja negativo e relevante. Nesses casos, a interpretação que pode ser feita é de que o consumidor está consumindo mais energia elétrica do que o padrão esperado para o seu tipo de lavoura. Os encaminhamentos, nessa situação, podem levar a uma revisão no dimensionamento das bombas de irrigação, obsolescência de equipamentos, e rendimento dos sistemas de bombeamento e tubulações;
- Treinar novas redes e sistemas com o objetivo de implementar uma ferramenta capaz de obter indicativos de perdas não técnicas em outros tipos de lavouras e aplicações.

REFERÊNCIAS BIBLIOGRÁFICAS

ABBASY, N. H. **Neural Network Aided Design for Metering System of Power System State Estimation**, Stellenbosch: Proceedings of 4th IEEE AFRICON, vol. 2, pp. 607 – 610, sept. 1996. Abbasy e Hassawy (1996);

ABBASY, N. H.; EL-HASSAWY, W. **Power system State Estimation: ANN-Application to bad data detection and identification**. Stellenbosch: IEEE, 1996, pp 611-615.

ABRADEE – Associação Brasileira de Distribuidores de Energia Elétrica. **SIG – Sistemas de Informação para a Gestão**. Brasília, DF, 2016.

AES-SUL – **“Experiência da AES Sul nos Projetos de Eficiência Energética em Sistemas de Bombeamento”** Seminário: Diretrizes para comissões de conservação de água e energia, ABAE: Associação Brasileira de Água e Energia. Porto Alegre, 2006.

AGÜERO, J. R. **“Improving the efficiency of power distribution systems through technical and non-technical losses reduction,”** IEEE Transmission and Distribution Conference and Exposition (T&D), Orlando FL, USA, May 2012.

AGUIAR, H.; OLIVEIRA JUNIOR (Coord.). **Inteligência Computacional: Aplicada à Administração, Economia e Engenharia em MatLab®**. São Paulo: Thomson, 2007. 320 p.

ALTRAN, A. B. **Aplicação de Funções de Base Radial em Problemas de Previsão de Cargas Elétricas Via Redes Neurais Artificiais**. 2005. 112 f. Dissertação (Mestrado em Engenharia Elétrica)–Universidade Estadual Paulista, Ilha Solteira, 2005.

ALVES, P. CASANOVA, E. QUIROGAS, O. RAVELO, AND W. GIMENEZ, **“Reduction of non-technical losses by modernization and updating of measurement systems,”** in Proc. IEEE/PES Transmission and Distribution Conf. Expo.: Latin America, 2006, pp. 1–5.

AMARAL, L.G.H. do; RIGHES, A.A. Estruturas automáticas para controle de água nos canais em lavoura de arroz irrigado. **Engenharia Agrícola**, Jaboticabal, v.25, n.1, p.272-281, 2005.

ANEEL Agência Nacional de Energia Elétrica. **Projeto Estratégico: “Atlas de Energia Elétrica do Brasil - Aneel”** Brasília - DF, (2011) Acesso em agosto 2016, disponível em: <http://www.aneel.gov.br>

ANEEL Agência Nacional de Energia Elétrica. **Tratamento regulatório de perdas Não técnicas - Aneel**” Rio de Janeiro - RJ, (2014) Acesso em agosto 2016, disponível em: <http://www.aneel.gov.br>

ANTONIO, A. B., TORREÃO, J. R. A., DO COUTTO FILHO, M. B. **Meter Placement for Power System State Estimation Using Simulated Annealing**. Portugal: IEEE Proceedings of Porto Power Tech. Conference, vol. 3, 5 pp., sept. 2001.

BIBLIOTECA DIGITAL, SCIELO: Épocas de início de inundação do solo e altura da lamina de água em arroz irrigado; Acesso em outubro 2016 disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S00067051995000200020&lng=pt&nrm=iso.

CALILI, R. F., **Desenvolvimento de um sistema de detecção de perda comerciais no sistema de distribuição**. Dissertação de Mestrado – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005.

CELIK, M. K.; LIU, W. H. E. **A Practical Distribution State Calculation Algorithm**. Power Engineering Society 1999 Winter Meeting, IEEE. Vol. 1, pp. 442 – 447, jan. 1999. INSPEC Accession Number: 6209741.

CELIK, M.; LIU, W.H.E. **A Practical Distribution State Estimation Algorithm**. Proceedings of PES Winter Meeting, 1999.

CHAUHAN, A.; RAJVANSHI, S. **Non-Technical Losses in power system: A review**. Proceedings of 2013 International Conference on Power, Energy and Control, ICPEC 2013.

COELHO, E. F.; COELHO FILHO, M. A.; OLIVEIRA, S. L. Agricultura irrigada: eficiência de irrigação e de uso de água. **Bahia Agrícola**, Salvador, v. 7, n. 1, p. 57-60, 2015.

CORREA. N. I. Consumo de água na irrigação do arroz por inundação. **Lavoura Arrozeira**. Porto Alegre, v. 50, n. 432, p. 3-8. jul./ago., 1997.

CRUZ, R.V. ; QUINTERO, C.V. ; PEREZ, F. **Detecting Non-Technical Losses in Radial Distribution System Transformation Point through the Real Time State Estimation Method**. Transmission & Distribution Conference and Exposition: Latin America, 2006.

CRUZ, R.V.; QUINTERO, C.V.; PEREZ, F. Detecting Non-Technical Losses in Radial Distribution System Transformation Point through the Real Time State Estimation

Method. **Transmission & Distribution Conference and Exposition: Latin America, 2006. TDC '06. IEEE/PES. 2006.**

DENG Y.; HE Y.; ZHANG B. **A Branch-Estimation-Based State Estimation Method for Radial Distribution Systems.** *Transactions on Power Systems Delivery*, Vol. 17, NO. 4, oct. 2002. ISSN : 0272-1724.

DEPURU, S. S. S. R., **Modeling, Detection, and Prevention of Electricity Theft for Enhanced Performance and Security of Power Grid.** Master Thesis, The University of Toledo, Toledo , 2012

DONADEL, C.; ANICIO, J.; FREDES, M.; VAREJÃO, F.; COMARELA, G.; PERIM, G. **A methodology to refine the technical losses calculation from estimates of non-technical losses.** In: INTERNATIONAL CONFERENCE ON ELECTRICITY DISTRIBUTION, 20., 2009, Praga. Anais... Praga: CIRED, 2009. 4 p.

DORTOLINA, C. A.; NADIRA, R. **The loss that is unknown is no loss at all: a topdown/bottom-up approach for estimating distribution losses.** *IEEE Transactions PowerSystems*, New York, v. 20, n. 2, p. 1119-1125, 2005.

EFROYMSON, M. A. “ **Multiple regression analysis**”. Ralston HS Wilf (Ed. 1.), New York, 1960.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. **Cultivo do Arroz Irrigado no Brasil, Manejo da Água em Arroz Irrigado**, 2005. Disponível em
<<http://sistemasdeproducao.cnptia.embrapa.br/FontesHTML/Arroz/ArrozIrrigadoBrasil/cap10.htm#drenagem>>. Acesso em setembro de 2016.

ERGEG (European Regulators Group for Electricity and Gas), **Treatment of Losses by Network Operators.** 2008.

FALCÃO, D.; ASSIS, S. **Linear Programming State Estimation: Error Analysis and Gross Error Identification.** *IEEE Transactions on Power Systems*, Vol. 3, No. 3, aug. 1988. ISSN : 0885-8950.

Faria, P.; Vale, Z.; Antunes, P. and Souza, A. “**Using baseline methods to identify non-technical losses in the context of smart grids,**” in *Innovative Smart Grid Technologies Latin America (ISGT LA)*, 2013 IEEE PES Conference On, 2013, pp. 1–7.

FERREIRA NETO, L. H. T. **Estimador de estado inteligente para análise de perdas em sistemas de distribuição de energia.** 2011. 99 f. Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo, 2011.

FIGUEIREDO, R. M. ; SANTOS, J. V. C. ; CECHIN, A. L. . **Um Novo Sistema Neural para Previsão de Carga em Sistemas de Energia Elétrica.** In: VIII CBQEE - Conferência Brasileira sobre Qualidade de Energia Elétrica, 2009, Blumenau. Anais da VIII CBQEE - Blumenau - SC, 2009.

Freeman, L.; Marshall, M.; Walling R. and Weiss, J. "**Loss characteristics of local-delivery distribution systems,**" in Electricity Distribution - Part 1, 2009. CIRED 2009. 20th International Conference and Exhibition on, 2009, pp. 1-4.

GHOSH, A.K. ; LUBKEMAN, D.L. ; JONES, R.H. **Load modeling for distribution circuit state estimation.** Power Delivery, IEEE Transactions on. 1997.

GONZALEZ-URDANETA, G. "**A Venezuelan experience in the reduction of non-technical power losses**" China International Conference on Electricity Distribution, China, 2010.

HAYKIN, S. **Redes Neurais: Princípios e Prática;** trad. Engel. P. M. - 2.ed. - Porto Alegre, Bookman, 2001. 902 p.

HUANG, S.; LO, Y.; and LU, C. "**Non-technical Loss Detection Using State Estimation and Analysis of Variance.**" IEEE Trans. Power Syst., pp 2959-2966, 2013.

HUANG, S.J.; SHIH, K.R.; "**Short-Term Load Forecasting Via ARMA Model Identification Including Non-Gaussian Process Considerations**", In: IEEE Transactions on Power Systems, v.18, n.2, pp. 673-679, May 2003. Disponível em: <<http://www.ieee.org.br>>. Acesso em: 26 fev 2013.

J. I. GUERRERO, CARLOS LEÓN, FÉLIX BISCARRI, IÑIGO MONEDERO, JESÚS BISCARRI, and ROCÍO MILLÁN, "**Increasing the efficiency in non-technical losses detection in utility companies**". MELECON 2010, 15th IEEE Mediterranean Electromechanical Conference. Pp. 136-141. Valleta, Malta. 25-28 April, 2010.

KENNEDY, J.; EBERHART, R. **Particle swarm optimization.** Perth, Australia: Proceedings IEEE Int. Conf. Neural Networks, pp. 1942–1948, vol. 4, 1995.

KERSTING, W.H. AND W.H. PHILLIPS. "**Modeling and analysis of rural electric distribution feeders.**" IEEE Transactions on Industry Applications. vol. 28(4), pp. 767.

KOTIUGA, W. W.; M. VIDYASAGAR. **Bad Data Rejection Properties of Weighted Least Absolute Value Techniques Applied to Static State Estimation**. IEEE Transactions on Power Apparatus and Systems, v.PAS-101, n.4, p.844-853, 1982. ISSN: 0272-1724.

LITRICO, X.; BELAUD, G.; BAUME, J.P.; RIBOT-BRUNO, J. Hydraulic modeling of an automatic upstream water-level control gate. **Journal of Irrigation and Drainage Engineering**, Reston, v.131, n.2, 2015

MAHAR, P. S.; SINGH, R. P. Optimal design of pumping mains considering pump characteristics. **Journal of Pipeline Systems Engineering and Practice**. [S.l], v. 5, n. 1. fev. 2014. doi: 10.1061/(ASCE)PS.1949-1204.0000157.

MANTOVANI, E. C.; BERNARDO, S.; PALARETTI, L. F. Irrigação - princípios e métodos. **Congress of Irrigation and Drainage**, Viçosa: UFV. 2016. 318 p.

MAREELS, I.; WEYER, E.; OOI, S.K.; CANTONI, M.; LI, Y.; NAIR, G. Systems engineering for irrigation systems: successes and challenges. **Annual Reviews in control**, Oxford, v.29, n.2, p.191- 204, 2005.

MARTINS, P. E. S.; SILVA, E. R.; SANTOS, N. L.; FILHO, M. A. F. L.; GALZERANO, L. Práticas de manejo de irrigação como medida de conservação do solo e da água. **Enciclopédia Biosfera**, Goiânia, v. 6, n. 10, p. 1-19, 2010.

MÉFFE, A. **Cálculo de Perdas Técnicas em Sistemas de Distribuição – Modelos Adequáveis às Características do Sistema e à Disponibilidade de Informações**. São Paulo, Tese de Doutorado, EPUSP, 2007.

MÉFFE, A. **Metodologia para Cálculo de Perdas Técnicas por Segmento do Sistema de Distribuição**, Dissertação de Mestrado, Departamento de Engenharia de Energia e Automação Elétricas da Escola Politécnica da Universidade de São Paulo, São Paulo, 2001.

MÉFFE, A.; OLIVEIRA, C. C. B.; KAGAN, N.; JONATHAN, S.; CAPARROZ, S.;CAVARETTI, J. L. **Technical and economic analysis for the reduction of losses in distribution systems**. In: Transmission and Distribution Conference and Expositio: Latin America, 2002, São Paulo. IEEE/PES, 2002. 6p.

MOLDEN, D. Water for food, water for life: a comprehensive assessment of water management in agriculture. London: Earthscan: **International Water Management Institute**, 2007.

MONEDERO, F. BISCARRI, C. LE & OACUTE; N, J. E R. BISCARRI MILL & AACUTE; **"MIDAS: Detecção de perdas não-técnicas em consumo de energia**

elétrica utilizando redes neurais e técnicas estatísticas", Proc. Int. Conf. Ciência e Aplicações Computacional , vol. 3984, 2006.

MONTGOMERY, D. C. and RUNGER, G. C. **"Engineering Statistics"**, 3rd ed. Hoboken, NJ: Wiley, 2009.

MONTICELLI, A. **State Estimation in Electric Power Systems: A Generalized Approach**. Massachusetts: Kluwer Academic Publishers, 2000.

MUNDSTOCK C. M. [et al.]. Manual de boas práticas agrícolas: guia para a sustentabilidade da lavoura de arroz irrigado do Rio Grande do Sul. **Instituto Rio Grandense do Arroz**, Porto Alegre, p.22-58, 2011. ISBN 978-8589900-12-6

NAKA, S. et al. **Practical Distribution State Estimation Using Hybrid Particle Swarm Optimization**. Columbus, Ohio: IEEE Power Engineering Society Winter Meeting, pp. 815-820, 2001.

NAKA, S.; GENJI, T.; FUKUYAMA, Y. **A hybrid particle swarm optimization for distribution state estimation**. IEEE Transaction on Power Systems, Vol. 18, No. 1, feb. 2003. INSPEC Accession Number: 7992583.

NANNI, M. **Estimador de Estado Robusto Baseado no Método da Mínima Mediana**. São Carlos: Tese (Mestrado em Engenharia Elétrica). Escola de Engenharia de São Carlos da Universidade de São Paulo, 145 f., abr. 2009.

Nizar, A.H.; Zhao, J. H; Dong Z. Y. **Customer Information System Data Pre-Processing with Feature Selection Techniques for Non-Technical Losses Prediction in an Electricity Market**. Power System Technology, 2006. PowerCon 2006 International Conference on DOI: 10.1109/ICPST.2006.321964

OLIVEIRA, C. C. B; MÉFFE, A.; CAMPOS, M. B. M. **Implantação em área piloto e treinamento para utilização do software, Relatório Técnico 04, Projeto de P&D: Metodologia e Determinação do Nível Ótimo de Perdas em um Sistema de Distribuição de Energia**, São Paulo, 2005.

OLIVEIRA, M. O. et al. **Projeção de Demanda de Energia Elétrica a Curtíssimo Prazo Considerando o Índice de Desconforto**, In: SBSE – SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS, 3, Foz do Iguaçu/PR, 2014. **Anais...** Disponível em: < <http://www.researchgate.net/>>. Acesso em: mar. 2016.

PARUCHURI V and DUBEY S, **"An Approach to Determine Non-Technical Energy Losses in India"**, Proc. of 14th Int'l Conf. on Advaned Comm. Tech., 2012, pp. 111-115.

PASQUOTTO, J. L. D. **Previsão de Séries Temporais no Varejo Brasileiro: Uma Investigação Comparativa da Aplicação de Redes Neurais Recorrentes de Elman**. 2010. 200 f. Dissertação (Graduação em Administração)–Universidade de São Paulo, São Paulo, 2010.

PEREIRA, L.A.M.; AFONSO, L.C.S.; PAPA, J.P ; VALE, Z.A.; RAMOS, C.C.O.; Gastaldello, D.S.; Souza, A.N. **Multilayer perceptron neural networks training through charged system search and its Application for non-technical losses detection**. Innovative Smart Grid Technologies Latin America (ISGT LA), 2013 IEEE PES Conference On. 2013.

PFITSCHER, L. L.; BERNARDON, D. P.; KOPP, L. M., HECKLER, M. V. T.; BEHRENS, J.; MONTANI, P. B.. Automatic Control of Irrigation Systems Aiming at High Energy Efficiency in Rice Crops. In: ICCDCS – **International Caribbean Conference on Devices, Circuits and Systems**, pg 1-4, 2012.

QUEIROS, L. M. O., **Estimação e Análise das Perdas Técnicas na Distribuição de Energia Elétrica**. Tese de Doutorado – Universidade Federal de Alfenas – universidade estadual de Campinas, Campinas, 2010.

RAKPENTHAI, C.; PREMRUDEEPREECHACHARN, S.; UATRONGJIT, S.; WATSON, N. R. **Measurement Placement for Power System State Estimation using Decomposition Technique**. Electric Power Systems Research, Elsevier, vol. 75, no. 1, pp. 41 – 49, jul. 2005, INSPEC Accession Number: 8332124.

RAMÍREZ J.M.; BAROCIO. E.E. **Solving State Estimation in Power Systems by an Interior Point method**. Vancouver: ELSEVIER- International Journal of Electrical Power & Energy Systems, no. 22, pp. 355-365, jun. 2000.

REIS, C. Z., **Eficácia de Solução Tecnológica para Redução de Furtos de Energia Elétrica em Empresas Distribuidoras: Estudo de Casos**. Dissertação de Mestrado – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005.

RIBEIRO, S.S. ; CAZES, T. ; MANO, R.F. ; MAIA, D. **“Investment optimization methodology applied to investments on non-technical losses reduction actions.”** Computers and Communications (ISCC), 2012 IEEE Symposium on DOI: 10.1109/ISCC.2012.6249321.

ROSENBLATT, F. **“The perceptron: A probabilistic model for information storage and organization in the brain”**. Psychological Review, Vol 65(6), Nov 1958.

SARIC, A. T.; CIRIC, R. M. **Integrated Fuzzy State Estimation and Load Flow Analysis in Distribution Networks**. IEEE Transaction on Power Delivery, Vol. 18, No.2, apr. 2003. ISSN: 0885-8977.

SCHWEPPE, F. C. **Power System Static-State, Part II: Approximate Model**. IEEE transactions on Power Apparatus and Systems, V.PAS-89, n.1, p 120-130, 1970, ISSN: 0018-9510.

SEBER, G. A. F. and LEE, A. J. **“Linear regression analysis”** (2nded.). Hoboken, NJ: Wiley, 2003.

SHAFIU, A.; JENKINS, N.; STRBAC, G. **Measurement Location for State Estimation of Distribution Networks with Generation**. IEE Proceedings on Generation, Transmission and Distribution,, vol. 152, no. 2, pp. 240–246, march 2005. ISSN: 1350-2360.

SIMÕES, M.G.; SHAW, I.S. **Controle e Modelagem Fuzzy**. Editora: EDGARD BLUCHER. 200 p. São Paulo, 2007.

WALPOLE, R. and MYERS, R. **“Probability and Statistics for Engineers and Scientists”**. New York: Macmillan, 2009.

YANG, G.; WEN, B.; GAO, G.. Devices for Automatic Irrigation Based on GSM Network and Radio Communication. In: **9th International Conference on Control, Automation, Robotics and Vision**, pg 1-5, 2006.

ZARCO, P.; EXPÓSITO, A. G. **Power System Parameter Estimation: A Survey**. IEEE Transactions on Power Systems, vol. 15, no 1: 216-222, 2000.

ZIMMERMAN, H. J., **Fuzzy Set Theory – and Its Application**. Boston: Kluwer-Nijhoff Publishing, 3rd Edition, pp. 281, 1984.

ZOUCAS, F. A. M. **Aplicação de Redes Neurais para Previsão de Séries Temporais em Segmentos Industriais**, 2009. 170 f. Dissertação (Mestrado em Engenharia Mecânica)–Centro Universitário da FEI, São Bernardo do Campo, 2009.

APÊNDICE A – FUNDAMENTAÇÃO TEÓRICA DO MÉTODO APLICADO

Neste Apêndice apresenta-se uma fundamentação teórica dos principais conceitos e avaliação técnica de Redes Neurais Artificiais, empregadas nesse trabalho.

A.1 Redes Neurais Artificiais

Uma Rede Neural Artificial (RNA) tem seu funcionamento baseado em conceitos que são observados no cérebro humano, reproduzindo características e funções de neurônios e caminhos sinápticos do cérebro. A RNA funciona como um processador paralelo distribuído, constituído por unidades de processamento simples, denominadas neurônios (ou nós computacionais), com capacidade de armazenar conhecimento e torná-lo disponível para uso. Assim como ocorre no cérebro, o conhecimento adquirido pela rede a partir de seu ambiente é realizado através de um processo de aprendizagem (HAYKIN, 2001).

As RNAs constituem um ramo importante da Inteligência Artificial (IA) e são amplamente utilizadas devido à possibilidade de se implementar computacionalmente versões simplificadas dos neurônios biológicos. As RNAs são capazes de organizar dados, reconhecer padrões, aprender, tolerar falhas e tomar decisões com base no aprendizado, extraindo informações não apresentadas de forma explícita, entre outras habilidades (ZOUCCAS, 2009).

A capacidade de aprender de uma RNA é obtida por um algoritmo de aprendizagem. O mesmo altera os pesos das ligações sinápticas entre os neurônios, distribuindo-as de maneira ordenada para a rede alcançar seus objetivos.

Na estrutura mais simples, os neurônios de uma RNA são organizados em camadas, sendo estas divididas em três tipos: Entrada, Oculta (Intermediária ou Escondida), e Saída. A Figura A.1 ilustra um exemplo de RNA simples com três neurônios na camada de entrada, 4 neurônios na camada oculta e 3 neurônios na camada de saída.

O número de neurônios das camadas de entrada e saída deve ser definido previamente, de acordo com o número de entradas e saídas do processo a ser modelado. Os conjuntos, ou vetores, de entrada e saída de uma RNA também são chamados de *padrões*. Por sua vez, a camada oculta deve ser definida em função da busca do melhor resultado oriundo de treinamento, podendo ser acrescentados ou retirados neurônios, e refazendo o treinamento até que se consiga uma configuração satisfatória (AGUIAR et al., 2007).




Figura A.1 – Exemplo de rede neural artificial simples.
Fonte: Elaborado pelo autor

A.1.1 Representação das RNAs

A unidade básica de processamento de informação de uma RNA é o neurônio. Esse pode ser dividido em três elementos principais, como mostra a Figura A.2:

- **Sinapses:** responsáveis por ponderar as entradas do neurônio, multiplicando-as por um peso;
- **Somador:** responsável pela soma das entradas multiplicadas pelos respectivos pesos;
- **Função de ativação:** responsável por limitar a amplitude de saída do neurônio tipicamente para valores normalizados nos intervalos $[0,1]$ ou $[-1,1]$.

Nesse modelo, está representado também um sinal b_k , usualmente denominado *bias*, que tem a função de deslocar o resultado do somador para cima ou para baixo, antes de sua entrada na função de ativação.

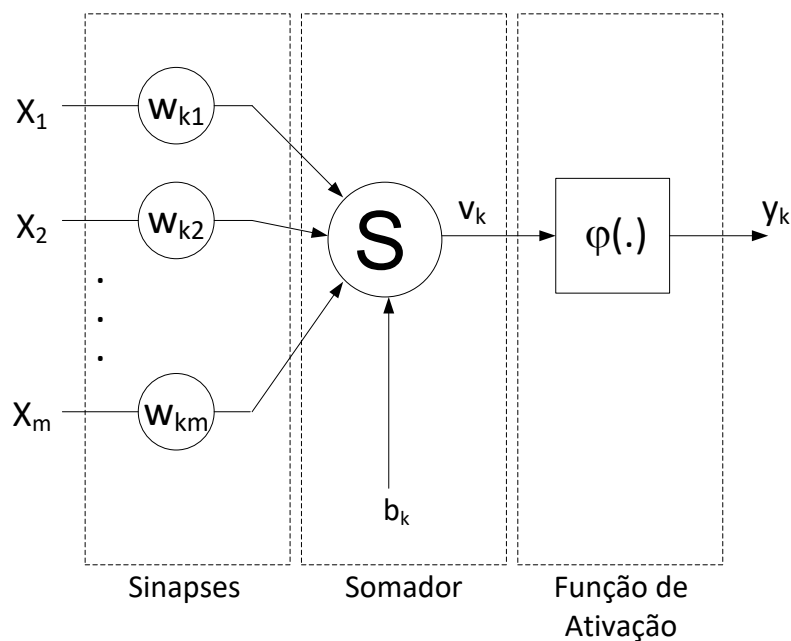


Figura A.2 – Representação de um neurônio

Fonte: Adaptado de Haykin (2001)

A saída y_k do neurônio pode ser expressa em função das entradas x_k pela Equação A.1:

$$y_k = \varphi \left(b_k + \sum_{j=1}^m w_{kj} \cdot x_j \right) \quad (\text{A.1})$$

sendo:

φ = operador da função de ativação;

k = índice do neurônio;

j = índice da sinapse;

w = peso sináptico;

b = bias;

m = número de sinapses.

A função de ativação pode ter diferentes formas, sendo as mais usuais apresentadas na Figura A.3. Além dessas funções, existem também funções que restringem a saída ao intervalo que inclui valores negativos, $[-1,1]$.

Nessa Tese, foi utilizada a função denominada Sigmóide (em forma de S), que pode ser representada pela Equação A.2:

$$\varphi(v) = \frac{1}{1 + e^{-a \cdot v}} \quad (\text{A.2})$$

na qual:

v = saída do somador (também denominado campo local induzido);

a = inclinação da curva.




Figura A.3 – Exemplos de funções de ativação

Fonte: Elaborado pelo autor

A.1.2 Estruturas de RNAs

De modo geral, existem três estruturas distintas relacionadas à forma como os neurônios estão organizados em uma RNA:

- **Redes alimentadas adiante com camada única:** nas quais existe apenas uma camada de neurônios onde ocorre processamento (Figura A.4.a); o termo “adiante” se refere ao fato da entrada se propagar para frente, através da rede.
- **Redes alimentadas adiante com múltiplas camadas:** nas quais existem camadas de neurônios ocultas (Figura A.4.b);
- **Redes recorrentes:** nas quais existe pelo menos um laço de realimentação, caracterizado pelo retorno da informação de saída de um neurônio para camadas anteriores da rede que influenciam em sua entrada (Figura A.4.c). O operador do ramo de realimentação é representado por z^{-1} , e consiste na aplicação de um atraso temporal unitário em sua saída em relação à sua entrada.

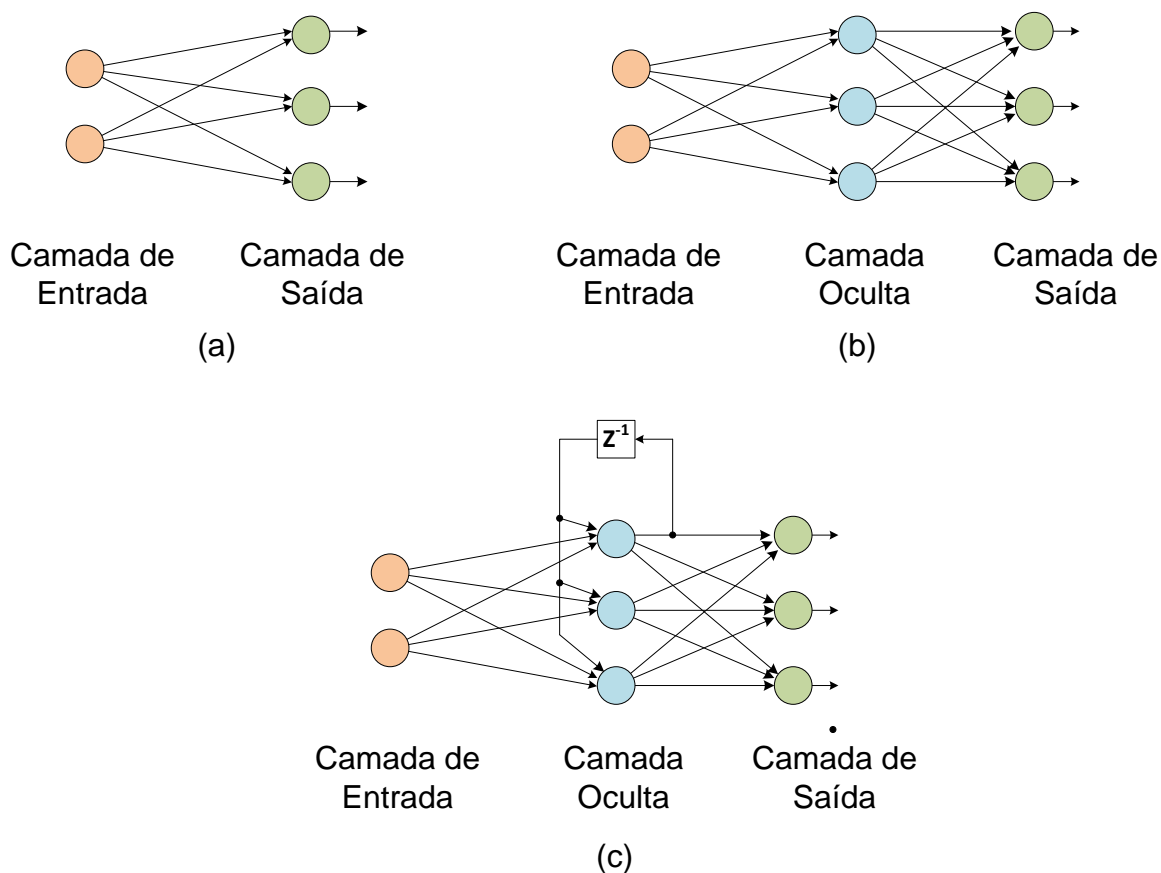


Figura A.4 – Exemplos de estruturas de RNAs.

Fonte: Elaborado pelo autor

Quando todos os neurônios de camadas consecutivas da RNA estão conectados entre si através de sinapses, a rede é dita *totalmente conectada*; caso contrário, a rede é dita *parcialmente conectada*.

A.1.3 Aprendizagem das RNAs

O conceito de aprendizagem de uma RNA está relacionado com mecanismos de adaptação de seus parâmetros através de estímulos provenientes do ambiente no qual a rede está inserida (HAYKIN, 2011). Em termos de aprendizagem, as RNAs podem ser divididas basicamente em duas classes: Redes Não-Supervisionadas e Redes Supervisionadas.

As RNAs Não-Supervisionadas obtêm seu aprendizado a partir somente dos dados de entrada e descobrindo, estaticamente, padrões relevantes destes dados. Neste treinamento, não há a associação entre os dados de entrada com os valores desejados de saída e, dessa forma, o sistema desenvolve seu próprio aprendizado (PEREIRA, 2013). A Figura A.5 ilustra o conceito de uma RNA com aprendizado Não-Supervisionado.

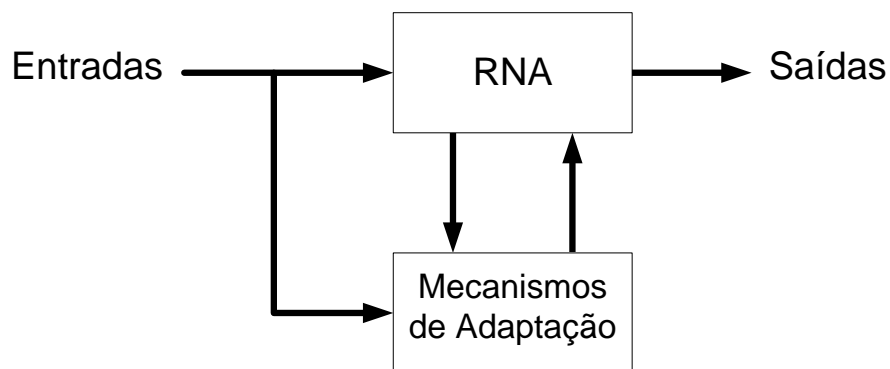


Figura A.5 – Estrutura de Aprendizado Não-Supervisionado.
Fonte: Adaptado de Altran (2005)

Nas RNAs Supervisionadas, existe uma associação entre os dados de entrada com valores almejados na saída, que podem ser, por exemplo, dados reais de um sistema e que serão utilizados como referência no treinamento da rede. Sempre que houver divergência entre a saída da RNA e a saída desejada, os valores dos pesos sinápticos da rede são ajustados, até que o erro entre a saída e a

referência atinja um valor aceitável (PASQUOTTO, 2010). Esse processo de aprendizagem é denominado *aprendizagem por correção de erro*, e essa estrutura emprega o paradigma conhecido como aprendizagem com professor.

Na Figura A.6 está ilustrado o conceito de aprendizado supervisionado. O bloco “Professor” recebe os mesmos dados de estímulo do ambiente que a rede, porém, ele detém o conhecimento prévio sobre o ambiente, a partir de exemplos. Dessa forma, para um determinado conjunto de entradas, o professor é capaz de produzir uma saída desejada, ou referência, que é comparada com a saída produzida pela RNA e utilizada para produzir o sinal de erro, que por fim é utilizado para ajustar os parâmetros da rede.

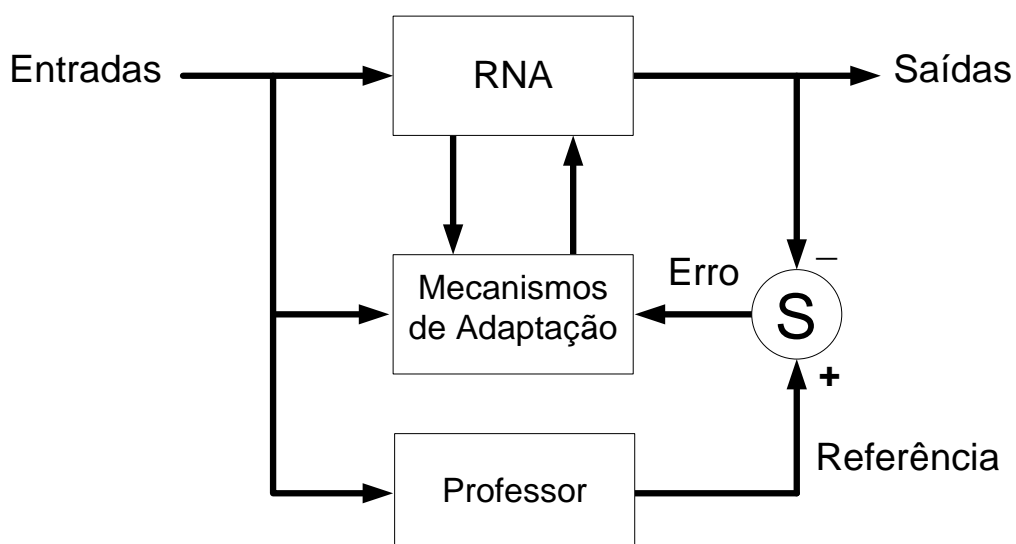


Figura A.6 – Estrutura de Aprendizado Supervisionado.
Fonte: Adaptado de Altran (2005)

As redes supervisionadas são as mais comumente utilizadas por permitirem um controle maior de sua resposta através da interpretação e atuação sobre o erro apresentado pela RNA. Elas foram originalmente propostas por Rosenblatt (1958), que introduziu o conceito do *perceptron*, que será abordado a seguir.

A.1.4 Redes *Perceptrons* de Múltiplas Camadas

Um *perceptron* consiste em um neurônio que computa uma única saída a partir de uma combinação linear de múltiplas entradas com pesos sinápticos ajustáveis e um valor de bias. Ele é considerado a forma mais simples de neurônio,

e segue o modelo apresentado previamente na Figura A.2. Tipicamente, ele é utilizado para classificação de padrões.

As redes Perceptrons de Múltiplas Camadas (MLP – *Multilayer Perceptron*) são redes com pelo menos uma camada oculta e uma camada de saída de nós computacionais, alimentadas adiante, cujo treinamento se dá de forma supervisionada.

O algoritmo de aprendizagem mais conhecido para esse tipo de rede é o Algoritmo de Retropropagação de Erro (*error back-propagation*), que emprega a regra de aprendizagem por correção de erro.

A.1.4.1 Algoritmo de Retropropagação de Erro

De modo resumido, o algoritmo de retropropagação de erro consiste no ajuste dos pesos sinápticos da rede em função de um sinal de erro, e pode ser representado pelo conjunto formado pelas Equações A.3 a A.6:

Erro $e_j(n)$: Diferença entre o valor da saída real ($y_j(n)$) de um neurônio e o valor esperado ($d_j(n)$), ou de referência. O índice j , nesse caso, denota um neurônio de saída e “ n ” indica uma iteração que representa o n -ésimo padrão de treinamento, ou exemplo, apresentado à rede.

$$e_j(n) = d_j(n) - y_j(n) \quad (\text{A.3})$$

Ajuste do peso sináptico: Alteração feita ao peso sináptico de uma conexão, que consiste na soma do peso atual ($w_{ji}(n)$) a um valor de correção ($\Delta w_{ji}(n)$). O índice ji indica a ligação do neurônio da camada j a um neurônio da camada i , à sua esquerda.

$$w_{ji}(n + 1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (\text{A.4})$$

Correção $\Delta w_{ji}(n)$: também referida como regra delta, dada por:

$$\Delta w_{ji}(n) = \eta \cdot \delta_j(n) \cdot y_j(n) \quad (\text{A.5})$$

Sendo η definida como a taxa de aprendizagem do algoritmo, que implica em o quanto maior ou menor será a variação do peso sináptico de uma iteração para outra, e $\delta_j(n)$ definido como o gradiente local, que aponta para as modificações necessárias no peso sináptico, em função do erro.

Gradiente local $\delta_j(n)$: é o produto entre o erro $e_j(n)$ e a derivada da função de ativação $\varphi(v_n)$, definida anteriormente.

$$\delta_j(n) = e_j(n) \cdot \varphi'_j(v_j(n)) \quad (\text{A.6})$$

O treinamento utilizando retropropagação consiste em dois passos básicos:

1. Passo adiante (propagação): Um padrão é apresentado às unidades da camada de entrada e, a partir desta camada, as unidades de processamento calculam a resposta que é produzida na camada de saída; a partir dessa resposta, o erro é calculado.
2. Passo atrás (retropropagação): O erro é propagado de volta a partir da camada de saída até a camada de entrada; nas unidades das camadas internas os pesos das conexões vão sendo modificados utilizando a regra delta.

Uma apresentação completa do conjunto de treinamento que está sendo processado, no qual os pesos são processados padrão por padrão, é denominada *época*.

A Figura A.7 ilustra um exemplo de RNA *Perceptron* com duas camadas de processamento ((1) e (2), cujos parâmetros estão em cores diferentes), e que contém dois neurônios em cada camada. A RNA está representada através de um gráfico de fluxo de sinal.

Na parte superior da figura, ocorre o primeiro passo do algoritmo, no qual as setas de fluxo apontam da entrada para a saída. Na parte inferior, as setas estão em sentido contrário, indicando o segundo passo do algoritmo (retropropagação). (HAYKIN, 2001, pg. 202).




Figura A.7 – Gráfico de Fluxo de Sinal de uma MLP com retropropagação de erro.

Fonte: Elaborado pelo autor.

A.1.4.2 Validação Cruzada

Conforme visto na seção anterior, a aprendizagem por retropropagação está fortemente relacionada com a aproximação da saída real da RNA a um valor esperado. Dessa forma, é necessário haver um conjunto de dados de exemplo, a partir do qual será codificado o mapeamento das entradas e saídas nos pesos sinápticos do *perceptron*. A validação do modelo deve ser feita com o conjunto de dados restantes (Figura A.8), sendo que esse tipo de validação é normalmente conhecido como *validação direta*, na qual não existe nenhuma manipulação dos dados.




Figura A.8 – Divisão do conjunto de dados para validação do modelo da RNA.

Fonte: Elaborado pelo autor.

A validação cruzada (*cross-validation*) é uma das ferramentas mais conhecidas para validar um modelo com um conjunto de dados diferente do que foi usado para o treinamento da rede. Segundo (FIGUEIREDO, R. M. ; SANTOS, J. V. C.; CECHIN, A. L., 2009) este método consiste na divisão do conjunto de dados disponíveis em grupos e no cruzamento desses grupos para formar um conjunto de treinamento e outro para validação. Entre as técnicas mais utilizadas que empregam esse conceito destaca-se a *Validação Cruzada K-fold*.

Na Validação Cruzada *K-fold*, o conjunto total de dados é dividido em K subconjuntos cruzados de mesmo tamanho, sendo que desses, " $K - 1$ " são utilizados para treinamento da rede, e o subconjunto restante é usado para validação. O processo é repetido K vezes, alternando-se o subgrupo de validação, até que todos os subgrupos tenham sido utilizados para essa finalidade. A Figura A.9 ilustra o conceito dessa validação, para $K = 3$. O valor usual de K em aplicações de RNAs é 10.

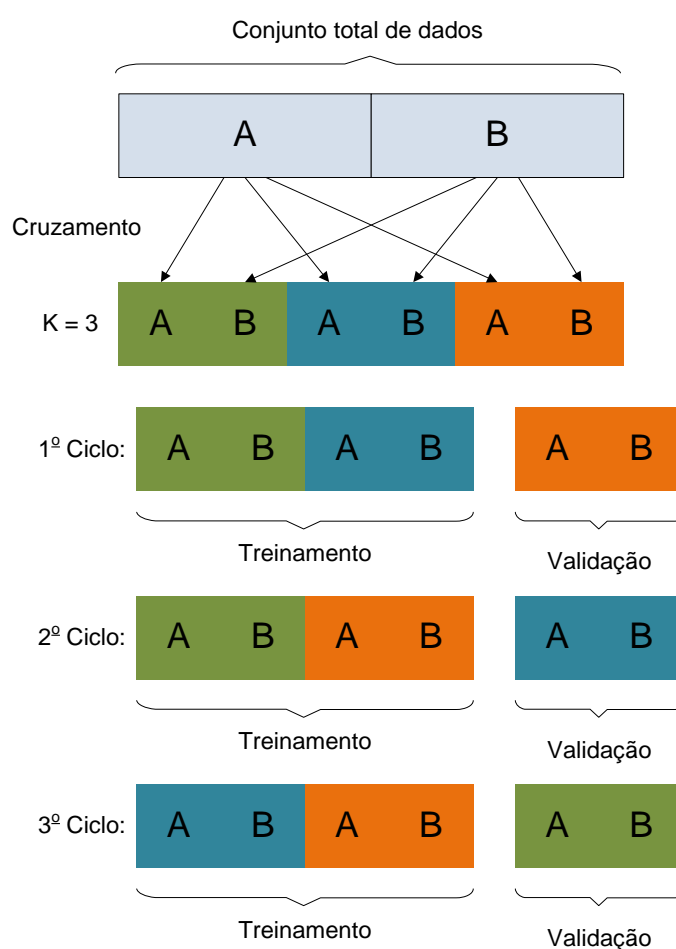


Figura A.9 – Técnica de Validação Cruzada *K-fold*

Fonte: Elaborado pelo autor

A.2 Avaliação de desempenho

Uma vez determinados os modelos que serão empregados para atender aos objetivos do projeto – Redes Neurais Artificiais ou outro método – é necessário fazer uma avaliação do seu desempenho, a fim de verificar o quanto sua resposta se aproxima dos valores esperados. Algumas ferramentas estatísticas ou gráficas podem ser utilizadas para essa finalidade. A Análise Estatística onde, obtém-se uma avaliação quantitativa quantificando-se o erro do previsor, método utilizado no modelo e detalhado na Tese. Existe o método de Análise Gráfica onde obtém-se uma análise qualitativa, na qual visualmente se verifica a aderência dos resultados conforme segue.

A.2.1 Análise Gráfica

Para uma análise qualitativa do desempenho de um modelo, as ferramentas mais simples são a Correlação Gráfica e a Sobreposição de Curvas.

A Correlação Gráfica consiste em correlacionar os dados de saída produzidos pelo modelo com os dados reais esperados, utilizando eixos diferentes do mesmo gráfico. A aderência perfeita consiste em obter os pontos dos dados estimados sobre a reta diretriz, que representa o lugar geométrico na qual as saídas estimadas são iguais às saídas esperadas. Quanto maior for a distância dos pontos estimados a essa reta, maior é o erro associado aos instantes de previsão daqueles pontos. A Figura A.10 ilustra um exemplo de Correlação Gráfica para um conjunto hipotético de dados.




Figura A.10 – Exemplo de análise por Correlação Gráfica

Fonte: Elaborado pelo autor

A Sobreposição de Curvas consiste no desenho simultâneo das séries de resultados produzidas pelo modelo e das séries de dados esperados, para cada resultado produzido, em um intervalo de tempo. Esse método oferece uma maneira simples e direta de visualizar a aderência dos resultados e o comportamento do modelo. A Figura A.11 mostra um exemplo de aplicação da Sobreposição de Curvas.




Figura A.11 – Exemplo de análise por Sobreposição de Curvas

Fonte: Elaborado pelo autor

APÊNDICE B – INFORMAÇÕES BASE PARA O SNA

Este conjunto de Informações será aplicado como pré-requisito e entrada do Sistema Neural Artificial – SNA.

As Informações estão divididas em obrigatórias (fundamentais para o funcionamento do SNA) e complementares (espera-se que estas respostas aumentem a precisão do SNA).

B.1 - Informações Obrigatórias:

O1. Localização da lavoura

Com a resposta desta pergunta, a ferramenta computacional fará um cruzamento de dados entre local e coordenadas geográficas. Com essa informação, encontram-se informações importantes para a RNAs como: tipo de solo e dados climatológicos das estações meteorológicas mais próximas da região da lavoura.

O2. Área da lavoura

Esta resposta é importante para as RNAs estabelecerem a relação de coerência entre o consumo real e o esperado para a área irrigada. Os dados de cadastros de cliente possuem as coordenadas geográficas do medidor de energia, possibilitando a conferência através de software de imagens da área da lavoura a ser verificada.

O.3 Carga instalada (kVA)

Esta informação consta de cadastro do cliente e também é importante para a relação de consumo real e previsto estabelecido pelo SNA.

B.2 - Informações Complementares:

C1. Nível de Automação

Neste questionamento busca-se encontrar um parâmetro lógico de consumo para a rede neural. Neste item apresenta-se uma relação de opções com 4 níveis possíveis para seleção:

- Automação inexistente;

- Automação baixa (Ex: sistema programado de ligar/desligar bombas);
- Automação média (Ex: programação de ligar/desligar bombas baseado em sistema de monitoramento de nível com poucos sensores);
- Automação alta (controle completo de bombeamento, medições de lâmina d'água em diversos pontos, utilização de inversores de frequência, etc.).

C2. Características do Levante (Altura)

- Natural (irrigação por gravidade).
- Baixa (0 – 5 metros);
- Média (6 – 10 Metros);
- Alta (11 – 50 Metros).

C3. Característica de nivelamento do solo

- Sistematização:

- Sistematização do solo em nível;
- Sistematização do solo em desnível.

- Declividade Média:

- Pequena (0 – 3%);
- Média (3 – 6%);
- Grande (Acima de 10%).

C4. Método de irrigação da lavoura

- Regime de solo saturado;
- Regime contínuo com lâmina d'água constante;
- Regime intermitente de irrigação, com variação da lâmina d'água.

APÊNDICE C – REDE NEURAL ARTIFICIAL DESENVOLVIDA EM PYTHON®

Nesse Apêndice é apresentado o código de treinamento e validação da Rede Neural Artificial proposta nessa Tese. O código foi desenvolvido em Linguagem de Programação Python® e está apresentado na Figura Apêndice C-1.

```
Python 2.7.8: teste (4).py - C:\Users\MAICON\Downloads\teste (4).py
File Edit Format Run Options Windows Help
# Chamada das bibliotecas
import numpy as np
import neurolab as nl
import misc
import ann_handling as ah
import ann_plot as ap
import ann_error_measure as em

# Leitura do arquivo para as variáveis
carga, precip, insol, evap, temp, umidade, cargaprev = misc.read_data("c:/trafo.txt")

# Normalização das variáveis de 0 a 1
carga_n = misc.normalize(carga, 1, 0)
precip_n = misc.normalize(precip, 1, 0)
insol_n = misc.normalize(insol, 1, 0)
evap_n = misc.normalize(evap, 1, 0)
temp_n = misc.normalize(temp, 1, 0)
umidade_n = misc.normalize(umidade, 1, 0)
cargaprev_n = misc.normalize(cargaprev, 1, 0)

# Configuração dos dados para leitura da RNA
carga_in = misc.conv_list2array(carga_n)
precip_in = misc.conv_list2array(precip_n)
insol_in = misc.conv_list2array(insol_n)
evap_in = misc.conv_list2array(evap_n)
temp_in = misc.conv_list2array(temp_n)
umidade_in = misc.conv_list2array(umidade_n)
cargaprev_in = misc.conv_list2array(cargaprev_n)

in_data = misc.matrix_concat(carga_in,precip_in,insol_in,evap_in,temp_in,umidade_in)
t_data = cargaprev_in

# Separação dos dados para treinamento
data_in = in_data[0:200] # Dados de entrada da RNA
data_t = t_data[0:200] # Dados alvo da RNA

# Separação dos dados para validação
data_test = in_data[201:len(in_data)] # Dados de entrada da RNA
data_val = t_data[201:len(t_data)] # Dados alvos da RNA

# Criação da RNA
```

(Continua)

(Conclusão)

```
ann = nl.net.newff([[0,1],[0,1],[0,1],[0,1],[0,1],[0,1]], [16, 1])

# Treinamento da RNA
err = ann.train(data_in, data_t, epochs=10000, show=100, goal=0.02)

# Simulação (Validação) da RNA
res = ah.ann_sim(ann,data_test)

# Cálculo do RMSE da RNA (verificação quantitativa)
print("RMSE: ")
print(em.rmse(res, data_val))

# Plot do gráfico da resposta da RNA (verificação qualitativa)
ap.plot_data(data_val, res, "", "")
```

Figura C-1 - Código de programação da RNA

Fonte: Desenvolvedor

APÊNDICE D – RESULTADOS DE CORRELAÇÃO ENTRE CONSUMO DE ENERGIA E VARIÁVEIS CLIMÁTICAS

Nesse Apêndice são apresentados os resultados extraídos do programa Minitab®, para a correlação entre as variáveis de entrada da pesquisa, da Unidade Consumidora 1 (UC-1). Os dados estão apresentados no formato disponibilizado pelo programa, sendo que em cada linha de variável se observa o Coeficiente de Correlação de Pearson e o Valor p .

UC-1 Safra 2009/2010

Welcome to Minitab, press F1 for help.

Retrieving project from file: 'D:\MAICON\1UFSM\DROPBOX\TESE\TESTES
MINITAB\TESTE 1.MPJ'

Results for: Worksheet 4

Correlations: Cosumo real ; Precipitacao; Insolacao; Evaporacao P; ...

	Cosumo real (kWh)	Precipitacao (mm)	Insolacao
Precipitacao (mm)	0,063 0,381		
Insolacao	0,077 0,286	-0,386 0,000	
Evaporacao Piche	-0,060 0,402	-0,357 0,000	0,276 0,000
Temp Media	0,026 0,720	-0,325 0,000	0,247 0,000
Umidade Relativa	-0,036 0,617	0,344 0,000	-0,780 0,000

	Evaporacao Piche	Temp Media	Umidade Relativa
Temp Media	0,405 0,000		
Umidade Relativa	-0,365 0,000	-0,179 0,012	

Cell Contents: Pearson correlation
P-Value

* NOTE * All values in column are identical.

UC-1 Safra 2010/2011

Precipitacao	Consumo Real	Precipitacao	Insolacao
	-0,037		
	0,607		
Insolacao	0,092	-0,291	
	0,196	0,000	
Evaporacao Piche	0,142	-0,254	0,254
	0,045	0,000	0,000
Temp Media	0,003	-0,022	0,186
	0,970	0,755	0,009
Umidade Relativa	-0,112	0,322	-0,722
	0,115	0,000	0,000
Temp Media	Evaporacao Piche	Temp Media	Umidade Relativa
	0,199		
	0,005		
Umidade Relativa	-0,337	0,076	
	0,000	0,289	

UC-1 Safra 2011/2012

Precipitacao	Consumo Real	Precipitacao	Insolacao
	-0,147		
	0,155		
Insolacao	0,072	-0,283	
	0,491	0,006	
Evaporacao Piche	0,101	-0,485	0,129
	0,331	0,000	0,213
Temp Media	0,059	-0,202	0,203
	0,573	0,050	0,049
Umidade Relativa	-0,155	0,365	-0,706
	0,133	0,000	0,000
Temp Media	Evaporacao Piche	Temp Media	Umidade Relativa
	0,369		
	0,000		
Umidade Relativa	-0,189	-0,084	
	0,067	0,418	

UC-1 Safra 2012/2013

Precipitacao	Consumo Real	Precipitacao	Insolacao
	-0,122		
	0,161		
Insolacao	0,136	-0,291	
	0,117	0,001	
Evaporacao Piche	0,123	-0,280	0,331
	0,158	0,001	0,000
Temp Media	0,092	-0,197	0,351
	0,288	0,022	0,000
Umidade Relativa	-0,101	0,385	-0,800
	0,244	0,000	0,000
	Evaporacao Piche	Temp Media	Umidade Relativa
Temp Media	0,482		
	0,000		
Umidade Relativa	-0,515	-0,413	
	0,000	0,000	

UC-1 Safra 2013/2014

Precipitacao	Consumo Real	Precipitacao	Insolacao
	-0,155		
	0,119		
Insolacao	0,247	-0,256	
	0,012	0,009	
Evaporacao Piche	0,355	-0,304	0,179
	0,000	0,002	0,070
Temp Media	0,383	-0,238	0,287
	0,000	0,015	0,003
Umidade Relativa	-0,371	0,242	-0,740
	0,000	0,014	0,000
	Evaporacao Piche	Temp Media	Umidade Relativa
Temp Media	0,463		
	0,000		
Umidade Relativa	-0,470	-0,484	
	0,000	0,000	

APÊNDICE E – CÓDIGO PARA ANÁLISE DE REGRESSÃO *STEPWISE* E RESULTADOS PARA UC-3

Nesse Apêndice são apresentados o código de programação para implementação da metodologia de Regressão Stepwise no Matlab, e os resultados obtidos a partir da análise da lavoura da unidade consumidora UC-3.

O Quadro E.1 apresenta o código utilizado para a análise da UC-3, Safra 2013/2014.

Regressão Stepwise – UC3 – Safra 2013/2014

Parte 1 - Calculo dos parâmetros para determinar o indicador de consumo

```
% Autor:
% Prof. Rodrigo Iván Goytia Mejía
% rmejia@unisininos.br
% All rights reserved, 2014
%
% Observations:
% . Sample developed for Maicon Evaldt
% . Using the code do not forget to cite the author.
% -----

clear all
close all
clc

% 1. Carregando os dados
%-----

% 1.1. Definindo o caminho dos arquivos em EXCEL que contem os dados
%-----
pathfile = 'C:\09_ACADEMIC\Organizar\Projetos Pesquisa\Docs Stepwise
Regression\Projeto Maicon\02_Calculo
Indicador\Cliente_3_UC20399\Cliente_3_UC20399.xls';

% 1.2. Fazendo a leitura dos dados da matriz de dados X
%-----
pagina      = 'Safra_2013_2014';
range       = strcat('E',num2str(2),':','I',num2str(103));
[Xvars aux] = xlsread(pathfile,pagina,range);

% 1.2. Fazendo a leitura dos dados do vetor de dados Y
%-----
pagina      = 'Safra_2013_2014';
range       = strcat('D',num2str(2),':','D',num2str(103));
```

(Continua)

(Continuação)

```
[Yopts aux] = xlsread(pathfile,pagina,range);

save('XY_Safra_2013_2014', 'Xvars', 'Yopts')

% 2. Normalização Z-score
%-----
Xvars = [Xvars Xvars.^2];

filcol = size(Xvars);
fil = filcol(1);
Xnormal = (Xvars-repmat(mean(Xvars),fil,1))./repmat(std(Xvars),fil,1);
Xnormal(isnan(Xnormal))=0;

Yoptnor = (Yopts-mean(Yopts))/std(Yopts);

% 3. Calculando os parametros do modelo utilizando StepWise Regression
%-----

var(1) = 1; % Precipitacao
var(2) = 1; % Evaporacao Piche
var(3) = 1; % Temp Comp Media
var(4) = 1; % Umidade Relativa Media
var(5) = 1; % Area Plantada
var(6) = 0; % Carga Instalada
var(7) = 0; %
var(8) = 1; %
var(9) = 1; %
var(10) = 1; %
% var(11) = 1; %
% var(12) = 1; %
% var(13) = 0; %
% var(14) = 0; %

initvar = find(var==1);

stepwise(Xnormal,Yoptnor, initvar)

% Logo de determinar os Xi que formarão parte do modelo, exportar os
% coeficientes e Intercept e modificar o arquivo IConsumo.m logo é só
% validar os resultados com o arquivo teste_IConsumoTE.
```

Parte 2 - Determina indicador

```
Intercept = 2.56631e-16;

beta = [
    -0.74458
         0
    0.57858
         0
         0
    0.6385
         0
         0
         0];
% beta = [
%         0
%         0
%    -38849.1184075767
%    178164.311643218
%    -55683.160567067
%         0
%         0
```

(Continua)

(Continuação)

```

%      -9256.12362990054
%      60433.0532804545
%      22038.639223978
%      -45109.0120245811
%
%      0
%      0
%      0];
b0      = Intercept;
b(1)    = beta(1);
b(2)    = beta(2);
b(3)    = beta(3);
b(4)    = beta(4);
b(5)    = beta(5);
b(6)    = beta(6);
b(7)    = beta(7);
b(8)    = beta(8);
b(9)    = beta(9);
b(10)   = beta(10);
% b(11) = beta(11);
% b(12) = beta(12);
% b(13) = beta(13);
% b(14) = beta(14);
Idxval = b0+span+b(1)*X(1)...
         +b(2)*X(2)...
         +b(3)*X(3)...
         +b(4)*X(4)...
         +b(5)*X(5)...
         +b(6)*X(6)...
         +b(7)*X(7)...
         +b(8)*X(8)...
         +b(9)*X(9)...
         +b(10)*X(10);
%
%      +b(11)*X(11)...
%      +b(10)*X(12)...
%      +b(11)*X(13)...
%      +b(12)*X(14);

End

```

Parte 3 – Validação do indicador de consumo

```

clear all
close all
clc
% 1. Determinando os parametros de entrada
% -----
load XY_Safra_2013_2014
% load XY_Safra_2012_2013
% load XY_Safra_2011_2012
% load XY_Safra_2010_2011
tag      = 50;           % Variável a ser analisada
span     = 0;           % Parametro de ajuste pelo operador

% Isto é so para testar se o modelo é adequado (A seguinte linha tem que ser
eliminada)

% 2. Normalização Z-score
% -----
Xvars = [Xvars Xvars.^2];
filcol = size(Xvars);
fil    = filcol(1);

```

(Continua)

(Continuação)

```

Xnormal = (Xvars-repmat(mean(Xvars),fil,1))./repmat(std(Xvars),fil,1);
Xnormal(isnan(Xnormal))=0;

% X = [Xvars(tag,:) Xvars(tag,).^2]; % <--- Isto é usando dados com os que foi
gerado o modelo

% Aqui tem que ser inserido os valores dos dados medidos para validação
% X(1) = 0; % Precipitacao
% X(2) = 2.3; % Evaporacao Piche
% X(3) = 11.06; % Temp Comp Media
% X(4) = 75.25; % Umidade Relativa Media
% X(5) = 140; % Area Plantada
% X(6) = 220; % Carga Instalada
% X(7) = 0; %
% X(8) = 5.29; %
% X(9) = 122.3236; %
% X(10) = 5662.5625; %
% X(11) = 19600; %
% X(12) = 48400; %

% 2. Cálculo do indicador consolidado
% -----
Idxval = IConsumo_Cliente_3_UC20399_Safra_2013_2014(Xnormal,span);

for k=1:length(Xvars)
    Index(k) = IConsumo_Cliente_3_UC20399_Safra_2013_2014(Xnormal(k,:),span);
end

Idxval = Index(tag);

% 3. Impressao dos resultados
% -----
disp('-----')
disp(' Cálculo do indicador consolidado de consumo')
disp('-----')

% Normalizando os valores
% -----
filcol = size(Xvars);
fil = filcol(1);
Xn = (Xvars-repmat(mean(Xvars),fil,1))./repmat(std(Xvars),fil,1);
Xn(isnan(Xn))=0;

Yn = (Yopts-mean(Yopts))./std(Yopts);
figure (1)
t = (1:length(Xvars))';
plot(t,Xn(:,1),'k','linewidth',1), hold on
plot(t,Xn(:,2),'-k','linewidth',1), hold on
plot(t,Xn(:,3),'--k','linewidth',2), hold on
plot(t,Xn(:,4),'-k','linewidth',1), hold on
plot(t,Xn(:,5),':k','linewidth',1), hold on
% plot(t,Xn(:,6),'b','linewidth',1), hold on
% plot(t,Xn(:,7),'--b','linewidth',1), hold on
plot(t,Yn,'r','linewidth',2)
legend('Precipitacao (mm)','Insolacao','Evaporacao Piche','Temp Media','Umidade
Relativa Media','Área (há)','Carga Instalada (kw)')

figure (2)
subplot(7,1,1), plot(t,Yn,'k','linewidth',2), title('Consumo (kwh)')
subplot(7,1,1), plot(t,Xn(:,1),'k','linewidth',2), title('Precipitacao (mm)')
subplot(7,1,2), plot(t,Xn(:,2),'k','linewidth',2), title('Insolacao')
subplot(7,1,3), plot(t,Xn(:,3),'k','linewidth',2), title('Evaporacao Piche')
subplot(7,1,4), plot(t,Xn(:,4),'k','linewidth',2), title('Temp Comp Media')
subplot(7,1,5), plot(t,Xn(:,5),'k','linewidth',2), title('Umidade Relativa Media')

```

(Continua)

(Conclusão)

```

% subplot(7,1,6), plot(t,Xn(:,6),'k','linewidth',2), title('Area Plantada (há)')

% subplot(7,1,7), plot(t,Xn(:,7),'k','linewidth',2), title('Carga Instalada (kw)')
xlabel('Tempo, dias')

figure (3)
plot(Yn,'Color',[0.7294 0.8314 0.9569]), ylabel('IConsumo'), hold on
plot(tag,Yn(tag),'ko','linewidth',1)
plot(tag,Idxval,'ro','linewidth',1)
legend('Yopt', 'Yopts(tag)', 'Idxval')

figure (4)
plot(Yn,'k'), ylabel('IConsumo'), hold on
plot(Index,'r')
legend('Yopt', 'Index')

end

```

Quadro E.1 – Código Matlab utilizado para análise de Regressão *Stepwise*
 Fonte: Desenvolvedor

As Figuras E.1 a E.10 apresentam os resultados obtidos para a análise de Regressão *Stepwise* dos dados das cinco safras da UC-3.

Nas figuras da interface gráfica (E.1, E.3, E.5, E.7 e E.9), no canto superior esquerdo apresentam-se as estimativas dos coeficientes de todos os termos potenciais, com barras horizontais, indicando os intervalos de confiança. A cor vermelha indica que, inicialmente, os termos não estão no modelo. Os valores mostrados na tabela ao lado do gráfico são os que resultariam se os termos fossem adicionados ao modelo.

As figuras E.2, E.4, E.6, E.8 e E.10 apresentam um comparativo do consumo real (*Yopt* - linha preta) com o consumo estimado (*Index* - linha vermelha). Observa-se que em todas as safras analisadas, há uma grande discrepância entre as duas curvas.

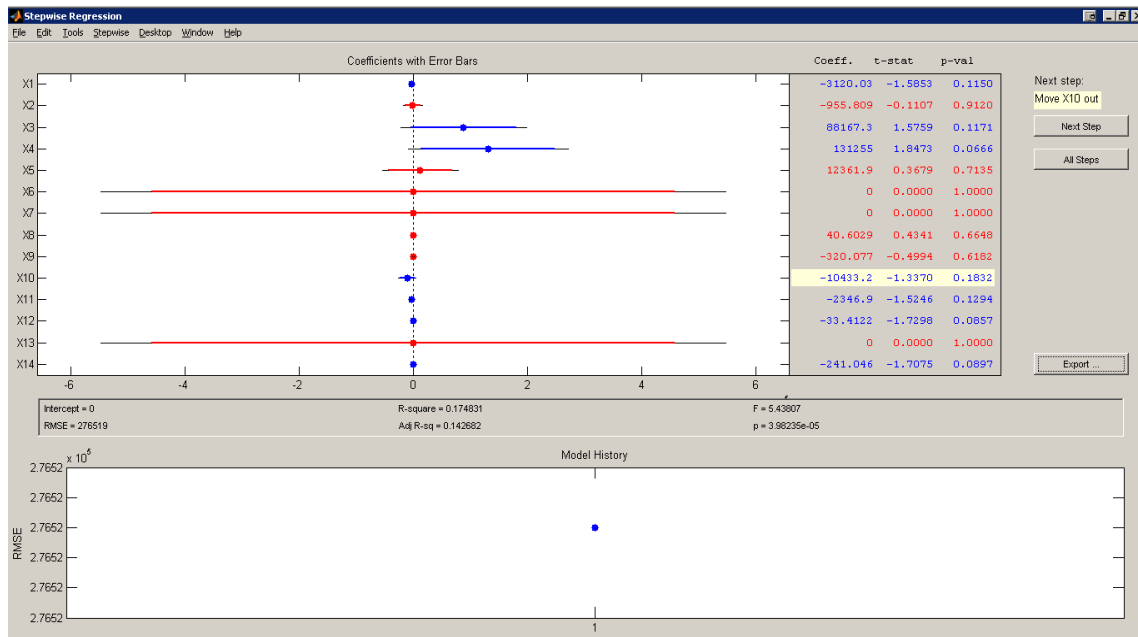


Figura E.1 – Interface gráfica da análise de Regressão *Stepwise*, UC-3, Safra 2009/2010.




Figura E.2 – Comparativo do consumo real (*Yopt*) com o consumo estimado (*Index*) por Regressão *Stepwise*, UC-3, Safra 2009/2010.

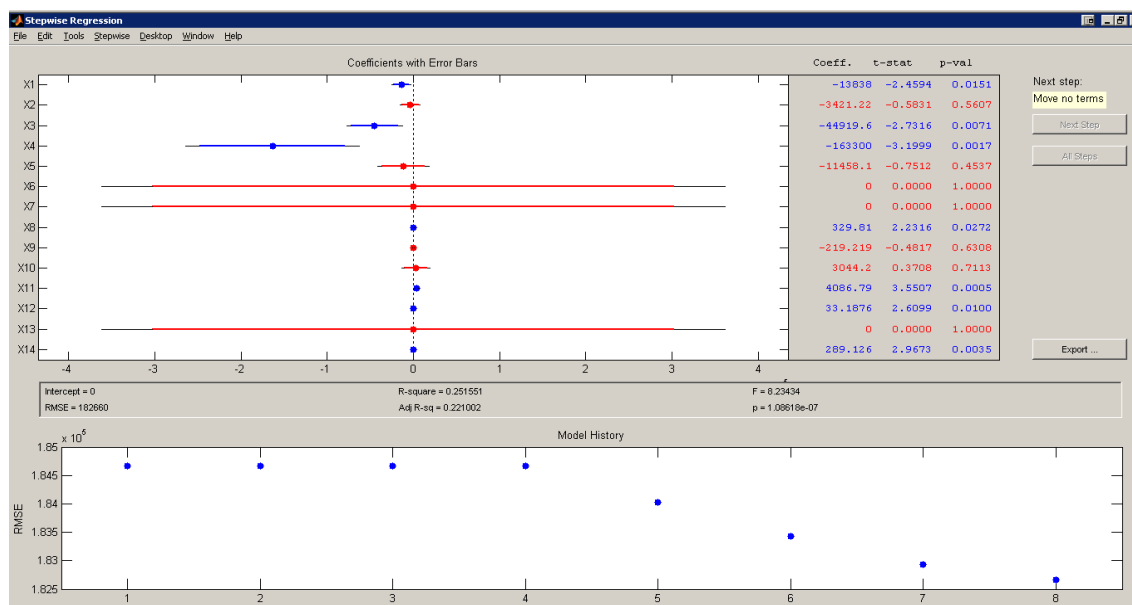


Figura E.3 – Interface gráfica da análise de Regressão *Stepwise*, UC-3, Safra 2010/2011.




Figura E.4 – Comparativo do consumo real (Y_{opt}) com o consumo estimado ($Index$) por Regressão *Stepwise*, UC-3, Safra 2010/2011.




Figura E.5 – Interface gráfica da análise de Regressão Stepwise, UC-3, Safra 2011/2012.




Figura E.6 – Comparativo do consumo real (Y_{opt}) com o consumo estimado ($Index$) por Regressão Stepwise, UC-3, Safra 2011/2012.

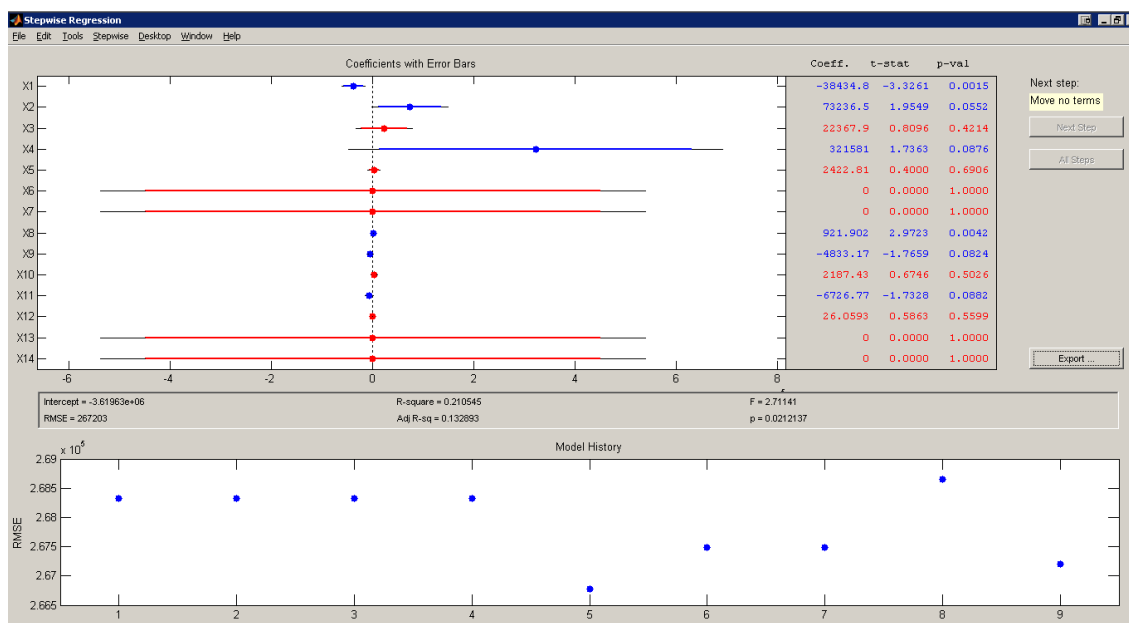


Figura E.7 – Interface gráfica da análise de Regressão *Stepwise*, UC-3, Safra 2012/2013.




Figura E.8 – Comparativo do consumo real (Y_{opt}) com o consumo estimado ($Index$) por Regressão *Stepwise*, UC-3, Safra 2012/2013.




Figura E.9 – Interface gráfica da análise de Regressão *Stepwise*, UC-3, Safra 2013/2014.




Figura E.10 – Comparativo do consumo real (Y_{opt}) com o consumo estimado ($Index$) por Regressão *Stepwise*, UC-3, Safra 2013/2014.

APÊNDICE F – FERRAMENTA DE VISUALIZAÇÃO DE ANÁLISE DE PERDAS DESENVOLVIDA EM VISUAL BASIC.

Neste Apêndice é apresentado um conjunto de telas que ilustra um supervisor possível de ser utilizado por uma concessionária de energia, por exemplo, com os alertas de possibilidade de Perdas Não Técnicas determinados pelo sistema proposto nesta Tese.

Na figura F.1 é apresentada uma visualização dos resultados da lavoura UC-1 safra 2009/2010 sem a simulação de Perdas Não Técnicas. Nas Figuras F.2 e F.3 apresenta-se uma simulação intencional de perdas não-técnicas na lavoura UC-2, para os níveis de alerta intermediário e crítico, respectivamente, para um período de 30 dias nas safras de 2010/2011 e 2012/2013.



Figura F.1 – Comparativo do consumo real com o consumo estimado UC-1, Safra 2009/2010.




Figura F.2 – Comparativo do consumo real com o consumo estimado (simulado) UC-2, Safra 2010/2011 para um período de 30 dias.




Figura F.3 – Comparativo do consumo real com o consumo estimado (simulado) UC-2, Safra 2012/2013 para um período de 30 dias.