

Sistema Neural Artificial para Identificação de Perdas Não Técnicas em Consumidores Rurais

Artificial Neural System to Identify Energy Losses in Rural Feeders

DOI:10.34115/basrv5n2-003

Recebimento dos originais: 12/02/2021

Aceitação para publicação: 12/03/2021

Maicon Coelho Evaldt

Mestre em Engenharia Elétrica
Universidade Federal Santa Maria
Av. Roraima, 1000, Santa Maria, RS
E-mail: mcevaldt@gmail.com

Alzenira da Rosa Abaide

Doutora em Engenharia Elétrica
Universidade Federal Santa Maria
Av. Roraima, 1000, Santa Maria, RS
E-mail: alzenira@ufsfm.com

Luciano Lopes Pfitscher

Doutora em Engenharia Elétrica
Universidade Federal de Santa Catarina
Campus Universitário Reitor João David Ferreira Lima, s/n°, Florianópolis - SC
E-mail: luciano.pfitscher@ufsc.com

Vinícius André Uberti

Doutorando em Engenharia Elétrica
Universidade Federal Santa Maria
Av. Roraima, 1000, Santa Maria, RS
E-mail: vuberti@gmail.com

Lúcio Rene Prade

Doutorando em Engenharia Elétrica
Universidade Federal Santa Maria
Av. Roraima, 1000, Santa Maria, RS
E-mail: luciorp@gmail.com

Rodrigo Marques de Figueiredo

Doutor em Geologia – Sensoriamento Remoto
Universidade do Vale do Rio dos Sinos
Av. Unisinos, 950, São Leopoldo - RS
E-mail: marquesf@unisinos.br

Daniel Pinheiro Bernardon

Doutor em Engenharia Elétrica
Universidade Federal Santa Maria
Av. Roraima, 1000, Santa Maria, RS

E-mail: vuberti@gmail.com

Felipe Arnhold

Engenheiro da Computação
Universidade do Vale do Rio dos Sinos
Av. Unisinos, 950, São Leopoldo - RS
E-mail: felipe_arnhold@edu.unisinos.br

RESUMO

Perdas não técnicas possuem um impacto significativo em redes de distribuição de energia e elas estão entre as principais preocupações dos agentes envolvidos nos sistemas de energia. Em redes de distribuição rural, particularmente, consumidores com lavouras com sistemas de irrigação caracterizam difícil detecção de perdas não técnicas, considerando os diferentes modos de irrigação, processos, características climáticas, além da dificuldade da inspeção local. Este trabalho apresenta uma proposta para a identificação de perdas de energia não técnicas em consumidores rurais que possuam sistemas de bombeamento de irrigação para lavouras de arroz. A metodologia é baseada na correlação de padrões no consumo de energia elétrica, nas características da área irrigada e nas condições climáticas do período irrigado. A metodologia utiliza um sistema neural artificial composto por redes neurais artificiais e usa como entrada: precipitação, temperatura, incidência solar, umidade relativa do ar, carga instalada, área irrigada, tipo de solo, elevação do solo, nível de automação e modo de irrigação. Os resultados indicam, para cada consumidor, o risco percentual de perdas não técnicas. O sistema neural artificial permite a análise de qualquer lavoura de arroz irrigado do Brasil, independente das características da lavoura, solo ou ambiente. Os resultados deste trabalho foram obtidos e validados com dados reais de safras de lavouras de arroz do Rio Grande do Sul, obtidos entre 2009 e 2014.

Palavras-chave: Perdas Não Técnicas, Sistema Neural Artificial, Consumidores Rurais.

ABSTRACT

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 results indicate, for each analyzed consumer, a 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.

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

1 INTRODUÇÃO

As perdas de energia elétrica 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 (CHAUAN; RAJVANSHI, 2013).

O processo mais elementar para detecção de perdas não técnicas é a inspeção local, que apresenta alto custo com equipes de inspeção. O problema se agrava em áreas rurais, devido às grandes áreas e dificuldade de acesso. De acordo com o Instituto Riograndense do Arroz (IRGA; 2017), as áreas de lavoura de arroz estão inseridas nessas áreas com dificuldade de realizar fiscalizações, representando 3,1 % do território do Rio Grande do Sul, maior estado produtor de arroz irrigado. Diversos fatores influenciam diretamente no consumo de energia elétrica, entre eles, o método de irrigação, o nível de automação presente nas lavouras, além do nivelamento do terreno, altura do levante e tipo de solo (PFITSCHER, 2012; YANG, WEN, GAO, 2006).

Nesse contexto, este trabalho apresenta um sistema que auxilia na identificação de possíveis situações de perdas não técnicas em lavouras de arroz, baseado em históricos e padrões de consumo, e considerando características próprias das lavouras e registros climatológicos. O sistema é construído através de Redes Neurais Artificiais (RNAs) treinadas com dados reais de três lavouras de arroz com diferentes características de irrigação. O resultado 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 e do consumo de energia faturado, é definido um índice de possibilidade de ocorrência de perdas não técnicas na lavoura analisada.

2 TRABALHOS RELACIONADOS

Diversos métodos já foram desenvolvidos para a identificação de perdas não técnicas em sistemas de potência. Podem ser utilizados métodos matemáticos, através de regressão linear para se obter um modelo matemático dos roubos e fraudes ocorrentes, com o objetivo de identificar as principais variáveis que influenciam essas irregularidades

(MADRIGAL et al.; 2017). Esse trabalho identificou que redes subterrâneas contêm menor quantidade de fraudes, assim como em redes com melhores condições de instalação. Segundo Madrigal et al. (2015), as perdas não técnicas são estimadas usando técnicas estatísticas com o objetivo de obter um resultado mais preciso possível com o menor número de informações e cálculos. Utilizando o método de Malthus, Thomas, Pinto e Lima (2020) desenvolveram um modelo matemático para a análise do consumo de energia. Os autores obtiveram resultados satisfatórios, com valores próximos aos reais. Outro trabalho utiliza-se de macro medidores nos transformadores instalados para identificar as perdas não técnicas (GIRALDO et al.; 2015). Os dados obtidos nesses medidores são comparados com informações que a companhia de energia possui dos consumidores ligados ao transformador. Identificados os transformadores com perdas, é analisado o histórico dos consumidores procurando por diferenças abruptas nas faturas de energia.

O aprendizado de máquina é explorado nos trabalhos de Buzau et al. (2018) e Meira et al. (2017) onde são apresentadas as metodologias para detecção de perdas não técnicas. Os dados foram obtidos através de medidores inteligentes assim como informações de localidade, similaridade e infraestrutura. Os trabalhos apresentam comparações entre diferentes técnicas, identificando as que possuem melhores resultados. Ambos utilizam validação cruzada para seleção, treinamento e validação dos dados.

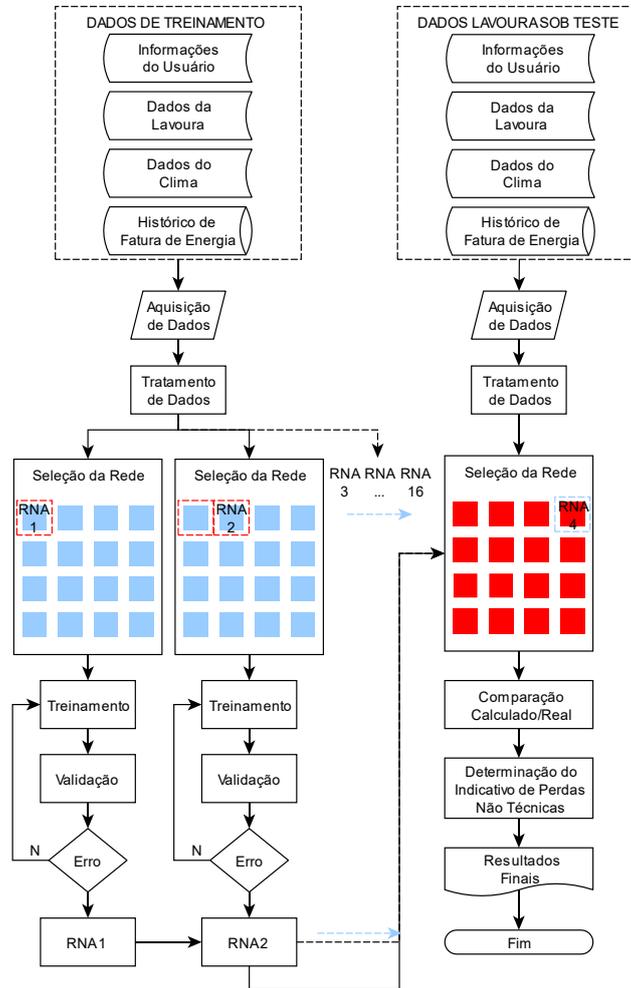
3 MATERIAIS E MÉTODOS

A metodologia proposta para identificação de perdas não técnicas em consumidores rurais segue o fluxograma geral apresentado na

Figura 1, empregando 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 possui um conjunto de 16 RNAs Perceptron de múltiplas camadas – RNA1 a RNA16 – que atuam individualmente, sendo sua seleção relacionada ao conjunto de informações básicas e complementares disponíveis sobre a lavoura. As RNAs 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.

O projeto foi desenvolvido em linguagem de programação Python®. Para construção das RNAs, foi utilizada a biblioteca específica para rede neurais, chamada PyBrain. As etapas da metodologia são explicadas a seguir.

Figura 1 – Fluxograma Geral da Metodologia Proposta



Fonte: Dos autores, 2020

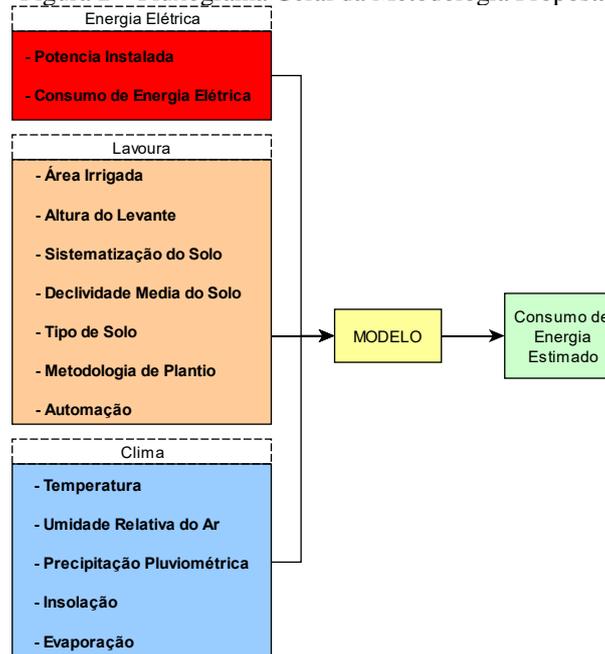
3.1 DADOS DE ENTRADA DO SISTEMA

A primeira etapa da metodologia consiste em adquirir um conjunto de dados de lavouras que contenham características distintas e estejam em regiões diferentes para realizar a modelagem do sistema.

As entradas são divididas em três grupos referente à natureza delas: Energia Elétrica, Lavoura e Clima, conforme ilustrado na Figura 2. As informações sobre Energia Elétrica englobam a instalação e consumo da energia elétrica pela lavoura. No grupo Lavoura, são apresentadas características gerais da lavoura, envolvendo o solo, plantio e nível de automação. E as informações do grupo Clima são referentes ao clima meteorológico.

Grande parte dos dados podem ser adquiridos sem a necessidade de visita à lavoura. A concessionária de energia elétrica possui a informação tanto da potência instalada quanto do histórico do consumo de energia elétrica faturada. Com a localização da lavoura, sabe-se a área através de um software de mapeamento por satélite, como o Google Earth, e sabe-se também o tipo de solo, através da ferramenta SOMA Brasil (INPE; 2020). Essa ferramenta é disponibilizada pela Embrapa, e dentre tantas informações disponíveis, está o tipo de solo existente em todo o país. Os dados climáticos são disponibilizados pelo Centro de Previsão de Tempo e Estudos Climáticos (CPTEC/INPE), com dados de mais de 500 estações meteorológicas espalhadas por todo o Brasil. Os únicos dados que devem ser inseridos pelo usuário são a altura do levante, a declividade do solo, a metodologia do plantio e o nível de automação. O usuário informa esses dados através de um questionário de múltipla escolha, contendo três alternativas: baixo, médio ou grande para altura, declividade e nível de automação; e solo saturado, contínuo com lâmina da água ou intermitente para método de irrigação.

Figura 2 – Fluxograma Geral da Metodologia Proposta



Fonte: Dos autores, 2020.

Foi definido que os dados utilizados são diários. Para informações que possuem intervalo de tempo menor, as medições devem ser integralizadas durante o dia, através de uma média.

A classificação das características entre baixo, médio e alto é realizada através de uma faixa de valores referente a cada dado, conforme a Tabela 1. O nível de automação

é considerado baixo quando existe apenas um sistema programado de liga/desliga. Médio para um sistema liga/desliga com monitoramento de nível e alto para quando se tem controle completo do bombeamento, incluindo medições em diversos pontos.

Tabela 1 – Fluxograma Geral da Metodologia Proposta

Informação Coletada	Baixo	Médio	Alto
Altura	0 a 5 metros	6 a 10 metros	11 a 50 metros
Declividade	0 a 3 %	3 a 10 %	Acima de 10 %

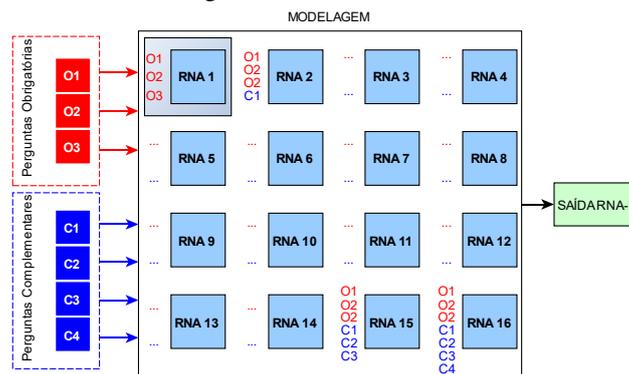
Fonte: Dos Autores, 2020.

Os dados de entrada então são processados e utilizados para alimentar o sistema neural artificial.

3.2 NEURÔNIOS DE ENTRADA DAS RNAS

Antes de servir como entrada dos neurônios da rede neural, as informações presentes na Fig. 2 são normalizados de 0 a 1 em função do conjunto utilizado. Os dados então são reorganizados em dois grupos: aqueles que são obrigatórios e aqueles que são complementares. Conforme a Figura 3, a seleção da rede neural artificial do SNA é realizada em função das informações disponíveis na entrada. Caso exista apenas as informações obrigatórias, a RNA-1 será selecionada. Se o dado complementar C1 estiver disponível, a rede selecionada é RNA-2.

Figura 3 – Visão da modelagem formando o Sistema Neural Artificial – SNA.



Fonte: Dos autores, 2020.

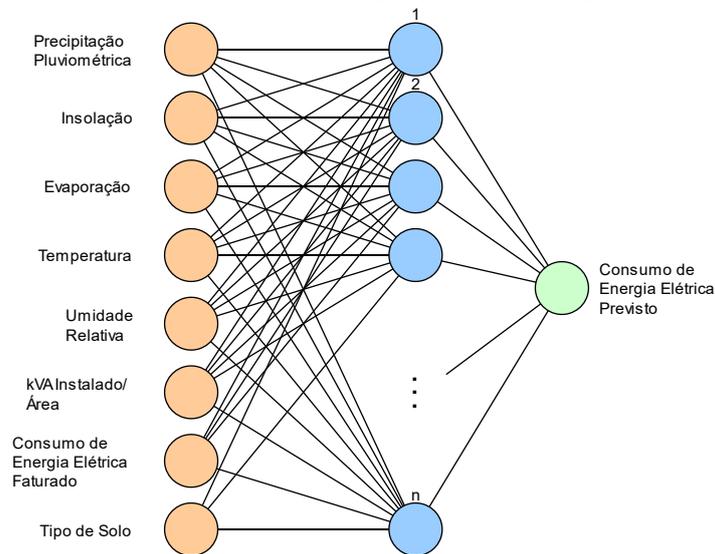
Os dados obrigatórios são caracterizados pela letra O. O1 é o conjunto de informações meteorológicas, O2 é a relação entre potência instalada e área da lavoura e O3 o histórico da energia elétrica faturada.

Os dados complementares são caracterizados pela letra C e são as informações que são obtidas através do questionário. C1 é o nível de automação, C2 a altura do levante, C3 o declive e C4 o método de irrigação.

3.3 IMPLEMENTAÇÃO E TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS

O Sistema Neural Artificial desenvolvido para estimar o consumo de energia elétrica nas lavouras utiliza 16 Redes Neurais Artificiais, cujas saídas indicam o consumo de energia elétrica previsto. Cada rede possui um número específico de neurônios de entrada, dependendo da quantidade de informações disponíveis. A Figura 4 apresenta a RNA-1 contendo apenas as informações obrigatórias.

Figura 4 – Rede Neural Artificial com apenas os dados obrigatórios (RNA-1).



Fonte: Dos autores, 2020.

As redes neurais possuem uma camada escondida, cuja quantidade de neurônios é definida pela automatização do treinamento. Inicia-se com o mesmo número de neurônios que a camada de entrada. O número de neurônios da camada escondida é incrementado a cada novo treinamento. A iteração que apresentar o menor erro de treinamento definirá o número de neurônios da camada escondida.

3.4 ÍNDICE DE PERDAS NÃO TÉCNICAS

A saída do sistema neural artificial é comparada com o consumo de energia elétrica real da lavoura. O erro máximo aceitável foi definido como 10%, em termos absolutos. A avaliação do erro é realizada através do Erro Médio Absoluto (MAE – *Mean Absolute Error*), obtido em (1).

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

Sendo:

N = quantidade total de dados;

y_i = saída prevista pelo modelo;

\hat{y}_i = saída real (esperada);

e_i = erro absoluto.

Dependendo da quantidade de dados disponíveis na entrada do SNA, a faixa de erro a ser considerada é diferente, conforme apresenta a Tabela 2.

Tabela 2 – Índice de Possibilidades 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: Dos Autores, 2020.

4 RESULTADOS E DISCUSSÃO

Com o objetivo de demonstrar e validar a metodologia, utilizou-se o conjunto de 3 lavouras. 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. Como período de irrigação nas culturas de arroz é geralmente compreendido entre os meses de setembro a março do ano, este estudo utilizou como parâmetro o início de registro dos medidores de energia e as safras de 2011/2012 até 2017/2018.

Primeiramente, foi feito o levantamento do índice de perdas não técnicas de todas as safras de todas as lavouras utilizando apenas as informações obrigatórias (RNA-1). Após, as lavouras UC-1, UC-2 e UC-3 foram analisadas com a RNA-8, RNA-16 e RNA-

17, respectivamente. Por fim, uma situação de falha foi adicionada à UC-3 para simular uma perda não técnica.

4.1 DESCRIÇÃO DO CONJUNTO DE DADOS

Foram selecionadas três lavouras distintas (UC-1, UC-2 e UC-3), apresentadas nas Figura 5, Figura 6 e Figura 7, respectivamente. Para os dados referentes ao clima, foi acessada uma estação meteorológica localizada aproximadamente a 40 km do local das lavouras. Com a ferramenta SOMA Brasil, identificou-se que o solo das três lavouras possui drenagem ruim. As áreas, extraídas pelas imagens de satélite são de 90, 300 e 50 hectares (ha), respectivamente. A potência instalada é disponibilizada pela concessionária de energia e dada em kVA. As informações complementares foram informadas pelo proprietário das lavouras.

Figura 5 – Unidade Consumidora UC-1.



Fonte: Adaptado do Google Earth, 2018.

Figura 6 – Unidade Consumidora UC-2.



Fonte: Adaptado do Google Earth, 2018.

Figura 7 – Unidade Consumidora UC-3.



Fonte: Adaptado do Google Earth, 2018.

Na Tabela 3 apresenta-se um resumo das informações gerais das lavouras utilizadas no trabalho.

Tabela 3 – Dados Gerais das Lavouras

Unidade Consumidora	Área irrigada aproximada	Potência instalada	Características 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

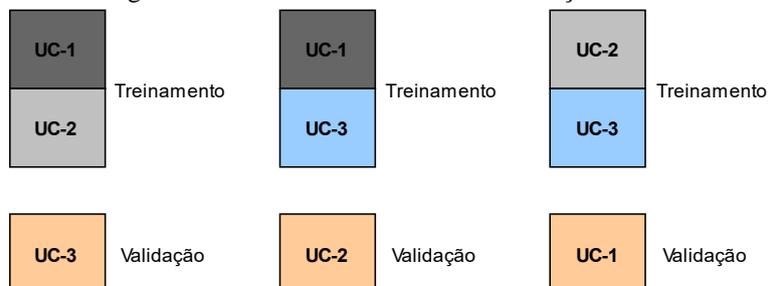
Fonte: Dos Autores, 2020.

4.2 TREINAMENTO E VALIDAÇÃO DAS RNAS

Para treinamento e validação do sistema neural artificial, foi utilizada o método de validação direta, dividindo o conjunto de dados em duas partes , sendo uma para treinamento e outra para validação.

Na validação direta, duas das três lavouras analisadas foram utilizadas para treinamento do sistema enquanto que a outra foi utilizada para validação, conforme Figura 8. Os dados são apresentados com uma sequencialidade temporal que permite à RNA reconhecer as tendências sazonais da série de dados.

Figura 8 – Três redes treinadas com validação direta.



Fonte: Adaptado do Google Earth, 2018.

4.3 ANÁLISE DA RNA1 APLICADA ÀS TRÊS LAVOURAS

Utilizando apenas os dados obrigatórios como dados de entrada, a RNA selecionada é a 1 (Figura 4). Foi verificado que o número de neurônios da camada oculta que apresentou menor erro de treinamento é 60, sendo o erro inferior a 1,5%. A Tabela 4, Tabela 5 e Tabela 6 apresentam os resultados obtidos para cada safra para as lavouras UC-1, UC-2 e UC-3, respectivamente. O erro médio absoluto informado é referente a todo período.

Com exceção das safras 2009/2010 e 2012/2013 da lavoura UC-2, todos os períodos resultaram em um baixo nível de perdas técnicas. Nos dois casos em específico, o nível foi médio.

Tabela 4 – Resumo da análise de UC-1 modelada com RNA-1

Safra	Erro Médio Absoluto
2009-2010	6,75 %
2010-2011	6,68 %
2011-2012	6,04 %
2012-2013	7,92 %
2013-2014	5,79 %

Fonte: Dos Autores, 2020.

Tabela 5 – Resumo da análise de UC-2 modelada com RNA-1

Safra	Erro Médio Absoluto
2009-2010	20,03%
2010-2011	3,31%
2011-2012	12,91%
2012-2013	21,70%
2013-2014	11,29%

Fonte: Dos Autores, 2020.

Tabela 6 – Resumo da análise de UC-3 modelada com RNA-1

Safra	Erro Médio Absoluto
2009-2010	11,02%
2010-2011	6,70%
2011-2012	11,27%
2012-2013	8,79%
2013-2014	10,44%

Fonte: Dos Autores, 2020.

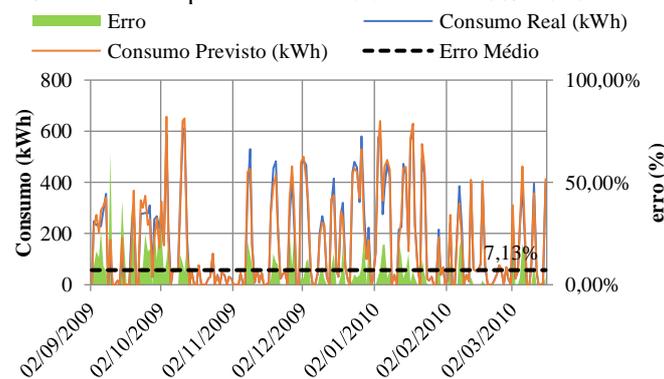
4.4 ANÁLISE DA RNA-8 APLICADA À UC-1

Aplicando as informações complementares número 2 (altura do levante), 3 (declividade do solo) e 4 (método de irrigação) juntamente com as informações obrigatórias da UC-1, a rede neural selecionada é a 8. Foi verificado que a rede com 44

neurônios na camada oculta foi a que apresentou menor erro de treinamento, inferior a 2%.

A Figura 9 apresenta a comparação entre o consumo real e previsto pela RNA da safra de 2009/2010, além de apresentar o erro absoluto e médio. O erro médio obtido nesse período é de 7,13%, muito próximo ao encontrado utilizando a RNA-1. Nesse caso, o acréscimo de informações não ocasionou a diminuição do erro, entretanto, ambos ficaram abaixo do erro mínimo de 10%.

Figura 9 – Resultado para a lavoura UC-1 safra 2009/2010 com RNA8.



Fonte: Dos Autores, 2020.

Os resultados para outras safras estão apresentados na Tabela 7 e seguiram o resultado da primeira safra, com o erro médio próximos. Para todas as safras, o risco de perdas não técnicas se permaneceu baixo.

Tabela 7 – Resumo da análise de UC-1 modelada com RNA-8.

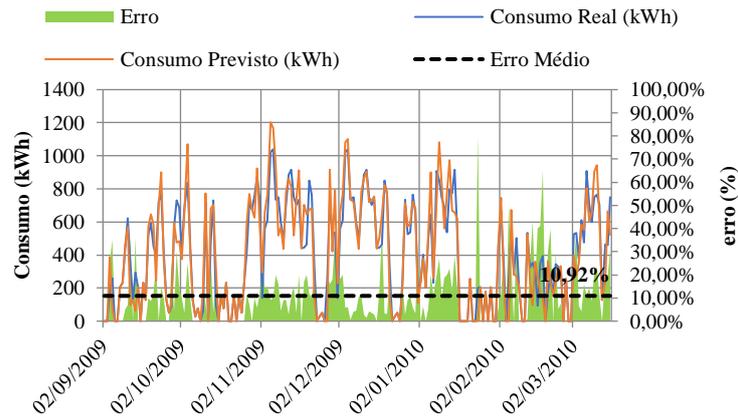
Safra	Erro Médio Absoluto
2009-2010	7,13 %
2010-2011	6,98 %
2011-2012	5,56 %
2012-2013	7,01 %
2013-2014	5,45 %

Fonte: Dos Autores, 2020.

4.5 ANÁLISE DA RNA-16 APLICADA À UC-2

Adicionando todas as informações obrigatórias e complementares, a RNA-16 é selecionada. O número de neurônios da camada escondida foi de 50 neurônios com erro de treinamento de 2,5 %. O erro médio para a safra de 2009/2010, apresentado na Figura 10, é de 10,92 % utilizando todas as informações de entrada, bem abaixo dos 20,03 % para o mesmo período utilizando apenas as informações obrigatórias.

Figura 10 – Resultado para a lavoura UC-2 safra 2009/2010 com RNA16.



Fonte: Dos Autores, 2020.

A inclusão das informações apresentou uma redução significativa no erro médio, apresentando uma tendência a melhorar o sistema com a inclusão das informações, conforme apresenta os resultados para as outras safras presentes na Tabela 8. Entretanto, o risco de perdas não técnicas passou de baixo para médio na safra de 2013/2014, apesar de ter diminuído o erro, devido à faixa de erro definida para a RNA-16.

Tabela 8 – Resumo da análise de UC-2 modelada com RNA-16.

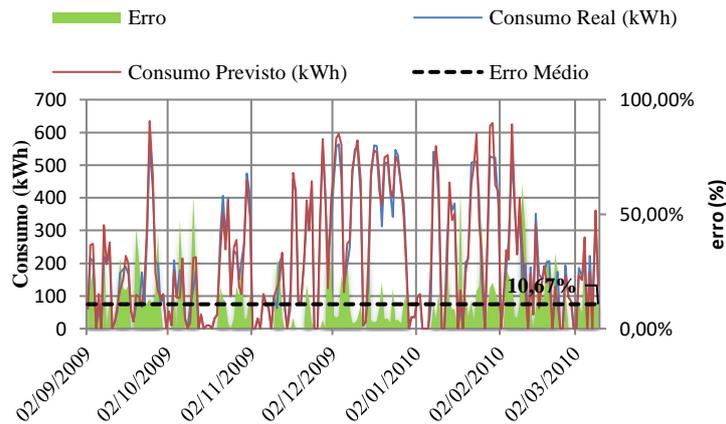
Safra	Erro Médio Absoluto
2009-2010	10,92 %
2010-2011	8,35 %
2011-2012	9,47 %
2012-2013	17,03 %
2013-2014	10,32 %

Fonte: Dos Autores, 2020.

4.6 ANÁLISE DA RNA-7 APLICADA À UC-3

A RNA-7 é composta pelos dados obrigatórios mais os dados sobre a altura do levante (C2) e declividade do solo (C4). Essa rede apresentou menor erro de treinamento (igual a 1,78 %) com 36 neurônios na camada escondida. Com erro médio de 10,67 %, a Figura 11 apresenta o resultado para a safra de 2009/2010. Novamente o erro ficou muito próximo de quando usada a RNA com apenas os dados obrigatórios, havendo uma pequena queda.

Figura 11 – Resultado para a lavoura UC-3 safra 2009/2010 com RNA7.



Fonte: Dos Autores, 2020.

Semelhante às outras lavouras, o resultado se repetiu para as outras safras, conforme Tabela 9. Os valores ficaram muito próximos e mantiveram o risco baixo de perdas não técnicas.

Tabela 9 - Resumo da análise de UC-3 modelada com RNA-7.

Safra	Erro Médio Absoluto
2009-2010	10,67 %
2010-2011	6,87 %
2011-2012	10,53 %
2012-2013	9,01 %
2013-2014	10,95 %

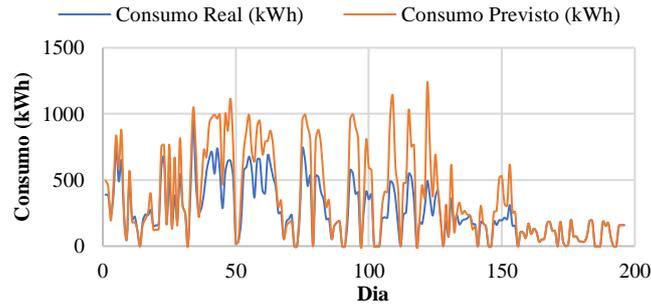
Fonte: Dos Autores, 2020.

4.7 SIMULAÇÃO DE SITUAÇÃO DE FALHA

Nessa seção, são apresentados os resultados obtidos com o modelo de RNA desenvolvido, 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 (apenas dados obrigatórios), 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.

A Figura 12 ilustra o resultado obtido através da RNA com Validação Direta, após a aplicação da falha intencional nos dados de consumo da lavoura UC-3.

Figura 12 – Resultado da simulação de falha na UC-3, safra de 2009/2010.



Fonte: Dos Autores, 2020.

Os resultados numéricos das análises de simulação de falha estão resumidos na Tabela 10.

Tabela 10 - Resumo da análise de UC-3 com simulação de falha.

Safra	Erro Médio Absoluto
2009-2010	43,46 %
2010-2011	65,49 %
2011-2012	80,45 %
2012-2013	76,26 %
2013-2014	32,83 %

Fonte: Dos Autores, 2020.

Considerando os critérios estabelecidos na Tabela 2, 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.

A análise realizada estabelecendo uma relação entre consumo real e esperado demonstrou ser satisfatória com índices de assertividades dentro dos parâmetros aceitáveis utilizando técnicas de RNA.

5 CONCLUSÃO

Esse artigo 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, e aplicando redes neurais artificiais.

Com os resultados do SNA é possível concluir que a metodologia é válida e que o acréscimo de informações sobre as lavouras em análise aumenta 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.

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.

Por fim, ao treinar novas redes e sistemas esta ferramenta pode ser implementada com o intuito de obter indicativos de perdas não técnicas em outros tipos de lavouras e aplicações.

REFERÊNCIAS

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

IRGA, Instituto Rio Grandense do Arroz, 2017.

L. L. PFITSCHER et al. Automatic Control of Irrigation Systems Aiming at High Energy Efficiency in Rice Crops, ICCDCS – International Caribbean Conference on Devices, Circuits and Systems, pp. 1-4, 2012.

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

M. MADRIGAL et al. Estimation of Non-Technical Energy Losses in Electrical Distribution Systems, IEEE Latin America Transactions, vol. 15, Issue. 8, IEEE 2017.

M. MADRIGAL et al. Estimation of technical energy losses in electrical distribution systems, IEEE Latin America Transactions, vol. 13, Issue. 10, IEEE 2015.

G. C. THOMAS, F. F. PINTO e K. P. LIMA. Modelagem matemática que descreve o comportamento da demanda de energia elétrica de uma cooperativa de eletrificação da cidade de Santa Rosa. Brazillian Journal of Development, vol. 6, n° 12, 2020.

F. D. GIRALDO et al. Identification of non-technical electricity losses in power distribution systems by applying techniques of information analysis and visualization, IEEE Latin America Transactions, vol. 13, Issue. 3, IEEE 2015.

M. BUZAU et al. Detection of Non-Technical Losses Using Smart Meter Data and Supervised Learning, IEEE Transactions on Smart Grid, IEEE 2018.

J. A. MEIRA et al. Distilling Provider-Independent Data for General Detection of Non-Technical Losses, IEEE Power and Energy Conference at Illinois, IEEE 2017.

INPE. Centro de Previsão de Tempo e Estudos Climáticos, Instituto Nacional de Pesquisas Espaciais. Disponível: <https://www.cptec.inpe.br>. Acesso em: setembro de 2020.