

# Uma Metodologia Baseada em Inteligência Artificial para Detecção de Perdas Não Técnicas em Irrigantes

Vanessa Gindri Vieira \* Roberta Razzolini Biazzi \*  
Daniel Pinheiro Bernardon \* Natalia Bastos de Sousa \*  
Henrique Silveira Eichkoff \* Paulo Ricardo da Silva Pereira \*\*  
Daniel Lima Lemes \* Rodrigo Marques de Figueiredo \*\*  
Matheus Mello Jacques \* Carlos Henrique Barriquello \*  
Vinícius Jacques Garcia \* Lucas Melo de Chiara \*\*\*  
Juliano Andrade Silva \*\*\*

\* PPGEE, Universidade Federal de Santa Maria, RS, (e-mail: [vanessa.vieira@ufsm.br](mailto:vanessa.vieira@ufsm.br), [roberta.biazzi@hotmail.com](mailto:roberta.biazzi@hotmail.com), [dpbernardon@ufsm.br](mailto:dpbernardon@ufsm.br), [bastos.nataliasousa@gmail.com](mailto:bastos.nataliasousa@gmail.com), [henriquekoff@gmail.com](mailto:henriquekoff@gmail.com), [daniellemesee@gmail.com](mailto:daniellemesee@gmail.com), [matheus.jacques@acad.ufsm.br](mailto:matheus.jacques@acad.ufsm.br), [carlos.barriquello@ufsm.br](mailto:carlos.barriquello@ufsm.br), [viniciusjg@ufsm.br](mailto:viniciusjg@ufsm.br)).

\*\* Escola Politécnica/Engenharia Elétrica, Universidade do Vale do Rio dos Sinos, RS (e-mail: [prpereira@unisinos.br](mailto:prpereira@unisinos.br), [marquesf@unisinos.br](mailto:marquesf@unisinos.br))

\*\*\* Companhia Paulista de Força e Luz - CPFL, SP, (e-mail: [lucaschiara@cpfl.com.br](mailto:lucaschiara@cpfl.com.br), [julianoandrade@cpfl.com.br](mailto:julianoandrade@cpfl.com.br))

---

**Abstract:** In electricity distribution networks, one of the challenges is to identify non-technical losses. The challenge is even greater in rural distribution networks. These have large extensions and the costs for on-site inspection are higher. Irrigated rice crops have particular characteristics in terms of consumption, due to the seasonality of the crop, different irrigation modes and processes, and climatic characteristics. This article presents a methodology that aggregates the consumption recorded by the concessionaires with more relevant information to analyze how much a given consumer presents risks of non-technical losses, as well as its neighbors. This work presents the use of Artificial Intelligence in the identification of non-technical losses in rural areas with integrated irrigation systems. The technique considers robust sub-methodologies, which evaluate: meteorological data, satellite images of the region, technological mapping of crops and the calculation of the energy balance for the estimation of non-technical loss by distribution feeder. The methodology was applied in consumer units located on the western border of RS. These consumer units use the flood irrigation system for rice planting, so they have a high monthly consumption. This high consumption significantly impacts the energy utility, in the event of a PNT. The results were obtained and validated with real information from rice harvests between 2018 and 2021.

**Resumo:** Identificar perdas não técnicas é um dos desafios em redes de distribuição de energia elétrica. Em se tratando de redes de distribuição rural, o desafio é ainda maior pelas grandes extensões da rede e custos de inspeção local. Consumidores rurais de lavouras de arroz apresentam características particulares quanto ao consumo, devido a sazonalidade da cultura, diferentes modos e processos de irrigação, e de características climáticas. Além dos dados de consumo registrado pelas concessionárias, este artigo apresenta uma metodologia que agrega mais informações relevantes para analisar quanto um determinado consumidor, e seus vizinhos, apresentam riscos de perdas não técnicas (PNT). O método utiliza o emprego de Inteligência Artificial na identificação de PNT e considera sub-metodologias robustas, as quais avaliam: dados meteorológicos, imagens de satélite da região, mapeamento tecnológico das lavouras e o cálculo do balanço energético para a estimativa de perda não técnica por alimentador de distribuição. A metodologia foi aplicada em unidades consumidoras localizadas na fronteira oeste do RS, as quais utilizam o sistema de irrigação por inundação para o plantio do arroz e apresentam um consumo mensal elevado que, na ocorrência de PNT, impactam significativamente a concessionária de energia. Os resultados foram obtidos e validados com informações reais de safras de arroz entre 2018 e 2021.

*Keywords:* rural consumer; artificial intelligence; irrigation; rice cultivation; non-technical losses;

*Palavras-chaves:* consumidor rural; inteligência artificial; irrigação; orizicultura; perdas não técnicas;

## 1. INTRODUÇÃO

No Brasil, as concessionárias de energia elétrica enfrentam algumas dificuldades para a distribuição de energia. Ao observar as redes elétricas em áreas rurais, é possível perceber maiores extensões de rede e com menor densidade demográfica por quilômetro de rede. Além disso, há dificuldade de manutenção de padrões de qualidade de energia, devido as quedas de tensão nos longos trechos de rede. Outra dificuldade observada, conforme Evaldt (2014), é quanto a sazonalidade das curvas de cargas, impactadas especialmente em regiões com intensa atividade agrícola e agroindustrial, o que reflete em um baixo fator de carga dos transformadores, como é o caso das regiões de rizicultura, isto é, lavouras de arroz.

No Rio Grande do Sul (RS), o problema relacionado a demanda referente a irrigação, é bastante visível, já que o estado é o maior produtor de arroz, correspondendo a 72,9% da área ocupada pelo arroz irrigado do país, cerca de 946 mil hectares (IRGA, 2020).

Além da preocupação com atendimento da demanda das atividades rurais, também é necessária a preocupação com a eficiência da irrigação de uma cultura. Dessa forma, o aumento de produtividade é garantido e, conseqüentemente, dos lucros do produtor. De acordo com o último levantamento realizado pela Agência Nacional de Águas e Saneamento Básico - ANA, no Brasil há cerca de 8,2 milhões de hectares de culturas irrigadas (ANA, 2021). Este grande número traz consequência direta ao consumo de energia elétrica na agricultura devido à utilização de motores e motobombas na irrigação.

Outras preocupações pertinentes estão relacionadas com a falta de eficiência dos equipamentos, perdas não técnicas (PNT) e sobrecarga da rede de distribuição. Equilibrar estes três pontos é fundamental para a saúde da rede de distribuição e qualidade do serviço fornecido.

As características de utilização da rede durante o período de irrigação levam a uma demanda elevada durante 21 horas do dia, reduzindo apenas no horário de ponta, entre 18h e 21h. Esse fator, além da possibilidade de sobrecarga no sistema, resulta em elevadas variações de carga no início e término do horário de ponta (Gautério, 2006).

As perdas não técnicas, ou perdas comerciais, são perdas associadas à quantidade de energia não faturada ou não paga. Tanto erros na medição ou faturamento, quanto o comportamento associado a fraude de usuários, levam a existência de PNT (Viegas et al., 2017). O custo associado as PNT acaba sendo pago pelas concessionárias e/ou consumidores legítimos.

No Brasil, os percentuais de perdas não técnicas calculados no país na última década chegam a mais de 16% da energia de baixa tensão distribuída (ANEEL, 2021). A Figura 1 mostra o levantamento das perdas não técnicas em baixa

tensão no período de 2008 a 2020, comparando o valor real e o definido pela Agência Nacional de Energia Elétrica - ANEEL, denominado regulatório.

Para evitar o abuso do poder de mercado, além de assegurar qualidade do serviço, a ANEEL definiu um procedimento regulatório para garantir o menor custo para o consumidor e uma remuneração adequada para as empresas, de forma a dispor de instrumento que permitam calcular o valor "justo" das tarifas (ANEEL, 2021). O detalhamento da aplicação da regra encontra-se no Submódulo 2.6 dos Procedimentos de Regulação Tarifária - PRORET (ANEEL, 2018).

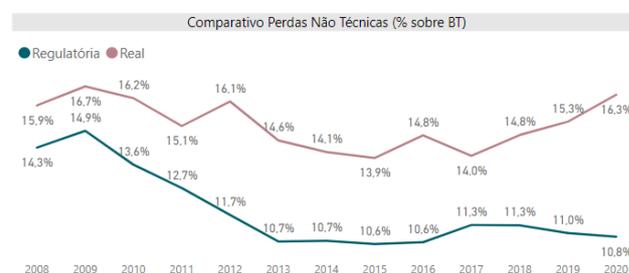


Figura 1. Perdas Não Técnicas no Brasil (2008 - 2020).

A principal contribuição deste artigo é a definição de uma metodologia que considera várias entradas para cada unidade consumidora, não apenas a energia consumida, para determinar se há perda não técnica.

A seguir será apresentada a metodologia geral e as sub-metodologias para definir as informações, que serão agregadas ao dado de consumo, para determinar o grau de pertencimento da unidade consumidora ao grupo envolvido com PNT.

## 2. DESENVOLVIMENTO

Para obter as informações das unidades consumidoras (UCs) que possuem maior chance de pertencer ao grupo com perdas não técnicas foi definida uma metodologia geral, representada na Figura 2, para obter a resposta do grau de assertividade de cada unidade consumidora analisada.

O consumo durante o período de irrigação está sujeito a quantidade de precipitação na região, ao tamanho da lavoura irrigada e ao tipo de cultivo. Para clarificar o que cada uma das entradas no diagrama significa e como são obtidas, as seções seguintes descrevem cada um dos módulos que geram como resultados estas informações.

### 2.1 Mapeamento Tecnológico

Considerando o âmbito rural, a energia elétrica é utilizada para o funcionamento dos sistemas de irrigação responsáveis por distribuir volume de água captada de fontes

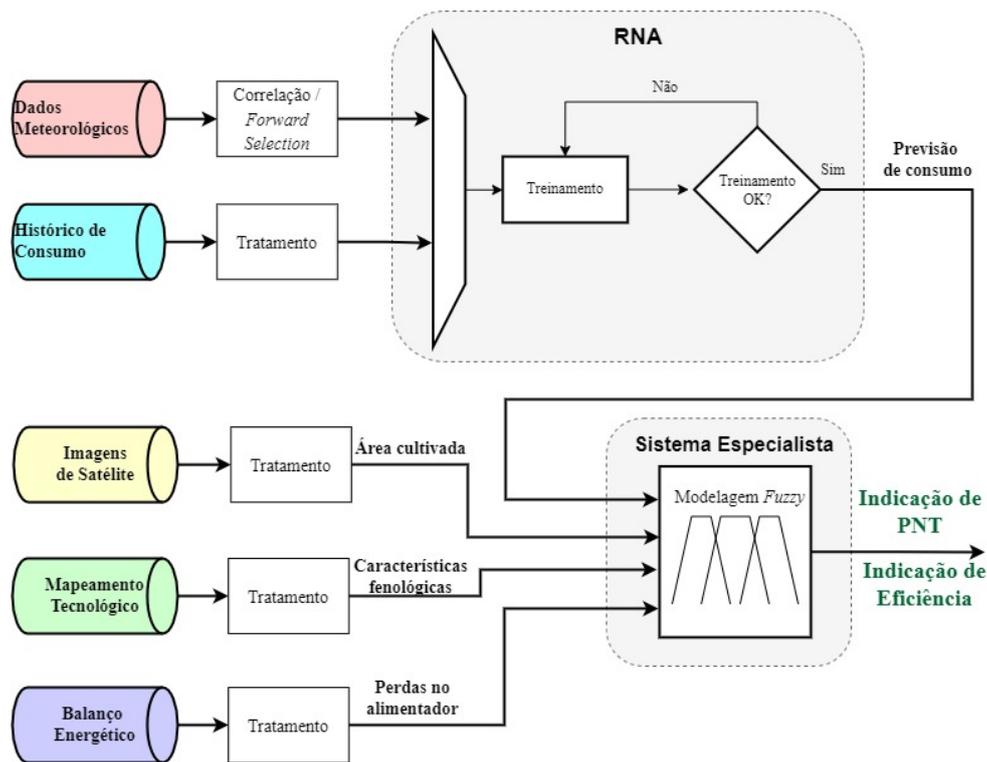


Figura 2. Metodologia Geral.

disponíveis para as delimitações das lavouras. No RS, o consumo de energia elétrica na área rural é destacado pelas lavouras de arroz irrigado. Dentre os municípios que cultivam arroz, destacam-se Uruguaiana na Região da Fronteira Oeste, onde está concentrado o maior número de hectares no Estado (75.000 ha). Com isso, escolheu-se implementar a metodologia, desenvolvida neste trabalho, no município de Uruguaiana.

As UCs presentes nas áreas rurais da Região da Fronteira Oeste do RS, apresentam elevados consumos mensais de energia elétrica, devido à atividade de irrigação da lavoura, principalmente nos meses de Janeiro, Fevereiro, Novembro e Dezembro (Marcolin et al., 2021). Esses consumidores são significativos nos alimentadores de distribuição e obrigam as concessionárias a disporem de um conhecimento prévio da carga instalada de seus clientes rurais, a fim de evitar irregularidades em registros de medições de energia faturada, por exemplo, PNT.

*Características das Lavouras de Arroz Irrigado:* No RS, o método adotado nas lavouras de arroz é de irrigação superficial por inundação contínua (Köpp, 2015). A irrigação por inundação tende a apresentar uma demanda hídrica que seja suficiente para saturar o solo, formar a lâmina d'água, compensar a evapotranspiração, e repor as perdas por percolação vertical e as perdas laterais nos canais de irrigação e tubulações. Como atributos importantes que compõem o cultivo de arroz irrigado, destacam-se: a eficiência do conjunto Bomba-Motor (média de 45% a 50%), tempo de funcionamento do sistema de irrigação (21 horas diárias na época de irrigação), variáveis meteorológicas (evapotranspiração, índice de precipitação pluviométrica) e área do cultivo.

*Impacto das Variáveis Meteorológicas nas Lavouras de Arroz Irrigado:* A meteorologia é um tópico importante para complementar o processo de irrigação em uma lavoura de arroz durante o período de safra. Do mesmo modo que a precipitação pluviométrica colabora para a reposição e o acúmulo de água nas lavouras, variáveis como radiação solar, velocidade do vento, temperatura e umidade relativa do ar colaboram para acelerar o processo de evapotranspiração da lavoura (Marcolin et al., 2021).

*Características do Consumo de Energia Elétrica da Região de Estudo:* As unidades consumidoras irrigantes presentes no município de Uruguaiana/RS são pertencentes em grande parte ao Grupo A, com tensão de fornecimento igual ou superior a 2,3 kV. Segundo Köpp (2015), esse tipo de consumidor pode enquadrar-se na modalidade tarifária horária verde (horo sazonal verde), caracterizada por tarifas diferenciadas de consumo de energia elétrica em intervalos horários, e valor único para demanda de potência ativa e com descontos que variam de 70% a 90% dos valores da Tarifa de Energia (TE) e Uso do Sistema de Distribuição (TUSD) da modalidade verde para os consumidores irrigantes. Dessa forma, os sistemas de irrigação são desligados no horário de ponta, devido ao enquadramento tarifário.

A Figura 3 ilustra o perfil anual de consumo de energia elétrica de uma UC irrigante de arroz do município de Uruguaiana/RS. Nota-se que os consumos de energia elétrica mais expressivos foram obtidos nos meses de Janeiro, Fevereiro, Novembro e Dezembro, pois nestes meses, estão compreendidos o período de irrigação intensa da lavoura de arroz.

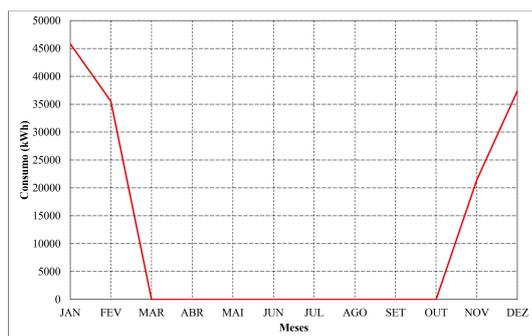


Figura 3. Curva Característica de Consumo de Energia Elétrica de Unidade Irrigante da Região de Estudo

## 2.2 Imagem de Satélite

Devido à vasta extensão territorial e a necessidade de monitoramento periódico faz-se necessário a utilização de sensoriamento remoto para que todo o sistema não seja custoso financeiramente. Existem inúmeras missões espaciais que fornecem seus produtos gratuitamente para a pesquisa. Dentre elas se destacam a LANDSAT e a SENTINEL, desenvolvidas pela *National Aeronautics and Space Administration* (NASA) e *European Union's Earth observation programme*, respectivamente. Apesar de ambas possuírem sensores multi-espectrais embarcados nos satélites, a missão Sentinel-2 foi escolhida para este trabalho por possuir uma *interface* mais amigável de disponibilização das imagens e uma melhor resolução.

As imagens da missão Sentinel-2 são disponibilizadas através de Cenas, que são imagens que varrem uma extensão territorial de 100x100 km. A região piloto escolhida, município de Uruguaiiana, é inteiramente coberta por 4 cenas, são elas: 21JVH, 21JWH, 21JVG e 21JWG. Para exemplificar a metodologia, os resultados mostrados são correspondentes a cena 21JWH. A Figura 4 mostra essa Cena extraída diretamente da missão Sentinel-2 sem nenhum pré-processamento.



Figura 4. Cena 21JWH disponibilizada pela Missão Sentinel-2.

A próxima etapa do fluxo de processamento das imagens de satélite é extrair da Cena escolhida somente as áreas de

cultivo. Para isso foi utilizado o índice NDVI (*Normalized Difference Vegetation Index*), as áreas cuja densidade de vegetação é alta são extraídas da Cena e servem de entrada para uma Rede Neural Artificial (RNA), para que seja classificado o tipo de cultivar presente.

Para diminuir o esforço computacional e o tempo necessário para processamento, as cenas foram divididas em 484 subimagens de 500x500 pixels. Essas subimagens são consumidas por uma RNA baseada na topologia proposta por Ronneberger et al. (2015). Essa rede neural é composta por duas partes: a etapa de contração e a etapa de expansão. Durante a contração, a RNA aprende características profundas sobre as imagens de satélite, internalizando detalhes que passam despercebidos por humanos. Já na parte de expansão, a rede tenta reproduzir o que aprendeu. Dessa forma, a saída da RNA são essas subimagens contendo uma máscara, cujos pixels são classificados segundo o tipo de cultivar. A Figura 5 mostra uma das subimagens contendo a máscara. Em azul são os corpos hídricos, em roxo as plantações de soja e em amarelo as plantações de arroz presentes na subimagem. Já a região em cinza são as demais áreas que não são lavouras de soja, de arroz ou corpos hídricos.

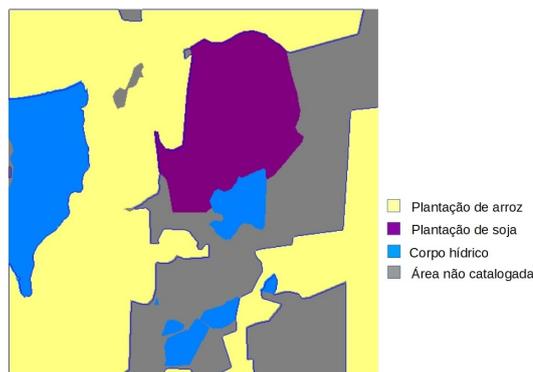


Figura 5. Subimagem da Cena 21JWH contendo a máscara do tipo de cultivar.

Depois de geradas as máscaras, o Algoritmo de Detecção de Borda Canny (Canny, 1986) é utilizado para gerar os contornos de cada plantação e a biblioteca OPENCV é utilizada para extrair a área ( $m^2$ ) e a localização geodésica do centroide de cada contorno.

A Figura 6 mostra, através de marcadores, as áreas de arroz pertencentes ao município de Uruguaiiana e à Cena 21JWH. Como existem UCs muito próximas uma das outras, a alocação de cada plantação à sua respectiva UC se tornou uma tarefa complexa. Para diminuir o erro optou-se por utilizar o método de agrupamento *k-means* para agrupar as áreas e posteriormente individualizá-las. Assim, obteve-se um número ótimo de agrupamentos igual a 20, como mostrado na Figura 6, onde cada agrupamento está destacado por uma cor. Depois de gerados os agrupamentos, verifica-se então as UCs que estão dentro desse agrupamento, somam-se as áreas mais próximas até que o número de áreas seja igual ao de UCs e aloca-se cada área à UC mais próxima. As coordenadas geodésicas das UCs foram obtidas junto à concessionária de energia responsável pela região de estudo.

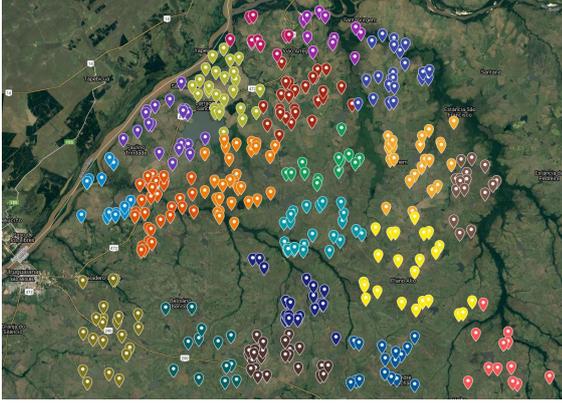


Figura 6. Áreas de Arroz pertencentes ao Município de Uruguaiana e à Cena 21JWH.

### 2.3 Dados Meteorológicos

Os dados meteorológicos foram obtidos do INMET (Instituto Nacional de Meteorologia). Entretanto, dado o número limitado de estações meteorológicas e, portanto, de medições das variáveis meteorológicas, torna-se necessário estimar através destas, os dados meteorológicos correspondentes às localizações a serem analisadas. Para obter tais estimativas, se faz uso de métodos de interpolação espacial de dados. A premissa básica é que existe correlação espacial nas medições obtidas. Portanto, torna-se possível estimar valores para pontos não medidos a partir dos pontos medidos.

*Método de interpolação:* Para realizar a interpolação foi empregado o método Inverso Ponderado da Distância, do inglês *Inverse Distance Weighing* (IDW) (Oliver and Webster, 2014) e (Ryu et al., 2021), o qual consiste em uma combinação linear dos valores ponderados por uma função exponencial da distância. No caso bidimensional, um novo valor (interpolado)  $Z(s_i^*)$  em uma localização  $s_i^*$  é obtido por:

$$Z(s_i^*) = \sum_{k=1}^m \omega(r_{ik}) Z(s_k), \quad s_i^*, s_k \in R \quad (1)$$

onde  $Z(s_k)$  são os  $m$  valores observados nas localizações  $s_k$ , respectivamente. A função de peso é definida como  $\omega(r_{ik}) = \frac{\hat{\omega}(r_{ik})}{\sum \hat{\omega}(r_{ik})}$ , onde  $\hat{\omega}(r_{ik}) = 1/r_{ik}^\beta$  e  $r_{ik} = |s_i^* - s_k|$  (isto é, a distância entre os locais  $s_i^*$  e  $s_k$ ). O parâmetro  $\beta$  representa o fator de decaimento da distância, sendo dependente da distribuição do campo de interesse.

*Interpolação das medições existentes:* Para realizar a interpolação, foi selecionado um subconjunto de unidades consumidoras localizadas na região de Uruguaiana/RS. Os dados meteorológicos de precipitação, velocidade do vento, temperatura mínima e máxima, correspondentes ao ano de 2021, foram coletados da base de dados do INMET e empregados na interpolação. Então, os resultados de interpolação foram integralizados mês a mês para cada unidade consumidora.

### 2.4 Balanço Energético

Visando realizar análises operacionais nos sistemas, as perdas de energia são estimadas utilizando o método de balanço energético proposto em Biazzini et al. (2022). A contribuição principal da integração da metodologia em questão com a técnica de IA (Inteligência Artificial) proposta neste trabalho é fornecer a relação dos alimentadores de distribuição que apresentam alto potencial de conter consumidores irregulares conectados, ou seja, valores estimados de PNT elevados. Para tanto, a técnica descrita em (Biazzini et al., 2022) trabalha com parâmetros e dados reais como os históricos de faturamento da concessionária de energia, medições na saída dos alimentadores fornecidas pelo Sistema de Supervisão e Aquisição de Dados (SCADA) e os dados de rede obtidos pelo acesso ao Sistema de Informação Geográfica (GIS).

De forma sucinta, a primeira etapa da metodologia de balanço energético é responsável por determinar o valor da perda global (PG), por alimentador e períodos mensais, através da diferença entre a energia total fornecida e a energia total faturada nas unidades consumidoras conforme (2).

Levando em consideração que o emprego da técnica IA tem foco nas unidades consumidoras com sistema de irrigação integrado para o plantio do arroz, localizadas na fronteira oeste do Rio Grande do Sul, devido a valores significativos de consumos mensais como descrito anteriormente, os alimentadores simulados são predominantemente rurais, com grandes extensões de redes e elevado carregamento. Tais características contribuem para que se tenha uma parcela significativa de perda relacionada ao processo de distribuição de energia elétrica (perdas nas linhas e equipamentos pela passagem de corrente elétrica, denominadas perdas técnicas) e não ao furto e fraude de energia elétrica. Desta forma, a segunda etapa da metodologia entra com o propósito de simular a operação do sistema, considerando dados e parâmetros reais da rede, e estimar de forma precisa o valor da perda técnica (PT), para o período considerado. O cálculo do fluxo de potência na estimativa da PT é realizado utilizando o software OpenDSS com atualização periódica (mês a mês) dos arquivos de rede como topologia do sistema, dados de subestação, transformadores e linhas, curva típica das UCs, histórico de consumo das UCs, carregamento, entre outros. Por fim, os valores estimados de PNT por alimentador é obtido por (3), subtraindo o valor estimado de PT do valor da PG.

Como descrito, a metodologia trabalha inicialmente os valores de PG, PT e PNT estimado mês a mês. Adaptando o método a proposta atual, os índices de PNT por alimentador são gerados considerando um horizonte anual, de forma que atenda períodos completos de safra.

$$PG = \sum E_{fornecida} - \sum E_{faturada} \quad (2)$$

$$PNT = PG - PT \quad (3)$$

onde  $E_{fornecida}$  é a energia entregue pelo alimentador e corresponde as medições de potência ativa fornecida pelo SCADA, em intervalos de 15 minutos, totalizando 96 pontos de medições diários.  $E_{faturada}$  é a energia faturada

em cada unidade consumidora atendida pelo alimentador em questão.

## 2.5 Inteligência Artificial

Para auxiliar na indicação das UCs com maior potencial a PNT e também indicar a eficiência desta UC, além do processamento do histórico de consumo utilizado para treinar a RNA, as informações meteorológicas recebidas para o consumidor em questão foram agregadas para determinar a previsão de consumo para a UC.

Foram necessários alguns tratamentos nos dados de entrada com o auxílio de ferramentas estatísticas. Inicialmente, realizou-se a correlação das variáveis meteorológicas, no intuito de excluir as variáveis correlacionadas (mutuamente dependentes), por se tratarem de variáveis que carregam dados redundantes, através da Análise de Correlação e *Forward Selection*, detalhes desse processo são apresentados em Uberti et al. (2021). Este tratamento é importante, na medida que reduz a necessidade computacional para a aplicação da lógica fuzzy e da RNA. Na Figura 7 são mostradas as variáveis selecionadas ao final do processo: Chuva (volume pluviométrico), Velocidade do Vento, Temperatura Média e Umidade Relativa do Ar.

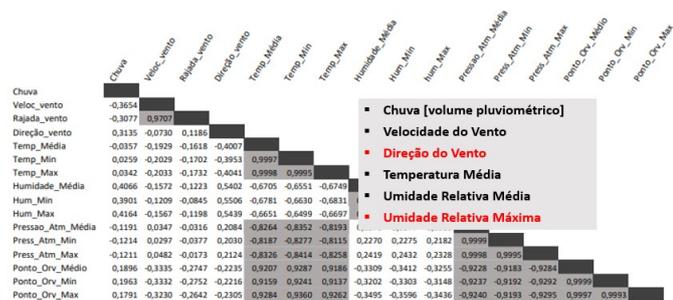


Figura 7. Correlação das variáveis meteorológicas.

Os valores do histórico de consumo passam por tratamento para verificar a consistência dos dados e eliminar dados faltantes, para serem utilizados para previsão de consumo realizada pela RNA. Após vários testes, optou-se pelo modelo de RNA *Multilayer Perceptron* com camada oculta. O número de neurônios desta camada é determinado através de um processo automático, conforme (Vieira et al., 2021). Vários treinamentos são realizados com diferentes números de neurônios, aquele com o menor erro de treinamento determina a quantidade de neurônios. Para a rede neural deste trabalho, ficou definido 60 neurônios na camada oculta. Com o uso de metodologia de treinamento foi possível reduzir ao mínimo o erro entre o valor de consumo previsto e o valor de consumo real.

Em relação à previsão de consumo de irrigantes de arroz, inicialmente, realizou-se o treinamento da RNA considerando uma janela de dados de 48 meses anteriores ao mês que se deseja prever o consumo, chamando-se de treinamento serial de 4 anos. Com este tipo de treinamento, foram obtidos resultados de previsão com erro absoluto de até 12,64% em relação ao consumo real. Diferentes metodologias de treinamento foram testadas, utilizando-se treinamento serial de 2 anos e também treinamento mês a mês. Este último foi o que apresentou os melhores resultados.

No treinamento mês a mês, para prever o consumo do mês de janeiro são utilizados os dados dos meses de janeiro dos quatro anos anteriores, e assim sucessivamente. Na Figura 8, são apresentados os valores previstos para 2020, considerando os dados dos 4 anos anteriores comparados mês a mês, e o valor medido de consumo (realizado) para analisar a acurácia da RNA. Com esta técnica de treinamento, os erros absolutos reduziram-se significativamente, caindo para pouco mais de 2%.



Figura 8. Comparação dos resultados da RNA para 2020 e os valores realizados.

A previsão de consumo da UC, juntamente com informações da área da lavoura e características fenológicas da lavoura são usadas como entrada para o sistema especialista para determinar o resultado final. Além dos dados obtidos da lavoura sob análise, a medida da PNT do alimentador associado à UC é considerada pelo sistema especialista, para definir o nível de PNT associado a esta UC. É no sistema especialista, que situações atípicas serão consideradas neste sistema. Tais situações são, basicamente, situações esporádicas que podem alterar significativamente os padrões de consumo, como mudanças econômicas num determinado período/safra, bem como a existência de rodízio de cultivar na mesma área de plantio em períodos distintos, o que pode gerar discrepâncias nos dados.

## 3. RESULTADOS E DISCUSSÕES

Com o intuito de validar a metodologia proposta foram utilizados dados reais, de unidades consumidoras irrigantes da região oeste do RS. A partir destes dados, foi realizada uma seleção de um subconjunto com aderência aos critérios representados na Figura 9. A partir desta seleção resultaram 65 unidades consumidoras selecionadas para inspeção em campo. Estas unidades foram priorizadas de modo que aquelas que atendiam o maior número de critérios receberam uma prioridade maior. Foram definidos quatro graus de prioridade.

No conjunto de consumidores resultante: 38% apresentaram interrupção de consumo mensal no período de safra, compreendido entre outubro de um ano e março do ano subsequente, nas 3 safras analisadas; 16% não apresentaram consumo durante 2 anos consecutivos, ou mais, durante o período de safra; 35% apresentaram variação significativa no consumo de uma safra para outra; 11% apresentaram variação de consumo em relação ao padrão observado no seu agrupamento.

Considerando o intervalo de 12 meses de dados analisados, o conjunto de consumidores foi classificado quanto à

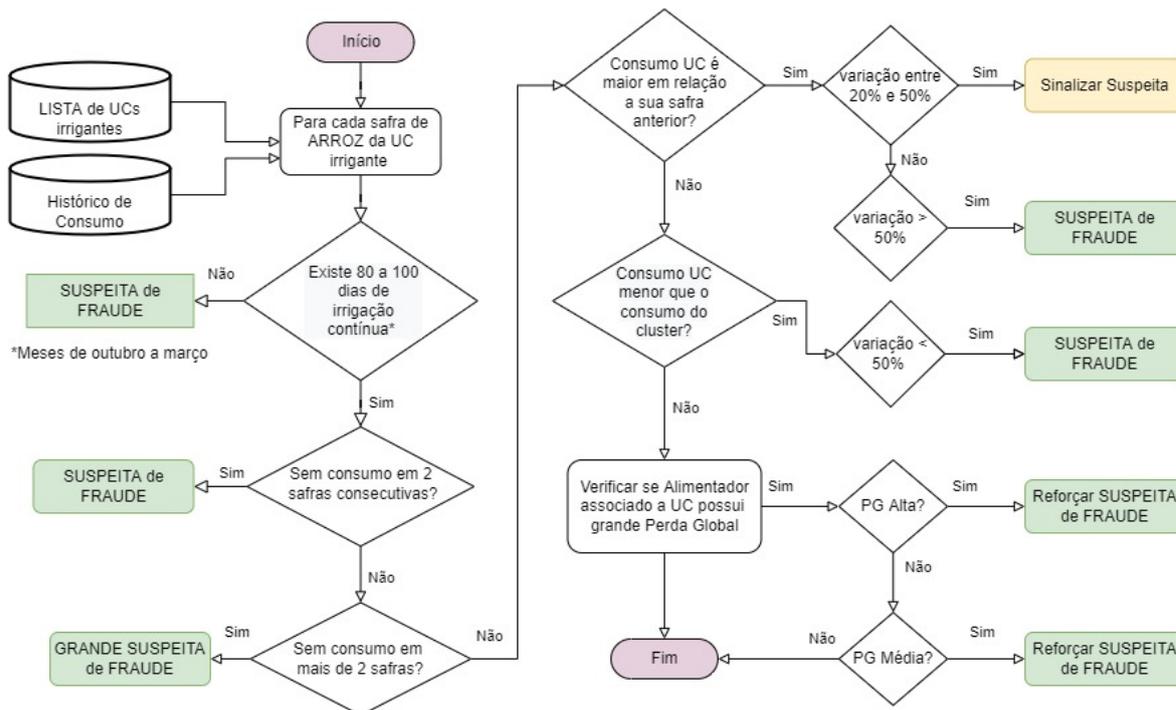


Figura 9. Fluxograma de avaliação de critérios para identificação de PNT.

priorização para inspeção no local, resultando no gráfico apresentado na Figura 10, onde 4% das UCs receberam prioridade MUITO ALTA, 14% das UCs prioridade ALTA, mas a maioria ficou com prioridade MÉDIA, 67% das UCs.

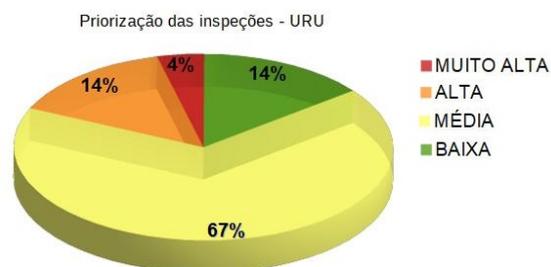


Figura 10. Priorização das UCs para inspeção.

Importante ressaltar que a seleção de variáveis realizadas em cada etapa do desenvolvimento é fundamental para extrair-se a melhor resposta do sistema integrado. Quando do mapeamento tecnológico os levantamentos trazem para o sistema a informação do comportamento geral do cultivar, já nas imagens de satélite tem-se a confirmação dos tipos de cultivares. Além disso, também se consegue uma boa estimativa da área do cultivar, o que auxilia o sistema na ponderação da necessidade energética para aquela região.

Já os dados meteorológicos trazem a demanda de irrigação para o cultivar e essas variáveis são as mais complexas de relacionar com o consumo, pois há sempre um elemento estocástico exógeno envolvido, como questões de mercado e ataques de pragas. Esses fenômenos não são espelhados nos dados meteorológicos e, por isso, devem ser muito bem avaliados. Os dados meteorológicos trazem as informações sazonais do comportamento de consumo.

Por fim, os dados de balanço energético trazem as características operacionais do sistema e, aqui, também se deve ter uma atenção especial para avaliar se o modelo está ou não embarcando o comportamento correto das relações do cultivar com as demais variáveis. Por isso, é importante realizar um ajuste dos dados de consumo e meteorológicos utilizando um sistema de predição baseado em RNA (Redes Neurais Artificiais) em um modelo de MLP (*Multilayer Perceptron*) associado a um sistema Fuzzy especialista, no qual as ponderações das variáveis com alta sensibilidade de amostragem são modeladas pelo seu histórico e, com isso, são dados os indicativos de Perdas Não Técnicas associados a uma informação de eficiência.

Como resultado do Plano Safra da RGE-Sul 2021/2022, a concessionária realizou inspeções nos meses de dezembro, janeiro e fevereiro nos consumidores rurais. Após a realização das inspeções in loco, 83% das inspeções levantadas pela metodologia apresentada já foram inspecionadas, resultando em 3,77% de assertividades, isto é, durante a inspeção 3,77% das UCs apresentaram sinais de PNT.

#### 4. CONCLUSÃO

Este artigo abordou o problema das perdas não técnicas no contexto de consumidores voltados à rizicultura. O trabalho foi motivado pela importância e volume de demanda de energia durante o período de irrigação das lavouras de arroz. Como a maior parte da produção de arroz irrigado do país, ocorre no RS, o impacto da irrigação é grande no sistema de distribuição de energia.

A partir da definição da lista de consumidores irrigantes, para inspeção em campo durante o Plano Safra da RGE-Sul 2021/2022, foram definidos indicadores para classificar e selecionar as unidades consumidoras com maior potencial em apresentar PNT. Os indicadores são resultados das

análises realizadas nas UCs quanto: ao tempo de irrigação durante a safra, falta de registro de consumo no período de safra por 2 anos consecutivos ou mais, variação elevada no próprio consumo de uma safra para outra, variações elevadas de consumo da UC em relação ao comportamento do seu agrupamento. Além de considerar se a UC está localizada em um alimentador com grandes quantidades de perdas globais.

Ao término do período de inspeções, o resultado proporcionará um *feedback* importante referente a assertividade destas vistorias e, especialmente, a aderência dos itens anteriormente detalhados como pontos de atenção no indicativo de incidência das PNT. Estes e outros critérios para avaliação são pontos fundamentais para atingir os objetivos finais de identificação de fraudes independentemente das ferramentas utilizadas.

A contribuição deste trabalho passa pela metodologia de mapeamento das variáveis, sendo estas mapeadas no seu sistema de origem, criando um modelo específico. A generalização para o modelo completo é dado pela integração de um sistema de IA (Inteligência Artificial) formado por uma RNA e um sistema Fuzzy especialista que une as características de predição mais modelagem comportamental da RNA com a capacidade de ponderação de um sistema Fuzzy. Dessa forma, com um sistema completo, é possível mapear sistema complexos com dados estocásticos e se obter um modelo comportamental consistente e coerente.

#### AGRADECIMENTOS

Os autores gostariam de agradecer ao grupo CPFL pelo apoio técnico e financeiro, através do projeto de Pesquisa e Desenvolvimento PD-00063-3065/2020 – “PA3065 - Sistema para Detectar Perdas Não Técnicas em Áreas de Irrigação Empregando Técnicas de Inteligência Artificial” com recursos do programa de P&D da ANEEL. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES/PROEX) - Código de Financiamento 001.

#### REFERÊNCIAS

- ANA (2021). Atlas da irrigação: uso da água na agricultura irrigada. Acesso em: jan/2022, disponível em: <http://atlasirrigacao.ana.gov.br>.
- ANEEL (2018). Proret - Procedimentos de Regulação Tarifária: Submódulo 2.6 - perdas de energia. Acesso em: dez/2021. Disponível em: [http://www2.aneel.gov.br/cedoc/aren2018806\\_Proret\\_Submod\\_2\\_2A\\_v2.pdf](http://www2.aneel.gov.br/cedoc/aren2018806_Proret_Submod_2_2A_v2.pdf).
- ANEEL (2021). Perdas de energia elétrica na distribuição. Acesso em: fev/2022. Disponível em: <https://www.aneel.gov.br/luz-na-tarifa>.
- Biazzi, R.R., Bernardon, D.P., Becker, E., de Chiara, L.M., and Silva, J.A. (2022). Technical and nontechnical energy loss estimation including volt/var control for active distribution systems. *Journal of Control, Automation and Electrical Systems*, 33(1), 255–267. Disponível em: <https://doi.org/10.1007/s40313-021-00813-x>.
- Canny, J. (1986). A computational approach to edge detection. *IEEE Transactions on pattern analysis and machine intelligence*, 8(6), 679–698.
- Evaldt, M.C. (2014). *Uma metodologia para a identificação de perdas não técnicas em grandes consumidores rurais*. Dissertação de mestrado em engenharia elétrica, Universidade Federal de Santa Maria, Santa Maria, RS, Brasil.
- Gautério, Z.W.B. (2006). *Impacto do Gerenciamento pelo Lado da Demanda em Transformadores de Potência*. Dissertação de mestrado em engenharia elétrica, Pontifícia Universidade Católica - PUC-RS, Porto Alegre, RS, Brasil.
- IRGA (2020). Mapeamento de ana e conab identifica 1,3 milhão de hectares de arroz irrigado no brasil. Acesso em: jan/2022. Disponível em: <https://irga.rs.gov.br/mapeamento-de-ana-e-conab-identifica-1-3-milhao-de-hectares-de-arroz-irrigado-no-brasil>.
- Köpp, L.M. (2015). *Índices de Desempenho para Estações de Bombeamento em Lavouras de Arroz Irrigado*. Tese de doutorado em engenharia agrícola, Universidade Federal de Santa Maria, Santa Maria, RS, Brasil.
- Marcolin, P., Bernardon, D.P., Sousa, N.B., Eichkoff, H.S., Madaloz, J., Köpp, L.M., Chiara, L.M., and Silva, J.A. (2021). Metodologia para detecção de perdas não técnicas de unidades consumidoras irrigantes de arroz. In *XIV Conferência Brasileira sobre Qualidade da Energia Elétrica - CBQEE*. Acesso em fev/2022. Disponível em: <https://proceedings.science/cbqee-2021/papers/metodologia-para-deteccao-de-perdas-nao-tecnicas-de-unidades-consumidoras-irrigantes-de-arroz?lang=pt-br>.
- Oliver, M.A. and Webster, R. (2014). A tutorial guide to geostatistics: Computing and modeling variograms and kriging. *Catena*, 113, 56–69. <https://doi.org/10.1016/j.catena.2013.09.006>.
- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, 234–241. Springer.
- Ryu, S., Song, J.J., Kim, Y., Jung, S., Do, Y., and Lee, G. (2021). Spatial interpolation of gauge measured rainfall using compressed sensing. *Asia-Pacific Journal of Atmospheric Sciences*, 57(2), 331–345. <https://doi.org/10.1007/s13143-020-00200-7>.
- Uberti, V., Bernardon, D.P., Vieira, V., Heinke, M., de Figueiredo, R., Evaldt, M., Abaide, A., Chiara, L., and Silva, J.A. (2021). In *Data Mining applied to features selectivity for a non-technical loss detection model in rural distribution grids*. Acesso em: 15/01/2022, disponível em: <https://www.cired2021.org/media/2000/cired-virtual-special-report.pdf>.
- Viegas, J.L., Esteves, P.R., Melício, R., Mendes, V.M.F., and Vieira, S.M. (2017). Solutions for detection of non-technical losses in the electricity grid: A review. In *Renewable and Sustainable Energy Reviews*, volume 80, 1256–1268.
- Vieira, V., Bernardon, D.P., Heinke, M., de Figueiredo, R., Evaldt, M., Uberti, V., Abaide, A., Chiara, L., and Silva, J.A. (2021). In *Methodology to identify non-technical losses in rural grids using Artificial Neural Networks and Deep Learning*. Acesso em: 15/01/2022, disponível em: <https://www.cired2021.org/media/2000/cired-virtual-special-report.pdf>.