



# Redes Neurais Artificiais e suas aplicações no setor elétrico

Alberto A. Kopiler, Victor Navarro A. L. da Silva, Luiz Antônio A. de Oliveira, Ricardo Linden, Luis Renato A. de A. Silva, Bruno L. da C. Fonseca

CEPEL - Centro de Pesquisas em Energia Elétrica

**Resumo—** Redes Neurais Artificiais são uma técnica de aprendizado de máquina que simula o funcionamento do cérebro humano, através da simulação de seus neurônios e de suas ligações. Elas apresentam uma inteligência emergente que tem aplicações em problemas complexos de diversas áreas. Neste artigo, fazemos uma pesquisa bibliográfica e apresentamos algumas aplicações no setor elétrico.

**Palavras-chave—** Redes Neurais Artificiais; Aprendizado de Máquina; Aplicações, Setor Elétrico.

## I. INTRODUÇÃO

A contínua evolução dos sistemas elétricos de potência vem exigindo o desenvolvimento de técnicas cada vez mais sofisticadas com o objetivo de garantir um funcionamento seguro e confiável. Este constante processo de automação faz com que os especialistas tenham que lidar com um volume crescente de informações, o que pode acarretar um impacto negativo nos objetivos de maior eficiência, disponibilidade e confiabilidade. Portanto, tarefas complexas, no planejamento, operação ou administração dos sistemas de potência, exigem maior sistematização, o que pode ser conseguido através do uso de ferramentas computacionais mais poderosas.

Estas características tornam bastante atraente a utilização de técnicas de Aprendizado de Máquina. De modo geral, estas aplicações visam incorporar o conhecimento humano ou sua simulação aos procedimentos automáticos dos centros de controle, proporcionando: ganhos de tempo na identificação e solução de problemas, na realização de estudos, etc.; redução de erros humanos; disponibilização do conhecimento de técnicos experientes para todos os operadores/engenheiros; automatização de procedimentos executados; entre outros.

A crescente complexidade e a constante mudança dos sistemas elétricos representam um grande desafio para as técnicas de Aprendizado de Máquina, pois exigem que seus algoritmos possuam a capacidade de uma aprendizagem contínua. Paralelamente, ocorre um grande aumento na quantidade de informação que tais sistemas terão que tratar,

armazenar e analisar para identificar o que será relevante para o problema a ser tratado. Técnicas de Mineração de Dados bem como novas infraestruturas de banco de dados deverão ser pesquisadas para possibilitar a transformação destes dados em informações relevantes.

Além disso, grande parte do conhecimento continua sendo privilégio de alguns especialistas, isto é, de pessoas capazes de tomar decisões a partir da lógica, heurística e até mesmo, intuição. Este problema torna-se mais crítico ao se considerar que o número de profissionais experientes tem diminuído cada vez mais ao longo dos anos. Com a aposentadoria destes, teme-se perder o conhecimento por eles armazenado.

O Cepel vem atuando, há mais de 30 anos, no desenvolvimento de sistemas utilizando Inteligência Computacional (especialmente Sistemas Especialistas, Lógica Fuzzy, Redes Neurais, Algoritmos Genéticos e Sistemas Multiagentes) em várias áreas de aplicação como processamento de alarmes, recomposição de sistemas, previsão de carga, diagnóstico de transformadores, diagnóstico de hidrogeradores, desligamento programado, identificação não invasiva de cargas elétricas residenciais entre outros.

Inúmeros problemas nos Sistemas Elétricos de Potência requerem o conhecimento de um especialista, que usualmente é capaz de resolvê-los bem melhor do que qualquer máquina que seja guiada por algoritmos tradicionais (não inteligentes). Esta característica torna atraente a utilização de técnicas de Inteligência Computacional em sua resolução, pois a forma de pensar do especialista poderia ser então devidamente simulada, auferindo resultados similares àqueles que foram atingidos pelo especialista humano.

As Redes Neurais são um campo de grande proeminência na área de inteligência computacional. Assim, elas têm recebido grande atenção e suas aplicações são amplamente disseminadas no setor elétrico em todo o mundo. Assim, vamos dar uma atenção maior a elas neste trabalho.

Para tanto, este artigo está organizado da seguinte forma. Na seção II, nós discutiremos os aspectos teóricos fundamentais das redes neurais. Na seção III, discutiremos algumas de suas aplicações. Finalmente, na seção V, nós apresentaremos algumas conclusões sobre o assunto e apontaremos algumas áreas de pesquisa relevantes na área.

## II. REDES NEURAIS ARTIFICIAIS

As Redes Neurais são um tema da computação altamente inspirada na natureza que nos cerca. Durante anos e anos os homens trabalharam para fazer computadores mais rápidos e mais potentes, mas apesar do seu incrível poder computacional estes computadores falhavam em fazer tarefas que uma criança de três anos faria imediatamente, como por exemplo, reconhecer uma pessoa ou aprender algo novo só com a experiência.

Apesar da ideia por trás ser bastante simples, a área de conhecimento relacionada às Redes Neurais cresceu e tornou-se incrivelmente diversa, com múltiplos tipos de Redes Neurais e de aplicações. Neste artigo, vamos discutir apenas o modelo mais popular, as redes neurais *feedforward*, mais conhecida pelo seu algoritmo de treinamento mais comum, o *backpropagation*. Vamos analisar suas principais características, explicando seu funcionamento, de forma a ficarem claros os principais conceitos e aplicações.

Com base na ideia de simular o cérebro humano em seu funcionamento e em suas potencialidades, os cientistas resolveram criar um modelo computacional que emulasse o comportamento do cérebro humano, fazendo um modelo que fosse análogo àquele de sua fisiologia. Para tanto, foram criados neurônios artificiais extremamente similares aos humanos, que foram interligados para formar redes que se mostraram capazes de fazer tarefas de cunho cognitivo e/ou criativo, antes restritas aos cérebros.

Assim, podemos definir uma Rede Neural como um processador maciçamente distribuído constituído de um grande número de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso.

Estas unidades de processamento simples inicialmente foram os neurônios artificiais definidos por McCulloch & Pitts em 1943, cujo aprendizado foi transformado em algoritmo por Charles Hebb em 1949. Como se pode ver, Redes Neurais não são uma área nova, já tendo pesquisa consolidada há muitas décadas.

Estes neurônios artificiais iniciais podem ser vistos lado a lado com seus pares naturais na figura 1. Como se pode ver, os elementos são extremamente simples e não apresentam qualquer tipo de complexidade de implementação. Existem outros tipos de neurônios, mais adequados aos vários tipos modernos de Redes Neurais existentes (o modelo da figura 1 é usado majoritariamente em uma rede conhecida como Rede Neural *feedforward*), mas todos são igualmente simples.

Entretanto, a utilização de um grande número de elementos em conjunto permite a formação de uma inteligência emergente capaz de resolver uma ampla gama de problemas complexos.

Note que esta inteligência é função do imenso tamanho da Rede Neural existente em nossos cérebros: nós nascemos com cerca de 100 bilhões de neurônios e cada neurônio pode se conectar com até 100.000 outros neurônios. Assim, existe toda

uma complexidade de processamento dentro do mesmo que pode ser alavancada para o aprendizado de coisas novas.

O cérebro se treina para realizar este aprendizado de coisas novas através de um processo chamado aprendizado por reforço. Cada vez que um impulso sensorial particular passa através de uma sequência de sinapses (as conexões entre os terminais do axônio e os dendritos), estas sinapses tornam-se mais capazes de transmitir o mesmo impulso da próxima vez. Assim, constituem-se os caminhos neurais (a sequência de sinapses) relativas àquele aprendizado.

As Redes Neurais artificiais tentam imitar este processo através da modificação dos pesos ( $W_i$ ) para que a rede "caminhe" para o aprendizado por reforço. Nas redes supervisionadas, onde o resultado da saída a partir das entradas é conhecido, o sinal  $y$  resultante é indicativo da modificação - isto é, se chegamos a um resultado indevido, então "pioramos" o peso, mas se chegamos ao resultado desejado, então nós o reforçamos. Nas redes não supervisionadas, onde o resultado da saída a partir das entradas não é conhecido, nós fazemos um trabalho de aprendizado por reforço praticamente igual àquele realizado pelo cérebro.

Na figura 1, os pesos na versão artificial são análogos às forças das sinapses que ligam os neurônios anteriores aos dendritos deste neurônio. O processamento de somatório e aplicação da função é similar àquilo que acontece no corpo (também chamado de soma) e a saída  $y$  é equivalente ao que sai por cada um dos terminais de transmissão.

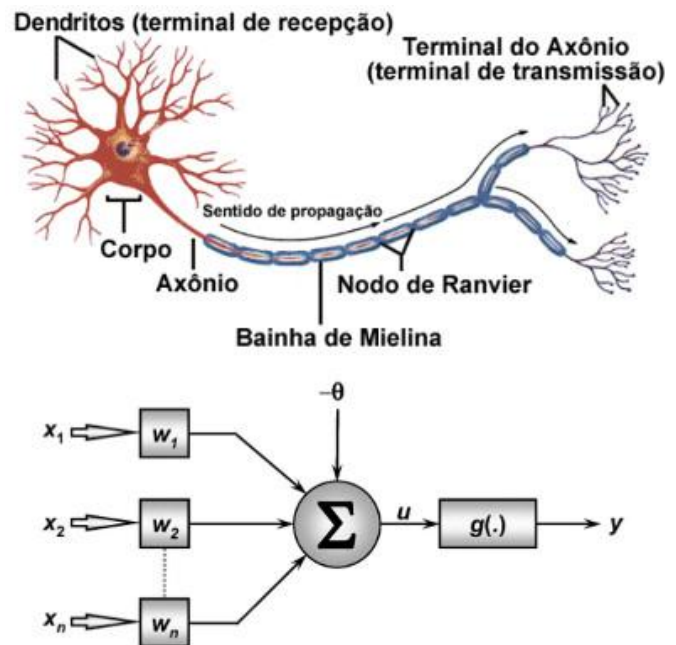


Figura 1 - Comparativo entre um neurônio real (acima) e um artificial (abaixo) [1].

Note-se que apesar de adiante nós apresentarmos as redes do tipo *backpropagation*, a maioria das redes existentes apresenta alguma similaridade conceitual com a Rede Neural *Feedforward*, especialmente no tocante ao funcionamento dos seus neurônios, não havendo nenhum problema maior para

reutilização da abstração aqui colocada. Esta similaridade permite que o conhecimento sobre a mesma possa ser extrapolado, ainda que de forma limitada, facilitando a compreensão de conceitos pertencentes a outros tipos de Redes Neurais.

Nos neurônios de McCulloch e Pitts, a "inteligência" está toda concentrada nos pesos, pois o neurônio opera sobre a soma ponderada das várias entradas, de acordo com as seguintes fórmulas:

$$u_k = \sum_{j=0}^m w_{kj} x_j \quad (1)$$

$$y_k = \varphi(u_k) \quad (2)$$

A fórmula (1) significa apenas que as entradas são apresentadas ao neurônio k e são multiplicadas cada um por um peso, sendo cada parcela desta multiplicação somada resultando em  $u_k$ . O resultado desta operação é chamado campo local induzido ou potencial de ativação do neurônio. A seguir é aplicada a fórmula (2), que indica que aplicamos uma função não linear (denominada função de ativação) a  $u_k$ , resultando na saída do neurônio (também denominada  $y_k$ ).

As funções de ativação mais usadas são majoritariamente não lineares e de comportamento relativamente simples. As versões não lineares buscam simular a ideia do funcionamento básico de um neurônio, que só gera saída (dispara, nos termos dos neurocientistas) se a soma dos seus estímulos exceder um nível pré-definido (o chamado *threshold* de ativação). As principais funções são mostradas na Figura 2.




Figura 2 - As principais funções de ativação usadas nas Redes Neurais artificiais [2].

As mais usadas encontram-se no quadrante inferior, e têm a vantagem sobre a função degrau de serem diferenciáveis e apresentarem um comportamento mais gradual nas regiões de transição ativação/não ativação, oferecendo maior nuance na

sua resposta. Uma simples inspeção visual permite ao leitor verificar que o comportamento mostrado pelas funções contínuas é qualitativamente similar àquele observado na função degrau. Dada a similaridade do resultado, a vantagem da gradualidade (que simula a realidade observada nos neurônios naturais) torna-se relevante, fazendo com que na maioria das vezes se escolham um destes dois tipos).

Uma vez definido o que é um neurônio, o próximo passo é entender a arquitetura das Redes Neurais que são formadas por um coletivo destes elementos. Existem duas arquiteturas principais, as arquiteturas em camada única (Figura 3a) e em múltiplas camadas (Figura 3b).




Figura 3 - Exemplos de arquiteturas possíveis de redes neurais artificiais [3].

Na Figura 3a vemos uma Rede Neural de camada única, cujas capacidades são extremamente limitadas. Já na Figura 3b vemos a mais simples das Redes Neurais de múltiplas camadas, aquela que possui uma única camada escondida, que já possui "inteligência" muito superior à versão de camada única, sendo capaz de resolver problemas com um grau de complexidade muito superior.

A versão de uma única camada é chamada de rede de perceptrons e praticamente não é usada, posto que Minsky e Papert provaram no final da década de 60 que este tipo de rede só conseguia classificar corretamente problemas linearmente separáveis. Isto inclusive atrasou o desenvolvimento da área até que Rumelhart, no início da década de 80, desenvolveu o algoritmo de Backpropagation para o treinamento de redes de múltiplas camadas, problema que, até então era considerado sem solução.

O algoritmo de Backpropagation, como o próprio nome diz, procura usar ("propagar") o erro da camada de saída para corrigir os erros das camadas anteriores, ou seja, retroação ou realimentação. Ele utiliza um mecanismo inteligente de cálculo para propagar os erros através das sinapses usando os pesos dos treinamentos, percorrendo assim a superfície de busca em busca dos mínimos locais.

Não cabe neste espaço discutir a matemática por trás do algoritmo. Entretanto, o processo está descrito de forma completa, inclusive com prova de convergência do mesmo que pode ser encontrada em [4].

A principal limitação deste algoritmo é a sua lentidão, mesmo cada passo sendo relativamente eficiente (é da ordem

do número de pesos em cada passo). Para não perder as variações do espaço de busca, o algoritmo o percorre de forma lenta.

Para acelerá-lo, na década de 90 passou a ser usado o que se convencionou chamar de termo de momento, que tem também a feliz característica de ajudar o treinamento a escapar de mínimos locais. Para tanto foram desenvolvidos dois algoritmos similares, mas muito mais velozes, denominados Quickprop e RProp, que chegavam a ser uma ordem de grandeza mais eficientes que a versão tradicional do Backpropagation.

Uma vez tendo estes algoritmos de treinamento, as redes deste tipo se popularizaram e, posto que usavam um grande conjunto de perceptrons organizados em camadas, passaram a ser conhecidas universalmente pelo nome de Multi Layer Perceptrons (MLP), nome este que permeia a literatura da área.

Mesmo sendo uma das técnicas mais antigas (ou talvez por causa disto), as Redes Neurais feedforward possuem ampla aplicação no setor elétrico, algumas das quais descreveremos na próxima seção.

### III. APLICAÇÕES

Uma das áreas de aplicação que costumam obter bons resultados é a área de previsão. Tendo em vista que as Redes Neurais conseguem compreender padrões a partir de dados relativamente "crus", elas podem entender muito da dinâmica subjacente aos dados e, por conseguinte, realizar um bom trabalho de extrapolação, gerando previsões relativamente confiáveis e precisas.

Souza et al. [5] implementaram e compararam o desempenho de duas redes neurais: FTDNN (Focused Time Delay Neural Network) e NARX (Nonlinear AutoRegressive model with eXogenous inputs) na predição das séries temporais de volumes úteis e vazões naturais relacionadas à Usina Hidrelétrica de Sobradinho. Ambas as redes são variações das redes MLP voltadas para a modelagem da dinâmica de processos. No caso específico, os autores utilizam dados mensais para prever, usando parâmetros explicados de forma esparsa e obtêm resultados que parecem capturar a dinâmica do volume útil de reservatórios, embora se percebam erros na previsão da série de vazões naturais.

Por outro lado, Milojkoviü et al [6] apresentou duas arquiteturas de Rede Neural Artificial para produzir previsões diárias de pico de carga de eletricidade e do horário em que ocorre o pico. Uma arquitetura foi chamada de *Extended Time Controlled Recurrent* (ETCR), inspirada no Time Delayed Recurrent ANN, e outra de *Extended Feed Forward Accomodated for Prediction* (EFFAP), sendo ambas extensões de soluções já implementadas com sucesso em outras áreas.

Note-se que o artigo acima usa uma versão de Redes Neurais (ETCR) que apresenta uma diferença substancial em termos arquiteturais em relação ao modelo que descrevemos acima, posto que a rede usada é recorrente e não *feedforward*. Como discutimos na parte teórica deste trabalho, não vamos

exaurir a teoria de Redes Neurais, pois os tipos existentes são muito diversos. Entretanto, este exemplo é extremamente valioso no tocante a esta questão, posto que ele usa neurônios do tipo McCulloch-Pitts. Isto é, apesar de ser distinta, esta arquitetura ainda apresenta similaridades estruturais consonantes com a descrição inicial que fizemos da área.

Rahman et al [7] propõem um sistema de previsão de geração de energia próxima ao consumo de eletricidade tomando como base os dados dos Estados Unidos, utilizando para isso uma análise *Big Data* com sistema distribuído de armazenamento Hadoop e algoritmo mapReduce em conjunto com *Machine Learning* (Artificial Neural Network com Backpropagation), de forma que sejam resolvidos problemas complexos de análise de grande massa de dados e seja elaborado um sistema preditivo efetivo.

Ainda que os resultados obtidos tenham sido expostos de maneira superficial e não permitam uma verdadeira avaliação da qualidade da previsão obtida, este artigo é interessante por mostrar que qualquer trabalho de análise de dados provenientes de grandes bases do setor elétrico (o chamado *Big Data*) deve conceber a existência de fases prévias de trabalho incluindo ferramentas de gerenciamento de grandes bases e de extração de dados das mesmas. Isto permite concluir que qualquer trabalho na área de *Big Data + Machine Learning* pressupõe a existência de uma ampla gama de habilidades que não podem ser supridas por uma única pessoa, mas provavelmente sim por um grupo de trabalho bem dimensionado com número e dedicação de tempo adequados.

A identificação de padrões é a característica das Redes Neurais que impele esta ampla aplicação na área de previsão de carga. Entretanto, ela pode ser usada em outros problemas também. Por exemplo, Souza et al. [8] procura realizar a caracterização das cargas elétricas, que oferece informações detalhadas sobre o uso residencial da energia elétrica, consistindo em uma das principais etapas do monitoramento não-intrusivo (NILM).

Os autores procuram extrair dos sinais de consumo de corrente as características de cargas elétricas semelhantes utilizando como metodologia para a extração de características das cargas elétricas a transformada MODWT (Maximal Overlap Discrete Wavelet Transform) e posterior aplicação de classificação das cargas usando Redes Neurais Autoencoder. O modelo de transformada é bem descrito, mas as redes neurais são pouco tratadas, ficando um pouco obscura a sua configuração e o seu uso.

Outro problema para o qual existe uma profusão de artigos que utilizam Redes Neurais é a determinação do fluxo de potência ótimo, que pode ser de grande complexidade quando lidamos com sistemas maiores e com alto grau de interligação e que descrevemos sem maiores detalhes a seguir.

Os sistemas de energia elétrica, operando em regime estacionário, estão sujeitos a restrições de carga, de operação e de segurança. A fim de simular o efeito de ações de controle de forma a manter a operação do sistema com o atendimento destas restrições ou determinar estratégias para retirar o sistema de uma situação indesejável, os operadores podem utilizar ferramentas de Fluxo de Potência ou, no caso de

determinação de estratégias de controle corretivo, ferramentas de Fluxo de Potência Ótimo.

Efe et al. [9] propõem o uso de uma MLP extremamente tradicional para o cálculo de fluxo de carga de uma rede elétrica simples utilizando *Backpropagation*. Os resultados são bastante satisfatórios levando em consideração sua aplicabilidade em clientes que não possuem o modelo elétrico de sua rede, visto que o algoritmo usa como entrada apenas os dados de injeção de potência líquida nas barras para o cálculo das saídas (tensões complexas nas barras).

Imen et al. [10] propõem a utilização de uma RNA a fim de resolver o problema de Fluxo de Potência Ótimo (FPO) e compara este método ao método convencional utilizando o sistema IEEE 30-bus. O FPO convencional utilizado é o do Power World Simulator, que utiliza o método de Newton-Raphson.

Uma das maiores vantagens segundo os autores é a redução do tempo de execução mantendo uma boa relação custo/benefício no que diz respeito à precisão dos resultados. Entretanto, a diferença apontada pelos autores é de 4s para o método tradicional versus 2s para o método neural. Esta diferença não se mostra significativa mesmo que sejam necessários cálculos periódicos ao longo do dia, pois as variações não são tão abruptas que requeiram recálculos com periodicidade tão pequena. Ademais, os autores não discutem a necessidade de retreinamento da Rede Neural, nem a periodicidade do mesmo.

Canyasse et al [11] faz um trabalho relativamente similar àquele colocado no artigo anterior. Assim como os autores em [10], estes buscam um método alternativo para calcular o FPO de forma mais veloz, sem acarretar em perda de precisão. Os autores usam modelos relativamente grandes (IEEE RTS-79 e RTS-96) para analisar o verdadeiro desempenho de três diferentes métodos, incluindo Redes Neurais, Árvores de Decisão e *Random Forests*.

Os autores encontraram resultados muito favoráveis às Redes Neurais, que classificaram a viabilidade corretamente em cerca de 99% dos casos (contra 80% do método naïve), com erro de 0,85% (contra valores superiores a 2,85% no caso da regressão linear) e uma capacidade de adaptação a novos dados que superou em muito os outros métodos.

Este exemplo demonstra uma das características interessantes de Redes Neurais, que é a capacidade de generalizar. Os próprios autores afirmam que "(...) as duas últimas técnicas (métodos Gaussianos e Redes Neurais) parecem ser extremamente adequados para computar este custo em situações reais, sendo capazes de generalizar bem quando recebem novos dados".

Existem várias outras aplicações possíveis de Redes Neurais ao setor elétrico. Farias et al. [12], por exemplo, propõem uma metodologia para localização de faltas monofásicas (proposição de rede rural) utilizando apenas os parâmetros de rede e medidas de corrente e tensão na subestação, não precisando de instalação de nenhum equipamento de medição adicional. A principal proposta do artigo é modelar uma barra e usar Redes Neurais para estimar os parâmetros faltantes nas equações que modelam o comportamento do alimentador durante as faltas. O trabalho também avalia a influência da

corrente de curto na determinação da localização da falta, mas não indica com clareza o quão fácil seria replicar o modelo colocado para outras topologias. Isto é, é difícil de dizer algo sobre a extrapolação deste método para outras situações reais.

Existem outros trabalhos que também pensam no problema de localização de faltas. Festa et al [13], por exemplo, procura resolvê-lo baseando-se na utilização de Redes Neurais artificiais *feedforward* do tipo Perceptron Múltiplas Camadas utilizando MATLAB. O artigo traz uma contribuição interessante sobre a questão de localização de sensores para otimizar a alocação de informações, ideia esta que talvez seja mais interessante que o próprio método inteligente. Neste trabalho, propõe-se uma metodologia utilizando duas Redes Neurais diferentes. A primeira para determinar a área que envolve uma situação de curto-circuito (RN1), e, a partir desta, executar a classificação quanto ao tipo da falta (RN2). Assim como outros artigos de detecção de faltas, o artigo se limita a indicar áreas de falta, que englobam um grande número de barramentos.

Outra área de aplicação que pode ser de grande valia é a de planejamento energético, que inclui o conceito de antecipar demanda ou a qualidade do sistema elétrico em um horizonte qualquer (curto ou não). A similaridade conceitual desta ideia com a aplicação de previsão deveria ser suficiente para nos demonstrar que seria possível utilizar Redes Neurais também nesta aplicação.

Haseltine et al. [14] utilizam Redes Neurais para esta tarefa. Este estudo concentrou-se na avaliação de uma Rede Neural como uma ferramenta para análise pré-evento de uma rede elétrica para determinar se é suscetível a falhas, determinar áreas de interesse e prever o seu desempenho para futuras condições do sistema. O artigo tem algumas limitações, mas mesmo assim serve como uma demonstração de que é possível aplicar Redes Neurais nesta área relevante.

Uma aplicação que tem se mostrado extremamente interessante para o setor elétrico em geral é a análise de dados de PMU (Phasor Measurement Unity, ou UMF – Unidade de Medição Fasorial). Estes dados são abundantes e oferecem uma ampla gama de informações sobre o sistema elétrico, podendo ser minerados para obter novas informações e novos insights sobre o funcionamento do sistema.

Zarzosa et al [15] apresentam uma metodologia de classificação de eventos do SIN (Sistema Interligado Nacional) baseada em RNAs que utiliza dados das UMFs do projeto MedFase Brasil (Baixa tensão) e MedFase CTEEP (Alta tensão). O uso de Redes Neurais *feedforward* neste tipo de aplicação tem sido relativamente raro, sendo que a maioria dos artigos usa Redes Neurais mais modernas como, por exemplo, *Deep Learning* ou Aprendizado Profundo.

O uso de redes mais modernas se justifica pela tentativa da maioria dos trabalhos de tentar fazer uma mineração completa nos dados de PMU. Já este artigo utiliza uma abordagem limitada que visa encontrar apenas eventos de acordo com determinados perfis de carga definidos a priori. Os resultados apresentados elencam apenas dois tipos de eventos: perda de geração e rejeição de carga, porém aparentemente é possível utilizar o mesmo produto para classificar também desligamentos de LTs e oscilações sistêmicas. A conclusão da

expansibilidade do método deriva da extensa introdução que mostra os perfis de outras situações, permitindo ao leitor concluir que a rede poderia, se devidamente treinada, compreender estas outras situações.

Ainda na área de planejamento energético, pode-se ver que existem artigos que usam Redes Neurais para avaliar a segurança de tensão. Como eles fazem previsão também, poderiam ter sido enquadrados nesta área geral, mas como o objetivo principal do artigo não é a previsão em si, criamos esta área adicional na qual sua análise foi colocada.

Marujo et al [16] apresentam uma metodologia para análise da segurança operativa de sistemas elétricos de potência, verificando a margem de carga, que no caso do artigo é definida como a quantidade de carga que pode ser adicionada ao ponto de operação até o ponto de colapso. A margem de carga é determinada através do método da continuação. O comportamento da carga é previsto utilizando uma técnica híbrida baseada em Lógica Fuzzy (Lógica Difusa ou Nebulosa) e Redes Neurais. A partir deste comportamento, ele verifica se estourou a margem de carga e com isso, comprometeu a segurança operativa do sistema.

Esta seção não se propõe a ser uma lista exaustiva de aplicações. Outras aplicações são possíveis. Veras et al. [17], por exemplo, aplicam Redes Neurais Artificiais para obter o diagnóstico da qualidade do óleo isolante de transformadores de potência a partir das concentrações dos gases dissolvidos nesse óleo. A área de manutenção oferece outras possibilidades. Por exemplo, Praxedes et al. [18] relatam o início do trabalho de criação de uma ferramenta de auxílio à manutenção e à operação de usinas hidrelétricas através da detecção, diagnóstico e possível previsão de falhas em tempo real.

Deve ficar claro neste momento que existem muitas outras aplicações, mas que as Redes Neurais têm um imenso potencial para ajudar as empresas do setor elétrico a resolver vários dos problemas complexos que elas são obrigadas a enfrentar em seu cotidiano.

#### IV. CONSIDERAÇÕES FINAIS

O setor elétrico tem múltiplos problemas difíceis, que costumam apresentar grande dificuldade para as técnicas tradicionais, necessitando de técnicas capazes de lidar com grande volume de dados e/ou grande complexidade.

Neste sentido, as Redes Neurais podem ser de grande valia, dada a sua capacidade inerente de lidar com padrões complexos que costumam passar despercebidos por técnicas mais tradicionais.

Neste artigo, mostramos que existe uma ampla gama de aplicações para as Redes Neurais, mesmo que nossa lista de aplicações nunca tenha se proposto a ser exaustiva.

Entretanto, o volume de dados aumenta a cada dia, assim como a complexidade do problema. Por isto, a tendência dos trabalhos mais atuais é utilizar Redes Neurais modernas, como redes paraconsistentes, redes de aprendizado profundo e redes convolutivas.

Todas estas fogem ao escopo deste trabalho, que se propõe a ser apenas uma introdução aos problemas em si e à aplicação das Redes Neurais em sua solução. Entretanto, o leitor interessado deve considerar aprendê-las e aplicá-las.

#### REFERÊNCIAS

- [1] "Perceptron – Redes Neurais", Site da Internet, disponível no endereço dado por <https://www.monolitonimbus.com.br/perceptron-redes-neurais/>, último acesso em 25/06/2019.
- [2] Sousa, R. M., "Avaliação da Predição de Algoritmos de Treinamento Supervisionado de Redes Neurais Artificiais Aplicado a Qualidade de Biodiesel", Dissertação de Mestrado em Engenharia Elétrica, UFMA, Fevereiro de 2015, São Luis/ MA, Brasil.
- [3] Conti G., Wiggers K. L., Ribeiro, S. R. A.; "Representação em Malhas 3D a partir de dados de textura do solo interpolados mediante Rede Neural Artificial: Estudo de caso FESCON - Ponta Grossa – PR ", Geo UERJ, n. 28, p. 410-429, Agosto de 2016, Rio de Janeiro/RJ, Brasil.
- [4] Hayki, S.; "Redes neurais: Princípios e Práticas", 2a Edição, Ed. Bookman, Porto Alegre/RS, Brasil, 2003
- [5] Souza, S. P. M.; de Menezes Júnior, J. M. P.; "Predição de séries temporais do Reservatório da Usina Hidrelétrica de Sobradinho através de redes neurais recorrentes NARX", XIV SEPOPE, Outubro de 2018, Recife/PE, Brasil.
- [6] Milojkoviü, J.; Litovski,I.; Litovski, V.; "ANN Application for the Next Day Peak Electricity Load Prediction", 11th Symposium on Neural Network Applications in Electrical Engineering, September 2012, Belgrade, Serbia.
- [7] Rahman, M. N.; Esmailpour, A.; Zhao, J; "Machine Learning with Big Data An Efficient Electricity Generation Forecasting System", Elsevier: Big Data Research - Volume 5, September 2016.
- [8] Souza, R.P; Resende,C.Z.; et al.," Identificação não Intrusiva de Cargas Elétricas usando a transformada MODWT e Rede Neural AUTOENCODER" XXII Congresso Brasileiro de Automática, Setembro de 2018, João Pessoa/PB, Brasil.
- [9] Efe, S. B., Cebeci, M. . Power Flow Analysis by Artificial Neural Network. International Journal of Energy and Power Engineering. Vol. 2, No. 6, 2013, pp. 204-208. doi: 10.11648/j.ijpe.20130206.11
- [10] Imen, L.; Djamel, L.; Hassiba, S. et al.; "Optimal Power Flow Study Using Conventional and Neural Networks Methods", 4th international conference on renewable energy research and applications, Palermo, Italy, 2015

- [11]Canyasse, R; Dalal, G.; Mannor, S.; "Supervised Learning for Optimal Power Flow as a Real-Time Proxy", 2017 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT), Washington, EUA, 2017
- [12]Farias, P. E. ; Morais A. P. D., Cardoso Junior, G. et al; "Fault Location in Distribution Systems: A Method Considering the Parameter Estimation Using a RNA Online", IEEE LATIN AMERICA TRANSACTIONS, Dezembro 2016
- [13]Festa, A.V.; Kempner, T.R. et al., "Diagnóstico de Falhas em um Sistema de Distribuição Subterrâneo Utilizando Redes Neurais Artificiais", XX Congresso Brasileiro de Automática, Setembro de 2014 Belo Horizonte/MG, Brasil.
- [14]Haseltine, C.; El-Sheikh, E.; "Prediction of Power Grid Failure using Neural Network Learning", 16th IEEE International Conference on Machine Learning and Applications, Cancun, Mexico, 2017.
- [15]Zarzosa, M.; Zimmer, V.; Decker, I. C.; "Classificador de Eventos no SIN baseado em Redes Neurais Artificiais e Sincrofasores", VI Simpósio Brasileiro de Sistemas Elétricos, Natal/RN, Brasil, 2016
- [16]Marujo D.; Santos M.V.; et al., "Avaliação de Segurança de tensão considerando uma técnica híbrida de previsão de carga", XXIII SNPTEE, Outubro de 2015, Foz do Iguaçu/PR, Brasil.
- [17]Veras, G.V.O.; Souza, L.G.M. et al., " Diagnóstico da qualidade do óleo isolante de transformadores de potência a partir da concentração de gases dissolvidos", XIII SBAI, Outubro de 2017, Porto Alegre/RS, Brasil.
- [18]Praxedes A.B.V. ; Alvares, A.J.," Monitoramento Inteligente de Equipamentos em Usinas Hidrelétricas usando Mensagens SV IEC61850 e Redes Neurais Artificiais Paraconsistentes", XI SIMPASE, Agosto de 2015, Campinas/SP, Brasil.