DOI: 10.48011/sbse.v1i1.2487

Identificação de Topologia de Sistemas de Distribuição de Energia Elétrica por Métodos de Aprendizagem Inteligentes

Nabeyama G. N. D.*. Asada E. N.*, Matrakas M. D.**

**Universidade de São Paulo, Escola de Engenharia de São Carlos, Departamento de Engenharia Elétrica. Brasil (Tel: 55 16 33738706; e-mails: nabeyama@msn.com, easada@usp.br).*
***Centro Latino-Americano de Tecnologias Abertas, Parque Tecnológico de Itaipu Brasil (Tel: 55 45 3576.7200; miguel.matrakas@pti.org.br)*

Abstract: The identification of the topology of electric power networks is a problem for the operation of electrical systems, topological errors affect applications such as contingency analysis, power flow estimation, etc. Distinguishing the way the lines are connected in distribution systems becomes even more complex, as changes are frequently made. The topology characterization can be considered a pattern recognition problem, since the voltages and power flows have a direct link with the structure in which the lines of a network are interconnected, that is, changes in these connections change the condition that currents flow through the network. With the progress in the processing capacity of computers and the large amount of information available, machine learning is greatly favored. The objective of this work is to apply artificial intelligence techniques to recognize the topology of distribution systems based on information from analog measurements. Tests were performed, based on the IEEE 33-bus distribution system, to retrieve information from the lines with the absence of part of topological data and data from analog measurements. The neural network was able to successfully retrieve information and return the topology of the distribution network.

Resumo: A identificação da topologia de redes de energia elétrica é um problema para operação de sistemas elétricos, erros topológicos afetam aplicações como análise de contingencias, estimação do fluxo de potência, etc. Distinguir a forma de ligação das linhas em sistemas de distribuição torna-se ainda mais complexo, pois alterações são executadas frequentemente. A caracterização topologia pode ser considerado um problema de reconhecimento de padrões, dado que as tensões e fluxos de potência tem um vínculo direto com a estrutura em que as linhas de uma rede estão interconectadas, ou seja, alterações nessas conexões alteram a condição com que as correntes fluem pela rede. Com o progresso da capacidade de processamento dos computadores e a grande quantidade de informações disponíveis, a aprendizagem de máquina é bastante favorecida. O objetivo deste trabalho é aplicar técnicas de inteligência artificial para reconhecer a topologia de sistemas de distribuição a partir de informações de medições analógicas. Foram realizados testes, com base no sistema distribuição IEEE 33 barras, para recuperação das informações das linhas com ausência de parte de dados topológicos e dados das medições analógicas. A rede neural foi capaz de recuperar informações e retornar a topologia da rede de distribuição com êxito.

Keywords: neural network, autoencoder, topology identification, distribution system, artificial intelligence.

Palavras-chaves: rede neural, auto associativa, identificação de topologia, sistema de distribuição, inteligência artificial.

1. INTRODUÇÃO

A energia elétrica se tornou algo indispensável para sobrevivência humana. Quando um consumidor tem seu fornecimento interrompido, mesmo que seja por alguns minutos, diversos problemas podem ocorrer.

A infraestrutura elétrica atual foi projetada há mais de 50 anos (Khan et al, 2009), assim, novos avanços tecnológicos em áreas como computação e comunicação favorecem a atualização da infraestrutura do sistema de distribuição atual.

Com o aumento da demanda de carga e o crescimento da geração distribuída, existe a necessidade da atualização das redes tradicionais para modelos mais interativos e/ou inteligentes (Gao, Redfern, 2011).

Dentre as diversas informações relevantes para operação, o conhecimento da topologia é de grande importância. Esta, é determinada pela condição de chaves e disjuntores, que indicam qual linha está conectada e a o que. Um equívoco nesses dados pode resultar em erros topológicos que consequentemente causariam uma inexatidão nas aplicações

baseadas em rede, como estimativa de estado, análise de contingências e fluxo de potências (Clements, Costa, 1998).

Em redes de distribuição, mudanças na topologia da rede ocorrem com bastante frequência, podem sofrer alterações sem a devida comunicação ou cadastro. Por se tratar de um sistema grande e bastante complexo, muitas vezes alterações passam despercebidas ou são difíceis de localizar a informação incorreta por meios convencionais. A instalação de sensores, para identificação da topologia, também poderia ser algo inviável, devido ao custo de implantação no sistema.

As principais formas de identificação da topologia de sistemas de distribuição são os registros originais do sistema de informações geográficas e inspeções manuais. Como as conexões das linhas são frequentemente alteradas e reconfiguradas, existem informações desatualizadas, que consequentemente geram erros na topologia. Outro problema é quando em grande número as linhas subterrâneas podem tornar a inspeção manual muito mais complexa.

Em um erro topológico, a sua detecção e identificação pode ser interpretada como sendo um problema de duas pontas. Por um lado, a solução analítica do problema exige uma alta demanda em termos de recursos computacionais, além de ser necessária a convergência da resposta e é inapropriado para aplicações em tempo real.

Por outro lado, um engenheiro experiente em sistemas de potência poderia identificar o erro topológico apenas observando os diagramas das estações para as condições de pré-comutação e pós-chaveamento. Ou seja, pode-se supor que a identificação ou a verificação da topologia pode ser considerada como um problema de reconhecimento de padrões (Lukomski, Wilkoz, 2003).

A topologia da rede elétrica é refletida dentro do conjunto de dados dos valores de tensão, potência ativa e reativa, deste sistema, e que os estados dos disjuntores ou chaves seccionadoras condicionam ou reconfiguram as soluções das Leis de Kirchoff, ou seja, descrevem as relações entre as variáveis elétricas. Assim, uma mudança no estado de uma chave, são definidas novas equações e o conjunto de equações terá uma nova solução. Uma das formas de diagnosticar as situações descritas anteriormente em uma estrutura automatizada é por meio de técnicas de aprendizado de máquina.

As técnicas baseadas em aprendizado de máquina têm como objetivo principal desenvolver um método que entenda automaticamente os dados, ou seja, ser possível prever uma saída utilizando informações brutas como entrada. A máquina é capaz de aprender por esses dados da entrada e consequentemente fazer uma previsão (PALA et al, 2017).

O aprendizado de máquina, hoje, conquistou a indústria, ela é basicamente o coração, ou melhor, o cérebro, de muitas companhias tecnológicas de ponta. Seja no sistema de busca na web, no reconhecimento de voz dos smartphones, recomendações e anúncios, e mais recentemente até dirigindo carros.

Outra aplicação de redes inteligentes é para a reconstrução de sinais, em que as informações são perdidas ou estão incompletas. Para esse tipo de abordagem, o treinamento da máquina, é focado em aprender uma variedade específica de informações, implícitas em um conjunto de dados.

Neste trabalho, o problema da identificação da topologia de redes de energia elétrica de distribuição será abordado com a aplicação de aprendizado de máquinas. Este artigo relata a implementação de uma variação da metodologia da utilização de uma rede neural auto associativa que é capaz de aprender a relação entre as informações disponíveis, pelos sistemas elétricos de potência, para determinar como as barras e as linhas estão conectadas. Testes, utilizando o sistema de distribuição do IEEE 33 barras, foram realizados afim de verificar a eficácia da rede neural neste tipo de topologia. Para avaliar a qualidade do aprendizado foram analisados os erros médios entre os valores retornado pela máquina e a quantidade de linhas corretamente estimadas.

O artigo está organizado da seguinte forma: a Seção 2 apresenta uma revisão a respeito da identificação de erros topológicos, a Seção 3 descreve a rede neural utilizada neste trabalho, a Seção 4 demonstra a modelagem do sistema proposto, a Seção 5 mostra a metodologia dos testes aplicados, na sequência na Seção 7 são comentados os resultados, e por fim na Seção 7 são apresentadas as conclusões.

2. IDENTIFICAÇÃO DE ERROS DE TOPOLOGIA EM REDES DE ENERGIA ELÉTRICA

As pesquisas relacionadas na área de identificação de erros topológicos vêm desde o fim dos anos 70 e início dos anos 80. Lugtu et al (1980) apresentaram uma metodologia simples e rápida no pós-processamento dos resultados, seu método reduz a necessidade de realizar novamente o teste de pós-processo das injeções das barras suprimidas. Contudo, essa estratégia é limitada apenas em um nível de linhas duvidosa.

Outra proposta é o trabalho de Clements e Davis (1988) que explora as informações contidas nos resíduos da estimação de estados. Com esse processo, verificou-se que os vetores residuais decorrentes de erros de topologia devem ser colineares com o produto da matriz de sensibilidade residual com a matriz de incidência de medição para ramo.

Em 1991, no trabalho de Alves da Silva et al, foi proposto a utilização de rede neural para determinação da topologia de sistemas de potência. Seus treinamentos apresentaram 97% de acerto para uma dada topologia, onde possuía apenas informações corretas. Porém ao injetar dados ruins ou incorretos a precisão da rede caiu para 20%. Além disso a rede só conseguiu reconhecer padrões de apenas 18 casos específicos.

O trabalho de Kumar et al (1996) utilizou redes neurais para o processamento de topologias e erros de medição para sistemas de monitoramento em tempo real. Sua pesquisa foi baseada em modelos de rede neural de contra propagação (CPN) e ligação funcional (FLN), focado em identificar a topologia da rede e estimar o estado da rede.

Lukomski e Wilkosz (2003), consideraram que a topologia era um problema de reconhecimento de padrões. Utilizaram uma rede neural do tipo retro propagação resiliente (RPROP), cujo

modelo de neurônio retornou a melhor estimativa. Posteriormente em 2007 apresentaram uma nova abordagem baseada em rede de função com base radial e índices de desbalanceamento, que em 2009 foi aperfeiçoada com as técnicas de reconhecimento de padrões.

Os trabalhos mais recentes a respeito de inteligência artificial para solução desse tipo de problema são de Miranda et al (2012) e de Krstulovic et al (2013), nas quais são exploradas a utilização de redes neurais do tipo auto associativas para identificar a topologia, mesmo na falta de informações nas medições elétricas.

Em 2018, Oliveira et al. utiliza a metodologia de redes neurais profundas para estimar o estado das chaves seccionadoras, incluindo testes onde ocorrem faltas de informações. Essa pesquisa considera que a topologia é um reflexo das suas variáveis elétricas.

3. REDES NEURAIS ARTIFICIAIS

Os neurônios dentro do cérebro enviam e recebem informações através de reações eletroquímicas, essas reações são responsáveis pelo cérebro apender, interpretar e processar os dados que chegam até ele.

As pesquisas na área de inteligência artificial têm mais de 50 anos, durante esse período diversas estratégias e modelos de neurônios foram e ainda são implementadas.

A arquitetura explorada neste trabalho é a rede neural auto associativa. Este modelo de configuração de neurônios artificiais utiliza algoritmos não supervisionado de aprendizagem que aplicam retropropagação, de forma que os valores de saída sejam iguais aos valores de entrada.

As redes auto associativas tem como objetivo fundamental aprender uma função que aproxime o valor estimado pela rede com o valor da entrada, a rede realiza esse trabalho codificando, comprimindo eficientemente os dados e é capaz de aprender a reconstruí-los a partir das informações reduzidas. Essa arquitetura é utilizada para aprender a codificar de forma bastante eficiente e não supervisionada um conjunto de dados (Liou, 2014).

De forma geral, a rede auto associativa, por definição, reduz a dimensão dos dados da entrada ignorando informações que a rede julga desnecessárias.

A estrutura desta rede é separada em um codificador, composto pela camada de entrada mais a camada oculta, e um decodificador, formado pelo conjunto da camada oculta e a camada de saída. Também é possível utilizar o conceito de aprendizagem profunda em redes auto associativas, dessa forma tem-se mais camadas ocultas na estrutura da rede como um todo.

4. MODELAGEM DO PROBLEMA

O problema a ser tratado será o de identificar a topologia de uma rede de distribuição, onde possíveis anomalias, como por exemplo erros topológicos ou falta de dados, nas informações possam ser detectadas e suprimidas.

O sistema implementado para treinamento é baseado no caso IEEE 33 barras para sistemas de distribuição, na Figura 1 é ilustrado a configuração das barras. As potências e os parâmetros de linhas são os mesmos utilizados no modelo proposto por Wazir, Arbab (2016).

São simulados casos para diferentes condições topológicas e de potências, assim produzindo um volume grande de informação para gerar a base de dados que será utilizada no treinamento da rede neural.

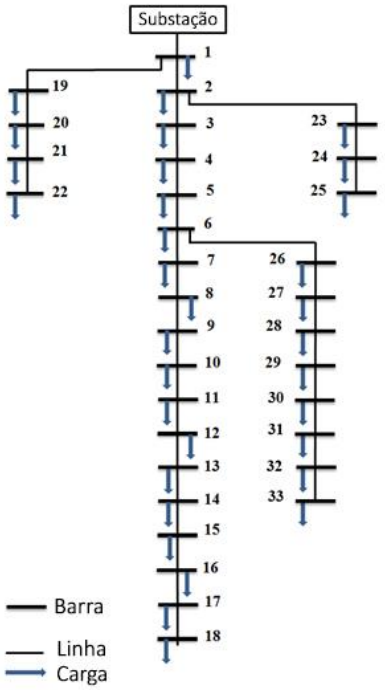

Fig. 1 Ilustração do Sistema de Distribuição do IEEE 33 Barras.

Na figura 2 é ilustrado um diagrama de blocos do procedimento de formação de uma linha da base de dados, esse processo é repetido para todos os diferentes casos.

Assim a base de dados é gerada pelas simulações do IEEE 33 Barras para 100 casos diferentes com a variação da potência nominal em 10% com uma distribuição normal e abertura de uma linha por vez. Assim a base de dados possui 3,3 mil casos distintos para treinamento da rede neural.

As informações observadas em cada teste, ou seja, a composição de cada uma das linhas da base de dados, consiste em:

- 33 elementos referente ao módulo de tensão
- 32 elementos de carga ativa
- 32 elementos de carga reativa
- 32 elementos de referente ao estado da linha (topologia)

O estado de cada linha é representado por um valor binário, pois ela está ou aberta ou fechada, assim para não prejudicar o desempenho da rede neural, na presença de dados nulos ou ausentes de topologia ou de medições, foi arbitrado os valores de 1 para linha fechada e -1 para linhas abertas.

Os valores de módulo de tensão são valores por unidade e as medidas de potência são kW e KVar.

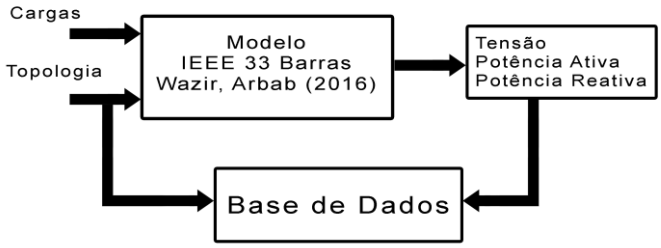

Fig. 2 Diagrama de blocos para geração da base de dados.

5. METODOLOGIA DE TESTES

A implementação da rede neural foi baseada no aplicativo Tensorflow, uma plataforma de código aberto de ponta a ponta para trabalhar, principalmente, com aprendizado de máquina. Ele possui um sistema com ferramentas abrangentes e flexíveis, bibliotecas e recursos, que são alimentados e desenvolvidos pela comunidade, permitindo que os pesquisadores promovam o estado da arte em aprendizado de máquinas e que os desenvolvedores criem e implemente mais aplicativos com esse progresso.

A estrutura da rede neural é baseada em uma rede auto associativa, ou seja, o número de neurônios da camada de saída deve ser igual a sua entrada, para assim conseguir na primeira parte codificar as informações na camada oculta e posteriormente decodificar na saída.

Assim a rede implementada consta com 129 neurônios de entrada e, consequentemente, 129 neurônios de saída, visto que, não existe uma forma de estimar quantos neurônios são necessários, ou qual é a quantidade mais eficaz, foram arbitrados 97 neurônios para a camada oculta.

Os valores escolhidos foram consequência de experimentos, no qual foi observado tanto a velocidade de treinamento e a qualidade da resposta, os testes que mostraram resultados melhores, foram com os valores utilizados neste trabalho.

Pela característica dessa rede neural, os elementos da entrada devem estar totalmente conectados com a camada oculta, assim como a camada oculta deve estar completamente interligada com a camada de saída. Na Figura 3 é ilustrada a rede neural desenvolvida.

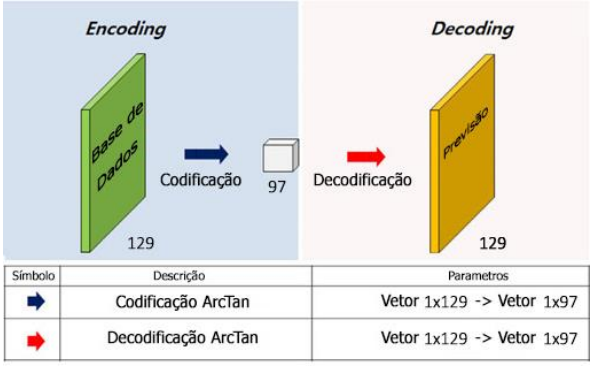

Fig. 3 Rede Neural Auto Associativa Implementada

A função de ativação que foi utilizada é o arco tangente, tanto no codificador como no decodificador. Essa função de ativação foi utilizada pelas suas características de não-linearidade e por retornar os valores com menor erro e menor tempo de treinamento.

A segunda parte, porém, não menos importante, é a função que garante a retro propagação da rede, ou seja, a função que calcula o custo da rede. A métrica selecionada foi a do erro médio absoluto, juntamente com o otimizador de Adam (Kingma, Ba, 2015).

Este otimizador é baseado em gradientes de funções objetivos estocásticos, além de responder muito bem em problemas com gradiente muito ruidosos ou esparsos

O erro médio absoluto fornece a informação do sinal do erro, negativo ou positivo, que não é fornecido pelo erro médio quadrático, assim para entregar a estimativa da topologia, onde existem valores negativos, o erro médio absoluto retornou resultados melhores.

Para uma melhor investigação dos resultados, os testes foram divididos em duas partes: A primeira consiste em recuperar informações da topologia da rede quando uma ou mais informações de topologia está ausente. A segunda consiste em verificar se, mesmo com ausência de medições, a rede consegue estimar a topologia de forma correta.

Dessa forma a primeira série de testes limita-se em manter as informações de medições elétricas (tensão e potência), e remover somente informações da topologia do sistema. Foram removidas até 8 informações de linhas, de casos aleatórios que não fazem parte da base de dados do treinamento, ou seja, foram simulados novos casos, mantendo os parâmetros mencionados na seção anterior, para validação da rede neural.

Os testes seguintes consistiram em remover informações das medições elétricas do caso de testes. Neste momento foram removidos até 6 valores de tensão, posteriormente 20 valores de potencias ativas e 20 de potencias reativas, realizados em duas situações, individualmente e, em seguida, ao mesmo tempo.

Para cada uma das séries de testes foram testados 100 casos e verificados os erros entre o valor estimado e o valor de entrada, com arquitetura de rede neural auto associativa utilizando a função de ativação arco tangente e um otimizador Adam com taxa de aprendizagem de 0,001 e por 50 mil épocas de treinamento.

Para validação foi considerado duas abordagens, a primeira é a quantidade de topologias estimadas corretamente e a segunda é o valor do erro médio entre os valores estimados e a entrada da rede neural.

6. RESULTADOS

Nas subseções seguintes são apresentados os resultados.

8.1 Ausência de Dados Topológicos

Neste teste o objetivo é verificar qual a interferência da falta de dados topológicos no vetor de entrada da rede neural. Ela

foi capaz de recuperar informações da ausência de elementos da topologia nos casos até 6 dados de linha faltantes.

Foram considerados corretos somente se os dados estimados de topologia possuíssem mais de 80% de chance de a linha estar aberta ou fechada, em todos as informações linhas estimadas, dessa forma na Tabela 1 a seguir estão apresentados os resultados das estimações de 8 casos nos quais existem as faltas de informações da topologia da rede.

Tabela 1. Resultado dos Testes com Falta de Informações da Topologia

Número de Dados Ausentes	Quantidade de Estimações Corretas	Erro Médio	Erro Médio da Estimação das Linhas Ausentes
1	100	1,78%	4,89%
2	100	2,04%	5,87%
3	100	2,68%	6,30%
4	100	1,49%	6,81%
5	100	1,41%	6,93%
6	98	1,35%	7,028%
7	94	2,67%	9,524%
8	27	4,19%	33,80%

As linhas removidas nos testes apresentados na Tabela 1 são: 6-7, 15-16, 3-4, 23-24, 31-32, 16-17, 3-23 e 6-26.

8.2 Ausência de Medições Analógicas

A segunda parte consiste em analisar o efeito da falta das medições de tensão e potências na entrada da rede neural. Da mesma forma que o teste anterior, foram considerados corretos os dados estimados com 20% de erro.

Na Tabela 2 estão compilados os resultados das estimações removendo até 5 valores de tensão do vetor de entrada da rede neural.

A última seção de testes realizada, removendo as informações de potência ativa e potência reativa, não causou nenhum problema com a recuperação da topologia. Em todos os casos testados o erro foi inferior a 1% e todas as estimações estavam corretas.

Tabela 2. Resultados dos Testes com Falta de Informações de Tensão

Número de Dados Ausentes	Quantidade de Estimações Corretas	Erro Médio	Linha Estimada com Maior Erro
1	99	1,65%	3-23
2	52	3,87%	3-23
3	95	1,81%	21-22
4	90	1,11%	17-18
5	82	1,04%	15-16
6	3	11,05%	28-29

As linhas removidas nos testes apresentados na Tabela 2 são: 5-6, 23-24, 31-32, 2-19, 9-10 2 16-17.

7. CONCLUSÃO

O avanço das tecnologias nos últimos anos, em relação às redes elétricas inteligentes e o aprendizado de máquinas tem sido muito intenso, seja pelo aparecimento cada vez mais frequentes da utilização da geração distribuída ou pelo progresso da capacidade de processamento dos computadores, tudo isso junto com a ampla capacidade de informações existentes.

Ao mesmo tempo que esses avanços motivam novas possibilidades, os recursos energéticos distribuídos também trazem grandes desafios para a operação dos sistemas, como por exemplo sobrecarga, sobre tensão ou desequilíbrio de tensão. Dessa maneira a necessidade do conhecimento da topologia clara e correta é fundamental.

A aprendizagem de máquina mostra-se muito eficiente para identificação de topologia, uma vez que métodos de reconhecimento de padrões é o interesse de grande parte das técnicas nesta área. Além disso a inteligência artificial é eficaz na recuperação de sinais com informações ausentes, o que é bem característico de sistemas de distribuição.

Nos testes realizados é possível verificar que a máquina foi capaz de aprender que existe uma relação entre as medições analógicas e a topologia da rede. Durante os testes com dados topológicos faltantes foi possível recuperar as informações da estrutura do sistema mesmo com a ausência de diversas informações.

Já nos testes com ausência de medidas analógicas fica visível a dependência dos valores de tensão para uma correta estimação da topologia da rede. Durante o caso de ausência de 2 sinais é visível que ao retirar uma linha dependente da outra causa uma divergência da estimação para a máquina e ela não é capaz de fornecer um valor confiável, porém ao remover mais informações essa adversidade é suprimida pela rede.

Esse fato ocorre, pois, ao remover a linha 5-6 na estimação da informação da linha 3-23 aparece um acumulo de erro,

indicando a rede neural encontrou um problema. Ao remover a linha 23-24 esse impasse se eleva fazendo com que a rede se desoriente.

Alguns problemas podem ocorrer ou serem causas de erros, por exemplo: a falta de tensão ou tensão zero pode ser decorrente da desconexão do componente ou em função de erro de comunicação e vice-versa. A máquina tem que aprender também com o comportamento da rede ao redor dessas áreas em que a falta de informação ocorre.

Dessa forma, é interessante averiguar possíveis soluções para esse impasse, como por exemplo a utilização de redes neurais variacionais auto associativas ou até mesmo aplicação de redes neurais profundas, com a utilização de diferentes funções de ativação para melhorar a codificação e decodificação deste tipo de arquitetura de rede.

AGRADECIMENTOS

Ao DINTER PPPG-EE/FPTI, à CAPES, ao Programa de Pós-Graduação em Engenharia Elétrica da EESC-USP, ao Parque Tecnológico de Itaipu e também ao Centro Latino-Americano de Tecnologias Abertas.

REFERÊNCIAS

Alves Da Silva A. P., Quintana V. H., Pang G. K. H., (1991) "Neural networks for topology determination of power systems," Proceedings of the First International Forum on Applications of Neural Networks to Power Systems, Seattle, WA, USA, pp. 297-301.

Arif W., Naeem A. (2016) Analysis and Optimization of IEEE 33 Bus Radial Distributed System Using Optimization Algorithm. (JETAE) Journal of Emerging Trends in Applied Engineering (ISSN 2518-4059), Vol. 1, No. 2.

Clements K. A., Costa A. S. (1998) “Topology Error Identification using Normalized Lagrange Multipliers”. IEEE Trans. on Power Systems, 13(2):347–353.

Clements K. A., Davis P. W. (1988) "Detection and identification of topology errors in electric power systems," in IEEE Transactions on Power Systems, vol. 3, no. 4, pp. 1748-1753.

Gao, C.; Redfern, M. A (2011) review of voltage control in smart grid and smart metering technologies on distribution networks. In: VDE. Universities’ Power Engineering Conference (UPEC), Proceedings of 2011 46th International. [S.l.], P. 1-5

Khan H. A., Xu Z, Iu H. and. Sreeram V. (2009) "Review of technologies and implementation strategies in the area of Smart Grid," 2009 Australasian Universities Power Engineering Conference, Adelaide, SA, pp. 1-6.

Kingma D. P., Ba J. (2015), Adam: A Method for Stochastic Optimization, 3rd International Conference for Learning Representations, San Diego.

Krstulovic J., Miranda V., Simões Costa A. J. A., Pereira J. (2013) "Towards an Auto-Associative Topology State Estimator," in IEEE Transactions on Power Systems, vol. 28, no. 3, pp. 3311-3318.

Liou, C. Y., Cheng, W. C., Liou, J. W. , Liou, D. R. (2014) “Autoencoder for words”, Neurocomputing, Volume 139, pp 84-96

Lugtu R. L. Hackett , D. F., Liu K. C., Might D. D. (1980) "Power System State Estimation: Detection of Topological Errors," in IEEE Transactions on Power Apparatus and Systems, vol. PAS-99, no. 6, pp. 2406-2412.

Lukomski R., Wilkosz K. (2003) "Power system topology verification using artificial neural networks: maximum utilization of measurement data," 2003 IEEE Bologna Power Tech Conference Proceedings,, Bologna, Italy, pp. 7 pp. Vol.3-.

Lukomski R., Wilkosz K. (2009) "Identification of topology errors with use of unbalance indices and neural networks," 2009 IEEE Bucharest PowerTech, Bucharest, pp. 1-8.

Miranda V., Krstulovic J., Keko H., Moreira C., Pereira J. (2012) "Reconstructing Missing Data in State Estimation With Autoencoders," in IEEE Transactions on Power Systems, vol. 27, no. 2, pp. 604-611.

Pala Z., Yamli V., Ünlük İ. H., (2017) "Deep Learning researches in Turkey: An academic approach," 2017 XIIIth International Conference on Perspective Technologies and Methods in MEMS Design (MEMSTECH), Lviv, pp. 120-123

ROSENBLATT, F. (1958) “The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain”, Cornell Aeronautical Laboratory, Psychological Review, v65, No. 6, pp. 386–408.

Vinod Kumar D. M., Srivastava S. C., Shah S., Mathur S. (1996) "Topology processing and static state estimation using artificial neural networks," in IEE Proceedings -Generation, Transmission and Distribution, vol. 143, no. 1, pp. 99-105.

Warren S. Mcculloch, Walter Pitts. (1943) “A Logical Calculus of Ideas Immanent in Nervous Activity”, Bulletin of Mathematical Biophysics, Vol. 5, pp. 115-133, Chicago: University of Chicago Press.