

## कृत्रिम तंत्रिका नेटवर्क का उपयोग करके ट्रांसमिशन लाइनों पर दोष संसूचन और वर्गीकरण प्रणाली

### Fault Detection and Classification System on Transmission Lines Using Artificial Neural Network

दीपेश भाटी<sup>1</sup>

<sup>1</sup>इलेक्ट्रिकल और इलेक्ट्रॉनिक्स इंजीनियरिंग, आईपीएस अकादमी,  
इंस्टीट्यूट ऑफ इंजीनियरिंग एंड साइंस, इंदौर (एम. पी.)

[deepeshbhati@ipsacademy.org](mailto:deepeshbhati@ipsacademy.org)

#### सारांश :

ट्रांसमिशन लाइन, जेनरेटिंग यूनिट और उपभोक्ताओं के बीच मुख्य कड़ी का काम करती है। इस शोध—पत्र में कृत्रिम तंत्रिका नेटवर्क की मदद से विद्युत शक्ति संचरण लाइनों के दोष का पता लगाया गया है। विकसित तंत्रिका नेटवर्क एक मजबूत नेटवर्क है जो तीन चरणों में दोष का पता लगाने में सक्षम है फिर चाहे वो जमीन पर सिंगल लाइन टू ग्राउंड और डबल लाइन हों। सिमुलेशन परिणाम यह प्रदर्शित करते हैं कि कृत्रिम तंत्रिका नेटवर्क—आधारित तरीके ट्रांसमिशन लाइनों पर दोष का पता लगाने में कुशल हैं और संतोषजनक प्रदर्शन प्राप्त करते हैं।

#### Abstract :

The transmission line acts as a link between the generating unit and the consumers. In this paper, faults of electric power transmission lines have been detected with the help of artificial neural networks. The developed neural network is a robust network capable of detecting faults in three phases whether it is single line to ground and double line to ground. Simulation results demonstrate that artificial neural network-based methods are efficient in detecting faults on transmission lines and achieve satisfactory performance.

**मुख्य शब्द :** फॉल्ट डिटेक्शन, एएनएन, ट्रांसमिशन लाइन, संसूचन, सिमुलेशन

**Keywords:** Fault Detection, ANN, Transmission Line, Simulation.

#### परिचय

पॉवर योजना में भौतिक आयाम को ध्यान में रखें तो ट्रांसमिशन लाइन सबसे अधिक संभावनायुक्त पाई जाती है। ट्रांसमिशन लाइन की मदद से वोल्टेज को एक लंबी दूरी के गंतव्य पर स्थानांतरित करने के लिए किया जाता है। वोल्टेज को जनरेटर से उत्पन्न करने के बाद ट्रांसमिशन लाइन के द्वारा लोड को आपूर्ति की जाती है [1]। ट्रांसमिशन लाइन को संचारण करते समय विभिन्न दोषों का सामना करना पड़ता है जैसे कि पक्षी या जानवरों का संपर्क, विभिन्न वृक्षों का संपर्क या अन्य प्राकृतिक कारण हो सकते हैं। [2–4]।

इस पत्र का उद्देश्य एक विश्वसनीय उपकरण के रूप में तंत्रिका नेटवर्क (एएनएन) विधि का उपयोग करके ट्रांसमिशन लाइन योजना में दोषों की पहचान करना है [5]। कृत्रिम तंत्रिका नेटवर्क (एएनएन) को ट्रांसमिशन लाइन अशुद्धि, अलगाव, और वर्गीकरण की पहचान में शक्तिशाली तरीका है। तंत्रिका नेटवर्क

(एनएन) में निहित समानता उन्हें पारंपरिक तकनीकों की तुलना में तेजी से संगणकीय समय के साथ सक्षम बनाती है। ट्रांसमिशन लाइन फॉल्ट डायग्नोसिस में इस तकनीक का उपयोग इसकी उपयोगिता को मान्य करता है और इंजीनियरों को अन्य विद्युत प्रणालियों में इस तकनीक का उपयोग करने के लिए प्रोत्साहित करता है [6]। इस पत्र का मुख्य उद्देश्य एक तंत्रिका नेटवर्क-आधारित स्वायत्त शिक्षण योजना विकसित करना है जो वास्तविक समय में ज्ञान को अधिमानतः प्राप्त करता है, जहां तक संभव हो कम पर्यवेक्षण, और अशुद्धि की पहचान के लिए ऐसी योजना के व्यावहारिक अनुप्रयोग के लिए प्रभावी रणनीति को तैयार करना है। निदान। ट्रांसमिशन लाइनों के संरक्षण में गलती की पहचान, वर्गीकरण और स्थान एक महत्वपूर्ण भूमिका निभाते हैं [7-10]।

परतों में न्यूरॉन्स की संख्या आवश्यक समस्या-समाधान गुणवत्ता के प्रावधान के लिए पर्याप्त होने के लिए चुनी गई है। समस्या को सुलझाने के समय को कम करने के लिए परतों की संख्या न्यूनतम होना आवश्यक है। मूल रूप से, हम तंत्रिका नेटवर्क को विशेष समस्याओं के समाधान के लिए डिजाइन और प्रशिक्षित कर सकते हैं जो मानव या पारंपरिक कम्प्यूटेशनल एल्गोरिदम के माध्यम से हल करना मुश्किल है। प्रशिक्षण का कम्प्यूटेशनल कुछ वजन के समायोजन के लिए नीचे आता है जो कृत्रिम तंत्रिका नेटवर्क के प्रमुख तत्व हैं। यह पारंपरिक कम्प्यूटेशनल विधि की तुलना में समस्या-समाधान के लिए तंत्रिका नेटवर्क दृष्टिकोण के प्रमुख अंतरों में से एक है। भार का समायोजन तब होता है जब तंत्रिका नेटवर्क को इनपुट डेटा रिकॉर्ड और संबंधित लक्ष्य मार्गों के साथ प्रस्तुत किया जाता है। ऑफ-लाइन डेटा के साथ तंत्रिका नेटवर्क को प्रशिक्षित करने की संभावना में, वे एक पावर सिस्टम के लिए उपयोगी पाए जाते हैं। ट्रांसमिशन लाइन प्रोटेक्शन में न्यूरल नेटवर्क (एनएन) एप्लिकेशन मुख्य रूप से अधिक प्रभावी और कुशल फॉल्ट डायग्नोसिस और डिस्टल रिलेइंग को प्राप्त करने में सुधार से संबंधित हैं [11]।

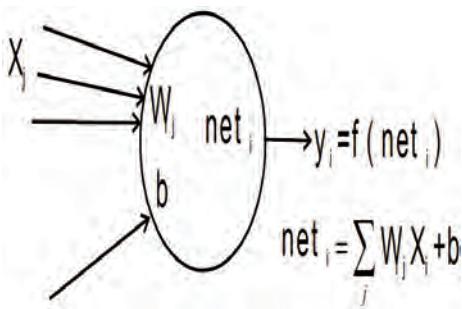
एनएन एप्लिकेशन का उपयोग ओवरहेड ट्रांसमिशन लाइनों, साथ ही बिजली वितरण प्रणालियों के लिए किया जा सकता है।

### कृत्रिम तंत्रिका नेटवर्क

एएनएन को मानव मस्तिष्क का एक बहुत ही सरलीकृत मॉडल माना जा सकता है जिसका उपयोग किसी विशेष कार्य या रुचि के कार्य को करने के लिए किया जा सकता है। नेटवर्क आमतौर पर डिजिटल कंप्यूटर पर सॉफ्टवेयर में इलेक्ट्रॉनिक उपकरणों या सिम्युलेटेड का उपयोग करके कार्यान्वित किया जाता है। बड़े पैमाने पर समानांतर वितरित संरचना और सीखने की क्षमता और सामान्यीकरण करना ANN के लिए जटिल समस्याओं को हल करना संभव बनाता है जो अन्यथा वर्तमान में असाध्य हैं [12]।

यह ऑपरेटिंग प्रक्रिया पारंपरिक इंजीनियरिंग डिजाइन मॉडल के साथ विपरीत होनी चाहिए, जो संपूर्ण उप-विशिष्टताओं के विनिर्देशों और अंतर-संचार प्रोटोकॉल से बना है। कृत्रिम तंत्रिका नेटवर्क में, डिजाइनर नेटवर्क टोपोलॉजी, प्रदर्शन फंक्शन, सीखने का नियम, प्रशिक्षण चरण को रोकने के लिए कसौटी चुनता है, लेकिन सिस्टम स्वचालित रूप से मापदंडों को समायोजित करता है। इसलिए, डिजाइन प्रक्रिया में एक प्राथमिक जानकारी लाना मुश्किल है, और जब सिस्टम ठीक से काम नहीं करता है, तो समाधान को बढ़ाना मुश्किल है। ANN- आधारित समाधान विकास के समय और संसाधनों के मामले में अत्यंत कुशल है [13]। कई कठिन समस्याओं में, कृत्रिम तंत्रिका नेटवर्क (एनएन) प्रदर्शन प्रदान करता है जो अन्य प्रौद्योगिकी के साथ मेल करना मुश्किल है। वर्तमान में, कृत्रिम तंत्रिका नेटवर्क विभिन्न अनुप्रयोगों के लिए पसंद की तकनीक के रूप में उभर रहे हैं, जैसे पैटर्न मान्यता, भविष्यवाणी और नियंत्रण, और सिस्टम पहचान।

दीपेश भाटी, "कृत्रिम तंत्रिका नेटवर्क का उपयोग करके ट्रांसमिशन लाइनों पर दोष संसूचन और वर्गीकरण प्रणाली"



चित्र 1. न्यूरॉन मॉडल

प्रत्येक नोड में इनपुट जुड़े होते हैं और प्रत्येक इनपुट डेटा के अनुसार वजन होता है जैसा कि चित्र 1 में दिखाया गया है। प्रत्येक नोड में केवल एक आउटपुट होता है। उपरोक्त संकेतन के आधार पर उपरोक्त न्यूरॉन  $i$  कहा जाता है। जम्मू इनपुट्स एकसजे और एक पूर्वाग्रह बी। प्रत्येक इनपुट एक वजन विज से मेल खाती है, इस प्रकार न्यूरॉन में जे वेट होते हैं। न्यूरॉन यी का आउटपुट, नेति के एक फंक्शन द्वारा निर्मित होता है

$$net_i = \sum_j W_{ij} X_i + b$$

### ANN—आधारित दोष का पता लगाना

आर्टिफिशियल इंटेलिजेंस, कॉर्पोरेट नेटवर्क और न्यूरल नेटवर्क, बायोलॉजिकल न्यूरल सिस्टम प्रोसेस डेटा से प्रेरित सूचना प्रसंस्करण प्रतिमान हैं। कृत्रिम बुद्धि और संज्ञानात्मक मॉडलिंग जैविक तंत्रिका नेटवर्क के कुछ गुणों का अनुकरण करने की कोशिश करते हैं। सॉफ्टवेयर एजेंटों (कंप्यूटर और वीडियो गेम में) या स्वायत्त रोबोट और विशेष रूप से गलती का पता लगाने वाले सिस्टम में निर्माण करने के लिए भाषण मान्यता, छवि विश्लेषण और अनुकूली नियंत्रण के लिए कृत्रिम तंत्रिका नेटवर्क को सफलतापूर्वक लागू किया गया है। तंत्रिका नेटवर्क सिद्धांत ने दोनों को बेहतर ढंग से पहचानने के लिए कार्य किया है कि मर्सिष्क के न्यूरॉन्स कैसे काम

करते हैं और कृत्रिम बुद्धि बनाने के प्रयासों के लिए आधार प्रदान करते हैं। चित्र 2 एक एकल न्यूरॉन दर्शाता है। निम्नलिखित आरेख एक साधारण न्यूरॉन दिखाता है:

एक न्यूरॉन में तीन बुनियादी घटक होते हैं, जिनका वजन, थ्रेसहोल्ड / बायसेस और एकल सक्रियण फंक्शन होता है। मान  $w_1, w_2, \dots, w_n$  इनपुट वेक्टर  $X$  की ताकत निर्धारित करने के लिए भार हैं

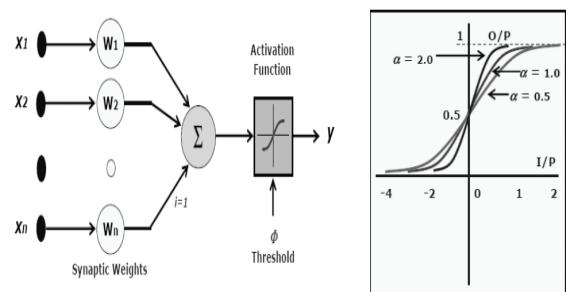
$$I = X^T \cdot W = x_1 w_1 + x_2 w_2 + \dots + x_n w_n = \sum_{i=1}^n x_i w_i$$

$$Y = f(I) = f \left\{ \sum_{i=1}^n x_i w_i - \varphi_k \right\}$$

अंतिम आउटपुट  $Y$  को उत्पन्न करने के लिए, एक गैर-रैखिक फिल्टर  $\Sigma$  को सक्रियण फंक्शन या ट्रांसफर फंक्शन नाम से पास किया जाता है, जो आउटपुट  $Y$  को रिलाइज करता है। सबसे लोकप्रिय सिग्मोइडल फंक्शन नीचे दिखाए गए संक्रमण समीकरण का अनुसरण करता है।

जहां  $\alpha$  सिग्मोइडल फंक्शन का ढलान है, उसके बाद।

$$Y = f(I) = \frac{1}{1 + e^{-\alpha I}}$$



चित्र 2. एक एकल न्यूरॉन और सिग्मोइड सक्रियण

न्यूरॉन्स की संख्या बढ़ने के साथ तंत्रिका नेटवर्क की क्षमता बढ़ जाती है। तंत्रिका नेटवर्क संरचना में परतों की संख्या बढ़ने पर यह क्षमता कई गुना बढ़ जाती है। चित्र 2 एक छिपी हुई परत के साथ एक बहुपरत तंत्रिका नेटवर्क दिखाता है। तंत्रिका नेटवर्क को प्रशिक्षित करते समय न्यूरॉन्स को जोड़ने वाले भार लगातार भिन्न होते हैं। एनएन अनुप्रयोगों में, चुनौती वजन और सीमा के लिए सही मूल्यों को खोजने के लिए है। विभिन्न एल्गोरिदम को विभिन्न नेटवर्क समस्याओं और अनुप्रयोगों के आधार पर विकसित किया जाता है जहां इसका उपयोग किया गया है। बैक प्रोपोगेशन, रेडियल बेसिस फंक्शंस, मल्टी-लेयर पेसेट्रॉन एल्गोरिदम।

### दोष जांच और वर्गीकरण प्रणाली

चित्र 3 प्रस्तावित दोष का पता लगाने और वर्गीकरण दृष्टिकोण की डिजाइन प्रक्रिया निम्नानुसार है :

- कृत्रिम तंत्रिका नेटवर्क का प्रशिक्षण और इसकी शुद्धता और सामान्यीकरण की जांच करने के लिए परीक्षण पैटर्न का उपयोग करके प्रशिक्षित एएनएन की मान्यता।
- विद्युत प्रणाली में वर्तमान और वोल्टेज संकेतों का डेटा अधिग्रहण करना।
- वर्तमान संकेतों पर D.W.T का अनुप्रयोग और ऊर्जा के गुणांकों की विस्तार से गणना।
- सिस्टम मापदंडों को बदलना, वर्तमान और वोल्टेज संकेतों का डेटा अधिग्रहण, और परिणाम का भंडारण और विश्लेषण करना।
- किसी दिए गए आवेदन के लिए उपयुक्त ANN टोपोलॉजी का चयन।

विभिन्न प्रशिक्षण पैटर्न उत्पन्न करने के लिए गलती प्रतिरोध, गलती स्थान, और गलती प्रकार को बदल दिया जाता है।

वर्तमान सिग्नल का डाटा अधिग्रहण

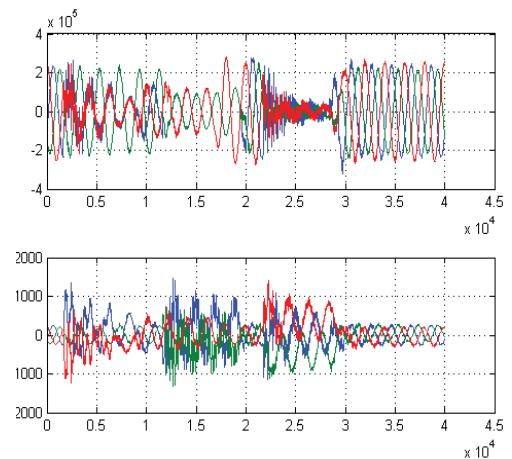
डी डब्ल्यू टी बहु संकल्प विश्लेषण

सुविधा निष्कर्षण, ऊर्जा गणना

ANN- आधारित वर्गीकरण दोष

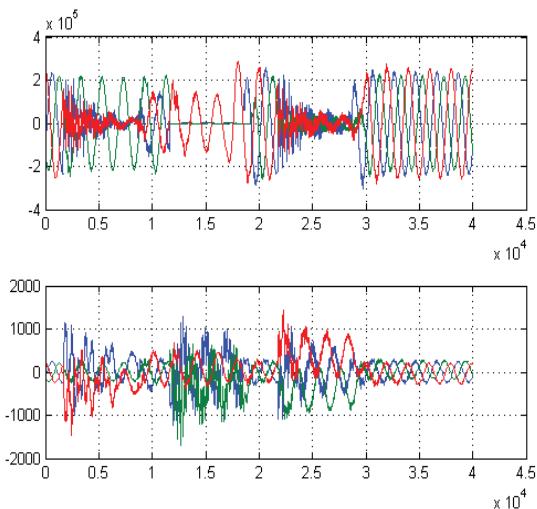
चित्र 3. दोष संसूचन और वर्गीकरण की प्रक्रिया परिणाम और चर्चा

प्रस्तावित पावर सिस्टम एक सिमुलेशन मॉडल था जिसका उपयोग सिम्बलिंग में सिमपॉवर टूलबॉक्स का उपयोग करके किया गया था। तीन-चरण फॉल्ट सिम्युलेटर का उपयोग अलग-अलग स्थानों पर विभिन्न प्रकार के दोषों का अनुकरण करने के लिए किया जाता है। चित्र 4 और 5 में दर्शाया गया है।



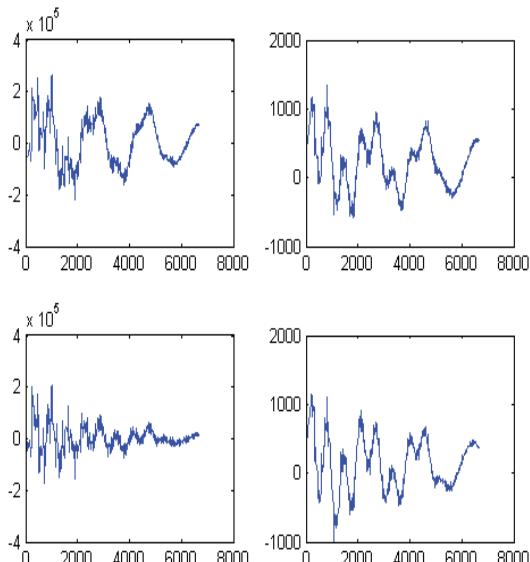
चित्र 4. चरण ए और बी की वर्तमान तरंग दिखाता है

दीपेश भाटी, "कृत्रिम तंत्रिका नेटवर्क का उपयोग करके ट्रांसमिशन लाइनों पर दोष संस्करण और वर्गीकरण प्रणाली"



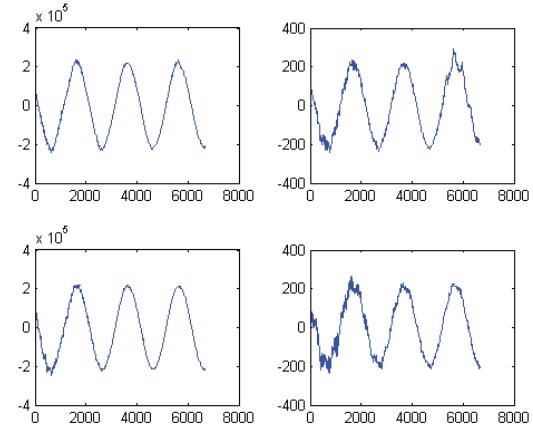
चित्र 5. ग्राउंड टू लाइन की वर्तमान तरंग को दर्शाता है

सिंगल लाइन टू ग्राउंड और डबल लाइन टू ग्राउंड फॉल्ट के अलग—अलग मामलों का परीक्षण विकसित फॉल्ट डिटेक्शन तकनीक के लिए किया जाता है। चित्र 6–8 में चार उपल्लॉट होते हैं। एक चरण में दोष एक और चरण वर्तमान को परेशान करता है जैसा कि नीचे दिए गए सभी परिणामों में दिखाया गया है।

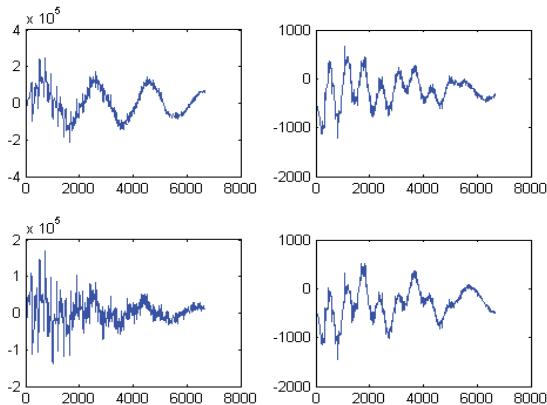


चित्र 6. सिंगल लाइन चरण ए और बी गलती का पता लगाना

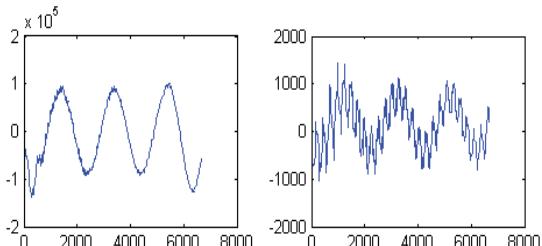
### केस -1, सिंगल लाइन फॉल्ट डिटेक्शन

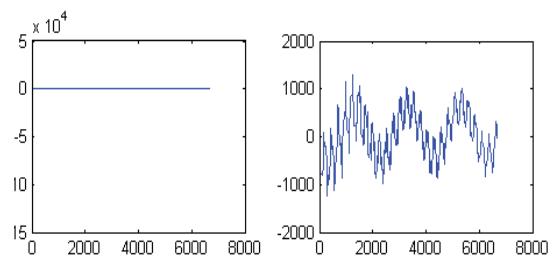


चित्र 7. सिंगल लाइन चरण बी और सी गलती का पता लगाना



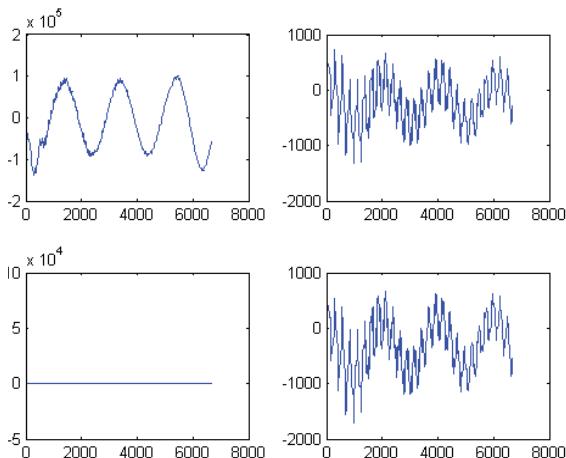
चित्र 8. सिंगल लाइन चरण बी और सी गलती का पता लगाना





चित्र 9. चरण ए में सिंगल लाइन टू ग्राउंड फॉल्ट के लिए गलती का पता लगाना

### केस -2, ग्राउंड टू लाइन फॉल्ट डिटेक्शन



चित्र 10. चरण सी में जमीन की गलती के लिए सिंगल लाइन के लिए दोष का पता लगाना

### निष्कर्ष

कृत्रिम तंत्रिका नेटवर्क (ANN) का उपयोग करके प्रस्तावित विधि, दोष का पता लगाना। ट्रांसमिशन लाइन तकनीक में दोष का पता लगाने के लिए तंत्रिका नेटवर्क तकनीक का उपयोग करके जांच की गई है। उत्पन्न डेटा का उपयोग सिंगल-फेज के लिए ग्राउंड फॉल्ट्स, डबल फेज फॉल्ट्स और डबल फेज से ग्राउंड फॉल्ट्स के लिए किया जाता है। ट्रांसमिशन लाइन फॉल्ट डिटेक्शन के लिए प्राप्त परिणाम।

Table: English and Hindi technical terms

Sl.	English Term	Hindi Term
1	Artificial Neural Network	कृत्रिम तंत्रिका नेटवर्क
2	Electricity	विद्युत
3	Energy	ऊर्जा
4	Fault	दोष
5	Load	भार
6	Power	शक्ति
7	Testing	परीक्षण
8	Detection	संसूचन

### संदर्भ (References) :

1. T.C. Lin, P.Y. Lin, and C.W. Liu, “An algorithm for locating faults in three-terminal multi-section non-homogeneous transmission lines using synchrophasor measurements,” IEEE Transactions on Smart Grid, Vol. 5, pp. 38-50, (2014).
2. H. Livani and C.Y. Evrenosoglu, “A machine learning and wavelet based fault location method for hybrid transmission lines,” IEEE Transactions on Smart Grid, Vol. 5, pp. 51-58, (2014).
3. M. Farshad and J. Sadeh, “Accurate single-phase fault-location method for transmission lines based on k-nearest neighbor algorithm using oneend voltage,” IEEE Transactions on Power Delivery, Vol. 27, pp. 2360–2367, (2012).
4. S. C. Naghate, S. M. Dhuldhara, A. B. Nagdewate, “Transmission line fault analysis”, International Journal of Engineering Sciences & Research Technology, Vol. 4, pp. 330-333, (2015).
5. M. Pourahmadi-Nakhli, and A. A. Safavi, “Path Characteristic Frequency Based Fault Locatingin Radial Distribution Systems Using Wavelets and Neural Networks,” IEEE Trans. Power Del., Vol. 26, pp. 772-781, (2011).

6. A. A. Gargis and M. B. Johnson, "A Hybrid Expert System for Faulted Section Identification, Fault Type Classification and Selection of Fault Location Algorithms," IEEE Trans. Power Del., Vol. 4, pp. 978- 985, (1989).
7. T. Adu, "An Accurate Fault Classification Technique for Power System Monitoring Devices," IEEE Trans. Power Del., Vol. 17, pp. 684- 690, (2003).
8. Y. Oualmakran, J. Mébénédéz, S. Herraiz, Mercedez López-Perea & Eloy Gonzalez, "Survey on Knowledge Based Methods to Assist Fault Restoration in Power Distribution Network", International Conference on Renewable Energies & Power Quality, 13th to 15th April (2011).
9. G. Shahgholian, h. Razaei, "Fault Location Scheme in Distributed System with Distributed Generators Using Neural Network", Majlesi Journal of Electrical Engineering, Vol. 4, pp. 57-62, (2010).
10. D. Wafi, M. Nomir, S. Bhowmick, S. Alam, "A Review of Neural Networking Methodology to Different Aspects of Electrical Power Systems", International Journal of Science & Advanced Technology, Vol. 1, pp. 1-7, (2011).
11. M. Tayeb, "Faults Detection in Power Systems Using Artificial Neural Network", American Journal of Engineering Research (AJER) Vol. 02, pp.69-75, (2013).
12. D. Thukaram, H. P. Khincha and H. P. Vijaynarsimha, "Artificial Neural Network and Support Vector Machine Approach for Locating Faults in Radial Distribution Systems", IEEE Transactions on Power Delivery, Vol. 20, pp. 710-721, (2005).
13. S. Kesharwani, D. Singh, "Simulation Of Fault Detection For Protection Of Transmission Line Using Neural Network", International Journal of Science, Engineering and Technology Research (IJSETR), Vol. 3, pp. 1367-1375, (2014).
14. P. Ray, D. Mishra, K. Dey, P. Mishra, "Detection and Classification of Faults on Transmission Line Using Wavelet Transform and Neural Network", International Conference on Information Technology (ICIT), pp. 178-183, (2017).
15. P. G. V. Axelberg, I. Y. H. Gu and M. H. J. Bollen, "Support Vector Machine for Classification of Voltage Disturbances," IEEE Trans. Power Del., Vol. 22, pp. 1297-1303, (2007).
16. W. M. Li, C. H. Wu, C. H. Lin and F. S. Cheng, "Detection and Classification of Multiple Power-Quality Disturbances With Wavelet Multiclass SVM," IEEE Trans. Power Del., Vol. 23, pp. 2575- 2582, (2008).
17. B. Ravikumar, D. Thukaram and H. P. Khincha, "Comparison of Multiclass SVM Classification Methods to Use in a Supportive System for Distance Relay Coordination," IEEE Trans. Power Del., Vol. 25, pp. 1296-1305, (2010).
18. F. R. Gomez, A. D. Rajapakse, U. D. Annakkage and I. T. Fernando, "Support Vector Machine-Based Algorithm for Post-Fault Transient Stability Status Prediction Using Synchronized Measurements," IEEE Trans. Power Syst., Vol. 26, pp. 1474-1483, (2011).
19. L. S. Martins, J. F. Martins, V. Fernão Pires and C. M. Alegria, "A neural space vector fault location for parallel double-circuit distribution lines," Electrical Power & Energy Systems, Vol. 27, pp. 225-231, (2005).
20. A. M. El-Zonkoly and H. Desouki, "Wavelet entropy based algorithm for fault detection and classification in FACTS compensated transmission line", Int. J. Electr. Power Energy Syst., Vol. 33, pp. 1368-1374, (2011).
21. B. Rathore and A. G. Shaik, "Wavelet-alienation based transmission line protection scheme", IET Gener. Transmiss. Distrib., Vol. 11, pp. 995-1003, (2017).