

कण दल इष्टतमीकरण आधारित कृत्रिम तंत्रिका नेटवर्क के द्वारा हवा की गति का पूर्वानुमान  
**Particle Swarm Optimization based Artificial Neural Network for Wind Speed Forecasting**

अजय कुमार बंसल<sup>1</sup> और विकास गर्ग<sup>2</sup>

<sup>1,2</sup>अभियांत्रिकी और प्रौद्योगिकी पीठ, हरियाणा केंद्रीय विश्वविद्यालय, महेंद्रगढ़  
ajaybansal@cuh.ac.in<sup>1</sup>, gargvikas27@cuh.ac.in<sup>2</sup>

**सारांश**

पवन संसाधनों से बिजली उत्पादन लगातार पूरी दुनिया में बहुत तेजी से बढ़ रहा है। पवन टरबाइन द्वारा उत्पादित पवन ऊर्जा (Wind Energy) की मात्रा, हवा की गति पर निर्भर करती है। हवा की गति अरैखिक (non-linear), प्रकृति में यादृच्छिक (Random), स्थान और आसपास के मौसम की स्थिति पर निर्भर करती है। ऊर्जा प्रणाली ऑपरेटर के लिए, हवा की गति में अनिश्चितता (uncertainty), ऊर्जा प्रेषण के लिए सिस्टम संचालन, समय-निर्धारण और नियोजन में कठिनाई पैदा करती है क्योंकि पवन-टरबाइन द्वारा उत्पन्न ऊर्जा पहले से ज्ञात नहीं होती है। कृत्रिम तंत्रिका नेटवर्क (Artificial Neural Network) (एएनएन) का व्यापक रूप से उपयोग, समय श्रृंखला पूर्वानुमान (time series forecasting), इष्टतमीकरण (Optimization), पैटर्न मिलान और साहचर्य यादों (associated memories) में किया जाता है। कृत्रिम तंत्रिका नेटवर्क का प्रदर्शन काफी हद तक प्रशिक्षण आंकड़ा समुच्चय (Data set), प्रशिक्षण प्रक्रिया और प्रशिक्षण कलन विधियों (algorithms) पर निर्भर करता है। यह शोध पत्र महेंद्रगढ़, भारत, में हवा की गति के पूर्वानुमान के लिए एक कृत्रिम तंत्रिका नेटवर्क उपगमन को प्रस्तुत करता है। कण दल इष्टतमीकरण (Particle Swarm Optimization) (पीएसओ) आधारित कलन विधियों का उपयोग एएनएन प्रशिक्षण कलन विधियों के रूप में किया गया है। कण दल इष्टतमीकरण आधारित कृत्रिम तंत्रिका नेटवर्क (PSO based ANN) पद्धति से हवा की गति के पूर्वानुमान का मूल्यांकन, वास्तविक दुनिया के मामले के अध्ययन से संख्यात्मक परिणामों के साथ किया गया है। हवा की गति के पूर्वानुमान के लिए प्रस्तावित उपगमन में 97% और उससे अधिक की सटीकता है।

**Abstract**

The power generation from wind resources are continually increasing very rapidly all over the world. The amount of wind energy produced by wind turbine, depends on the wind speed. The wind speed is non-linear, random in nature and vary from location to location and surrounding weather conditions. For the energy system operator, the uncertainty in the wind speed generates a difficulty in the system operation, scheduling and planning for energy dispatching because the power generated by wind-turbine is not known in advance. Artificial Neural Networks are extensively used in time series forecasting, optimization, pattern matching and associative memories. The performance of Artificial Neural Network largely depends on training data set, training process and the training algorithm. This research paper presents an artificial neural network approach for wind speed forecasting at Mahendergarh, India. The Particle Swarm Optimization (PSO) based algorithm is used as training algorithm. The accuracy of the wind speed forecasting by PSO based ANN approach is evaluated with the numerical results from a real-world case study. The proposed

approach for wind speed forecast has accuracy of 97% and above.

**मुख्य शब्द :** कृत्रिम तंत्रिका नेटवर्क, पश्च-प्रसारण, कण दल इष्टतमीकरण, हवा की गति का पूर्वानुमान।

**Keywords:** Artificial neural network, back-propagation, particle swarm optimization, wind speed forecasting.

## 1. परिचय (Introduction)

विश्व स्तर पर निरंतर जनसंख्या वृद्धि, आर्थिक विकास और रिहायशी सुधार के कारण, ऊर्जा की खपत भी तेजी से बढ़ी है। विद्युत ऊर्जा (Electrical energy) उत्पन्न करने का मुख्य स्रोत जीवाश्म ईंधन (fossil fuel) है। जीवाश्म ईंधन के सीमित भंडार और उनसे जुड़े हानिकारक उत्सर्जन के कारण हाल के वर्षों में अक्षय ऊर्जा स्रोतों पर अधिक ध्यान केंद्रित किया गया है। अक्षय ऊर्जा के क्षेत्र में, सौर और पवन ऊर्जा की क्षमता बहुत अधिक है, जबकि बायोमास ऊर्जा, ज्वारीय ऊर्जा और भूतापीय ऊर्जा की क्षमता बहुत सीमित है। मुख्य अक्षय ऊर्जा स्रोत पवन, सौर, भूतापीय (geothermal) और ज्वार (tidal) की ऊर्जा हैं। पवन ऊर्जा को सबसे मूल्यवान और आसानी से उपयोग किए जाने वाले अक्षय ऊर्जा प्रकारों [7] में से एक माना जाता है, लेकिन यह केवल तब तक संभव है जब तक कि मौसम की स्थिति अनुकूल हो। पवन बिजली के किफायती बिजली प्रेषण के लिए, हवा की गति का पूर्वानुमान करने में सक्षम होना महत्वपूर्ण है, जो सीधे उत्पादन की क्षमता [8] को प्रभावित करता है। हवा की गति के सटीक पूर्वानुमान के आधार पर, पवन बिजली उत्पन्न करने की योजना को कुशलता से बिजली ग्रिडों पर समायोजित किया जा सकता है [11]।

कई शोधों ने दिखाया है कि अगर पवन ऊर्जा पूर्वानुमान की तकनीक में सुधार किया जा सके तो यह पवन ऊर्जा भंडार पर महत्वपूर्ण प्रभाव डालेगी [26, 16]। कई शोध पत्रों [14] 20, 29, ने अच्छी हवा

की गति के पूर्वानुमान के वित्तीय लाभों का आकलन किया है और साबित किया है कि अग्रिम पूर्वानुमान तकनीकों की आवश्यकता है। कृत्रिम बुद्धि (Artificial intelligence) (एआई) एक शब्द है जो व्यापक अर्थ में मानव और अन्य जन्तुओं द्वारा प्रदर्शित प्राकृतिक बुद्धि के विपरीत मशीनों द्वारा प्रदर्शित बुद्धि है [22]। कृत्रिम बुद्धि को कंप्यूटर निकाय और अधिक जटिल प्रक्रियाओं पर लागू किया गया है जो कार्य को सरल और सीधा करते हैं [25], हालांकि कृत्रिम बुद्धि अभी भी वास्तविक बुद्धि के दायरे से बहुत दूर है। बर्र और फीजेनबाउम (Barr and Feigenbaum) के अनुसार, कृत्रिम बुद्धि कंप्यूटर विज्ञान का एक हिस्सा है जो बुद्धिमान कंप्यूटर निकाय को डिजाइन करने से संबंधित है, अर्थात् सिस्टम जो मानव व्यवहार में बुद्धिमत्ता से जुड़ी विशेषताओं, जैसे समझ, भाषा, शिक्षण, तर्क, समस्याओं को हल करना को प्रदर्शित करता है। कई बुद्धिमान कंप्यूटिंग प्रौद्योगिकियां पारंपरिक तकनीकों के लिए वैकल्पिक पद्धतियाँ अथवा एकीकृत प्रणालियों के घटकों के रूप में उपयोगी हो रही हैं [24]।

समय श्रृंखला, कलमन फिल्टर आदि रैखिक तरीकों का उपयोग पूर्वानुमान के लिए करना उचित नहीं है, क्योंकि हवा की गति की भिन्नता एक गैर-स्थिर और अरेखीय है [5]। एएनएन की ब्लैक बॉक्स सुविधा पूर्वानुमान [19] के लिए उपयुक्त है। एएनएन स्वचालित रूप से इनपुट-आउटपुट प्रक्षेपण मॉडल को सीख सकता है और उसमें किसी भी अनुभवात्मक सूत्रों की आवश्यकता के बिना इनपुट और आउटपुट नमूनों के साथ प्रशिक्षण के माध्यम से इनपुट-आउटपुट प्रक्षेपण मॉडल को समझने, अनुभव करने और फ़ैसले लेने की क्षमता आ जाती है [4]। हाल ही में, कई शोधकर्ताओं ने कृत्रिम तंत्रिका नेटवर्क (एएनएन) प्रशिक्षण और संरचना इष्टतमीकरण में मृदु संगणन (Soft computing) तकनीकों का उपयोग किया है [3]। पूर्व में, कई इष्टतमीकरण कलन विधियों (optimization algorithms) का उपयोग प्रशिक्षण के लिए किया गया है, जिसमें आनुवंशिक


कलन विधि (Genetic algorithm), जीवाणु फोर्जिंग कलन विधि (Bacterial Foraging Algorithm), चींटी कॉलोनी कलन विधि (Ant Colony Algorithm), कृत्रिम मधुमक्खी कॉलोनी कलन विधि (Artificial bee colony algorithm) आदि शामिल हैं। इन कलन विधियों का उपयोग करके, एएनएन के भार (weight) और पूर्वाग्रह (biases) को सर्वोत्तम प्रदर्शन के लिए समायोजित किया जाता है और सर्वोत्तम तंत्रिका नेटवर्क के वास्तुकला को भी खोजा जाता है [13]। प्रस्तावित पीएसओ आधारित एएनएन (PSO based ANN) पद्धति के प्रदर्शन का विश्लेषण करने के लिए, इसके परिणामों की तुलना पहले से ही प्रकाशित तरीकों जैसे एनआरएम (NRM) [23], एनएन (NN) [15], एनएनडब्ल्यूटी (NNWT) [30], एनएफ (NF) [25], बीपीएनएन (BPANN) [2] से की गयी है।

शोध पत्र का संगठन निम्नानुसार है: कृत्रिम तंत्रिका नेटवर्क और कण दल इष्टतमीकरण क्रमशः अनुभाग 2 और अनुभाग 3 में प्रस्तुत किए गए हैं। तंत्रिका नेटवर्क के प्रशिक्षण के लिए कण दल इष्टतमीकरण आधारित कृत्रिम तंत्रिका नेटवर्क अनुभाग 4 में प्रस्तुत किए गए हैं। खंड 5 में, हवा की गति के पूर्वानुमान के लिए पीएसओ आधारित एएनएन नेटवर्क के सिमुलेशन परिणाम प्रस्तुत किए गए हैं। खंड 6 में, प्रस्तावित उपगमन के निष्कर्ष पर चर्चा की गई है।

## 2. कृत्रिम तंत्रिका नेटवर्क (Artificial Neural Network)

कृत्रिम तंत्रिका नेटवर्क (एएनएन) मानव मस्तिष्क की जैविक प्रणालियों पर आधारित है। एएनएन का निर्माण एक उचित संरचना में न्यूरॉन्स (Neurons) या नोड्स को परस्पर जोड़कर किया जाता है। तंत्रिका नेटवर्क में, तीन प्रकार की परतें मौजूद होती हैं, जिन्हें इनपुट, छिपी (hidden) और आउटपुट परत के रूप में जाना जाता है। इनपुट को छिपी परतों की ओर संसाधित किया जाता है, जिसमें अन्तर्ग्रथनी लिंक

(Synaptic links) का उपयोग किया जाता है जिसे भार (weight) कहा जाता है और इसी तरह आउटपुट परत को छिपी परतों से जोड़ा जाता है। यदि एक से अधिक छिपी हुई परत तंत्रिका नेटवर्क में मौजूद है, तो कनेक्शन भार भी उनके बीच मौजूद होते हैं। प्रत्येक नोड पर, कई नोड्स से इनपुट संकेत प्राप्त होते हैं, इन इनपुट संकेतों से स्थानीय रूप से चयनित सक्रियण फलन (Activation function) का उपयोग करके, संसाधित (processed) आउटपुट संकेत उत्पन्न किए जाते हैं। एक तंत्रिका नेटवर्क को आसानी से सिखाया जा सकता है और कई जटिल अरैखिक कार्यों को काफी कुशलता से करने के लिए प्रशिक्षित किया जा सकता है। जैसा कि एएनएन प्रकृति में अरैखिक है, प्रशिक्षण एक बहुत ही जटिल कार्य है जिसके लिए पर्याप्त प्रशिक्षण समय और डेटा की आवश्यकता होती है। प्रशिक्षण चरण में कनेक्शन भार को इस तरह से समायोजित (adjusted) किया जाता है कि वांछित और वास्तविक आउटपुट के बीच त्रुटि कम हो जाये। प्रशिक्षण डेटा का उपयोग करते हुए, तंत्रिका नेटवर्क समस्या सीखते हैं और उनके प्रदर्शन में सुधार होता है। प्रशिक्षण प्रक्रिया को गणितीय कलन विधि द्वारा दर्शाया जाता है। कई तंत्रिका नेटवर्क संरचनाएँ उपलब्ध हैं, लेकिन बहुपरत तंत्रिका नेटवर्क का उपयोग ज्यादातर समय श्रृंखला पूर्वानुमान के लिए किया जाता है, जैसाकि चित्र 1 में दिखाया गया है।



चित्र.1 तीन परत फीड-अग्र तंत्रिका नेटवर्क (Three layer feed-forward neural network)

### 3. कण दल इष्टतमीकरण (Particle Swarm Optimization)

डॉ. एबेहार्ट और डॉ. कैंनेडी [9] ने कण दल इष्टतमीकरण (पीएसओ) विकसित किया। पीएसओ पक्षी झुंड के सामाजिक व्यवहार का कृत्रिम मॉडल है। पीएसओ में, यादृच्छिक संभावित (random potential) समाधान उम्मीदवारों को प्रारंभिक किया जाता है, जिन्हें कणों के रूप में जाना जाता है और सर्वोत्तम कण पर आधारित होता है। कणों की स्थिति को दो मापदंडों के आधार पर अद्यतित (Updated) किया जाता है, पहला स्वयं द्वारा देखी गई सबसे अच्छी स्थिति है और दूसरी पूरी आबादी में सबसे अच्छी कण स्थिति है। स्वयं द्वारा देखी गई सबसे अच्छी स्थिति को व्यक्तिगत सर्वोत्तम (Local best) के रूप में जाना जाता है और पूरी आबादी द्वारा प्राप्त सबसे अच्छी स्थिति को वैश्विक सर्वोत्तम (Global best) के रूप में जाना जाता है। इष्टतमीकरण समस्या के आधार पर, प्रत्येक कण की वर्तमान स्थिति का मूल्यांकन फिटनेस फलन का उपयोग करके और व्यक्तिगत

सर्वोत्तम और वैश्विक सर्वोत्तम स्थिति के साथ तुलना करके किया जाता है [27]।

प्रत्येक कण, n- आयामी खोज स्थान में चर (variable) के आधार पर घूमता है। पीएसओ कलन विधियों को समझने के लिए, एक दो-आयामी खोज स्थान ईल निर्देशांक माना जाता है। x- अक्ष के साथ वेग  $v_x$  है और y- के साथ  $v_y$  है। कण की स्थिति, वर्तमान स्थिति और वेग जानकारी के आधार पर अद्यतित (update) की जाती हैं। प्रत्येक कण की सबसे अच्छी स्थिति को व्यक्तिगत सर्वोत्तम (pb) के रूप में संग्रहीत किया जाता है। पूरी आबादी द्वारा प्राप्त की गई सबसे अच्छी स्थिति को वैश्विक सर्वोत्तम (gb) के रूप में संग्रहीत किया जाता है। प्रत्येक कण, अपने वेग और स्थिति को वर्तमान स्थिति (x, y), वर्तमान वेगों ( $v_x, v_y$ ), वर्तमान स्थिति तथा pb के बीच की दूरी और वर्तमान स्थिति तथा gb के बीच की दूरी के आधार पर अद्यतित करता है [1]। कणों के वेग और स्थिति में संशोधन की गणना क्रमशः समीकरण 1 और 2 का उपयोग करके की जाती है।


$$v_i^{(k+1)} = \omega v_i^{(k)} + c_1 rand_1 (pb_i - s_i^{(k)}) + c_2 rand_2 (gb_i - s_i^{(k)})$$

समीकरण 1: प्रत्येक कण का अद्यतित वेग (Updated velocity of each particle)

$$s_i^{(k+1)} = s_i^{(k)} + v_i^{(k+1)}$$

समीकरण 2: प्रत्येक कण की अद्यतित वेग स्थिति (Updated position of each particle)

जहां कण i का वर्तमान वेग  $v_i^{(k)}$ , कण i का पुनरावृत्ति के दौरान नया वेग  $v_i^{(k+1)}$ , कण i की वर्तमान स्थिति  $s_i^{(k)}$ , कण I की पुनरावृत्ति k के दौरान नयी स्थिति  $s_i^{(k+1)}$ , समायोज्य संज्ञानात्मक त्वरण स्थिरांक (आत्मविश्वास)  $c_1$ , समायोज्य सामाजिक त्वरण स्थिरांक (झुंड आत्मविश्वास)  $c_2$ , यादृच्छिक संख्या (0 से 1)  $rand_1$  और  $rand_2$ , कण i का व्यक्तिगत सर्वोत्तम, वैश्विक जनसंख्या का वैश्विक सर्वोत्तम और जड़ता वजन कारक है।



चित्र.2 पीएसओ में स्थिति और वेग को अद्यतित करना (Updating position & velocity in PSO)

चित्र 2 पीएसओ (PSO) प्रक्रिया के दौरान किसी खोज कण के संशोधन की अवधारणा को दर्शाता है। पीएसओ कलन विधि के प्रारंभिक संस्करणों से जुड़ी मुख्य समस्या यह है कि समस्या की प्रतिक्रिया विस्तृत श्रृंखला के साथ दोलनशील (oscillatory) हो जाती है। वेग को नम (damp) करने के लिए और बेकाबू कणों को सीमित करने के लिए एक विधि पेश की जाती है जो वेग को पूर्व निर्धारित मान के साथ अधिकतम वेग मापदंडों [19] तक सीमित करती है। समीकरण 3 का प्रभाव कणों को सीमा में परिवर्तित करने की प्रवृत्ति के साथ सीमा के भीतर दोलन कराता है।

$$\begin{aligned} \text{If} \quad & v^{k+1} > V_{\max} \quad \text{then} \quad v^{k+1} = V_{\max} \\ \text{Elseif} \quad & v^{k+1} < -V_{\max} \quad \text{then} \quad v^{k+1} = -V_{\max} \end{aligned}$$

समीकरण 3: कण वेग को सीमित करना ( Limiting the particle velocity)

PSO कलन विधि में पाँच चरण हैं [1]–

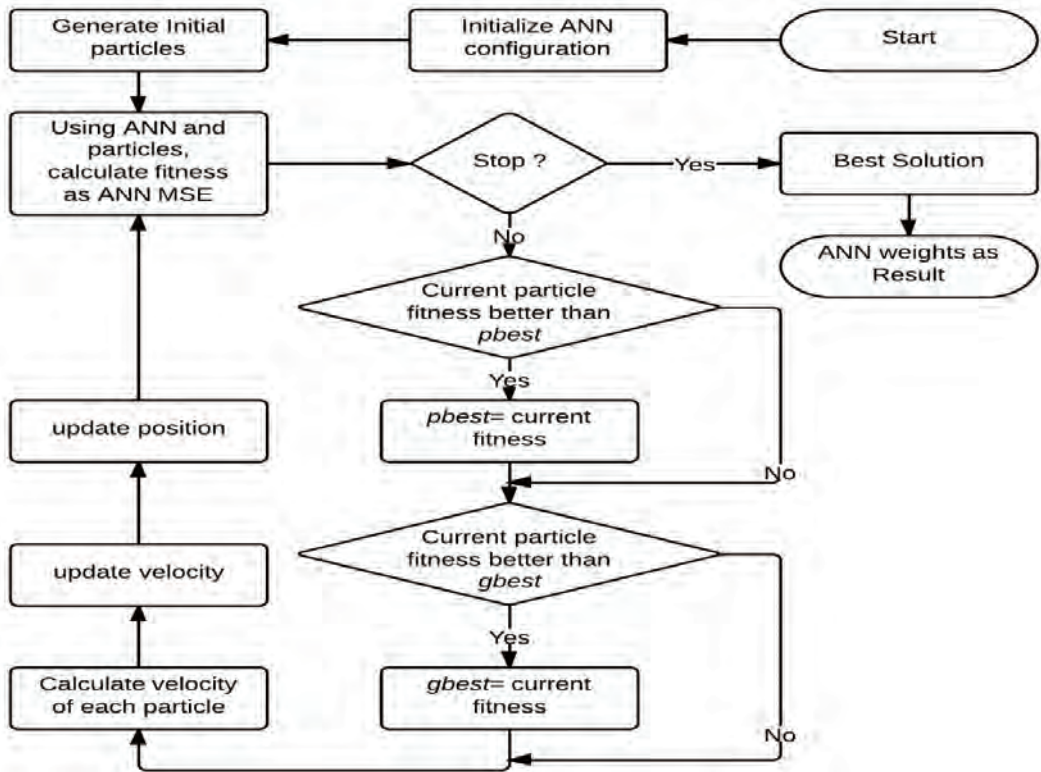
- चरण 1: खोज स्थान के आधार पर झुंड की शुरुआत करें;
- चरण 2: प्रत्येक कण की फिटनेस का मूल्यांकन करें;
- चरण 3: व्यक्तिगत सर्वोत्तम (pb) और वैश्विक सर्वोत्तम (gb) का अद्यतन करें;
- चरण 4: प्रत्येक कण की स्थिति और वेग का अद्यतन करें;
- चरण 5: समाप्ति की स्थिति संतुष्ट होने तक चरण 2 पर जाएं।

#### 4. कण दल इष्टतमीकरण आधारित कृत्रिम तंत्रिका नेटवर्क (PSO based ANN)

चित्र 3 में पीएसओ आधारित एएनएन (PSO based ANN) कलन विधियों का प्रवाह चित्र दिखाया गया है। पीएसओ आधारित एएनएन कलन विधि में महत्वपूर्ण दो भाग हैं:–

**पहला – कृत्रिम तंत्रिका नेटवर्क पूर्वानुमान भाग:** एएनएन नेटवर्क के भार और पूर्वाग्रह (bias) के रूप में कण के एक सेट का चयन किया जाता है। इन सेटों का उपयोग करके, जनसंख्या झुंड बनाया जाता है। प्रत्येक कण की फिटनेस का मूल्यांकन किया जाता है [17]।

**दूसरा – कृत्रिम तंत्रिका नेटवर्क संशोधन भाग:** पहले भाग में आकलन किए गए एएनएन प्रदर्शन के आधार पर, दूसरा भाग भार और पूर्वाग्रह में संशोधन के लिए है [12]। फिटनेस मूल्यांकन, प्रशिक्षण सेट पर औसत वर्ग त्रुटि (mean square error) (एमएसई) है। स्थिति बदलने का मतलब है कि नेटवर्क के भार को ऐसे अपडेट किया जाता है कि वह एमएसई कम कर दे।



चित्र. 3 पीएसओ आधारित एएनएन कलन विधि का प्रवाह चार्ट  
(Flow chart of PSO based ANN Algorithm)

निम्न रूपरेखा पीएसओ आधारित एएनएन कलन विधि को सारांशित करती है:

- चरण 1: प्रारंभिक एएनएन विन्यास, भार और पूर्वाग्रहों की संख्या निर्धारित करे।
- चरण 2: पीएसओ आधारित एएनएन की शुरुआत यादृच्छिक रूप से उत्पन्न प्रारंभिक जनसंख्या के चयन से होती है। एएनएन में परतों और नोड्स के चयन के आधार पर प्रत्येक जनसंख्या को कई वर्गों में विभाजित किया गया है। प्रत्येक कण स्ट्रिंग को एएनएन के लिए कनेक्शन भार के एक समूह के रूप में दर्शाया गया है और कण के प्रत्येक खंड में एएनएन विन्यास, भार और पूर्वाग्रहों का प्रतिनिधित्व होता है। प्रत्येक कण एक माइक्रो एजेंट को प्रदर्शित करता है। प्रशिक्षण डेटा को फिर नेटवर्क में जमा किया जाता है। कणों की जनसंख्या, स्थिति और वेग का प्रारंभिक वर्णन करते हैं।
- चरण 3: प्रारंभिक जनसंख्या के बाद, एएनएन का उपयोग परिणाम की भविष्यवाणी करने के लिए किया जाता है। प्रत्येक कण की फिटनेस का मूल्यांकन करके उन्हें एएनएन वेट के रूप में लागू करते हैं और दिए गए डेटा सेट पर एमएसई निकालते हैं।
- चरण 4: फिटनेस के प्रत्येक कण की तुलना उसके व्यक्तिगत सर्वोत्तम (pb) से करते हैं। यदि pb वर्तमान फिटनेस से कम है, तो pb के रूप में वर्तमान फिटनेस को स्टोर करते हैं।
- चरण 5: कणों के व्यक्तिगत सर्वोत्तम (pb) से, वैश्विक सर्वोत्तम (gb) के साथ सबसे अच्छे फिटनेस मूल्य की




तुलना की जाती है, यदि वर्तमान सबसे अच्छी फिटनेस संग्रहीत निकाले गए gb से बेहतर है, तो gb को अद्यतित करते हैं।

चरण 6: कण के वेग और स्थान को अद्यतित करते हैं।


चरण 7: समाप्ति की स्थिति संतुष्ट होने तक चरण 3 पर जाते हैं। आबादी का सबसे अच्छा कण दी गई समस्या के लिए एनएन के सर्वश्रेष्ठ भार का प्रतिनिधित्व करता है।

## 5. पीएसओ आधारित एनएन द्वारा हवा की गति का पूर्वानुमान (Wind speed forecasting using PSO based ANN)

प्रस्तावित पीएसओ आधारित एनएन पद्धति को महेंद्रगढ़, हरियाणा (भारत) में हवा की गति के पूर्वानुमान के लिए लागू किया गया है। प्रशिक्षण डेटा 7 वर्षों का, 1 जनवरी 2011 से 31 दिसंबर 2018 तक चुना गया है, जो वर्ष के चार ऋतु के अनुरूप है। प्रशिक्षित नेटवर्क को मान्य करने के लिए एक वर्ष की पवन गति के डेटा, 1 जनवरी 2019 से 31 दिसंबर 2019 तक का उपयोग किया गया है [21]। तंत्रिका नेटवर्क प्रशिक्षण के दौरान परिसंचारी विधि (circulation method) का उपयोग किया जाता है, जिसमें एक सप्ताह की हवा की गति के डेटा को इनपुट के रूप में चुना जाता है और अगली हवा की गति को लक्षित किया जाता है। पुनरावृत्ति (Iteration) के बाद, डेटा सेट को एक डेटा बिंदु पर अपडेट किया जाता है। डेटा हर 3 घंटे के लिए लिया जाता है जिसका मतलब है कि एक दिन में 8 डेटा यानी 00:00, 03:00, 06:00, 09:00, 12:00, 15:00, 18:00, 21:00 हैं।




क) वास्तविक हवा की गति, ठोस रेखा और पूर्वानुमानित हवा की गति, धराशायी लाइन, मीटर/सेकंड




ख) अनुमान में त्रुटि, मीटर/सेकंड में


चित्र 4: पीएसओ आधारित एनएन से शिशिर ऋतु में हवा की गति का पूर्वानुमान, 3 से 9 जनवरी 2019



चित्र 5: पीएसओ आधारित एनएएन से वसंत ऋतु में हवा की गति का पूर्वानुमान, 18 से 24 अप्रैल 2019



चित्र 6: पीएसओ आधारित एनएएन से वसंत ऋतु में हवा की गति का पूर्वानुमान, 11 से 17 जुलाई 2019



चित्र 7: पीएसओ आधारित एनएएन से वसंत ऋतु में हवा की गति का पूर्वानुमान, 24 से 30 अक्टूबर 2019

मौसम ऋतु को महीने के आधार पर चुना जाता है। प्रस्तावित तंत्रिका नेटवर्क में 57 इनपुट हैं, जिसमें एक सप्ताह की हवा की गति के लिए 56 डेटाबिंदु (प्रतिदिन 8 डेटा) और मौसम ऋतु के लिए एक डेटा शामिल हैं। एनएन परिणाम चित्रों में, वास्तविक हवा की गति को वर्ग के साथ ठोस रेखा (Solid line) द्वारा दर्शाया गया है और पूर्वानुमानित हवा की गति को वृत्त के साथ डैशदार लाइन (Dashed line) द्वारा दर्शाया गया है। हवा की गति के पूर्वानुमान की सटीकता का मूल्यांकन करने के लिए, विभिन्न मानदंडों



का उपयोग किया जाता है। इस सटीकता की गणना वास्तविक हवा की गति के आधार पर की जाती है। औसत निरपेक्ष प्रतिशत त्रुटि (Mean absolute percentage error) (एमएपीई) मानदंड, योग वर्ग त्रुटि (Sum square error) (एसएसई) मानदंड और मानक विचलन त्रुटि (Standard deviation error) (एसडीई) मानदंड उपयोग किए गए हैं।

प्रस्तावित पीएसओ आधारित एएनएन पद्धति के साथ संख्यात्मक परिणाम सर्दियों, वसंत, गर्मियों और शरद ऋतु के दिनों के लिए क्रमशः चित्र 4 से 7 में दिखाए गए हैं। प्रस्तावित पीएसओ आधारित एएनएन के MAPE का औसत मूल्य 4.57% है, जबकि NRM और पिछले ANN दृष्टिकोणों के लिए औसत MAPE मूल्य क्रमशः 19.73% और 7.25% हैं। इसके अलावा, एक पूरे सप्ताह के लिए हवा की गति का पूर्वानुमान लगाने के लिए औसत गणना समय 2 सेकंड है जब 8 जीबी रैम और 2.1-गीगाहर्ट्ज-आधारित प्रोसेसर के साथ पीसी पर MATLAB 2019 के साथ प्रयोग किया जाता है। प्रस्तावित पीएसओ आधारित एएनएन पद्धति हवा की गति के पूर्वानुमान के लिए एक उपन्यास, प्रभावी और सटीक तरीका है।

तालिका 1: दैनिक अग्रेषण त्रुटि का सांख्यिकी विश्लेषण

ऋतु	MAPE			SSE			SDE		
	x	y	z	x	y	z	x	y	z
शिशिर	9.5	6.2	5.3	593.7	164.4	160.1	34.7	14.79	21.15
वसंत	9.9	5.4	6.0	578.1	247.1	233.8	42.4	29.76	25.22
ग्रीष्म	6.3	4.3	4.2	232.5	183.4	157.5	17.1	17.53	16.73
शरद	3.2	3.1	3.0	207.1	168.2	168.8	14.8	16.28	15.64

x= ANN by J. P. S. Catalão et. al.[6] y= BPANN [2] z= proposed PSO based ANN

तालिका 2: हवा की गति के पूर्वानुमान के तरीकों के मौसमी तुलनात्मक एमएपीई परिणाम

विधि	शिशिर	वसंत	ग्रीष्म	शरद	औसत
NRM [23]	13.9	32.4	13.4	16.4	19.03
NN [15]	9.5	9.9	6.3	3.3	7.25
NNWT [30]	9.2	9.6	6.0	3.1	6.98
NF [25]	8.9	9.0	5.6	3.1	6.65
BPANN [2]	6.2	5.4	4.3	3.1	4.83
PSO based ANN	5.3	6.0	4.2	3.0	4.57

तालिका 1 हवा की गति का पूर्वानुमान लगाने में प्रस्तावित पीएसओ आधारित एएनएन पद्धति की सटीकता का मूल्यांकन करने के लिए मानदंड प्रस्तुत करती है। पहला स्तंभ ऋतु को दर्शाता है, दूसरा स्तंभ एमएपीई (MAPE), तीसरा स्तंभ एसएसई (SSE) का वर्गमूल और चौथा स्तंभ एसडीई (SDE) प्रस्तुत करता है। पूर्वानुमान सटीकता मापदंडों की तुलना एएनएन [9] और बीपीएएनएन [1] पद्धति से की जाती है।

तालिका 2 में एनआरएम (NRM) [23], एनएन (NN) [15], एनएनडब्ल्यूटी (NNWT) [30], एनएफ (NF) [25], बीपीएएनएन (BPANN) [2] विधियों के साथ प्रस्तावित पीएसओ आधारित एएनएन पद्धति की

सीजन की तुलना एमएपीई (MAPE) के लिए दिखाई गई है। प्रस्तावित पद्धति में बेहतर पूर्वानुमान सटीकता है क्योंकि अन्य पद्धति की तुलना में एमएपीई का औसत मूल्य 4.57% है, जो अन्य पद्धति एनआरएम (NRM), एनएन (NN), एनएनडब्ल्यूटी (NNWT), एनएफ (NF), बीपीएनएन (BPANN) के लिए क्रमशः 19.03%, 7.25%, 6.69%, 6.65%, 4.83% है। एमएपीई के लिए अन्य पद्धति के साथ प्रस्तावित पद्धति की मासिक तुलना तालिका 3 में प्रस्तुत की गई है। बोल्ट चेहरे के साथ एमएपीई का संख्यात्मक मान उस महीने के दौरान हवा की गति के पूर्वानुमान के लिए सबसे अच्छी पद्धति की ओर इंगित करता है।

तालिका 3: विभिन्न हवा की गति के पूर्वानुमान की विधियों के मासिक एमएपीई परिणाम

महीना	NRM	NN	NNWT	NF	BPANN	PSOANN
जनवरी	16.8	13.6	12.2	10.7	6.2	6.1
फरवरी	22.8	14.6	12.9	11.7	6.3	5.8
मार्च	18.9	12.0	11.0	8.8	5.6	6.1
अप्रैल	22.5	9.4	9.2	8.8	6.8	6.5
मई	16.8	9.9	8.8	8.3	6.0	5.8
जून	36.4	14.2	12.5	11.6	6.3	6.1
जुलाई	20.9	13.6	12.3	11.2	6.2	6.1
अगस्त	13.6	8.4	7.5	6.2	5.2	5.3
सितम्बर	24.2	10.6	10.3	9.9	5.8	6.2
अक्टूबर	26.2	12.9	11.3	10.5	6.8	5.9
नवम्बर	26.2	12.7	12.2	11.4	6.2	5.8
दिसम्बर	16.9	10.0	9.5	9.0	6.0	6.1
औसत	21.9	11.8	10.8	9.8	6.2	5.9

जैसा कि हवा की गति का पूर्वानुमान लगाया गया है, सौर विकिरण और मौसम के अन्य मापदंडों का पूर्वानुमान भी लगाया जा सकता है। जैसे ही नई इष्टतमीकरण कलन विधि विकसित की जाती है, उसका उपयोग पूर्वानुमान के लिए किया जा सकता है।

### निष्कर्ष

इस शोध पत्र में, हवा की गति के पूर्वानुमान के लिए कण दल इष्टतमीकरण आधारित कृत्रिम तंत्रिका नेटवर्क पद्धति का उपयोग प्रस्तावित है, जो हवा की गति और मौसम को ध्यान में रखता है। प्रस्तावित पद्धति एक कुशल फीचर चयन तकनीक से बनी है जो संशोधित राहत, पारस्परिक सूचना तकनीकों और एक तंत्रिका नेटवर्क आधारित पूर्वानुमान इंजन पर आधारित है। महेंद्रगढ़ मौसम केंद्र के वास्तविक आंकड़ों का उपयोग प्रस्तावित पूर्वानुमान पद्धति का परीक्षण करने के लिए किया गया है। प्रस्तुत सिमुलेशन परिणामों के आधार पर, प्रस्तावित पूर्वानुमान पद्धति अन्य परीक्षण किए गए विकल्पों से बेहतर है और कुछ प्रासंगिक साहित्य की तुलना में महत्वपूर्ण सुधार को प्रदर्शित करता है। महेंद्रगढ़ में हवा की गति के पूर्वानुमान के लिए पीएसओ आधारित एनएन पद्धति का उपयोग सफल साबित हुआ है। एमएपीई का औसत मूल्य 4.57% है, जबकि

औसत गणना समय 2 सेकंड से कम है। इसलिए प्रस्तावित पूर्वानुमान पद्धति, सटीकता और गणना समय के लिये अच्छा परिणाम प्रस्तुत करती है। इसलिए प्रस्तुत परिणाम समय श्रृंखला पूर्वानुमान में पीएसओ आधारित एएनएन पद्धति की प्रवीणता को मान्य करते हैं।

Alphabetically sorted Terminology in English	वर्णमालानुसार क्रमबद्ध हिंदी शब्दावली
Activation function	सक्रियण फलन
Algorithms	कलनविधियाँ
Artificial intelligence	कृत्रिम बुद्धि
Artificial Neural Network (INN)	कृत्रिम तंत्रिका नेटवर्क (एएनएन)
Global best	वैश्विक सर्वश्रेष्ठ
Local best	व्यक्तिगत सर्वश्रेष्ठ
Neurons	न्यूरॉन्स
Non-linear	अरैखिक
Optimization	इष्टतमीकरण
Particle Swarm Optimization	कण दल इष्टतमीकरण
Soft computing	मृदु संगणन
Synaptic links	अन्तर्ग्रथनी लिंक
Time series forecasting	समय श्रृंखला पूर्वानुमान
Weight	भार

#### संदर्भ (References)

[1] Alanis, Alma Y., Luis J. Ricalde, Chiara Simetti, and Francesca Odone. "Neural model with particle swarm optimization Kalman learning for forecasting in smart grids." *Mathematical Problems in Engineering*, pp. 1-9, 2013.

[2] Bansal, Ajay Kumar, and Vikas Garg. "Biogeography-Based Optimization (BBO) Trained Neural Networks for Wind Speed Forecasting." In *Proceedings of International Conference on Trends in Computational and*

*Cognitive Engineering*, pp. 79-94, 2021.

[3] Barbounis, T. G., and John B. Theocharis. "Locally recurrent neural networks for long-term wind speed and power prediction", *Neurocomputing* 69, no. 4-6, pp. 466-496, 2006.

[4] Barbounis, Thanasis G., John B. Theocharis, Minas C. Alexiadis, and Petros S. Dokopoulos. "Long-term wind speed and power forecasting using local recurrent neural network models." *IEEE Transactions on Energy Conversion* 21, no. 1, pp. 273-284, 2006.

[5] Blanchard, Tyler, and Biswanath Samanta. "Wind speed forecasting using neural networks." *Wind Engineering* 44, no. 1, pp. 33-48, 2020.

[6] Catalao, J. P. S., H. M. I. Pousinho, V. M. F. Mendes, and V. M. F. Mendes. "An artificial neural network approach for short-term wind power forecasting in Portugal." *Engineering Intelligent Systems for Electrical Engineering and Communications* 17, pp. 1-5, 2009.

[7] Costa, Alexandre, Antonio Crespo, Jorge Navarro, Gil Lizcano, Henrik Madsen, and Everaldo Feitosa. "A review on the young history of the wind power short-term prediction." *Renewable and Sustainable Energy Reviews* 12, no. 6, pp. 1725-1744, 2008.

[8] Duan, Jikai, Hongchao Zuo, Yulong Bai, Jizheng Duan, Mingheng Chang, and Bolong Chen. "Short-term wind speed forecasting using recurrent neural networks with error correction." *Energy*, 217: 119397, 2021.

[9] Eberhart, Russell, and James Kennedy. "Particle swarm optimization." In *Proceedings of the IEEE international conference on neural networks*, vol. 4, pp. 1942-1948, 1995.

[10] Ebrahimzade, Hossein, Gholam Reza Khayati, and Mahin Schaffie. "PSO-ANN-based prediction of cobalt leaching rate from waste lithium-ion batteries." *Journal of Material Cycles and Waste Management* 22, no. 1, pp. 228-239, 2020.

[11] Huang, Chiou-Jye, and Ping-Huan Kuo. "A short-term wind speed forecasting model by using artificial neural networks with stochastic optimization for renewable energy systems." *Energies* 11, no. 10: 2777, 2018.

[12] Kumar, Vijay, Yash Pal, and Madan Mohan

- Tripathi. "Soft computing based techniques for comparative analysis of wind speed and power prediction." *Journal of Information and Optimization Sciences* 41, no. 1, pp. 1-11, 2020.
- [13] Le, Le Thi, Hoang Nguyen, Jie Dou, and Jian Zhou. "A comparative study of PSO-ANN, GA-ANN, ICA-ANN, and ABC-ANN in estimating the heating load of buildings' energy efficiency for smart city planning." *Applied Sciences* 9, no. 13 p. 2630, 2019.
- [14] Lei, Ma, Luan Shiyang, Jiang Chuanwen, Liu Hongling, and Zhang Yan. "A review on the forecasting of wind speed and generated power." *Renewable and Sustainable Energy Reviews* 13, no. 4, pp. 915-920, 2009.
- [15] Mabel, M. Carolin, and E. Fernandez. "Estimation of energy yield from wind farms using artificial neural networks." *IEEE Transactions on energy conversion* 24, no. 2, pp. 459-464, 2009.
- [16] Madhiarasan, M., and S. N. Deepa. "Comparative analysis on hidden neurons estimation in multi layer perceptron neural networks for wind speed forecasting." *Artificial Intelligence Review* 48, no. 4, pp. 449-471, 2017.
- [17] Malik, Hasmat, Vinoop Padmanabhan, and R. Sharma. "PSO-NN-based hybrid model for long-term wind speed prediction: a study on 67 cities of India." In *Applications of Artificial Intelligence Techniques in Engineering*, pp. 319-327, 2019.
- [18] Moayed, Hossein, Mohammad Mehrabi, Mansour Mosallanezhad, Ahmad Safuan A. Rashid, and Biswajeet Pradhan. "Modification of landslide susceptibility mapping using optimized PSO-ANN technique." *Engineering with Computers* 35, no. 3, pp. 967-984, 2019.
- [19] Monfared, Mohammad, Hasan Rastegar, and Hossein Madadi Kojabadi. "A new strategy for wind speed forecasting using artificial intelligent methods." *Renewable energy* 34, no. 3, pp. 845-848, 2009.
- [20] More, Anurag, and M. C. Deo. "Forecasting wind with neural networks." *Marine structures* 16, no. 1, pp. 35-49, 2003.
- [21] National climate data center. [Online]: <http://www.ncdc.noaa.gov/oa/ncdc.html>
- [22] Navas, R. Kaja Bantha, S. Prakash, and T. Sasipraba. "Artificial Neural Network based computing model for wind speed prediction: A case study of Coimbatore, Tamil Nadu, India." *Physica A: Statistical Mechanics and its Applications* 542, pp. 1-6, 2020.
- [23] Nielsen, Torben Skov, Alfred Joensen, Henrik Madsen, Lars Landberg, and Gregor Giebel. "A new reference for wind power forecasting." *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology* 1, no. 1, pp. 29-34, 1998.
- [24] Öztopal, Ahmet. "Artificial neural network approach to spatial estimation of wind velocity data." *Energy Conversion and Management* 47, no. 4, pp. 395-406, 2006.
- [25] Potter, Cameron W., and Michael Negnevitsky. "Very short-term wind forecasting for Tasmanian power generation." *IEEE Transactions on power systems* 21, no. 2, pp. 965-972, 2006.
- [26] Ramirez-Rosado, Ignacio J., L. Alfredo Fernandez-Jimenez, Cláudio Monteiro, João Sousa, and Ricardo Bessa. "Comparison of two new short-term wind-power forecasting systems." *Renewable Energy* 34, no. 7, pp. 1848-1854, 2009.
- [27] Ren, Chao, Ning An, Jianzhou Wang, Lian Li, Bin Hu, and Duo Shang. "Optimal parameters selection for BP neural network based on particle swarm optimization: A case study of wind speed forecasting." *Knowledge-based systems* 56, pp. 226-239, 2014.
- [28] Rukhaiyar, S., M. N. Alam, and N. K. Samadhiya. "A PSO-ANN hybrid model for predicting factor of safety of slope." *International Journal of Geotechnical Engineering* 12, no. 6, pp. 556-566, 2018.
- [29] Wu, Yuan-Kang, and Jing-Shan Hong. "A literature review of wind forecasting technology in the world." In *2007 IEEE Lausanne Power Tech*, pp. 504-509, 2007.
- [30] Yang, Qi, Jianhua Zhang, Xiangfeng Wang, and Wei-guo Li. "Wind speed and generated wind power forecast based on wavelet-neural network." *Power Syst. Technol* 33, no. 17, pp. 44-48, 2009.