

फीड फॉरवर्ड न्यूरल नेटवर्क का उपयोग करके जल शुद्धिकरण प्रकल्प में इष्टतम
कौयगुलांट खुराक की भविष्यवाणी
**Prediction of Optimum Coagulant Dosage in Water Treatment Plant by using
Feed Forward Neural Network**

डॉ डी वी वाडकर¹, डॉ जी सी चिकुटे², श्रीमती पी डी वाडकर³, श्रीमती एम जी चिकुटे⁴
एवं डॉ पी एस पाटिल⁵

Dr. D.V. Wadkar¹, Dr. G.C. Chikute², Mrs. P. D. Wadkar³, Mrs. M.G. Chikute⁴ and Dr. P. S. Patil⁵

^{1,2} Department of Civil Engineering,

AISSMS College of Engineering PUNE (Maharashtra)

³ Department of Electronics and Telecommunication Engineering,

Marathwada Mittr Mandal College of Engineering, PUNE (Maharashtra)

⁴ P.V.G.S. Muktangan School, PUNE (Maharashtra)

⁵ Department of Civil Engineering, D.Y. Patil University, Ambee, PUNE (Maharashtra)

dvwadkar@aissmscoe.com, chikute.ganesh@gmail.com, pallavidny@gmail.com,

pravispatil154@gmail.com, manasiganesh8@gmail.com

Corrospoding Author- Dr. Ganesh C. Chikute, chikute.ganesh@gmail.com

<https://doi.org/10.10427/VP.2025200858>

सारांश

जार परीक्षण का उपयोग कौयगुलांट की इष्टतम खुराक को निर्धारित करने के लिए किया जाता है, जिसके लिए अधिक समय की आवश्यकता होती है। भारत में, जार परीक्षण में देरी के कारण जल शुद्धिकरण प्रकल्प (Water Treatment Plant (WTP)) में कौयगुलांट की खुराक निश्चित अवधि के दौरान स्थिर रखी जाती है, जिससे कौयगुलांट की कम खुराक या अधिक खुराक हो सकती है। जिसके परिणामस्वरूप जल शुद्धिकरण प्रकल्प में पानी की अयोग्य शुद्धता होगी, इसलिए जल शुद्धिकरण प्रकल्प के अंतर्गम (inlet) पानी की गुणवत्ता के अनुसार कौयगुलांट की इष्टतम खुराक को निर्धारित करना ज़रूरी है।

यह शोध कार्य जल शुद्धिकरण प्रकल्प में इष्टतम कौयगुलांट खुराक की भविष्यवाणी करने के लिए कृत्रिम तंत्रिका नेटवर्क (Artificial Neural Network (ANN)) दृष्टिकोण को लागू करने पर केंद्रित है। जल शुद्धिकरण प्रकल्प के अंतर्गम से संबंधित अड़तालीस महीने का दैनिक जल परीक्षण डेटा जुटाया गया है। फीड फॉरवर्ड न्यूरल नेटवर्क (FFNN) कौयगुलांट मॉडल की उपयुक्त संरचना को विभिन्न प्रशिक्षण कार्यों को लागू करके प्रशिक्षण और परीक्षण के कई चरणों के साथ स्थापित किया गया है। जल शुद्धिकरण प्रकल्प में कौयगुलांट खुराक की भविष्यवाणी के लिए फीड फॉरवर्ड न्यूरल नेटवर्क के चार कृत्रिम तंत्रिका नेटवर्क मॉडल विकसित करने के लिए सबसे अच्छा प्रदर्शन करने वाले लेवेनबर्ग-माक्वार्ड (LM) और बायेसियन रेगुलराइजेशन (BR) प्रशिक्षण कार्यों का उपयोग किया गया है। बायेसियन रेगुलराइजेशन प्रशिक्षण समारोह के साथ फीड फॉरवर्ड न्यूरल नेटवर्क कौयगुलांट मॉडल ने सहसंबंध गुणांक $R = 0.943$ (प्रशिक्षण) और $R = 0.945$ (परीक्षण) के अधिकतम मूल्य के साथ कौयगुलांट खुराक के लिए नेटवर्क संरचना (2-50-1) (2-इनपुट पैरामीटर / 50-हिडन नोड्स / 1- आउटपुट पैरामीटर) के साथ उत्कृष्ट अनुमान प्रदान किया है। इस प्रकार, कृत्रिम तंत्रिका नेटवर्क का उपयोग कौयगुलांट प्रक्रिया में जटिल प्रक्रिया को समझने के लिए एक प्रभावी निदान प्रदान करता है और

इसका उपयोग जल शुद्धिकरण प्रकल्प संयंत्र संचालकों और निर्णय निर्माताओं के लिए एक मूल्यवान मूल्यांकन पद्धति के रूप में किया जा सकता है। जिसके चलते वो कौयगुलांट की इष्टतम खुराक की भविष्यवाणी पहले ही जान ले, जो जल शुद्धिकरण प्रकल्प के अंतर्गम पानी की गुणवत्ता में बदलाव होने पर, तुरंत कौयगुलांट की इष्टतम मात्रा निर्धारित कर सके। जिसके चलते कौयगुलांट की कम या ज्यादा होने वाली मात्रा को समय रहते ही टाला जा सके और शुद्धिकरण प्रकल्प संयंत्र से निकलने वाले पानी की गुणवत्ता हर समय बरकरार रहे।

साहित्य अध्ययन से यह पाया गया है कि कई कृत्रिम तंत्रिका नेटवर्क और अस्फुट दृष्टिकोण किसी विशेष जल शुद्धिकरण प्रकल्प संयंत्र के लिए कौयगुलांट खुराक की भविष्यवाणी के लिए उपलब्ध हैं, जबकि वही दृष्टिकोण अन्य जल शुद्धिकरण प्रकल्प संयंत्र के लिए समान भविष्यवाणी नहीं दे सकते हैं। इसलिए यह शोध पत्र महाराष्ट्र (भारत), पिंपरी-चिंचवड नगर निगम (PCMC) के एक जल शुद्धिकरण प्रकल्प संयंत्र के लिए फीड फॉरवर्ड न्यूरल नेटवर्क का उपयोग करके, कौयगुलांट खुराक मॉडलिंग को प्रस्तुत करता है।

Abstract

Jar testing is used to determine the optimal dose of coagulant, which requires more time. In India, the dose of coagulant in Water Treatment Plants (WTP) is kept constant for a certain period due to delays in jar testing, which can result in underdosing or overdosing of coagulant. This research work focuses on applying the Artificial Neural Network (ANN) approach to predict coagulant dosage in WTP. Daily water testing data related to the inlet for forty-eight months has been collected. The appropriate architecture of the Feed Forward Neural Network (FFNN) coagulant model was established through several phases of training and testing by applying various training tasks.

Furthermore, for the prediction of coagulant dosage in WTP, the best performing

Levenberg-Marquardt (LM) and Bayesian Regularization (BR) training functions have been used to develop four ANN models of FFNN. The FFNN coagulant model with BR training function provided excellent estimates for coagulant dosage with a network architecture of (2- Input parameters / 50- Hidden nodes / 1- Output parameter) and achieved maximum correlation coefficients $R = 0.943$ (training) and $R = 0.945$ (testing). Thus, the use of ANN provides an effective diagnosis for understanding the nonlinear behavior in the coagulant process and can be used as a valuable evaluation method for plant operators and decision-makers.

From the literature study, it was found that several ANN and fuzzy approaches are available for predicting coagulant dosage for a particular WTP, whereas the same approaches may not give the same prediction efficiency for other WTPs. Therefore, this paper presents coagulant dosage modeling using feed forward neural networks for a WTP of Pimpri-Chinchwad Municipal Corporation (PCMC) of Maharashtra (India).

मुख्य शब्द: कृत्रिम तंत्रिका नेटवर्क, जल शुद्धिकरण प्रकल्प संयंत्र, कौयगुलांट खुराक, बायेसियन एल्गोरिथ्म

Keywords: Artificial Neural Network, Water Treatment Plant, Coagulant Dosage, Bayesian Algorithm

परिचय

कौयगुलांट एक जल शुद्धिकरण प्रकल्प का महत्वपूर्ण घटक है और इसमें कौयगुलांट की इष्टतम खुराक निर्धारित करना आवश्यक है, क्योंकि अपर्याप्त खुराक के परिणामस्वरूप पानी की अयोग्य शुद्धता होगी। परंपरागत रूप से, जार परीक्षण और संचालकों के अनुभव का उपयोग इष्टतम कौयगुलांट खुराक निर्धारित करने के लिए किया जाता है। हालांकि, जार परीक्षण में अधिक समय लग सकता है और जल शुद्धिकरण प्रकल्प संयंत्र में पानी की गुणवत्ता में होने वाले त्वरित परिवर्तनों के दौरान, जार परीक्षण के

परिणाम कम अनुकूल हो सकते हैं। जब भारी बारिश की असामान्य स्थिति होती है, तो बारिश का पानी जल स्रोत में उच्च गंदगी लाता है और जल शुद्धिकरण प्रकल्प संयंत्र के पारंपरिक संचालन के कारण उपचारित प्रवाह की गुणवत्ता निम्न हो सकती है। इन सीमाओं को पार करने के लिए इष्टतम मॉडलिंग का उपयोग किया जा सकता है। भारत में आमतौर पर जल शुद्धिकरण प्रकल्प संयंत्र में जार परीक्षण के परिणामों में समय की देरी के कारण कौयगुलांट की खुराक को उस अवधि के लिए स्थिर रखा जाता है, जिससे कौयगुलांट की कम खुराक या अधिक खुराक हो सकती है। इसलिए एक जल शुद्धिकरण प्रकल्प संयंत्र में इष्टतम कौयगुलांट खुराक के लिए भविष्यवाणी मॉडल विकसित करने की आवश्यकता है।

जल शुद्धिकरण प्रकल्प संयंत्र के प्रदर्शन, जल की गुणवत्ता और जल शुद्धिकरण प्रकल्प की भौतिक प्रक्रियाओं जैसे छानने का काम, अवसादन, जमावट, वातन और कीटाणुशोधन पर काफी शोध पत्र उपलब्ध है। हमीद एवं अन्य [1] ने जैव-रासायनिक ऑक्सीजन की मांग (Bio-Chemical oxygen demand) और प्रसुप्त ठोसों (suspended solids) की पिछली जानकारी के आधार पर जल शुद्धिकरण प्रकल्प संयंत्र के प्रदर्शन की भविष्यवाणी करने के लिए लेवेनबर्ग-माक्वार्ड (LM) प्रशिक्षण एल्गोरिथ्म के साथ फीड फॉरवर्ड न्यूरल नेटवर्क विकसित किया। राव एवं अन्य [2] ने LM, पुनः वातन दर की भविष्यवाणी करने के लिए फीड फॉरवर्ड न्यूरल नेटवर्क मॉडल विकसित किया। वर्तमान शोध पत्रों के अध्ययन से पता चलता है कि LM एक बहुत ही कुशल एल्गोरिथ्म है। रडुली एवं अन्य [3] ने एफ्लुएंट मापदंडों के साथ जल शुद्धिकरण प्रकल्प संयंत्र के तेजी से प्रदर्शन मूल्यांकन के लिए फीड फॉरवर्ड न्यूरल नेटवर्क भविष्यवाणी मॉडल प्रस्तुत किया। गुआन-डी एवं अन्य [4] ने ताइपे राज्य, ताइवान में जल शुद्धिकरण प्रकल्प संयंत्र के लिए वास्तविक समय पॉली एल्यूमिनियम क्लोराइड (PAC) खुराक की भविष्यवाणी करने के लिए कृत्रिम तंत्रिका नेटवर्क और ANFIS मॉडल प्रस्तुत किया जिसमें वास्तविक

समय PAC खुराक की भविष्यवाणी के लिए दो सिमुलेशन कृत्रिम तंत्रिका नेटवर्क और ANFIS विकसित किए गए हैं। PAC खुराक की भविष्यवाणी के लिए ANFIS मॉडल ($R = 0.896$ और $RMSE = 0.004$ के साथ) कृत्रिम तंत्रिका नेटवर्क से बेहतर है।

पानी की उपचार प्रक्रियाओं का मॉडल बनाना मुश्किल होता है क्योंकि इसमें कई रासायनिक और भौतिक प्रतिक्रियाओं के बीच जटिल परस्पर क्रियाएँ होती हैं। इष्टतम कौयगुलांट खुराक की भविष्यवाणी के लिए कृत्रिम तंत्रिका नेटवर्क का उपयोग किया जाता है। कृत्रिम तंत्रिका नेटवर्क एक जैविक प्रेरित प्रणाली है जिसमें कई पर परस्पर जुड़े तत्व होते हैं जिन्हें न्यूरॉन कहा जाता है। ये न्यूरॉन निवेश, छिपी हुई और निर्गत परत में उपस्थित होते हैं। सभी परतें मानव मस्तिष्क की तन्तुकाओं की तरह अच्छी प्रकार से जुड़ी होती हैं। कृत्रिम तंत्रिका नेटवर्क में गैर-रैखिक और जटिल संबंधों को सीखने और मॉडल बनाने की क्षमता होती है।

कई शोधकर्ताओं ने कौयगुलांट खुराक की भविष्यवाणी के लिए प्रयास किए हैं, जिसका विवरण प्रस्तुत है। लार्मिनी एवं अन्य [5] ने जल शुद्धिकरण प्रकल्प संयंत्र में इष्टतम कौयगुलांट खुराक का वास्तविक समय में मूल्यांकन करने के लिए एक नाजुक सेंसर विकसित किया है। चेन और होउ [6] ने चांगशिंग में ताइपे जल विभाग की जल शुद्धिकरण योजना की कौयगुलांट खुराक नीति की निगरानी के लिए एक व्यावहारिक फीडबैक नियंत्रण प्रणाली बनाई है। मलेशिया में सेगामा जल शुद्धिकरण प्रकल्प संयंत्र के लिए एक प्रतिलोम कृत्रिम तंत्रिका नेटवर्क मॉडल रॉबेंसन एवं अन्य [7] द्वारा विकसित किया गया है। इसी प्रकार, हेडम सलीम एवं अन्य [8] ने अल्जीरिया में एक जल शुद्धिकरण प्रकल्प संयंत्र के कौयगुलांट खुराक की भविष्यवाणी के लिए जीआरएनएन और आरबीएनएन मॉडल का सुझाव दिया है। कुमार एवं अन्य [9] ने एलएम ट्रेनिंग और ANFIS (Adaptive Neuro - Fuzzy Interface System) के साथ कौयगुलांट खुराक की भविष्यवाणी के लिए एक FFNN मॉडल बनाया है। इसके अलावा, बेलो एवं अन्य [10],

[11] ने एक धुंधली स्विचिंग रणनीति पर आधारित विभिन्न भविष्यवाणी नियंत्रण मॉडल का सुझाव दिया है। कैनेडी एवं अन्य [12] ने जैविक घुलित पदार्थ और धुंध की भविष्यवाणी में कृत्रिम तंत्रिका नेटवर्क मॉडल का आकलन किया है। गाओ लैरी एवं अन्य [13] ने समुद्री और खारे पानी दोनों में अल्ट्राफिल्ट्रेशन उपचार का उपयोग करके एक वास्तविक समय खुराक रणनीति बनाई है। वू जी एवं अन्य [14] ने अनुकूली न्यूरल फजी इन्फरेंस सिस्टम के साथ कौयगुलांट खुराक की भविष्यवाणी की है।

परंपरागत रूप से, आदर्श कौयगुलांट खुराक जार परीक्षण के माध्यम से पाई जाती है, जिसके लिए अधिक समय की आवश्यकता होती है। जार परीक्षण में देरी के कारण, भारत में जल शुद्धिकरण प्रकल्प संयंत्र में कौयगुलांट की खुराक कुछ समय तक स्थिर रहती है, जिसके परिणामस्वरूप कौयगुलांट की खुराक या तो बहुत अधिक या बहुत कम हो सकती है। इसलिए संयंत्र संचालक और निर्णय-निर्माता आदर्श कौयगुलांट खुराक का अनुमान लगाने के लिए कृत्रिम तंत्रिका नेटवर्क मॉडल का उपयोग कर सकते हैं।

इस अध्ययन में, कौयगुलांट की इष्टतम खुराक के लिए कई कृत्रिम तंत्रिका नेटवर्क मॉडल विकसित किए गए हैं। एक नेटवर्क विकसित करने के लिए विभिन्न कृत्रिम तंत्रिका नेटवर्क और प्रशिक्षण एल्गोरिथ्म का परीक्षण और तुलना करना आवश्यक है जो उचित समय में संतोषजनक प्रदर्शन कर सके। प्रत्येक मॉडल को कई बार प्रशिक्षित किया जाता है और सर्वोत्तम प्रदर्शन का मूल्यांकन किया जाता है। इस मॉडल का उपयोग करके, जल शुद्धिकरण प्रकल्प संयंत्र में पानी की गुणवत्ता मापदंडों के आधार पर इष्टतम कौयगुलांट खुराक की भविष्यवाणी संभव है।

साहित्य अध्ययन से यह पाया गया है कि कई कृत्रिम तंत्रिका नेटवर्क और अस्फुट दृष्टिकोण किसी विशेष जल शुद्धिकरण प्रकल्प संयंत्र के लिए कौयगुलांट खुराक की भविष्यवाणी के लिए उपलब्ध हैं, जबकि वही दृष्टिकोण अन्य जल शुद्धिकरण प्रकल्प संयंत्र के लिए समान भविष्यवाणी दक्षता नहीं दे सकते हैं। इसलिए यह शोध पत्र महाराष्ट्र (भारत) के

पिंपरी-चिंचवड नगर निगम (PCMC) के एक जल शुद्धिकरण प्रकल्प संयंत्र के लिए फीड फॉरवर्ड न्यूरल नेटवर्क का उपयोग करके कौयगुलांट खुराक मॉडलिंग प्रस्तुत करता है।

सामग्री और तरीके

अध्ययन क्षेत्र


अध्ययनाधीन प्रकल्प, पिंपरी-चिंचवड नगर निगम (PCMC), महाराष्ट्र (भारत) में स्थित है। इसमें 18° 37' 33.87" N अक्षांश और 73° 48' 43.76" E देशांतर के वैश्विक निर्देशांक हैं। इस शहर में 59 एलिवेटेड स्टोरेज जलाशय और 1,17,936 पानी के कनेक्शन के साथ 170 एलपीसीडी की औसत जल आपूर्ति है। यह जल शुद्धिकरण प्रकल्प संयंत्र 177 वर्ग किमी के क्षेत्र में 428 एमएलडी पानी की आपूर्ति करता है।

कार्यप्रणाली

इस अध्ययन का उद्देश्य बहु-परत FFNN पर आधारित एक कुशल कृत्रिम नेटवर्क स्थापित करना है, ताकि इसे पानी की गंदगी के परिवर्तनीय मूल्यों के लिए कौयगुलांट खुराक की मात्रा निर्धारण के लिए लागू किया जा सके। कृत्रिम तंत्रिका नेटवर्क मॉडल के विकास के लिए निवेश प्राचल के रूप में अंतर्गम और निर्गम जल का मैलापन और निर्गम प्राचल के रूप में कौयगुलांट खुराक निर्धारित की है। कौयगुलांट डोज़ न्यूरल नेटवर्क (CDNN) मॉडल के निवेश परत में अंतर्गम और निर्गम पानी की गंदगी के साथ विकसित किया गया है जबकि निर्गम परत कौयगुलांट खुराक की भविष्यवाणी करती है जैसा कि चित्र 1 में दिखाया गया है। चार वर्षों अर्थात् वर्ष 2014 से वर्ष 2017 तक के निवेश और निर्गम मापदंडों का दैनिक डेटा संयंत्र प्रयोगशाला से प्राप्त किया गया है। कृत्रिम तंत्रिका नेटवर्क मॉडलिंग के लिए आवश्यक निवेश और निर्गम मापदंडों के डेटाबेस में 11,688 डेटा पॉइंट हैं। डेटा अंतराल दिन सुबह 7 बजे से अगले दिन सुबह 7 बजे तक तीन-तीन घंटे के अंतराल का है।

इस अध्ययन में डेटा को प्रशिक्षण और परीक्षण सेट में इस तरह विभाजित किया गया है कि उनका

100% तक जुड़ जाए। अपनाया गया विभाजन 80:20 है। इसमें 80% प्रशिक्षण डेटा कृत्रिम तंत्रिका नेटवर्क मॉडल को प्रशिक्षित करने के लिए उपयोग किया जाता है। डेटा के इस हिस्से का उपयोग निवेश सुविधाओं और लक्ष्य चर के बीच संबंधों को जानने के लिए किया जाता है। 20% परीक्षण डेटा का उपयोग कृत्रिम तंत्रिका नेटवर्क मॉडल का परीक्षण करने के लिए किया जाता है। इस हिस्से को प्रशिक्षण डेटा से अलग रखा जाता है और इसका उपयोग मॉडल के प्रदर्शन और अनदेखी डेटा के सामान्यीकरण का मूल्यांकन करने के लिए किया जाता है। डेटा श्रृंखला सामान्य वितरण के करीब है, इसलिए प्रशिक्षण एल्गोरिथ्म को बदलकर और कठोर प्रशिक्षण द्वारा बेहतर परिणाम प्राप्त किए जा सकते हैं। FFNN मॉडल के विकास के लिए, प्रशिक्षण फलन जैसे कि, लेवेनबर्ग-माक्वार्ड (LM), बायेसियन नियमतीकरण (BR), लचीला बैक-प्रोपेगेशन (RP), बीएफजीएस क्वासी-न्यूटन (BFG), वन स्टेप सेकेंट (OSS), संयुग्म ग्रेडिएंट बैक-प्रोपेगेशन (CGB), फ्लेचर-पॉवेल (GCF), वेरिएबल लर्निंग रेट ग्रेडिएंट डिसेंट (VLRGD), ग्रेडिएंट डिसेंट (GD), और ग्रेडिएंट डिसेंट विद मोमेंटम (GDM) का उपयोग किया गया है।




चित्र 1: कौयगुलांट खुराक तंत्रिका नेटवर्क मॉडल

प्रशिक्षण के दौरान, सिग्मॉइड ट्रांसफर फलनों का उपयोग किया गया है। न्यूनतम-अधिकतम स्केलिंग द्वारा निवेशी और निर्गत डेटा को सामान्य किया गया है। मॉडल विकास के लिए सबसे अच्छा प्रदर्शन करने वाले प्रशिक्षण फलन का चयन किया गया है। प्रशिक्षण एल्गोरिथ्म का सबसे अच्छा संयोजन, हिडन लेयर में न्यूरोन्स की संख्या और उच्चतम R के लिए एपोक की संख्या है, जिनको निर्धारित की जाती है। अंतिम नेटवर्क त्रुटि की गणना के लिए परीक्षण डेटा सेट का उपयोग करके प्रशिक्षित तंत्रिका नेटवर्क का और परीक्षण किया गया है।

परिणाम और विश्लेषण

चर्चा की गई कार्यप्रणाली के आधार पर, कौयगुलांट खुराक की भविष्यवाणी के लिए विभिन्न प्रशिक्षण एल्गोरिथ्म का विश्लेषण किया गया है। मॉडल विकास के लिए प्रशिक्षण एल्गोरिथ्म के प्रदर्शन का सारांश चित्र 2 में दिखाया गया है। यह देखा गया है कि अधिकांश प्रशिक्षण एल्गोरिथ्म ने अच्छा प्रदर्शन दिखाया जबकि कुछ मॉडल ने ऋणात्मक सहसंबंध दिखाया, जिससे मॉडलिंग में अक्षमताओं का संकेत मिलता है। चित्र 2 से यह देखा गया है कि BFG, NRP, CGB, CGF, OSS, GDX, GDM और GD को केवल एक एपोक और 15 छिपे हुए नोड्स की आवश्यकता है; जबकि एलएम और बीआर प्रशिक्षण एल्गोरिथ्म एपोक 12 से 7228 तक और छिपे हुए नोड 15 से 60 तक होते हैं।




चित्र 2: FFNNCD मॉडल के लिए प्रशिक्षण एल्गोरिथ्म का प्रदर्शन


हालांकि LM ($R = 0.944$) और BR ($R = 0.945$) प्रशिक्षण एल्गोरिथ्म अन्य प्रशिक्षण एल्गोरिथ्म की तुलना में अधिक प्रभावी हैं। बीआर प्रशिक्षण एल्गोरिथ्म ओवरफिटिंग के मुद्दे को कुशलतापूर्वक संबोधित करने और जटिल मॉडलों को अनुकूलित करने में सक्षम है। यह किसी भी नेटवर्क को तब तक प्रशिक्षित कर सकता है जब तक इसकी डेरीवेटीव विशेषताओं में वेट, इनपुट और ट्रांसफर एल्गोरिथ्म शामिल होते हैं।

लेवेनबर्ग-माक्वार्ड ट्रेनिंग एल्गोरिथ्म का उपयोग करके फॉरवर्ड न्यूरल नेटवर्क कौयगुलांट डोज़ मॉडल

LM प्रशिक्षण एल्गोरिथ्म (FFNNCD1) का उपयोग करते हुए FFNN कौयगुलांट खुराक मॉडल MATLAB सॉफ्टवेयर में विकसित किया गया है। यह मॉडल LM के साथ विकसित हुआ है, जो LM अनुकूलन के अनुसार वजन और पूर्वाग्रह मूल्यों का अद्यतन करता है। LM अक्सर सबसे तेज़ बैक-प्रोपेगेशन एल्गोरिथ्म होता है और इसे पहली पसंद पर्यवेक्षित एल्गोरिथ्म के रूप में अत्यधिक अनुशंसित किया जाता है, हालांकि इसके लिए अन्य एल्गोरिथ्म की तुलना में अधिक मेमोरी की आवश्यकता होती है। इस मॉडल के परिणामस्वरूप अधिकतम ' $R = 0.944$ ' के साथ 60 छिपे हुए नोड्स मिलते हैं। प्रशिक्षण और परीक्षण अवधि के दौरान FFNNCD1 (2-60-1) (2 Input parameters – 60 Hidden nodes – 1 Output parameter) मॉडल की समय श्रृंखला और स्कैटर प्लॉट चित्र 3 (a) और (b) में दिखाए गए हैं, जो एक अच्छे परिणाम का संकेत देते हैं।




चित्र 3 (a) : प्रशिक्षण और परीक्षण अवधि के दौरान FFNNCD1 (2-60-1) मॉडल की समय श्रृंखला




चित्र 3 (b) : प्रशिक्षण और परीक्षण अवधि के दौरान FFNNCD1 (2-60-1) मॉडल का स्कैटर प्लॉट

बायेसियन रेगुलराइजेशन प्रशिक्षण एल्गोरिथ्म का उपयोग करके फॉरवर्ड न्यूरल नेटवर्क कौयगुलान्ट डोज मॉडल

FFNN कौयगुलान्ट खुराक मॉडल, BR प्रशिक्षण एल्गोरिथ्म (FFNNCD2) का उपयोग करके MATLAB सॉफ्टवेयर में बनाया गया है। यह देखा गया है कि छिपे हुए नोड्स को 5 से बढ़ाकर 15 किया गया, जहां R और MSE तदनुसार बदल गए। 20 से 60 तक छिपे हुए नोड्स के लिए मॉडल के प्रदर्शन में कोई बदलाव नहीं हुआ है। इसी तरह, यह देखा गया है कि प्रशिक्षण के लिए $R = 0.943$ और परीक्षण के लिए $R = 0.945$ के साथ छिपे हुए नोड 50 के लिये प्राप्त की गई सर्वोत्तम भविष्यवाणी है। परीक्षण अवधि के दौरान FFNNCD2 (2 Input parameters – 50 Hidden nodes – 1 Output parameter) मॉडल की समय श्रृंखला और स्कैटर प्लॉट चित्र 4 (a) और (b) में दिखाए गए हैं, जो सर्वोत्तम परिणाम का संकेत देते हैं।



चित्र 4 (a) : परीक्षण अवधि के दौरान FFNNCD2 (2-50-1) मॉडल की समय श्रृंखला



चित्र 4 (b) : परीक्षण अवधि के दौरान FFNNCD2 (2–50–1) मॉडल की समय श्रृंखला और स्कैटर प्लॉट

उपरोक्त अध्ययन से यह पता चलता है कि बीआर प्रशिक्षण एल्गोरिथ्म के साथ FFNNCD 2 (2 Input parameters – 50 Hidden nodes – 1 Output parameter) मॉडल ने FFNNCD 1 (2 Input parameters – 60 Hidden nodes – 1 Output parameter) मॉडल की तुलना में बेहतर प्रदर्शन किया है।

निष्कर्ष

इष्टतम कौयगुलांट खुराक का निर्धारण महत्वपूर्ण है क्योंकि अपर्याप्त खुराक के परिणामस्वरूप पानी की अनुचित शुद्धता होगी। इस शोध पत्र में, PCMC (Pimpri–Chinchwad Municipal Corporation) के एक प्रमुख जल शुद्धिकरण प्रकल्प संयंत्र में कौयगुलांट खुराक की भविष्यवाणी करने के लिए कृत्रिम तंत्रिका नेटवर्क मॉडल विकसित किए गए हैं। ये मॉडल विभिन्न प्रशिक्षण एल्गोरिथ्म का उपयोग करके विकसित किए गए हैं, जहां बीआर प्रशिक्षण एल्गोरिथ्म ने अन्य प्रशिक्षण एल्गोरिथ्म की तुलना में बेहतर भविष्यवाणी प्रदान की है। सभी एलएम और बीआर एनएन मॉडलों ने विशेष रूप से कौयगुलांट खुराक के निम्न और उच्च मूल्यों के लिए अच्छा प्रदर्शन किया है। बीआर प्रशिक्षण एल्गोरिथ्म ($R = 0.945$) के साथ FFNNCD–2 (2 Input parameters – 50 Hidden nodes – 1 Output parameter) मॉडल ने अन्य सभी मॉडलों की तुलना में कौयगुलांट खुराक के लिए सबसे अच्छा पूर्वानुमान प्रदान किया है।

इस प्रकार, प्रस्तुत कृत्रिम तंत्रिका नेटवर्क मॉडल कौयगुलांट के गैर-रैखिक व्यवहार को समझने के लिए एक उपयोगी निदान प्रदान करता है और इसे संयंत्र संचालकों और निर्णय निर्माताओं के लिए एक मूल्यवान प्रदर्शन मूल्यांकन उपकरण के रूप में उपयोग किया जा सकता है। प्रस्तुत कृत्रिम तंत्रिका नेटवर्क मॉडल इनलेट वॉटर टर्बिडिटी के आधार पर अपेक्षित आउटगोइंग वॉटर टर्बिडिटी का अनुमान लगाने में सक्षम होंगे। संक्षेप में, कृत्रिम तंत्रिका नेटवर्क एक अच्छा विकल्प है और जल शुद्धिकरण प्रकल्प संयंत्र में कौयगुलांट की इष्टतम खुराक की भविष्यवाणी के लिए एक शक्तिशाली मॉडल है।

शोध पत्र में प्रयुक्त अंग्रेजी शब्दों की समानार्थक हिंदी शब्दावली

Alphabetically sorted terminology in English	वर्णमाला अनुक्रमित हिंदी शब्दावली
Adaptive Network-Based Fuzzy Inference System (ANFIS)	अनुकूली नेटवर्क – आधारित अस्फुट अनुमान प्रणाली
Artificial Neural Network (ANN)	कृत्रिम तंत्रिका नेटवर्क
Bayesian Regularization (BR)	बेसियन नियमतीकरण
Biochemical Oxygen Demand (BOD)	जैव-रासायनिक ऑक्सीजन मांग
Chemical Oxygen Demand (COD)	रासायनिक ऑक्सीजन मांग
Dissolved Oxygen (DO)	विघटित ऑक्सीजन
Dissolved Oxygen Meter (DOM)	विघटित ऑक्सीजन मीटर
Extreme Learning Machine-Radial Basis Function (ELM-RBF)	चरम अधिगम मशीन – किरण सदृश्य आधारी फलन
Feed Forward Neural Network (FFNN)	अग्र प्रदाय तंत्रिका नेटवर्क
Feed Forward Neural Network Coagulant Dosage Model (FFNNCD1)	अग्र प्रदाय तंत्रिका नेटवर्क कौयगुलांट डोज मॉडल जो लेवेनबर्ग-माक्वार्ड प्रशिक्षण एल्गोरिथ्म का उपयोग करता है
Feed Forward Neural Network Coagulant Dosage Model (FFNNCD2)	अग्र प्रदाय तंत्रिका नेटवर्क कौयगुलांट डोज मॉडल जो बेजीयन संशोधन प्रशिक्षण एल्गोरिथ्म का उपयोग करता है
Fuzzy Weight Multiple Prediction Model (FWMPM)	अस्फुट भार बहुल भविष्यवाणी निदर्श
Levenberg-Marquardt (LM)	लेवेनबर्ग-माक्वार्ड
Mean Absolute Error (MAE)	माध्य निरपेक्ष त्रुटि
Mean Square Error (MSE)	माध्य वर्ग त्रुटि
Root Mean Square Error (RMSE)	मूल माध्य वर्ग त्रुटि

सन्दर्भ

1. Hamed M. M., Galal M. M. and Ezzat A. H. (2004). Prediction of wastewater treatment plant formance using artificial neural networks. Environmental Modelling and Software, 19(10) : 919-928, DOI: 10.1016/j.envsoft.2003.10.005.
2. A. Ramakrishna Rao and Bimlesh Kumar (2007). Neural Modeling of Square Surface Aerators. Journal of Environmental Engineering, 133(4), DOI: 10.1061/(ASCE)0733-9372(2007)133:4(411).
3. Raduly, B. and Gernaey K. (2007). Artificial neural networks for rapid WWTP performance evaluation: Methodology and case study. Environmental Modelling & Software, 22:1208-1216.
4. Guan-De W. and Shang-Lien, L. (2008). Predicting real-time coagulant dosage in water treatment by artificial neural networks and adaptive network-based fuzzy inference system. Engineering Applications of Artificial Intelligence. 21 : 1189–1195.

5. Larmrini B., Benhammou A., Le Lann. M. & Karama, A. (2005). A neural software sensor for online prediction of Coagulant dosage in a drinking WTP. *Transactions of the Institute of Measurements and Control*, 27(3),195-213.
6. Chen, C. L. and Hou, P. L. (2006). Fuzzy model identification and control system design for coagulation chemical dosing of potable water. *Water Sci. Technol Water Supply*, Vol. 6(3), 97–104, doi: 10.2166/ws.2006.782.
7. Robenson, A., Shukor and Araiz, N. (2009). Development of process inverse neural network model to determine the required alum dosage at Segama WTP Sabah, Malaysia. *Computer-aided chemical engg.*, 27, 525–530.
8. Heddam Salim. A. Bermad and Nouredine, D. (2011). Applications of RBF and GRNN for Modeling of Coagulant Dosage in a Drinking WTP: Comparative Study. *Journal of Environmental Engineering*, Vol. (137), pp.1209-1214.
9. J Satheesh Kumar, Poongodi, P. and Balakumaran, P. (2013). Artificial Intelligence Based Alum Dosage Control in Water Treatment Plant. *International Journal of Engineering and Technology (IJET)*, Vol 5 No 4 Aug-Sep 2013,3344-3350.
10. Oladipupo Olubunmi Bello, Yskandar Hamam and Karim D. Djouani, (2014). Coagulation process control in water treatment plants using multiple model predictive control. *Alexandria Engineering Journal*, 53(4), 939-948, DOI: 10.1016/j.aej.2014.08.002.
11. Oladipupo Olubunmi Bello, Yskandar Hamam and Karim D. Djouani, (2015). Multiple Model Predictive Control Based on Fuzzy Switching Scheme of a Coagulation Chemical Dosing Unit for Water Treatment Plant., *IFAC-Papers On-Line*, 48(11), 180–185, DOI: 10.1016/j.ifacol.2015.09.180.
12. Kennedy, M. J., Gandomia, A. H. and Miller, C. M. (2015). Coagulation modeling using ANN to predict both turbidity and DOM-PARAFAC component removal. *J. of Environ. Chemical Engg.*, 3(4)A, 2829–2838.
13. Gao Larry X., Han Gu, Anditya, R. (2017). Self-adaptive cycle to cycle control of inline coagulant dosing in ultrafiltration for pre-treatment of reverse osmosis feed water. *Desalination*, 401 ,22–31, <https://doi.org/10.1016/j.desal.2016.09.024>.
14. Wu G. and Lo, S. L. (2008). Predicting real-time coagulant dosage in water treatment by ANN and adaptive network -based fuzzy inference system. *Engg. Applications of Artificial Intelligence*, 21, 1189– 1195.