

मशीन लर्निंग मॉडल द्वारा भ्रमिल ट्यूब सैंड ट्रैप की ट्रैपिंग दक्षता की भविष्यवाणी

The Prediction of Trapping Efficiency of Vortex Tube Sand Trap by Machine Learning Model

अखिलेश कुमार सिंह¹ और नंद कुमार तिवारी²

Akhilesh Kumar Singh¹ and Nand Kumar Tiwari²

¹ M.Tech.(Student), National Institute of Technology Kurukshetra, Haryana,

²Associate Professor, Department Of Civil Engineering, N.I.T Kurukshetra, Haryana,India

akhilesh_32112509@nitkkr.ac.in, nand@nitkkr.ac.in

<https://doie.org/10.0820/VP.2024214981>

सारांश

डायवर्जन हेड कार्यों के आगमन के बाद से नहर में तलछट का जमाव सिविल इंजीनियरों के लिए एक महत्वपूर्ण चिंता का विषय रहा है। अधिकांश कृषि और विद्युत नहर का पानी हिमालयी नदियों से लिया जाता है, जिनमें बहुत अधिक तलछट सामग्री जमा होती है। भ्रमिल ट्यूब रेत जाल निकलने वाली नहर से गाद सामग्री को बाहर निकालता है। इसमें नहर के पूरे तल पर एक ट्यूब बिछाई गई है, जिसके किनारे पर एक छेद है। यह अन्य स्थानापन्न हाइड्रोलिक उपकरणों की तुलना में बहुत प्रभावी और सस्ता है। इस अध्ययन में भ्रमिल ट्यूब इजेक्टर रेत जाल दक्षता का अनुमान लगाने के लिए डीप न्यूरल नेटवर्क (डीएनएन) और स्टैकड एन्सेम्बल (एसई) मॉडल का उपयोग किया गया। भ्रमिल ट्यूब रेत जाल पर प्रयोगों से 174 प्रेक्षणों का एक डेटा सेट एकत्र किया गया था। 174 डेटासेट में से, यादृच्छिक रूप से चुने गए 134 डेटासेट का उपयोग प्रशिक्षण के लिए किया गया था, जबकि शेष 40 डेटासेट का उपयोग मॉडल के परीक्षण के लिए किया गया था। इनपुट डेटासेट में वेग (मी./से.), तलछट का आकार (मिमी.), तलछट की सांद्रता (पीपीएम), स्लिट की मोटाई और ट्यूब के व्यास का अनुपात (टी/डी), और निष्कर्षण अनुपात (%) शामिल हैं, जबकि ट्रैपिंग दक्षता (%) को आउटपुट माना गया। मॉडल की क्षमता की तुलना करने के लिए दो प्रदर्शन सूचकांकों को नियोजित किया गया था। परिणामों की तुलना से पता चलता है कि एसई मॉडल अन्य डीएनएन मॉडल की तुलना में बेहतर प्रदर्शन करता है। सुग्रहिता विश्लेषण से पता चलता है कि भ्रमिल ट्यूब रेत जाल फंसाने की दक्षता का आकलन करने में निष्कर्षण अनुपात सबसे महत्वपूर्ण प्राचल है।

Abstract

Sediment deposition in the canal has been a significant concern for civil engineers since the advent of diversion head works. Most agricultural and power canal water is taken from Himalayan rivers, which keep much sediment materials. The vortex tube sand trap ejects silt materials from the off-taking channel. It comprises a tube laid across the whole bed of the canal with an opening at the ridge. It is very effective and cheap compared to the other substitute hydraulic devices. This study used Deep Neural Network (DNN) and Stacked Ensemble (SE) models to estimate vortex tube ejector sand trap efficiency. A data set of 174 observations was collected from experiments on the vortex tube sand trap. Out of 174 datasets, 134 datasets chosen randomly were used for training, whereas the residual 40 datasets were used for testing the models. The input dataset consists of

velocity (m/s), sediment size (mm), the concentration of sediment (ppm), the ratio of slit thickness to diameter of the tube (t/d), and extraction ratio (%), whereas trapping efficiency (%) was considered as output. Two performance indices were employed to compare the potential of the model. A comparison of outcomes proposes that the SE model performs better than other DNN models. Sensitivity analysis show that the extraction ratio is the most vital parameter in estimating vortex tube sand trap trapping efficiency.

मुख्य शब्द : डीप न्यूरल नेटवर्क (डीएनएन), स्टैकड एन्सेम्बल (एसई), भ्रमिल ट्यूब रेत जाल दक्षता, सुग्रहिता विश्लेषण।

Keywords: Deep neural network (DNN), Stacked ensemble (SE), vortex tube sand trap efficiency, Sensitivity analysis.

1. परिचय

नदी का हमारे जीवन में बहुत महत्व है और यह देश के वित्तीय विकास में प्रमुख भूमिका निभाती है क्योंकि जलविद्युत, सिंचाई और नेविगेशन जलमार्ग से जुड़े हुए हैं। चैनल में तलछट का जमाव एक मुख्य कठिनाई है जिसका कई देशों को सामना करना पड़ रहा है। भारत में हिमालय क्षेत्र से निकलने वाली अधिकांश नदियाँ तल भार और निलंबित भार के रूप में भारी मात्रा में तलछट भार वहन करती हैं। सिंचाई कार्यों और जलविद्युत योजनाओं के डिजाइन में तलछट प्रमुख समस्याओं में से एक है। तलछट की उच्च सांद्रता वाले नदी के पानी को सिंचाई नहरों की ओर मोड़ दिया जाता है क्योंकि नहरों की परिवहन क्षमता आमतौर पर नदियों की तुलना में कम होती है। यदि भारी तलछट भार नहर में प्रवेश करता है, तो नहर इतने छोटे ढलान के साथ कुल तलछट भार को स्थानांतरित करने में असमर्थ होगी, और तलछट भार का कुछ हिस्सा चैनल में जमा हो जाएगा। सिंचाई और बिजली नहरों में बारीक तलछट की एक निश्चित मात्रा हमेशा सहन की जा सकती

है। हालाँकि, नहर द्वारा ले जाए जाने वाले मोटे तलछट की मात्रा को यथासंभव कम रखना आवश्यक है। बिजली नहरों के मामले में, टरबाइन ब्लेड के जीवन के लिए हानिकारक सभी मोटे पदार्थों को हटा दिया जाना चाहिए। इसलिए यह बहुत महत्वपूर्ण है कि चैनल द्वारा ले जाने वाली तलछट की मात्रा को कम किया जाना चाहिए। यह आवश्यक है कि तलछट के मोटे अंश को नहर में प्रवेश करने से रोका जाए। बिजली चैनलों के मामले में भी, गाद का प्रवेश हाइड्रो-टरबाइन के घटकों के लिए हानिकारक है। इससे टरबाइन की बाल्टी भी विघटित हो जाएगी और कम हो जाएगी, जिससे अंततः टरबाइन की प्रभावशीलता कम हो जाएगी[1]। चैनल में गाद के प्रवेश को प्रबंधित करने के लिए चैनलों में एक अलग प्रकार के इजेक्टिंग डिवाइस का उपयोग किया जाता है। ये भ्रमिल ट्यूब प्रकार [2], निपटान बेसिन [3-4], सुरंग प्रकार [5] और भ्रमिल कक्ष श्रेणी [6-7] हैं। चैनल हेड में तलछट को कम करना एक तलछट बेदखलदार के साथ प्राप्त किया जाता है जो आम तौर पर नहरों को बंद करके उपकरण के माध्यम से भौतिक रूप से हटाने से अलग एक लाभकारी दृष्टिकोण है। सुरंग श्रेणी में 15%-25% निकास प्रवाह के माध्यम से हटाने की प्रभावशीलता लगभग 35% है, इसलिए यह बेहद महंगा है क्योंकि काफी मात्रा में पानी गायब हो जाता है। इसके अलावा ऐसी जगह के लिए उपयुक्त नहीं है जहां जल संकट गंभीर हो। सिंक को व्यवस्थित करने के कई नुकसान हैं क्योंकि इसमें अपेक्षाकृत बड़े स्थान, लंबे समय तक रहने की आवश्यकता होती है, और व्यक्तिगत फ्लशिंग के दौरान कई परेशानी होती है। भ्रमिल-श्रेणी के निपटान कक्ष की सीमाएँ हैं, क्योंकि इसकी योजना और निर्माण चुनौतीपूर्ण हैं। इसके अलावा, यह केवल सीमित मात्रा में गाद वाले पानी को ही हटा सकता है। यह शोध पत्र भ्रमिल ट्यूब-श्रेणी गाद बेदखलदार की जांच करता है, और फँसाने की दक्षता का पूर्वानुमान लगाने के लिए मॉडलिंग का उपयोग किया जाता है। भ्रमिल ट्यूब रेत जाल (वीटीएसटी)

एक सरल संरचनात्मक उपकरण है जिसका उपयोग सिंचाई और बिजली चैनलों से गाद हटाने के लिए किया जाता है [8]। वीटीएसटी एक खुली ट्यूब है जो चैनल के निचले भाग में स्थित होती है, जो या तो धारा के सामान्य होती है या धारा से 30 या 45 (डिग्री) जैसे कुछ कोणों पर होती है [9]। पार्श्व द्वारा विभिन्न प्रकार के वीटीएसटी का परीक्षण किया गया। जैसे ही पानी ट्यूब के ऊपर बहता है, 200 से 500 आरपीएम के क्रम की घूर्णन गति के साथ भ्रमिल प्रवाह स्थापित होता है, जो मोटे बजरी और यहां तक कि कॉबल्स को बाहर निकालने के लिए पर्याप्त है। भ्रमिल ट्यूब आमतौर पर व्यास में बड़े होते हैं। गेट भ्रमिल ट्यूब के डाउनस्ट्रीम छोर पर डिस्चार्ज की गति को नियंत्रित करता है। अधिकतम प्रभावशीलता तब प्राप्त होती है जब ट्यूब के हॉट समान ऊंचाई पर होते हैं, और ट्यूब पर फ्राउड संख्या एक होती है। वीटीएसटी की दक्षता का वर्णन तब किया जाता है जब एक चैनल के अंदर पारित गाद भार का अनुपात निकाला जाता है। अधिकांश समय, नहर के तल कण गाद को नहर के प्रवाह के 10% से 20% के बीच बाहर रखा जा सकता है [8]। वीटीएसटी की ट्रेपिंग प्रभावशीलता की जांच के लिए भौतिक और संख्यात्मक मॉडलिंग को नियोजित किया गया था। वीटीएसटी संरचना में सरल और कुशल है। इसका उपयोग उन क्षेत्रों में निलंबित लोड और बेड लोड गाद को हटाने के लिए किया जाता है जहां गंभीर जल संकट है। तलछट को प्रवाहित करने के लिए 5% से 10% पानी की हानि की आवश्यकता होती है। अन्य प्रकार के इजेक्टरों की तुलना में, वीटीएसटी बहुत छोटा है और इसे स्थापित करना आसान है। अन्य इजेक्टर की तुलना में इसकी स्थापना लागत कम है। कई मामलों में, वीटीई अतिरिक्त विघटन उपकरण का अधिक किफायती और पानी कम करने वाला विकल्प है। इसके अलावा वीटीई के भीतर स्ट्रीम डिवाइस इतनी जटिल है कि तलछट फंसाने की दक्षता का पूर्वानुमान लगाने के लिए पारंपरिक प्रतिगमन प्रोटोटाइप सही ढंग से स्थापित करना

जटिल है। परिणामस्वरूप, मशीन लर्निंग को एक अन्य तकनीक के रूप में उपयोग किया जा सकता है। इसके अलावा, मशीन लर्निंग विश्लेषण अब जल संसाधन इंजीनियरिंग के कई क्षेत्रों में व्यापक रूप से उपयोग किया जाता है। वर्तमान अध्ययन का उद्देश्य स्टैक्ड एन्सेम्बल (एसई) और डीप न्यूरल नेटवर्क (डीएनएन) की तकनीक का उपयोग करके डेटाबेस का विश्लेषण करना है ताकि यह देखा जा सके कि ट्रेपिंग दक्षता का बढ़ा हुआ पूर्वानुमान प्राप्त करने योग्य है या नहीं। परिणामों की तुलना से पता चलता है कि एसई मॉडल, डीएनएन मॉडल की तुलना में अच्छा निष्पादनकर्ता है।

1.1. लक्ष्य और उद्देश्य

कई शोधकर्ताओं ने वीटीएसटी प्रभावशीलता को बढ़ाने के लिए भौतिक मॉडलिंग का उपयोग करके भ्रमिल ट्यूब इजेक्टर में कई ज्यामितीय समायोजन किए हैं। फंसाने की दक्षता के परिणामों को अभी भी संशोधित करने रहने की आवश्यकता है। लोकप्रिय भ्रमिल ट्यूब योजना अंगूठे के कानून, अनुभवजन्य समीकरणों, पिछली धारणाओं, भौतिक प्रोटोटाइप विश्लेषण और पारंपरिक तरीकों के अनुसार है। चूंकि भ्रमिल ट्यूब के दौरान धारा उपकरण कठिन और अरेखीय होता है, आमतौर पर देखे गए रिश्तों के ट्रेपिंग दक्षता की पूरी तरह से भविष्यवाणी करने के लिए एक प्रोटोटाइप बनाने की चुनौती दी जाती है। यह रिपोर्ट वीटीएसटी की गाद-फंसाने की प्रभावशीलता का पूर्वानुमान लगाने के लिए सुझाई गई एमएल तकनीकों और पारंपरिक और पहले जारी किए गए प्रोटोटाइप की जांच करती है। कई कारक वीटीएसटी की गाद फंसाने की क्षमता को प्रभावित करते हैं, साथ ही व्यास से स्लिट-मोटाई का अनुपात, विचलन का कोण, गाद का आकार, वेग, गाद की तीव्रता, इसके अलावा पलशिंग डिस्चार्ज की मात्रा भी प्रभावित करते हैं। वीटीएसटी में स्ट्रीम प्रदर्शन बेहद कठिन है, जिससे मानक प्रोटोटाइप का उपयोग करके गाद फंसाने की प्रभावशीलता का अनुमान लगाना मुश्किल

हो जाता है। वर्तमान जांच मशीन लर्निंग (एमएल) दृष्टिकोण जैसे स्टैकड एन्सेम्बल (एसई) और डीप न्यूरल नेटवर्क (डीएनएन) पर केंद्रित है, जो प्रवाह के गैर-रेखीय व्यवहार को ट्रैक कर सकता है। एमएल विधियों का उपयोग करके वीटीएसटी की अनुमानित ट्रेपिंग दक्षता की तुलना आपस में की जाती है।

2. सामग्री और तरीके

कंप्यूटर उपकरणों के सुधार का अध्ययन जो सामान्य रूप से किसी व्यक्ति की बुद्धि की आवश्यकता के लिए गतिविधियों को पूरा कर सकता है, मशीन लर्निंग (एमएल) के रूप में जाना जाता है, जो कंप्यूटर विज्ञान इंजीनियरिंग का एक उपक्षेत्र है। एमएल एक विशाल, वितरित समानांतर प्रोसेसर है जो प्रयोगात्मक ज्ञान को सीखता है और बनाए रखता है। ये प्रोटोटाइप कई आवश्यक कम्प्यूटेशनल उपकरणों या न्यूरॉन्स को जोड़कर उचित सामान्य निष्पादन प्राप्त करने का प्रयास करते हैं। कृत्रिम बुद्धिमत्ता मॉडल को सटीक बनाने के लिए नेटवर्क संरचना, नोड फंक्शन और शिक्षा या सीखने के नियमों का उपयोग किया जाता है। ये दिशानिर्देश वजन के शुरुआती सेट को निर्दिष्ट करते हैं और विस्तार से बताते हैं कि प्रशिक्षण अवधि के दौरान प्रदर्शन को बढ़ाने के लिए उन्हें कैसे बदला जाना चाहिए।


2.1. डीप न्यूरल नेटवर्क (डीएनएन)

डीप न्यूरल नेटवर्क को एक गहरे मल्टीलेयर न्यूरल नेटवर्क के रूप में भी जाना जाता है क्योंकि इसमें एक से अधिक छिपी हुई परतें होती हैं, और प्राप्त नोड्स की संख्या एनएन की तुलना में बहुत बड़ी है। तंत्रिका नेटवर्क विभिन्न आकारों में आते हैं, लेकिन उन सभी के आवश्यक घटक समान होते हैं। यह भी मानव मस्तिष्क के समान कार्य करता है और इसे अन्य मशीन लर्निंग एल्गोरिथ्म के लिए प्रशिक्षित किया जा सकता है। इनपुट चर या नोड्स की संख्या, भार और पूर्वाग्रहों से गुणा की जाती है, एक विशिष्ट सक्रियण फलन के तहत समायोजित और आगे बढ़ती है, जैसे कि सिग्मॉइड रेक्टिफाइड

लीनियर एक्टिवेशन यूनिट (ReLU), tanh, और इसी तरह, जिसे यादृच्छिक रूप से प्रारंभ किया जाता है। चित्र 1 में दिखाए गए छिपे हुए न्यूरॉन्स को सक्रिय करने के लिए पूर्वाग्रह और वजन को समायोजित करने के लिए त्रुटि के पीछे प्रसार का उपयोग किया जाता है। फॉरवर्डिंग पास में, यह उनके आंतरिक कारकों की गणना करता है। फिर, बैक प्रसार के दौरान, यह इनपुट डेटा संरचनाओं को निकालने के लिए पुनरावृत्त रूप से पॉलिश करता है। यह इनपुट मान जोड़कर शुरु होता है, जिसे आउटपुट उत्पन्न करने के लिए सक्रियण फलन के माध्यम से पारित किया जाता है। सक्रियण फलन के रूप में, किसी भी विभेदक फलन का उपयोग किया जा सकता है। DNN सभी डील-आउट नोड्स को परतों में व्यवस्थित करता है। समान परत में कोई नोड जुड़े नहीं हैं। डीएनएन में आम तौर पर एक इनपुट परत होती है जो नेटवर्क में दिखाए गए डेटा के लिए वितरण संरचना के रूप में कार्य करती है लेकिन प्रसंस्करण के लिए उपयोग नहीं की जाती है, और फिर प्रसंस्करण स्तर के साथ एक या अधिक छिपी हुई परतें आती हैं। आउटपुट लेयर प्रोसेसिंग लेयर का परिणाम है। एक युग तब होता है जब एक संपूर्ण प्रशिक्षण डेटासेट ने तंत्रिका नेटवर्क को आगे और पीछे दोनों दिशाओं में पार कर लिया हो। सक्रियण फलन डेटा के अधिक परिष्कृत पहलुओं को जानने के लिए न्यूरॉन नेटवर्क में गैर-रैखिकता का परिचय देते हैं। रेक्टिफाइड रैखिक सक्रियण फलन (RELU) एक टुकड़ा-वार रैखिक फलन है जिसका उपयोग DNN को डिजाइन करने के लिए किया जाता है। यदि इनपुट मान सकारात्मक है तो रेक्टिफाइड रैखिक सक्रियण फलन एक सकारात्मक मान आउटपुट करता है; अन्यथा, आउटपुट शून्य है और प्रशिक्षित करना आसान है। यह पता चला है कि DNN के साथ उपयोग करने पर RELU का उपयोग अन्य सक्रियण कार्यों से बेहतर प्रदर्शन करता है। रेक्टिफायर सक्रियण फलन इस प्रकार दिया गया है

$$f(x_m) = \max(0, x_m)$$

जहाँ x_m न्यूरॉन इनपुट है, एक विशिष्ट सक्रियण फलन, जैसे सिग्मॉइड, ReLU, और tanh, जो वजन और पूर्वाग्रह से गुणा किए गए किसी दिए गए इनपुट चर या नोड संख्या के तहत समायोजित और आगे बढ़ता है। उपरोक्त समग्र प्रक्रिया कई छिपी हुई परतों पर होती है और चित्र 1 में दिखाए गए छिपे हुए न्यूरॉन्स को सक्रिय करने के लिए, पूर्वाग्रह और वजन को समायोजित करने के लिए त्रुटि के पीछे प्रसार का उपयोग किया जाता है। डीएनएन प्रशिक्षण चरण के दौरान, सीखने की दर उपयोगकर्ता-परिभाषित पैरामीटर है जिसका उपयोग नेटवर्क भार को अद्यतन और संशोधित करने के लिए किया जाता है। इसका चयन पहले के अनुभवों और प्रकाशित कार्यों के आधार पर मनमाने ढंग से किया जाता है।



चित्र.1. डीएनएन की संरचना

2.2. स्टैकड एंसेम्बल (एसई)

एसई विधि, जिसे सबसे पहले [10] द्वारा प्रक्षेपित किया गया था और [11] द्वारा परिभाषित किया गया था, को एक स्टैकड सामान्यीकरण के रूप में भी पहचाना जाता है, क्योंकि यह मेटा लर्नर की अवधारणा का परिचय देता है, जो विभिन्न मॉडलों को मिश्रित

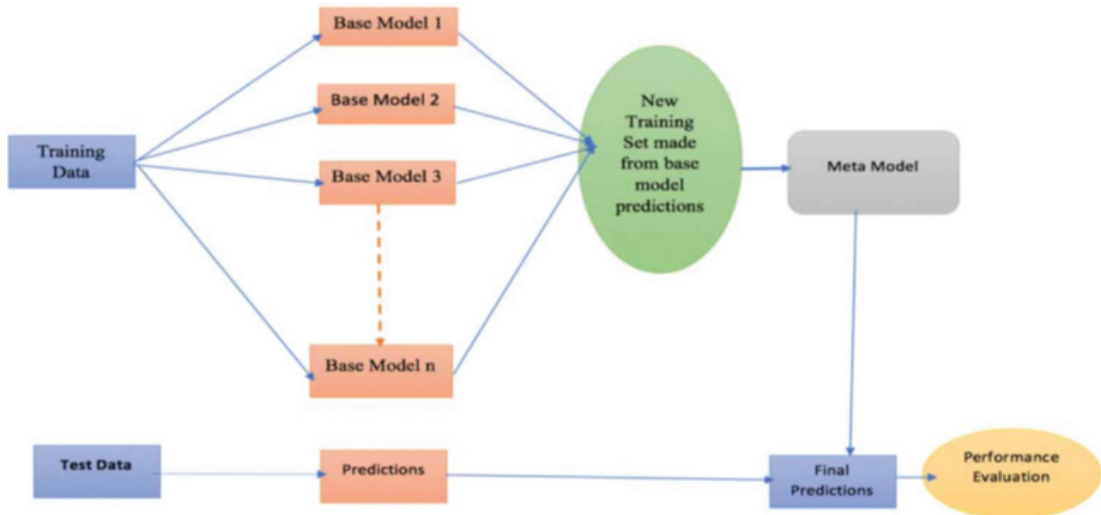
करने की एक विशिष्ट विधि है। पारंपरिक स्टैकिंग एक दो-परत असंबली है जिसमें अगली परत (स्तर-1 मॉडल) के मेटा-मॉडल का उपयोग पहली परत के आधार शिक्षार्थियों (स्तर-0) के परिणामों को एकत्रित करने के लिए किया जाता है। पिछले अध्ययनों से पता चला है कि स्टैकिंग मॉडल की सफलता में आधार शिक्षार्थियों की सटीकता और विविधता महत्वपूर्ण घटक हैं [12]। जब आधार शिक्षार्थियों की तुलना की जाती है, तो यह उम्मीद की जाती है कि कई विविध आधार शिक्षार्थियों को एकजुट करने के लिए स्टैक का उपयोग करना जो प्रभावी ढंग से एक-दूसरे की खामियों की भरपाई कर सकते हैं, अनुमानों में सुधार करेंगे। परिणामस्वरूप, उपयुक्त फाउंडेशन शिक्षार्थियों का चयन करना स्टैकिंग का एक महत्वपूर्ण पहलू है। अधिकांश अध्ययनों ने मॉडलों का मूल्यांकन केवल उनकी सटीकता के आधार पर किया है, लेकिन

विविधताओं को प्रभावी ढंग से परिभाषित नहीं किया गया है [13]। चित्र 2 वर्तमान अध्ययन में सटीकता और विविधता के आधार पर आधार शिक्षार्थियों के चयन को दर्शाता है।

आँकड़ों को यादृच्छिक रूप से प्रशिक्षण डेटा (75%) और परीक्षण डेटा (25%) में विभाजित किया गया था, और अंशांकन डेटा को 5 गुना में विभाजित किया गया था। प्रत्येक 5 पुनरावृत्तियों के लिए आधार

शिक्षार्थियों को अंशांकित करने के लिए 4 फोल्ड चुने गए थे, जबकि ट्रेपिंग दक्षता की भविष्यवाणी करने के लिए अवशिष्ट फोल्ड का उपयोग नहीं किया गया था। मेटा-फीचर्स मेटा-लर्नर के लिए इनपुट पैरामीटर के रूप में कार्य करते थे और पांच गुना क्रॉस-वैध भविष्यवाणियां थीं। मेटा शिक्षार्थी को प्रशिक्षित करने के लिए मापदंडों का अंक आधार शिक्षार्थियों के अंक के बराबर था जब मूल सामग्री को स्टैकिंग में एकीकृत नहीं किया गया था। जीबीएम मॉडल, वितरित यादृच्छिक वन (डीआरएफ), और अत्यंत यादृच्छिक पेड़ (एक्सआरटी) मॉडल विधियों को आवेदक आधार शिक्षार्थियों के रूप में नियोजित

आधार शिक्षार्थियों के रूप में किया गया था, जो कई सामूहिक तरीकों से तुलनीय था। ट्रेपिंग की दक्षता की गणना संबंधित स्टैकिंग मॉडल के आउटपुट का उपयोग करके की गई थी। मेटा-मॉडल एक सरल जनरल लीनियर मॉडल (जीएलएम) है, जो बेस मॉडल के अनुमानों की एक समान व्याख्या प्रदान कर सकता है। प्राथमिक विशेषताओं का उपयोग जीबीएम, डीआरएफ और एक्सआरटी द्वारा प्रदान किए गए विशिष्ट महत्व मूल्यों द्वारा आधार शिक्षार्थियों को प्रशिक्षित करने के लिए किया गया था। स्टैकिंग मॉडल में मेटा लर्नर के पूरक इनपुट के रूप में चार आवश्यक सुविधाओं का उपयोग किया गया था।



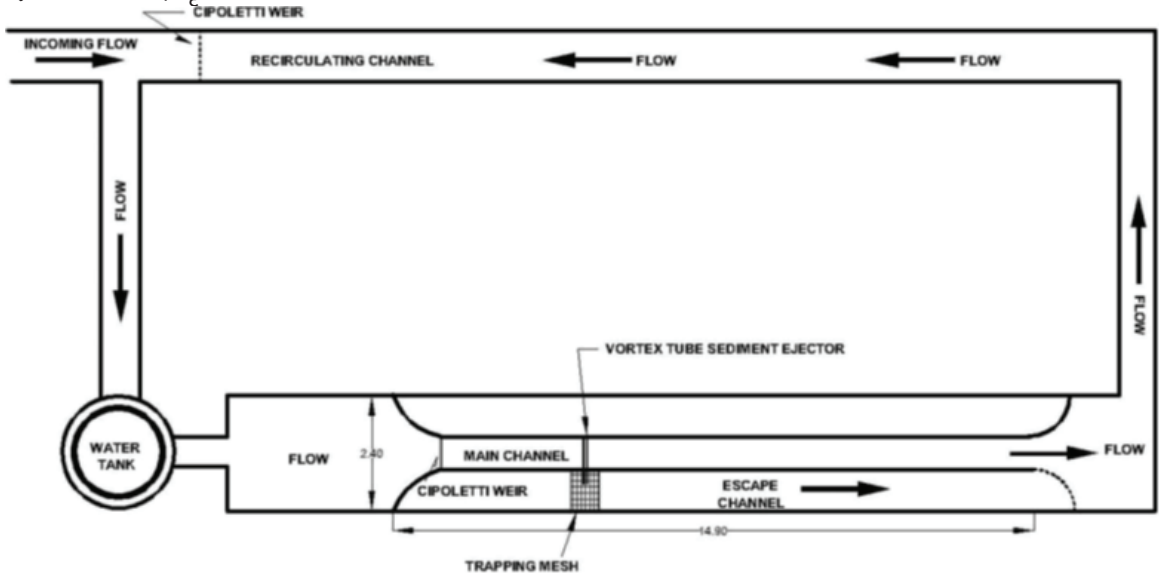
किया गया था। इसके अलावा, कुछ अध्ययनों से पता चलता है कि प्रत्येक उपलब्ध शिक्षार्थी के बजाय केवल कुछ आधार शिक्षार्थियों को संयुक्त रूप से स्तरित किया जाना चाहिए, जिसमें तीन या चार आधार शिक्षार्थी सर्वोत्तम संभव हैं। परिणामस्वरूप, वर्तमान अध्ययन में, ट्रेपिंग प्रभावशीलता प्रदर्शन के पूर्वानुमान के लिए तीन-स्टैक बेस शिक्षार्थियों का विश्लेषण किया जाता है। व्यक्तिगत शिक्षार्थियों की स्टैकिंग दक्षता का अनुमान लगाने के लिए जीबीएम, डीआरएफ और एक्सआरटी का उपयोग

चित्र .2. एस.ई. की संरचना

2.3. प्रयोग सेटअप विवरण

यह परीक्षण कुरुक्षेत्र में एनआईटी हाइड्रोलिक लैब में 30 सेमी. चौड़ी, 50 सेमी. गहरी और 1490 सेमी. लंबी लचीली नहर में किया गया था। इसमें 16 लीटर/सेकेंड का चरम प्रवाह है और एक तंत्र है जो गुरुत्वाकर्षण बल के तहत पानी को नाबदान के रूप में जमीन के ऊपर बने टैंक में प्रसारित करता है। अधिकतम दक्षता प्राप्त करने के लिए, भ्रमिल ट्यूब

को मुख्य चैनल के इनलेट से 3.92 मीटर की दूरी पर चैनल में रखा गया था ताकि कोई भी कण इजेक्टर की उपलब्धि से पहले व्यवस्थित न हो सके। भ्रमिल ट्यूब के अंत में, जहां गाद का पानी निकलता है, एक नियंत्रण वाल्व होता है। भ्रमिल ट्यूब से निष्कासन इजेक्शन को समायोजित करने और ट्रैपिंग उपकरण में गाद जमा होने की अनुमति देता है। द्रव निकास नहर में वापस आ जाता है। ट्रैपिंग उपकरण में जमा सिल्ट को सूखा दिया जाता है। इसके अलावा, उनके भार की गणना वीटीएसटी प्रभावशीलता का अनुमान लगाने के लिए की जाती है। चैनल में वेग निर्धारित करने के लिए वर्तमान मीटर का उपयोग किया जाता है और प्रवाह की गहराई की गणना 0.01 सेमी. संवेदनशीलता सूचक गेज के साथ की जाती है। सिपोलेटी वियर का उपयोग चैनल डिस्चार्ज को मापने के लिए भी किया जाता है। प्रमुख वाहिनी में धारा की दर 29 से 33 सेमी./सेकंड तक होती है, जबकि गहराई 9 से 16 सेमी. तक होती है। चित्र 3 प्रायोगिक सेटअप का एक योजनाबद्ध दृश्य दिखाता है।



चित्र.3. प्रायोगिक सेटअप का योजनाबद्ध आरेख.

2.4. डेटा प्रभाग

प्रयोगशाला में किए गए अध्ययनों से कुल 174 प्रेक्षण प्राप्त हुए। पूरे डेटा को बेतरतीब ढंग से दो खंडों में विभाजित किया गया था, जिसमें 75% डेटा (134) का उपयोग अंशांकन के लिए और 25% आंकड़ों (40) का उपयोग सत्यापन के लिए किया गया था। पांच इनपुट चर थे: मिमी. में सिल्ट का आयाम (एसजेड), (मी./से.) में वेग, पीपीएम में गाद की तीव्रता (आई), (t/d), अनुपात, जहां t सेंटीमीटर में सिल्ट की चौड़ाई है और d सेंटीमीटर में भ्रमिल पाइप का व्यास है, "एक्सट्रो" निष्कासन अनुपात (%) है, और "T.E." ट्रैपिंग दक्षता (%) को इंगित करता है, यह सिस्टम का आउटपुट है। आंकड़ों के अंशांकन और सत्यापन की संख्यात्मक जांच तालिका 1 में प्रदर्शित की गई है। कार्यप्रणाली का प्रवाह आरेख चित्र 4 में दिखाया गया है।

3. सांख्यिकीय प्रदर्शन मॉडलिंग मानदंड

3.1. मूल माध्य वर्ग त्रुटि (आरएमएसई)

आरएमएसई त्रुटि के वर्ग के योग और अवलोकनों की संख्या के अनुपात का वर्गमूल है।

$$RMSE = \sqrt{\frac{\sum_{k=0}^n (A_k - P_k)^2}{n}}$$

जहाँ A_k = माध्य प्रेक्षित मान, P_k = माध्य अनुमानित मान, n = प्रेक्षणों की संख्या

सहसंबंध गुणांक


इसका उपयोग वास्तविक अवलोकनों के साथ मॉडल की भविष्यवाणी के लिए किया जाता है।

सहसंबंध गुणांक

$$= \frac{n \sum_{k=0}^n A_k P_k - (\sum_{k=0}^n A_k)(\sum_{k=0}^n P_k)}{\sqrt{n(\sum_{k=0}^n A_k^2) - (\sum_{k=0}^n A_k)^2} \sqrt{n(\sum_{k=0}^n P_k^2) - (\sum_{k=0}^n P_k)^2}}$$

तालिका 1. प्रशिक्षण और परीक्षण डेटा

Parameters	Units	Min.	Max.	Mean	Std.	Kurtosis	Skewness
Training							
Sz	mm	0.21	0.84	0.470	0.211	-0.586	0.677
Velocity	m/s	0.24	0.33	0.318	0.026	3.024	-2.097
I	mg/l	207	1190	447.567	264.246	1.844	1.684
Extro	%	0.225	7.5	2.793	1.995	0.253	0.874
t/d	-	0.125	0.3	0.195	0.086	-1.868	0.400
T.E.	%	14.4	85.1	38.773	15.546	0.185	0.814
Testing							
Sz	mm	0.21	0.84	0.466	0.223	-0.684	0.739
Velocity	m/s	0.24	0.33	0.321	0.023	6.311	-2.653
I	mg/l	207	1190	436.85	237.493	3.828	1.962
Extro	%	0.3	7.5	2.936	2.030	0.2227	0.857
t/d	-	0.125	0.3	0.203	0.088	-2.062	0.208
T.E.	%	19.2	83.2	40.135	16.446	-0.101	0.682



चित्र.4. एसई और डीएनएन द्वारा मॉडलिंग तकनीकों का प्रवाह आरेख

4. परिणाम और चर्चा

प्रशिक्षण और संबंधित परीक्षण डेटासेट पर कई परीक्षणों को लागू करके उत्पादित उपयोगकर्ता-परिभाषित मापदंडों के अनुकूलन का उपयोग सर्वोत्तम मॉडल की भविष्यवाणी करने के लिए डीएनएन और एसई को लागू करने के लिए किया जाता है क्योंकि प्राथमिक मापदंडों का ट्यूनिंग चरण एक प्रभावी सॉफ्ट कंप्यूटिंग मॉडल बनाने का एक महत्वपूर्ण हिस्सा है। भ्रमिल ट्यूब रेत जाल दक्षता की भविष्यवाणी में प्राप्त उपयोगकर्ता-परिभाषित मापदंडों के इष्टतम मान तालिका 2 और तालिका 3 में दिखाए गए हैं। प्रस्तावित

मॉडल के प्रदर्शन को निर्धारित करने के लिए मूल माध्य वर्ग त्रुटि (आरएमएसई) और सहसंबंध गुणांक (सीसी) सहित विभिन्न सांख्यिकीय मूल्यांकन मानदंडों का उपयोग किया गया था। कम आरएमएसई मान सर्वोत्तम मॉडल अनुमान का संकेत देते हैं, जबकि उच्च सीसी मान इनपुट और आउटपुट चर के बीच एक अच्छे संबंध का संकेत देते हैं। भ्रमिल ट्यूब रेत जाल के निर्माण के लिए DNN और S.E मॉडल को सबसे उपयुक्त मॉडल के रूप में चुना गया था। इसके अलावा, उन्होंने सर्वोत्तम मॉडल निर्धारित करने के लिए उत्पादित बहुभिन्नरूपी रैखिक और गैर-रेखीय प्रतिगमन के साथ परिणामों की तुलना की। सभी प्रस्तावित मॉडलों का प्रदर्शन मूल्यांकन तालिका 4 में सूचीबद्ध है। डेटासेट प्रयोगात्मक टिप्पणियों से प्राप्त किया गया था और मॉडलिंग रणनीतियों में सॉफ्ट कंप्यूटिंग तकनीक डीएनएन और एसई शामिल थे। इस प्रयोग में कुल 174 प्रेक्षित डेटासेट का उपयोग किया गया। डेटासेट को यादृच्छिक रूप से दो समूहों में विभाजित किया गया था: प्रशिक्षण डेटा (134) और परीक्षण डेटा (40)।

तालिका 2. डीएनएन मॉडल के लिए इष्टतम मूल्य उपयोगकर्ता-परिभाषित हाइपर-पैरामीटर का विवरण

S.No.	Parameters	Value/type
1	N folds	5
2	Rho	0.95
3	Epochs	2007.40
4	Activation function	Rectifier with dropout (RELU)
5	Hidden Layer	20 with 100 nodes each

तालिका 3. एसई मॉडल के लिए इष्टतम मूल्य उपयोगकर्ता-परिभाषित हाइपर-पैरामीटर का विवरण

Sl.	Parameters	Value/Type
1	Meta model	GLM
2	Nfolds	5

3	Base models	DRF,XRT,GBM
---	-------------	-------------

तालिका 4. गैर-पारंपरिक तरीकों का उपयोग करके प्रदर्शन मूल्यांकन


Models	CC Value	RMSE Value
Training		
SE	0.996	0.068
DNN	0.814	0.195
Testing		
SE	0.976	0.251
DNN	0.883	1.132

4.1. डीप न्यूरल नेटवर्क (डीएनएन) मॉडल के परिणाम

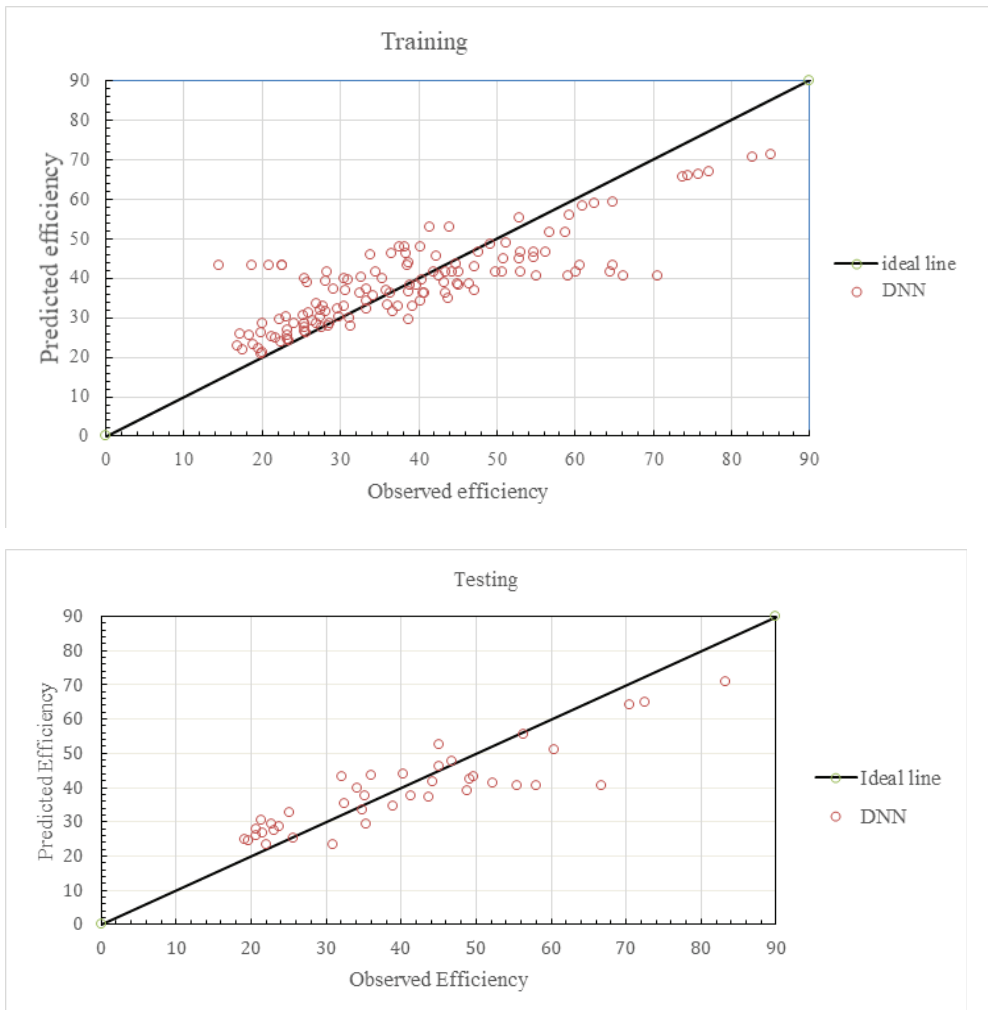
भ्रमिल ट्यूब सैंड ट्रेप (वीटीएसटी) दक्षता डीएनएन तकनीक का उपयोग करके निर्धारित की जाती है। यहां, हिट और ट्रायल विधि द्वारा भी, प्रशिक्षण और परीक्षण में डेटा के विभिन्न वितरण के साथ विभिन्न मॉडल तैयार किए जाते हैं। गहन शिक्षण दृष्टिकोण में पहला चरण डेटा को प्रशिक्षण और परीक्षण में विभाजित करना है, जैसा कि पहले बताया गया है, और फिर एनफोल्ड का इष्टतम मूल्य चुना जाता है, और सबसे कम कंप्यूटिंग लागत वाले मॉडल का पूर्वानुमान लगाने के लिए आवश्यक युगों की संख्या निर्धारित की जाती है। प्राथमिक अनुकूलित उपयोगकर्ता-परिभाषित पैरामीटर तालिका 2 में वर्णित हैं।

चित्र 5(ए) विचलन और युगों की संख्या के बीच परीक्षण और प्रशिक्षण डेटासेट के इतिहास विचलन को दर्शाता है। ग्राफ से यह देखा जा सकता है कि जैसे ही युग 2,000 तक पहुँचता है, विचलन X-अक्ष के प्रति स्पर्शान्मुख है। इसके अलावा, प्रशिक्षण और परीक्षण डेटासेट के लिए डीएनएन द्वारा देखे गए और अनुमानित वीटीएसटी के बीच प्रकीर्णन आरेख चित्र 5 (बी) में दिखाया गया है। चित्र 5(बी) से यह स्पष्ट है कि परीक्षण और प्रशिक्षण दोनों में सभी अनुमानित

मूल्य आदर्श रेखा के आसपास हैं, जिसका अर्थ है कि डीएनएन मॉडल अच्छा प्रदर्शन कर रहा है। यह दावा आगे तालिका 4 द्वारा समर्थित है, जो दर्शाता है कि इस मॉडल में, सहसंबंध गुणांक का मूल्य अधिक है, और त्रुटि मान कम है।




चित्र. 5(ए). डीएनएन का स्कोरिंग विचलन



चित्र. 5(बी). प्रेक्षित और पूर्वानुमानित दक्षता के बीच बिखराव

4.2. स्टैकड एन्सेम्बल (एसई) मॉडल के परिणाम

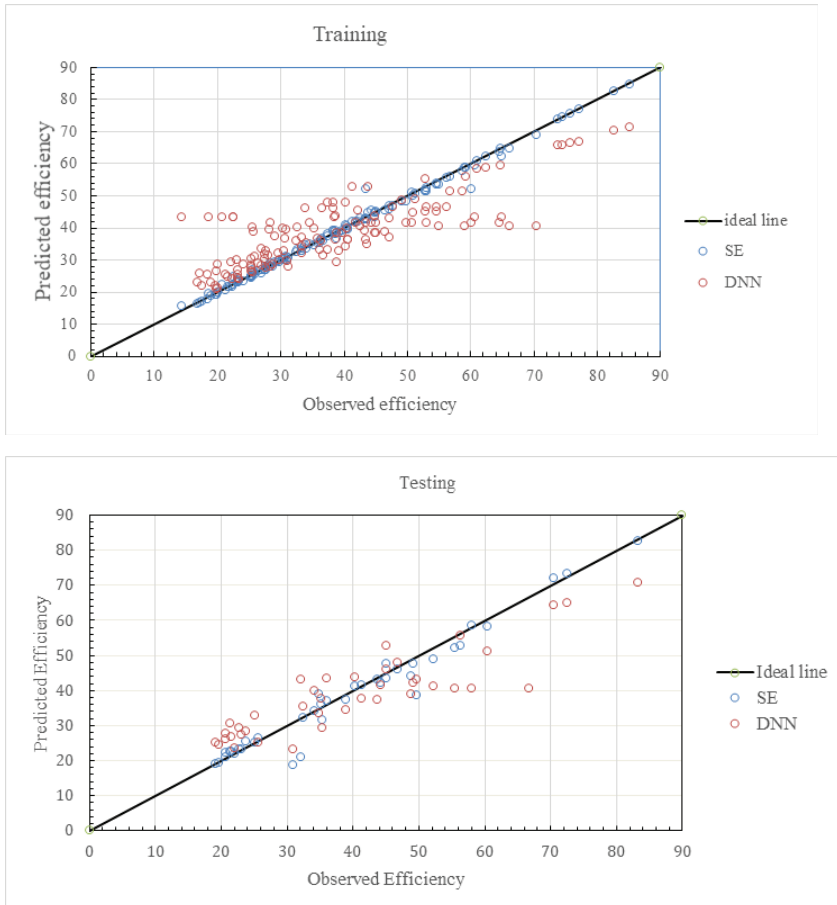
इस खंड में, वीटीएसटी दक्षता की भविष्यवाणी करने के लिए, एक स्टैकड समूह का उपयोग करके डेटा का विश्लेषण किया जाता है। स्टैकड एन्सेम्बल के लिए, विभिन्न बेसमॉडल यादृच्छिक रूप से उत्पन्न होते हैं, जैसे ग्रेडिएंट बूस्टिंग मशीन (जीबीएम) और वितरित रैंडम फॉरेस्ट (डीआरएफ)। एक अत्यंत यादृच्छिक वृक्ष (XRT) और प्रशिक्षण मॉडल उत्पन्न होते हैं। उसके बाद, यह प्रशिक्षण मॉडल मेटा-मॉडल, सामान्यीकृत रैखिक मॉडल (जीएलएम) से चलाया जाता है, और अनुमानित मान प्राप्त किए जाते हैं। प्रमुख मापदंडों का इष्टतम मूल्य तालिका 3 में दिखाया गया है। चित्र 6 प्रशिक्षण और परीक्षण डेटासेट के लिए वास्तविक वीटीएसटी दक्षता और इसके अनुमानित मूल्यों के बीच बिखरे हुए मॉडल-आधारित मॉडल को दर्शाता है। यह देखा गया है कि परीक्षण डेटासेट के लिए सभी अनुमानित बिंदु आदर्श रेखा के पास स्थित हैं, जबकि कुछ पूर्वानुमानित प्रशिक्षण डेटासेट थोड़े बिखरे हुए हैं। इसके अलावा, तालिका 4 को देखने से यह स्पष्ट है कि स्टैकड एन्सेम्बल अच्छा प्रदर्शन कर रहा है।



चित्र.6. प्रेक्षित और पूर्वानुमानित दक्षता के बीच बिखराव

4.3. परिणामों की तुलना

भ्रमिल ट्यूब गाद इजेक्टर के डेटासेट का उपयोग करके विकसित किए गए मॉडल की तुलना सांख्यिकीय प्रदर्शन मॉडलिंग मापदंडों का उपयोग करके की जाती है। एसई और डीएनएन मॉडल ने भ्रमिल ट्यूब की ट्रेपिंग दक्षता का कुशलतापूर्वक अनुमान लगाया है। हालाँकि, एसई मॉडल ने भ्रमिल ट्यूब गाद इजेक्टर की ट्रेपिंग दक्षता की भविष्यवाणी करने में सभी प्रस्तावित मॉडलों से बेहतर प्रदर्शन किया, क्योंकि एसई मॉडल में उच्चतम सहसंबंध गुणांक है। इसके अलावा, चित्र 7 के अवलोकन से, यह स्पष्ट है कि एसई मॉडल द्वारा अनुमानित बिंदु डीएनएन मॉडल की तुलना में आदर्श रेखा के अपेक्षाकृत करीब हैं।




चित्र.7. प्रेक्षित और अनुमानित दक्षता के बीच परिणामों की तुलना के लिए प्रकीर्णन आरेख

4.4. सुग्राहिता विश्लेषण

चित्र 8 डीएनएन के सर्वोत्तम प्रदर्शन करने वाले मॉडल का उपयोग करके इनपुट मापदंडों की सापेक्ष प्रासंगिकता को दर्शाता है। निष्कर्षण अनुपात (एक्स्ट्रो) सबसे सुग्राही प्राचल पाया गया क्योंकि डीएनएन मॉडल महत्व के पैमाने पर अधिकतम मान पढ़ता है, जबकि तलछट का आकार सबसे कम सुग्राही प्राचल पाया गया

क्योंकि यह महत्व के समान पैमाने पर न्यूनतम मान इंगित करता है।



चित्र.8. इनपुट पैरामीटर का सुग्राहिता विश्लेषण

5. निष्कर्ष

भ्रमिल ट्यूब गाद इजेक्टर की ट्रेपिंग दक्षता के मॉडलिंग की जांच एसई और डीएनएन जैसी सॉफ्ट कंप्यूटिंग तकनीकों का उपयोग करके की जाती है। उपरोक्त अध्ययनों से निम्नलिखित महत्वपूर्ण निष्कर्ष निकाले गए हैं:

सहसंबंध गुणांक और आरएमएसई का उपयोग सॉफ्ट कंप्यूटिंग तकनीकों के प्रदर्शन का मूल्यांकन करने के लिए किया जाता है। इन दो सॉफ्ट कंप्यूटिंग दृष्टिकोण मॉडल ने भ्रमिल ट्यूब गाद इजेक्टर की ट्रेपिंग दक्षता का पूर्वानुमान लगाने के लिए प्रयोगात्मक डेटासेट का उपयोग किया है। डीएनएन मॉडल की तुलना में, एसई मॉडल ने प्रशिक्षण के लिए सहसंबंध गुणांक = 0.996 और सबसे कम आरएमएसई = 0.068 के साथ सबसे अच्छा प्रदर्शन किया, और परीक्षण के लिए अधिकतम मूल्य सहसंबंध गुणांक = 0.976 और आरएमएसई = 0.251 के सबसे कम मूल्यों के साथ। इस अध्ययन से पता चला कि एसई मॉडल की तुलना में डीएनएन

मॉडल में भ्रमिल ट्यूब गाद इजेक्टर की ट्रेपिंग दक्षता की पर्याप्त क्षमता होती है।

डीएनएन के सर्वोत्तम प्रदर्शन करने वाले मॉडलों द्वारा सुग्राहिता विश्लेषण से पता चला कि निष्कर्षण अनुपात (एक्सट्रो) सबसे संवेदनशील प्राचल है। साथ ही तलछट का आकार सबसे कम संवेदनशील होता है।

शोध पत्र में प्रयुक्त अंग्रेजी शब्दों की समानार्थक हिंदी शब्दावली

Alphabetically Sorted Terminology in English	वर्णमाला अनुक्रमित हिंदी शब्दावली
Activation Function	सक्रियण फलन
Coefficient of Correlation (CC)	सहसंबंध गुणांक
Distributed Random Forest	वितरित यादृच्छिक वन
Extraction Ratio	निष्कर्षण अनुपात
Generalized Linear Model	सामान्यीकृत रैखिक निदर्श

Root Mean Square Error	मूल माध्य वर्ग त्रुटि
Sensitivity Analysis	सुग्राहिता विश्लेषण
Sediment	तलछट
Trapping Efficiency	प्रपाशन दक्षता
Vortex Tube Sand Trap (VTST)	भ्रमिल ट्यूब रेत जाल

संदर्भ

1. Singh, Mandeep, J. Banerjee, P. L. Patel, and Himanshu Tiwari. "Effect of silt erosion on Francis turbine: a case study of Maneri Bhali Stage-II, Uttarakhand, India." *ISH Journal of Hydraulic engineering* 19, no. 1 (2013): 1-10.
2. Atkinson, Edmund. "Vortex-tube sediment extractors. II: design." *Journal of Hydraulic Engineering* 120, no. 10 (1994 a): 1126-1138.
3. Raju, KG Ranga, U. C. Kothiyari, Somya Srivastav, and Manish Saxena. "Sediment removal efficiency of settling basins." *Journal of Irrigation and Drainage Engineering* 125, no. 5 (1999): 308-314.
4. Singh, K. K., Mahesh Pal, C. S. P. Ojha, and V. P. Singh. "Estimation of removal efficiency for settling basins using neural networks and support vector machines." *Journal of Hydrologic Engineering* 13, no. 3 (2008): 146-155.
5. Singh, B. K., N. K. Tiwari, and K. K. Singh. "Support vector regression based modelling of trapping efficiency of silt ejector." *J. Indian Water Resour. Soc* 36, no. 1 (2016): 41-49.
6. Ansari, Mujib Ahmad, and Mohd Athar. "Artificial neural networks approach for estimation of sediment removal efficiency of vortex settling basins." *ISH Journal of Hydraulic Engineering* 19, no. 1 (2013): 38-48.
7. Ansari, Mujib Ahmad, and Mohd Amir Khan. "Performance assessment of vortex settling chambers." *ISH Journal of Hydraulic Engineering* 20, no. 3 (2014): 324-338.
8. Atkinson, Edmund. "Vortex-tube sediment extractors. I: Trapping efficiency." *Journal of Hydraulic Engineering* 120, no. 10 (1994 b): 1110-1125.
9. Parshall, Ralph L. "Model and prototype studies of sand traps." *Transactions of the American Society of Civil Engineers* 117, no. 1 (1952): 204-212.
10. Wolpert, David H. "Stacked generalization." *Neural networks* 5, no. 2 (1992): 241-259.
11. Breiman, Leo. "Stacked regressions." *Machine learning* 24 (1996): 49-64.
12. Nath, Abhigyan, and Gopal Krishna Sahu. "Exploiting ensemble learning to improve prediction of phospholipidosis inducing potential." *Journal of Theoretical Biology* 479 (2019): 37-47.
13. Wang, Ran, Shilei Lu, and Wei Feng. "A novel improved model for building energy consumption prediction based on model integration." *Applied Energy* 262 (2020): 114561.