



## कृतिम तंत्रिका नेटवर्क मॉडल द्वारा भूजल स्तर के उत्तर-चढ़ाव का पूर्वानुमान : एक अध्ययन

सौरभ नेमा, एम के नेमा, एम के अवस्थी\* एवं आर के नेमा\*

राष्ट्रीय जलविज्ञान संस्थान, रुड़की 247 667

\*जवाहरलाल नेहरू कृषि विश्वविद्यालय, जबलपुर 482 004 (मध्य प्रदेश)

**सारांश :** पिछले कुछ वर्षों में, भूजल के अत्यधिक दोहन के कारण भारत के कई क्षेत्रों में भूजल स्तर काफी नीचे चला गया है। केन्द्रीय भूजल बोर्ड के आकड़ों के अनुसार, भारत में वर्ष 2007 और 2017 के बीच भूजल स्तर में औसतन 61 प्रतिशत की कमी हुई है, जिसके कारण जल की उपलब्धता एवं गुणवत्ता की समस्या दिन-प्रतिदिन गंभीर रूप से रही है। केन्द्रीय भूजल बोर्ड की 2017 की रिपोर्ट के अनुसार, भारत के कुल 6881 खंडों (ब्लॉक) में से 313 ब्लॉक गंभीर (Critical), 1186 ब्लॉक अति शोषित (Over Exploited) एवं 100 ब्लॉक खारे पानी (Saline) की श्रेणी में आते हैं। इसके अलावा 94 ऐसे भी ब्लॉक हैं जहाँ भूजल की उपलब्धता बहुत कम है। भूजल संसाधन के गिरते हुए स्तर से उत्पन्न हुए जल संकट एवं देश की सामाजिक और आर्थिक वृद्धि में इसके अत्यधिक महत्व को देखते हुए भूजल संसाधनों का समग्र विकास एवं प्रबंधन अति आवश्यक है। भूजल स्तर का सटीक पूर्वानुमान, भूजल संसाधनों के कुशल प्रबंधन एवं परिस्थितिक तंत्र के सतत विकास के लिए अति आवश्यक है। इस अध्ययन में एक चयनित जलभूत (Aquifer) तंत्र में भूजल स्तर के पूर्वानुमान के लिए मल्टी लेयर परसेप्ट्रॉन (MLP) कृतिम तंत्रिका नेटवर्क (ANN) का उपयोग किया गया था। एएनएन मॉडल के विकास में वर्षा, तापमान, नदी जल स्तर और भूजल स्तर के आंकड़े शामिल थे। एएनएन मॉडल को ग्रेडिएंट दिसेंसेट एल्गोरिदम (GDM) का उपयोग करके प्रशिक्षित किया गया था। उक्त मॉडल को सात विभिन्न अवलोकन स्थानों पर अनुप्रयोगित एवं मान्य किया गया तथा प्रत्येक स्थान के लिए एएनएन मॉडल की अनुमानित क्षमता विकसित की गई थी। जिसका मूल्यांकन चार सारिखीय संकेतक ख्बायरस (Bias), आर.एम.एस.ई (RMSE), एन.एस.ई (NSE) और एमएसई (MSE) के साथ-साथ दृश्य परिक्षण का उपयोग करके किया गया था। इस अध्ययन के परिणामों के आधार पर तंत्रिका नेटवर्क मॉडल (ANN) को लगभग सभी चुने हुए अवलोकन स्थानों पर मासिक भूजल स्तर के पूर्वानुमान के लिए कुशल पाया गया। अध्ययन से यह निष्कर्ष निकाला गया कि कृतिम तंत्रिका नेटवर्क तकनीकों (ANN) का उपयोग भूजल स्तर के उत्तर-चढ़ाव के पूर्वानुमान करने के लिए, विशेष रूप से डेटा-दुर्लभ परिस्थितियों में, कुशलतापूर्वक किया जा सकता है।

## Prediction of groundwater level fluctuations by artificial neural network models : A case study

Sourabh Nema, M K Nema, M K Awasthi\* & R K Nema\*

National institute of Hydrology, Roorkee 247 667

\*Jawaharlal Nehru Krishi Vishwavidyalaya, Jabalpur 480 004 (Madhya Pradesh)

### Abstract

In the last few years, due to excessive exploitation of groundwater resources, the water level has gone down in many parts of India. According to a data from the Central Ground Water Board (CGWB), the average groundwater level in India has decreased by 61 per cent between 2007 and 2017, due to which the availability and quality of water are taking serious problems day-by-day. According to the CGWB (2017), 313 blocks out of a total of 6881 blocks are Critical, 1186 blocks are over exploited, and 100 blocks fall into the category of saline. And there are 94 such blocks where the availability of groundwater is significantly less. The overall development and management of groundwater resources are critical because of the water crisis arising from the declining level of groundwater resources and its immense importance in the social and economic growth of the country. Accurate forecasting of groundwater levels is essential for efficient management of groundwater resources and sustainable development of ecosystems. In this study, Multi-Layer Perceptron (MLP) artificial neural network (ANN) was used to predict groundwater levels in a selected aquifer system. The development of the ANN model included data on rainfall, temperature and river water level and groundwater level. The ANN model was trained using the gradient decent algorithm (GDM). The said model was applied and validated at seven different observation locations, and the estimated capacity of the ANN model was developed for each location. This was assessed using four statistical indicators [Bias, RMSE, NSE and MSE] as well as visual testing. Based on the results of this study, the Neural Network Model (ANN) was found to be efficient for forecasting monthly groundwater levels at almost all selected observation locations. The study concluded that artificial neural network techniques (ANNs) could be used efficiently to predict groundwater level fluctuations, especially in data-scarce situations.

## प्रस्तावना

दुनिया के अनेक भागों में घरेलू, कृषि और औद्योगिक क्षेत्रों के लिए भूजल, ताजे पानी की आपूर्ति का एक प्रमुख स्रोत है। इसके अलावा, भूजल को सतह के जल स्रोतों की तुलना में जलवायु में उत्तार-चढ़ाव के मुकाबले कम असुरक्षित माना जाता है। पिछले कुछ वर्षों में भूजल के अत्यधिक दोहन के कारण भारत के कई क्षेत्रों में भूजल स्तर काफी नीचे चला गया है। केन्द्रीय भूजल बोर्ड के आंकड़ों के अनुसार, भारत में वर्ष 2007 और 2017 के बीच भूजल स्तर में औसतन 61 प्रतिशत की कमी हुई है, जिसके कारण जल की उपलब्धता एवं गुणवत्ता की समस्या दिन-प्रतिदिन गंभीर रूप ले रही है। केन्द्रीय भूजल बोर्ड की 2017 की रिपोर्ट के अनुसार भारत के कुल 6881 ब्लॉक (ब्लॉक) में से 313 ब्लॉक गंभीर (Critical), 1186 ब्लॉक अति शोषित (Over Exploited) एवं 100 ब्लॉक खारे पानी (Saline) की श्रेणी में आते हैं। इसके अलावा 94 ऐसे भी ब्लॉक हैं जहाँ भूजल की उपलब्धता बहुत कम है। भूजल संसाधन के गिरते हुए स्तर से उत्पन्न हुए जल संकट एवं देश की सामाजिक और आर्थिक वृद्धि में इसके अत्यधिक महत्व को देखते हुए भूजल संसाधनों का समग्र विकास एवं प्रबंधन अति आवश्यक है। भूजल स्तर का सटीक पूर्वानुमान, भूजल संसाधनों के कुशल प्रबंधन एवं पारिस्थितिक तंत्र के सतत विकास के लिए अति आवश्यक है।

हाल के समय में, भूजल मॉडलिंग को भूजल के इष्टतम उपयोग, संरक्षण और भूजल संसाधन के स्थायी प्रबंधन के लिए सबसे प्रमुख उपकरण के रूप में विकसित किया गया है। हालांकि, चूंकि भूजल छिपा हुआ है और भूजल प्रक्रियाएं उच्च स्तर के स्थानिक के साथ-साथ लौकिक विविधताओं को प्रदर्शित करती हैं, जो भूजल मॉडलिंग को बहुत कठिन कार्य बनाती हैं। भूजल के विश्वसनीय पूर्वानुमान के लिए, भौतिक वितरण आधारित संख्यात्मक मॉडल (यानी, विजुअल मॉडल्स) को आमतौर पर एक्वीफर क्षेत्र और मॉडल मापदंडों के भौतिक गुणों को निर्दिष्ट करने और मॉडल सिमुलेशन की जांच करने के लिए बड़ी मात्रा में सटीक जानकारी की आवश्यकता होती है। व्यवहार में, हालांकि, मॉडल विकास के लिए पर्याप्त डेटा हर जगह आसानी से उपलब्ध नहीं है, क्योंकि लागत और समय की सीमा है<sup>5,6&17</sup>। कृत्रिम तंत्रिका नेटवर्क (एएनएन) मॉडल ऐसे मॉडलों में से एक है, जिन्हें सार्वभौमिक सन्निकट के रूप में माना जाता है और यह गतिशील अरेखीय प्रणाली मॉडलिंग के लिए बहुत अनुकूल है<sup>3</sup>। पारंपरिक तरीकों पर इस दृष्टिकोण का मुख्य लाभ यह है कि इसे गणितीय रूप में वर्णित मौलिक प्रक्रिया की जटिल प्रकृति की आवश्यकता नहीं

है। पर्याप्त प्रशिक्षण के बाद, वे जल विज्ञान में कई पूर्वानुमान समस्याओं के लिए उपयुक्त परिणाम उत्पन्न करने में सक्षम हैं<sup>3</sup>। यह गुण एएनएन को भूजल के उत्तार-चढ़ाव के लिए मॉडलिंग का एक आकर्षक साधन बनाता है।

कृत्रिम तंत्रिका नेटवर्क (एएनएन) को समय-शृंखला पूर्वानुमान सहित विभिन्न जल संसाधन समस्याओं को हल करने के लिए सफलतापूर्वक लागू किया गया है। भूजल स्तर (GWL) के उत्तार-चढ़ाव के लिए एएनएन मॉडल के प्रदर्शन का मूल्यांकन किया गया है, जो पूर्व भूजल स्तर, वर्षा, नदी का जल स्तर और तापमान जैसे जल एवं मौसम संबंधी डेटा का उपयोग कर रहे हैं। कोपोला आदि (2003) ने पंपिंग और जलवायु परिस्थितियों में भूजल पूर्वानुमान मॉडल बनाने के लिए एएनएन का उपयोग किया था<sup>5</sup>। कुछ हालिया अध्ययनों ने तटीय जलभृतों में जल स्तर के पूर्वानुमान करने के लिए एएनएन मॉडल लागू किए<sup>11,16</sup>। मौसम संबंधी सूचना और पूर्व जल स्तर डेटा जैसे इनपुट चर के साथ एएनएन मॉडल का उपयोग कर तटीय एक्वीफरों में भूजल के उत्तार-चढ़ाव की सफलतापूर्वक पूर्वानुमान की। भौतिक भूजल मॉडल और एएनएन भूजल मॉडल का तुलनात्मक अध्ययन किया गया था क्योंकि उन्होंने भूजल स्तरों के अनुकरण के लिए विजुअल मॉडलों और एएनएन के प्रदर्शन का मूल्यांकन किया था<sup>15</sup>। अध्ययन से पता चला कि एएनएन कम समय के लिए बेहतर पूर्वानुमान प्रदान करता है। विभिन्न डोमेन में जटिल अरेखीय प्रक्रिया से जुड़ी समस्याओं को ध्यान में रखते हुए, हाल के वर्षों में विज्ञान और इंजीनियरिंग के कई क्षेत्रों में पूर्वानुमान के लिए कृत्रिम तंत्रिका नेटवर्क (एएनएन) का व्यापक रूप से उपयोग किया गया है<sup>16</sup>। यद्यपि कई शोधकर्ताओं ने भूजल-स्तर की पूर्वानुमान [1, 2, 4, 5, 7, 12, 11, 14] के लिए एएनएन को लागू किया है, हालांकि, एएनएन तकनीक का उपयोग करके भूजल मॉडलिंग थोड़ा सीमित है<sup>2,4,5,7,18,12,14</sup>। वर्तमान अध्ययन के उद्देश्य के अनुसार अध्ययन क्षेत्र में एएनएन तकनीक की मदद से कई साइटों पर जल स्तर में उत्तार-चढ़ाव के पूर्वानुमान करने के लिए सफलता पूर्वक एएनएन मॉडल विकसित करना तथा उसकी कुशलता का अध्ययन करना था ताकि भविष्य में जरूरत पड़ने पर इस तकनीक का उपयोग करके इस क्षेत्र के लिए भूजल संसाधनों का समग्र विकास एवं प्रबंधन किया जा सके।

## अध्ययन क्षेत्र का विवरण

मध्य प्रदेश राज्य के होशंगाबाद जिले को वर्तमान अध्ययन के लिए अध्ययन क्षेत्र के रूप में चुना गया था। अध्ययन क्षेत्र में कई स्थलों पर पर्याप्त और प्रामाणिक हाइड्रोलॉजिकल और जल स्तर

डेटा है जो वर्तमान अध्ययन के लिए आवश्यक थे। अध्ययन क्षेत्र दक्षिण में सतपुड़ा पर्वत शृंखला और उत्तर दिशा में नर्मदा नदी से घिरा है। संपूर्ण अध्ययन नर्मदा नदी और उसकी सहायक नदियों द्वारा किया जाता है। इस प्रकार, क्षेत्र नर्मदा बेसिन में पड़ता है। नर्मदा नदी जिले की उत्तरी सीमा के साथ बहती है।

अध्ययन क्षेत्र में जलोढ़ रेत और बजरी और/ या जलोढ़ सिल्ट रेत और बजरी शामिल हैं जो इस क्षेत्र में प्रमुख हैं और उत्तर में नर्मदा नदी और दक्षिण में सतपुड़ा वन के बीच के क्षेत्र को शामिल करते हैं (चित्र-1)। अध्ययन के लिए सभी चयनित स्थल जलोढ़ अपरिभाषित जलभूत में मर्मज्ञ थे। एकीफर की हाइड्रोलिक चालकता एक बड़े स्थानिक परिवर्तनशीलता को प्रदर्शित करती है, जो ऊपरी नर्मदा बेसिन की काफी विविधता का सुझाव देती है। यह 65 से 804 मीटर /दिन तक भिन्न होता है। बेसिन में भूजल का समग्र प्रवाह दक्षिण से उत्तर की ओर है। बेसिन के एक बड़े हिस्से तक नर्मदा नदी एक महत्वपूर्ण नदी-जलभूत संपर्क करती है।

## सामग्री एवं विधि

### डेटा का संग्रहण एवं अधिग्रहण

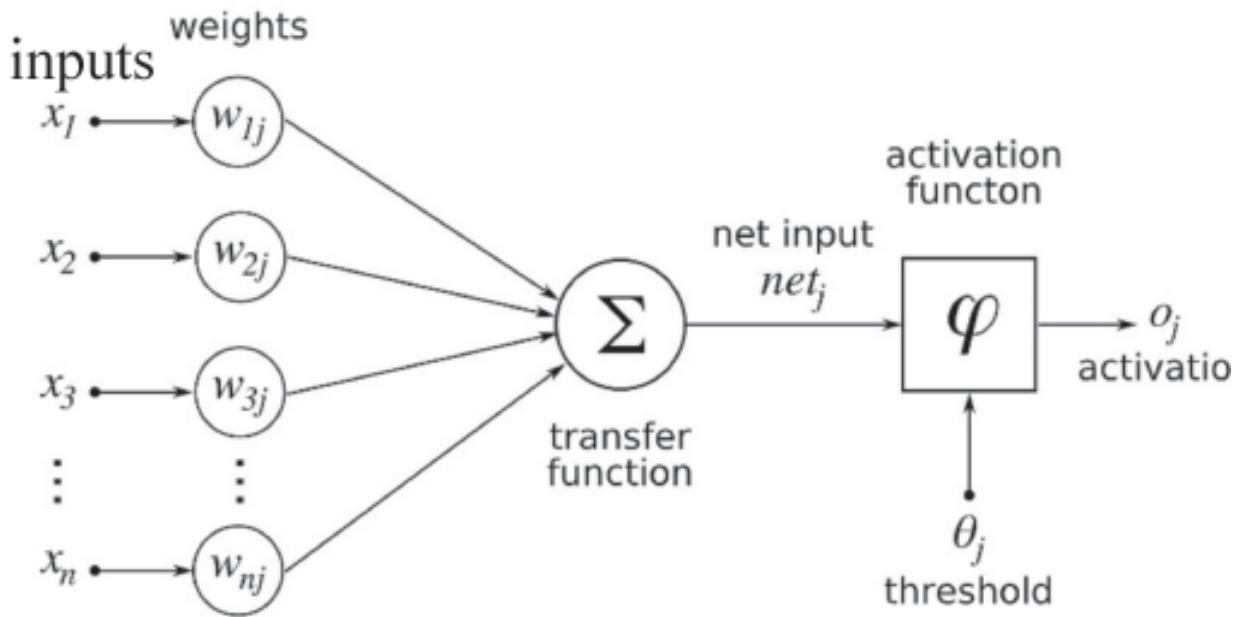
भारतीय भौवैज्ञानिक सर्वेक्षण (जीएसआई), राज्य डेटा केंद्र, भोपाल से 10 वर्षों (2005 से 2015) की दैनिक वर्षा के आंकड़े प्राप्त हुए। नर्मदा नदी का दैनिक नदी स्तर, केंद्रीय जल आयोग, भोपाल से प्राप्त किया गया था। अध्ययन क्षेत्र का दैनिक अधिकतम और न्यूनतम परिवेश तापमान भारतीय मेट्रोलॉजिकल विभाग, पुणे से प्राप्त किया गया था। केंद्रीय भूजल बोर्ड, भोपाल और जी.एस.आई विभाग, भोपाल से दैनिक जल स्तर के आंकड़े प्राप्त किए गए। इस अध्ययन के

लिए साइटों का चयन करने के लिए उपयोग किए जाने वाले मानदंड दैनिक जल स्तर डेटा की दीर्घकालिक उपलब्धता और व्यक्तिगत साइटों पर डेटा की निरंतरता थे। इन मानदंडों के आधार पर सात साइटों (ए, बी, सी, डी, ई, एफ और जी) को एनएन तकनीक का उपयोग करके 2005-2015 की अवधि के लिए जल स्तर में उत्तर-चढ़ाव के अनुकरण के लिए चुना गया था। चित्र-1 में इन घेरे हुए अवलोकन साइटों को दिखाया गया है।

एनएन आर्किटेक्चर और ट्रेनिंग एल्गोरिदम एक तंत्रिका नेटवर्क जैविक न्यूरॉन प्रणाली से प्रेरित होता है, जिसमें एक व्यापक समानांतर वितरित प्रसंस्करण प्रणाली शामिल होती है। यह अत्यंत परस्पर तंत्रिका कंप्यूटिंग तत्वों से बनी होती है जो सीखने और ज्ञान प्राप्त करने तथा इसे उपयोग के लिए उपलब्ध कराने की क्षमता रखती है। यह मानव मस्तिष्क के दो पहलुओं से मिलता-जुलता है- (1) ज्ञान जोकि वातावरण से एक सीखने की प्रक्रिया के माध्यम से प्राप्त किया जाता है, और (2) तंत्रिका कंप्यूटिंग तत्वों का आपस में मजबूत सम्बन्ध (जिसे सिनैटिक वेट के रूप में जाना जाता है) जिसका उपयोग अधिग्रहीत ज्ञान को संग्रहीत करने के लिए किया जाता है। दूसरे शब्दों में, एनएन शामिल किए गए वास्तविक प्रक्रियाओं के बारे में कोई डेटा दिए बिना इनपुट और वांछित आउटपुट के सेट के बीच संबंध प्राप्त करता है। यह पैटर्न के आधार पर पहचान करने का मुख्य सार है। एनएन की सरल इकाई न्यूरॉन है, जो प्राकृतिक न्यूरॉन्स के दो मूल उद्देश्यों को अनुकरण करती है: पहले यह इसमें दिये गए सभी इनपुटों के भारित योग की गणना करता है और इस गणना की गई भार राशि को एक सक्रियण फंक्शन/गैर-रेखीय फंक्शन द्वारा पारित किया जाता है। निम्नलिखित आंकड़ा एक



चित्र 1 – अध्ययन क्षेत्र एवं अवलोकन स्थानों की भारत में स्थिति



चित्र 2 – एक गैर-रेखीय एएनएन मॉडल

न्यूरॉन के एक गैर-रेखीय मॉडल की व्याख्या करता है, जो इसके लिए आधार तैयार करता है (चित्र 2)।

#### अध्ययन में प्रयुक्त एएनएन (ANN) मॉडल की संरचना

इस अध्ययन में बहुस्तरीय पर्सेप्ट्रॉन (MLP) का उपयोग अध्ययन क्षेत्र पर मासिक जल स्तर की पूर्वानुमान के लिए एएनएन मॉडल को डिजाइन करने के लिए किया गया है। एक बहुप्रत फीड फॉरवर्ड नेटवर्क को आमतौर पर बैक प्रोपगेशन के साथ प्रशिक्षित किया जाता है जिसमें इनपुट लेयर, आउटपुट लेयर और एक या अधिक छिपी लेयर्स होती हैं (चित्र 3)। इनपुट संकेत केवल इनपुट नोड्स से आउटपुट नोड्स तक छिपे हुए नोड्स से गुजरकर आगे की ओर जाता है, जो उपयोगी मध्यवर्ती संगणना प्रदर्शन करने में मदद करता है। एमएलपी न्यूरल नेटवर्क का प्रमुख प्लस पॉइंट यह है कि इसे संभालना काफी आसान है, और किसी भी इनपुट-आउटपुट मैप को अनुमानित कर सकता है।

#### मॉडल इनपुट्स और एएनएन पैरामीटर का निर्धारण

महत्वपूर्ण इनपुट चरों का चयन एएनएन मॉडल विकास प्रक्रिया में सबसे अनिवार्य चरणों में से एक है। सामान्य तौर पर, सभी प्रासंगिक इनपुट चर समान रूप से जो कि अंतिम निष्कर्ष के लिए महत्वपूर्ण हैं तथा आपस में सम्बंधित नहीं हैं, को चयनित किया जाना चाहिए<sup>13</sup>। इस अध्ययन में, भूजल पूर्वानुमान के लिए चयनित स्थलों की महीने की वर्षा, तापमान और माध्य

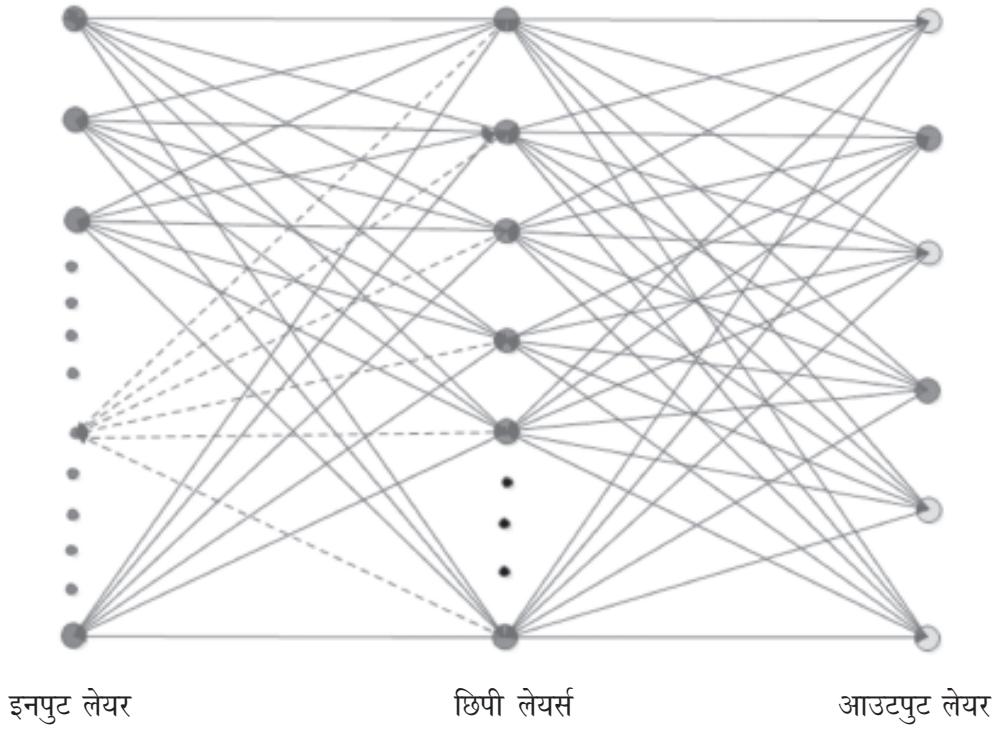
नदी के जल स्तर, परिवेश का तापमान, और औसत अंतराल का चयन किया गया था। इस अध्ययन में एएनएन मॉडल के विकास के लिए आउटपुट लेयर में एक रेखिक स्थानांतरण फ़ंक्शन सहित तीन परतों वाली छिपी हुई परत में एक लॉजिस्टिक सिग्मॉइड ट्रांसफर फ़ंक्शन का चयन किया गया था। 8 साल (2005-2013) के मासिक जल स्तर के डेटा का इस्तेमाल एएनएन मॉडल और 2 साल (2014-2015) के परीक्षण के लिए किया गया था। एएनएन मॉडलिंग MATLAB 7.0 सॉफ्टवेयर का उपयोग करके किया गया था।

#### विकसित एएनएन मॉडल का प्रदर्शन मूल्यांकन

सात साइटों के लिए विकसित सभी एएनएन मॉडलों का प्रदर्शन मूल्यांकन चार सांख्यिकीय संकेतकों (आरएमएसई, एमएर्ई और एनएसई) का उपयोग करके किया गया था ताकि प्रशिक्षण और परीक्षण अवधि के लिए व्यक्तिगत साइटों पर पानी के स्तर की पूर्वानुमान में उनकी प्रभावशीलता की जांच की जा सके। RMSE, MAE और NSE के लिए भाव इस प्रकार हैं :

$$\text{बायस (Bias)} = \frac{1}{N} \sum_1^N (h_{si} - h_{oi}) \quad \dots (1)$$

$$\text{आर.एम.एस.ई (RMSE)} = \sqrt{\frac{\sum_{i=1}^N (h_{si} - h_{oi})^2}{N}} \quad \dots (2)$$



चित्र 3 – बहुस्तरीय पर्सेप्ट्रॉन संरचना (MLP)

$$\text{एम.एस.ई (M.S.E.)} = \sum_{i=1}^n \left( \frac{hs_i - hoi}{N} \right)^2 \quad \dots (3)$$

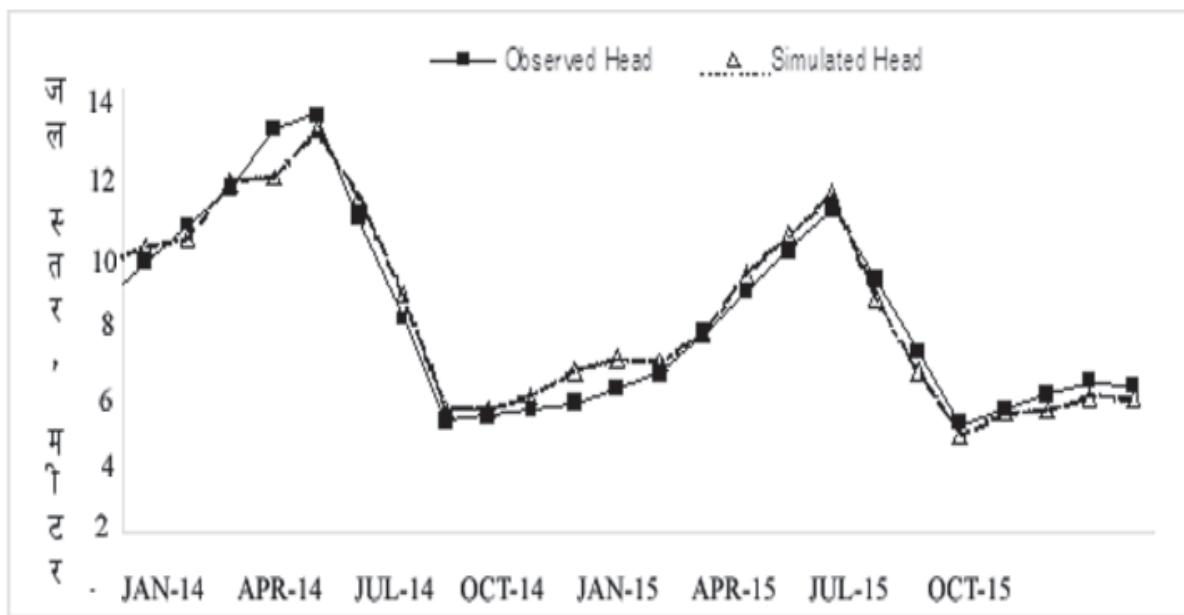
$$\text{एन.एस.ई. (NSE)} = 1 - \frac{\sum_{i=1}^N (h_{oi} - \bar{h}_o)^2}{\sum_{i=1}^N (h_{oi} - \bar{h}_o)^2} \quad \dots (4)$$

जहाँ,  $hoi$  = भूजल स्तर के देखे जाने का मतलब [L],  
 $hs_i$  = सिम्युलेटेड भूजल स्तर और  $N$  = अवलोकन की कुल संख्या।

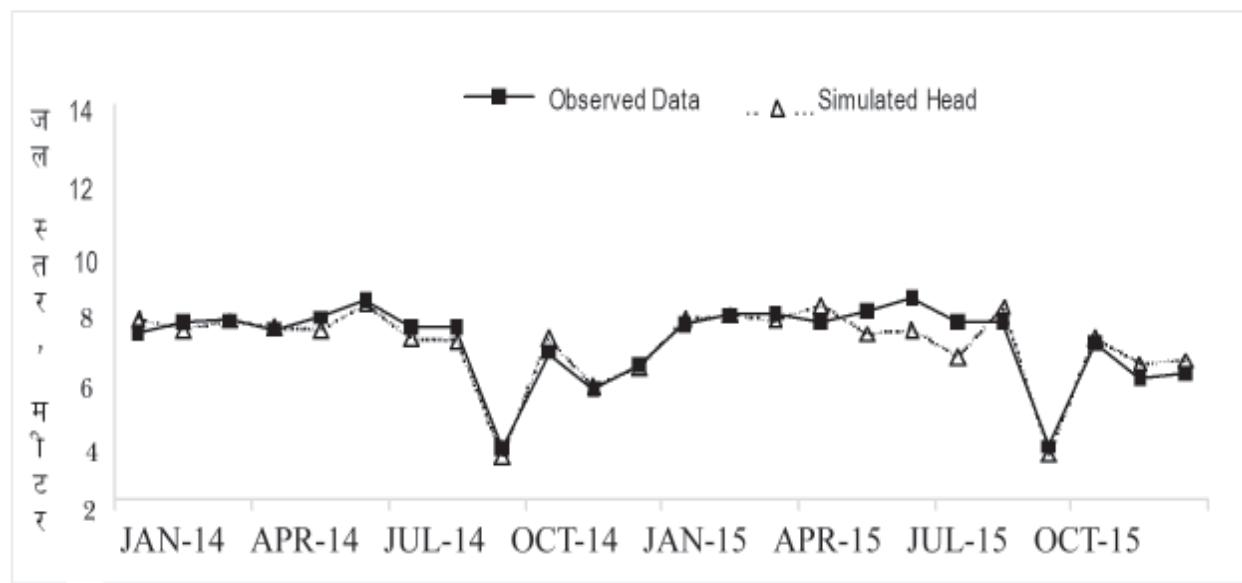
#### परिणाम एवं विवेचना

विकसित कृत्रिम तंत्रिका मॉडल द्वारा जल स्तर पूर्वानुमान सात स्थलों पर पानी की स्तर के उत्तर-चढ़ाव के पूर्वानुमान के लिए विकसित एनएन मॉडल का मूल्यांकन किया जा रहा था। एनएन प्रशिक्षण चार सांख्यिकीय मापदंडों का उपयोग करते हुए किया गया था जोकि एमएसईए, आरएमएसईए, बाईस, और एनएसई थे। अध्ययन के फलस्वरूप निकले हुए परिणाम संक्षेप में प्रस्तुत किये गए हैं (सारणी 1)। सांख्यिकीय मापदंडों को प्रशिक्षण

अवधि (अर्थात् 2005-2013) के साथ-साथ परीक्षण अवधि (यानी 2014-2015) के दौरान निर्धारित किया गया था जैसा कि सारणी-1 में दिखाया गया है। परिणाम से यह सन्देश मिलता है कि एएनएन एमएलपी मॉडल ने सभी सात साइट्स पर (ए, बी, सी, डी, ई, एफ और जी) पर काफी अच्छी तरह से लक्ष्य को प्राप्त किया है। सारणी-1 से यह स्पष्ट है कि एनएसई का मूल्य 0.87 से 0.95 के बीच है, एनएसई 0.86 (साइट बी) से 0.95 (साइट ए) में भिन्न होता है। नैश-सिटिक्लिफ दक्षता-1 से -1 से भिन्न हो सकती है। 1 (एनएसई = 1) दिखलाती है कि मॉडल की दक्षता मापे हुए और प्रेक्षित डेटा से परिपूर्ण मेल खाती है। इसी तरह आरएमएसई 0.77 (साइट B) से लेकर 0.95 (साइट C) मॉडल तक है, जिसमें भी प्रेक्षित और मापे हुए डेटा के बीच एक यथोचित सम्बन्ध का संकेत दिया गया है। एमएलपी-एएनएन मॉडल के लिए एमएसई का मान 0.59 (साइट जी) से 0.97 (साइट बी) तक पाया गया था। एमएसई के कम मूल्य ने देखे हुए और प्रतिरूपित मूल्यों की तुलना करते हुए कम त्रुटि का संकेत दिया। यह भी पाया गया है कि न्यूरॉन को बढ़ाने से एमएसई मूल्य (यानी प्रदर्शन में वृद्धि) में कमी आई है। इसी तरह 2 से 3 तक बढ़ती परतों ने भी पूर्वानुमान के प्रदर्शन में सुधार किया है। हालाँकि, इष्टतम बिंदु के ऊपर



चित्र 4 – प्रशिक्षण (2014-2015) की अवधि के लिए साइट (A) पर एएनएन मॉडल का उपयोग करते हुए देखे गए प्रतिरूपित पानी के अन्य स्तर



चित्र 5 – प्रशिक्षण (2014-2015) की अवधि के लिए साइट (डी) पर एएनएन मॉडल का उपयोग करके मापे हुए और प्रतिरूपित पानी के स्तर

बढ़ता हुआ न्यूरॉन और परत मॉडल के प्रदर्शन पर प्रतिकूल प्रभाव डालता है। एएनएन मॉडल के प्रशिक्षण और परीक्षण के दौरान गणना किए गए बायस के मूल्य अधिकांश साइटों में

नकारात्मक हैं (साइट सी एंड साइट डी को छोड़कर)। एएनएन मॉडल द्वारा पानी के स्तर का ओवर-प्रीडिक्शन क्यों इंगित किया गया है।

सारणी 1 – एएनएन मॉडल के परीक्षण के लिए मापे गए सांख्यिकीय मानक

SITES	एएनएन मॉडल	NSE	BIAS	RMSE	MSE
A	प्रशिक्षण	0.95	-0.08	0.83	0.69
	परीक्षण	0.91	-0.12	0.89	0.80
B	प्रशिक्षण	0.90	0.12	0.89	0.79
	परीक्षण	0.86	0.32	0.99	0.97
C	प्रशिक्षण	0.92	0.12	0.96	0.91
	परीक्षण	0.95	0.07	0.89	0.79
D	प्रशिक्षण	0.93	0.10	0.89	0.79
	परीक्षण	0.89	-0.04	0.84	0.70
E	प्रशिक्षण	0.93	0.02	0.89	0.8
	परीक्षण	0.90	-0.16	0.89	0.79
F	प्रशिक्षण	0.91	0.01	0.93	0.87
	परीक्षण	0.94	-0.26	0.9	0.80
G	प्रशिक्षण	0.92	0.17	0.89	0.79
	परीक्षण	0.90	-0.24	0.77	0.59

### निष्कर्ष

इस अध्ययन में, एमएलपी न्यूरल नेटवर्क आर्किटेक्चर ने प्रासारिक मेट्रोलॉजिकल और हाइड्रोलॉजिकल इनपुट चर पर विचार करते हुए अध्ययन क्षेत्र में मासिक जल स्तर में उतार-चढ़ाव की पूर्वानुमान के लिए उपयोग किया। सात साइटों में से प्रत्येक के लिए विकसित तंत्रिका नेटवर्क मॉडल की प्रभावशीलता का मूल्यांकन सांख्यिकीय संकेतकों के साथ-साथ अवलोकन और अनुमानित जल स्तर की दृश्य तुलना का उपयोग करके किया गया था। कृत्रिम तंत्रिका नेटवर्क मॉडल को लगभग सभी स्थलों पर मासिक जल स्तर का पूर्वानुमान करने के लिए कुशल पाया गया। यह निष्कर्ष निकाला जा सकता है कि तंत्रिका नेटवर्क तकनीक का उपयोग विशेष रूप से उन क्षेत्रों में जल स्तर के उतार-चढ़ाव के पूर्वानुमान के लिए किया जा सकता है जहां भूजल प्रबंधन के लिए क्षेत्र डेटा की पर्याप्तता और गुणवत्ता गंभीर मुद्दे हैं।

### संदर्भ

- Almasri M N & Kaluarachchi J J Modular neural networks to predict the nitrate distribution in ground water using the on-ground nitrogen loading and recharge data, *Environmental Modelling & Software* **20**(7) (2005) 851-871.
- Arndt O, Barth T, Freisleben B & Grauer M, Approximating a finite element model by neural

network prediction for facility optimization in groundwater engineering. *Eur. J. Oper. Res.* **166** (2005) 769-781.

- Bhattacharjya R K Datta B & ANN-GA-based model for multiple objective management of coastal (2009).
- Coppola E A Jr, Szidarovszky F, Poulton M & Charles E Artificial neural network approach for predicting transient water levels in a multi layered groundwater system under variable state, pumping, and climate conditions. *Journal of Hydrologic Engineering* **8**: 348-360. (2003). DOI: 10.1061/(ASCE)1084-0699(2003)8:6(348).
- Coulibaly P, Anctil F, Aravena R Bobee B Artificial neural network modelling of water table depth fluctuations. *Water Resour Res* **37**(4)(2001):885-896.
- Coulibaly P, Anctil F & Bobee B Hydrological forecasting using artificial neural networks: the state of art. *Can J Civ Eng* **26** (3)(1999) 293-304.
- Coulibaly P, Anctil F & Bobee B Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *J Hydrol* **230** (2000) 244-257.
- Fausett L Fundamentals of neural networks: Architectures, Algorithms and Applications. Prentice Hall, Englewood Cliffs, New Jersey, (1994) 461 pp.
- Haykin S Neural Networks: A Comprehensive Foundation. Macmillan Publishing, New York (1994).
- Krishna B, Rao Y R S & Vijaya T Modelling groundwater levels in an urban coastal aquifer using artificial neural networks. *Hydrol Process.* **22** (2008) 1180-1188.
- Lallaheem S, Mania J, Hani A & Najjar Y, On the use of neural networks to evaluate groundwater levels in fractured media. *Journal of Hydrology*, **307** (2005) pp. 92-111.
- Maier H R & Dandy G C. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, *Environmental Modelling & Software*., **15** (2000), pp. 101-124.

13. Mohanty S, Jha M K., Kumar A & Sudheer K P, Artificial Neural Network Modelling for Groundwater Level Forecasting in a River Island of Eastern India. *Water Resour Manage* 24: (2010)1845. <https://doi.org/10.1007/s11269-009-9527-x>.
14. Mohanty S, Jha M K, Kumar A & Panda D K, Comparative evaluation of numerical model and artificial neural network for simulating groundwater flow in Kathajodi-Surua Inter-basin of Odisha, India. *Journal of Hydrology*. Vol. **495** (2013) 38-51.
15. Nayak P C, Rao Y R S, Sudheer K P, Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water resources management*, **20** (2006) (1), 77-90.
16. Nikolos I K, Stergiadi M Papadopoulou M P, Karatzas G P Artificial neural networks as an alternative approach to groundwater numerical modelling and environmental design *Hydrological Processes: An International Journal* **22** (17) (2008)., 3337-3348.
17. Rao S & Govindaraju. Artificial neural networks in hydrology. I: Preliminary concepts, *Journal of Hydrologic Engineering*, Vol **5**(2) (2000).