

## फीड फॉरवर्ड न्यूरल नेटवर्क का उपयोग करके मिट्टी के गणितीय मॉडल के माध्यम से फसल वृद्धि अनुकूलन

### Crop Growth Optimization through Soil's Mathematical Model using Feed Forward Neural Networks (FNNs)

ब्रजेश कुमार मिश्र<sup>1</sup>, रुचि पंवार<sup>2</sup> एवं भगत सिंह<sup>3</sup>

Brajesh Kumar Mishra<sup>1</sup>, Ruchi Panwar<sup>2</sup> and Bhagat Singh<sup>3</sup>

<sup>1,3</sup>School of Engineering and Sciences, G D Goyenka University Gurgaon

<sup>2</sup>Department of ASH, PIET, Panipat

brajeshkumar.mishra@gdgu.org<sup>1</sup>, ruchipanwar321@gmail.com<sup>2</sup>, bhagat.singh@gdgu.org<sup>3</sup>

<https://doi.org/10.5281/zenodo.18442687>

#### सारांश

मृदा स्वास्थ्य और फसल उपयुक्तता; मिट्टी के प्रकार, पीएच, पर्णहरित और नमी के स्तर जैसे प्रमुख कारकों के माध्यम से जटिल रूप से जुड़े हुए हैं। पारंपरिक मृदा विश्लेषण विधियों में मैनुअल नमूना संग्रह और प्रयोगशाला परीक्षण की आवश्यकता होती है, जो समय लेने वाली और महंगी हो सकती है। इसके अलावा सेंसर इस क्षेत्र में वांछित परिणाम नहीं दे रहे हैं। इस शोध पत्र में गणितीय मॉडलिंग और डेटा संचालित भविष्यवाणी को मिलाकर एक नया दृष्टिकोण प्रस्तावित किया गया है क्योंकि यह यांत्रिक मॉडल और डेटा संचालित भविष्यवाणी की ताकत का लाभ उठाएगा। विलंब विभेदक समीकरण (Delay Differential Equation (DDE)) मिट्टी मॉडलिंग जैसी समय-विलंबित प्रक्रियाओं को मॉडल करने के लिए एक मजबूत उपकरण प्रदान करते हैं, जबकि एआई का उपयोग करके डेटा संचालित भविष्यवाणी मिट्टी की छवियों से मिट्टी के प्रकार और पीएच मान को निकाल सकती है। अंत में, न्यूरल नेटवर्क (NN) मिट्टी के स्वास्थ्य स्कोर के आधार पर उपयुक्त फसलों जैसे परिणामों की भविष्यवाणी करने के लिए जटिल, गैर-रेखीय संबंधों को संसाधित कर सकते हैं।

#### Abstract

Soil health and crop suitability are intricately connected through key factors such as soil type, pH, chlorophyll and moisture levels. Traditional soil analysis methods require manual sample collection and laboratory testing, which can be time-consuming and expensive. Also the sensors are not giving the desired results in this field. In this paper, a new approach is proposed by combining mathematical modeling and data driven prediction because this will leverages the strength of mechanistic models and data-driven prediction. Delay Differential Equations (DDEs) provide a robust tool to model time-lagged processes like soil modelling, while data driven prediction using AI can be extracted soil type and pH value from soil images. Finally, Neural Networks (NNs) can process complex, nonlinear relationships to predict outcomes such as suitable crops based on soil health scores.

**मुख्य शब्द :** मृदा पोषक तत्व, तंत्रिका नेटवर्क, छवि प्रसंस्करण, मॉडलिंग।

**Keywords :** Soil Nutrients, Neural Network, Image processing, Modelling.

#### परिचय

मिट्टी के स्वास्थ्य, फसल की उपयुक्तता और पौधों के स्वास्थ्य को समझना और पूर्वानुमान लगाना टिकाऊ कृषि के लिए महत्वपूर्ण है। मिट्टी का स्वास्थ्य भौतिक (जैसे, मिट्टी का प्रकार), रासायनिक (जैसे, पीएच, पोषक तत्व सामग्री) और जैविक कारकों द्वारा नियंत्रित होता है, जबकि फसल की उपयुक्तता मिट्टी के गुणों और

पर्यावरणीय स्थितियों पर निर्भर करती है। ये प्राचल पोषक तत्वों की उपलब्धता, जड़ों की पैठ और पौधों की वृद्धि को निर्धारित करने में महत्वपूर्ण भूमिका निभाते हैं, जो अंततः किसी दिए गए क्षेत्र के लिए उपयुक्त फसलों के चुनाव को प्रभावित करते हैं। मिट्टी का प्रकार, जिसे रेतीली, दोमट या चिकनी मिट्टी के रूप में वर्गीकृत किया जाता है, जल प्रतिधारण, वातन और पोषक तत्व धारण क्षमता को नियंत्रित करता है। मिट्टी का पीएच पोषक तत्वों की घुलनशीलता और पौधों के लिए उनकी उपलब्धता निर्धारित करता है। मिट्टी की नमी जड़ों द्वारा पानी के अवशोषण और पोषक तत्वों के परिवहन को प्रभावित करती है। पोषक तत्व मूल्य (नाइट्रोजन, पोटेशियम, फॉस्फोरस) फसल के लिए आवश्यक कारक हैं।

विलंब विभेदक समीकरण (DDE) अंतर्निहित समय विलंब के साथ जैविक और पर्यावरणीय प्रक्रियाओं के मॉडलिंग के लिए एक मजबूत गणितीय ढांचा प्रदान करते हैं। विलंब विभेदक समीकरण पौधे-मृदा अंतःक्रियाओं में अंतर्निहित विलंब को मॉडल करने के लिए एक शक्तिशाली गणितीय ढांचा प्रदान करते हैं। संख्यात्मक सिमुलेशन निष्कर्षों को मान्य करते हैं, पौधे-मृदा अंतःक्रियाओं में विकास दक्षता और संरचनात्मक स्थिरता पर समय अंतराल के प्रभाव को उजागर करते हैं [11]। लेखकों ने विलंब विभेदक समीकरणों का उपयोग करके पौधे की वृद्धि गतिशीलता के लिए एक गणितीय मॉडल प्रस्तावित किया है। विचार किए गए अवस्था चर हैं: पौधे का बायोमास और पोषक तत्व सांद्रता। यह माना जाता है कि विलंबित पोषक तत्व सांद्रता, पौधे की वृद्धि को प्रतिकूल रूप से प्रभावित करती है [13]। विषाक्तता की उपस्थिति में पौधे की वृद्धि के लिए एक विलंब विभेदक गणितीय मॉडल की योजना बनाई गई है [12]।

कई अध्ययनों ने मृदा स्वास्थ्य आकलन के लिए डेटा-संचालित दृष्टिकोणों की खोज की है। निर्णय वृक्ष और सहायक वेक्टर मशीनों जैसी मशीन लर्निंग तकनीकों को मृदा गुणों की भविष्यवाणी करने के लिए लागू किया गया है। हुसैन एवं अन्य [1] ने छवि विश्लेषण और रिमोट सेंसिंग डेटा के आधार पर मिट्टी की बनावट की भविष्यवाणी करने के लिए एक कन्वोल्यूशनल न्यूरल नेटवर्क (CNN) मॉडल विकसित किया, जिससे विभिन्न प्रकार की मिट्टी में उच्च सटीकता प्राप्त हुई। मंडल एवं अन्य [2] द्वारा किए गए शोध में मिट्टी के प्रकारों को वर्गीकृत करने और नमी के स्तर की भविष्यवाणी करने के लिए न्यूरल नेटवर्क का उपयोग किया गया, जिससे सिंचाई शेड्यूलिंग में सहायता मिली। कन्वोल्यूशनल और रीकरंट न्यूरल नेटवर्क जैसी बहु-स्तरीय वास्तुकलाओं ने जटिल मिट्टी और पर्यावरण डेटासेट को संसाधित करने की क्षमता दिखाई है [8]।

न्यूरल नेटवर्क सहित एआई मॉडल का उपयोग दी गई मिट्टी और जलवायु परिस्थितियों के लिए उपयुक्त फसलों का सुझाव देने के लिए किया गया है। चक्रवर्ती एवं अन्य [5] ने फसलों में पोषक तत्वों के अवशोषण पर मिट्टी के पीएच के प्रभाव का आकलन करने के लिए मशीन लर्निंग मॉडल विकसित किए। गुप्ता एवं अन्य [9] जैसे अध्ययनों ने मिट्टी के पीएच को फसल की उपज क्षमता में मैप करने के लिए फीड फॉरवर्ड न्यूरल नेटवर्क का उपयोग किया। सिंह एवं अन्य [3] ने पोषक तत्वों के स्तर और पर्यावरणीय परिस्थितियों के आधार पर मिट्टी की उर्वरता का अनुमान लगाने के लिए न्यूरल नेटवर्क का उपयोग किया। झोउ एवं अन्य [6] ने एक बहु-कार्य न्यूरल नेटवर्क मॉडल प्रस्तावित किया जो फसल की उपज का अनुमान लगाने और टिकाऊ खेती के तरीकों की सिफारिश करने के लिए मिट्टी और पर्यावरण डेटा को एकीकृत करता है। वांग एवं अन्य [10] द्वारा किए गए शोध में मिट्टी के स्वास्थ्य का पूर्वानुमान लगाने के लिए मल्टी-लेयर परसेप्ट्रॉन (एमएलपी) मॉडल में मिट्टी के प्रकार और पीएच को इनपुट विशेषताओं के रूप में जोड़ा गया। अध्ययन में इस बात पर प्रकाश डाला गया कि तटस्थ पीएच वाली दोमट मिट्टी ने चरम पीएच मान वाली चिकनी मिट्टी की तुलना में स्वास्थ्य मीट्रिक में लगातार उच्च स्कोर किया। न्यूरल नेटवर्क के साथ युग्मित उन्नत प्रतिगमन मॉडल का उपयोग मिट्टी की नमी की गतिशीलता का अनुमान लगाने, सिंचाई शेड्यूलिंग और फसल उपज की भविष्यवाणी में सुधार करने के लिए किया गया है [7]।

हालांकि, न्यूरल नेटवर्क मिट्टी की विशेषताओं और पौधों की उपयुक्तता के बीच गैर-रेखीय संबंधों को संभालने में बेहतर प्रदर्शन प्रदान करते हैं। हाल के शोध ने मिट्टी के स्वास्थ्य और फसल की सिफारिशों का एक साथ पूर्वानुमान लगाने के लिए मल्टी-आउटपुट न्यूरल नेटवर्क पर ध्यान केंद्रित किया है। पटेल एवं अन्य [4] द्वारा किए गए एक अध्ययन ने फसल अनुशंसा प्रणालियों के लिए मल्टीलेयर परसेप्ट्रॉन के उपयोग की खोज की। आर्टिफिशियल इंटेलिजेंस (न्यूरल नेटवर्क, सीएनएन) के साथ विलंब अंतर समीकरण मिट्टी के स्वास्थ्य स्कोर और उपयुक्त फसलों जैसे परिणामों की भविष्यवाणी करने के लिए जटिल, गैर-रेखीय संबंधों को संसाधित कर सकते हैं। इन तरीकों को मिलाने से मैकेनिस्टिक मॉडल और डेटा-संचालित भविष्यवाणी की ताकत का लाभ मिलता है। यह संकर ढांचा न केवल मृदा स्वास्थ्य और फसल उपयुक्तता की भविष्यवाणी करता है, बल्कि टिकाऊ और सटीक कृषि पद्धतियों का भी समर्थन करता है।

यह शोध पत्र मृदा स्वास्थ्य पूर्वानुमान और फसल अनुशंसाओं को बेहतर बनाने के लिए कृत्रिम बुद्धिमत्ता के साथ विलंब विभेदक समीकरण को संयोजित करने वाला एक संकर दृष्टिकोण प्रस्तुत करता है। खंड 2 में, इस कार्य की कार्यप्रणाली को समझाया गया है, खंड 3 में इस कार्य के निष्कर्षों को प्रदर्शित किया गया है। निष्कर्ष खंड 4 में दिया गया है।

## क्रियाविधि

### मृदा पोषक तत्व गतिशीलता और पोषक तत्व गतिशीलता के लिए विलंब विभेदक समीकरण

मिट्टी में पानी और पोषक तत्वों की सांद्रता का अनुकरण अक्सर प्रथम-क्रम अंतर समीकरणों का उपयोग करके किया जाता है, जैसा कि वेरकोस्ट और वासेन [14] द्वारा वर्णित किया गया है। समय के साथ पानी की सांद्रता में परिवर्तन,  $W_c(t)$  कई कारकों द्वारा नियंत्रित होता है, जिसमें पानी की आवक, पत्ती का आकार और वाष्पीकरण शामिल है। दिया गया समीकरण जल स्तर में गतिशील परिवर्तन को दर्शाता है,

$$\frac{dW_c(t)}{dt} = k_{W_c} \Delta_{W_c}(t) + k_{\bar{S}_{W_c}} \bar{S} - k_v W(t) + (k_{\bar{R}_{W_c}} R) + k_{\bar{T}_{W_c}} (T - 10) - k_{\bar{P}_{W_c}} |P - 7|,$$

जहाँ  $W_c(t)$  जल सांद्रता है,  $\Delta_{W_c}(t)$  समय  $t$  पर मिलीलीटर में जल की आवक है,  $k_{W_c}$  जल की आवक के प्रभाव को विनियमित करने वाला प्राचल है।  $R$  वर्षा है,  $T$  तापमान है,  $pH$  मिट्टी का  $pH$  मान है।

$$S = \frac{1}{n_m(t)} \sum_{m=1}^{n_m(t)} S_i(t),$$

$S$  किसी विशेष फसल की पत्तियों का औसत आकार है, और  $k_{\bar{S}_w}$  पत्तियों के औसत आकार के प्रभाव को नियंत्रित करने वाला प्राचल है।  $k_v W(t)$  शब्द मिट्टी में पानी के वाष्पीकरण को दर्शाता है। मिट्टी में पानी की मात्रा जितनी अधिक होगी वाष्पीकरण दर उतनी ही अधिक होगी।

मिट्टी में पोषक तत्व की सांद्रता में परिवर्तन को नीचे दिए गए मॉडल के अनुसार दर्शाया गया है

$$\frac{dN_c(t)}{dt} = k_{N_c} \Delta_{N_c}(t) = k_{\bar{S}_{N_c}} \bar{S},$$

जहाँ  $N_c(t)$  पोषक तत्व सांद्रता है, समय  $t$  पर  $ml$  में पोषक तत्व आय है, और पोषक तत्व सांद्रता में पत्तियों के औसत आकार के प्रभाव को नियंत्रित करता है। ध्यान दें कि, पानी और पोषक तत्वों की सांद्रता में भिन्नता में, पत्तियों का औसत आकार जितना बड़ा होगा, पौधे द्वारा संसाधनों की खपत उतनी ही अधिक होगी और सांद्रता में कमी उतनी ही अधिक होगी।

विभिन्न फसलों के पर्णहरित गतिशीलता के लिए विलंब विभेदक समीकरण है

$$\frac{dCh(t)}{dt} = k_{ch} \frac{Nc}{Nc + K} - \beta Ch(t) - \gamma s(t)$$

$$ds/dt = d \cdot t;$$

जहाँ  $\beta$ ,  $\gamma$ ,  $d$  परिवर्तन दर गुणांक हैं और  $s$  पौधों में तनाव का स्तर है।

### मृदा प्रकार और पीएच मॉडलिंग

मिट्टी का प्रकार (जैसे, रेतीली, चिकनी, दोमट) इसके भौतिक और रासायनिक गुणों को निर्धारित करता है। रेतीली मिट्टी जल्दी सूख जाती है लेकिन उसमें कम पोषक तत्व होते हैं, जबकि चिकनी मिट्टी पोषक तत्वों को बनाए रखती है लेकिन जलभराव का कारण बन सकती है। दोमट मिट्टी अधिकांश फसलों के लिए एक आदर्श संतुलन प्रदान करती है। मिट्टी का pH पोषक तत्वों की घुलनशीलता और सूक्ष्मजीवी गतिविधि को प्रभावित करता है, जो दोनों ही पौधों द्वारा पोषक तत्वों के अवशोषण को प्रभावित करते हैं। अधिकांश फसलें तटस्थ से लेकर थोड़ी अम्लीय मिट्टी (pH 6.0–7.5) में बेहतर तरीके से उगती हैं। pH (अम्लीय या क्षारीय) में अत्यधिक मात्रा पोषक तत्वों की उपलब्धता को कम करती है। pH पोषक तत्वों के अवशोषण की क्षमता को नियंत्रित करता है। मिट्टी की उर्वरता, पोषक तत्वों की उपलब्धता और इष्टतम फसल चयन का निर्धारण करने के लिए सटीक कृषि में मिट्टी के प्रकार और pH मान की पहचान महत्वपूर्ण है। MATLAB छवि प्रसंस्करण और मशीन लर्निंग के लिए एक शक्तिशाली वातावरण प्रदान करता है, जो इसे मिट्टी के विश्लेषण को स्वचालित करने के लिए एक प्रभावी उपकरण बनाता है। MATLAB का उपयोग करके मिट्टी के प्रकार और pH मान की पहचान में छवि प्रसंस्करण और मशीन लर्निंग शामिल है। प्रक्रिया छवि अधिग्रहण से शुरू होती है, जहाँ मिट्टी की छवियों को कैप्चर या लोड किया जाता है। इसके बाद ग्री-प्रोसेसिंग की जाती है, जिसमें छवियों को ग्रेस्केल में परिवर्तित किया जाता है, कंट्रास्ट को बढ़ाया जाता है और शोर को हटाया जाता है। बनावट, रंग और तीव्रता विश्लेषण का उपयोग करके फीचर निष्कर्षण किया जाता है। मिट्टी का वर्गीकरण थ्रेशोल्ड-आधारित या SVM जैसी मशीन लर्निंग तकनीकों का उपयोग करके किया जाता है। pH अनुमान अनुभवजन्य या प्रतिगमन मॉडल का उपयोग करके pH मानों के लिए मिट्टी के रंग की विशेषताओं को मैप करता है।

यहाँ MATLAB में इमेज प्रोसेसिंग टूलबॉक्स का उपयोग करके मिट्टी के प्रकार और pH मान की पहचान के लिए विशेष रूप से एक प्लोचार्ट दिया गया है। इसमें मुख्य चरण शामिल हैं:

- 1. छवि अधिग्रहण** – मिट्टी की छवि कैप्चर या लोड करें।
- 2. ग्रीप्रोसेसिंग** – छवि को ग्रेस्केल में बदलें, कंट्रास्ट बढ़ाएँ और शोर हटाएँ।
- 3. फीचर एक्सट्रैक्शन** – बनावट, रंग और तीव्रता जैसी प्रमुख विशेषताओं की पहचान करें।
- 4. मिट्टी के प्रकार का वर्गीकरण** – मिट्टी के प्रकार को निर्धारित करने के लिए मशीन लर्निंग या थ्रेशोल्ड-आधारित वर्गीकरण लागू करें।
- 5. pH मान अनुमान** – अनुभवजन्य या प्रशिक्षित मॉडल का उपयोग करके मिट्टी के रंग की विशेषताओं को pH मानों पर मैप करें।
- 6. परिणाम प्रदर्शन** – पहचानी गई मिट्टी के प्रकार और अनुमानित pH मान दिखाएँ।

## तंत्रिका नेटवर्क वास्तुकला (Neural Network Architecture)

### न्यूरल नेटवर्क

मशीन लर्निंग मॉडल का एक प्रकार जो मानव मस्तिष्क की संरचना और संचालन से प्रेरणा लेता है, वह है न्यूरल नेटवर्क। प्रत्येक न्यूरॉन आने वाले संकेतों को ग्रहण करता है, उन्हें संसाधित करने के लिए एक सक्रियण फंक्शन का उपयोग करता है, और फिर परिणाम को ऊपर की परत में न्यूरॉन्स को भेजता है। प्रशिक्षण के दौरान, न्यूरल नेटवर्क प्रशिक्षण डेटा के दिए गए बैच के लिए अपेक्षित और वास्तविक आउटपुट के बीच अंतर को कम करने के लिए न्यूरॉनल कनेक्शन के भार को समायोजित करते हैं। इस प्रक्रिया के लिए, ग्रेडिएंट डिसेंट जैसे अनुकूलन एल्गोरिथ्म आमतौर पर नियोजित होते हैं। प्रशिक्षण में आगे के प्रसार द्वारा आउटपुट की गणना करना, हानि (यानी त्रुटि) की गणना करना और बैक प्रोपेगेशन अपडेट भार का उपयोग करना शामिल है।

**फॉरवर्ड प्रोपेगेशन:** नेटवर्क इनपुट डेटा को परत दर परत प्रोसेस करता है, और आउटपुट बनाने के लिए वेत और सक्रियण फलन का उपयोग करता है।

प्रत्येक परत  $l = 1, 2, 3, \dots, L-1$  के लिए,

इनपुट के वेत योग की गणना करें

$$Z^{(l)} = W^{(l)} \alpha^{(l-1)} + b^{(l)}$$

अब हम सक्रियण फलन लागू करते हैं

$$\alpha^{(l)} = \sigma(Z^{(l)})$$

जहाँ,  $l$  लेयर  $W^{(l)}$  का वेत मैट्रिक्स है,  $\sigma$  सक्रियण फलन है,  $\alpha^{(0)}$  न्यूरल नेटवर्क में इनपुट है

लेयर  $l$  का बायस वेक्टर  $b^{(l)}$  है।

लागत फंक्शन:  $C =$  नेटवर्क आउटपुट – सही आउटपुट

**बैक प्रोपेगेशन:** लॉस फंक्शन को कम करने के लिए न्यूरल नेटवर्क के वेत को बैक प्रोपेगेशन के ज़रिए अपडेट किया जाता है।

आउटपुट परत में त्रुटि की गणना

$$\delta^{(L)} = \nabla_{\alpha} C * \sigma'(z^{(L)})$$

प्रत्येक परत के लिए त्रुटि की गणना

$$\delta^{(l)} = ((W^{(l+1)})^T \delta^{(l+1)}) * \sigma'(z^{(l)}) \quad l = 2, 3, \dots, L-1$$

भार दिए गए समीकरण द्वारा  $\mu$  सीखने की दर का उपयोग करके अद्यतन किया जाएगा


$$W^{(l)} \rightarrow W^{(l)} - \mu \frac{\partial C}{\partial W^{(l)}}$$

जहाँ  $*$  तत्ववार गुणन को दर्शाता है।  $\nabla_{\alpha} C$  आउटपुट सक्रियण के संबंध में लागत फंक्शन के ढाल को दर्शाता है।  $\sigma'$  सक्रियण फंक्शन के व्युत्पन्न को दर्शाता है।

### फसल अनुकूलन के लिए तंत्रिका नेटवर्क

मिट्टी के प्रमुख मापदंडों का उपयोग करके मिट्टी के स्वास्थ्य और फसल की उपयुक्तता का विश्लेषण करने के लिए एक न्यूरल नेटवर्क (NN) मॉडल तैयार किया गया है। इनपुट विशेषताओं में मिट्टी का प्रकार (वन-हॉट एनकोडेड), पीएच मान, नमी की मात्रा, क्लोरोफिल स्तर और पोषक तत्व स्तर (DDE सिमुलेशन से) शामिल हैं।

आउटपुट में मिट्टी का स्वास्थ्य शामिल है, जिसे 1–4 (खराब से उत्कृष्ट) के पैमाने पर रेट किया गया है, और फसल की उपयुक्तता, जो गेहूं, चावल और मक्का जैसी फसलों के लिए संभावनाएं प्रदान करती है।




न्यूरल नेटवर्क वास्तुकला पांच नोड्स की एक इनपुट परत से शुरू होता है, जिनमें से प्रत्येक एक इनपुट विशेषता का प्रतिनिधित्व करती है। इसमें दो छिपी हुई परतें हैं, जिनमें से प्रत्येक में 10–20 न्यूरॉन्स होते हैं, जो गैर-रैखिकता के लिए ReLU सक्रियण का उपयोग करते हैं। आउटपुट परत में दो भाग होते हैं: मृदा स्वास्थ्य पूर्वानुमान (प्रतिगमन या वर्गीकरण) और फसल उपयुक्तता पूर्वानुमान (बहु-वर्ग वर्गीकरण)। प्रशिक्षण के लिए, उपयोग किए जाने वाले हानि कार्य मृदा स्वास्थ्य प्रतिगमन के लिए माध्य वर्ग त्रुटि (MSE) और फसल उपयुक्तता वर्गीकरण के लिए श्रेणीबद्ध क्रॉस-एंट्रॉपी हैं। यह मॉडल मृदा गुणवत्ता मूल्यांकन और फसल चयन के लिए डेटा-संचालित अंतर्दृष्टि प्रदान करके, मैनुअल प्रयास को कम करके और उपज में सुधार करके सटीक कृषि में मदद करता है।

## परिणाम


पूर्वानुमान में प्रयुक्त प्राचलों  $k_{\bar{R}_{wc}} = 0.4$ ,  $k_{\bar{T}_{wc}} = 0.2$ ,  $k_{\bar{P}_{wc}} = 0.1$ ,  $k_{N_c} = 0.02$ ,  $k_{\bar{S}_{Nc}} = 1.5$ ,  $k_{Ch}$ ,  $\beta$ ,  $\gamma$  को क्लोरोफिल अवशोषण में परिवर्तन की दर को यादृच्छिक रूप से 0.5 से 1.5 और  $d=0.02$  के बीच चुना जाता है। मिट्टी के पोषक स्तर और मिट्टी की नमी का स्तर चित्र 1 में प्रस्तुत किया गया है। इस पोषक स्तर का उपयोग करके क्लोरोफिल स्तर को चित्र 2 में प्रस्तुत किया गया है, पौधे में तनाव को उसी चित्र में लाल रंग में दिखाया गया है। चित्र 1 और 2 से, यह निष्कर्ष निकाला जा सकता है कि जब पौधे प्रारंभिक विकास में होते हैं, तो यह क्लोरोफिल की आवश्यकता के कारण पोषक तत्वों के उच्च स्तर को अवशोषित करते हैं। प्रारंभिक सिमुलेशन संकेत देते हैं कि DDE को एकीकृत करने से मिट्टी की नमी और पोषक तत्व पूर्वानुमान में सुधार होता है। आगे मिट्टी की छवि का उपयोग मैटलैब में इमेज प्रोसेसिंग टूलबॉक्स का उपयोग करके मिट्टी के प्रकार और पीएच मान की भविष्यवाणी करने के लिए किया जाता है। मिट्टी के चित्र 3 का उपयोग करके पूर्वानुमान परिणाम हैं: श्रेणी: जलोढ़ मिट्टी, पीएच परिणाम: पीएच 4 और 6 के बीच है। इसके लिए भ्रम मैट्रिक्स चित्र 4 में दिया गया है। अब, मिट्टी के डेटा का उपयोग करके फसल की उपयुक्तता का अनुमान लगाने के लिए FFNN का उपयोग

### मृदा में पोषक तत्व और नमी का स्तर



चित्र 1: लगभग 17 दिनों के लिए DDE का उपयोग करते हुए मृदा पोषक तत्व और मृदा नमी मान

### पोषक तत्व और तनाव के प्रभाव में पर्णहरित गतिशीलता




चित्र 2: 50 दिनों के लिए DDE का उपयोग करके मिट्टी में क्लोरोफिल और तनाव का स्तर

किया जाता है। इसका उपयोग करके प्रशिक्षण समय और प्रदर्शन चित्र 5 में दिखाया गया है और त्रुटि का अभिसरण चित्र 6 में दिखाया गया है। NN का उपयोग करके उपयुक्त फसल और मिट्टी के स्वास्थ्य के लिए पूर्वानुमान क्रमशः चित्र 7 और 8 में दिया गया है। NN-आधारित मॉडल फसल की सिफारिशों में उच्च सटीकता दर प्राप्त करते हैं, जो संकर दृष्टिकोण को मान्य करता है।




चित्र 3: मैटलैब टूलबॉक्स का उपयोग करके विश्लेषण के लिए मिट्टी के चित्र




चित्र 4: भ्रम आव्यूह






चित्र 5: मैटलैब का उपयोग करके प्रशिक्षण समय और प्रदर्शन कालावधि 69 पर सर्वोत्तम सत्यापन प्रदर्शन  $1.8815 \times 10^{-5}$  है।




चित्र 6: NN आधारित भविष्यवाणी के लिए माध्य वर्ग

### अनुमानित फसल उपयुक्तता बंटन



चित्र 7: NN का उपयोग करके उपयुक्त फसल की भविष्यवाणी  
निवेश आधारित मृदा स्वास्थ्य पूर्वानुमान



चित्र 8: NN का उपयोग करके मिट्टी के स्वास्थ्य की भविष्यवाणी

### निष्कर्ष

यह अध्ययन मृदा स्वास्थ्य आकलन और सटीक खेती में मदद करने के लिए डेटा-ड्रिवन मॉडल के साथ मैकेनिस्टिक मॉडल को जोड़ने की क्षमता पर प्रकाश डालता है। यह पूर्वानुमान मॉडल प्रमुख संकेतकों, जैसे:

पोषक तत्वों की उपलब्धता, मृदा pH स्तर, और अंतर्निहित मृदा वर्गीकरण के आधार पर समग्र मृदा स्वास्थ्य का निर्धारण करता है। न्यूरल नेटवर्क अन्य मिट्टी के साथ-साथ इनपुट के रूप में DDE मॉडल से आउटपुट का उपयोग करके मिट्टी के स्वास्थ्य और फसल की उपयुक्तता की भविष्यवाणी करता है। मिट्टी में पोषक तत्व का स्तर पौधे के अवशोषण और पर्यावरणीय कारकों से प्रभावित होता है। इस मॉड्यूल में मैटलैब इमेज प्रोसेसिंग टूलबॉक्स में विशिष्ट मापदंडों के आधार पर मिट्टी के प्रकारों और पीएच मान को वर्गीकृत करने के लिए मिट्टी के डेटा का विश्लेषण करना शामिल है।

## संदर्भ

1. Hossain, M., Smith, J., and Lee, K. (2018). Soil Texture Prediction Using Convolutional Neural Networks. *Journal of Remote Sensing Applications*, 14(3), 456-468.
2. Mandal, P., Singh, V., and Das, A. (2020). Neural Networks for Soil Type Classification and Moisture Prediction. *Precision Agriculture*, 21(2), 234-245.
3. Singh, R., Kumar, A., and Gupta, P. (2020). Neural Network-Based Soil Fertility Prediction. *Journal of Soil Science and Plant Nutrition*, 20(4), 934-946.
4. Patel, D., Sharma, B., and Jain, R. (2019). Machine Learning Techniques for Crop Recommendation Systems. *International Journal of Agricultural Science and Research*, 9(2), 56-64.
5. Chakraborty, A., Basu, S., and Ghosh, T. (2018). Modeling the Impact of Soil pH on Nutrient Availability Using AI Techniques. *Computers and Electronics in Agriculture*, 154, 120-130.
6. Zhou, Q., Chen, L., and Wang, X. (2020). Multi-Task Learning for Soil and Crop Prediction. *IEEE Transactions on Geoscience and Remote Sensing*, 58(8), 5672-5685.
7. Jones, M., Brown, A., and White, C. (2021). Predicting Soil Moisture Dynamics with Neural Networks for Irrigation Management. *Precision Agriculture*, 22(3), 501-520.
8. Reddy, S., Rao, P., and Nair, R. (2022). Advanced Neural Architectures for Soil and Crop Analytics. *Environmental Informatics*, 34(1), 45-59.
9. Gupta, R., Saini, S., and Yadav, N. (2019). pH-Based Crop Yield Prediction Using Feedforward Neural Networks. *Computers in Agriculture*, 35(1), 12-25.
10. Wang, Y., Liu, F., and Xu, Z. (2021). Multi-Layer Perceptron for Soil Health Prediction Based on pH and Soil Type. *Environmental Informatics*, 29(4), 89-101.
11. Dalal, D., Kumar, V., and Singh, R. (2024). A novel approaches to 6th-order delay differential equations in toxic plant interactions and soil impact: beyond newton-raphson. *Physica Scripta*. 99.
12. Kumar, D.P., Singh, K., and Saini, B. (2024). Analysis of plant growth dynamics under the effect of Toxicity: a delay differential equation model. *Malaysian Journal of Science*.
13. Kaur, D. (2022). Bifurcation induced by delay parameter in plant growth dynamics. *J. Phys.: Conf. Ser.* 2267 012031.
14. Verkleest, A., Veen, A., and Jansen, H. (2005). A simple model for nitrogen-limited plant growth and nitrogen allocation. *Ann. Bot.* 96(5), 871-876.