

डीप लर्निंग तकनीकों का उपयोग करके आड़ू के पौधों में पत्ती की छवियों के माध्यम से रोगों का पता लगाना

Detection of Diseases in Peach Plants Through Leaf Images Using Deep Learning Techniques

सिमरन गुल¹, परविंदर सिंह², सुरिंदर सिंह खुराना³ एवं परमजीत सिंह⁴

Simran Gull¹, Parvinder Singh², Surinder Singh³ and Paramjeet Singh⁴

^{1,2,3}Central University of Punjab, Bathinda, Punjab, India

⁴National Informatic Center, Sri Ganganagar, Rajasthan, India

simrangull19@gmail.com¹, parvinder.singh@cup.edu.in²,

surinder.singh@cup.edu.in³, paramjeet.singh@nic.in⁴

<https://doi.org/10.5281/zenodo.17954305>

सारांश

एआई आधारित (AI based) विधियों द्वारा पौधों में रोग की जांच करना उपयोगी होता है क्योंकि इसके परिणाम स्वरूप सामान्यतः प्रारंभिक अवस्था में रोगों की जांच एवं उनके अनुमान की प्रक्रिया में लगने वाले समय में कमी आती है। पौधों में रोग उनकी उत्पादकता और आर्थिक नुकसान का कारण बनते हैं। आड़ू का पौधा अधिक रोग ग्रस्त होता है जिसके परिणाम स्वरूप आड़ू की फसल का उत्पादन कम हो जाता है। आड़ू के पत्तों में बैक्टीरियल स्पॉट (जीवाणु धब्बे), लीफ कर्ल (पत्ती मरोड़) और लीफ रस्ट (पत्ती का रतुआ) जैसे रोग आमतौर पर पाए जाते हैं जिन्हें आम आदमी द्वारा पहचाना नहीं जा सकता है। कई अध्ययनों ने बैक्टीरियल स्पॉट रोग की जांच की है जबकि लीफ कर्ल और लीफ रस्ट जैसी अन्य बीमारियों पर अपेक्षित ध्यानाकर्षण नहीं हो पाया है। इस शोध पत्र में आड़ू के पौधे में डीप कॉन्वोल्यूशनल न्यूरल नेटवर्क (Deep Convolutional Neural Networks) का उपयोग करके रोगों का पता लगाने के लिए एक स्वचालित प्रणाली विकसित करने की तकनीकी का सुझाव दिया गया है। इस मॉडल के अंतर्गत पौधे की पत्तियों का उपयोग करके आड़ू के पौधे में रोगों की पहचान की जा सकती है। लीफ कर्ल और लीफ रस्ट का डाटासेट भारत के कश्मीर क्षेत्र से मैनुअल रूप से एकत्रित किया गया है, जबकि बैक्टीरियल स्पॉट के लिए डाटासेट ऑनलाइन प्लेटफॉर्म से डाउनलोड किया गया है। संयुक्त डाटासेट का उपयोग, डीप लर्निंग मॉडलों, सीएनएन (CNN) तथा इनसेप्शन V3 (Inception V3) को प्रशिक्षित करने के लिए किया गया है। इसके अलावा, सीएनएन और इनसेप्शन वी 3 के बीच तुलनात्मक विश्लेषण किया गया, जहां सीएनएन को 84.78% की परीक्षण सटीकता (Testing Accuracy) मिली और इनसेप्शन वी 3 ने सीएनएन से बेहतर प्रदर्शन करते हुए 96.00% की परीक्षण सटीकता दिखाई है।

Abstract

Detection of diseases in plants by automatic methods is very useful as it reduces the time consumed to monitor diseases and their prediction at early stages. The diseases in plants cause significant productivity and economic losses. The peach plant is very prone to diseases which results in the decline of peach crop production. Diseases like Bacterial Spot, Leaf Curl, and Leaf Rust are commonly found in peach leaves which can't be identified by laymen. Several studies have investigated the Bacterial Spot disease, while other diseases like Leaf Curl and Leaf Rust didn't get much interest. In this paper, we have suggested a strategy to develop an automatic system for disease detection in the peach plant using deep convolutional neural networks. This model can

be used to identify diseases in the peach plant using the leaves of the plant. The dataset used has been collected manually from the Kashmir region for Leaf Curl and Leaf Rust, while for Bacterial Spot it has been downloaded from an online platform. The combined dataset was trained using CNN and Inception V3 models. Further, the comparative analysis between CNN and Inception V3 was done where CNN got a testing accuracy of 84.78% and Inception V3 showed a testing accuracy of 96% outperforming the CNN model.

मुख्य शब्द: बैक्टीरियल स्पॉट, सीएनएन, डिजिटल इमेज प्रोसेसिंग, इंसेप्शन V3, पत्ती रोग।

Key words: Bacterial Spot, CNN, Digital Image Processing, Inception V3, Plant Disease.

परिचय

भारत एक कृषि प्रधान देश है जहाँ देश की अधिकांश जनसंख्या प्रत्यक्ष या अप्रत्यक्ष रूप से कृषि पर निर्भर है। फसलों में पाए जाने वाले रोग एक गंभीर समस्या हैं, जो कृषि उत्पादन को प्रभावित करती है। [1] एफएओ के अनुसार, कृषिजीवी जनसंख्या, भारत की कुल जनसंख्या का 67 प्रतिशत है, कृषि का सकल घरेलू उत्पाद में 39.4% हिस्सा है, और कृषि वस्तुओं का निर्यात 43% है। गत कुछ वर्षों में, फसल उत्पादन के लिए अधिक भूमि समर्पित की गई है, और किसान भी कई क्षेत्रों में उर्वरकों, कीटनाशकों और जैविक खाद जैसे आदानों के उपयोग के माध्यम से पैदावार बढ़ाने में सफल हुए हैं। यदि हम विशेष रूप से जम्मू और कश्मीर के बारे में बात करते हैं तो कृषि उत्पादन राज्य के राजस्व का लगभग 65% योगदान देता है जो कृषि उत्पादन पर हमारी निर्भरता को दर्शाता है। विचारणीय मुख्य कारकों में से प्रमुख उचित भूमि उपयोग और सही समय पर फसलों में रोगों का पता लगाना है। चूंकि उपलब्ध कृषि योग्य भूमि सीमित है, इसलिए जनसंख्या की बढ़ती जरूरतों को पूरा करने के लिए खेती में इनका उपयोग योजनाबद्ध तरीके से किया जाना चाहिए। रोग का समय पर पता लगाना एक बड़ी

आवश्यकता है क्योंकि कई फसलों में ऐसी बीमारियां होती हैं जो पूरी फसल को नष्ट कर देती हैं। आड़ू के पौधे की बात करें तो दुनिया भर में पैदा होने वाले कुल आड़ू में से केवल 16% का ही व्यापार होता है, बाकी 84% या तो कुछ बीमारियों के कारण या उत्पाद के संरक्षण संबंधित ज्ञान के अभाव में नष्ट हो जाते हैं। सटीक कृषि (Precision agriculture) अपेक्षाकृत नवीन अवधारणा है, और अधिकांश किसान इस बात से अनजान हैं कि यह क्या होती है। इंटरनेट ऑफ थिंग्स (IoT), सेंसर, पोजिशनिंग सिस्टम, रोबोट और कृत्रिम बुद्धिमत्ता (Artificial Intelligence) जैसी तकनीकों का खेत में उपयोग स्मार्ट कृषि के रूप में जाना जाता है। इसका सर्वोत्तम लक्ष्य आवश्यक मानव कार्यभार को कम करते हुए फसलों की विविधता, अधिकता और गुणवत्ता में सुधार करना है। पौधों की बीमारी का पता लगाने के क्षेत्र में बहुत सारे शोध कार्य किए गए हैं। अधिकांश परिस्थितियों में रोगों की जानकारी उस समय होती है जब फल सहित पौधे के अन्य भाग प्रभावित हो जाते हैं। इस शोध में, एक मॉडल विकसित किया गया है जो डीप लर्निंग तकनीकों पर आधारित है, जो पत्तियों की छवियों (इमेज) का उपयोग करके आड़ू के पौधे में बीमारियों का पूरी तरह से पता लगाएगा ताकि हम जल्द से जल्द बीमारी का अनुमान लगा सकें और समय रहते संबंधित बीमारी के निदान एवं फसल के संरक्षण के लिए आवश्यक कदम बढ़ा सकें [2]।

साहित्य समीक्षा

कृत्रिम बुद्धिमत्ता का उपयोग करके स्मार्ट कृषि के विकास की दिशा में गत कुछ वर्षों में काफी शोध कार्य किए गए हैं। कृत्रिम बुद्धिमत्ता का उपयोग फसल संबंधित पूर्वानुमानों में किया जाता है जिनमें प्रमुख हैं: मौसम का पूर्वानुमान, हवा की गति का पूर्वानुमान [3], महामारियों का पूर्वानुमान [4], तथा पौधे के विकास प्रतिधारण की भविष्यवाणी [5]। पिछले कार्यों से पता चलता है कि पौधों के लिए रोग का पता लगाने वाली प्रणाली विकसित करने के लिए शोधकर्ताओं द्वारा विभिन्न प्रयास किए गए हैं

और किए जा रहे हैं। शोधकर्ताओं द्वारा पौधों की बीमारियों का पता लगाने और इन बीमारियों को वर्गीकृत करने के लिए विभिन्न तकनीकों का विकास और उनको प्रस्तावित किया गया है। इस प्रकार की शोध, [6] ने एक स्वचालित प्रणाली (Automated System) की शुरुआत की, जिसे बीमारियों के कारण पौधों में होने वाले रूपात्मक परिवर्तनों के आधार पर चावल के पौधों की पत्ती में रोवन स्पॉट और लीफ ब्लास्ट रोगों के वर्गीकरण के लिए विकसित किया गया था। एसवीएम (SVM) और बेयस क्लासिफायर (Bayes Classifier) का उपयोग पौधों को दोषपूर्ण और स्वस्थ श्रेणी में वर्गीकृत करने के लिए किया गया है। उन्हें जो वर्गीकरण सटीकता मिली वह क्रमशः 79.5% और 68.1% थी। पुजारी एवं अन्य [7] ने इमेज प्रोसेसिंग का उपयोग करते हुए विभिन्न पौधों पर कवक रोग के लक्षणों की पहचान और वर्गीकरण करने के लिए इस्तेमाल किए गए एक अध्ययन की शुरुआत की। यह कार्य पौधों के विभिन्न भागों जैसे फल, पत्ती और तना पर किया गया था। इसके लिए k-औसत गुच्छन (K-mean clustering), निकटतम पड़ोसी (Nearest neighbor), बैक प्रोपेगेशन (Back propagation) और कुछ अन्य छवि प्रसंस्करण तकनीकों का उपयोग किया गया था।

विभिन्न फसलों के वर्गीकरण की सटीकता 76.6% से 94.085% तक के परिसर में थी। इसके अलावा, पडोल और सावंत [8] ने एक ऐसी विधि का प्रस्ताव दिया जो छवि प्रसंस्करण का उपयोग करके अंगूर के पत्तों में रोगों की मात्रा निर्धारित करने की समस्या का समाधान कर सकती है। सपोर्ट वेक्टर मशीन और एएनएन को बेस क्लासिफायर के रूप में इस्तेमाल किया गया था और फिर इस बेस क्लासिफायर को फिर से बनाने और अंततः इसके प्रदर्शन को बेहतर बनाने के लिए फ्यूजन क्लासिफिकेशन (Fusion Classification) तकनीक का इस्तेमाल किया गया था। युवाना एवं अन्य [9] ने एक ऐसी विधि का प्रस्ताव रखा, जिसका उद्देश्य कई प्रशिक्षण स्थितियों के साथ एक डीप


कॉन्वोल्यूशनल न्यूरल नेटवर्क को प्रशिक्षित करके पौधों में बीमारियों का पता लगाना है। दो प्रकार के प्रशिक्षण सेटों पर विचार किया गया: मूल प्रशिक्षण सेट और रूपांतरित प्रशिक्षण सेट। इस्तेमाल किए गए क्लासिफायर: डीसीएनएन, एलेक्स नेट और गूगल नेट थे। हरि एवं अन्य [10] ने हल्के (लाइटवेट) सीएनएन मॉडलों का केले, अमरुद और आम की पत्तियों पर प्रयोग किया है जहां इन मॉडलों ने अपेक्षाकृत कम प्राचलों के उपयोग के साथ 99.14% सही वर्गीकरण सटीकता प्राप्त की है। दोलाताबादियन एवं अन्य [11] ने विभिन्न फसलों पर विकास की प्रभावशीलता को रेखांकित किया है तथा व्यावहारिक कृषि प्रयोग हेतु उनकी संभावनाओं को प्रस्तुत किया है। वीजीजी-19 और इंसेप्शन वी-3 जैसे कॉन्वोल्यूशनल न्यूरल नेटवर्क (सीएनएन) को मशीन लर्निंग क्लासिफायर के साथ संयोजित करने पर 99.1% तक सही वर्गीकरण की सटीकता प्राप्त हुई, जो विभिन्न फसलों में इन तकनीकों की बहुमुखी उपयोगिता को दर्शाती है। तथापि, अधिकांश अध्ययन केवल विशिष्ट फसलों या सीमित डेटासेट तक ही सीमित रहे हैं। कृष्णन एवं अन्य [12] द्वारा बताया गया है कि वर्तमान परिस्थितियों, बहु-फसल अनुकूलनशीलता तथा बड़े पैमाने पर परिनियोजन पर अपेक्षाकृत कम कार्य हुआ है।

ज्ञानान्तराल

कई अध्ययनों ने आड़ू के पौधों में बैक्टीरियल स्पॉट रोग की जांच की है, जबकि लीफ कर्ल और लीफ रस्ट जैसी अन्य बीमारियों पर अधिक शोध के संकेत नहीं मिले। इस शोध पत्र में, हमने आड़ू के पौधों में डीप कॉन्वोल्यूशनल न्यूरल नेटवर्क और इंसेप्शन वी-3 का उपयोग करके रोगों की जांच करने के लिए एक स्वचालित प्रणाली विकसित करने की तकनीक का सुझाव दिया है। इस प्रणाली का उपयोग पौधों की पत्तियों का उपयोग करके आड़ू के पौधों में रोगों की पहचान करने के लिए किया गया है। उपयोग किए गए डेटासेट को कश्मीर क्षेत्र से लीफ कर्ल और लीफ रस्ट के लिए हमारे द्वारा एकत्र किया गया है।

प्रस्तावित विधि

पौधों की पत्तियों की छवि (इमेज) से रोगों की पहचान, वर्गीकरण और विभाजन में अच्छे परिणाम प्राप्त करने के लिए आमतौर पर कृषि में डीप लर्निंग मॉडल का उपयोग किया जाता है। प्रारंभिक चरण में पौधे की पत्तियों की छवि प्राप्त करना है, यह सिस्टम के प्रदर्शन के लिए एक महत्वपूर्ण कार्य है। पत्तियों की इमेज को इकट्ठा करने के लिए डिजिटल उपकरण का उपयोग किया गया है। प्रशिक्षण उद्देश्यों के लिए ऑनलाइन कई डेटासेट उपलब्ध हैं। इमेज प्राप्ति के बाद, सबसे पहले विकार (Noise) और विकृतियों को कम करने के लिए छवियों को पूर्व-संसाधित (प्री-प्रोसेसिंग) किया जाता है। फिर इनपुट इमेज का वर्गीकरण क्लासिफायर द्वारा किया जाता है। चित्र 1 पादप रोग पहचान प्रणाली के मूल मॉडल को दर्शाता है।



चित्र 1: प्रस्तावित प्रणाली का ब्लॉक आरेख

डेटासेट

हमने प्लांट विलेज (Plant Village) डेटासेट [13] से आडू के पौधों की पत्तियों का डेटासेट लिया है और बड़ा डेटासेट बनाने के लिए हमने कुछ लाइव डेटा भी एकत्रित किया है। दोनों डेटासेट के सम्मिलित रूप से बने संयुक्त डेटा में स्वस्थ और रोगग्रस्त पौधों की पत्तियों की 3014 छवियां हैं। डेटासेट को रोगों के अनुसार बैक्टीरिया स्पॉट, हेल्दी, आडू लीफ कर्ल और लीफ रस्ट के रूप में वर्गीकृत किया गया है। हम विभिन्न मूल्यांकन मैट्रिक्स (इवेलुएशन मैट्रिक्स) का उपयोग करके डेटासेट से डीप लर्निंग मॉडल द्वारा वर्गीकृत इमेज के लिए मॉडल के कुल चार वर्गों के प्रदर्शन की जांच करेंगे। डेटासेट के लिए एकत्रित आडू के पत्तों की छवियों की रूपरेखा नीचे दी गई तालिका में दी गई है:



चित्र 2: विभिन्न रोगों की पत्ती छवियां

तालिका 1: डेटासेट की रूपरेखा

रोग का नाम	एकत्रित छवियों की संख्या
बैक्टीरियल स्पॉट	2324
लीफ रस्ट	151
लीफ कर्ल	181
स्वस्थ	358
कुल	3014

डेटा लेबलिंग


इस प्रक्रिया में उपयोग में लिए जाने वाले डाटा की लेबलिंग की जाती है। इसमें डाटा के साथ उपयुक्त एवं वर्णनात्मक लेबल जोड़े जाते हैं इन लेबलों के माध्यम से डाटा को संदर्भ और अर्थ प्रदान किया जाता है ताकि मॉडल इससे सीख सके और सर्वोत्तम निष्कर्ष संभव हो सकें। यह डेटा नमूनों का पता लगाने और उन्हें टैग करने की एक सीधी प्रक्रिया है।

डेटा वृद्धि

इस प्रक्रिया में प्रत्येक छवि के लिए विभिन्न संवर्द्धन तकनीकों को लागू किया गया है। इस प्रक्रिया में 25° , 40° , 65° , 120° , 185° , 240° और 300° कोण पर घुमाकर प्रत्येक छवि की अन्य उप-छवियों को बनाया गया है। इस प्रकार, एक बड़ा डेटासेट तैयार किया गया है। इसमें निम्नलिखित तकनीकों का उपयोग किया गया है।

क्षैतिज और लंबवत शिफ्ट वृद्धि


क्षैतिज और लंबवत शिफ्ट वृद्धि से हमारा मतलब छवि के आयाम और सीमाओं को बदले बिना छवि के पिक्सेल को क्षैतिज या लंबवत रूप से स्थानांतरित करना है। ऐसा करते समय छवि के कुछ पिक्सेल काट दिए जाते हैं, इसलिए छवि के समान आयामों को बनाए रखने के लिए नए पिक्सेल के लिए एक नया क्षेत्र जोड़ा जाता है। चित्र 3 में देखा जा सकता है कि पहली आकृति में पत्ती की छवि को क्षैतिज दिशा में यादृच्छिक रूप से (randomly) पलटा गया है, जबकि दूसरी आकृति में इसे ऊर्ध्वाधर दिशा (vertically) में पलटा गया है।



चित्र 3: क्षैतिज और लंबवत शिफ्ट वृद्धि

क्षैतिज और लंबवत फिलप वृद्धि:


क्षैतिज और लंबवत फिलप ऑगमेंटेशन का मतलब है कि पिक्सेल्स को रो-वाइज या कॉलम-वाइज रिवर्सल करना। चित्र 4 पहली आकृति में क्षैतिज रूप से और दूसरे में लंबवत रूप से पत्ती के फिलपिंग को दर्शाता है।



चित्र 4: क्षैतिज और लंबवत पिलप ऑग्मेंटेशन

रैंडम रोटेशन ऑग्मेंटेशन:


इसमें छवि को यादृच्छिक रूप से घड़ी की दिशा अथवा विपरीत दिशा में घुमाया जाता है, जिससे छवि में वस्तु की स्थिति को एक निश्चित कोण तक बदला जा सके। चित्र 5 एक पत्ती की छवि के यादृच्छिक घुमावों को दिखाता है जिसमें एक घूर्णी श्रेणी विकल्प 0 से 180 डिग्री तक भिन्न होता है।



चित्र 5: रैंडम शिफ्ट ऑग्मेंटेशन

यादृच्छिक चमक वृद्धि:


इस प्रक्रिया में छवियों को अलग-अलग चमक स्तरों के साथ उत्पन्न किया जाता है जो नीचे चित्र 6 में दिखाया गया है:



चित्र 6: यादृच्छिक चमक वृद्धि

प्रस्तावित कार्यप्रणाली का उपयोग करके पौधों में रोगों का पता लगाना और रोगों का वर्गीकरण


पत्तियों, फलों और तने की छवियों का उपयोग करके पौधों में रोगों का पता लगाने और वर्गीकरण करने में उच्च परिणाम देने के लिए डीप लर्निंग एल्गोरिदम का व्यापक रूप से उपयोग किया गया है। आड़ू के पौधे की पत्तियों की छवियों में रोगों का पता लगाने के लिए डेटा सेट को पारंपरिक सीएनएन मॉडल और इंसेप्शन V3 के साथ पाइथन की सहायता से प्रशिक्षित किया गया है। इसके लिए डाटा सेट को तीन भागों में वर्गीकृत किया गया है प्रशिक्षण (ट्रेनिंग), सत्यापन (वैलिडेशन) और परीक्षण (टेस्टिंग)।



चित्र 7: प्रस्तावित प्रणाली का विवरणात्मक ब्लॉक आरेख

सीएनएन

कॉन्वोल्यूशनल न्यूरल नेटवर्क (सीएनएन) एक डीप लर्निंग एल्गोरिथ्म है जिसका उपयोग छवियों की पहचान और वर्गीकरण जैसे कार्यों में किया जाता है। यह विशेष रूप से पिक्सेल डेटा के प्रसंस्करण (processing) के लिए डिज़ाइन किया गया है। कॉन्वोल्यूशन ऑपरेशन इनपुट छवि पर एक फ़िल्टर लगाने की प्रक्रिया है, जिसके माध्यम से छवि से उच्च स्तरीय विशेषताएँ उभारी जाती हैं। चित्र 8 में दर्शाए गए सीएनएन ढांचे (आर्किटेक्चर) के अनुसार, इनपुट लेयर में पत्ती की छवि दी जाती है, जिसका प्रारंभिक आकार $148 \times 148 \times 3$ होता है। इसके बाद तीन कॉन्वोल्यूशनल लेयर (Conv 1, Conv 2, Conv 3) तथा उनके बाद संबंधित मैक्स पूलिंग लेयर (Pooling 1, Pooling 2, Pooling 3) का प्रयोग किया गया है। इन कॉन्वोल्यूशनल लेयर्स का उद्देश्य छवि से विभिन्न स्तरों की विशेषताओं जैसे किनारों, पैटर्न और बनावट को स्पष्ट करना है, जबकि मैक्स पूलिंग लेयर का उपयोग फीचर (विशेषता) मैप्स का आकार घटाने तथा महत्वपूर्ण विशेषताओं को बनाए रखने के लिए किया जाता है। इसके पश्चात एक फ़्लैटन (समतलन) लेयर फीचर मैप्स को एक-आयामी (One-dimensional) वेक्टर में परिवर्तित करती है, जिसे आगे डेंस (फुली कनेक्टेड) लेयर में भेजा जाता है। डेंस लेयर (512 न्यूरोन्स के साथ) निकाली गई विशेषताओं को एकीकृत कर वर्गीकरण की प्रक्रिया को संचालित करती है। अंतिम आउटपुट लेयर का आकार 1×4 है, जो इनपुट छवि को चार वर्गों में वर्गीकृत करती है। इस आर्किटेक्चर में सक्रियण फ़ंक्शन का प्रयोग नेटवर्क में गैर-रेखीयता जोड़ने के लिए तथा ड्रॉपआउट लेयर का प्रयोग ओवरफिटिंग से बचाव हेतु किया गया है। इस प्रकार यह सीएनएन आर्किटेक्चर पत्ती की छवियों का कुशलतापूर्वक विश्लेषण और वर्गीकरण करता है।




चित्र 8: सीएनएन की मूल संरचना

इंसेप्शन V3

इनसेप्शन वी-3 (Inception V3) आधारित मॉडल एक उन्नत कॉन्वोल्यूशनल न्यूरल नेटवर्क है, जिसका उपयोग छवियों में उच्च-स्तरीय विशेषताओं को उभारने और उन्हें वर्गीकृत करने में किया जाता है। चित्र में दर्शाए गए आर्किटेक्चर के अनुसार, इनपुट के रूप में पत्ती की छवि मॉडल को प्रदान की जाती है। यह छवि सबसे पहले Inception V3 नेटवर्क से होकर गुजरती है, जहाँ छवि से किनारे, आकृति, पैटर्न और बनावट जैसी जटिल विशेषताएँ स्वचालित रूप से उभारी जाती हैं। यह मॉडल तीन कॉन्वोल्यूशनल लेयर (आकार 32, 64, 128) से बना है, प्रत्येक के बाद एक सक्रियण फलन (एक्टिवेशन फंक्शन) ReLU आकार 3×3 और अधिकतम-पूलिंग परत आकार 2×2 का आयोग हुआ है। रेखीय रूप को गैर-समान प्रतिनिधित्व में बदलने के लिए एक सक्रियण फलन का उपयोग किया जाता है। इसके बाद प्राप्त फीचर मैप्स को फ़्लैटन लेयर के माध्यम से एक-आयामी वेक्टर (1×18432) में परिवर्तित किया जाता है। यह प्रक्रिया बहु-आयामी (Multi-dimension) डेटा को एक सरल रूप में बदलकर आगे की गणनाओं के लिए

उपयुक्त बनाती है। इसके पश्चात यह वेक्टर डेंस (घनी) लेयर में भेजा जाता है, जिसमें 1024 न्यूरोन्स होते हैं। यह लेयर निकाली गई विशेषताओं को संयोजित कर पत्ती की छवि से संबंधित महत्वपूर्ण पैटर्न को समझने और वर्गीकरण की नींव तैयार करने का कार्य करती है।



चित्र 9: इंसेप्शन की मूल संरचना V3

अंतिम चरण में, आउटपुट लेयर (1×4 आकार वाली) इनपुट छवि को चार संभावित वर्गों में वर्गीकृत करती है। यह लेयर मॉडल का निर्णय प्रस्तुत करती है कि पत्ती किस श्रेणी में आती है। इस प्रकार, यह Inception V3—आधारित आर्किटेक्चर पत्ती की छवियों का गहन विश्लेषण कर उन्हें सटीक रूप से वर्गीकृत करने में सक्षम है।

आड़ू के उत्पादन को प्रभावित करने वाली बड़ी बीमारियों के बीच, हमने तीन सबसे अधिक प्रभावित करने वाले रोगों की जांच की है। पौधों की पत्तियों पर उनके प्रभाव के आधार पर रोगों का चयन किया गया था। इन रोगों का संक्षिप्त विवरण नीचे दी गई तालिका में दिया गया है:

तालिका 2: आड़ू के रोग उनके कारण और लक्षण

क्रम संख्या	रोग का नाम	कारण	पत्तियों पर लक्षण
1.	बैक्टीरियल स्पॉट	जीवाणु	गहरे, छोटे निशान अक्सर पत्ती की नोक पर जमा हो जाते हैं। निशानों के चारों ओर पत्ती का ऊतक पीला हो जाता है।
2.	लीफ कर्ल	कवक	आड़ू के पौधे की युवा पत्तियां विकृत हो जाती हैं; लीफ कर्ल के कारण कर्ल और लाल रंग के क्षेत्र विकसित होते हैं।
3.	लीफ रस्ट	कवक	पत्ती में जंग लगने के कारण आड़ू के पौधे की पत्तियाँ भूरे रंग की हो जाती हैं और जल्दी गिर जाती हैं।

परिणाम

दोनों प्रस्तावित मॉडलों जो कि पारंपरिक सीएनएन और इंसेप्शन वी 3 हैं, के लिए कन्फ्यूजन मैट्रिक्स नीचे दिए हैं:


bacterialsport	665	0	27	8
healthy	96	141	11	2
leafcurl	0	0	42	13
rust	0	0	3	43
	bacterialsport	healthy	leafcurl	rust

bacterialsport	672	3	25	8
healthy	14	236	0	0
leafcurl	0	0	55	0
rust	0	0	0	46
	bacterialsport	healthy	leafcurl	rust


चित्र 10(a): कन्फ्यूजन मैट्रिक्स (सीएनएन)

चित्र 10(b): कन्फ्यूजन मैट्रिक्स (इंसेप्शन V3)

पारंपरिक सीएनएन और इंसेप्शन V3 के मामले में, मॉडल सटीकता को नीचे दिए गए चित्र 11 में ग्राफ में दर्शाया गया है। जिसमें दर्शाया गया है कि 30 इपॉक (पूरे प्रशिक्षण डेटासेट का एक बार न्यूरल नेटवर्क से गुजरना) के लिए सीएनएन में 94.31% की प्रशिक्षण सटीकता और 93.18% की सत्यापन सटीकता हासिल की है। और इंसेप्शन V3 में 20 इपॉक के लिए प्रशिक्षण सटीकता 98.10% और सत्यापन सटीकता 97.67% प्राप्त कर ली गई है।




चित्र 11(a): प्रशिक्षण और सत्यापन सटीकता (सीएनएन)




चित्र 11(b): प्रशिक्षण और सत्यापन सटीकता (इंसेप्शन V3)

सीएनएन और इंसेप्शन V3 के मामले में, प्रशिक्षण और सत्यापन हानि नीचे दिए गए चित्र 12 में ग्राफ में दर्शाया गया है।



चित्र 12(a): प्रशिक्षण और सत्यापन हानि (सीएनएन)



चित्र 12(b): प्रशिक्षण और सत्यापन हानि (इंसेप्शन V3)


तालिका 3: प्रेसिजन-रिकॉल और F1 स्कोर (CNN)

वर्ग	प्रेसिजन	रिकॉल	F1 स्कोर
बैक्टीरियल स्पॉट	0.87	0.95	0.91
लीफ कर्ल	0.51	0.76	0.61
लीफ रस्ट	0.65	0.93	0.77
स्वस्थ	1.00	0.56	0.72

तालिका 4: प्रेसिजन-रिकॉल और F1 स्कोर (इंसेप्शन V3)

वर्ग	प्रेसिजन	रिकॉल	F1 स्कोर
बैक्टीरियल स्पॉट	0.98	0.96	0.97
लीफ कर्ल	0.69	1.00	0.81
लीफ रस्ट	1.00	1.00	1.00
स्वस्थ	0.99	0.94	0.97

विभिन्न प्रस्तावित मॉडलों (सीएनएन और इंसेप्शन वी 3) के प्रशिक्षण, परीक्षण और सत्यापन सटीकता के बीच तुलना का चित्रमय प्रतिनिधित्व नीचे दिए गए आंकड़े में दिखाया गया है ।



चित्र 13: पारंपरिक सीएनएन और इंसेप्शन V3 के बीच तुलना

पारंपरिक सीएनएन मॉडल का प्रशिक्षण, सत्यापन और परीक्षण सटीकता (एक्यूरेसी) क्रमशः 94.31%, 93.18% और 84.78% है। इसके अलावा, इंसेप्शन V3 के मामले में प्रशिक्षण, सत्यापन और परीक्षण सटीकता क्रमशः 98.10%, 97.67% और 96% है।

निष्कर्ष

आड़ू के पौधे में रोग का पता लगाने के लिए स्वचालित डीप लर्निंग आधारित मॉडल विकसित किया गया है। आड़ू के पौधों में आमतौर पर देखी जाने वाली तीन अलग-अलग प्रकार की बीमारियों का पता लगाया गया, जो कि क्रमशः बैक्टीरियल स्पॉट, लीफ कर्ल, और लीफ रस्ट हैं। इस शोध के लिए, हमने दो अलग-अलग

डेटासेट से छवियों को मिलाकर एक बड़ा डेटासेट बनाया – एक कश्मीर के ग्रामीण क्षेत्र के पौधे से स्वयं एकत्रित किया है तथा दूसरा हमने ऑनलाइन स्रोतों से एकत्र किया है। इस तरह स्वस्थ और संक्रमित आड़ू के पत्तों की कुल 3014 छवियां एकत्र की गईं। इस कार्य का मुख्य लक्ष्य आड़ू के पौधे में डीप लर्निंग मॉडलों का उपयोग करके बीमारी का पता लगाना था। इस शोध कार्य में विभिन्न तरह की बीमारियों का पता लगाने और वर्गीकरण की एक्यूरेसी को बढ़ाने के लिए पारंपरिक सीएनएन और इंसेप्शन वी 3 का भी उपयोग कर तुलनात्मक अध्ययन किया गया है। प्रस्तावित तकनीकों से प्राप्त परिणाम अत्यधिक आशाजनक तथा सटीकता में सीएनएन और इंसेप्शन वी3 की परीक्षण एक्यूरेसी क्रमशः 84.78% और 96% थी। एक्यूरेसी, रि कॉल और F1 स्कोर जैसे अन्य मापदंडों की भी गणना की गई। अतः विकसित मॉडल कृषि प्रधान देशों में उत्पादकता बढ़ाने में तथा रोगों की प्रारम्भिक अवस्था में पता लगाने में बहुत ही कारगर साबित होगा। भविष्य में अन्य पौधों में भी इस तकनीक का उपयोग किया जा सकता है एवं अन्य डीप लर्निंग मॉडल विकसित कर परिणाम की सटीकता को बढ़ाया जा सकता है। यह तकनीकी विश्वसनीय रोग नियंत्रण के लिए उच्च संभावनाएं भी दर्शाती है।

शोध पत्र में प्रयुक्त अंग्रेजी शब्दों की समानार्थक हिंदी शब्दावली

Alphabetically sorted terminology in English	वर्णमाला अनुक्रमित हिन्दी शब्दावली
Artificial Intelligence	कृत्रिम बुद्धिमत्ता
Automated System	स्वचालित प्रणाली
Data Augmentation	डेटा वृद्धि
Deep Convolutional Neural Network	गहरे दृढ़ तंत्रिका नेटवर्क
K-mean clustering	k-औसत गुच्छन
Nearest neighbor	निकटतम पड़ोसी
Neural Network	तंत्रिका नेटवर्क
Precision Agriculture	आधुनिक कृषि
Preprocessed	पूर्व-संसाधित
Training Accuracy	प्रशिक्षण सटीकता

संदर्भ

1. Ahmad, J., Alam, D., & Haseen, M. S. (2011). Impact of climate change on agriculture and food security in India. *International Journal of Agriculture, Environment and Biotechnology*, 4(2), 129-137.
2. Singh, P., & Kaur, A. (2022). A systematic review of artificial intelligence in agriculture. *Deep learning for sustainable agriculture*, 57-80.
3. Kumar, A., & Garg, V. (2021). Particle swarm optimization based artificial neural network for wind speed forecasting. *Vigyan Prakash – Research Journal of Science & Technology*, 19(1–2), 19–30.

4. Bhatnagar, M., Kumar, S., & Jain, C. (2021). Understanding the Covid-19 pandemic using machine learning techniques. *Vigyan Prakash – Research Journal of Science & Technology*, 19(4), 18–28.
5. Kauleshwar, P., Padmavati, M. V., & Patnaik, P. K. (2021). Prediction of fetal growth retention using deep learning techniques: A review. *Vigyan Prakash – Research Journal of Science & Technology*, 19(4), 29–39.
6. Phadikar, S., Sil, J., & Das, A. K. (2012). Classification of rice leaf diseases based on morphological changes. *International Journal of Information and Electronics Engineering*, 2(3), 460-463.
7. Pujari, J. D., Yakkundimath, R., & Byadgi, A. S. (2015). Image processing based detection of fungal diseases in plants. *Procedia Computer Science*, 46, 1802-1808.
8. Padol, P. B., & Sawant, S. D. (2016, December). Fusion classification technique used to detect downy and Powdery Mildew grape leaf diseases. In *2016 International Conference on Global Trends in Signal Processing, Information Computing and Communication (ICGTSPICC)* (pp. 298-301). IEEE.
9. Yuwana, R. S., Suryawati, E., Zilvan, V., Ramdan, A., Pardede, H. F., & Fauziah, F. (2019, October). Multi-condition training on deep convolutional neural networks for robust plant diseases detection. In *2019 international conference on computer, control, informatics and its applications (IC3INA)* (pp. 30-35). IEEE.
10. Hari, P., & Singh, M. P. (2023). A lightweight convolutional neural network for disease detection of fruit leaves. *Neural Computing and Applications*, 35(20), 14855-14866.
11. Dolatabadian, A., Neik, T.X., Danilevich, M.F., Upadhyaya, S.R., Batley, J. and Edwards, D., 2025. Image based crop disease detection using machine learning. *Plant Pathology*, 74(1), pp.18-38.
12. Sujatha, R., Krishnan, S., Chatterjee, J. M., & Gandomi, A. H. (2025). Advancing plant leaf disease detection integrating machine learning and deep learning. *Scientific Reports*, 15(1), 11552.
13. Ali, A. (n.d.). *PlantVillage dataset*. Kaggle. <https://www.kaggle.com/datasets/abdallahalidev/plantvillage-dataset>