

## नरमा फसल की पत्तियों पर डीप लर्निंग के आधार पर रोगों का पता लगाना

परमजीत सिंह

अतिरिक्त जिला सूचना विज्ञानअधिकारी (सिस्टम एनालिस्ट)

राष्ट्रीय सूचना-विज्ञान केन्द्र, इलेक्ट्रॉनिकी एवं सूचना प्रौद्योगिकी विभाग, भारत सरकार

(✉ paramjct.singh@nic.in)

### सार

श्रीगंगानगर में नरमा कपास खरीफ की एक मुख्य रेश वाली नकदी फसल है, जिसे "सफ़ेद सोना" के रूप में जाना जाता है। जिले के 80 % एरिया में नरमा कपास की बिजाई की जाती है। नरमा के पत्तों से रोगों की पहचान जल्दी और सटीक रूप से की जा सकती है। पत्तों पर व्याधि की दशा रोग के प्रकार की पहचान करने में मदद करती है डीप लर्निंग एक समाधान प्रदान करता है। इस शोधपत्र में स्वस्थ और संक्रमित पत्ती छवियों के साथ एक डीप लर्निंग मॉडल को प्रशिक्षित किया गया है। यह मॉडल संक्रमित पैटर्न के आधार पर पत्ती की छवियों को स्वस्थ या व्याधिग्रस्त जैसी विभिन्न श्रेणियों में वर्गीकृत करके अपने लक्ष्य को प्राप्त करता है। नरमा व्याधि डेटासेट श्री गंगानगर जिले के खेतों से पत्तिया एकत्र कर किया गया है। Python Programming Language तथा Trained Model में hypothesis लगाकर वर्गीकरण सटीकता 96.67% हासिल की गई है, जो मौजूदा अत्याधुनिक तरीकों में से बेहतर है।

**मुख्य शब्द :** पत्ती व्याधि, कंप्यूटर विज्ञान, डीप लर्निंग, आर्टिफिशियल इंटेलिजेंस

### परिचय

**जि**ले की लगभग 21 लाख जनता अपने जीवन

के लिए इस पर निर्भर हैं। सबसे महत्वपूर्ण कौटों की पहचान करना है जैसे कि उपयुक्त नुकसान को कम करने के लिए कदम उठाए जा सकते हैं। नरमा फसल को पत्तियों पर Viral, Fungal and Bacteria एक गंभीर फसल समस्या का कारण बनता है। रोग निदान व्याधि विज्ञान की शिक्षा का एक अनिवार्य हिस्सा है। यदि व्याधिजनक और व्याधि को पर्याप्त रूप से पहचान नहीं की जाती है, तो निवारक तंत्र अप्रभावी होंगे, जिसके परिणामस्वरूप Agriculture Yield प्रभावित होगा। इसलिए सही व्याधि निदान आवश्यक है [19]। किसान आमतौर पर नरमा के पत्तों के रोगों को अपनी नग्न आंखों से देखकर उनका निदान और पहचान करते हैं। हालांकि यह गलत निदान की ओर ले जाता

है जब किसान अपने स्वयं के अनुभवों के आधार पर संकेतों का आकलन करते हैं। इसलिए स्वचालित व्याधि पहचान आवश्यक है, क्योंकि यह नरमा को पत्ती रोगों के शीघ्र और विश्वसनीय निदान में सहायता करेगा। विभिन्न शोधकर्ताओं ने नरमा उत्पादन क्षेत्र [13] के भीतर विभिन्न प्रबंधन क्षेत्रों को पहचान करने के लिए विभिन्न एल्गोरिद्म का विकास किया है।

### नरमा व्याधि

S.No.	Disease Type	Count of diseases	List of the included diseases
1	Bacterial	3	Blight, Wilt, Soft Spot
2	Viral	4	Mottling, Dwarfing, Distortion, Curl
3	Fungal	5	Rust, Spot, Mildew, Rot, Sooty mold
4	Nutrient Deficiency	9	Nitrogen Deficiency, Phosphorus deficiency, Sulphur Deficiency, Magnesium deficiency, Calcium deficiency, Potassium deficiency, Iron deficiency, Boron deficiency, Zinc deficiency

**प्रस्तावित कार्य**

कार्यान्वयन को तीन चरणों में विभाजित किया गया है: डेटा संग्रह, पूर्व-प्रसंस्करण, और छवि विभाजन। फिर, व्याधि का निदान करने के लिए, फीचर निष्कर्षण और वर्गीकरण किया जाता है, इसके बाद प्राप्त डेटा का उपयोग करके मॉडल सत्यापन किया जाता है। चरण दर चरण प्रक्रिया के लिए प्रवाह चार्ट नीचे दिखाया गया है:

**इनपुट छवि**

यहां हमारे पास एक मानक डेटाबेस [16] से इनपुट छवियां हैं। छवियां सटीकता को प्रभावित कर सकती हैं क्योंकि उनके पास अलग-अलग पृष्ठभूमि और गैर-समान रोशनी हो सकती है। शोर को दूर करने

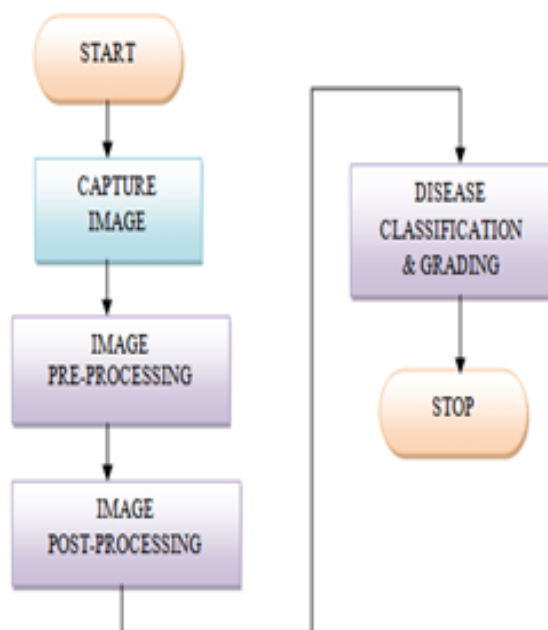
के लिए छवि को पूर्व-संसाधित किया जाना चाहिए [ 5] [ 21- 23]। छवि विभाजन के लिए, छवि का पूर्व-प्रसंस्करण आवश्यक है।

**संबंधित पूर्व शोध कार्य**

S. No	Name of the Author & Year	Methodology	Remarks
1	Nikhil Shah <i>et al.</i> [5], 2019	Artificial Neural Networks	Relative Error 0.05%
2	Kapil Prashar <i>et al.</i> [7], 2019	Support Vector Machine KNN	Accuracy 96%
3	Ch. Usha Kumari <i>et al.</i> [16], 2019	K-Means Clustering Artificial Neural Networks	Accuracy of Bacterial leaf spot 90% Target spot 80% Average Accuracy 92.50%
4	Yogita K.Dubey <i>et al.</i> [3], 2018	Roughness Measure Simple Linear Iterative	Accuracy 94%
5	Namrata R. Bhimte <i>et al.</i> [4], 2018	Support Vector Machine Classification	Accuracy 98.46%
6	Viraj Mehta <i>et al.</i> [17], 2018	Decision Tree Random Forest	For Cotton Disease prediction, RF 95.30% Decision tree 96.73% Multi- output Regressor 89.61% Sensitivity 82.12%
7	Omkar Kulkarni [1], 2018	Deep Learning Image Classification	Accuracy of mobile net 99.04% Accuracy of Inception V3 99.45%
8	Melike Sardogan <i>et al.</i> [19], 2018	CNN Learning Vector Quantisation	Accuracy of 86%
9	Hyeon Park <i>et al.</i> [2], 2018	Deep Learning CNN	Accuracy of 92%
10	Adhao Asmita Sarangdhar <i>et al.</i> [8], 2017	Machine Learning using Regression IoT	Accuracy 83.26%
11	Rathod Vijaya Kishor <i>et al.</i> [20], 2017	SVM Tool Classification	Accuracy 96%
12	Aditya Parikh <i>et al.</i> [9], 2016	KNN Classification	Accuracy 82.5%
13	P. R. Rothe <i>et al.</i> [11], 2015	Pattern Recognition	Average Accuracy 85.52%
14	Jagadeesh D. Pujari <i>et al.</i> [18], 2014	KNN ANN PNN SVM	Accuracy of KNN 91.54% ANN 84.11% PNN
15	P. R. Rothe <i>et al.</i> [14], 2014	Graph cut Method in Image Segmentation	Sharpness features of Bacterial Leaf Blight
16	P. R. Rothe <i>et al.</i> [15], 2014	Adaptive Neuro- Fuzzy Inference	Performance of Bacterial Leaf Blight is 90% Alternaria is 91% Myrothrecium is 92%
17	Viraj A. Gulhane <i>et al.</i> [10], 2014	Principal Component Analysis, KNN	Accuracy 95%
18	M.Hemalatha <i>et al.</i> [12], 2012	Image Processing Edge Detection	Accuracy 98.1%
19	P. Revathi <i>et al.</i> [6], 2012	K-Means Nearest Neighbour	Accuracy 92%
20	Edmund W. Schuster <i>et al.</i> [13], 2011	K-Means Clustering Artificial Neural	Accuracy 88%


### पूर्व प्रसंस्करण

विभिन्न पूर्व-प्रसंस्करण तकनीकों जैसे कि छवि क्रॉपिंग, आकार बदलना, रंग परिवर्तन, कंट्रास्ट एन्हांसमेंट और फ़िल्टरिंग का उपयोग Noise को दूर करने और डेटासेट की छवियों को बेहतर बनाने के लिए किया जाता है। यहां हम इमेज प्री-प्रोसेसिंग के लिए हिस्टोग्राम इक्वलाइजेशन (HE) का उपयोग कर रहे हैं। छवि प्रसंस्करण में बुनियादी माप के लिए अनुप्रयोगों में HE का उपयोग किया जाता है। इसका उपयोग के लिए किया जाता है छवियों को बराबर करें। उच्च कंट्रास्ट छवि उत्पन्न करने के लिए धूसर स्तर की तीव्रता को x-अक्ष के साथ बढ़ाया जाता है। हिस्टोग्राम का उपयोग थ्रेशोल्डिंग में किया जाता है क्योंकि वे छवि की उपस्थिति को बढ़ाते हैं। हिस्टोग्राम इक्वलाइजेशन एक सम्मोहक छवि बढ़ाने वाली तकनीक है जो छवि विपरीतता को बढ़ाती है। हिस्टोग्राम इक्वलाइजेशन आउटपुट इमेज में तीव्रता का एक समान वितरण बनाने के लिए इनपुट इमेज में पिक्सल को तीव्रता मान प्रदान करता है। यह कंट्रास्ट को बढ़ाता है और अधिक सुसंगत हिस्टोग्राम बनाता है।



चित्र 1: प्रस्तावित कार्यप्रणाली के लिए प्रवाह चार्ट।

कंट्रास्ट लिमिटेड एडेप्टिव हिस्टोग्राम इक्वलाइजेशन (CLAHE) हिस्टोग्राम इक्वलाइजेशन तकनीक के विपरीत, जो पूरी इमेज पर काम करता है, CLAHE इमेज के एक छोटे से सेक्शन पर काम करता है जिसे टाइल्स कहा जाता है। प्रत्येक टाइल में बराबर होने के बाद, पड़ोसी टाइलों को सीमा किनारों को खत्म करने के लिए बिलिनियर इंटरपोलेशन का उपयोग करके जोड़ा जाता है, और छवि में मौजूद शोर को मजबूत करने से रोकने के लिए छवि कंट्रास्ट को कम करने के लिए CLAHE एक पैरामीटर का उपयोग करता है।



चित्र 2: एक छवि का CLAHE।

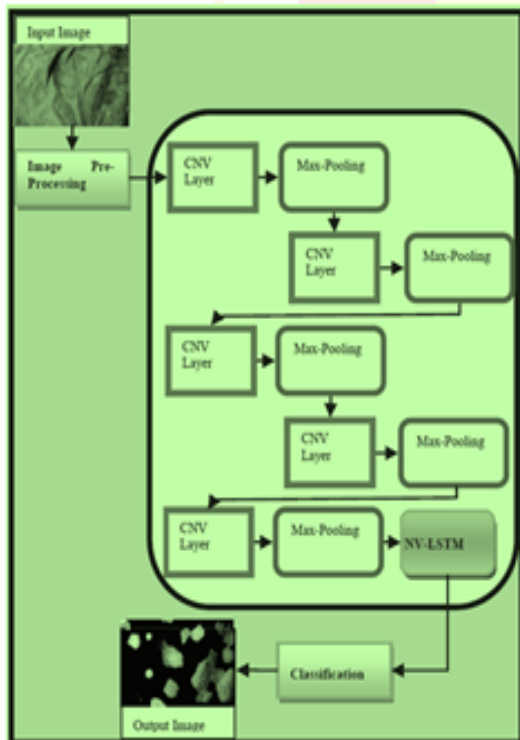
### छवि विभाजन और फ़ीचर निष्कर्षण

छवि विभाजन एक छवि को अलग-अलग भागों में विभाजित करने की प्रक्रिया है, प्रत्येक अपनी वस्तु के साथ। कन्वैन्शनल न्यूरल नेटवर्क्स ने साधारण इमेज के लिए अच्छा प्रदर्शन किया है लेकिन विस्तृत इमेज के लिए इतना अच्छा नहीं है। अन्य एल्गोरिदम, जैसे यू-नेट और रेस-नेट, यहां काम में आते हैं। सीएनएन तंत्रिका नेटवर्क के समान हैं जिसमें उनके पास अलग-अलग वजन और विश्वास वाले कई न्यूट्रॉन हैं जिन्हें सीखा जा सकता है। प्रत्येक न्यूट्रॉन को कई इनपुट दिए जाते हैं, एक भारित योग किया जाता है, एक सक्रियण फ़ंक्शन जोड़ा जाता है, और एक आउटपुट दिया जाता है। नेटवर्क में एक हानि फ़ंक्शन होता है जिसका उपयोग वजन त्रुटि को कम करने के लिए किया जाता है।

सीएनएन एक छवि को एक वेक्टर में परिवर्तित करता है, जिसका उपयोग आमतौर पर वर्गीकरण समस्याओं में किया जाता है।

### रेसनेट

पारंपरिक तंत्रिका नेटवर्क में अधिक परतें एक अधिक मजबूत नेटवर्क का संकेत देती हैं, लेकिन पहली परत के वजन को गायब होने वाले ग्रेडिएंट मुद्दे के कारण बैक-प्रोपेगेशन द्वारा सही ढंग से संशोधित नहीं किया जाएगा। त्रुटि प्रवणता न्यूनतम है क्योंकि इसे बार-बार गुणा करके पिछली परतों में वापस प्रचारित किया जाता है। नतीजतन, जैसे-जैसे नेटवर्क परतों में फैलता है, इसका आउटपुट संतृप्त हो जाता है और तेजी से घट जाता है। Res-Net इस समस्या को हल करने के लिए पहचान मैट्रिक्स का उपयोग करता है। बैक-प्रचार के लिए पहचान फंक्शन का उपयोग करके, ग्रेडिएंट को केवल एक से गुणा किया जाता है।



चित्र 3: प्रस्तावित कार्य की विभिन्न परतें।

यह सुनिश्चित करता है कि इनपुट संरक्षित है, और कोई डेटा खो नहीं गया है। एक अवशिष्ट नेटवर्क में

घटक 3X3 फिल्टर हैं, CNN डाउन-सैपलिंग लेयर्स स्ट्राइड 2 के साथ, पूलिंग लेयर वैश्विक औसत, और सॉफ्टमैक्स सहित 1000 की पूरी तरह से जुड़ी हुई परत।

### कनवल्शन लेयर

एक संकेंद्रित नेटवर्क में व्यापक रूप से उपयोग किए जाने वाले कई कार्यों को समझना आवश्यक है। कनवल्शन के संचालन में दो इनपुट होते हैं: आकार का एक 3D वॉल्यूम (इनपुट छवि) ( $n \times n$  चैनल)  $k$  फिल्टर का एक सेट (जिसे कर्नेल या फंक्शन एक्सट्रैक्टर्स के रूप में भी जाना जाता है), प्रत्येक का आकार ( $f \times f$  चैनल) होता है, जहां  $f$  आमतौर पर 3 या 5 होता है। एक 3D वॉल्यूम (जिसे आउटपुट इमेज या फंक्शन मैप के रूप में भी जाना जाता है) भी एक कनवल्शनल प्रोसेस ( $n \times n \times k$ ) का उत्पाद है।

### मैक्स पूलिंग

संक्षेप में, पूलिंग फीचर आरेख के आकार को कम करता है, जिसके परिणामस्वरूप नेटवर्क में कम पैरामीटर होते हैं। हम पूल फीचर मैप बनाने के लिए इनपुट फीचर मैप के प्रत्येक  $2 \times 2$  ब्लॉक से अधिकतम पिक्सेल मान चुनते हैं। मैक्स-पूलिंग प्रक्रिया में, फिल्टर आकार और स्ट्राइड्स दो महत्वपूर्ण हाइपर-पैरामीटर हैं जिन्हें ध्यान में रखना चाहिए। इसका उद्देश्य प्रत्येक क्षेत्र से केवल सबसे महत्वपूर्ण विशेषताओं (उच्चतम मूल्य वाले पिक्सेल) को रखना और अन्य को त्यागना है। यह ध्यान देने योग्य है कि दोनों कनवल्शन और, विशेष रूप से, पूलिंग ऑपरेशन सिग्नल के आकार को कम करते हैं, जिसे डाउनसैपलिंग के रूप में जाना जाता है। मैक्स पूलिंग, जिसे पीक पूलिंग के रूप में भी जाना जाता है, एक पूलिंग प्रक्रिया है जो प्रत्येक फंक्शन फीचर मैप में अधिकतम या सबसे महत्वपूर्ण मान तय करती है। निष्कर्ष औसत पूलिंग में फीचर की औसत उपस्थिति के बजाय पैच में सबसे वर्तमान फीचर को हाइलाइट करने वाले फीचर मैप्स को डाउनसैपल या पूल किए गए

फॉचर मैक्स हैं। यह मानक पूलिंग की तुलना में अधिक प्रभावी है।

21	5	12	19
14	2	4	11
42	32	28	16
5	23	21	31

21	19
42	31

ए) इनपुट छवि (बी) मैक्स। पूल छवि

चित्र 4: पूलिंग तंत्र

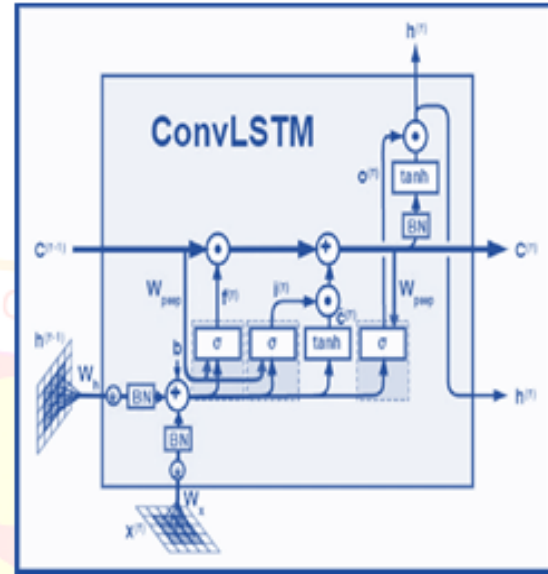
### सक्रियण और अवशिष्ट कार्य

एक अवशिष्ट ब्लॉक में एक 3x3 कनवल्शन लेयर होता है, जिसके बाद एक बैच नॉर्मलाइजेशन लेयर और एक एक्टिवेशन फॉचर होता है जिसे ReLU कहा जाता है। प्रक्रिया कनवल्शन और बैच नॉर्मलाइजेशन लेयर से शुरू होती है। इन सभी परतों को छोड़ कर, स्किप लिंक ReLU सक्रियण सुविधा से ठीक पहले संलग्न हो जाता है। उन अवशिष्ट ब्लॉकों को दोहराकर एक अवशिष्ट नेटवर्क बनाता है।

### कनवल्शन LSTM

LSTM के विपरीत, मैट्रिक्स गुणन के बजाय कनवल्शन ऑपरेशन शामिल हैं। नतीजतन, विशेषताओं के साथ एक 1D वेक्टर होने के बजाय, इनपुट आयामों को ConvLSTM की कोशिकाओं में मौजूद डेटा द्वारा बनाए रखा जाता है। एक कन्वैक्शनल-एलएसटीएम मॉडल एक कन्वैक्शनल-एलएसटीएम के लिए एक अलग दृष्टिकोण का अनुसरण करता है, जिसमें छवि को कनवल्शन लेयर्स के माध्यम से पारित किया जाता है और परिणाम प्राप्त विशेषताओं के 1 डी सरणी के लिए एक संग्रह होता है। जब आप इस पद्धति को सभी समय श्रृंखला

छवियों पर लागू करते हैं, तो आपको समय के साथ बदलने वाली सुविधाओं का एक सेट मिलता है, जो कि LSTM परत इनपुट है।



चित्र 5: कनवल्शन LSTM की कार्यप्रणाली।

### वर्गीकरण

छवि विभाजन सॉफ्टमैक्स क्लासिफायरियर लॉजिस्टिक रिग्रेशन की बाइनरी संरचना का सामान्यीकरण है। हमारे मैपिंग फंक्शन  $f$  को उसी तरह परिभाषित किया गया है जैसे कि हिंज लॉस या स्क्वर्ड हिंज लॉस जिसमें यह डेटा  $x$  का एक इनपुट सेट लेता है और इसे आउटपुट क्लास में मैप करता है। यह मैपिंग क्रमशः डेटा और वेट मैट्रिक्स,  $x$  और  $W$  के बीच एक डॉट उत्पाद का उपयोग करके की जाती है:

$$f(X_i, W) = W X_i$$

हालांकि प्रत्येक क्लासमार्क के स्कोर काज के नुकसान के रूप में असामान्य संभावनाओं के समान होते हैं, हमने हिंज लॉस फंक्शन को बदलकर क्रॉस-एन्ट्रॉपी नुकसान की गणना की है:

$$L_i = -\log \left( \frac{e^i}{\sum_j e^j} \right)$$

प्रत्येक पिक्सेल को एक सॉफ्टमैक्स मान दिया जाता है, जिसके बाद एक हार्नि फंक्शन होता है। यह समस्या को विभाजन से समूहीकरण में बदल देता है,

जिससे प्रत्येक पिक्सेल को किसी एक वर्ग को असाइन करने के लिए मजबूर किया जाता है।

**परिणाम**

ऊपर वर्णित एल्गोरिथम एनाकॉडा टूल का उपयोग करके python में लागू किया गया है। प्रयोग एसर एस्पायर 7, कोर i7 , 11वीं पीढ़ी के लैपटॉप पर NVIDIA Geforce के साथ किए गए हैं जीटीएक्स 1650/60 हर्ट्ज 4GB समर्पित ग्राफिक्स कार्ड, 16GB रैम विंडोज ऑपरेटिंग सिस्टम प्रस्तावित विधि का मूल्यांकन नरमा व्याधि डेटासेट District Sri Ganganagar पर किया जाता है। तालिका 2 में सूचीबद्ध प्रस्तावित कार्यप्रणाली के प्रदर्शन का मूल्यांकन करने के लिए विभिन्न रेस-नेट हाइपरपैरामीटर का उपयोग किया जाता है। प्रस्तावित कार्यप्रणाली के प्रदर्शन को तुलना विभिन्न मौजूदा अत्याधुनिक विधियों और मूल्यांकन के अनुसार की जाती है।

**Table 2: Res-Net Hyper Parameters**

Parameter Name	Values
Epocs	
Dropout	0.30
Batch Size	130
Learning Rate	0.001
No. of Convolution + ReLU	5
No. of Fully Connected Layer	1
Pooling Layer	Max Pooling
Pooling Layer Window Size	2

**Table 3: Comparison of proposed work with other state-of-art technology.**

S.No	Name of the Author & Year	Classification Technique	Accuracy (in %)
1	Aditya Parihar <i>et al.</i> [9], 2016	KNN	82.5
2	Adhao Asmita Sarangdhar <i>et al.</i> [8], 2017	Machine Learning using IoT	83.26
3	P. R. Rohe <i>et al.</i> [11], 2015	Edge Detection	85.52
5	Edmund W. Schuster <i>et al.</i> [13], 2011	K-Means, ANN	88
6	P. Revathi <i>et al.</i> [6], 2012	KNN	92
7	Hyeon Park <i>et al.</i> [2], 2018	Deep Learning, CNN	92
8	Ch. Usha Kumari <i>et al.</i> [16], 2019	K-Means, ANN	92.5
9	Yogita K. Dubey <i>et al.</i> [3], 2018	Roughness Measure	94
10	Viraj A. Gulhane <i>et al.</i> [10], 2014	PCA, KNN	95
11	Rathod Vijaya Kishor <i>et al.</i> [20], 2017	SVM	96
12	Kapil Pashar <i>et al.</i> [7], 2019	SVM, KNN	96
13	Proposed Methodology	ResNet, LSTM	97.16

विभिन्न रोगों के लिए, हम क्षेत्र-आधारित छवियों का उपयोग करते हैं, जिनका विश्लेषण संक्रमित क्षेत्र को प्राप्त करने और चुने हुए क्षेत्र में व्याधि के प्रकार को पहचान करने के लिए किया जाना चाहिए। इन रोगों का विश्लेषण और वर्गीकरण मॉडल का उद्देश्य

दुनिया भर में किसानों को सहायता करना है क्योंकि यह अपनी उपस्थिति का निदान करने के लिए दृश्यमान जानकारी का उपयोग करता है। प्रस्तावित एल्गोरिथम के प्रदर्शन का मूल्यांकन कॉटन डिजीज डेटासेट Sri Ganganagar क्षेत्र के नरमा पर किया जाता है और एल्गोरिथम की सटीकता 96.67% है। के मुताबिक

तुलनात्मक अध्ययन के अनुसार नरमा रोगों को वर्गीकृत करने की प्रस्तावित विधि मौजूदा विधियों की तुलना में अधिक उपयुक्त है।

### संदर्भ

- [1] ओंकार कुलकर्णी(2018), "डीप लर्निंग का उपयोग करके फसल व्याधि का पता लगाना।"
- [2] हियोन पार्क, यूनु जी सूक, और से-हान किम (2018), "फसल व्याधि छवि-आधारित डीप लर्निंग मैकेनिज्म का उपयोग करके निदान कर रहा है।"
- [3] योगिता के. दुबे, मिलिंद एम. मुश्रीफ, सोनम टिपल (2018), " सूती पत्ती के रोगों का पता लगाने और वर्गीकरण के लिए सुपरपिक्सेल आधारित खुरदरापन उपाय ।" में: सूचना और प्रौद्योगिकी में हालिया प्रगति पर चौथा अंतर्राष्ट्रीय सम्मेलन ( आरएआईटी-2018)
- [4] नम्रता आर. भीमटे, वी.आर. थूल(2018), " इमेज प्रोसेसिंग और एसवीएम क्लासिफायर का उपयोग कर कॉटन लीफ स्पॉट की बीमारी का पता लगाना।" में: इंटेलेजेंट कंप्यूटिंग और कंट्रोल सिस्टम पर दूसरे अंतर्राष्ट्रीय सम्मेलन की कार्यवाही( आईसीआईसीएस 2018)
- [5] कृत्रिम तंत्रिका नेटवर्क का उपयोग करके नरमा की पत्ती में व्याधि का पता लगाना ।"
- [6] पी. रेवती, एम. हेमलता (2012), "एडवांस कंप्यूटिंग एनरिचमेंट इवैल्यूएशन ऑफ कॉटन लीफ स्पॉट डिजीन डिटेक्शन यूनिंग इमेज एन डिटेक्शन।" ICCCNIT -2012, कोयंबटूर, श्रीगंगानगर, राजस्थान में।
- [7] कपिल पराशर, रजनीश तलवार, चंदर कांत (2019), " अमेरिकन कॉटन लीफ डिजीन रिकॉग्निशन के लिए एसवीएम और केएनएन के साथ ओवरलैपिंग पुलिंग मेथड और मल्टी-लेयर्ड लर्निंग पर आधारित सीएनएन।" में: स्वचालन, कम्प्यूटेशनल और प्रौद्योगिकी प्रबंधन पर अंतर्राष्ट्रीय सम्मेलन ( आईसीएसटीएम )
- [8] अधो अस्मिता सारंगधर, प्रो. डॉ. वी.आर. पवार (2017), "कॉटन लीफ डिजीन डिटेक्शन एंड कंट्रोलिंग यूनिंग आईओटी के लिए मशीन लर्निंग रिग्रेसन तकनीक ।" में: इलेक्ट्रॉनिक्स, संचार और एयरोस्पेस प्रौद्योगिकी पर अंतर्राष्ट्रीय सम्मेलन( आईसीईसीए 2017)
- [9] आदित्य पारिख, मेहल एस. रावल, चंद्रसिंह परमार, और संजय चौधरी (2016), "अनर्कॉन्स्ट्रैन्ड इमेजेज से नरमा के पौधे में व्याधि का पता लगाने और गंभीरता का अनुमान।" में: 2016 डेटा विज्ञान और उन्नत विश्लेषिकी पर आईईईई अंतर्राष्ट्रीय सम्मेलन
- [10] विराज ए. गुल्हाने, महेशकुमार एच. कोलेकर (2014), " पीसीए क्लासिफायर का उपयोग कर नरमा की पत्तियों पर रोगों का निदान।" में: 2014 वार्षिक आईईईई इंडिया सम्मेलन( इंडिकॉन )
- [11] पीआर रोटे, आरवी क्षीरसागर (2015), " पैटर्न रिकॉग्निशन तकनीक का उपयोग कर नरमा की पत्ती व्याधि की पहचान।" व्यापक कंप्यूटिंग(आईसीपीसी) पर अंतर्राष्ट्रीय सम्मेलन में
- [12] पी. रेवती, एम. हेमलता (2012), " इमेज प्रोसेसिंग एन डिटेक्शन तकनीक का उपयोग कर नरमा लीफ स्पॉट डिजीन का वर्गीकरण।" 2012 में विज्ञान, इंजीनियरिंग और प्रौद्योगिकी में उभरते रुझानों पर अंतर्राष्ट्रीय सम्मेलन
- [13] एडमंड डब्ल्यू. शूस्टर, सुमीत कुमार, जेफरी एल। विलर्स, जॉर्ज ए। मिलिकेन(2011), "डेटा-संचालित कृषि के लिए बुनियादी ज्ञांचा : सांख्यिकीय मॉडलिंग और मशीन लर्निंग तकनीकों का उपयोग करके नरमा के लिए प्रबंधन क्षेत्रों की पहचान करना ।"
- [14] रोटे, पीआर, और आरवी क्षीरसागर । " नरमा पत्ती रोगों की पहचान के लिए अनुकूली न्यूरो-फजी अनुमान प्रणाली।" 2014 में बिजली, ऊर्जा और नियंत्रण पर कम्प्यूटेशनल इंटेलेजेंस के अभिनव अनुप्रयोग , मानवता पर उनका प्रभाव ( CIPECH ), पीपी। 12-17। आईईईई, 2014।
- [15] रोटे, पीआर, और आरवी क्षीरसागर । "डिजिटल छवियों का स्वचालित निष्कर्षण तीन प्रकार के नरमा के पत्तों की बीमारियों की विशेषता है।" 2014 में इलेक्ट्रॉनिक्स पर अंतर्राष्ट्रीय सम्मेलन , संचार और कम्प्यूटेशनल इंजीनियरिंग ( आईसीईसीसीई ), पीपी 67-71। आईईईई, 2014।
- [16] सीएच. उषा कुमारी, एस. जीवन प्रसाद, जी. मौनिका (2019), "लीफ डिजीन डिटेक्शन : फीचर एक्सट्रैक्शन विद के-मीन्स क्लस्टरिंग एंड क्लासिफिकेशन विद एएनएन।"

- [17] विराज मेहता, चाहत जैन, करण कंचन, प्रो. विनया सावंत (2018), "ए मशीन लर्निंग अप्रोच टू फोरटेल द प्रोबेबिलिटी ऑफ ए डिजीन कॉन्ट्रिब्यूटिंग ए डिजीन।"
- [18] जगदीश डी. पुजारी, राजेश यक्कुंडीमठ, अब्दुलमुनाफ एस. ब्यादगी (2014), "इमेज प्रोसेसिंग तकनीकों का उपयोग करते हुए फंगल रोगों से प्रभावित कृषि/बागवानी फसलों की पहचान और वर्गीकरण।"
- [19] मुझे पसंद है सरगोडोगन, Adem ट्यूनर, यूनुस ओज़ेन (2018), " सीएनएन और एलवीक्यू एल्गोरिथम पर आधारित प्लांट लीफ डिजीन डिटेक्शन एंड क्लासिफिकेशन।"
- [20] राठौड़ विनया किशोर, खंडारे पूजा शत्रुघ्न, मुखेकर कोमल बाला साहब, मदाक भाग्यश्री सदाशिव, प्रो. विधाते सचिन, डॉ. गायके वीवी, मलथी सीतामराजू (2017), " क्षेत्रीय क्षेत्र में नरमा और सोयाबीन फसलों के लिए कृषि मौसम विशेषज्ञ प्रणाली।" इन: संचार और कंप्यूटिंग प्रौद्योगिकी में प्रगति पर अंतर्राष्ट्रीय सम्मेलन ( आईसीएसीटी 2018)।
- [21] कुमार एस, सुखविंदर सिंह, और जगदीश कुमार। "मल्टी-फीचर विधि के साथ मशीन लर्निंग का उपयोग करके लिंग वर्गीकरण।" आईईईई 9वां वार्षिक कंप्यूटिंग और संचार कार्यशाला और सम्मेलन ( सीसीडब्ल्यूसी ), पीपी 0648-0653, लास वेगास, यूएसए, 7 जनवरी-9 वें, 2019।
- [22] कुमार एस, सुखविंदर सिंह, और जगदीश कुमार। " मल्टी-फीचर विधि के साथ मशीन लर्निंग का उपयोग करके चेहरे का लाइव पता लगाना।" वायरलेस पर्सनल कम्युनिकेशंस, वॉल्यूम। 103, नंबर 3, पीपी 2353-2375, 2018।
- [23] कुमार एस, सुखविंदर सिंह, और जगदीश कुमार। " हार वेवलेट फीचर्स और एसवीएम के साथ जेनेटिक एल्गोरिथम का उपयोग करते हुए ऑटोमेटिक लाइव फेशियल एक्सप्रेशन डिटेक्शन।" वायरलेस पर्सनल कम्युनिकेशंस, वॉल्यूम। 103, नंबर 3, पीपी 2435-2453, 2018।
- [24] कुमार एस, सुखविंदर सिंह और जगदीश कुमार "फेस स्मूफिंग डिटेक्शन यूजिंग इम्पूव्ड सेगनेट आर्किटेक्चर विद ब्लर एस्टीमेशन टेक्नीक" इंटरनेशनल जर्नल ऑफ बायोमेट्रिक, इंडर्सईस पब्लिकेशन, 2021 में।
- [25] रोहित राजा, संदीप कुमार, और राशिद महमूद, वायरलेस पर्सनल कम्युनिकेशन में "कलर ऑब्जेक्ट डिटेक्शन बेस्ड इमेज रिट्रीवल यूजिंग आरओआई सेगमेंटेशन विद मल्टी-फीचर मेथड" इन वायरलेस पर्सनल कम्युनिकेशन, पीपी 1-24, 2020।
- [26] कुमार एस, सुखविंदर सिंह, और जगदीश कुमार, "ए मल्टीपल फेस डिटेक्शन यूजिंग हाइब्रिड फीचर्स विद एसवीएम क्लासिफायर" स्पिंगर नेचर ऑन डेटा कम्युनिकेशन एंड नेटवर्क्स विद आईएसबीएन: 978-981-13-2254-9।