



“ईएमडी–एसवीआर” हाइब्रिड मशीन लर्निंग मॉडल और कृषि मूल्य पूर्वानुमान में इसका अनुप्रयोग

पंकज दास, गिरीश कुमार झा, अचल लामा, भारती

10.18805/BKAP385

सारांश

समयबद्ध और सटीक मूल्य पूर्वानुमान कृषि चुनौतियों में से एक है। यह उत्पादक और उपभोक्ता दोनों को कुशल योजना बनाने में मदद करता है। मूल्य डेटा में अंतर्निहित गैर-स्थिरता और गैर-रैखिकता पूर्वानुमान में समस्या पैदा करती है। एक एकल पूर्वानुमान मॉडल एक साथ गैर-स्थिरता और गैर-रैखिकता से निपटने में सक्षम नहीं हो सकता है। इस संदर्भ में समस्या से निपटने के लिए ईएमडी–एसवीआर नामक एक गैर-रेखीय हाइब्रिड मॉडल प्रस्तावित है। अनुभवजन्य मोड अपघटन (ईएमडी) मूल्य डेटा को एक सीमित और छोटी संख्या में सबसेट में विघटित करके गैर-स्थिरता से संबंधित है। इसके अलावा इन विघटित उपसमुच्चयों का समर्थन वेक्टर रिग्रेशन (एसवीआर) मॉडल का उपयोग करके पूर्वानुमान लगाया जाता है और अंतिम पूर्वानुमान लगाने के लिए एकत्र किया जाता है। प्रस्तावित हाइब्रिड मॉडल के प्रदर्शन का मूल्यांकन मिर्च के मासिक मूल्य सूचकांक में किया गया है। अनुभवजन्य परिणामों ने ईएमडी–एसवीआर मॉडल श्रेष्ठतम पाया गया।

शब्द कुंजी: कृषि मूल्य पूर्वानुमान, अनुभवजन्य विघटन अपघटन, गैर-विहीनता, गैर-सहायक, समर्थन वेक्टर प्रतिगमन।

“EMD-SVR” Hybrid Machine Learning Model and its Application in Agricultural Price Forecasting

Pankaj Das, Girish Kumar Jha, Achal Lama, Bharti

ABSTRACT

Timely and accurate price forecasting is one of challenges in agriculture. It helps both producer and consumer to make the efficient plan. The inherent nonstationarity and nonlinearity in price data makes problem in forecasting. A single forecasting model may not be able to tackle nonstationarity and nonlinearity, simultaneously. With this context, a nonlinear hybrid model called EMD-SVR has been proposed to deal the problem. The empirical mode decomposition (EMD) deals with nonstationarity by decomposing price data into a finite and small number of subsets. Further, these decomposed subsets are forecasted using support vector regression (SVR) model and aggregated to make final forecast. The performance of the proposed hybrid model are evaluated in monthly price index of chili. The empirical results indicated the superiority of the EMD-SVR model.

Key words: Agricultural price forecasting, Empirical mode decomposition, Nonlinearity, Nonstationary, Support vector regression.

प्रस्तावना

कृषि बाजार/मंडी का माहौल अभूतपूर्व गति के साथ स्थानीय और विश्व दोनों स्तर पर बदल रहा है। बाजार/मंडी की गतिशील प्रकृति खेत की कीमतों और इस तरह खेत की आमदनी को प्रभावित करती है। अधिकांश ग्रामीण किसान अपने लाभों के लिए बाजार और मूल्य व्यवहार को समझने और व्याख्या करने में असमर्थ हैं (Anjaly *et al.*, 2010)। इस प्रकार, बाजार की जानकारी और ज्ञान किसानों और व्यापारियों के लिए यह निर्णय लेने के लिए महत्वपूर्ण है कि क्या उगाना

ICAR-Indian Agricultural Statistics Research Institute, New Delhi-110 012, India.

Corresponding Author: Pankaj Das, ICAR-Indian Agricultural Statistics Research Institute, New Delhi-110 012, India.

Email: pankaj.iasri@gmail.com

How to cite this article: Das, P., Jha, G.K., Lama, A. and Bharti (2022). “EMD-SVR” Hybrid Machine Learning Model and its Application in Agricultural Price Forecasting. *Bhartiya Krishi Anusandhan Patrika*. 37(1): 1-7. DOI: 10.18805/BKAP385.

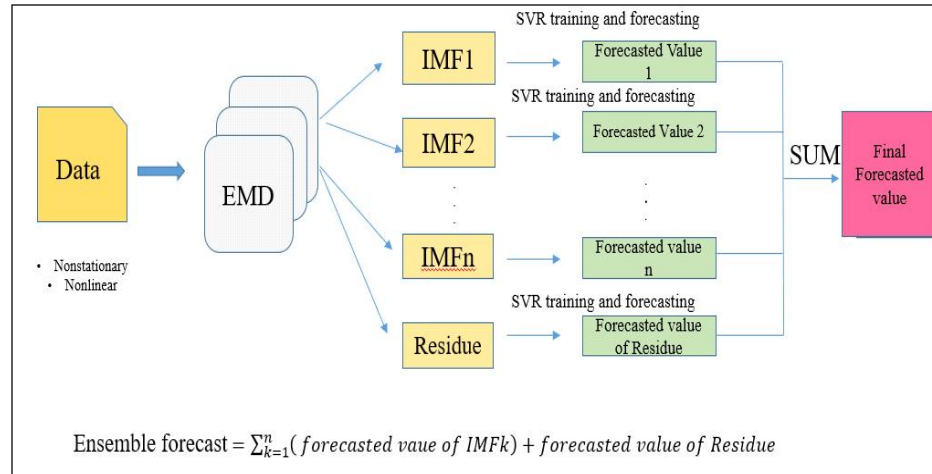
Submitted: 13-10-2021 **Accepted:** 22-03-2022 **Online:** 16-04-2022

है, कब और कहाँ बेचना है। इसके अलावा, मूल्य अस्थिरता और अनिश्चितता निर्णय और नीति निर्माता पर प्रतिबंधन होता है। इसलिए, कृषि मूल्य पूर्वानुमान उत्पादन और बाजार की रणनीति दोनों के लिए महत्वपूर्ण भूमिका निभाता है। मूल्य का पूर्वानुमान वस्तु की मांग और आपूर्ति को नियंत्रित करता है। कृषि उत्पाद का मूल्य पूर्वानुमान एक अत्यंत कठिन कार्य है क्योंकि यह बहुत से कारकों पर निर्भर करता है जिनकी सटीक भविष्यवाणी नहीं की जा सकती है। गैर-रेखीय और अप्रत्यक्षता का व्यवहार कृषि मूल्य डेटा में अहम समस्याएं हैं। पारंपरिक गैर-रेखीय काल श्रृंखला मॉडल जैसे कि ऑटोरिग्रेसिव कंडिशनल विषमलैंगिक (आर्च) मॉडल (Engle, 1982), सामान्यीकृत आर्च (गार्च) मॉडल (Bollerslev, 1986) आदि अंतर्निहित गैर-रेखीय और गैर-प्राथमिक विशेषता के कारण कृषि मूल्य श्रृंखला को मॉडल करने में विफल रहता है। इस समस्या को दूर करने के लिए, मशीन लर्निंग की तकनीक जैसे कृत्रिम तंत्रिका नेटवर्क (ए. एन. एन) और सपोर्ट वेक्टर मशीन (एस.वी.एम) ने आर्थिक काल श्रृंखला पूर्वानुमान के लिए नमूना आदानों से एक मॉडल के निर्माण के माध्यम से भविष्यवाणियां या निर्णय लेने में महत्वपूर्ण लोकप्रियता हासिल की। एस वी एम में एक अनूठा समाधान प्राप्त करने की सामान्यीकरण क्षमता है (Lu *et al.*, 2009)। एस वी एम का संरचनात्मक जोखिम न्यूनीकरण सिद्धांत मॉडल के प्रदर्शन को बढ़ाता है (Duan and Stanley, 2011)। एस वी आर मॉडल को बड़े डेटासेट को प्रशिक्षित करने के लिए लंबे समय की आवश्यकता होती है। समस्या के समाधान के लिए, Suykens और Vandewalle (1999) लीस्ट स्क्वायर सपोर्ट वेक्टर रिग्रेशन (LSSVR) को समर्थन करते हैं जो स्क्वायर रूट फंक्शन के माध्यम से असमानता बाधाओं को समानता बाधाओं में परिवर्तन करता है। मशीन लर्निंग विधियाँ आमतौर पर इस धारणा पर आधारित होती हैं कि डेटा पीढ़ी तंत्र समय के साथ बदलता नहीं है। गैर-स्टेशनरी से निपटना आधुनिक मशीन सीखने की सबसे बड़ी चुनौतियों में से एक है (Sugiyama and Kawanabe, 2012)।

साहित्य में कई शोधकर्ताओं ने गैर-रेखीय और गैर-स्थिर की समस्या से निपटने के लिए विभिन्न संकर विधियाँ प्रस्तावित किए हैं। Huang *et al.* (1998) ईएमडी के मुख्य गुणों पर प्रकाश डाला जैसे डेटासेट पर स्थिर धारणाएँ की कमी यानी स्टेशनरिटी या रैखिकता और प्राथमिकता निर्धारित आधार कार्यों का उपयोग नहीं करना। Zhang (2003) ने काल श्रृंखला पूर्वानुमान के लिए हाइब्रिड ऑटोरिग्रेसिव इंटीग्रेटेड मूविंग एवरेज (अरिमा) और न्यूरल नेटवर्क (एन. एन.) मॉडल का प्रस्ताव दिया और यह निष्कर्ष निकाला कि रैखिक और गैर-रेखीय मॉडलिंग में एक संकर पद्धति के पास अरिमा और

एन एन मॉडल की अनूठी ताकत है। Ince और Trafalis (2006) ने पूर्वानुमान सटीकता में सुधार करने के लिए ऑटोरिग्रेसिव इंटीग्रेटेड मूविंग एवरेज और सपोर्ट वेक्टर रिग्रेशन (एस वी आर) पर आधारित एक हाइब्रिड मॉडल का प्रस्ताव दिया। प्रस्तावित कार्यप्रणाली ने लॉगिटध्रोबिट मॉडल को बेहतर बनाया। Chen (2007) द्वारा किए गए प्रयोग में एसवीआर ने एनएन और अधिकतम संभावना अनुमान (एम एल ई) से बेहतर की श्रेष्ठता का प्रदर्शन किया। Brandl *et al.* (2009) परिवर्तनशील चयन के लिए जेनेटिक एल्गोरिथ्म का इस्तेमाल किया और एसवीआर कार्यप्रणाली का उपयोग करके मॉडल को सेट किया। प्रस्तावित मॉडल ने एन एन, आर्डिनरी लीस्ट स्क्वायर (ओ एल एस) रिग्रेशन और ऑटोरिग्रेसिव इंटीग्रेटेड मूविंग एवरेज मॉडल से बेहतर प्रदर्शन किया। An *et al.* (2012) ने बताया कि ईएमडी काल श्रृंखला के छिपे हुए पैटर्न और रुझानों को प्रकट कर सकते हैं जो विभिन्न अनुप्रयोगों के लिए पूर्वानुमान मॉडल डिजाइन करने में प्रभावी ढंग से सहायता कर सकते हैं। Guo *et al.* (2012) ने ईएमडी का उपयोग करके विंड स्पीड सीरीज विघटित किया और फीड फॉरवर्ड नेटवर्क का उपयोग करके उन्हें पूर्वानुमानित किया गया। Chen *et al.* (2012) ने पर्यटन मांग पूर्वानुमान के लिए एन एन मॉडल के साथ संयुक्त एक ईएमडी का प्रस्ताव रखा। Lama *et al.* (2016) ने कृषि कमोडिटी की कीमत में उतार-चढ़ाव के पूर्वानुमान के लिए, टाइम डिले न्यूरल नेटवर्क्स (टी डी एन एन) आधारित गार्च की श्रेष्ठता का पता लगाया।

पूर्वानुमान साहित्य में यह सार्वभौमिक रूप से लगभग सहमत है कि कोई भी विधि हर स्थिति में सर्वश्रेष्ठ नहीं है। यह काफी हद तक एक वास्तविक दुनिया की समस्या है जो स्वभाव में जटिल होती है और कोई भी एक मॉडल अलग-अलग पैटर्न को समान रूप से कैप्चर नहीं कर सकता है। यह एक संयोजन मॉडल विकसित करने के लिए प्रेरित करता है जो काल श्रृंखला मॉडल और मशीन लर्निंग तकनीक के साथ संबंधित है और पूर्वानुमान सटीकता में सुधार के लिए दोनों रैखिक और गैर-रेखीय पैटर्न के साथ काम कर सकता है। चित्र 1 इस वर्तमान अध्ययन में, EMD-SVR हाइब्रिड दृष्टिकोण प्रस्तावित किया गया है। इस विधि में, ईएमडी का उपयोग गैर-रेखीय और गैर-स्थिर श्रृंखला को सीमित और उप संकेत के छोटी संख्या में विघटित करने के लिए किया गया था। तब ये उप-संकेत व्यक्तिगत रूप से एस वी आर तकनीक का उपयोग करके मॉडलिंग और पूर्वानुमानित किया गया था। उप-संकेतों के सभी पूर्वानुमानित मूल्यों को अंतिम पूर्वानुमान के लिए एकत्र किया गया। इस प्रस्तावित मॉडल में व्यक्तिगत मॉडल की तुलना में पूर्वानुमान दक्षता में बेहतर परिणाम आया।



चित्र 1: प्रस्तावित EMD-SVR प्रतिमान का कार्य प्रवाह ।

सामग्री एवं परीक्षण विधि

संयोजन विधि एक मशीन लर्निंग का तरीका है जो इष्टतम प्रेडिक्टिव मॉडल उत्पादन करने के लिए कई आधार मॉडल का संयुक्त करता है। प्रस्तावित ईएमडी-एसवीआर में आकृति में परिभाषित तीन चरण शामिल हैं। पहला चरण, ईएमडी तकनीक द्वारा मूल गैर-रेखीय और गैर-स्थिर डेटासेट एक परिमित और अक्सर स्वतंत्र उप-श्रृंखला की छोटी संख्या में विघटित होता है। इस उपश्रेणी में उजी इन्ट्रिंसिक मोड फंक्शन्स (आई एम एफ) और अंतिम अवशेष शामिल हैं। दूसरे, एसवीआर के माध्यम से, आई एम एफ और अवशेष की मॉडलिंग और भविष्यवाणी की जाती है। फिर, सभी आई एम एफ और अवशेषों के पूर्वानुमानित मूल्यों की टुकड़ी को मूल श्रृंखला के पूर्वानुमानित करने के लिए संक्षेप में प्रस्तुत किया गया है (Huang *et al.*, 1998)।

Empirical mode decomposition (EMD)

एम्पिरिकल मोड डीकम्पोजीशन (ई एम डी) विधि का प्रस्ताव Huang *et al.* द्वारा 1998 में पेश किया गया। उनके अनुसार डेटा के कई सहसंयोजक दोलन मोड हैं जो काफी अलग फ्रीक्वेंसी के हैं और ये मोड एक दूसरे पर निर्भर हैं और एक अवलोकन योग्य काल श्रृंखला बनाते हैं। ईएमडी मूल गैर-स्थिर और गैर-केंद्रित डेटा को एक परिमित और स्वतंत्र उप-श्रृंखला की छोटी संख्या में विघटित करता है (इन्ट्रिंसिक मोड फंक्शन्स और एक अंतिम अवशेष सहित)। एम्पिरिकल मोड डीकम्पोजीशन (ई एम डी) ईएमडी द्वारा विघटित परिमित योज्य ऑसिलेटरी घटक है। उदाहरण के लिए, मान लिया कि y_t एक डेटासेट जिसमें उच्च आवृत्ति भाग और कम आवृत्ति भाग शामिल है। डेटा = तेज दोलन गति को धीमी दोलन गति में आरोपित किया।

$$y_t = d_{1(t)} + r_{1(t)} \quad (1)$$

जहाँ y_t = काल श्रृंखला डेटा, $d_{1(t)}$ = उच्च आवृत्ति भाग अर्थात आई एम एफ और $r_{1(t)}$ = कम आवृत्ति भाग ई एम डी एल्गोरिथ्म, धीम गति दोलन घटक पर पुनरावृत्ति करता है जो एक नया संकेत माना जाता है।

$$r_{1(t)} = d_{2(t)} + r_{2(t)} \quad (2)$$

पूर्ण विघटन के बाद

$$y_t = \sum_{i=1}^m d_{i(t)} + r_{i(t)} \quad (3)$$

डेटा = आई एम एफ की राशि + अंतिम अवशेष।

चरण ई एम डी एल्गोरिदम प्रक्रिया नीचे उल्लिखित है:

चरण 1: y_t के सभी विलोपन को पहचानें।

चरण 2: ऊपरी एनवलप U_t बनाने के लिए स्थानीय मैक्सिमा को इंटरपोल करें।

चरण 3: निम्न एनवलप L_t बनाने के लिए स्थानीय मिनीमा को इंटरपोलेट करें।

चरण 4: माध्य एनवलप की गणना करें: $m_t = \frac{(U_t + L_t)}{2}$

चरण 5: संकेत से औसत एनवलप निकालें: $h_t = y_t - m_t$

चरण 6: जांचें कि क्या h_t आई एम एफ की स्थिति को संतुष्ट करता है।

हाँ: h_t एक आई एम एफ है, स्थानांतरण बंद करें।

नहीं: $y_t = h_t$ को शिफ्ट करते रहें।

सपोर्ट वेक्टर रिग्रेशन (एस वी आर) मॉडल

वैपनिक द्वारा प्रस्तावित सपोर्ट वेक्टर मशीन (एस वी एम) (1998), नॉनलाइनियर एल्गोरिदम है जो सुपरवाइज्ड लर्निंग परमेवर्क्स में डेटा विश्लेषण और पर्यवेक्षित शिक्षण में पैटर्न के ढांचे को सीखने के लिए किया जाता है। Vapnik (1998) ने लॉस फंक्शन का उपयोग करके प्रस्तावित सपोर्ट वेक्टर

रिग्रेशन (एस वी आर) मॉडल का प्रस्ताव रखा। एस वी आर इनपुट वैक्टर को एक उच्च आयामी अंतरिक्ष में मैप करता है और फिर बाहरी अंतरिक्ष में रैखिक प्रतिगमन चलाते हैं। मॉडल दो चरणों में बनाया गया है यानी प्रशिक्षण और परीक्षण कदम। प्रशिक्षण चरण में, डेटासेट का सबसे बड़ा हिस्सा फंक्शन के अनुमान के लिए उपयोग किया जाता है। परीक्षण चरण में, छोटा उपसमुच्चय जो प्रशिक्षण के दौरान अलग रह गया था उसमें मॉडल के प्रदर्शन की जाँच करके मॉडल की सामान्यीकरण क्षमता का मूल्यांकन किया जाता है।

किसी दिए गए डेटा सेट के लिए, एस वी आर नॉन लिनियर फंक्शन द्वारा, मूल डेटा को उच्च या अनंत आयामी स्थान में मैप करता है। फिर मैपिंग फंक्शन की तलाश करता है।

रैखिक सपोर्ट वेक्टर मशीन के लिए सामान्य सूत्र:

$$y_i = \phi(x) = W \cdot \phi(x) + b \quad (4)$$

जहाँ W भार सदिश को परिभाषित करता है, ϕ मानचित्रण फलन को दर्शाता है और b बायस है। एल एस एस वी आर सबसे छोटा वर्ग संस्करण है एस वी आर जहाँ समाधान खोजने के लिए रैखिक समीकरणों के सेट का उपयोग किया जाता है।

वर्तमान अध्ययन में, लीस्ट स्क्वायर एस वी आर मॉडल, विशेष रूप से ε -एस वी आर उपयोग किया गया है। रेडियल बेसिस कर्नेल फंक्शन (आर बी एफ) का उपयोग डेटासेट का नॉनलाइनियर मैपिंग के लिए किया गया है।

परिणाम एवं विवेचना


डेटासेट विवरण

वर्तमान अध्ययन में, मासिक मिर्च थोक मूल्य सूचकांक (डब्लु पी आई) डेटासेट प्रस्तावित ई एम डी-एस वी आर मॉडल के प्रदर्शन का मूल्यांकन करने के लिए उपयोग किया गया है। भारत सरकार, मंत्रालय वाणिज्य कार्यालय के आर्थिक सलाहकार से डेटासेट प्राप्त किया गया था। चित्र 2 में मिर्च डब्लु पी आई का मासिक डेटा (अप्रैल, 1994 – मई, 2018) 290 डेटा बिंदु आधार वर्ष 2005 के साथ प्रस्तुत किया गया है। डेटा का डिस्क्रिप्टिव स्टैटिस्टिक्स, स्टेशनरिटी टेस्ट और सामान्यता तालिका 1 में प्रस्तुत की गई है। संवर्धित डिकी-फुलर (ऐ डी एफ) और फिलिप्स-पेरोन (पी पी) परीक्षण के माध्यम से प्राप्त किया आँकड़े निरर्थक अशक्त थे यानी यूनिट रूट टेस्ट की परिकल्पना से इनकार नहीं किया जा सकता है। यह अस्थिर (nonstationary) डेटा सेट का संकेत था। Jarque-Bera परीक्षण (तालिका 1) ने भी आँकड़ों की गैर-असमानता का संकेत दिया।

ब्रॉक-डेचर्ट-स्किकमैन (Brock et al., 1996) परीक्षण डेटासेट में, डेटा के गैर-शुद्धता की जाँच के लिए उपयोग किया गया था। बी डी एस परीक्षण (तालिका 2) के परिणामों ने बताया कि परीक्षण आँकड़े आलोचनात्मक मूल्यों से कहीं बड़े थे। यह शून्य परिकल्पना को अस्वीकार करने के लिए एक सबूत प्रदान किया है कि मूल्य श्रृंखला रैखिक रूप से

तालिका 1: डेटा, स्थिरता परीक्षण और सामान्यता परीक्षण के वर्णनात्मक आँकड़े।

Observations	Minimum	Maximum	Mean	Standard deviation	Skewness	Kurtosis
290	136.5	971.3	412.8	201.415	1.042	3.252
	Augmented dickey-fuller test		Phillips-perron test		Jarque-bera test	
	(p value)		(p value)		(p value)	
	0.924		0.821		2.772e-12	




चित्र 2: मिर्च के मासिक थोक मूल्य सूचकांक का टाइम प्लॉट।

निर्भर है। इसलिए, मासिक चिल्ली डब्लु पी आई डेटासेट गैर-रेखीय और गैर-स्थिर था।

ई एम डी-एस वी आर प्रशिक्षण और पूर्वानुमान

पूरा विश्लेषण RStudio में किया गया था। पैकेज “EMD-SVR” hybrid (Das *et al.*, 2021) का उपयोग क्रमशः ईएमडी और एसवीआर फिटिंग के लिए किया गया। सबसे पहले, संपूर्ण मूल डेटासेट को 4 आई एम एफ और एक अंतिम अवशेष में विघटित किया गया, चित्र 3 में यह देखा गया है कि आई एम एफ के आवृत्तियों और आयाम एक दूसरे से अलग थे।

इस प्रकार, मूल डेटासेट में विभिन्न छिपे हुए ओसिलेट्री मोड ई एम डी द्वारा अलग किए गए थे। यूनिट रूट टेस्ट आई एम एफ और अवशेषों की स्थिरता की जांच करने के लिए किया गया था। तालिका 3 में परीक्षण के परिणामों का वर्णन किया गया है। आई एम एफ 4 और अवशेष अस्थिर थे। वे भिन्न द्वारा स्थिर में तब्दील हो गए। प्रत्येक व्यक्तिगत घटक (आई एम एफ और अवशेष) एसवीआर द्वारा मॉडलिंग और पूर्वानुमानित किया गया। प्रशिक्षण के रूप में 80 प्रतिशत डेटा और परीक्षण के रूप में 20 प्रतिशत का उपयोग किया गया।



चित्र 3: मासिक मिर्च WPI के विघटित घटक।

तालिका 2: ब्रॉक-डेचर्ट-स्किकमैन (बीडीएस) परीक्षण का परिणाम।

		Embedding dimension		Conclusion
Statistics	Probability	Statistics	Probability	
66.089	<0.001	106.523	<0.001	Nonlinear
51.709	<0.001	62.327	<0.001	
40.525	<0.001	42.372	<0.001	
35.129	<0.001	34.132	<0.001	

तालिका 3: मिर्च डेटासेट के विघटित घटकों की इकाई जड़ परीक्षण।

IMFs	Phillips-Perron Test (p value)	Augmented Dickey-Fuller Test (p value)	Remarks
1	<0.01	<0.01	Stationary
2	<0.01	<0.01	Stationary
3	<0.01	<0.01	Stationary
4	0.559	0.260	Non-stationary
Residue	0.99	0.985	Non-stationary

तालिका 4: SVR और EMD-SVR मॉडल का पूर्वानुमान प्रदर्शन।

Method	Forecast period	RMSE	MAPE	MAD	ME
EMD-SVR	F_1-F_6	27.228	0.021	19.627	58.519
	F_1-F_8	37.483	0.033	31.420	68.734
SVR	F_1-F_6	73.373	0.078	72.580	69.984
	F_1-F_8	78.918	0.050	46.041	116.450

फिर, सभी आई एम एफ और अवशेषों के पूर्वानुमानित मूल्यों की टुकड़ी को मूल श्रृंखला के एन्सेम्बल पूर्वानुमानित करने के लिए संक्षेप में प्रस्तुत किया गया है।

आईट्रेटिव चरण 8 और चरण 6 भविष्यवाणी ई एम डी-एस वी आर मॉडल की आउट-ऑफ-सैंपल प्रेडिक्टिविलिटी को मापने के लिए उपयोग किया जाता है। मॉडल हर बार एक-कदम आगे की भविष्यवाणी करता है और अगली बार भविष्यवाणी के लिए वर्तमान उत्पादन को जोड़ा गया। अध्ययन में, रेडियल के साथ ϵ -SVR बेसिस फंक्शन (आर बी एफ) कर्नेल फंक्शन के रूप में नियोजित किया गया। ग्रीड खोज विधि का उपयोग करके इष्टतम पैरामीटर संयोजन तय किया गया। 10- फोल्ड क्रॉस सत्यापन संगठन की समस्या को दूर करने के लिए किया गया। पूर्वानुमान का प्रदर्शन की तुलना रूट मीन स्क्वायर त्रुटियों (आर एम एस आई), मीन एब्सोल्यूट डिविएशन (एम डी), मीन पूर्ण प्रतिशतता त्रुटि (एम ऐ पी ई) और अधिकतम त्रुटि (एम ई) से की गई (Das et al. 2020)। जहां उपर्युक्त समीकरणों में y और F_i^h प्रतिक्रिया चर, $i=1, \dots, N$, $N=6$ और 8 का h वास्तविक मान और पूर्वानुमानित मूल्य हैं। तुलना के लिए एस वी आर का उपयोग करके चरण 6 और चरण 8 में आगे की भविष्यवाणी की गई। तालिका 4 में मॉडलों का पूर्वानुमान प्रदर्शन वर्णित है।

तालिका 4 स्पष्ट रूप से दर्शाती है कि ईएमडी-एसवीआर मॉडल की पूर्वानुमान सटीकता मानक एसवीआर मॉडल की तुलना में बेहतर थी। यहां तक कि ई एम डी-एस वी आर का प्रदर्शन भी मॉडल पूर्वानुमान अवधि तक सीमित नहीं था। यह परिणाम दर्शाता है कि ई एम डी को शामिल करके एस वी आर की सटीकता में सुधार कर सकते हैं। चरण-8 एस वी आर पूर्वानुमान की सटीकता चरण-6 ई एम डी-एस वी आर पूर्वानुमान से थोड़ा कम था।

निष्कर्ष

वर्तमान कृषि मंडी का माहौल अचानक बदल रहा है और यह गतिशील प्रकृति किसान और व्यापारी को प्रभावित करती है। उनमें से अधिकांश किसानों को बाजार और मूल्य व्यवहार समझ में नहीं आता है। इसलिए, कीमत पूर्वानुमान कुशल निर्णय बनाने के लिए महत्वपूर्ण भूमिका निभाता है। जल्दी खराब होने वाले कृषि उत्पाद जैसे कि मिर्च के लिए यह एक और समस्या है। अग्रिम में मूल्य जानकारी बाजार के नुकसान से किसानों और व्यापारियों की मदद करता है। वर्तमान अध्ययन में, एक नया तकनीक “ई एम डी-एस वी आर” प्रस्तावित किया गया है। पहनावा दृष्टिकोण की नवीनता यह है कि यह गैर-रेखीय और गैर-स्थिर डेटा को संभाल कर

सकते हैं जो पारंपरिक काल श्रृंखला विधियों के लिए अनुपयुक्त था। सबसे पहले, प्रस्तावित ई एम डी-एस वी आर मॉडल ने मूल गैर-रेखीय और गैर-स्थिर डेटा श्रृंखला को आई एम एफ और अवशेषों में विघटित कर दिया। प्रत्येक विघटित घटक (आई एम एफ और अवशेष) अलग-अलग आवृत्तियों और आयाम का वर्णन करता है।

फिर प्रत्येक व्यक्तिगत घटक (आई एम एफ और अवशेष) ϵ -एस वी आर मॉडलिंग द्वारा पूर्वानुमान लगाया गया है। आखिरकार, ई एम डी-एस वी आर का अनुमानित पूर्वानुमानित मूल्य आईएमएफ और अवशेष के सभी व्यक्तिगत पूर्वानुमानित मूल्यों को संक्षेप में करके प्राप्त किया गया। प्रस्तावित डब्लु पी डी-एस वी आर की प्रभावशीलता और पूर्वानुमान क्षमता को मिर्च डब्लु पी आई डेटासेट का उपयोग करके सत्यापित किया गया। इस प्रकार, यह निष्कर्ष निकाला जा सकता है कि प्रस्तावित ईएमडीएसवीआर मॉडल कृषि मूल्य पूर्वानुमान के लिए एक प्रभावी उपकरण हो सकता है।

REFERENCES

- An, X., Jiang, D., Zhao, M. and Liu, C. (2012). Short time prediction of wind power using EMD and chaotic theory. *Communication in Nonlinear Science and Numerical Simulation*. 17(2): 1036-1042.
- Anjaly, K.N., Surendran, S., Babu, S.K. and Thomas, J.K. (2010). Impact Assessment of Price Forecast: A Study of Cardamom Price Forecast by AMIC, KAU. NAIP on Establishing and Networking of Agricultural Market Intelligence Centres in India. College of Horticulture, Vellanikkara. 31.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroscedasticity. *Journal of Econometrics*. 31: 307-327.
- Brandl, B., Wildburger, U. and Pickl, S. (2009). Increasing of the fitness of fundamental exchange rate forecast models. *International Journal of Contemporary Mathematical Sciences*. 4(16): 779-798.
- Brock, W.A., Scheinkman, J.A., Dechert, W.D. and LeBaron, B. (1996). A test for independence based on the correlation dimension. *Econometric Reviews*. 15: 197-235.
- Chen, C.F., Lai, M. and Yeh, C.C. (2012). Forecasting tourism demand based on empirical mode decomposition. *Knowledge-Based Systems*. 26: 281-287.
- Chen, S.Y. (2007). Forecasting exchange rates: A new nonparametric support vector regression. *The Journal of Quantitative and Technical Economics*. 5: 142-150.
- Das, P., Jha, G.K., Lama, A., Parsad, R. and Mishra, D. (2020). Empirical Mode Decomposition based Support Vector Regression for Agricultural Price Forecasting. *Indian Journal of Extension Education*. 56 (2): 7-12. (<http://krishi.icar.gov.in/jspui/handle/123456789/44138>).
- Das, P., Lama, A. and Jha, G.K. (2021). R Package EMDSV Rhybrid. (<http://krishi.icar.gov.in/jspui/handle/123456789/44898>).
- Duan, W.Q. and Stanley, H.E. (2011). Cross-correlation and predictability of financial return series. *Physica A*. 390(2): 290-296.
- Engle, R.F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of U.K. inflation. *Econometrica*. 50: 987-1008.
- Guo, Z., Zhao, W., Lu, H. and Wang, J. (2012). Multi-step forecasting for wind speed using a modified EMD-based artificial neural network model. *Renewable Energy*. 37(1): 241-249.
- Huang, N.E., Shen, Z., Long, S.R., Wu, M.L., Shih, H.H., Zheng, Q., Yen, N.C., Tung, C.C. and Liu, H.H. (1998). The empirical mode decomposition and Hilbert spectrum for nonlinear and nonstationary time series analysis. *Proceeding of the Royal Society London A*. 454: 909-995.
- Ince, H. and Trafalis, T. (2006). A hybrid model for exchange rate prediction. *Decision Support Systems*. 42(2): 1054-1062.
- Lama, A., Jha, G., Gurung, B., Paul, R.K., Bharadwaj, A. and Parsad, R. (2016). A comparative study on time-delay neural network and GARCH models for forecasting agricultural commodity price volatility. *Journal of the Indian Society of Agricultural Statistics*. 70(1): 7-18.
- Lu, C.J., Lee, T.S. and Chiu, C.C. (2009). Financial time series forecasting using independent component analysis and support vector machine. *Decision Support Systems*. 47(2): 115-125.
- Sugiyama, M. and Kawanabe, M. (2012). *Machine Learning in Non-Stationary Environments-Introduction to Covariate Shift Adaptation*. The MIT Press, Cambridge, Massachusetts, London, England. 2nd ed.
- Suykens, J.A.K. and Vandewalle, J. (1999). Least squares support vector machine classifier. *Neural Processing Letters*. 9(3): 293-300.
- Vladimir, N. Vapnik. (1998). *Statistical Learning Theory*. Wiley-Interscience. 1st ed.
- Zhang, G.P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. 50: 159-175.