RESEARCH ARTICLE Bhartiya Krishi Anusandhan Patrika, Volume 38 Issue 3: 218-222 (September 2023)

कृषि मूल्य पूर्वानुमान हेतु लॉन्ग शॉर्ट–टर्म मेमोरी (एल.एस.टी.एम.) आधारित न्यूरल नेटवर्क का उपयोग

रौनित जायसवाल[1,2], गिरीश कुमार झा[1], कपिल चौधरी[1], राजीव रंजन कुमार[3]

सारांश

पृष्ठभूमिः कृषि मूल्य पूर्वानुमान अपनी अनूठी विशेषताओं के कारण समय श्रृंखला विश्लेषण के सबसे कठिन क्षेत्रों में से एक है। इस अध्यन में, एक गैर–स्थिर और गैर–रेखीय कृषि मूल्य श्रृंखला की सटीक पूर्वानुमान के लिए लॉन्ग शॉर्ट–टर्म मेमोरी (एल.एस.टी.एम.) मॉडल का उपयोग किया गया है।

विधियाँः एक एल.एस.टी.एम. मॉडल अपने आवर्तक तंत्रिका वास्तुकला और छिपे हुए नोड्स में उपयोग किए जाने वाले मेमोरी फंक्शन के कारण एक जटिल समय श्रृंखला के अल्पकालिक और दीर्घकालिक दोनों अस्थायी पैटर्न का प्रभावी ढंग से विश्लेषण और अधिकृत करता है।

परिणामः मक्के की अंतरराष्ट्रीय मासिक मूल्य श्रृंखला का उपयोग करते हुए विभिन्न पूर्वानुमान मूल्यांकन मानदंडों के परिणाम अनुसार, अन्य मॉडलों कि तुलना में विकसित एल.एस.टी.एम. मॉडल के परिणाम श्रेष्ठता को स्पष्ट रूप से प्रदर्शित करते हैं। अतः एल.एस.टी.एम. मॉडल किसानों, व्यापारियों और नीति निर्माताओं को कृषि मूल्य पूर्वानुमान के क्षेत्र में लाभान्वित करने के लिए काफी संभावनाएं दिखाता है।

शब्द कुंजीः लॉन्ग शॉर्ट–टर्म मेमोरी, टाइम डिले न्यूरल नेटवर्क, मूल्य पूर्वानुमान।

Agricultural Commodity Price Prediction using Long Short-Term Memory (LSTM) based Neural Networks

Ronit Jaiswal[1,2], Girish K. Jha[1], Kapil Choudhary[1], Rajeev Ranjan Kumar[3]

10.18805/BKAP613

ABSTRACT

Background: Agricultural price forecasting is one of the research hotspots in time series forecasting due to its unique characteristics. In this paper, we develop a standard long short-term memory (LSTM) for accurately predicting a nonstationary and nonlinear agricultural price series.

Methods: An LSTM model effectively analyses and captures short-term and long-term temporal patterns of a complex time series due to its recurrent neural architecture and the memory function used in the hidden nodes.

Result: The empirical results using the international monthly price series of maize demonstrate the superiority of the developed LSTM model over other models in terms of various forecasting evaluation criteria. Overall, LSTM model shows great potential for improving the accuracy and reliability of agricultural price predictions, benefiting farmers, traders and policymakers in making informed decisions.

Key words: Long short-term memory, Price forecasting, Time-delay neural networks.

प्रस्तावना

कृषि वस्तुओं का समय पर और सटीक मूल्य पूर्वानुमान किसानों, उपभोक्ताओं और नीति नियोजकों के लिए महत्वपूर्ण और उपयोगी जानकारी प्रदान कर सकता है। कृषि वस्तुओं के उत्पादन की मौसमी प्रभाव, उनकी मांग की व्युत्पन्न प्रकृति, जलवायु परिवर्तनशीलता, बाजार की खामियों, वैश्वीकरण, सट्टा व्यापार, आदि के कारण, कृषि वस्तुओं की कीमतों में गैर–स्थिरता और गैर–रैखिकत जैसी जटिल विशेषताएं हैं, जो समय श्रृंखला पूर्वानुमान के लिए एक बड़ी चुनौती है (बनर्जी और अन्य, 2021; चौधरी और अन्य, 2019)। कुमार और अन्य (2019)

[1]ICAR-Indian Agricultural Research Institute, New Delhi-110 012, India.
[2]ICAR-Central Institute of Temperate Horticulture, Srinagar-191 132, Jammu and Kashmir, India.
[3]ICAR-Indian Agricultural Statistics Research Institute, New Delhi-110 012, India.

Corresponding Author: Girish K. Jha, ICAR-Indian Agricultural Research Institute, New Delhi-110 012, India. Email: girish.stat@gmail.com

How to cite this article: Jaiswal, R., Jha, G.K., Choudhary, K. and Kumar, R.R. (2023). Agricultural Commodity Price Prediction using Long Short-Term Memory (LSTM) based Neural Networks.Bhartiya Krishi Anusandhan Patrika. 38(3): 218-222. doi: 10.18805/BKAP613.

Submitted: 24-11-2022 **Accepted:** 28-08-2023 **Online:** 14-10-2023

ने पाया कि पिछले कई दशकों में, शोधकर्ताओं ने प्रभावी और कुशल समय श्रृंखला पूर्वानुमान मॉडल के डिजाइन और विकास में गहरी रुचि ली है।

मूल्य पूर्वानुमान के लिए विकसित विभिन्न समय श्रृंखला दृष्टिकोणों को मोटे तौर पर दो श्रेणियों में विभाजित किया जा सकता है, अर्थात् सांख्यिकीय मॉडल और आर्टिफिशियल इंटेलिजेंस मॉडल। आर्टिफिशियल इंटेलिजेंस (ए.आई.) मॉडल या मशीन लर्निंग (एम.एल.) मॉडल अपने लचीले परिचालन डिजाइन और शक्तिशाली स्व–शिक्षण क्षमताओं के साथ हाल ही में समय श्रृंखला पूर्वानुमान के लिए एक आशाजनक विकल्प बन गए हैं। कृत्रिम तंत्रिका नेटवर्क (ए.एन.एन.), एम.एल. के महत्वपूर्ण क्षेत्रों में से एक, डेटा संचालित हैं जो पारंपरिक मॉडल आधारित विधियों के विपरीत स्व–अनुकूली दृष्टिकोण का पालन करते हैं। वे मॉडलिंग के लिए शक्तिशाली उपकरण हैं, खासकर जब अंतर्निहित डेटा उत्पन्न करने की प्रक्रिया ज्ञात नहीं है। फीड–फॉरवर्ड प्रकार के तंत्रिका नेटवर्क, नेटवर्क की इनपुट परत के सिनैप्टिक स्तर पर समय की देरी के उपयोग के माध्यम से किसी भी समय श्रृंखला के अस्थायी पैटर्न को पकड़ लेते हैं (झा और अन्य, 2013)। ये फीड–फॉरवर्ड नेटवर्क प्रत्येक उदाहरण (डेटा बिंदुओं का नमूना) के प्रसंस्करण के बाद अपना वजन अद्यतन करते हैं और इस प्रकार नेटवर्क की कोई भी स्थिति संग्रहीत नहीं होती है। इस समय की देरी अल्पकालिक निर्भरता के लिए पर्याप्त हो सकती है लेकिन निश्चित रूप से वांछनीय नहीं है जब हम किसी भी समय श्रृंखला से निपटते हैं जिसमें इसके डेटा बिंदुओं के बीच दीर्घकालिक निर्भरता की संपत्ति होती है। दूसरी ओर, आवर्तक तंत्रिका नेटवर्क (RNN), इनपुट से आउटपुट तक मैपिंग फंक्शन सीखते समय टिप्पणियों के बीच क्रम की स्पष्ट हैंडलिंग को जोड़ते हैं। आर.एन.एन. वास्तव में किसी विशेष समय में किसी भी इनपुट अनुक्रम के एकल तत्वों को संसाधित करते हैं, और उनकी छिपी हुई इकाइयों में एक 'स्टेट वेक्टर' बनाए रखते हैं। फिर भी, जब डेटा निर्भरता का अंतराल बढ़ता है, तो मानक आर.एन.एन.या तो लुप्त हो रहे ग्रेडिएंट या एक्सप्लोडिंग ग्रेडिएंट की समस्या से ग्रस्त हो जाते हैं। इसलिए, मानक आर.एन.एन. दीर्घकालिक निर्भरता के साथ समस्याओं की भविष्यवाणी करने में सबसे अच्छा विकल्प नहीं हो सकता है (बेंजीओ और अन्य 1994)। इस स्थिति के लिए, लंबी अवधि की निर्भरता (एल.एस.टी.एम.) आधारित आर.एन.एन. को दीर्घकालिक निर्भरता से निपटने के दौरान लुप्त हो रही ढाल की समस्या को दूर करने के लिए डिजाइन किया गया है (लेकन और अन्य, 2015)।

यह अध्ययन कृषि मूल्य श्रृंखला के सटीक पूर्वानुमान के साथ–साथ इसके परिवर्तन की दिशा में योगदान करने के उद्देश्य से संबंधित है। चूंकि फीड–फॉरवर्ड एएनएन कृषि मूल्य श्रृंखला के उच्च गैर–रैखिकता, लंबे अंतराल और विषम गुणों को सटीक रूप से मॉडल करने में असमर्थ हैं, इसलिए यह अध्ययन एल.एस.टी.एम. सेल के लाभों का लाभ उठाकर आवर्तक तंत्रिका नेटवर्क पर आधारित मूल्य पूर्वानुमान मॉडल का प्रस्ताव करता है। अधिक सटीक रूप से, विकसित मॉडल कृषि मूल्य श्रृंखला की अल्पकालिक और दीर्घकालिक निर्भरता दोनों की पहचान करके उपयोगी जानकारी निकालने और आंतरिक प्रतिनिधित्व सीखने में एलएसटीएम के मेमोरी सेल की आदत का उपयोग करके कृषि मूल्य की भविष्यवाणी करता है। इसके अलावा, विकसित मॉडल में अगले महीने की दिशा की भविष्यवाणी करने की क्षमता है। यह ध्यान दिया जाना चाहिए कि टर्निंग पॉइंट से संबंधित व्यापार चक्र के चरणों को समझने के लिए पूर्वानुमान की ऐसी दिशा अर्थशास्त्र में विशेष रूप से मूल्यवान है। विकसित मॉडल का और मूल्यांकन किया है और इसकी तुलना ए.आर.आई.एम.ए. और टी.डी.एन.एन. मॉडल से की है।

सामग्री एवं परीक्षण विधि

जायसवाल और अन्य, (2021) के अनुरूप वैनिशिंग ग्रेडिएंट की समस्या के लिए, एल.एस.टी.एम. एक प्रभावी समाधान है जो अल्पकालिक और दीर्घकालिक निर्भरता दोनों को सीखने में सक्षम है। एल.एस.टी.एम. की संरचनात्मक संरचना इसे बिना किसी कठिनाई के लंबी अवधि के लिए जानकारी को याद रखने में सक्षम बनाती है। एक मानक आर.एन.एन के छिपे हुए नोड्स में एक बहुत ही सरल संरचना होती है, जैसे सिग्मॉइड या सिंगल टैन परत। इसके विपरीत, एल.एस.टी.एम. में एक अद्वितीय जटिल संरचनात्मक संरचना होती है जिसमें चार द्वार होते हैं और एक कोशिका अवस्था एक विशेष तरीके से परस्पर क्रिया करती है।

सेल स्टेट (C_t) एल.एस.टी.एम. की कुंजी है जो कुछ छोटी बातचीत के साथ पूरी दोहराई जाने वाली श्रृंखला के समानांतर चलती है। सेल की स्थिति में जानकारी को हटाने या जोड़ने के लिए गेट्स का उपयोग किया जाता है। ये द्वार सिग्मॉइड सक्रियण फंक्शन से बने होते हैं क्योंकि यह शून्य और एक के बीच के मान उत्पन्न करता है और इस प्रकार द्वार के भीतर सूचना के प्रवाह को नियंत्रित करता है। एक एल.एस.टी.एम. में तीन गेट होते हैं, जैसे फोरेगेट गेट (f_t), इनपुट गेट (i_t) और आउटपुट गेट (o_t)। सिग्मॉइड सक्रियण

फंक्शन के अलावा, एक अन्य सक्रियण फंक्शन (आमतौर पर tanh) का उपयोग एलएसटीएम सेल में भी किया जाता है ताकि वैनिशिंग ग्रेडिएंट की समस्या को दूर किया जा सके, जो कि लंबे समय तक दूसरे व्युत्पन्न को बनाए रख सकता है। एल.एस.टी.एम. के माध्यम से सूचना को संसाधित करने में पहला कदम सेल की स्थिति से अप्रासंगिक जानकारी को दूर करना है। यह पहले गेट द्वारा किया जाता है जिसमें सिग्मॉइड फंक्शन होता है।

$$f_t = \sigma (W_f.[h_{t-1},y_t]+b_f)$$

अगला चरण सेल स्थिति में नई या प्रासंगिक जानकारी संग्रहीत करना है। यह एक अन्य गेट द्वारा किया जाता है जिसमें सिग्मॉइड फंक्शन होता है जिसे ''इनपुट गेट'' कहा जाता है और एक tanh परत होती है।

$$i_t = \sigma (W_i.[h_{t-1},y_t]+b_i)$$

$$C_t = \tanh (W_c.[h_{t-1},y_t]+b_c)$$

अंत में, आउटपुट एक सिग्मॉइड परत और tanh परत का उपयोग करके अद्यतन सेल स्थिति पर आधारित होता है जो एक साथ केवल उन हिस्सों को आउटपुट करता है।

$$C_t = f_t \times C_{t-1} + i_t \times C_t$$

$$o_t = \sigma(W_o.[h_{t-1},y_t]+b_o)$$

$$h_t = o_t \times \tanh (C_t)$$

जहाँ W भार आव्यूह का प्रतिनिधित्व करता है, b एक पूर्वाग्रह पद है, σ (.) एक सिग्मॉइड फलन है, और tanh (.) एक अतिपरवलयिक स्पर्श रेखा फलन है। चित्र 1 एक एल. एस.टी.एम. सेल में इन समीकरणों का उपयोग करके सूचना के प्रवाह को दर्शाता है।

परिणाम एवं विवेचना

वर्तमान अध्ययन के लिए, जनवरी 1980 से जुलाई 2020 की अवधि विश्व बैंक कमोडिटी मूल्य डेटा (पिंक शीट) से एकत्र किए गए मक्का की मासिक कीमत ($/एम.टी.) का प्रयोग किया गया है। मूल मूल्य श्रृंखला को दो सेटों में विभाजित किया गया है, अर्थात् प्रशिक्षण सेट (जनवरी 1980 से जुलाई 2019) एवं परीक्षण सेट (अगस्त 2019 से जुलाई 2020)। चित्र 2 में समय श्रृंखला का प्लॉट दिया गया है। इस अध्ययन में प्रयुक्त मूल्य श्रृंखला के मूल वर्णनात्मक आंकड़े तालिका 1 में प्रस्तुत किए गए हैं।

इस अध्ययन में, कृषि मूल्य श्रृंखला का पूर्वानुमान लगाने के लिए एक मानक एल.एस.टी.एम. मॉडल विकसित किया गया है। मॉडलिंग प्रक्रिया डेटा सामान्यीकरण के साथ शुरू होती है और उन्हें पर्यवेक्षित शिक्षण प्रारूप में बदल देती है। फिर विभिन्न हाइपरपैरामीटर को बदलने के आधार पर एल. एस.टी.एम. मॉडल के विभिन्न विन्यासों को प्रशिक्षण सेट पर फिट और प्रशिक्षित किया जाता है। छिपे हुए नोड्स की संख्या और इनपुट की संख्या को बदलने से पूर्वानुमान सटीकता पर पर्याप्त प्रभाव पड़ता है जबकि अन्य हाइपरपैरामीटर जैसे युगों की संख्या, बैच आकार और सक्रियण फंक्शन के प्रकार का बहुत कम प्रभाव पड़ता है। युगों की संख्या और बैच का आकार 100 पर सेट है, और ReLU का उपयोग हिडन और आउटपुट लेयर दोनों में सक्रियण कार्यों के रूप में किया जाता है। प्रारंभिक रोक विधि का उपयोग सही समय पर प्रशिक्षण को रोककर ओवरफिटिंग से बचा जाता है और सही संख्या में युग प्राप्त करने में मदद करता है। लॉस फंक्शन का अनुकूलन स्टोकेस्टिक ग्रेडिएंट डिसेंट मेथड के एक प्रमुख संस्करण द्वारा किया जाता है जिसे एडम (एडेप्टिव मोमेंट एस्टीमेशन) ऑप्टिमाइजर कहा जाता है। किसी भी ऑप्टिमाइजेशन एल्गोरिथम की सीखने की दर उसके सुगम अभिसरण के लिए बहुत महत्वपूर्ण है लेकिन इसके मूल्य को चुनना समस्याग्रस्त है क्योंकि उच्च मूल्य से एल्गोरिथम विचलन हो सकता है और कम मूल्य धीमी अभिसरण बनाता है। इस प्रकार, ऐसे अनुकूलक

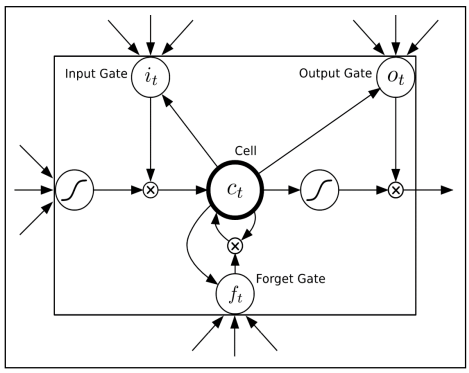

चित्र 1: एल.एस.टी.एम. सेल।

तालिका 1: मूल्य ($/एम.टी.) श्रृंखला के वर्णनात्मक आंकड़े।

सांख्यिकी	वैल्यू
न्यूनतम	65.31
औसत	139.59
अधिकतम	333.05
मानक विचलन	54.85
तिरछापन	1.57
कुकुदता	5.26
जार्क–बेरा	304.63

को चुनना हमेशा बेहतर होता है जिसकी सीखने की दर पिछले परिणामों के आधार पर खुद को अनुकूलित कर सकती है और प्रशिक्षण में सुधार कर सकती है। अतः हम विभिन्न हाइपरपैरामीटर को स्थाई करने के लिए एडम ऑप्टिमाइजर का प्रयोग करते है। यदि i इनपुट नोड्स की संख्या है और h छिपे हुए नोड्स की संख्या है, तो प्रशिक्षित मापदंडों की संख्या 4×[h(h+i)+h] है। हाइपरपैरामीटर के कई अलग–अलग विन्यास ग्रिड खोज पद्धति और उनकी ट्यूनिंग का उपयोग करके फिट किए जाते हैं। दोनों मूल्य श्रृंखला के लिए, कुल 81 एल.एस.टी.एम. मॉडल छिपे हुए नोड्स (एल.एस.टी.एम. कोशिकाओं) की संख्या और अंतराल की संख्या के सभी संभावित संयोजनों से निर्मित होते हैं, दोनों 2 से 10 तक होते हैं। प्रत्येक कॉन्फिगरेशन को तब 50 बार दोहराया जाता है, और अधिक वैध और मजबूत परिणामों के लिए, परिणामों का औसत लिया जाता है। 81 एल.एस.टी.एम. मॉडलों में से, 4 इनपुट नोड्स और 2 हिडन नोड्स वाला मॉडल मक्का मूल्य श्रृंखला के प्रशिक्षण और परीक्षण सेट दोनों पर प्राप्त पूर्वानुमान मूल्यांकन मानदंडों के संदर्भ में अन्य प्रतिस्पर्धी मॉडल की तुलना में बेहतर प्रदर्शन करता है।

इस अध्यन में, हमारा ध्यान अल्पकालिक पूर्वानुमान पर है, और इसलिए, हमने बारह महीनो तक के पूर्वानुमान क्षितिज पर विचार किए हैं। क्लेमेंट्स और अन्य (1977) ने ईएमडी आधारित ए.एन.एन. की पूर्वानुमान क्षमता की तुलना आर.एम.एस.ई., एम.ए.पी.ई. (औसत निरपेक्ष प्रतिशत त्रुटि), एम.ए.डी. (माध्य निरपेक्ष विचलन) और D_{stat} के संदर्भ में ए.एन.एन. और ए.आर.आई.एम.ए. से की है। तालिका 2, स्पष्ट रूप से प्रदर्शित करती है कि एल.एस.टी.एम. की पूर्वानुमान सटीकता ए.एन.एन. और ए.आर.आई.एम.ए. मॉडल की तुलना में बेहतर है।

इस अध्यनन में यह देखा जा सकता है कि पूर्वानुमानित श्रृंखला के मूल्य एल.एस.टी.एम. का उपयोग करके प्राप्त किए जाने पर वास्तविक मूल्य श्रृंखला के मूल्यों के अधिक करीब हैं। एल.एस.टी.एम. की यह श्रेष्ठता पहले से ही विभिन्न पूर्वानुमान मूल्यांकन मानदंडों के परिणामों द्वारा पुष्टि की गई है जैसा कि तालिका 2 में दिखाया गया है। तालिकाओं में यह देखा गया है कि तीन मूल्यांकन मानदंड आर.एम.एस.ई., एम.ए.पी.ई. और एम.ए.डी. लगातार ए.आर.आई.एम.ए. मॉडल से एल.एस.टी.एम. मॉडल तक घट रहे हैं। विशेष रूप से मक्का श्रृंखला के लिए, एलएसटीएम का उपयोग करके गणना किए गए मूल्यांकन मानदंड ने अनुकूलित आर.एम.एस.ई. मॉडल से लगभग 72% और अनुकूलित टी.डी.एन.एन. मॉडल से 47% की कमी दिखाई है। आंकड़ा स्पष्ट रूप से इंगित करता है कि एल.एस.टी.एम. मॉडल का प्रत्येक मूल्यांकन मानदंड के लिए

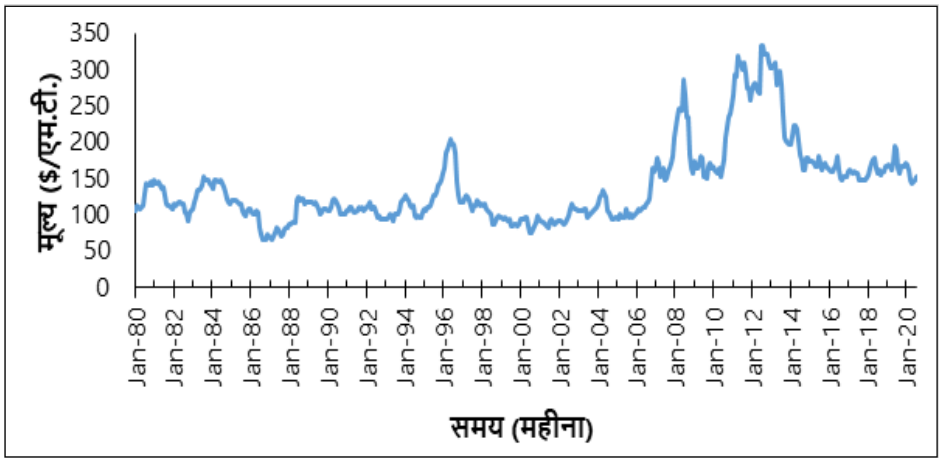

चित्र 2: अंतरास्ट्रीय बाजार की मासिक मक्का मूल्य श्रृंखला का टाइम प्लॉट।

तालिका 2: अंतरास्ट्रीय बाजार के मासिक मक्का मूल्य के लिए प्रत्येक पूर्वानुमान मॉडल की तुलना।

मॉडल	आर.एम.एस.ई	एम.ए.पी.ई.	एम.ए.डी.	D_{stat} (%)	हाइपरपारामीटर
ए.आर.आई.एम.ए.	0.110	31.194	0.105	45	p=1, d=1 and q=0
टी.डी.एन.एन.	0.058	14.027	0.046	54	Lags=5, Hidden nodes=6
एल.एस.टी.एम.	0.031	7.337	0.026	63	Lags=4, Hidden nodes=2

तालिका 3: डी.एम. टेस्ट परिणाम।

टेस्टेड मॉडल	बेंचमार्क मॉडल	
	ए.आर.आई.एम.ए.	टी.डी.एन.एन.
टी.डी.एन.एन.	4.87 (0.0002)	
एल.एस.टी.एम.	4.47 (0.0004)	2.00 (0.03)

सबसे कम मूल्य है। एल.एस.टी.एम. न केवल वास्तविक कीमतों के संदर्भ में बल्कि परिवर्तनों की दिशा के संदर्भ में भी बेहतर प्रदर्शन करता है। तालिका 2 में दिए गए D_{stat} परिणामों ने सत्यापित किया कि एल.एस.टी.एम. परिवर्तन की दिशा को दूसरों की तुलना में बेहतर तरीके से पकड़ लेता है। अन्य मॉडलों पर एलएसटीएम की भविष्य कहने वाला सटीकता की श्रेष्ठता (DM) परीक्षण द्वारा निर्धारित की जाती है। तालिका 3 में दिखाए गए डी.एम. परीक्षण के परिणाम यह साबित करते हैं कि एल.एस.टी.एम. में श्रृंखला के लिए अन्य बेंचमार्क मॉडल की तुलना में पूर्वानुमानों में महत्वपूर्ण सटीकता है।

निष्कर्ष

इस अध्ययन में मक्का की मासिक अंतरराष्ट्रीय मूल्य श्रृंखला का उपयोग करके मॉडलिंग और पूर्वानुमान दोनों के संदर्भ में ए.आर.आई.एम.ए. और टी.डी.एन.एन. मॉडल के साथ एल.एस.टी.एम. मॉडल के प्रदर्शन की जांच करता है। यह देखा गया है कि एल.एस.टी.एम. मॉडल गैर–रैखिक संबंधों के लिए ए.आर.आई.एम.ए. और टी.डी.एन.एन. मॉडल की तुलना में विभिन्न मूल्यांकन मानदंडों के संदर्भ में बेहतर पूर्वानुमान सटीकता प्रदान करता है। डी.एम. परीक्षण ने अन्य दो मॉडलों की तुलना में एल.एस.टी.एम. की सटीकता में भी महत्वपूर्ण सुधार दिखाया। आवर्तक तंत्रिका नेटवर्क की वास्तुकला और छिपे हुए नोड्स में उपयोग किए जाने वाले द्वार मिलकर एल.एस.टी.एम. को किसी भी जटिल समय श्रृंखला का विश्लेषण करने में बेहतर प्रदर्शन करने में मदद करते हैं। कुल मिलाकर, हम कह सकते हैं कि प्रस्तावित मॉडल कृषि मूल्य पूर्वानुमान के क्षेत्र में प्रत्येक कृषि हितधारक के लिए एक सारथी का काम कर सकता है।

संदर्भ

Banerjee, R., Das, P., Ahmad, T. and Kumar, M. (2021). Modeling and forecasting of agricultural commodity production under changing climatic condition: A review. Bhartiya Krishi Anusandhan Patrika. 36(4): 273-279.

Bengio, Y., Simard, P. and Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. IEEE Transactions on Neural Networks. 5(2): 157-166.

Box, G.E.P. and Jenkins, G.M. (1970). Time Series Analysis: Forecasting and Control. Holden-Day, San Francisco, CA.

Clements, M.P. and Smith, J. (1997). The performance of alternative forecasting methods for SETAR models. International Journal of Forecasting. 13(4): 463-475.

Choudhary, K., Jha, G.K. and Kumar, R.R. (2019). Delhi potato price analysis using ensemble empirical mode decomposition. Bharatiya Krishi Anusandhan Patrika. 34(1): 33-37.

Jaiswal, R., Jha, G.K., Kumar, R.R. and Choudhary, K. (2021). Deep long short-term memory based model for agricultural price forecasting. Neural Computing and Applications. 34(6): 4661-4676.

Jha, Girish, K. and Sinha, K. (2013). Agricultural price forecasting using neural network model: An innovative information delivery system. Agricultural Economics Research Review. 26(2): 229-239.

Kumar, R.R., Jha, G.K., Choudhary, K. and Budhlakoti, N. (2019). Examining integration between Agra and Delhi potato markets. Bhartiya Krishi Anusandhan Patrika. 34(1): 62-64.

LeCun, Y., Bengio, Y. and Hinton, G. (2015). Deep learning. Nature. 521(7553): 436-444.