

आर्थिक संकेतक के रूप में भुगतान प्रवाह: हाइब्रिड मशीन लर्निंग फ्रेमवर्क का उपयोग करके तात्कालिक अनुमान*

अमित कुमार[^], शिवम निगम #
और संध्या कुरुगंती[^] द्वारा

यह अध्ययन भारत के लिए उच्च आवृत्ति भुगतान प्रणाली डेटा का उपयोग करके सकल मूल्य वर्धित (जीवीए) में वृद्धि का तात्कालिक अनुमान लगाने का प्रयास करता है। इस अध्ययन में सपोर्ट वेक्टर मशीन (एसवीएम) के साथ मिश्रित डेटा सैंपलिंग रिग्रेशन मॉडल (एमआईडीएस) का उपयोग करके एक हाइब्रिड मशीन लर्निंग दृष्टिकोण अपनाया गया है। प्रत्येक भुगतान संकेतक के लिए मात्रा और मूल्य चैनल दोनों का पता लगाया जाता है। एमआईडीएस-एसवीएम हाइब्रिड मॉडल से तात्कालिक अनुमान क्रमशः दो भार तकनीकों अर्थात् ई-डब्ल्यू (समान भार) और आरएमएसएफई (रूट मीन स्क्वायर पूर्वानुमान त्रुटि) का उपयोग करके प्राप्त किए जाते हैं। अनुभवजन्य परिणाम हाइब्रिड दृष्टिकोण और आरएमएसएफई भार रणनीति का प्रयोग करके लगाए गए तात्कालिक अनुमान के लिए पूर्वानुमानित सटीकता में पर्याप्त वृद्धि को प्रदर्शित करते हैं।

भूमिका

भुगतान प्रक्रिया वित्तीय मध्यस्थता का एक महत्वपूर्ण पहलू है। यह विभिन्न आर्थिक एजेंटों के बीच चलनिधि के निर्माण और हस्तांतरण को सक्षम बनाता है। एक अच्छी तरह से संरचित भुगतान ढांचा वस्तुओं और सेवाओं में व्यापार के लिए बाधाओं को समाप्त करने की सुविधा प्रदान करता है, लेनदेन लागत को कम करता है, ग्राहक विश्वास को बढ़ाता है और इस प्रकार वित्तीय बाजार की क्षमता को बढ़ाता है (बीआईएस, 2003; ईसीबी, 2010)। आर्थिक विकास की गति भुगतान और निपटान प्रणाली के कुशल कामकाज से बनती है, जो अर्थव्यवस्था में चलनिधि

प्रवाह को गति देती है (आरबीआई सामयिक प्रकाशन, 1998)। वास्तव में, कई शोधकर्ताओं ने अनुभवजन्य रूप से भुगतान प्रणालियों और वास्तविक आर्थिक गतिविधि के बीच प्रत्यक्ष या अप्रत्यक्ष संबंध दिखाया है। हमफ्रे एवं अन्य (2006) और हसन एवं अन्य (2012) खुदरा इलेक्ट्रॉनिक भुगतान उपकरणों के व्यापक उपयोग के साथ बैंकिंग दक्षता में उल्लेखनीय वृद्धि पाते हैं। झांग एवं अन्य (2019) द्वारा 27 यूरोपीय संघ के सदस्य देशों में खुदरा भुगतान डेटा का विश्लेषण करके, व्यापार, खपत और अर्थव्यवस्था पर एक अच्छी तरह से डिज़ाइन की गई खुदरा भुगतान प्रणाली के महत्व और प्रभाव का दस्तावेजीकरण किया गया है। इसके अलावा, सुरक्षित और अधिक कुशल भुगतान प्रणाली वास्तविक अर्थव्यवस्था को व्यापक लाभ प्राप्त करने में सक्षम बनाती है (बांकड इटालिया, 1999)।

पिछले कुछ वर्षों में, भारत में तकनीकी-नीति विकास ने कागज आधारित से डिजिटल माध्यमों वाली भुगतान प्रणालियों का मार्ग प्रशस्त किया है। राष्ट्रीय इलेक्ट्रॉनिक निधि अंतरण (एनईएफटी) और वास्तविक समय सकल निपटान (आरटीजीएस) दो व्यवस्थित रूप से महत्वपूर्ण भुगतान और निपटान प्रणालियां हैं, जो रिज़र्व बैंक द्वारा संचालित हैं और इसके स्वामित्व में हैं। तत्काल भुगतान सेवा (आईएमपीएस), एकीकृत भुगतान इंटरफेस (यूपीआई), प्रीपेड भुगतान लिखत (पीपीआई), भारत बिल भुगतान प्रणाली (बीबीपीएस) आदि जैसी अन्य अभिनव भुगतान प्रणालियों की स्थापना भी प्रतिस्पर्धा को बढ़ा रही है और इस प्रकार भारत में बदलते भुगतान परिदृश्य में महत्वपूर्ण योगदान दे रही है। प्रभावशाली विकास प्रदर्शन, विशेष रूप से यूपीआई में, व्यापार और उपभोक्ताओं दोनों द्वारा डिजिटल इलेक्ट्रॉनिक भुगतान उपकरणों की व्यापक स्वीकृति की ओर इशारा करता है (चार्ट 1 ए)। इसके अलावा, कार्ड-आधारित भुगतान लिखतों ने भी पिछले पांच वर्षों में इसी तरह का कार्य प्रदर्शन देखा (चार्ट 1 बी) है। यह महत्वपूर्ण वृद्धि भारत में भुगतान उद्योग की बढ़ती परिपक्वता और देश के कुल आर्थिक आउटपुट पर पड़ने वाले प्रभाव का संकेत देती है।

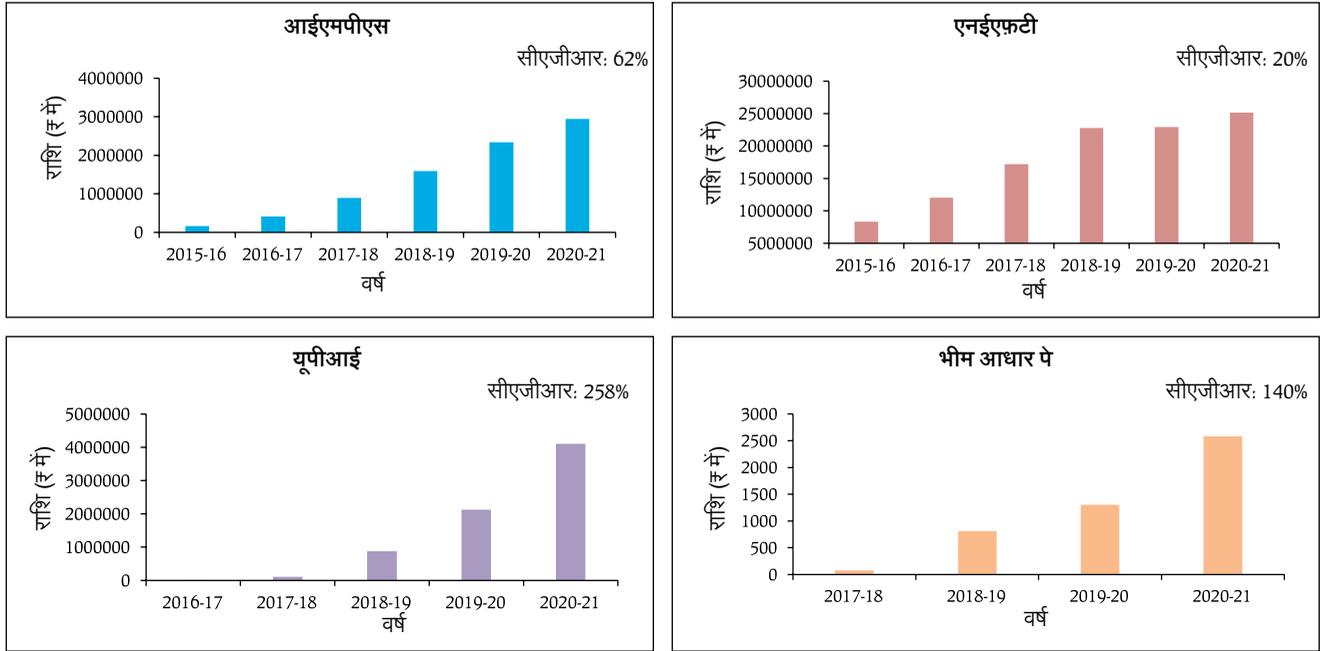
आर्थिक प्रगति का एक महत्वपूर्ण और पारंपरिक मीट्रिक इसके सकल मूल्य वर्धित (जीवीए) में परिलक्षित और मापा जाता है तथा जीवीए वृद्धि का प्रभावी मापन नीति निर्माताओं के लिए महत्वपूर्ण है। हालांकि, भारत सहित कई अर्थव्यवस्थाओं में जीवीए डेटा दो महीने के अंतराल के साथ जारी किया जाता है। इसलिए जीवीए वृद्धि का तात्कालिक अनुमान तिमाही आधार पर

[^] लेखक सांख्यिकी और सूचना प्रबंध विभाग से हैं।

लेखक रिज़र्व बैंक सूचना प्रौद्योगिकी प्रा. लिमिटेड से हैं।

* इस आलेख में व्यक्त किए गए विचार लेखकों के हैं और भारतीय रिज़र्व बैंक के विचारों को नहीं दर्शाते हैं।

चार्ट 1ए: डिजिटल भुगतान संकेतकों में रुझान (मूल्य)

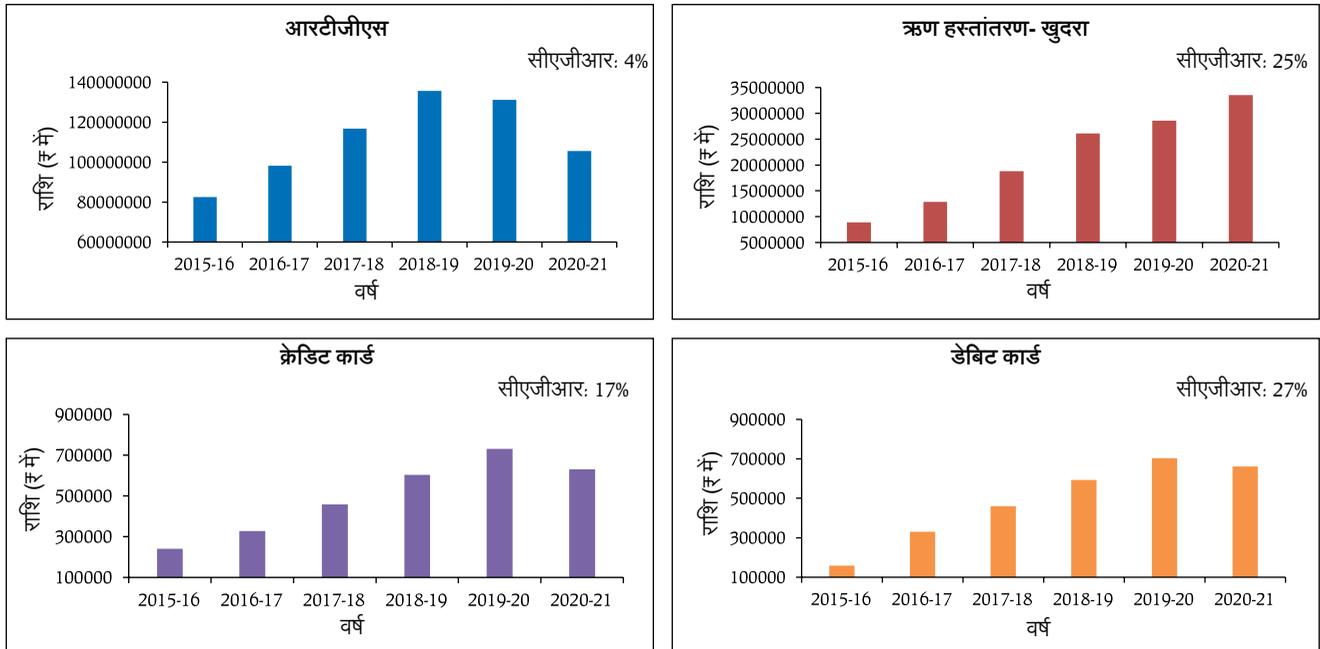


स्रोत: भारतीय अर्थव्यवस्था पर डेटाबेस।

लगाना आवश्यक हो जाता है। यह शोध पत्र उच्च आवृत्ति मासिक भुगतान डेटा का उपयोग करके कम आवृत्ति त्रैमासिक जीवीए

वृद्धि (वर्ष-दर-वर्ष) का तात्कालिक अनुमान लगाने की दिशा में एक प्रयास है।

चार्ट 1बी: चुनिंदा भुगतान संकेतकों में रुझान (मूल्य)



स्रोत: भारतीय अर्थव्यवस्था पर डेटाबेस।

इस अध्ययन के माध्यम से, लेखक अर्थमिति और मशीन लर्निंग के प्रतिमान दोनों के आधार पर एक हाइब्रिड मॉडल बनाने का प्रयास करते हैं। हाइब्रिड फ्रेमवर्क हमें मिश्रित आवृत्ति डेटा मॉडलिंग की संबंधित विशेषताओं और गैर-रैखिक संबंधों के लिए मशीन लर्निंग की बेहतर सामान्यीकरण सटीकता को भुनाने की अनुमति देता है। आलेख में प्रस्तुत किए गए हाइब्रिड फ्रेमवर्क को भारतीय संदर्भ में किए गए नए काम के रूप में माना जा सकता है।

मिश्रित डेटा नमूना प्रतिगमन (एमआईडीएएस) स्वतंत्र और निर्भर चर (ओं) को विभिन्न आवृत्तियों पर नमूना लेने की अनुमति देता है जबकि वितरित अंतराल बहुपद सूक्ष्म विशिष्टताओं के मूल्यांकन के लिए उपयोगी है। इस उद्देश्य के लिए ऑटोरिग्रेसिव डिस्ट्रिब्यूटेड लैंग मिडास (एडीएल-एमआईडीएएस) मॉडल विनिर्देश पर विचार किया जाता है। इसे मासिक भुगतान डेटा के आधार पर त्रैमासिक जीवीए वृद्धि का तात्कालिक अनुमान प्राप्त करने के लिए सपोर्ट वेक्टर मशीन (एसवीएम) विधि के साथ एकीकृत किया जाता है। मशीन लर्निंग एल्गोरिदम के अंतर्गत, एसवीएम एल्गोरिदम छोटे नमूना प्रतिगमन और वर्गीकरण (मेंग और झाओ, 2015) के लिए एक इष्टतम विधि के रूप में एक अनूठी ताकत प्रदर्शित करता है। इसी प्रकार का एक खोज यह है कि एसवीएम एक सीमित नमूना आकार परिदृश्य (शाओ और लुनेटा, 2012) में अधिक सामान्यीकरण सटीकता प्रदर्शित करता है। समष्टि अर्थशास्त्र अनुप्रयोग अनुसंधान में, आम तौर पर छोटे नमूने मॉडलिंग के लिए उपलब्ध होते हैं, और इस प्रकार एसवीएम एक उपयुक्त एल्गोरिथ्म हो सकता है।

इस अध्ययन में, हम बड़े पैमाने पर मूल्य या मात्रा के दृष्टिकोण से भुगतान कारकों का उपयोग करते हैं, जिससे तात्कालिक अनुमान की सटीकता में सुधार के लिए सूचना समूह को विस्तारित किया जा सके। शेष अध्ययन को पांच खंडों में व्यवस्थित किया गया है। खंड II प्रासंगिक साहित्य का एक संक्षिप्त सर्वेक्षण है। खंड III अध्ययन में उपयोग किए गए डेटा को प्रस्तुत करता है। खंड IV हाइब्रिड तात्कालिक अनुमान पद्धति पर चर्चा करता है। खंड V में अनुभवजन्य परिणाम प्रस्तुत किए गए हैं और खंड VI में निष्कर्ष प्रस्तुत किया गया है।

II. साहित्य का सर्वेक्षण

विशिष्ट नीति उन्मुख समष्टि-आर्थिक शृंखला की समय पर उपलब्धता के अभाव में, आर्थिक संकेतकों की निगरानी के लिए उच्च आवृत्ति समय शृंखला डेटा का उपयोग करने की बढ़ती

प्रवृत्ति रही है। उपलब्ध उच्च आवृत्ति डेटा में से, भुगतान और निपटान डेटा को जानकारी के भरोसेमंद स्रोत के रूप में गिना जा सकता है। साहित्य की समीक्षा बहु-गुना परिप्रेक्ष्य से तात्कालिक अनुमान / पूर्वानुमान के लिए वास्तविक समय इलेक्ट्रॉनिक भुगतान प्रणाली डेटा का उपयोग करने की प्रभावकारिता पर प्रकाश डालती है। इन अध्ययनों में शामिल किए गए कुछ प्रश्न हैं - यदि मशीन लर्निंग एल्गोरिदम पारंपरिक तकनीकों की तुलना में अधिक सटीक अनुमान प्रदान करते हैं तो क्या भुगतान प्रणाली डेटा वैकल्पिक उच्च आवृत्ति स्रोतों की तुलना में बेहतर पूर्वानुमान प्रदान करता है और क्या भुगतान डेटा अनिश्चित अशांत अवधि में तात्कालिक अनुमान के लिए विश्वसनीय सिद्ध हो सकता है।

हाल के एक अध्ययन में, डेनमार्क के राष्ट्रीय बैंक के बेंटसेन और गोरिया (2021) डेनमार्क की अर्थव्यवस्था के लिए भुगतान प्रणाली डेटा का उपयोग करके त्रैमासिक समष्टि-आर्थिक चर का तात्कालिक अनुमान लगाने के लिए मिश्रित डेटा नमूनाकरण (एमआईडीएएस) प्रतिगमन का उपयोग किया गया है। लेखकों ने एक तिमाही आगे के लिए जीडीपी के तात्कालिक अनुमान के लिए आर्थिक गतिविधि के अक्सर उपयोग किए जाने वाले भविष्यवाणियों के एक सेट के सापेक्ष भुगतान के बेहतर प्रदर्शन को रेखांकित किया है। हालांकि, कोविड के पहले चरण के दौरान पूर्वानुमान पर अतिरिक्त बढ़त में गिरावट आई है। इसी प्रकार, अपरिगलियानों एवं अन्य ने इटली की खुदरा निपटान प्रणाली का उपयोग करके इटली के जीडीपी और इसके मुख्य घटकों की भविष्यवाणी के लिए मिश्रित आवृत्ति कारक मॉडल का प्रयोग किया है। मशीन लर्निंग तकनीकों का उपयोग करते हुए, बैंक ऑफ कनाडा के चैपमैन और देसाई (2021) वैश्विक वित्तीय और कोविड-19 संकट के दौरान पारंपरिक तरीकों की आर्थिक भविष्यवाणी और अविश्वसनीयता से संबंधित चुनौतियों का समाधान करते हैं। इसके अलावा, वे देखते हैं कि भुगतान डेटा की उपस्थिति में, मशीन लर्निंग मॉडल वैश्विक वित्तीय संकट वाली अवधि के लिए तात्कालिक अनुमान आरएमएसई को लगभग 15-45 प्रतिशत तक कम कर सकते हैं, जबकि मॉडल भविष्यवाणियां कोविड -19 के पहले आघातों के लिए आधिकारिक अनुमानों के करीब हैं। लियोन और ओर्टेगा (2018) इलेक्ट्रॉनिक भुगतान डेटा का उपयोग करके कोलंबिया में एक अल्पकालिक आर्थिक गतिविधि संकेतक का तात्कालिक अनुमान लगाने के लिए एक गैर-रैखिक ऑटोरिग्रेसिव एक्सोजेनस न्यूरल नेटवर्क मॉडल (एनएनएक्स) का उपयोग करते हैं।

भारतीय संदर्भ में, तात्कालिक अनुमान के लिए भुगतान प्रवाह का लाभ उठाने पर शोध प्रकाशन सीमित रहे हैं। एशियाई विकास बैंक के रूज और सेनगुमा (2021) ने इलेक्ट्रॉनिक भुगतान प्रणाली का उपयोग करके निजी खपत का अनुमान लगाया। एमआईडीएस के आधार पर, वे निष्कर्ष निकालते हैं कि डिजिटल भुगतान प्रणाली डेटा ने निजी खपत के पूर्वानुमान में पूर्वानुमान शक्ति में सुधार किया है। राजू और बालाकृष्णन (2019) स्वतः-प्रतिगामी एकीकृत चल औसत (एआरआईएमए) मॉडल का उपयोग करके जीडीपी के तात्कालिक अनुमान के लिए आरटीजीएस डेटा का उपयोग करते हैं।

साहित्य की समीक्षा से पता चलता है कि आर्थिक गतिविधि के विश्वसनीय संकेतों को निकालने के लिए इलेक्ट्रॉनिक भुगतान प्रणाली डेटा का व्यापक रूप से उपयोग किया जाता है। इसमें निष्कर्ष मिश्रित आवृत्ति डेटा के लिए एक अर्थमितीय विनिर्देश, और मशीन लर्निंग एल्गोरिदम की बेहतर सामान्यीकरण शक्ति, हालांकि एकल आधार पर, के सफल कार्यान्वयन से संबंधित हैं। हाइब्रिड मशीन लर्निंग मॉडल दोनों मॉडल प्रकारों की शक्ति को जोड़ते हैं; प्रत्येक विधि विनिर्देश के एक अलग तत्व का दोहन करती है, और उनके संयोजन या एकीकरण से एकल विधि (वांग एवं अन्य, 2021) का उपयोग करने की तुलना में बेहतर परिणाम की उम्मीद है।

लेखकों ने भुगतान प्रवाह के आधार पर आर्थिक विकास के लिए तात्कालिक अनुमान ढांचा विकसित करने के लिए क्रमिक तरीके से मशीन लर्निंग आधारित एसवीएम प्रगतिमान के साथ एमआईडीएस को जोड़कर एक हाइब्रिड मॉडल तैयार किया। इसके अतिरिक्त, मौजूदा साहित्य तात्कालिक अनुमान उद्देश्यों के लिए भुगतान डेटा के केवल मूल्य या मात्रा घटकों के उपयोग को दर्शाता है। लेखक अपने वर्तमान कार्य में भुगतान डेटा के मूल्य और मात्रा दोनों घटकों का प्रयोग करके अधिक व्यापक दृष्टिकोण लेते हैं।

III. डेटा

भारत में, जीवीए पर डेटा दो महीने के अंतराल के साथ त्रैमासिक आधार पर उपलब्ध है, जिसमें भुगतान और निपटान प्रणाली पर डेटा दैनिक आवृत्ति पर उपलब्ध है और सार्वजनिक रूप से उपलब्ध कुछ उच्च आवृत्ति शृंखलाओं में से एक है। भुगतान प्रणाली के आंकड़े रिजर्व बैंक द्वारा दैनिक, मासिक और वार्षिक आवृत्ति पर जारी किए जाते हैं। इन आंकड़ों को भारतीय

अर्थव्यवस्था के आंकड़े (डीबीआईई) प्लेटफॉर्म से डाउनलोड किया गया है। 2001 से 2010 के बीच भुगतान प्रणाली के बुनियादी ढांचे और भुगतान प्रणालियों से संबंधित नीतिगत परिवर्तनों में वृद्धि के कारण, भुगतान प्रणालियों के आंकड़ों में अनेक उदाहरणों में अचानक वृद्धि देखी गई है (राज एवं अन्य 2020)। इसलिए, वर्तमान अध्ययन के लिए मासिक भुगतान प्रणाली डेटा अप्रैल 2011 से मार्च 2022 तक भारत के लिए अन्य शोध अध्ययनों के अनुरूप लिया गया है। जीवीए पर तिमाही आंकड़े सांख्यिकी और कार्यक्रम कार्यान्वयन मंत्रालय (एमओएसपीआई) द्वारा प्रकाशित किए जाते हैं। यही आंकड़े भारतीय रिजर्व बैंक द्वारा डीबीआईई के माध्यम से भी प्रसारित किए जाते हैं। जीवीए के तिमाही आंकड़े अप्रैल 2011 से मार्च 2022 तक लिए गए हैं। प्रशिक्षण (नमूने में) डेटा को अप्रैल 2012 से जून 2020 (33 तिमाहियों) तक साल-दर-साल वृद्धि के रूप में लिया जाता है और परीक्षण (नमूना से बाहर) डेटा जुलाई 2020 से जून 2021 (4 तिमाहियों) तक की है। जीवीए वृद्धि का तात्कालिक अनुमान वित्तीय वर्ष के आधार पर तीन तिमाहियों अर्थात् 2021-22 की दूसरी तिमाही से 2021-22 की चौथी तिमाही के लिए किया गया है। पहली कोविड अवधि (2020-21 की पहली तिमाही) को प्रशिक्षण में शामिल किए जाने की स्थिति में मॉडल की पूर्वानुमान शक्ति को अतिरिक्त बढ़ावा मिलता है। इस अध्ययन के लिए शामिल किए गए स्वतंत्र चर में क्रेडिट कार्ड (सीसी), डेबिट कार्ड (डीसी), खुदरा के माध्यम से क्रेडिट अंतरण (क्रेडिट ट्रांसफर- रिटेल), वास्तविक समय सकल निपटान (क्रेडिट ट्रांसफर-आरटीजीएस) के माध्यम से क्रेडिट अंतरण, पॉइंट-ऑफ-सेल मशीनों पर कार्ड लेनदेन (कार्ड-पीओएस) (परिशिष्ट 1) पर मासिक डेटा शामिल हैं।

IV. हाइब्रिड तात्कालिक अनुमान पद्धति

अध्ययन में एमआईडीएस, एसवीएम प्रतिगमन और त्रुटि सुधार रणनीति (एमआईडीएस-एसवीएम हाइब्रिड मॉडल) को शामिल करते हुए एक चार-चरण हाइब्रिड पद्धति को अपनाया गया है। अंत में, भुगतान संकेतकों (चार्ट 2) का उपयोग करके जीवीए वृद्धि का तात्कालिक अनुमान लगाने के लिए दो चरण रणनीतियों का उपयोग किया जाता है।

IV.1 एमआईडीएस मॉडल

हाल के वर्षों में, घिसेल्स एवं अन्य (2016) द्वारा प्रस्तावित एमआईडीएस मॉडलिंग दृष्टिकोण को विभिन्न डोमेन में बड़े

पैमाने पर प्रयोग में लाया गया है, जिसमें कृषि निर्यात¹ का उपयोग करके जीवीए की वृद्धि का पूर्वानुमान लगाना, राजकोषीय शृंखला² के वार्षिक अलग-अलग सेट की भविष्यवाणी करना और वित्तीय बाजारों³ से संबंधित अनुसंधान शामिल है। साहित्य समीक्षा (खंड II) पर अनुभाग भुगतान संकेतकों का उपयोग करके आर्थिक पूर्वानुमान के लिए एमआईडीएस के कई अनुप्रयोगों को भी प्रस्तुत करता है।

हमारे अध्ययन में, डेटा मिश्रित आवृत्तियों को प्रदर्शित करता है, अर्थात् भुगतान डेटा महीनों में है और जीवीए डेटा तिमाही स्तर पर है। इस प्रकार, हम कार्यात्मक बाधाओं के रूप में वितरित अंतराल बहुपदों को दर्शाने वाली विभिन्न आवृत्तियों पर चर के बीच गतिशील संबंध को प्रतिबिंबित करने के लिए मिडास को नियोजित करते हैं। आश्रित चर के अंतराल और प्रत्येक भुगतान संकेतक का उपयोग करते हुए एकल मिडास मॉडल का अनुमान लगाया गया है।

चूंकि, कम आवृत्ति वाली जीवीए वृद्धि दर स्वाभाविक रूप से स्वतः सहसंबंध प्रदर्शित करती है, इसलिए हम मॉडल में जीवीए वृद्धि दर के स्वतः प्रतिगमन प्रभाव पर भी विचार करते हैं। एडीएल-मिडास (एम,के,एल) मॉडल के साथ एक कदम आगे का पूर्वानुमान इस प्रकार अनुमानित है:

$$Y_t = \text{intercept} + \sum_{j=1}^p \alpha_j Y_{t-j} + \beta \sum_{k=0}^K \omega(k; \delta) L^k X_t^{(m)} + \varepsilon_t \dots (1)$$

जहां:

$\omega(k; \delta)$ प्रकार्य बहुपदीय भार है,

Y_t निम्न आवृत्ति तिमाही जीवीए वृद्धि दर (व-द-व) को दर्शाता है, $t = 1, 2, \dots, T$,

$X_t^{(m)}$ उच्च आवृत्ति मासिक भुगतान संकेतक वृद्धि दर (व-द-व) को दर्शाता है, जो $t-1$ और t तिमाही के बीच 'एम' बार देखा जाता है (इस प्रकार एम=3),

K उच्च आवृत्ति मासिक भुगतान संकेतक वृद्धि दर के अधिकतम अंतराल क्रम का वर्णन करता है,

¹ उटारी, डी.टी., और एच. इल्मा, (2021), "कृषि निर्यात का उपयोग करके इंडोनेशियाई जीडीपी का पूर्वानुमान लगाने के लिए मिश्रित डेटा नमूनाकरण (एमआईडीएस) प्रतिगमन मॉडल के तरीकों की तुलना", एआईपी सम्मेलन की कार्यवाही।

² असीमकोपोलोस, एस., जे. परेडेस, और टी. वार्मिडिंगर, (2013), "मिश्रित आवृत्ति डेटा का उपयोग करके वित्तीय समय शृंखला का पूर्वानुमान", ईसीबी वर्किंग पेपर संख्या 1550।

³ सालिसु, ए., और आर. गुप्ता, (2020), "ऑयल शॉक्स एंड स्टॉक मार्केट वोलैटिलिटी ऑफ द ब्रिक्स: ए गर्च-मिडास अप्रोच", ग्लोबल फाइनेंस जर्नल, 1, 100546।

δ हाइपर-पैरामीट्रिक वेक्टर है जो बहुपद भार प्रकार्य के आकार को निर्धारित करता है,

L एक बहुपद अंतराल परिचालक है,

इंटरसेप्ट α_j और β मॉडल द्वारा अनुमानित किए जाने वाले मानदंड हैं,

ε_t प्रसंभाव्य त्रुटि पद को दर्शाता है।

यह ध्यान दिया जा सकता है कि $k = 0$ वर्तमान तिमाही "1" में भुगतान संकेतक की हाल के महीने की वृद्धि दर को दर्शाता है। उदाहरण के लिए, यदि हम 2021-22 की तीसरी तिमाही के लिए जीवीए वृद्धि दर का अनुमान लगा रहे हैं, तो $k = 0$ दिसंबर 2021 के लिए मासिक भुगतान संकेतक की वृद्धि दर को दर्शाता है। इसी तरह, $k = 1$ नवंबर 2021 और इसी प्रकार आगे की मासिक भुगतान संकेतक की वृद्धि दर को दर्शाता है।

बहुपद भार प्रकार्य, जो विभिन्न आवृत्ति वाले चर के बीच गतिशील संबंध को दर्शाता है, इसके कई कार्यात्मक रूप हैं, और इसका उद्देश्य मितव्ययिता बनाए रखना है⁴। इसलिए, जीवीए वृद्धि के सटीक पूर्वानुमानों का पता लगाने के लिए, इस अध्ययन में बहुपद भार प्रकार्यों के दो अलग-अलग विनिर्देशों का उपयोग किया गया है। इनमें प्रसामान्यीकृत घातांकी अलमोन अंतराल बहुपद (ईएक्सपीअलमोन) और अलमोन अंतराल बहुपद (अलमोन) शामिल हैं (अनुबंध II)।

IV.2 सहायक वेक्टर मशीन प्रतिगमन

एसवीएम प्रतिगमन एक गैर-पैरामीट्रिक विधि है जिसे पहली बार वापनिक (1995) द्वारा प्रस्तावित किया गया था। एसवीएम एल्गोरिदम की सफलता इस तथ्य से स्पष्ट है कि इसका विभिन्न क्षेत्र में विशिष्ट रूप से समष्टिआर्थिक अनुसंधान में प्रतिगमन और वर्गीकरण समस्याओं में व्यापक रूप से उपयोग किया गया है। उदाहरण के लिए, रिजर्व बैंक ऑफ न्यूजीलैंड से रिचर्डसन एवं अन्य (2019) वास्तविक जीवीए वृद्धि दर का समयोचित पूर्वानुमान प्राप्त करने के लिए विभिन्न एमएल विधियों के एक समूह का उपयोग करते हैं और एसवीएम सबसे अच्छी तकनीक के रूप में सामने आता है।

⁴ झांग, बी., एल. नाओ, आर. लॉ, और एच. लिउ, (2021), "खोज डेटा के बड़े पैमाने का उपयोग करके होटल की मांग का पूर्वानुमान लगाने के लिए एक हाइब्रिड मिडास वृष्टिकोण", पर्यटन अर्थशास्त्र।

सहायक वेक्टर प्रतिगमन वास्तविक-मूल्य प्रकार्य आकलन में एक प्रभावी उपकरण साबित हुआ है। वर्गीकरण के अनुरूप, सहायक वेक्टर मशीन प्रतिगमन को विभिन्न आधार प्रकार्य और सहायक वेक्टरों की संख्या द्वारा चिह्नित किया जाता है।⁵ एसवीएम द्वारा 'संरचनात्मक जोखिम न्यूनीकरण' सिद्धांत का उपयोग इसे सामान्य प्रदर्शन में वृद्धि करने में काफी मदद करता है, क्योंकि यह ट्रेन डेटा पर मॉडल को अनुकूल बनाने में आने वाली मॉडल जटिलता को संतुलित करता है (वापनिक और चेवर्नेकिंस, 1974)। इसके अलावा, मॉडल की कम्प्यूटेशनल जटिलता भी कम हो जाती है क्योंकि अंतिम निर्णय प्रकार्य मुख्य रूप से केवल सहायक वेक्टर पर निर्भर करता है, जो कुल नमूने का एक अंश है।

हमारे अध्ययन में, हम प्रत्येक भुगतान संकेतक के लिए उचित सर्वोत्तम एकल मिडास मॉडल के त्रैमासिक स्तर के अवशेषों को मॉडल करने के लिए एसवीएम प्रतिगमन का उपयोग करते हैं। हम इसे प्रत्येक भुगतान संकेतक की तिमाही वृद्धि दर (वर्ष-दर-वर्ष) की तुलना में लाते हैं। इसके अलावा, हम बड़े पैमाने पर विभिन्न आधार प्रकार्य (बहुपद, अर्धव्यास, अवग्रहाकार, रैखिक) को नियोजित करते हैं और प्रत्येक भुगतान संकेतक चर के लिए सर्वोत्तम मॉडल का चयन करने के लिए लागत और एप्सिलॉन जैसे अन्य हाइपर मापदंडों को अनुकूल बनाते हैं।

IV.3 त्रुटि सुधार कार्यनीति: मिडास-एसवीएम हाइब्रिड मॉडल

पूर्वानुमानों को बेहतर बनाने के लिए, हम मिडास-एसवीएम हाइब्रिड मॉडल का निर्माण करते हैं, जिसमें एसवीएम एल्गोरिथम से अवशिष्टों के अनुमानित मूल्यों को प्रत्येक एकल सर्वोत्तम मिडास मॉडल के लिए तिमाही जीवीए वृद्धि दर के उचित मूल्यों में जोड़ा जाता है। इस कदम से प्रत्येक भुगतान कारक के लिए सर्वोत्तम एकल मिडास मॉडल की पूर्वानुमान सटीकता में सुधार होने की उम्मीद है।

IV.4 पूर्वानुमान के लिए भारण की रूपरेखा

गलत विवरण से बचने के लिए और प्रत्येक एकल सर्वोत्तम मिडास-एसवीएम मॉडल द्वारा प्रदान किए गए विभिन्न सूचना सेट (एकल भुगतान संकेतक) को निकालने के लिए, हम उन्हें दो भारण तकनीकों, यानी, ई-डबल्यू (समान भार) और आरएमएसएफई (मूल माध्य वर्गित पूर्वानुमान त्रुटि) का उपयोग करके जोड़ते हैं।

⁵ अवध, एम., और आर. खन्ना, (2015), "सहायक वेक्टर प्रतिगमन", एफिशिएंट लर्निंग मशीन्स, अप्रेस, बर्कले, सीए

आरएमएसएफई भारण तकनीक परीक्षण/नमूना डेटा से बाहर मूल माध्य वर्गित पूर्वानुमान त्रुटि वाले कारकों को कम महत्व देकर उन्हें दंडित करती है। यह मॉडल तीन तिमाहियों (2021-22 की दूसरी तिमाही से 2021-22 की चौथी तिमाही तक) के लिए कम आवृत्ति तिमाही जीवीए वृद्धि दर के पूर्वानुमान को और सटीक बनाता है। पूर्वानुमान हर बार एक कदम आगे के आधार पर तैयार किया जाता है।

सामान्य तौर पर, पूर्वानुमान का निर्माण इस प्रकार किया जाता है:⁶

$$\tilde{\theta}_{m,T+l|T} = \sum_{m=1}^M (w_{m,T} \times \theta_{m,T+l|T})$$

जहां:

T सर्वोत्तम एकल मिडास-एसवीएम हाइब्रिड मॉडल के लिए परीक्षण/नमूना डेटा में से अंतिम नमूना बिंदु को दर्शाता है,

l आगे के पूर्वानुमान को दर्शाता है (हमारे पेपर में, हमने $l = 1$ सेट किया है),

प्रत्येक m^{th} मिडास-एसवीएम हाइब्रिड मॉडल के लिए नमूने डेटा के परीक्षण/बाहर के भार के आकलन को परिभाषित करता है।

$\theta_{m,T+l|T}$ m^{th} सर्वोत्तम एकल मिडास-एसवीएम हाइब्रिड मॉडल के एक कदम आगे के परिणामों को दर्शाता है,

$\tilde{\theta}_{m,T+l|T}$ M एकल के भारित औसत के 1-कदम आगे के पूर्वानुमान परिणाम को दर्शाता है।

प्रत्येक भुगतान संकेतक से संबंधित m^{th} मिडास-एसवीएम हाइब्रिड मॉडल के लिए भार को अद्यतन किया जाता है और प्रत्येक उत्तरोत्तर पूर्वानुमान के लिए पिछले पूर्वानुमान के लिए प्राप्त वास्तविक मूल्य को वापस परीक्षण/बाहर के नमूना डेटा में जोड़कर पुनः गणना की जाती है, (परिशिष्ट-II)।

V. निष्कर्ष

प्रत्येक भुगतान संकेतक (या तो मात्रा और मूल्य चैनल) के लिए सर्वोत्तम एकल मिडास मॉडल का चयन एकल मिडास-एसवीएम हाइब्रिड मॉडल के लिए नींव के रूप में कार्य करता है और इसकी क्रमशः खंड V.1 और V.2 में चर्चा की गई है। खंड V.3 में पूर्वानुमान फ्रेमवर्क और परिणामों पर चर्चा की गई है।

⁶ वैंग, सी., और डब्ल्यू कांग, (2021), "डायनेमिक फैक्टर्स और मिश्रित-आवृत्ति डेटा का उपयोग करके चीन की स्टीम कोयले की कीमतों का पूर्वानुमान", पर्यावरण अध्ययन का पोलिश जर्नल, 30(5):4241-4254

V.1 सर्वोत्तम एकल मिडास मॉडल

जैसा कि इष्टतम मॉडल का चयन तिमाही जीवीए वृद्धि के पूर्वानुमान को महत्वपूर्ण रूप से प्रभावित करता है, हम तिमाही जीवीए और मासिक भुगतान संकेतकों दोनों के लिए अलग-अलग अंतराल के साथ विभिन्न मिडास विनिर्देशों का एक समूह चलाते हैं। इसके अलावा, विभिन्न बहुपद भारों पर भी विचार किया जाता है, ताकि उच्चतम पूर्वानुमान क्षमता वाले सर्वश्रेष्ठ एकल मिडास मॉडल का चयन किया जा सके (अर्थात्, नमूने/परीक्षण डेटा में सबसे छोटा आरएमएसई)। अंतिम चयन बहुपद भार के हाइपर-पैरामीटर के गैर-रैखिक निम्नतम वर्ग (एनएलएस) पूर्वानुमान और बहुपद भार प्रकार्य की अनुभवजन्य पर्याप्तता पर निर्भर करता है। अनुभवजन्य पर्याप्तता का परीक्षण hAh परीक्षण द्वारा किया जाता है (केवेदरस एवं अन्य, 2012)।

सारणी 2 निर्धारित स्थिति के साथ एक कदम आगे के पूर्वानुमान की स्थिति पर विचार करते समय मूल्य और मात्रा दोनों शर्तों में प्रत्येक भुगतान कारक के साथ सर्वोत्तम एकल मिडास मॉडल के पूर्वानुमान प्रदर्शन (नमूना / परीक्षण डेटा से बाहर आरएमएसई) को प्रदर्शित करती है। जैसा कि पहले उल्लेख किया गया है, कई चयन जांचों पर विचार करने के बाद बोल्ड वैल्यू एकल भुगतान संकेतक के लिए सर्वोत्तम मिडास मॉडल को उजागर करते हैं, यानी परीक्षण/नमूना डेटा से बाहर पर सबसे कम आरएमएसई, बहुपद भार एनएलएस हाइपर-पैरामीटर महत्व और बहुपद प्रतिबंधों की अनुभवजन्य पर्याप्तता।

सारणी 2: प्रत्येक भुगतान संकेतक के लिए सर्वश्रेष्ठ एकल मिडास मॉडल

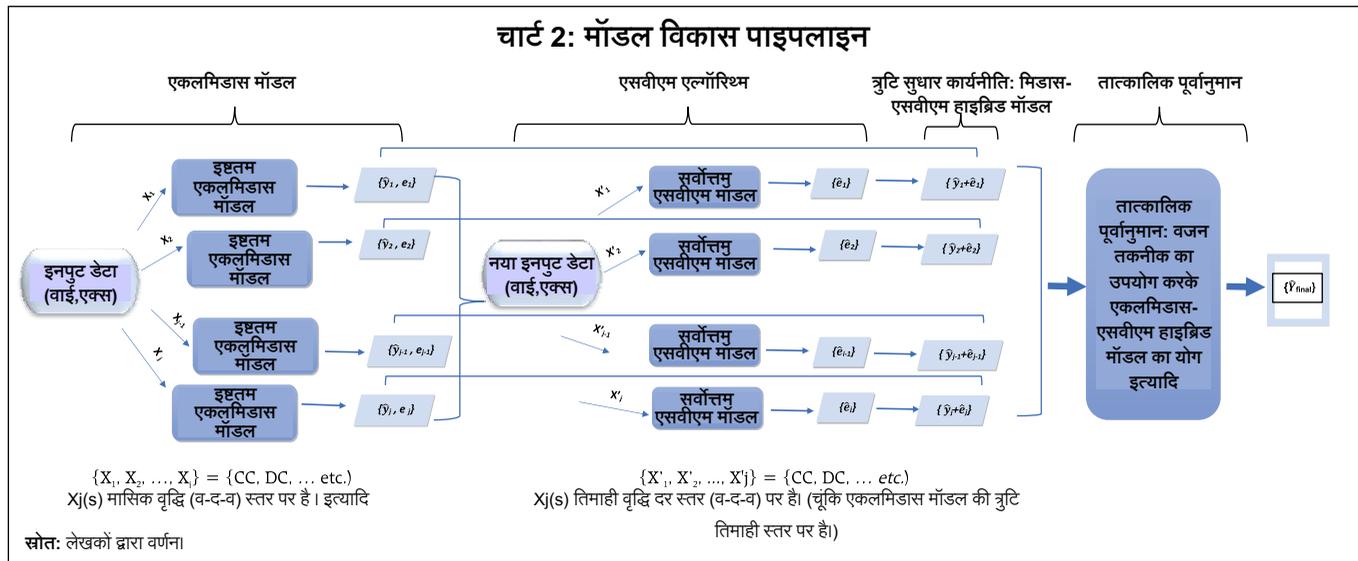
ए: मूल्य		
संकेतक	सर्वोत्तम एकल मिडास मॉडल	आरएमएसई
क्रेडिट कार्ड (सीसी)	एआर (3)- अलमोन-मिडास (1,3)	2.1
डेबिट कार्ड (डीसी)	एआर (0)-अलमोन-मिडास (0,2)	3.4
ऋण हस्तांतरण- खुदरा	एआर (1)- अलमोन-मिडास (2,6)	3.3
ऋण हस्तांतरण- आरटीजीएस कार्ड_पीओएस	एआर (0)- अलमोन-मिडास (1,3)	3.2
	एआर (1)- अलमोन-मिडास (2,3)	3.7
बी: मात्रा		
संकेतक	सर्वोत्तम एकल मिडास मॉडल	आरएमएसई
क्रेडिट कार्ड (सीसी)	एआर (1)- अलमोन-मिडास (1,5)	2.8
डेबिट कार्ड (डीसी)	एआर (2)- अलमोन-मिडास (1,3)	2.7
ऋण हस्तांतरण- खुदरा	एआर (1)- अलमोन-मिडास (2,9)	4.8
ऋण हस्तांतरण- आरटीजीएस कार्ड_पीओएस	एआर (0)- अलमोन-मिडास (0,3)	5.1
	एआर (0)- अलमोन-मिडास (1,3)	5.1

टिप्पणी: एडीएल-मिडास मॉडल के लिए समीकरण 3 शब्दों का एक संयोजन है – एआर(एस) जहां तिमाही जीवीए वृद्धि (व-द-व) के लिए 'एस' अंतराल की स्थिति है, तिमाही जीवीए वृद्धि (वर्ष-दर-वर्ष) और मासिक भुगतान और मिडास (आर,क्यू) के बीच संबंध का पता लगाने में 'अलमोन' सर्वोत्तम बहुपद भार प्रकार्य दर्शाता है, जहां 'आर' अंतराल की शुरुआत वाला माह है और 'क्यू' मासिक भुगतान वृद्धि संकेतक के अंतराल माह का समापन दर्शाता है।

स्रोत: लेखकों का अनुमान।

V.2 सर्वोत्तम एकल मिडास-एसवीएम हाइब्रिड मॉडल

सारणी 3 त्रुटि सुधार तंत्र (चार्ट 2 में चरण 3) पर विचार करने के बाद पूर्ववर्ती चरण में चयनित भुगतान कारकों के साथ सर्वोत्तम एकल मिडास-एसवीएम हाइब्रिड मॉडल के पूर्वानुमान प्रदर्शन (नमूना/परीक्षण डेटा से बाहर आरएमएसई) को प्रदर्शित करता है।



सारणी 3: मात्रा या मूल्य माध्यम में चयनित भुगतान संकेतकों के लिए सर्वोत्तम एकल मिडास-एसवीएम हाइब्रिड मॉडल

संकेतक	सर्वोत्तम एकल मिडास-एसवीएम मॉडल	आरएमएसई	सुधार (प्रतिशत में)
क्रेडिट कार्ड (सीसी) मात्रा	एआर (1)- अलमोन-मिडास (1,5)-एसवीएम	0.58	79.6
डेबिट कार्ड (सीसी) मात्रा	एआर (2)- अलमोन-मिडास (1,3)-एसवीएम	2.05	24.4
ऋण हस्तांतरण- खुदरा मूल्य	एआर (1)- अलमोन-मिडास (2,6)-एसवीएम	1.80	45.3
ऋण हस्तांतरण- आरटीजीएस मूल्य	एआर (0)- अलमोन-मिडास (1,3)-एसवीएम	3.13	3.00
कार्ड- पीओएस मूल्य	एआर (1)- अलमोन-मिडास (2,3)-एसवीएम	2.14	41.7

टिप्पणी: एडीएल-मिडास-एसवीएम मॉडल के लिए समीकरण 4 शब्दों का एक संयोजन है – एआर(एस) जहां 'एस' तिमाही जीवीए वृद्धि (व-द-व) के लिए अंतराल की स्थिति है, तिमाही जीवीए वृद्धि (वर्ष-दर-वर्ष) और मासिक भुगतान और मिडास (आर,क्यू) के बीच संबंध का पता लगाने में 'अलमोन' सर्वोत्तम बहुपद भार प्रकार्य दर्शाता है, जहां 'आर' अंतराल की शुरुआत वाला माह है और 'क्यू' मासिक भुगतान वृद्धि संकेतक के अंतराल माह का समापन दर्शाता है। एसवीएम सर्वोत्तम एकल मिडास मॉडल के अवशेषों पर लागू समर्थन वेक्टर प्रतिगमन है।

स्रोत: लेखकों का अनुमान।

'सुधार' कॉलम उस प्रतिशत राशि को दर्शाता है जिसके द्वारा मिडास-एसवीएम हाइब्रिड मॉडल के नमूना/परीक्षण डेटा पूर्वानुमान सटीकता में से सर्वोत्तम एकल मिडास मॉडल से अधिक है। परिणाम हमारी परिकल्पना की पुष्टि करते हैं कि मिडास मॉडल के अवशिष्टों पर एसवीएम एल्गोरिथम को लागू करने से अधिकांश भुगतान संकेतकों के लिए पूर्वानुमान त्रुटि में महत्वपूर्ण कमी आई है। यह इस तथ्य के कारण हो सकता है कि मशीन लर्निंग जीवीए वृद्धि में गैर-रैखिकताओं को पकड़ने में सक्षम है जिसका मिडास द्वारा पता लगाना मुश्किल है।

V.3 तात्कालिक पूर्वानुमान मूल्यांकन

तीन तिमाहियों यानी 2021-22 की दूसरी तिमाही से 2021-22 की चौथी तिमाही तक के लिए जीवीए वृद्धि के तात्कालिक पूर्वानुमान उत्पन्न करने के लिए, हम दो भारोत्तोलन तकनीकों जो बराबर-वजन वाली है (ई-डब्ल्यू) और वर्ग माध्य मूल मान पूर्वानुमान त्रुटि (आरएमएसएफई)का उपयोग करते हुए प्रत्येक सर्वोत्तम मिडास-एसवीएम हाइब्रिड मॉडल के एक कदम आगे के तात्कालिक पूर्वानुमान परिणामों को जोड़ते हैं।

V.3.1 भारण कार्यनीति

ई-डब्ल्यू भारण तकनीक के मामले में, हम सर्वोत्तम एकल मिडास-एसवीएम हाइब्रिड मॉडल द्वारा उत्पन्न तात्कालिक पूर्वानुमान परिणामों पर एक निरंतर भार लागू करते हैं (एम कारकों की कुल संख्या है, हमारे मामले में यह 5 है)। आरएमएसएफई भारण कार्यनीति के लिए, प्रत्येक कारक के लिए भार की गणना प्रत्येक क्रमिक तात्कालिक पूर्वानुमान पुनरावृत्ति के लिए की जाती है, अर्थात्, 2021-22 की दूसरी तिमाही के तात्कालिक पूर्वानुमान

को प्राप्त करने के लिए, भार की गणना परीक्षण/नमूने से बाहर डेटा पर की जाती है (ति2: 2020-21 से ति1:2021-22 तक) और इसी तरह, 2021-22 की तीसरी तिमाही का तात्कालिक पूर्वानुमान प्राप्त करने के लिए, 2021-22 की दूसरी तिमाही और इसी तरह आगे के लिए वास्तविक अवलोकन के साथ संलग्न परीक्षण डेटा पर भार की फिर से गणना की जाती है (परिशिष्ट-II)।

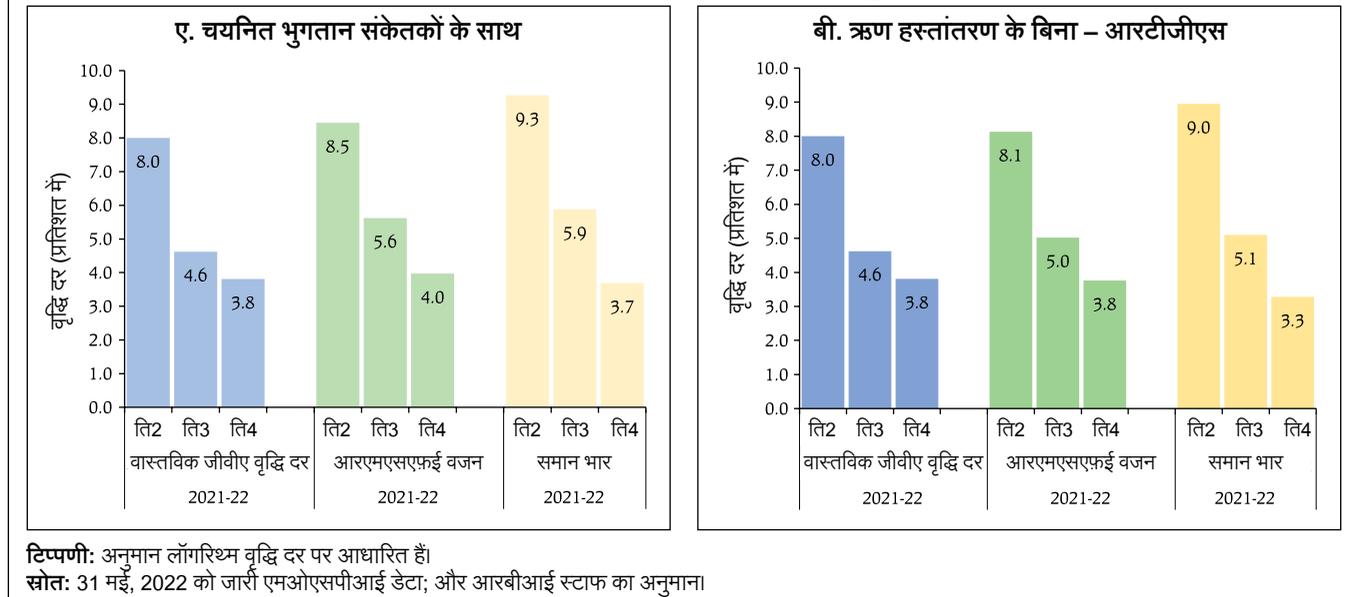
V.3.2 तात्कालिक प्रदर्शन

चार्ट 3 दोनों भार तकनीकों के साथ ति2: 2021-22 से ति4: 2021-22 तक तीन तिमाहियों के लिए तात्कालिक पूर्वानुमान दिखाता है। वास्तविक जीवीए वृद्धि में क्रमशः 8.0 प्रतिशत (ति2: 2021-22) से 4.6 प्रतिशत (ति3: 2021-22) और 3.8 प्रतिशत (ति4: 2021-22) की गिरावट देखी गई।

चार्ट 3ए के लिए, चयनित भुगतान संकेतक क्रेडिट कार्ड (सीसी) वॉल्यूम, डेबिट कार्ड (डीसी) वॉल्यूम, क्रेडिट ट्रांसफर-रिटेल वैल्यू, क्रेडिट ट्रांसफर-आरटीजीएस वैल्यू, कार्ड - पीओएस वैल्यू हैं। यह देखा गया है कि हाइब्रिड मॉडल के तात्कालिक पूर्वानुमान स्पष्ट रूप से वास्तविक जीवीए वृद्धि के प्रक्षेपवक्र का पता लगा रहे हैं। अनुभवजन्य परिणाम भी स्पष्ट रूप से प्रदर्शित करते हैं कि सटीकता के मामले में आरएमएसएफई भार योजना अग्रणी है। आरटीजीएस (मूल्य) श्रृंखला के लिए, कुछ डेटा विपथन⁷ नोट किए गए थे और हमने इस भुगतान कारक को ध्यान में रखे बिना तात्कालिक पूर्वानुमान के साथ प्रयोग किया। चार्ट 3बी क्रेडिट ट्रांसफर आरटीजीएस (मूल्य) के बिना तात्कालिक

⁷ 2012-13 की चौथी तिमाही में और फिर 2019-20 की चौथी तिमाही में ऋण हस्तांतरण-आरटीजीएस (मूल्य) में भारी गिरावट देखी गई। समान तिमाहियों के अध्ययन में उपयोग किए गए अन्य भुगतान संकेतकों के लिए यह तेज गिरावट नहीं देखी गई।

चार्ट 3: मिडास-एसवीएम हाइब्रिड मॉडल का उपयोग करते हुए तात्कालिक पूर्वानुमान



पूर्वानुमान प्रदर्शन दिखाता है और सृजित तात्कालिक पूर्वानुमान सटीकता में पर्याप्त सुधार प्रदर्शित करता है। इस मामले में भी, आरएमएसएफई भार योजना के आधार पर सबसे सटीक परिणाम प्राप्त किए जाते हैं।

VI. निष्कर्ष

इस अध्ययन का उद्देश्य मूल्य और मात्रा दोनों घटकों के आधार पर भुगतान प्रवाह पर उच्च आवृत्ति डेटा का उपयोग करके जीवीए वृद्धि का पता लगाना है। विश्लेषणात्मक दृष्टिकोण हाइब्रिड मशीन लर्निंग मॉडल फ्रेमवर्क पर आधारित है जिसमें मिश्रित आवृत्ति अर्धमितीय मॉडल और मशीन लर्निंग एल्गोरिदम शामिल हैं। अलग-अलग अंतराल के साथ अलग-अलग मिडास विनिर्देशों के एक समूह के कई दौर के आधार पर अलग-अलग भुगतान संकेतक आधारित मिडास मॉडल का चयन किया जाता है।

इसके बाद अलग-अलग मिडास-एसवीएम मॉडल आते हैं जिसमें अलग-अलग मिडास मॉडल के अवशेषों पर एसवीएम एल्गोरिथम का अनुप्रयोग शामिल होता है। यह चरण हमें उन गैर-रैखिकताओं का पता लगाने की अनुमति देता है जिसका पता मिडास नहीं लगाता और इस प्रकार पूर्वानुमान सटीकता में सुधार करते हैं। अंत में, सर्वोत्तम एकल मिडास-एसवीएम मॉडल चुने जाते हैं और दो भारण तकनीकों - ई-डब्ल्यू और आरएमएसएफई

का उपयोग करके तात्कालिक पूर्वानुमान प्राप्त करने के लिए आगे संयोजित किए जाते हैं। अनुभवजन्य परिणाम बताते हैं कि आरएमएसएफई की भारण योजनाओं से प्राप्त तात्कालिक पूर्वानुमान सटीकता के मामले में ई-डब्ल्यू से बेहतर प्रदर्शन करते हैं। इस विश्लेषणात्मक दृष्टिकोण का लचीलापन आसानी से अन्य समष्टिआर्थिक समुच्चय के तात्कालिक पूर्वानुमान का पता लगाने में आसानी से मदद करता है।

संदर्भ

- Aprigliano, V., G. Ardizzi, and L. Monteforte, (2019), "Using payment system data to forecast economic activity", *International Journal of Central Banking*, 15 (4).
- Bancad'Italia (1999), "White Paper on Payment System Oversight, Objectives, Methods, Areas of Interest".
- Benchmarking India's Payment System, July 2022, Reserve Bank of India.
- Bentsen, K.N., and D. Gorea, (2021), "Nowcasting and forecasting economic activity in Denmark using payment system data", *Denmarks National Bank, Working Paper no. 17*.

- Chapman, J.T.E., and A. Desai, (2021), "Using payments data to nowcast macroeconomic variables during the onset of COVID-19", *Staff Working Paper 2021-2*, Bank of Canada.
- Cortes, C., and V. Vapnik, (1995), "Support-vector networks." *Mach Learn* 20: 273– 297.
- Ghysels, E., V. Kvedaras, and V. Zemlys, (2016), "Mixed Frequency Data Sampling Regression Models: The R Package midasr", *Journal of Statistical Software*, 72(4):1–35.
- Hasan, I., H. Schmiedel, and L. Song, (2012), "Retail payment and bank performance". *Journal of Financial Services Research*, 41 (3): 163-195.
- Humphrey, D.B., M. Willeson, G. Bergendahl, and T. Lindblom, (2006), "Benefits from a changing payment technology in European banking". *Journal of Banking and Finance*, 30(6): 1631-1652.
- Kvedaras, V., and V. Zemlys, (2012), "Testing the functional constraints on parameters in regressions with variables of different frequency", *Economics Letters*, 116: 250-254.
- León, C., and F. Ortega, (2018), "Nowcasting economic activity with electronic payments data: A predictive modeling approach", *Borraderas de Economía No. 1037*, Banco de la Republica.
- Meng, M.H., and C.F. Zhao, (2015), "Application of support vector machines to a small-sample prediction", *Advances in Petroleum Exploration and Development*, 10(2):72-75.
- Payment Systems in India, RBI Occasional Publications, 1998.
- Payments Vision 2025, June 2022, Reserve Bank of India.
- Raj, J., I. Bhattacharya, S.R. Behra, J. John, and B.A. Talwar, (2020), "Modelling and forecasting currency demand in India: A heterodox approach", *RBI Occasional Papers*, 41(1)
- Raju, S., and M. Balakrishnan, (2019), "Nowcasting economic activity in India using payment systems data", *Journal of Payments Strategy and Systems*, 13 (1)
- Richardson, A., T.V.F. Mulder, and T. Vehbi, (2019), "Nowcasting New Zealand GDP using machine learning algorithms", *IFC Bulletin Chapters*, 50, Bank for International Settlements.
- Rooj, D., and R. Sengupta, (2021), "Forecasting private consumption with digital payment data: A mixed frequency analysis", *ADB Working Paper series no. 1249*.
- Seventh SEPA Progress Report, *European Central Bank*, 2010.
- Shao, Y., and R.S. Lunetta, (2012), "Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points", *ISPRS Journal of Photogrammetry and Remote Sensing*, 70: 78-87.
- The Payment Systems, *European Central Bank*, 2010.
- The role of Central Bank Money in Payment Systems, Committee on Payment and Settlement Systems, *Bank for International Settlement*, 2003.
- Vapnik, V., and A. Chervonenkis, (1974) "Pattern Recognition Theory, Statistical Learning Problems, Nauka, Moskva".
- Wang, C., and W. Kang, (2021), "Forecasting China's Steam Coal Prices Using Dynamic Factors and Mixed-Frequency Data", *Polish Journal of Environmental Studies*, 30(5):4241-4254.
- Zhang, Y., G. Zhang, L. Liu, T.D. Renzis, and H. Schmiedel, (2019), "Retail payments and the real economy", *Journal of Financial Stability*, 44, ISSN 1572-3089.

अनुबंध-1
चर विवरण

क्रम सं.	चर के नाम	चर विवरण
1	क्रेडिट कार्ड (सीसी)	यह लेन-देन क्रेडिट कार्ड के जरिए किया जाता है। सीसी के प्रमुख घटक हैं: ए. क्रेडिट कार्ड से कार्ड भुगतान बी. क्रेडिट कार्ड द्वारा एटीएम से नकद निकासी
2	डेबिट कार्ड (डीसी)	यह डेबिट कार्ड के माध्यम से किया जाने वाला लेन-देन है। डीसी के प्रमुख घटक हैं: ए. डेबिट कार्ड से कार्ड से भुगतान बी. डेबिट कार्ड द्वारा एटीएम से नकद निकासी
3	ऋण हस्तांतरण-खुदरा	यह खुदरा भुगतान प्रणाली के माध्यम से होने वाला लेनदेन है। इसमें निम्नलिखित प्रणाली के माध्यम से होने वाले लेन-देन शामिल हैं: ए. आधार सक्षम भुगतान प्रणाली (एईपीएस) बी. आधार भुगतान ब्रिज प्रणाली (एपीबीएस) सी. इलेक्ट्रॉनिक समाशोधन सेवाएं (ईसीएस) डी. तत्काल भुगतान सेवा (आईएमपीएस) इ. अंतरबैंक लेनदेन एफ. राष्ट्रीय स्वचालित समाशोधन गृह (एनएसीएच) जी. राष्ट्रीय इलेक्ट्रॉनिक निधि अंतरण (एनईएफटी) एच. एकीकृत भुगतान इंटरफ़ेस (यूपीआई)
4	ऋण हस्तांतरण-आरटीजीएस	यह आरटीजीएस प्रणाली के माध्यम से होने वाले बड़े मूल्य का लेनदेन है। इसे आगे उपविभाजित किया गया है: ए. ग्राहक लेनदेन बी. अंतरबैंक लेनदेन
5	कार्ड_पीओएस	प्वाइंट-ऑफ-सेल मशीनों पर कार्ड लेनदेन: ए. बिक्री केंद्र पर क्रेडिट कार्ड का उपयोग बी. बिक्री केंद्र पर डेबिट कार्ड का उपयोग

अनुबंध- II

ए. बहुपद भार प्रकार्य :

- चरघातांकी अलमोन अंतराल बहुपद: क्रम पी (ईएक्सपीअलमोन) के चरघातांकी अलमोन अंतराल बहुपद को इस प्रकार परिभाषित किया गया है:

$$w(k; \delta) = w(k; \delta_1, \delta_2, \dots, \delta_p) = \frac{e^{(\delta_1 k^1 + \delta_2 k^2 + \dots + \delta_p k^p)}}{\sum_{k=1}^K e^{(\delta_1 k^1 + \delta_2 k^2 + \dots + \delta_p k^p)}}$$

- अलमोन अंतराल बहुपद: क्रम पी (एलमोन) के अलमोन अंतराल बहुपद को इस प्रकार परिभाषित किया गया है:

$$w(k; \delta) = w(k; \delta_1, \delta_2, \dots, \delta_p) = \sum_{p=0}^P \delta_p k^p$$

- बी. आरएमएसएफई भारण: आरएमएसएफई मूल माध्य वर्ग पूर्वानुमान त्रुटि को संदर्भित करता है, जिसका उपयोग व्यक्तिगत दृष्टिकोण को संयोजित करने के लिए किया जाता

है। भार को इस प्रकार दिया जाता है:

$$w_{m,T} = \frac{r_{m,T}^{-1}}{\sum_m r_{m,T}^{-1}}$$

जहां, $r_{m,T} = \sqrt{\sum_{i=T_0}^t (y_{m,T+s} - \hat{y}_{m,T+s|T})^2 / t - T_0 + 1}$

$r_{m,T}$ को m^{th} कारक के साथ सर्वोत्तम एकल मिडस-एसवीएम मॉडल के आरएमएसएफई के रूप में परिभाषित किया जाता है। यहां, $t - T_0 + 1$ नमूने के बाहर के अवलोकन की संख्या का संकेत देता है। $y_{m,T+s}$ वास्तविक अवलोकन और $\hat{y}_{m,T+s|T}$ पूर्वानुमानित को संदर्भित करता है।

- सी. समान भार: समान भारित प्रकार औसत वजन को संदर्भित करता है, जैसा कि सरल रूप से दिया गया है: $w_{m,T} = 1/M$