کنون‌بینی رشد بخش خدمات در ایران با استفاده از داده‌های بخش حمل و نقل[1]

سجاد ابراهیمی
استادیار پژوهشکده پولی و بانکی
s.ebrahimi@mbri.ac.ir

نوع مقاله: علمی - پژوهشی تاریخ دریافت: ۱۴۰۰/۰۹/۲۰ تاریخ پذیرش: ۱۴۰۰/۱۲/۰۲

چکیده

وقفه‌های قابل پیش‌بینی و غیرقابل پیش‌بینی در انتشار داده‌های حساب‌های ملی در ایران ضرورت پیش‌بینی وضعیت کنونی اقتصاد (کنون‌بینی[2]) را با استفاده از داده‌های به‌هنگام و با تواتر بالا نشان می‌دهد. کنون‌بینی رشد بخش خدمات با توجه به سهم بالایی که این بخش در GDP دارد از اهمیت بالاتری برخوردار است. این پژوهش به دنبال پاسخ به این سوال است که آیا با استفاده از مجموعه داده‌های تردد‌شماری وسایل نقلیه در جاده‌های کشور می‌توان وضعیت بخش خدمات و حمل و نقل را پیش‌بینی کرد. در این راستا از داده‌های روزانه ۲۵۹۰ نقطه از جاده‌های کشور از ابتدای سال ۱۳۹۴ تا شهریور ۱۴۰۰ استفاده شده است. علاوه بر بکارگیری روش تجمیعی ساده برای ساخت شاخص، از مدل‌های شبکه عصبی و میانگین‌گیری مدل بیزین نیز به استفاده شده است. نتایج نشان می‌دهد که شاخص‌های برآوردی مستخرج از این داده‌ها خطای کمتری نسبت به مدل‌های معیار (ARMA) داشته‌اند و می‌توانند نمایان‌گر تغییرات هر دو بخش خدمات و حمل و نقل باشند. یافته‌های پژوهش نشان می‌دهد که در بین روش‌های مختلف ساخت شاخص، شاخص خروجی شبکه عصبی عملکرد بهتر و خطای کمتری داشته است.

طبقه‌بندی JEL: C45، C11، L91، L80

کلیدواژه‌ها: خدمات، حمل و نقل، شبکه عصبی، پیش‌بینی، میانگین‌گیری مدل بیزین

---

[1]. این مقاله برگرفته از طرح « استخراج و بررسی شاخص‌های بهنگام تبیین‌کننده وضعیت اقتصاد» است که در پژوهشکده پولی و بانکی انجام شده است.

[2]. Nowcasting

۱. مقدمه

اطلاعات و داده‌ها به عنوان اصلی‌ترین ورودی فرآیند تصمیم‌گیری و سیاست‌گزاری اقتصادی است و تا حدود زیادی خروجی سیاست‌گزاری‌ها را تحت تاثیر قرار می‌دهد. با توجه به اینکه با کمک داده‌های اقتصاد کلان و به خصوص داده‌های حساب‌های ملی می‌توان وضعیت بخش‌های مختلف اقتصاد را از ابعاد مختلف تبیین کرد، می‌توان این داده‌ها را جز اطلاعات و داده‌های اثرگذار در تصمیم‌گیری‌های اقتصادی برشمرد. اما ضعف اصلی داده‌های رسمی حساب‌های ملی این است که اولا در تواترهای فصلی و سالانه تهیه و منتشر می‌شود و ثانیا وقفه انتشار نسبتا طولانی برای انتشار این‌چنین داده‌هایی وجود دارد. به عبارت دیگر اتکای به داده‌های رسمی حساب‌های ملی در بهترین حالت با سه تا چهار ماه وقفه اطلاعات مربوط به فعالیت بخش‌های حقیقی را منتشر می‌کنند که با توجه به وقفه‌ای که دارد ارزش آنها را کاهش می‌دهد. بنابراین نیاز دانستن وضعیت فعلی اقتصاد با وقفه کم را نمی‌توان با داده‌های رسمی اقناع کرد.

برای حل این مشکل رویکردهای کنون‌بینی[1] معرفی و گسترش داده شده‌اند. کنون‌بینی به معنی پیش‌بینی وضعیت کنونی و یا گذشته نزدیک است. پایه اصلی کنون‌بینی بکارگیری اطلاعات در دسترس با تواتر بالا و تاخیر انتشار کم به منظور بدست آوردن برآورد زودهنگام از متغیرهای مهم است (بانبورا[2] و همکاران، ۲۰۱۳). ارزش کنون‌بینی این است که قبل از انتشار داده‌های رسمی می‌تواند وضعیت فعلی را تبیین کند. در بسیاری از کشورها از شاخص‌های با تواتر بیشتر مثلا ماهانه و وقفه انتشار کم برای کنون‌بینی استفاده می‌شود. البته این شاخص‌های جایگزین اگرچه دقت داده‌های رسمی را ندارد ولی از جهت به روز بودن و وقفه کم انتشار اطلاعات ارزشمندی از وضعیت اقتصاد را در اختیار فعالان قرار می‌دهد. در بسیاری از بانک‌های مرکزی و تجاری و سازمان‌های بین‌المللی نیز از کنون‌بینی برای برآورد وضعیت موجود استفاده می‌شود. به‌عنوان نمونه فدرال رزرو نیویورک هر دو هفته یک بار تا یک ماه پس از پایان فصل کنون‌بینی خود را از رشد اقتصادی آمریکا در آن فصل ارائه می‌کند[3]. بانک مرکزی انگلیس نیز برای پر کردن وقفه انتشار رسمی آمار رشد GDP اقدام به کنون‌بینی رشد اقتصادی می‌کند. برای این منظور برای هر بخش اقتصادی به صورت مجزا مدل‌سازی کرده و داده‌های به‌روز مربوط

[1]. Nowcasting
[2]. Bańbura
[3]. https://www.newyorkfed.org/research/policy/nowcast.html

به آن بخش استفاده می‌کند[1]. بانک مرکزی فنلاند نیز با استفاده از اطلاعات بیش از ۵۰ متغیر که قابلیت بروزشدن را با تواتر بالا دارند و بکارگیری مدل خودرگرسیون برداری بیزین بزرگ[2] اقدام به کنون‌بینی GDP می‌کنند[3].

نحوه انتشار آمار رسمی در ایران ضرورت پرداختن به کنون‌بینی را بیشتر می‌کند. در ایران علاوه بر وقفه انتشار منظمی که در همه کشورها وجود دارد وقفه نامنظم و غیرقابل پیش‌بینی نیز در انتشار آمار رسمی به وجود می‌آید که در برخی دوره‌ها از چندین فصل فراتر رفته است. لذا کنون‌بینی فعالیت بخش‌های مختلف اقتصادی با داده‌های در دسترس که با تواتر بالا به روز می‌شوند می‌تواند اطلاعات مفیدی از وضعیت فعلی بخش‌های مختلف اقتصادی ارائه دهد. در این مقاله با توجه به اهمیت بخش خدمات تلاش شده است که شاخص‌های به هنگامی برای کنون‌بینی این بخش معرفی و مورد ارزیابی قرار گیرد. بخش خدمات بیش از نیمی از GDP بدون نفت کشور را شامل می‌شود و کنون‌بینی وضعیت این بخش تا حدود زیادی وضعیت کل GDP را مشخص می‌کند. در این راستا از کلان‌داده[4]تردد‌شماری وسایل نقلیه در جاده‌های سراسر کشور استفاده شده است که مشتمل بر بیش از ۱۲ هزار سری زمانی است و تلاش شده است که به سه سوال در این مقاله پاسخ داده شود.

اول: آیا می‌توان داده‌های تردد‌شماری وسایل نقلیه را برای رصد تغییرات میزان فعالیت بخش حمل و نقل و ساخت شاخص برای این بخش بکار برد؟

دوم: آیا می‌توان از داده‌های تردد شماری برای شاخص‌سازی بخش خدمات و رصد تغییرات این بخش استفاده کرد؟[5]

---

1. https://www.bankofengland.co.uk/quarterly-bulletin/2014/q1/nowcasting-uk-gdp-growth
2. Bayesian Large VAR
3. https://www.suomenpankki.fi/en/research/forecasting-models/
4. Big data
5. داده‌های ورودی مورد استفاده از بخش حمل و نقل زمینی بجز راه‌آهن و خطوط لوله است و شاید با این داده‌ها بتوان برای این زیربخش تغییرات را تمام‌شماری لحاظ کرد و اصولا تغییرات آن را محاسبه کرد. اما ادعایی که این پژوهش به دنبال اثبات آن است این است که آیا از این داده‌ها می‌توان تغییرات سایر بخش ها را نیز پیش‌بینی کرد. این ادعا با ماهیت بخش حمل و نقل و مطالعات مربوطه سازگار است. ماهیت بخش حمل و نقل به گونه‌ای است که بیشترین ارتباط پسینی و پیشینی را با سایر بخش‌ها دارد، می‌تواند تغییرات سایر بخش‌ها (به طور خاص بخش حمل و نقل و بخش خدمات) را هم منعکس کند. در واقع در این پژوهش به دنبال بررسی تجربی این ادعا در اقتصاد ایران هستیم.

سوم این‌که آیا استفاده از روش‌های مختلف پیش‌بینی مانند شبکه عصبی مصنوعی[۱] و میانگین‌گیری مدل بیزین[۲] در ساخت شاخص به‌هنگام بخش خدمات می‌تواند به بهبود پیش‌بینی‌ها کمک کند؟

در ادامه ابتدا مروری به مطالعات انجام شده در این حوزه صورت می‌گیرد. سپس در بخش سوم داده‌های مورد استفاده در تحقیق تشریح می‌شوند و روش تحقیق مورد بررسی قرار می‌گیرد. در بخش چهارم نیز شاخص‌های ساخته شده برای بخش خدمات و بخش حمل و نقل مورد ارزیابی قرار می‌گیرد و در بخش پنجم جمع‌بندی صورت می‌گیرد.

۲. مروری بر ادبیات موضوع

در این مقاله از داده‌هایی یکی از زیربخش‌های سیستم حمل و نقل (داده‌های تردد شماری جاده‌ها) برای ساخت شاخص سنجش فعالیت بخش خدمات و بخش حمل و نقل استفاده شده است. برای اینکه مشخص شود جایگاه بخش حمل و نقل در اقتصاد به چه صورتی است، در این بخش ابتدا به مرور مطالعات در خصوص رابطه بین بخش حمل و نقل و بخش‌های دیگر اقتصاد می‌پردازیم. در قسمت دیگر نیز مطالعاتی که بر روی کنون‌بینی تمرکز داشته‌اند مرور می‌شود.

۲-۱. اهمیت بخش حمل و نقل

بخش حمل و نقل یکی از بخش‌های مهم کشورهای توسعه یافته به شمار می‌رود و همچنین یکی از پیش‌شرط‌های رشد و توسعه در کشورهای در حال توسعه محسوب می‌شود (کویل[۳] و همکاران، ۲۰۱۱). به علاوه بخش حمل و نقل مجرای حیاتی زنجیره عرضه کالاها و خدمات در اقتصاد محسوب می‌شود که نقل و انتقال مواد اولیه، کالاهای واسطه به تولیدکننده و رساندن کالاهای نهایی به بازار هدف به عهده این بخش است(لی و یو[۴]، ۲۰۱۶) بنابراین اثرگذاری و اثرپذیری این بخش از سایر بخش‌های اقتصاد بسیار بالا است. مطالعات متعددی مانند کیم[۵] (۲۰۰۲) فدرک[۶] و همکاران (۲۰۰۶) به رابطه مثبت رشد بخش حمل و نقل و رشد اقتصادی اشاره کردند. در این راستا لی و یو (۲۰۱۶)

---

1. Artificial neural networks (ANNs)
2. Bayesian model averaging (BMA)
3. Coyle
4. Lee & Yoo
5. Kim
6. Fedderke

با بکارگیری جدول داده ستانده اهمیت چهار زیربخش حمل و نقل جاده‌ای، ریلی، هوایی و دریایی در اقتصاد کره‌جنوبی را نشان دادند. بر اساس این مطالعه حمل و نقل جاده‌ای و ریلی نقش پررنگ‌تری در اقتصاد کره‌جنوبی داشته است.

در برخی مطالعات جهت رابطه بین رشد اقتصادی و رشد بخش حمل و نقل و دو طرفه یا یک طرفه بودن آن مورد بررسی قرار گرفته است. بیزاتلار[۱] و همکاران (۲۰۱۴) از داده‌های پانل ۱۵ کشور اروپایی برای بررسی رابطه بین بخش حمل و نقل و رشد GDP استفاده کردند. در این مطالعه از شاخص‌های مختلف بخش حمل و نقل مانند مصرف سوخت، حمل بار و حمل مسافر استفاده شده است. بر اساس نتایج برای کشورهای پیشرفته رابطه دوطرفه بین رشد اقتصادی و رشد شاخص‌های بخش خدمات برقرار است. آلاجیک[۲] (۲۰۱۷) در بررسی رابطه بین رشد بخش حمل و نقل و رشد GDP با استفاده از داده‌های آمریکا به این نتیجه رسید که رشد بخش حمل و نقل علت گرنجری رشد GDP است و رابطه یک طرفه بین این دو متغیر برقرار است.

در بررسی رابطه بین بخش حمل و نقل و سایر بخش‌های اقتصاد، در مطالعات نقش ویژه‌ای برای حمل و نقل بار لحاظ کرده‌اند. گنپ و وارجان[۳] (۲۰۱۸) با استفاده از داده‌های اتحادیه اروپا رابطه بین رشد حمل و نقل بار با رشد GDP را بررسی کردند و رابطه مثبت بین این دو متغیر را تایید کردند. گائو[۴] و همکاران (۲۰۱۶) نیز همین رابطه را برای کشور چین بررسی کرند و به این نتیجه رسیدند که تغییرات حمل و نقل بار در چین با رشد GDP همبستگی مثبتی دارد. بر اساس این مطالعه تغییرات در حمل و نقل بار می‌تواند دوران رکودی در اقتصاد چین را پیش‌بینی کند.

به واسطه گسترده ارتباط بخش حمل و نقل با سایر بخش‌ها، در مطالعات از شاخص‌های این بخش به عنوان شاخص منعکس‌کننده تغییرات کل اقتصاد استفاده می‌کنند. مطالعات وست[۵] (۱۹۸۵)، بلایندر[۶] (۱۹۸۶) و فایر[۷] (۱۹۸۹) رفتار ضدسیکلی موجودی انبار را تئوریزه کردند. به‌گونه‌ای که تغییرات در موجودی انبار به یکی از ویژگی‌های سیکل تجاری و مولفه‌های شناسایی رونق و رکود شد. از طرف دیگر لاهیری و یاهو[۸](۲۰۰۶) نشان دادند

---

1. Beyzatlar
2. Alagic
3. Gnap & Varjan
4. Gao
5. West
6. Blinder
7. Fair
8. Lahiri & Yao

که در زنجیره تولید تقریبا موجودی انبار و کالاهای واسطه نیاز به حمل و نقل دارند. بنابراین تغییرات بخش حمل و نقل منعکس کننده تغییرات در موجودی انبار و بخش حقیقی است و آمار بخش حمل ونقل منعکس کننده تغییرات در میزان فعالیت بخش‌های تولیدی است.

لاهیری[1] و همکاران (۲۰۱۰) و لاهیری و یاهو (۲۰۰۶) تطابق یک به یکی بین سیکل تجاری بخش حمل و نقل و کل اقتصاد پیدا کردند و اشاره کردند که سیکل در بخش حمل و نقل نسبت به سیکل تجاری کل اقتصاد کمی زودتر شروع شده و دیرتر به پایان می‌رسد. بر اساس این مطالعات شاخص بخش حمل و نقل قدرت پیش‌بینی کنندگی سیکل تجاری کل اقتصاد را دارد. گوزاویسیوس[2] و همکاران (۲۰۱۳) از شاخص‌های حمل و نقل برای کنون‌بینی سیکل‌های تجاری کشورهای اروپایی استفاده کردند و به این نتیجه رسیدند که شاخص‌های بخش حمل و نقل سیکل همزمانی با سیکل تجاری کل اقتصاد دارند و می‌توانند نشان دهنده رکود و رونق بخش حقیقی باشند.

بر اساس آمار حساب‌های ملی ایران ارزش افزوده بخش حمل و نقل تنها ۱۱،۵ درصد از ارزش افزوده کل بخش خدمات و حدود ۷ درصد GDP بدون نفت را شامل می‌شود، اما ماهیتی که دارد باعث می‌شود بخش حمل و نقل بیشتر از سهم خود در بخش‌های دیگر نقش داشته باشد. یوسفی (۱۳۹۱) با بررسی آمار جدول داده- ستانده ایران به این نتیجه رسید که بخش حمل و نقل در بین ۳۵ بخش هفتمین بخش با بیشترین پیوند پسین و سومین بخش با بیشترین پیوند پیشین است. همچنین کلانتر زاده و همکاران(۱۴۰۰)، مهرگان و دهقانی احمدآباد (۱۳۸۹) و رضایی و همکاران(۱۳۸۶) شواهدی مبنی بر رابطه مثبت بین رشد بخش حمل و نقل و رشد اقتصادی در ایران ارائه دادند. مطالعات متعدد دیگری مانند پهلوانی و همکاران(۱۳۹۳)، بابازاده و همکاران(۱۳۸۸) و ابوالحسنی هستیانی و همکاران(۱۳۹۸) نیز به نقش مثبت سرمایه‌گذاری بر رشد اقصادی در ایران تاکید کردند. بنابراین بخش حمل و نقل با توجه به کارکرد و ماهیت عملکردی‌اش در اقتصاد و رابطه‌ای که با سایر بخش‌ها دارد می‌تواند منعکس‌کننده تغییرات سایر بخش‌ها به خصوص بخش‌های مختلف خدمات باشد و می‌توان از شاخص‌های این بخش برای کنون‌بینی بخش خدمات استفاده کرد. در بخش بعد جایگاه بکارگیری کنون‌بینی در مطالعات مختلف مرور می‌شود.

---

1. Lahiri
2. Guzavicius

۲-۲. کنون بینی

کنون‌بینی به معنی پیش‌بینی زمان حال یا آینده نزدیک و یا گذشته خیلی نزدیک تعریف می‌شود و از ترکیب دو کلمه «کنون[۱]» و «پیش‌بینی[۲]» تشکیل شده است که مدت‌های طولانی در هواشناسی استفاده می‌شده و اخیرا در اقتصاد وارد شده است(جیونانی[۳] و همکاران، ۲۰۰۸). مفهوم کنون‌بینی به این دلیل در علم اقتصاد کاربرد دارد که آمارهای کلیدی تبیین کننده وضعیت کنونی اقتصاد با وقفه قابل توجهی در دسترس خواهند بود. به طور مثال تولید ناخالص داخلی در تواتر فصلی تهیه می‌شود که در بهترین حالت در کشورهای پیشرفته مانند آمریکا و انگلستان بعد از یک ماه از اتمام فصل منتشر می‌شوند (بانبورا[۴] و همکاران، ۲۰۱۳). کنون‌بینی در چنین شرایطی می‌تواند خلا در دسترس نبودن داده‌ها را پر کند. مبانی و پایه اصلی کنون‌بینی بهره‌گیری از اطلاعات در دسترس و با تواتر بالا برای بدست آوردن برآورد زودهنگام از متغیر هدف است که داده‌های رسمی آن با تاخیر منتشر می‌شود.

در این راستا مطالعات متعددی اقدام به کنون‌بینی متغیرهای اقتصاد کردند. بوئل و همکاران[۵](۲۰۲۱) در پژوهشی که در صندوق بین‌المللی پول انجام دادند اثر شیوع ویروس کرونا را برای چند کشور آفریقایی که محدودیت و وقفه دسترسی به داده‌های اقتصاد کلان وجود داشت بررسی کردند. در این پژوهش با بکارگیری مدل‌های عاملی و الگوریتم‌های فراگیری ماشین ، داده‌های جستجو در گوگل و داده‌های پرداخت موبایلی برای کنون‌بینی GDP برخی کشورهای آفریقایی استفاده کردند. بانبورا و همکاران (۲۰۱۳) با استفاده از مدل عامل پویای روزانه از اطلاعات روزانه شاخص S&P ، قیمت نفت خام، نرخ‌های اوراق خزانه و نرخ ارز برای کنون‌بینی GDP آمریکا استفاده کرده است. نتایج نشان می‌دهد که داده‌ها بخش عمده‌ای از پویایی‌های GDP را نشان می‌دهد. از دیگر کاربردهای روش‌های کنون‌بینی برای تبیین وضعیت موجود می‌توان به مطالعات، متسون[۶] (۲۰۱۱) برای رشد ۳۲ کشور، جیانونی و همکاران (۲۰۰۹) برای شاخص فعالیت اتحادیه اروپا، مورگادو[۷] و

---

1. Now
2. Forecasting
3. Giannone
4. Bańbura
5. Buell
6. Matheson
7. Morgado

همکاران (۲۰۰۷) برای GDP پرتغال، مارسلینو و شوماخر[1](۲۰۱۰) برای GDP آلمان اشاره کرد.

سوما[2] (۲۰۰۹) از داده‌های ماهانه تولید صنعتی، خرده فروشی، واردات، توریسم و شاخص‌های بخش حمل و نقل برای کنون بینی رشد اقتصادی در کشور یونان استفاده کرد. شوماخر و بریتنگ[3] (۲۰۰۸) از داده‌های ماهانه تولید صنعتی بخش‌های مختلف، نرخ ارز، نرخ بهره، سفارش خرید از خارج، شاخص قیمت‌ها، شاخص قیمت سهام و .. برای ساخت شاخص کنون‌بینی GDP آلمان استفاده کرد. در این پژوهش که از الگوریتم حداکثرسازی امیدریاضی[4] و مدل‌های عاملی برای ساخت شاخص استفاده شد. نتایج مقایسه خطای پیش‌بینی شاخص ساخته شده با شاخص‌های معیار نشان داد که شاخص‌های ساخته شده خطای کمتری دارند.

مدل‌های مختلفی برای کنون‌بینی در مطالعات مورد استفاده قرار گرفته است. ابزارهای اقتصادسنجی (مانند رگرسیون و مدل‌های عاملی) و الگوریتم‌های یادگیری ماشین (مانند شبکه عصبی) از پرکاربردترین ابزارهایی هستند که هم برای پیش‌بینی و هم برای کنون‌بینی مورد استفاده قرار می‌گیرد. اما مسئله‌ای که در کنون‌بینی اهمیت بیشتری پیدا می‌کند، مسئله عدم تطابق تواتر داده‌های متغیرهای مورد استفاده است. معمولا در کنون‌بینی متغیر هدف تواتر پایین دارد (مثلا GDP که تواتر فصلی دارد) و متغیرهایی که به کمک آن تلاش می‌شود که کنون‌بینی از متغیر هدف انجام شود تواتر بالا دارند (مثلا نرخ ارز و متغیرهای مالی که تواتر روزانه یا ماهانه دارند). در این صورت برای اینکه ناسازگاری در تواتر داده‌ها برطرف شود عمدتا دو رویکرد مورد استفاده می‌شود.

اولین روش مدل‌های معادلات پل[5] است که در آن از داده‌های تواتر بالا برای پیش‌بینی متغیر با تواتر پایین استفاده می‌شود. در این روش از تجمیع داده‌های با تواتر بالا و تبدیل آن‌ها به داده‌های با تواتر پایین‌تر (سازگار با تواتر متغیر وابسته) استفاده می‌شود. بعد از هم‌خوان کردن تواتر داده‌ها معادله بدست آمده از روش‌های رگرسیونی برآورد می‌شود. این روش به دلیل سادگی در مطالعات متعددی مورد استفاده قرار گرفته است. مطالعات

---

1. Marcellino & Schumacher
2. Tsouma
3. Schumacher & Breitung
4. expectation–maximization (EM)
5. bridge equations

اینجنیتو و ترهان[۱] (۱۹۹۶) و رونستلر و سدیلوت[۲] (۲۰۰۳) از مطالعات اولیه بودند که این روش را در کنون‌بینی متغیرهای اقتصادی بکار بردند. گالوز سوریانا[۳] (۲۰۲۰) نشان داده است که استفاده از داده‌های تواتر بالا در پیش‌بینی و کنون‌بینی متغیر رشد اقتصادی با استفاده از روش معادلات پل دقت پیش‌بینی را نسبت به مدل‌های عاملی بیشتر می‌کند. دومین روش برای بکارگیری متغیرهای با تواتر متفاوت در کنون‌بینی، مدل نمونه‌گیری داده‌های ترکیبی[۴] (MIDAS) است. در این روش از معادلات رگرسیونی استفاده می‌شود که مشاهدات متغیر با تواتر پایین را مستقیما به مشاهدات متغیرهای با تواتر بالا مرتبط می‌کند. در این روش تجمیع داده‌ها اتفاق نمی‌افتد. این روش ابتدا توسط مطالعات نظیر قیسلز[۵] و همکاران (۲۰۰۶) برای پیش‌بینی متغیرهای مالی استفاده شد و سپس مطالعاتی توسط مطالعات کلمنتس و کالواو[۶] (۲۰۰۸و۲۰۰۹) برای اولین بار از این روش برای پیش‌بینی GDP استفاده کردند. در این راستا شوماخر [۷] (۲۰۱۶) دو روش معادلات پل و مدل نمونه‌گیری داده‌های ترکیبی را با هم مقایسه کرد و به این نتیجه رسید که این دو روش در مدل‌های مختلف عملکرد متفاوتی دارند و نمی‌توان به طور قطع گفت کدام روش عملکرد بهتری نسبت به دیگری دارد.

در مجموع، کنون‌بینی متغیرهای اقتصادی یکی از رویکردهای متواتر در رصد وضعیت فعلی اقتصاد است که توسط مطالعات متعددی بسط داده شده و در مراکز سیاست‌گزاری اقتصادی نیز مورد استفاده قرار می‌گیرند. در این پژوهش با استفاده از کلان‌داده بخش حمل و نقل به دنبال کنون‌بینی رشد ارزش افزوده بخش خدمات هستیم. دو مورد از نوآوری این پژوهش این است که اولا از کلان‌داده تردد شماری وسایل نقلیه برای کنون بینی متغیر اقتصادی برای اولین بار استفاده شده است و ثانیا عملکرد مدل‌های مختلف شبکه عصبی و میانگین‌گیری مدل بیزین در پیش‌بینی مورد ارزیابی قرار گرفته است.

---

1. Ingenito and Trehan
2. Rünstler & Sédillot
3. Gálvez-Soriano
4. Mixed-data sampling
5. Ghysels
6. Clementsand Galvao
7. Schumacher

۳. معرفی داده‌ها روش تحقیق

یکی از نوآوری‌های این پژوهش بکارگیری کلان‌داده ترددشماری برای پیش‌بینی یک متغیر اقتصادی در ایران است. با توجه به این که از این داده‌ها در حوزه اقتصاد کمتر استفاده شده است، در این بخش ابتدا این مجموعه داده‌ها تشریح می‌شود. سپس در بخش بعدی مدل‌های بکار برده شده برای پیش‌بینی مرور می‌شود.

۳-۱. داده‌ها

با توجه به نقش محوری بخش حمل و نقل و بررسی داده‌های با تواتر بالا بررسی عملکرد شاخص‌های مربوط به بخش حمل و نقل برای ساختن شاخص فعالیت برای بخش خدمات بهترین گزینه است. در این راستا مجموعه داده‌های تردد شماری وسایل نقلیه در جاده‌های کشور که توسط سازمان راهداری و حمل و نقل جاده‌ای جمع‌آوری و بر روی سایت[۱] ارائه می‌شود می‌تواند قابل بررسی باشد. این داده‌ها تقریبا برای تمام محورهای تردد جاده‌ای کشور به صورت ساعتی و هم روزانه اطلاعات تردد انواع وسایل نقلیه را ارائه می‌دهد و از این لحاظ کلان‌داده به حساب می‌آید. در این پژوهش از داده‌های روزانه بیش از ۲۵۹۰ نقطه از جاده‌های کشور در بازه زمانی ۱ فروردین ۱۳۹۴ تا ۳۰ مهر ۱۴۰۰ استفاده شده است. در این پایه اطلاعاتی تعداد تردد پنج نوع یا کلاس از وسایل نقلیه شمارش شده است که کلاس۱ سواری و وانت، کلاس۲ کامیونت و کامیونهای کوچک و مینی‌بوس، کلاس۳ کامیون‌های معمولی کمتر از ۱۰ متر و سه محوره‌ها، کلاس ۴ اتوبوس، کلاس ۵ تریلرها و باربرهای بالاتر از سه محور می‌باشد. با توجه به اینکه در هر ۲۵۹۰ ایستگاه تردد شماری پنج نوع تردد فوق شمارش می‌شود در مجموع داده‌ها مشتمل بر ۱۲ هزار و ۹۵۰ سری زمانی روزانه است که شامل ۵ میلیون و ۱۴۱ هزار مشاهده بوده است.

همان‌طور که در مطالعات مرور شد حمل و نقل مسافر و حمل و نقل بار در برخی مطالعات از هم تفکیک شدند و بیشتر مطالعات تاکید کردند که حمل و نقل بار بیشتر می‌تواند واقعیت‌های اقتصاد را نشان دهد. در این داده‌ها نیز تردد انواع مختلف وسایل نقلیه با توجه به کاربری که دارند محتوای اطلاعاتی متفاوتی دارد. شکل ۱ سهم هر یک از انواع وسایل نقلیه از تردد را در بازه ۱۳۹۴ تا ۱۴۰۰ نشان می‌دهد. همان‌طور که مشخص است سهم قابل توجهی از ترددها یعنی بیش از ۸۵ درصد متعلق به سواری‌ها و وانت‌ها است و بقیه انواع وسایل نقلیه کمتر از ۱۵ درصد تردد را در بر می‌گیرند. شکل ۳ روند کل ترددهای

---

[۱]. آدرس سایت https://141.ir/trafficcounterfiles

ماهانه را نشان می‌دهد که بر این اساس بیشترین تردد در بین ماه‌های مورد بررسی شهریور ۱۳۹۸ با حدود ۶۰۰ میلیون تردد بوده است. همچنین شکل ۲ رشد تردد ماهانه نسبت به سال قبل را نشان می‌دهد[۱].

علاوه بر این داده‌ها از آمار رشد ارزش افزوده بخش خدمات به قیمت ثابت و بخش حمل و نقل به قیمت ثابت سال ۱۳۹۰ نیز استفاده شده است. این آمار از داده‌های حساب‌های ملی تهیه شده توسط مرکز ملی آمار گرفته شده است.

شکل (۱): سهم تردد انواع وسایل نقلیه از کل ترددها در راه‌های کشور (درصد) در پنج سال اخیر

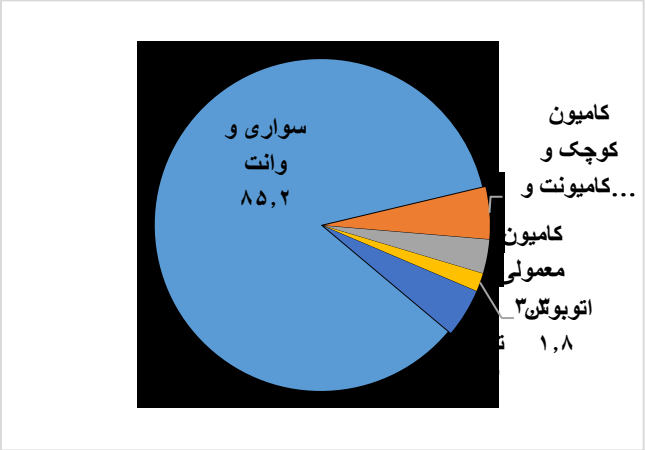

شکل (۲): رشد تعداد ترددهای ماهانه انواع وسایل نقلیه در کل کشور

شکل (۳): روند تعداد ترددهای ماهانه انواع وسیله نقلیه در کل کشور

[۱]. بر این اساس فرودین ۱۳۹۹ با توجه به مسائل مربوط به قرنطینه کردن ناشی از شیوع کرونا میزان ترددها نسبت به مدت مشابه بیش از ۵۰ درصد کاهش داشته است که البته این کاهش قابل توجه باعث شده رشد ترددها در فروردین ۱۴۰۰ نسبت به سال قبل به بیش از ۷۰ درصد برسد.

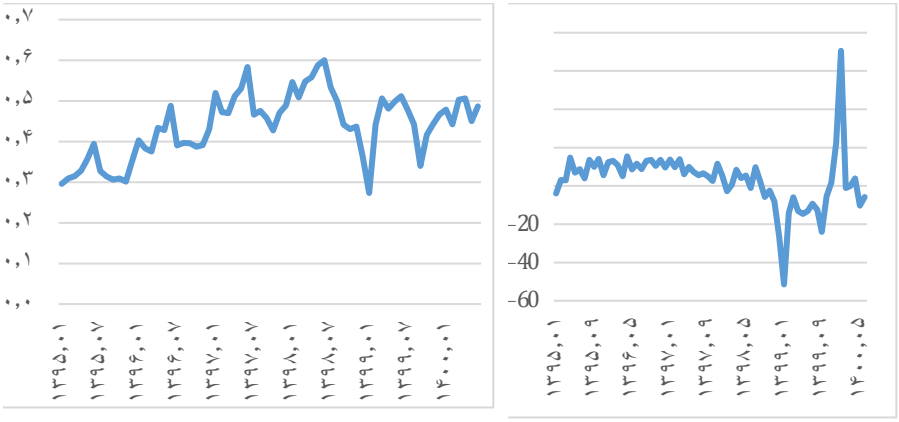

منبع: سازمان راهداری و حمل و نقل جاده‌ای و محاسبات پژوهش

۳-۲. روش تحقیق

۳-۲-۱. روش‌های شاخص‌سازی

برای ارزیابی قدرت پیش‌بینی داده‌های تردد شماری، لازم است که سری‌های زمانی این دیتابیس با هم ترکیب شوند. به عبارت دیگر بیش از ۱۲ هزار سری زمانی در این دیتابیس وجود دارد(بر حسب نقاط مختلف در جاده‌های کشور و نوع وسیله نقلیه) که روش‌ها و مدل‌های متفاوتی وجود دارد که می‌توان آنها را با هم ترکیب کرد در این پژوهش از سه روش زیر استفاده می‌شود:

۱- شاخص تجمیعی: ساده‌ترین روش برای استفاده از داده‌ها در راستای ساختن شاخص فعالیت بخش خدمات تجمیع داده‌های ۲۵۹۰ ایستگاه تردد شماری در سطح جاده‌های کل کشور با هم‌دیگر است. اما به منظور بهبود عملکرد شاخص‌های تجمیعی ساده داده‌های پرت حذف شده‌اند و سپس تجمیع صورت گرفته است. به گونه‌ای که ۱۰ درصد از مشاهدات که روند غیرمتعارف داشته و کمترین همبستگی را با شاخص هدف (ارزش افزوده بخش خدمات) داشته حذف شدند. در گام دوم بعد از حذف داده‌های پرت، داده‌های روزانه به تواترهای فصلی تبدیل شد تا قابلیت مقایسه با داده‌های کلان را داشته باشد. در گام بعدی برای شاخص‌سازی از جمع ساده بر اساس نوع وسایل نقلیه استفاده شده است. همان‌طور که اشاره شد تردد خودروها به تفکیک پنج نوع ثبت می‌شود. بنابراین پنج سری زمانی از سال ۱۳۹۴ تا ۱۴۰۰ ایجاد می‌شود که به ترتیب ۱- تردد ماشین‌های سواری و وانت ۲- کامیونت و مینی‌بوس ۳- کامیون‌های معمولی ۴- اتوبوس و ۵- تریلرها هستند. علاوه بر پنج سری که بر اساس نوع وسایل نقلیه ساخته شد، سری‌های زمانی تردد کل

وسایل نقلیه (جمع همه پنج مورد)، تردد کامیون‌ها و تریلرها (از جمع مورد ۳ و ۵) و ماشین‌های سنگین (جمع موارد ۲، ۳ و ۵) نیز ساخته شده است. از این روش هشت شاخص در مجموع محاسبه می‌شود.

۲-شبکه عصبی مصنوعی: شبکه عصبی مصنوعی یک کلاس از الگوریتم‌های یادگیری ماشین هستند که مانند بسیاری از الگوریتم‌های یادگیری ماشین برای طبقه‌بندی و پیش‌بینی متغیرهای پیوسته مورد استفاده قرار می‌گیرند. اجزای شبکه عصبی عبارت‌اند از ورودی‌ها (متغیرهای پیش‌بینی کننده) خروجی (متغیر هدف) نرون‌ها یا گره‌ها[1]، وزن‌های متغیرهای ورودی و توابع تبدیل هستند. نرون‌ها در این شبکه در سه لایه ورودی، لایه‌های میانی یا پنهان و لایه خروجی قرار گرفته‌اند. کار پردازش اطلاعات در لایه‌های میانی و خروجی انجام می‌شود. یک مثال ساده از یک شبکه عصبی مصنوعی با H گره یا نرون پنهان (نرون‌های درون لایه پنهان) و I متغیر ورودی در قالب سری زمانی به شکل زیر خواهد بود:

$$y_{t+1} = \sum_{h=1}^{H} \beta_{hg} \left(\sum_{i=1}^{I} \gamma_{hi} p_i - \gamma_{0i} \right) - \beta_0 \qquad (۱)$$

که در آن $p = [y_t, \dots, y_{t-n}, x'_{t+1}, \dots, x'_{t-k}]$ بردار متغیرهای ورودی و وقفه‌های متغیر وابسته و متغیرهای ورودی است. بردار ضرایب $\beta = [\beta_1, \dots, \beta_H]$ و $\gamma = [\gamma_1, \dots, \gamma_I]$ به ترتیب وزن‌های لایه خروجی و لایه پنهان نیز نامیده می‌شوند. ضرایب β_0 و γ_{0i} بایاس۲ نامیده می‌شود. بایاس در خصوص اینکه یک نرون فعال باشد یا خیر موثر خواهد بود. تابع g تابع فشرده‌ساز۳ نامیده می‌شود که جمع وزنی نرون‌های لایه قبلی منهای بایاس را در یک بازه مشخص (معمولا بین ۱ تا صفر) قرار می‌دهد(لوئرمن و ماس۴،۲۰۱۹). خروجی مدل شبکه عصبی با توجه به چهار مورد می‌تواند تغییر کند:

- تعداد لایه‌ها یا نرون‌های پنهان،
- تعداد وقفه‌های ورودی‌ها که باید در مدل شبکه عصبی لحاظ شود
- نوع الگوریتم یادگیری (لونبرگ- مارکوارت[5]، منظم‌سازی بیزی[6] و گرادیان مزدوج[7])

---

1. Neurons or Nods
2. bias
3. squashing function
4. Loermann & Maas
5. Levenberg-Marquardt
6. Bayesian regularization
7. scaled conjugate gradient

- شرایط اولیه و نمونه‌گیری (با توجه به اینکه عملکرد الگوریتم‌های یادگیری به شرایط اولیه و نمونه‌گیری بستگی دارند، اجرای هر بار مدل شبکه عصبی با توجه به نمونه‌گیری متفاوت خروجی متفاوتی ارائه می‌دهد)

در این پژوهش با توجه به تعداد قابل توجه ورودی‌ها از الگوریتم یادگیری گرادیان مزدوج استفاده شده است. اما برای تعیین تعداد وقفه‌ها و تعداد لایه‌های پنهان خروجی شبکه عصبی برای حالت‌های مختلف تعداد یک تا چهار وقفه و لایه‌های پنهان ۵، ۱۰،۱۵ و ۲۰ لایه گرفته شد و با توجه به مقادیر متغیر هدف(رشد بخش خدمات) میانگین مربعات خطا (MSE) برای حالت‌های مختلف محاسبه شد. همچنین برای اینکه اثر شرایط اولیه حذف شود از هر حالت (تعداد مشخص لایه و وقفه) ۱۰۰ بار خروجی گرفته شد و با توجه میانگین MSEها تعداد وقفه‌ها و لایه‌های پنهان بهینه مشخص شد. سپس با توجه به مشخص شدن تعداد لایه پنهان و تعداد وقفه‌ها مدل برای مشاهدات دورن‌نمونه آموزش داده شد.

۳- میانگین‌گیری مدل بیزین[1]: انتخاب متغیر توضیحی برای مدل رگرسیون یکی از چالش‌های اقتصادسنجی است که راه‌کارهای متعددی دارد. روش میانگین‌گیری که با استفاده از قابلیت آمار بیزی پژوهشگر را در انتخاب متغیرهای ورودی به مدل کمک می‌کند. فرض کنیم که متغیر هدف در اینجا y_t باشد و کل متغیرهای در دسترس که می‌توان به‌طور بالقوه برای توضیح دادن متغیر y_t قرار گیرد در ماتریس متغیرهای بالقوه X با ابعاد k×T قرار گیرد که در آن k تعداد متغیرهای بالقوه است. یک مدل M_i را می‌توان به صورت زیر نوشت:

$$M_i: y = X_i\beta_i + \varepsilon_i \qquad (۲)$$

با توجه به تعداد متغیرهای توضیحی بالقوه می‌توان 2^k مدل داشت. بنابراین در خصوص اینکه کدام متغیر باید وارد مدل شود و اثر هر متغیر بالقوه بر متغیر وابسته چیست نااطمینانی وجود دارد. توزیع پسین اثر یک متغیر بالقوه j بر متغیر وابسته(b_j) را می‌توان به صورت زیر نوشت:

$$p(b_j|y,X) = \sum_{i=1}^{2^k} p(b_j|y,X,M_i) \times p(M_j|y,X) \qquad (۳)$$

[1]. Bayesian Model Averaging

اولین توزیع سمت راست معادله بالا توزیع پسین b_j به شرط مدل i ام است و دومین توزیع، توزیع پسین مدل i ام است. به عبارت دیگر معادله بالا توزیع برای ضرایب همه متغیرهای بالقوه محاسبه می‌کند که از میانگین وزنی توزیع‌های آن ضرایب در مدل‌های مختلف است و وزن استفاده شده در این میانگین وزنی احتمال وقوع مدل‌ها است. اما یک مشکل اصلی در بدست آوردن توزیع بالا تعداد بالای مدل‌ها یعنی 2^k است. در این روش الگوریتمی تعریف می‌شود که تنها زمانی مدل M_i به M_j حرکت می‌کند که M_j قدرت توضیح‌دهندگی بالاتری داشته باشد (مجاب و همکاران،۱۳۹۲).

در این روش با استفاده از احتمال وقوع پسین[1] احتمال وقوع هر مدل محاسبه می‌شود(مهرآرا و غضنفری، ۱۳۹۳). سپس می‌توان مدل‌ها را بر اساس بیشترین احتمال وقوع رتبه‌بندی کرد و بهترین مدل را انتخاب کرد. در این پژوهش بعد از طی این مراحل بهترین مدل، میانگین پنج مدل برتر و میانگین ۱۰۰ مدل برتر انتخاب شده و عملکرد شاخص محاسبه شده از این سه روش مورد بررسی قرار گرفته است.

۳-۲-۲. معیارهای ارزیابی شاخص‌ها

به منظور پاسخ به این سوال که آیا داده‌های تردد‌شماری می‌تواند به بهبود پیش‌بینی و کنون‌بینی بخش خدمات و بخش حمل و نقل کمک کند یا خیر نیاز است که یک معیار ارزیابی معرفی شود. در این راستا مدل‌های ARMA که از اطلاعات گذشته خود سری برای پیش بینی استفاده می‌کنند به عنوان معیار در نظر گرفته شد. برای بکارگیری این مدل‌ها مراحل زیر طی شده است:

- تمام ترکیب‌های AR و MA و ARMA از وقفه یک تا چهار برای رشد ارزش افزوده بخش خدمات و همچنین بخش حمل و نقل برآورد می‌شود. در برآورد بخشی از داده‌ها برای ارزیابی برون نمونه‌ای وارد برآورد نمی شوند.
- همه مدل‌ها با تمام وقفه‌ها در قالب مدل ARMA فصلی[2] نیز برآورد می‌شود.
- از تمام برآوردهای انجام شده پیش‌بینی‌های یک تا چهار گام به جلو گرفته می‌شود.
- برای انتخاب بهترین مدل ARMA از معیار شاخص مجذور میانگین مربعات خطا[3] RMSE استفاده می‌شود. به گونه‌ای که برای هر گام پیش‌بینی RMSE محاسبه شده و سپس میانگین RMSE های یک تا چهارگام پیش‌بینی هر مدل محاسبه می شود.
- وقفه‌هایی از مدل ARMA انتخاب می‌شود که کمترین RMSE را داشته باشد.

---

1. Posterior Odds Ratio
2. Seasonal ARMA
3. Root Mean Square Error (RMSE)

لازم به ذکر است که در مجموع ترکیب‌های مختلف وقفه‌های AR و MA و ARMA فصلی و غیرفصلی برای هر بخش خدمات و بخش حمل و نقل ۶۱ مدل مختلف برآورد شد و RMSE آنها حساب شد و بهترین مدل برای هر بخش محاسبه شد. لازم به ذکر است که برای برآورد این مدل‌ها رشد ارزش افزوده بخش خدمات (و رشد ارزش افزوده بخش حمل و نقل) به قیمت ثابت در یک فصل نسبت به فصل مشابه سال قبل در بازه فصل اول ۱۳۹۴ تا فصل اول ۱۳۹۹ به عنوان متغیر وابسته در نظر گرفته شده است. بر اساس حداقل بودن RMSE برای بخش خدمات SARMA(3,3)(s مربوط به لحاظ فصلی است) و برای بخش حمل و نقل MA4 انتخاب شد.

مقایسه و ارزیابی قدرت پیش‌بینی شاخص‌های ساخته شده در دو دوره برون‌نمونه‌ای و درون‌نمونه‌ای انجام می‌شود و معیارهای ارزیابی بکار برده شده در این پژوهش دو شاخص زیر است:

- شاخص خطای پیش‌بینی علامت (S) : تعداد دوره‌هایی که علامت رشد شاخص مورد ارزیابی مخالف علامت رشد شاخص هدف (رشد ارزش افزوده بخش خدمات) بوده تقسیم بر تعداد مشاهدات

$$F_t = \begin{cases} 1 & if\ sign(y_t) \neq sign(\widehat{y_t}) \\ 0 & otherwise \end{cases} \qquad S = \frac{\sum_{t=1}^{T} F_t}{T} \qquad (۴)$$

- شاخص مجذور میانگین مربعات خطا[1] (RMSE) :

$$RMSE = \frac{\sum_{t=1}^{T}(y_t - \widehat{y_t})^2}{T} \qquad (۵)$$

۴. نتایج مدل‌ها

برای پاسخ به سوال اصلی پژوهش که «آیا شاخص‌های مستخرج از دیتابیس تردشماری می‌تواند منعکس کننده تغییرات بخش خدمات و حمل و نقل باشد یا خیر؟» با استفاده از داده‌های تردد شماری شاخص‌هایی از سه روش (روش تجمیعی، مدل شبکه عصبی و روش میانگین‌گیری مدل بیزین) برای دو بخش خدمات و حمل و نقل ساخته شد. در برآورد همه مدل‌های شبکه عصبی و میانگین‌گیری مدل بیزین رشد ارزش افزوده بخش خدمات (و رشد ارزش افزوده بخش حمل و نقل) به قیمت ثابت در یک فصل نسبت به فصل مشابه سال قبل در بازه فصل اول ۱۳۹۴ تا فصل اول ۱۳۹۹ به عنوان متغیر هدف

[1]. Root Mean Square Error (RMSE)

یا متغیر وابسته در نظر گرفته شد. همچنین متغیرهای توضیحی مدل‌های شبکه عصبی و میانگین‌گیری بیزین ۱۲ هزار و ۹۵۰ سری زمانی تردد شماری وسایل نقلیه مختلف در نقاط مختلف کشور بوده است. همچنین از داده‌های فصل دوم ۱۳۹۹تا فصل اول ۱۴۰۰ برای ارزیابی برون‌نمونه‌ای مدل‌ها استفاده شده است. نتایج ارزیابی برآوردهای مختلف در این بخش ارائه می‌شود.

۴-۱. بخش خدمات

اولین و ساده‌ترین روش محاسبه‌های شاخص‌های تجمیعی است که نتایج ارزیابی ۸ شاخص تجمیعی در جدول ۱ برای دو معیار ارزیابی در دو دوره درون‌نمونه و برون‌نمونه آورده شده است. بر اساس نتایج از بین شاخص‌های تجمیعی در دوره درون‌نمونه شاخص تردد ماشین‌های سنگین از نظر RMSE و شاخص تریلر و کامیون‌ها از نظر معیار خطای علامت بهترین عملکرد را داشتند. بر این اساس رشد شاخص تردد تریلرها و کامین‌ها تنها در ۶ درصد از مشاهدات علامتی مخالف علامت رشد بخش خدمات داشته است. برای دوره برون‌نمونه‌ای شاخص تردد ماشین‌های سنگین از نظر هر دو معیار بهترین شاخص تجمیعی است. بنابراین می‌توان گفت که شاخص تردد ماشین‌های سنگین بهترین تطابق و کمترین خطای پیش‌بینی را داشته است و شاخص منتخب برای بخش خدمات خواهد بود. شکل ۴ روند شاخص منتخب با رشد ارزش افزوده بخش خدمات ترسیم شده است. قسمت تیره رنگ نمودار مقایسه برون‌نمونه‌ای شاخص محاسبه شده (رشد تردد ماشین‌های سنگین) با رشد ارزش افزوده بخش خدمات را نشان می‌دهد.

جدول (۱): نتایج ارزیابی رشد شاخص‌های تجمیعی تردد وسایل نقلیه مختلف در مقایسه با رشد ارزش افزوده بخش خدمات

		شاخص‌های تردد							
		سواری و وانت	کامیونت و مینی‌بوس	کامیون	اتوبوس	تریلرها	کل	تریلرها و کامیون‌ها	ماشین‌های سنگین
درون‌نمونه	شاخص خطای پیش‌بینی علامت	۰،۲۴	۰،۵۳	۰،۱۸	۰،۲۹	۰،۱۲	۰،۱۸	۰،۰۶	۰،۱۲
	RMSE	۸،۷۲	۶،۱۰	۷،۲۴	۱۰،۸۷	۶،۱۵	۷،۵۴	۴،۸۶	۲،۲۷
برون‌نمونه	شاخص خطای پیش‌بینی علامت	۰	۰	۰،۲۵	۰،۲۵	۰	۰	۰،۲۵	۰
	RMSE	۱۱،۱	۵،۲	۴،۶	۱۴،۲	۴،۶	۱۰،۲	۴	۳،۶

منبع : محاسبات پژوهش

شکل (۴): روند شاخص تجمیعی منتخب با رشد ارزش افزوده بخش خدمات

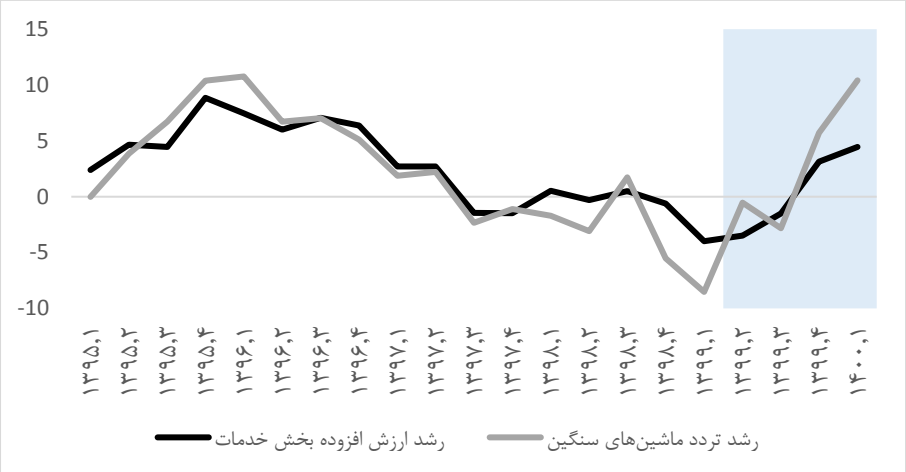

منبع : محاسبات پژوهش – مرکز آمار ایران

در جدول ۲ شاخص‌های بدست آمده از روش شبکه عصبی، میانگین‌گیری مدل بیزین و مدل ARMA منتخب بر اساس دو معیار معرفی شده در دو دوره درون نمونه و برون نمونه ارزیابی شده‌اند. شاخص‌های برآوردی از روش‌های مختلف در شکل ۵ و شکل ۶ ترسیم شده و با رشد ارزش افزوده مقایسه شده است. قسمت تیره رنگ نمودار مقایسه

برون‌نمونه‌ای شاخص محاسبه شده به روش‌های مختلف با رشد ارزش افزوده بخش خدمات را نشان می‌دهد. بر این اساس می‌توان به نکات زیر اشاره کرد:

- شاخص منتخب تجمعی (تردد ماشین‌های سنگین) در مقایسه با عملکرد مدل ARMA منتخب از نظر شاخص خطای پیش‌بینی علامت عملکرد بهتری در هر دو دوره درون‌نمونه‌ای و برون نمونه‌ای داشته است ولی از منظر معیار RMSE عملکرد بدتری از مدل SARMA(3,3) داشته است.
- شاخص برآوردی شبکه عصبی (بر اساس داده‌های تردد شماری) هم از نظر شاخص خطای پیش‌بینی علامت و هم RMSE عملکرد بهتری نسبت به مدل SARMA(3,3) داشته است.
- اگرچه خروجی بهترین مدل مستخرج از روش میانگین‌گیری مدل بیزین در دوره درون‌نمونه عملکرد بهتری نسیت سایر مدل‌ها داشته و در دوره برون‌نمونه‌ای بر اساس شاخص خطای پیش‌بینی علامت عملکرد مشابه برآورد شبکه عصبی و مدل ARMA منتخب داشته اما با توجه به خطای بالای RMSE در دوره برون‌نمونه‌ای نمی‌تواند مدل منتخب باشد.
- در مجموع بر اساس دوره برون‌نمونه‌ای شاخص برآوردی شبکه عصبی کمترین خطا را نسبت به مدل‌های رقیب داشته است و مدل منتخب برای پیش‌بینی رشد بخش خدمات خواهد بود.

جدول (۲): نتایج ارزیابی شاخص‌های مدل‌های مختلف برای پیش‌بینی بخش خدمات

		شبکه عصبی	میانگین‌گیری مدل بیزین			بهترین مدل ARMA
			بهترین مدل	پنج مدل برتر	۱۰۰ مدل برتر	SARMA(3,3)
درون‌نمونه	شاخص خطای پیش‌بینی علامت	۰	۰	۰	۰٫۲	۰٫۲
	RMSE	۱٫۹۶	۰٫۲۱	۰٫۲۱	۳٫۸۰	۱٫۳۳
برون‌نمونه	شاخص خطای پیش‌بینی علامت	۰٫۲۵	۰٫۲۵	۰٫۵	۰٫۵	۰٫۲۵
	RMSE	۰٫۶	۶٫۴	۳٫۸	۲٫۷	۳٫۳

منبع : محاسبات پژوهش

شکل (۵): برآورد رشد بخش خدمات با استفاده از مدل شبکه عصبی و sARMA و مقایسه با رشد ارزش افزوده این بخش در دوره‌های برون‌نمونه و درون‌نمونه

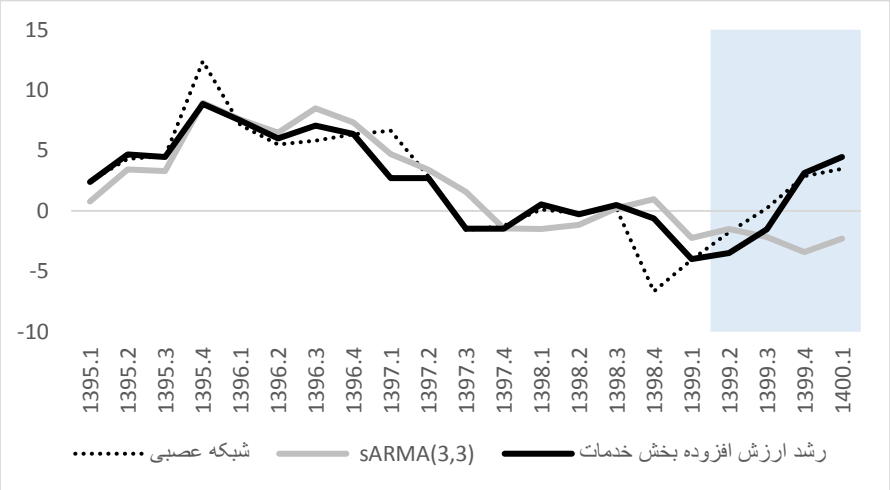

منبع : محاسبات پژوهش – مرکز آمار ایران

شکل (۶): برآورد رشد بخش خدمات با استفاده مدل‌های منتخب میانگین‌گیری مدل بیزین و مقایسه با رشد ارزش افزوده بخش خدمات در دوره درون‌نمونه و برون‌نمونه

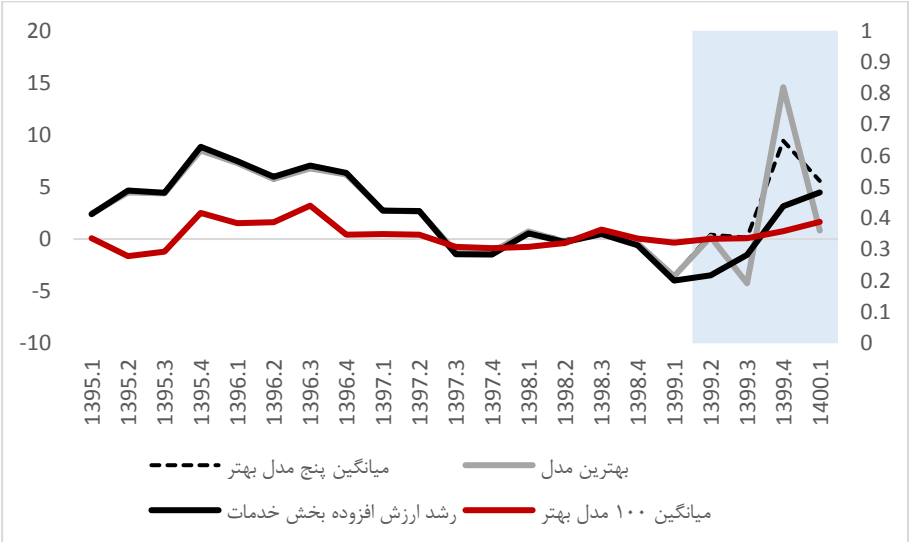

منبع : محاسبات پژوهش – مرکز آمار ایران

۴-۲. بخش حمل و نقل

برای ارزیابی اینکه آیا شاخص‌های هشت‌گانه تجمیعی تردد وسایل نقلیه می‌تواند تغییرات بخش حمل و نقل را نمایندگی کند یا خیر، بعد از محاسبه شاخص‌ها از آنها رشد گرفته و با دو معیار ارزیابی معرفی شده (RMSE و شاخص خطای پیش‌بینی علامت) با رشد ارزش افزوده حقیقی بخش حمل و نقل مقایسه شده است که نتایج این ارزیابی‌ها در جدول ۳ منعکس شده است. بر اساس این نتایج رشد تردد تریلرها هم در دوره درون‌نمونه‌ای و هم در دوره برون نمونه‌ای کمترین خطای پیش‌بینی علامت را نسبت به سایر شاخص‌ها داشته است. همچنین این شاخص در دوره برون‌نمونه‌ای کمترین RMSE را داشته است. بنابراین می‌توان گفت در بین شاخص‌های تجمیعی، شاخص تردد تریلرها و کامیون‌ها کمترین خطا را داشته است. شکل ۷ رشد ارزش افزوده بخش حمل و نقل را با شاخص محاسبه شده مقایسه کرده است. قسمت تیره رنگ نمودار مقایسه برون‌نمونه‌ای شاخص محاسبه شده با رشد ارزش افزوده بخش حمل و نقل را نشان می‌دهد.

جدول (۳): نتایج ارزیابی رشد شاخص‌های تجمیعی تردد وسایل نقلیه مختلف در مقایسه با رشد ارزش افزوده حمل و نقل

		شاخص تردد						
		سواری و وانت	کامیونت و مینی‌بوس	کامیون	اتوبوس	تریلرها	کل	تریلرها و کامیون‌ها	ماشین‌های سنگین
درون‌نمونه	شاخص خطای پیش‌بینی علامت	۰،۲۴	۰،۵۳	۰،۱۸	۰،۲۹	۰،۱۲	۰،۱۸	۰،۰۶	۰،۱۲
	RMSE	۸،۳۶	۷،۵۸	۷،۸۱	۱۱،۵۸	۵،۲۲	۷،۳۹	۴،۶۹	۳،۶۱
برون‌نمونه	شاخص خطای پیش‌بینی علامت	۰،۲۵	۰،۲۵	۰	۰،۵۰	۰،۲۵	۰،۲۵	۰	۰،۲۵
	RMSE	۱۱،۴۱	۴،۲۳	۳،۰۲	۱۵،۴۷	۲،۲۹	۱۰،۲	۱،۲۸	۱،۴۳

منبع : محاسبات پژوهش

شکل (۷): روند شاخص‌های تجمیعی منتخب با رشد ارزش افزوده بخش حمل و نقل

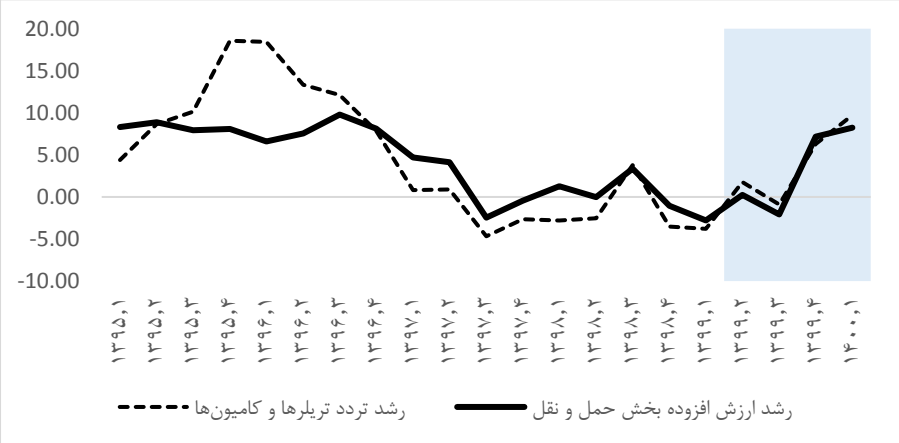

منبع : محاسبات پژوهش – مرکز آمار ایران

بعد از برآوردی مدل‌های شبکه عصبی و مدل‌های منتخب روش میانگین‌گیری مدل بیزین، از این مدل‌ها برای رشد ارزش افزوده بخش حمل و نقل شاخص برآوردی محاسبه می‌شود که در شکل ۸ و شکل ۹ به نمایش درآمده است. برای ارزیابی این شاخص‌ها با دو معیار معرفی شده رشد این شاخص‌ها با رشد ارزش افزوده بخش حمل و نقل مقایسه شده است. قسمت تیره رنگ نمودارها مقایسه برون‌نمونه‌ای شاخص‌های محاسبه شده با رشد ارزش افزوده بخش حمل و نقل را نشان می‌دهد. نکات اصلی این مقایسه به شرح زیر است:

- شاخص تجمیعی منتخب در جدول ۱ یعنی تردد تریلرها و کامیون‌ها دو دوره برون‌نمونه‌ای بر اساس هر دو معیار RMSE و خطای پیش‌بینی علامت عملکرد بهتری از مدل ARMA منتخب داشته است. در دوره درون‌نمونه‌ای هم خطای علامت کمتری داشته است.
- بکارگیری مدل شبکه عصبی در ترکیب داده‌های تردد شماری باعث می‌شود که خطای پیش‌بینی برآورد بدست آمده از شاخص‌های تجمیعی و مدل ARMA منتخب کمتر باشد.
- خروجی‌های روش میانگین‌گیری مدل بیزین در برآورد رشد ارزش افزوده بخش حمل و نقل خطای بیشتری نسبت به خروجی شبکه عصبی و ARMA منتخب دارند.

جدول (۴): نتایج ارزیابی شاخص‌های مدل‌های مختلف برای پیش‌بینی بخش حمل و نقل

		شبکه عصبی	میانگین‌گیری مدل بیزین			بهترین مدل ARMA
			بهترین مدل	پنج مدل برتر	۱۰۰ مدل برتر	MA4
درون‌نمونه	شاخص خطای پیش‌بینی علامت	۰	۰،۰۶	۰،۰۶	۰،۱	۰،۱۵
	RMSE	۱،۱۶	۰،۲۷	۰،۲۸	۲،۵	۲،۰۷
برون‌نمونه	شاخص خطای پیش‌بینی علامت	۰،۲۵	۰،۷۵	۰،۵	۰،۳	۰،۲۵
	RMSE	۱،۴	۱۵،۶	۵،۴	۸،۳	۴،۸

منبع : محاسبات پژوهش

شکل (۸): برآورد رشد بخش حمل و نقل با استفاده از مدل شبکه عصبی و ARMA و مقایسه با رشد ارزش افزوده این بخش در دوره‌های برون‌نمونه و درون‌نمونه

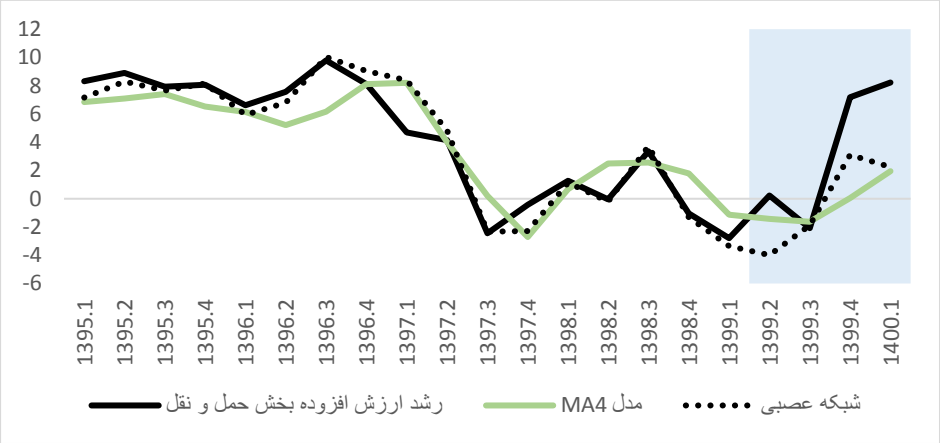

منبع : محاسبات پژوهش – مرکز آمار ایران

شکل ۹- برآورد رشد بخش حمل و نقل با استفاده مدل‌های منتخب میانگین‌گیری مدل بیزین و مقایسه با رشد ارزش افزوده این بخش در دوره درون‌نمونه و برون‌نمونه

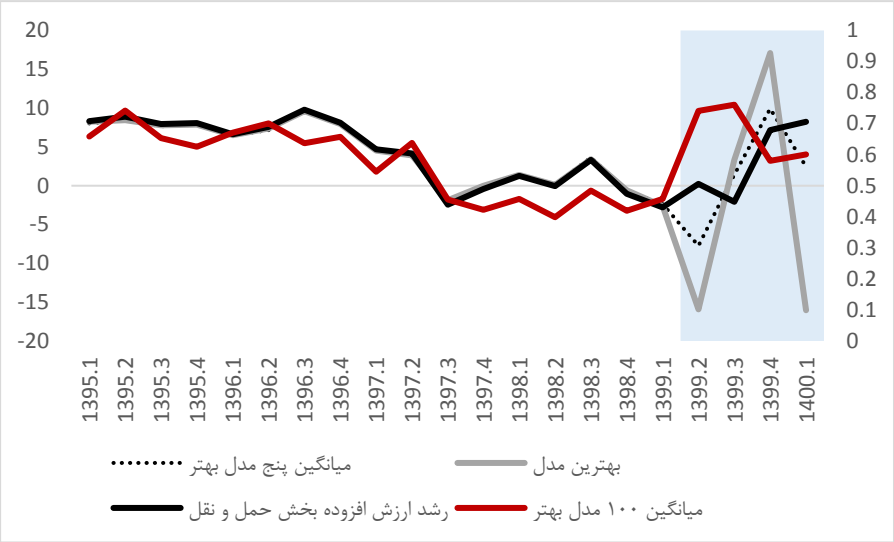

منبع : محاسبات پژوهش – مرکز آمار ایران

۵. جمع‌بندی

کنون‌بینی به پیش‌بینی دوره حال یا گذشته نزدیک یا آینده نزدیک اتلاق می‌شود و شامل روش‌هایی است که در آن از همه اطلاعات و داده‌های با تواتر بالا استفاده می‌شود تا در نبود داده‌های رسمی به دلیل وقفه تهیه و انتشار، کارگزاران اقتصادی از وضعیت کنونی اقتصاد اطلاع داشته باشند. رویکردهای کنون‌بینی در بسیاری از بانک‌های مرکزی کشورهای پیشرفته بکار برده می‌شوند تا سیاست‌گزاران از وضعیت و رکود و رونق بخش های مختلف آگاه سازند. علاوه بر وقفه قابل پیش‌بینی آمارهای رسمی و داده‌های حساب‌های ملی در ایران (که در همه کشورها وجود دارد) در برخی برهه‌های زمانی وقفه‌های پیش‌بینی نشده‌ای نیز در انتشار این داده‌ها اتفاق افتاده است که لزوم توجه به کنون‌بینی شاخص‌های مهم اقتصادی و بکارگیری داده‌های با تواتر بالا برای برآورد شاخص جایگزین به هنگام برای آنها را بیش از سایر کشورها می‌کند. در این راستا در این پژوهش تلاش شد به این سوال پاسخ داده شود که آیا بکارگیری از کلان‌داده تردد شماری وسایل نقلیه می‌تواند شاخص و نماینده تغییرات بخش خدمات و حمل و نقل باشد یا خیر. کلان‌داده های تردد شماری وسایل نقلیه شامل اطلاعات ۲۵۹۰ نقطه از جاده‌های کشور

بوده و در هر نقطه تردد انواع وسیله نقلیه به پنج گروه تفکیک شده و به صورت روزانه ارائه شده است. لذا در مجموع داده‌ها مشتمل بر ۱۲ هزار و ۹۵۰ سری زمانی روزانه از ابتدای سال ۱۳۹۴ تا شهریور ۱۴۰۰ بوده است. به منظور ساخت شاخص از این داده‌ها از سه روش شاخص‌های تجمیعی، شاخص برآوردی از شبکه عصبی و شاخص‌های برآوردی از روش میانگین‌گیری مدل بیزین برای ساخت شاخص استفاده شد. برای ارزیابی دقت پیش‌بینی شاخص‌های مختلف طول دوره مشاهدات به دو دوره درون‌نمونه‌ای و برون نمونه‌ای تقسیم شده و از دو معیار شاخص خطای پیش‌بینی علامت و شاخص RMSE استفاده شده است. همچنین از مدلهای ARMA به عنوان مدل معیار استفاده شده است. در پاسخ به این سوال که آیا داده‌های تردد شماری می‌تواند تغییرات بخش خدمات و بخش حمل و نقل را نشان دهد باید پاسخ داد که به طور کلی شاخص‌های برآوردی مستخرج از این دیتابیس خطای کمتری نسبت به مدل‌های سری زمانی که تنها از اطلاعات گذشته متغیر استفاده می‌کنند (ARMA) داشته‌اند و می‌توانند نمایان‌گر تغییرات هر دو بخش خدمات و حمل و نقل باشند. نکته‌ای که حائز اهمیت است این است که نحوه شاخص‌سازی از این دیتابیس بر دقت پیش‌بینی اثرگذار است. به عبارت دیگر زمانی که از شاخص‌های تجمیعی ساده استفاده می‌شود شاخص‌های برآوردی تنها از نظر پیش‌بینی علامت رشد خطای کمتری از مدل‌های ARMA منتخب دارد (مقایسه جدول ۱ و ۲) ولی در برخی موارد RMSE شاخص‌های تجمیعی مستخرج از داده‌های تردد شماری از مدل ARMA منتخب بالاتر بوده است. اما استفاده از مدل شبکه عصبی باعث بهبود دقت پیش‌بینی می‌شود و خطای پیش‌بینی بر اساس هر دو معیار RMSE و خطای پیش‌بینی علامت در برآورد شبکه عصبی هم از شاخص‌های تجمیعی ساده و هم از مدل‌های ARMA کمتر است. همچنین نتایج نشان می‌دهد که بکارگیری روش میانگین‌گیری مدل بیزین در انواع روش‌ها نتوانسته بهبود معنی‌داری در دقت پیش‌بینی نسبت به حالت شاخص تجمیعی ساده ایجاد کند.

بنابراین می‌توان گفت که بهره‌گیری از شاخص‌های تجمیعی تردد شماری در هر دوره می‌توان علامت رشد بخش خدمات و رشد بخش حمل و نقل را با دقت بالایی(بالاتر از مدل‌های ARMA) برآورد کند. برای پیش‌بینی عدد رشد بخش خدمات و ارزش افزوده نیز بکارگیری شاخص برآوردی مدلشبکه عصبی (که بر اساس داده‌های ترددشماری بوده) می‌تواند خطای پیش‌بینی را نسبت به سایر مدل‌ها چند برابر کاهش دهد. لذا سیاست‌گزاران می‌توانند با بکاگیری این داده‌ها در قالبی که معرفی شد برآورد با دقت

قابل قبولی از رشد بخش خدمات (که بیش از نیمی از GDP کشور است) چندماه زودتر از داده‌های رسمی داشته باشند.

فهرست منابع:

ابوالحسنی هستیانی، اصغر، متقی، سمیرا و صفارزاده، سروشا (۱۳۹۸)، واکاوی ارتباط سرمایه‌گذاری در زیرساخت‌های حمل و نقل و رشد اقتصادی کشور ایران (کاربرد الگوی VAR)، فصلنامه مهندسی حمل و نقل، ۱۱(۴۲): ۲۵۳-۲۳۹.

بابازاده، محمد، قدیمی، خلیل و محسنی، رضا (۱۳۸۸)، تاثیر سرمایه‌گذاری در بخش حمل و نقل بر رشد اقتصادی در ایران، پژوهشنامه بازرگانی، ۱۳(۵۰): ۱۵۷-۱۷۴.

پهلوانی، مصیب، مهرابی بشرآبادی، حسین و افشارپور، مهلا (۱۳۹۳)، بررسی تأثیر توسعهٔ زیرساخت‌های حمل و نقل بر رشد اقتصادی استان‌های ایران، تحقیقات مدلسازی اقتصادی، ۴(۱۶): ۹۹-۱۲۷.

رضایی ارجرودی، عبدالرضا، و تسبیحی، آمنه (۱۳۸۶)، ارایه مدل ارتباطی توسعه حمل و نقل و رشد اقتصادی در ایران بر مبنای الگوی رگرسیون برداری، پژوهش های رشد و توسعه پایدار (پژوهشهای اقتصادی)، ۷(۲)؛ ۱۲۵-۱۳۸.

مهرآرا، محسن و غضنفری، آرزو (۱۳۹۳)، بررسی علل تورم در اقتصاد ایران مبتنی‌بر رویکرد متوسط‌گیری بیزین (BMA)، فصلنامه علمی پژوهشی راهبرد اقتصادی،۳(۱۰): ۷-۳۷.

کلانترزاده، مهسا، زندی، فاطمه، خضری، محمد و صفوی، بیژن (۱۴۰۰)، رابطه بین حمل و نقل، رشد اقتصادی و محیطزیست درکشورهای منتخب منا، فصلنامه علمی -پژوهشی تحقیقات اقتصاد کشاورزی, ۱۳(۲): ۱۹۶-۱۷۳.

مجاب، رامین، برکچیان، سید مهدی و نیلی، فرهاد (۱۳۹۲)، تحلیل عوامل موثر در تغییرات پایه پولی و مخارج دولت در ایران با استفاده از روش میانگین‌گیری بیزین مدل، فصلنامه پژوهش های پولی - بانکی، ۶(۱۷): ۱۶-۱.

مهرگان، نادر و دهقانی احمدآباد، هانی (۱۳۸۹)، تخمین اثر رشد اقتصادی بخش حمل و نقل بر توزیع درآمد در ایران، پژوهشنامه حمل و نقل، ۷(۴): ۳۸۵-۳۶۵.

یوسفی، محمدقلی (۱۳۹۱)، تعیین پیوندهای بین بخشی در اقتصاد ایران با استفاده از روش حذف فرضی، پژوهش‌های رشد و توسعه پایدار (پژوهشهای اقتصادی)، ۱۲(۴): ۱۷۰-۱۵۵.

سایت سازمان راهداری و حملو نقل جاده‌ای کشور به آدرس: https://141.ir/trafficcounterfiles

Alagic, A. (2017), An analysis of the causal relationship between transportation and GDP: A time-series approach for the United States, Major themes in economics, 19(1): 17-37.

Buell, B., Cherif, R., Chen, C., Walentin, K. & Tang, J. (2021), Impact of COVID-19: Nowcasting and Big Data to Track Economic Activity in Sub-Saharan Africa, IMF Working paper WP/21/124 .

Bańbura, M., Giannone, D., Modugno, M. & Reichlin, L. (2013), Now-casting and the real-time data flow, In Handbook of economic forecasting (Vol. 2, pp. 195-237), Elsevier.

Blinder, A. S. (1986), Can the production smoothing model of inventory behavior be saved?, The Quarterly Journal of Economics, 101(3): 431-453.

Clements, M. P. & Galvao, A. B. (2008), Macroeconomic forecasting with mixed frequency data: Forecasting output growth in the United States, Journal of Business & Economic Statistics, 26(4): 546–554.

Clements, M. P. & Galvao, A. B. (2009), Forecasting US output growth using leading indicators: An appraisal using MIDAS models, Journal of Applied Econometrics, 24(7): 1187–1206.

Coyle, J. J., Novack, R. A., Gibson, B. J. & Bardi, E. J. (2011), Transportation: a supply chain perspective, South-Western Cengage Learning.

Fair, R. C. (1989), The production-smoothing model is alive and well, Journal of Monetary Economics, 24(3): 353-370.

Fedderke, J. W., Perkins, P. & Luiz, J. M. (2006), Infrastructural investment in long-run economic growth: South Africa 1875–2001, World development, 34(6): 1037-1059.

Gao, Y., Zhang, Y., Li, H., Peng, T. & Hao, S. (2016), Study on the relationship between comprehensive transportation freight index and GDP in China, Procedia Engineering, 137: 571-580.

Gálvez-Soriano, O. D. J. (2020), Nowcasting Mexico's quarterly GDP using factor models and bridge equations, Estudios Económicos (México, DF), 35(2): 213-265.

Ghysels, E., Santa-Clara, P. & Valkanov, R. (2006), Predicting volatility: getting the most out of return data sampled at different frequencies, Journal of Econometrics, 131(1): 59–95.

Giannone, D., Reichlin, L. & Simonelli, S. (2009), Nowcasting Euro Area Economic Activity in Real Time: The Role of Confidence Indicators, National Institute Economic Review, 210(1):90–97.

Giannone, D., Reichlin, L. & Small, D. (2008), Nowcasting: The real-time informational content of macroeconomic data, Journal of Monetary Economics, 55(4): 665-676.

Gnap, J., Konečný, V. & Varjan, P. (2018), Research on relationship between freight transport performance and GDP in Slovakia and EU countries, NAŠE MORE: znanstveni časopis za more i pomorstvo, 65(1): 32-39.

Guzavicius, A., Barkauskas, V. & Tamulis, V. (2013), Nowcasting business cycles using transportation index, European Financial Systems , 114-119.

Ingenito, R. and Trehan, B. (1996), Using monthly data to predict quarterly output, Federak Reserve Bank of San Francisco Economic Review, 3: 3–11.

Kim, E. (2002), Determinants of optimal level of transportation infrastructure, Journal of urban planning and development, 128(3):150-163.

Loermann, J. & Maas, B. (2019), Nowcasting US GDP with artificial neural networks (No. 95459), University Library of Munich, Germany.

Lee, M. K. & Yoo, S. H. (2016), The role of transportation sectors in the Korean national economy: An input-output analysis, Transportation Research Part A: Policy and Practice, 93: 13-22.

Lahiri, K. & Yao, V. W. (2006), Economic indicators for the US transportation sector, Transportation Research Part A: Policy and Practice, 40(10): 872-887.

Lahiri, K., Baltagi, B. H. & Sadka, E. (2010), Transportation indicators and business cycles, Emerald Group Publishing.

Marcellino, M. & Schumacher, C. (2010), Factor MIDAS for Nowcasting and forecasting with ragged-edge data: A model comparison for German GDP, Oxford Bulletin of Economics and Statistics, 72(4): 518-550.

Matheson, T. (2011), New Indicators for Tracking Growth in Real Time, IMF Working Paper, 11(43): 1–22.

Morgado, A. J., Nunes, L. C, & Salvado, S. (2007), Nowcasting an economic aggregate with disaggregate dynamic factors: An application to portuguese GDP (No. 0002), Gabinete de Estratégia e Estudos, Ministério da Economia.

Rünstler, G. & Sédillot, F. (2003), Short-term estimates of euro area real GDP by means of monthly data (No. 276), ECB working paper.

Schumacher, C. & Breitung, J. (2008), Real-time forecasting of German GDP based on a large factor model with monthly and quarterly data, International Journal of Forecasting, 24(3): 386-398.

Schumacher, C. (2016), A comparison of MIDAS and bridge equations, International Journal of Forecasting, 32(2): 257-270.

Tsouma, E. (2009), A Coincident Economic Indicator of Economic Activity in Greece, Center for Planning and Economic Research (KEPE).

West, K. D. (1986), A variance bounds test of the linear quadratic inventory model, Journal of Political Economy, 94(2): 374-401.