

ارزیابی مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا در پیش‌بینی قیمت صادرات خشکبار ایران

امیرحسین توحیدی، محمد رضا زارع مهرجردی، حسین مهرابی بشراآبادی و

حسین نظام آبادی پور *

تاریخ وصول: ۱۳۹۴/۴/۲۶ تاریخ پذیرش: ۱۳۹۴/۱۲/۱۹

چکیده:

در بسیاری از مطالعات برای پیش‌بینی متغیرهای اقتصادی اغلب از روش‌های کمی مبتنی بر داده‌های سری زمانی یا مقطع زمانی استفاده می‌شود. مطالعات سری زمانی و مقطع زمانی ناهمگنی کشورها را کنترل نمی‌کنند و همواره ریسک به دست آوردن نتایج و پیش‌بینی‌های اریب‌دار وجود دارد. داده‌های پانل اطلاعات و درجه آزادی بیشتری را فراهم می‌آورد که این امر موجب حصول نتایج و پیش‌بینی‌های دقیق‌تری می‌شود. با توجه به سهم قابل توجه خشکبار از صادرات غیرنفتی کشور، در این مطالعه از روش ترکیبی شبکه عصبی مصنوعی-پانل دیتا برای پیش‌بینی قیمت صادرات پسته، کشمش و خرما استفاده گردید و پس از آن عملکرد پیش‌بینی بر اساس معیارهای دقت با الگوی رگرسیونی (مدل جزء خطای دو طرفه) مورد مقایسه قرار گرفت. با استفاده از داده‌های مربوط به ده بازار مقصد برای هر یک از خشکبار مورد بررسی طی دوره‌ی ۹۱-۱۳۷۱، نتایج پژوهش نشان داد که رویکرد جدید و ترکیبی شبکه عصبی مصنوعی-پانل دیتا در پیش‌بینی قیمت صادرات پسته، کشمش و خرمای ایران در مقایسه با روش رگرسیونی دارای عملکرد بهتری است. لذا به صادرکنندگان، سیاست‌گذاران و محققان توصیه می‌گردد که از این روش در پیش‌بینی متغیرهای اقتصادی استفاده نمایند.

طبقه‌بندی JEL: F1، E37، C33

واژه‌های کلیدی: قیمت صادرات، شبکه عصبی مصنوعی، پیش‌بینی

* به ترتیب، دانشجوی دکترا اقتصاد کشاورزی، دانشکده کشاورزی، دانشگاه فردوسی مشهد، دانشیار و استاد گروه اقتصاد کشاورزی دانشکده کشاورزی و استاد گروه مهندسی برق دانشگاه شهید باهنر کرمان.

(zare@uk.ac.ir)

۱- مقدمه

پیش‌بینی متغیرهای اقتصادی، نظیر قیمت کالاهای اقتصادی، طی دهه‌های اخیر بسیار مورد توجه محققان قرار گرفته است. زیرا، شناسایی روند آتی قیمت کالاها در برنامه‌ریزی، طراحی و مدیریت فعالیت‌ها نقش بسیار مهمی را ایفا می‌نماید (جین و کومار^۱، ۲۰۰۷). از سوی دیگر، پیش‌بینی قیمت برای فعالان اقتصادی امری بسیار ضروری است؛ زیرا، تغییرات شرایط بازار موجب تغییرات مداوم و پیوسته در قیمت‌ها می‌گردد. بر این اساس، روش‌های مختلف پیش‌بینی طی دهه‌های اخیر معرفی شده است (اریکول و همکاران^۲، ۲۰۱۰). علوم اقتصادسنجی، آمار و هوش مصنوعی؛ طیف وسیعی از این روش‌ها را ارائه نموده‌اند. اما به طور کلی، برای پیش‌بینی در شرایط مختلف، روش جامعی وجود ندارد (رویز-آگویلر و همکاران^۳، ۲۰۱۴). در طراحی یک مدل مناسب برای پیش‌بینی، در درجه اول لازم است که رابطه ضمنی میان متغیرها شناسایی گردد. اما در واقع، تشخیص چنین امری بسیار مشکل است؛ زیرا متغیرهای پیش‌بینی تحت تأثیر عوامل مختلفی (نظیر نرخ بهره، نرخ تورم، تغییر رشد اقتصادی، شرایط سیاسی و ویژگی‌های روانشناختی) قرار می‌گیرند. در طول سال‌های اخیر، محققین متعددی سعی در توصیف مناسب، مدل‌سازی و پیش‌بینی متغیرها داشته‌اند. اما، متغیرهایی که از روند غیرخطی برخوردار می‌باشند؛ پیش‌بینی آن‌ها دشوار می‌باشد. شبکه‌های عصبی مصنوعی^۴ یک گزینه بسیار مناسب برای در نظر گرفتن روند غیرخطی موجود در داده‌ها است. در حوزه اقتصاد، شبکه‌های عصبی مصنوعی بسیار مورد استفاده قرار گرفته‌اند؛ زیرا این مدل‌ها غیرخطی، ناپارامتریک، خودتطبیقی و مقاوم در برابر اختلال می‌باشند. این ویژگی‌ها، مدل شبکه عصبی مصنوعی را قادر می‌سازند که به طور مؤثرتری به تشخیص رابطه ذاتی میان متغیرها بپردازند. برعکس سایر مدل‌های غیرخطی، مدل شبکه عصبی مصنوعی بدون نیاز به هر گونه اطلاعات در مورد فرآیند تولید داده‌ها، می‌تواند روابط غیرخطی را با کمترین خطا تشخیص دهد (ادهیکری و اگروال^۵، ۲۰۱۴). اما، شبکه‌های عصبی به طور معمول به تعداد زیادی داده برای آموزش و آزمون نیاز دارند (نجفی و طرازکار،

¹ Jain and Kumar

² Areekul *et al.*

³ Ruiz-Aguilar *et al.*

⁴ Artificial Neural Networks (ANNs)

⁵ Adhikari and Agrawal

۱۳۸۵). با توجه به ویژگی‌های منحصر به فرد شبکه‌های عصبی مصنوعی، محدودیت در تعداد داده‌ها می‌توان استفاده از این مدل‌ها را در پیش‌بینی غیرممکن سازد. برای مقابله با این مشکل لازم است که شبکه‌های عصبی مصنوعی با سایر روش‌های آماری ترکیب گردد. افزایش حجم داده‌ها و درجه آزادی یکی از مزیت‌های مهم داده‌های پانل است. اما تاکنون از این داده‌ها برای بهبود عملکرد شبکه عصبی مصنوعی استفاده نشده است. ترکیب دو مدل پانل دیتا و شبکه عصبی مصنوعی مزایای قابل توجهی را به همراه دارد: (۱) حتی اگر تعداد مشاهدات برای پیش‌بینی با شبکه عصبی مصنوعی اندک باشد؛ با وارد همزمان بعد مکان و زمان، تعداد مشاهدات افزایش خواهد یافت؛ (۲) مدل‌های داده‌های تابلویی به تنهایی نیاز به تصریح مدل دارند و روابط غیرخطی را نادیده می‌گیرند؛ اما مدل ترکیبی، روابط غیرخطی را در نظر می‌گیرد و نیازی به پیش فرض‌هایی در مورد رابطه میان متغیرها نمی‌باشد.

ایران به عنوان بزرگترین تولیدکننده و صادرکننده محصولات خشکبار مثل پسته، خرما و کشمش در سطح جهان به شمار می‌رود و در بازار جهانی دارای جایگاه مناسب و قدرت بازاری است، به طوری که افزایش صادرات این سه محصول گامی مؤثر در جهت کاهش وابستگی کشور به درآمدهای نفتی می‌باشد. از این رو، پیش‌بینی قیمت‌های صادراتی پسته، کشمش و خرما دارای اهمیت استراتژیک برای اقتصاد ایران است؛ زیرا، این قیمت‌ها به طور مستقیم و غیرمستقیم بر صادرات این محصولات اثرگذار می‌باشند. از سوی دیگر، امکان افزایش درآمدهای صادراتی با پیش‌بینی قیمت صادراتی این سه محصول و اتخاذ برنامه‌ریزی صحیح و سیاست‌های راهبردی مناسب وجود دارد. لذا، هدف اصلی این مطالعه طراحی یک شبکه عصبی مصنوعی سازگار با داده‌های پانل به منظور پیش‌بینی قیمت صادرات پسته، کشمش و خرما طی دوره‌ی ۹۱-۱۳۷۱ است تا صادرکنندگان و سیاست‌گذاران اقتصادی بتوانند با پیش‌بینی قیمت‌های آتی، سیاست‌های ارزی و تجاری خود را به تفکیک بازارهای مقصد تنظیم نمایند. انجام پیش‌بینی با استفاده از شبکه‌های عصبی مصنوعی در چارچوب داده‌های پانل ویژگی متمایز این مطالعه نسبت به مطالعات پیشین است. پس از بررسی ادبیات موضوع، مواد و روش‌ها بیان می‌گردد. در قسمت نتایج و بحث، نتایج برآورد و پیش‌بینی گزارش و تفسیر می‌شود و سرانجام بر اساس یافته‌های مطالعه، نتیجه‌گیری و پیشنهادات سیاستی ارائه می‌گردد.

۲- سوابق و ادبیات موضوع

علوم اقتصادسنجی، آمار و هوش مصنوعی طیف وسیعی از روش‌ها را برای پیش‌بینی متغیرهای مالی ارائه نموده‌اند. اما به طور کلی، برای پیش‌بینی در شرایط مختلف روش جامعی وجود ندارد. روش خودرگرسیون میانگین متحرک انباشته^۶ یکی از متداول‌ترین رهیافت‌ها برای پیش‌بینی متغیرهای مالی است و از آن در حوزه‌های مختلف پیش‌بینی (نظیر اقتصادسنجی، اقتصاد، مهندسی، محیط زیست و حمل و نقل) استفاده می‌گردد. یکی از مفروضات اساسی روش ARIMA این است که متغیر مورد مطالعه از طریق یک فرآیند خطی ایجاد شده است. اما در عالم واقع؛ پیچیدگی، عدم اطمینان و روابط غیرخطی وجود دارد. در مواردی که رفتار غیرخطی وجود دارد؛ استفاده از روش‌های سنتی نامناسب است. برای در نظر گرفتن روابط پیچیده، چندین مدل غیرخطی به عنوان روش‌های جایگزین معرفی شده‌اند که شبکه‌های عصبی مصنوعی یکی از متداول‌ترین و پرکاربردترین آن‌ها است (رویز-آگویلر و همکاران، ۲۰۱۴).

مطالعات مربوط به شبکه‌های عصبی مصنوعی دارای سابقه طولانی می‌باشد. در دهه ۱۹۴۰، یک مدل ساده شبکه عصبی مصنوعی معرفی گردید و پس از آن، مدل پرسپترون با قابلیت یادگیری در دهه ۱۹۵۰ پیشنهاد شد. با توجه به محدودیت‌های نظری و تکنیکی، توسعه مطالعات در حوزه شبکه‌های عصبی مصنوعی در دهه‌های ۱۹۶۰ و ۱۹۷۰ کاهش یافت، اما میزان اقبال محققین به سمت مطالعه و پژوهش در این زمینه از دهه ۱۹۸۰ به طور قابل توجهی بیشتر گردید (لیو و ژیاو^۷، ۱۹۹۱). به عنوان متداول‌ترین مدل شبکه عصبی مصنوعی، شبکه پرسپترون از سه لایه ورودی، پنهان و خروجی تشکیل می‌گردد. فعالیت هر گره (نرون) لایه پنهان به فعالیت نرون‌های لایه ورودی و وزن اتصالات (سیناپس) میان نرون‌های لایه‌های ورودی و پنهان بستگی دارد. از سوی دیگر، فعالیت هر نرون خروجی به فعالیت‌های نرون‌های لایه پنهان و وزن‌های اتصالات میان نرون‌های لایه‌های پنهان و خروجی بستگی دارد. وزن هر اتصال نشان‌دهنده قدرت آن اتصال است. تعداد لایه‌های شبکه، نرون‌های لایه پنهان و معیار توقف از طریق آزمون و خطا مشخص می‌گردد؛ زیرا، تئوری عمومی و در عین حال قابل قبولی در ارتباط با تعیین تعداد مطلوب نرون‌های

^۶ Autoregressive Integrated Moving Averages (ARIMA)

^۷ Liu and Xiao

لایه پنهان وجود ندارد. فرآیند آموزش در مدل شبکه عصبی شامل پیدا کردن مقادیر وزن‌های سیناپسی است، به طوری که مقادیر خروجی مدل نزدیک به مقادیر هدف مورد انتظار باشد. تعدیل وزن‌ها بر اساس حداقل‌سازی مجموع مربعات خطا میان خروجی شبکه و مقادیر هدف صورت می‌پذیرد (کو و بوسرونگسه^۸، ۲۰۰۷).

شبکه‌های عصبی از برخی جهات شبیه به مدل‌های خطی و غیرخطی رگرسیونی می‌باشند و از این شبکه‌ها می‌توان به عنوان یک جایگزین برای رهیافت‌های معمول آماری استفاده نمود. حداقل‌سازی مجموع مربعات خطا هدف اصلی هر دو رهیافت شبکه عصبی مصنوعی و مدل رگرسیونی است. پارامتر بایاس در شبکه عصبی معادل با جمله عرض از مبدأ در معادله رگرسیونی است. تعداد نرون‌های ورودی برابر با تعداد متغیرهای مستقل و نرون خروجی نمایانگر متغیر وابسته است. مدل‌های رگرسیونی مشابه با یک مدل شبکه عصبی است که در آن، لایه پنهان وجود ندارد و نرون خروجی از یک تابع انتقال خطی ایجاد می‌گردد. وزن‌های اتصال از نرون ورودی به نرون خروجی مشابه با ضرایب مدل رگرسیون خطی می‌باشد. شبکه‌هایی با یک لایه پنهان همانند مدل‌های رگرسیونی غیرخطی هستند که وزن‌های آن نشان‌دهنده پارامترهای منحنی رگرسیون است (کاسترا و بوید^۹، ۱۹۹۶). با وجود این شباهت‌ها، شبکه‌های عصبی مصنوعی در مقایسه با سایر مدل‌های پیش‌بینی دارای برخی مزایا و تفاوت‌ها می‌باشند. قابلیت نگاشت توابع غیرخطی و ویژگی اول شبکه‌های عصبی مصنوعی است که می‌توانند هر تابع قابل اندازه‌گیری پیوسته را با دقت بالایی مدل‌سازی نمایند. دوم، شبکه‌های عصبی مصنوعی ناپارامتریک و اطلاعات محور می‌باشند. در شبکه‌های عصبی نیاز به در نظر گرفتن پیش فرض‌هایی در مورد فرآیند تولید داده‌ها نمی‌باشد. با در نظر گرفتن این ویژگی، شبکه‌های عصبی کمتر دچار مشکلات رایج سایر روش‌های غیرخطی، نظیر تصریح نادرست، می‌شوند. سوم، شبکه‌های عصبی مصنوعی دارای ماهیت خودتطبیقی می‌باشند. این ویژگی باعث می‌شود که شبکه‌های عصبی مصنوعی قابلیت تعمیم خود را در یک محیط متغیر حفظ نمایند. چهارم، شبکه‌های عصبی مصنوعی برای مدل‌سازی روابط غیرخطی از پارامترهای کمتری در مقایسه با مدل‌های دیگر (نظیر مدل‌های رگرسیونی چندجمله‌ای) استفاده می‌کنند. اما،

^۸ Co and Boosarawongse

^۹ Kaastra and Boyd

استفاده از شبکه‌های عصبی مصنوعی برای هر نوع داده‌ای مناسب نمی‌باشد (خاشعی و بیجاری^{۱۰}، ۲۰۱۱). از این رو، بسیاری از محققین با ترکیب شبکه‌های عصبی مصنوعی با سایر مدل‌های آماری سعی در بهبود عملکرد پیش‌بینی دارند. بر این اساس در سال‌های گذشته، روش‌های ترکیبی مختلفی به منظور غلبه بر محدودیت‌ها و بهبود دقت و عملکرد پیش‌بینی ارائه شده است (اریکول و همکاران، ۲۰۱۰؛ خاشعی و بیجاری، ۲۰۱۱). هدف اصلی ترکیب مدل‌ها در پیش‌بینی، استفاده از ویژگی‌های منحصر به فرد هر یک از آن‌ها برای اندازه‌گیری الگوهای مختلف موجود در داده‌ها است. مدل‌های ترکیبی می‌توانند همگن (مانند استفاده از ساختارهای متفاوت شبکه‌های عصبی) و یا ناهمگن (مانند ترکیب دو روش متفاوت آماری) باشند. در مدل‌های ترکیبی فرض بر این است که یک مدل به تنهایی قادر به اندازه‌گیری رفتار یک متغیر نمی‌باشد (خاشعی و بیجاری، ۲۰۱۱).

در برخی از مطالعات، از روش‌های ARIMA و SARIMA برای ترکیب با مدل شبکه عصبی مصنوعی استفاده شده است. برای مثال، تسنگ و همکاران^{۱۱} (۲۰۰۲) در پژوهشی با ترکیب مدل ANN با SARIMA، به پیش‌بینی داده‌های فصلی ارزش کل تولید برای صنعت ماشین‌سازی تایوان و نوشیدنی‌های غیرالکلی پرداختند. در این پژوهش با استفاده از داده‌های ماهانه طی دوره‌ی (۱۲)۱۹۹۶- (۱)۱۹۹۱، نتایج مطالعه نشان داد که مدل ترکیبی ANN و SARIMA دارای کمترین خطا در پیش‌بینی است. ژانگ^{۱۲} (۲۰۰۳) در مطالعه‌ای با ترکیب شبکه عصبی مصنوعی و مدل ARIMA به پیش‌بینی نرخ برابری دلار آمریکا در مقابل پوند انگلیس پرداختند. نتایج مطالعه آن‌ها طی دوره‌ی ۹۳-۱۹۸۰ نشان داد که روش ترکیبی از دقت بالاتری در پیش‌بینی نرخ ارز برخوردار است. دایز-روبلز و همکاران^{۱۳} (۲۰۰۸) در مطالعه‌ای با استفاده از ترکیب مدل‌های شبکه عصبی و ARIMA به پیش‌بینی کیفیت هوا در شیلی پرداختند. نتایج مطالعه آن‌ها برای دوره زمانی ۲۰۰۶-۲۰۰۰ نمایانگر برتری عملکرد مدل ترکیبی است. اریکول و همکاران (۲۰۱۰) در پژوهشی به پیش‌بینی کوتاه‌مدت قیمت برق در بازار استرالیا در سال ۲۰۰۶ پرداختند. نتایج مطالعه آن‌ها مؤید آن است که ترکیب روش‌های

¹⁰ Khashei and Bijari

¹¹ Tseng *et al.*

¹² Zhang

¹³ Di'az-Robles *et al.*

شبکه عصبی مصنوعی و ARIMA موجب افزایش دقت پیش‌بینی می‌شود. فاروق^{۱۴} (۲۰۱۰) در مطالعه‌ای به پیش‌بینی کیفیت ماهانه آب طی دوره‌ی ۲۰۰۴-۱۹۹۶ پرداختند. نتایج مطالعه آن‌ها نیز نشان داد که مدل ترکیبی شبکه عصبی مصنوعی و ARIMA در مقایسه با هر یک از این روش‌ها از دقت بیشتر و عملکرد بهتری در پیش‌بینی کیفیت آب برخوردار است.

علاوه بر ترکیب روش‌های شبکه عصبی مصنوعی و ARIMA، برخی محققان مدل‌های فازی را با شبکه‌های عصبی مصنوعی ترکیب نموده‌اند (برای مثال؛ کیم و همکاران^{۱۵}، ۱۹۹۵؛ لی و همکاران^{۱۶}، ۲۰۰۴؛ لنگ و همکاران^{۱۷}، ۲۰۰۵؛ خاشعی و همکاران، ۲۰۰۸). از مدل‌های هیبرید دیگر می‌توان به مدل‌های ترکیبی ناهمسانی واریانس-شبکه عصبی مصنوعی اشاره نمود. تسنگ و همکاران (۲۰۰۸) در مطالعه‌ای با ترکیب مدل شبکه عصبی مصنوعی و ناهمسانی واریانس به پیش‌بینی شاخص سهام کشور تایوان پرداختند. با استفاده از داده‌های روزانه طی سال‌های ۲۰۰۵ و ۲۰۰۶، نتایج مطالعه نشان داد که مدل ترکیبی در مقایسه با مدل‌های تغییرپذیری از عملکرد بهتری در پیش‌بینی شاخص سهام برخوردار است. بیلدیرسی و ارسین^{۱۸} (۲۰۰۹) در مطالعه‌ای به منظور پیش‌بینی بازده سهام در کشور ترکیه، مدل‌های ناهمسانی واریانس را با الگوی شبکه عصبی مصنوعی ادغام نمودند. آن‌ها با استفاده از داده‌های مربوط به بازده روزانه سهام در بورس اوراق بهادار استانبول طی دوره‌ی ۱۹۸۷/۱۰/۲۳-۲۰۰۸/۲/۲۲ به این نتیجه دست یافتند که مدل ترکیبی در پیش‌بینی مقادیر بازدهی دارای عملکرد بهتری است.

به طور کلی، مطالعات تجربی بسیاری وجود دارد که نمایانگر برتری مدل‌های پیش‌بینی هیبرید است و این استدلال برای مدل‌های ترکیب شده کاملاً متفاوت، مصداق بیشتری دارد. با مروری بر مطالعات گذشته می‌توان دریافت که از داده‌های پانل برای پیش‌بینی کمتر مورد استفاده قرار گرفته است؛ هرچند که این داده‌ها با در نظر گرفتن ناهمگنی میان مقاطع، نتایج قابل قبولی را ارائه می‌دهند. در این مطالعه، علاوه بر پیش‌بینی با استفاده از مدل داده‌های پانل، از این روش برای افزایش

¹⁴ Faruk

¹⁵ Kim *et al.*

¹⁶ Lee *et al.*

¹⁷ Leng *et al.*

¹⁸ Bildirici and Ersin

حجم مشاهدات در مدل شبکه عصبی مصنوعی نیز استفاده می‌گردد و سپس، عملکرد مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا با پیش‌بینی ارائه شده توسط مدل پانل دیتا مورد مقایسه قرار می‌گیرد.

۳- مواد و روش‌ها

در این بخش از مطالعه، پس از معرفی الگوی تجربی، مدل داده‌های پانل معرفی می‌شود و سپس، نحوه طراحی مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا توصیف می‌گردد. به منظور مقایسه و ارزیابی روش‌های مختلف پیش‌بینی از معیارهای دقت استفاده می‌شود.

۳-۱- الگوی تجربی

در این مطالعه با توجه به چارچوب داده‌های پانل، از مدل جزء خطای دو طرفه استفاده می‌شود:

$$\text{LnP}_{it} = \mu_i + \lambda_t + \beta_i \text{LnER}_{it} + v_{it} \quad (1)$$

که LnP_{it} لگاریتم ارزش هر واحد صادرات خشکبار ایران (پسته، کشمش و خرما) بر حسب پول داخلی (ریال) به بازار i در زمان t ، μ_i مجموعه‌ای از اثرات کشوری، λ_t مجموعه‌ای از اثرات زمانی، LnER_{it} لگاریتم نرخ ارز میان ریال ایران و پول رایج بازارهای مقصد می‌باشد. در مدل رگرسیونی (۱)، اثرات غیرقابل مشاهده به دو دسته اثرات کشوری (μ_i) و اثرات زمانی (λ_t) تقسیم می‌شوند. اثرات کشوری (μ_i) بیانگر ویژگی‌های خاص هر یک از کشورها است که غیرقابل مشاهده می‌باشند و در طول زمان تغییر نمی‌کنند (گجراتی^{۱۹}، ۲۰۰۳؛ وولدریج^{۲۰}، ۲۰۰۶). عوامل تأثیرگذار بر تقاضا در بازارهای مختلف متفاوت می‌باشند که تغییرات در آن‌ها باعث انتقال منحنی تقاضا در این بازارها می‌شود. بنابراین اندازه‌گیری اثر این عوامل بر قیمت صادرات خشکبار ایران توسط متغیر اثرات کشوری (μ_i) امکان‌پذیر است. ب

رای لحاظ کردن متغیر اثرات کشوری (μ_i) در مدل رگرسیونی (۱) از روش متغیرهای مجازی استفاده می‌شود که این متغیرهای مجازی برای کشور i مقدار یک و برای سایر کشورها مقدار صفر را اختیار می‌کنند. اما، اثرات زمانی (λ_t) بیان‌گر

¹⁹ Gujarati

²⁰ Wooldridge

عوامل غیرقابل مشاهده‌ای است که در میان کشورها ثابت و در طول زمان تغییر می‌کنند. بنابراین، متغیر اثرات زمانی (λ_t) را می‌توان به عنوان هزینه نهایی تولید در نظر گرفت؛ زیرا، فرض بر این است که هزینه نهایی تولید بر قیمت صادراتی خشکبار ایران در تمام بازارهای مقصد تأثیر می‌گذارد و مقدار آن در طول زمان تغییر می‌یابد^{۲۱} (گلدبرگ و نتر^{۲۲}، ۱۹۹۷؛ حق و رزاق^{۲۳}، ۲۰۰۴).

برای لحاظ نمودن متغیر اثرات زمانی (λ_t) در مدل رگرسیونی (۱) از متغیرهای مجازی استفاده می‌شود که این متغیرهای مجازی برای سال t مقدار یک و برای سایر سال‌ها مقدار صفر را اختیار می‌کنند.

قلمرو زمانی این مطالعه برای پیش‌بینی الگوی (۱) از سال ۹۱-۱۳۷۱ و قلمرو مکانی (بازارهای مقصد) آن برای هر یک از خشکبار صادراتی به شرح زیر است: پسته: اردن، استرالیا، پاکستان، ترکیه، تونس، عربستان سعودی، روسیه، قطر، مصر و سوریه.

کشمش: اتریش، انگلستان، آلمان، ترکیه، رومانی، روسیه، کانادا، لهستان، مالزی و مجارستان.

خرما: استرالیا، انگلستان، ترکیه، رومانی، سنگاپور، کانادا، کویت، مالزی، نیوزیلند و هند.

این مطالعه به جهت نوع تحقیق، به روش کتابخانه‌ای انجام شده است و داده‌های مورد استفاده برای پیش‌بینی الگوی (۱) به صورت سالانه و پانل دیتا سازمان یافته‌اند.

برای پیش‌بینی الگوی (۱) لازم است که قیمت صادرات خشکبار ایران و نرخ ارز دوجانبه محاسبه شوند. ارزش هر واحد صادرات خشکبار ایران (پسته، کشمش و خرما) بر حسب ریال، از تقسیم ارزش کل صادرات بر مقدار آن در هر بازار محاسبه شده است. اطلاعات مربوط به این متغیر از سالنامه‌های آماری گمرک جمهوری اسلامی ایران جمع‌آوری شده‌اند.

^{۲۱} با توجه به موضوع مطالعه، بیان جزئیات مدل رگرسیونی از حوصله‌ی این مقاله خارج است، خواننده محترم برای آشنایی بیشتر با مدل و متغیرهای آن شایسته است که به مطالعه‌ی زارع مهرجردی و توحیدی (۱۳۹۲) مراجعه فرمایند.

^{۲۲} Goldberg and Knetter

^{۲۳} Hoque and Razzaque

با توجه به عدم گزارش نرخ مستقیم برابری ریال ایران در برابر پول رایج شرکای تجاری در پایگاه‌های آماری بین‌المللی، در این مطالعه با مبنا قرار دادن ارزش دلار، از روش متقاطع برای محاسبه نرخ ارز دوجانبه استفاده می‌شود. داده‌های مربوط به نرخ ارز اسمی دو جانبه از آمارنامه آمارهای مالی بین‌المللی جمع‌آوری شده است. در این مطالعه، برای برآورد، انجام آزمون‌های آماری و پیش‌بینی از نرم‌افزارهای EViews⁶، STATA¹² و MATLAB^{7.12.0} استفاده می‌گردد.

۳-۲- پیش‌بینی با مدل داده‌های پانل

در ابتدا پیش‌بینی بر اساس مدل جز خطای یک طرفه شرح داده می‌شود. برای پیش‌بینی S دوره بعد برای $\hat{y}_{i,T+S}$ آمین مقطع، بهترین پیش‌بینی کننده خطی بدون تورش برای $y_{i,T+S}$ به صورت زیر است (بالتاجی^{۲۴}، ۲۰۰۵):

$$\hat{y}_{i,T+S} = Z'_{i,T+S} \hat{\delta}_{GLS} + w' \Omega^{-1} \hat{u}_{GLS} \quad \text{برای } S \geq 1 \quad (2)$$

که y بردار با ابعاد $1 \times NT$ ، $Z = [NT, X]$ بردار با ابعاد $NT \times K$ ، NT بردار یکه با بعد NT ، $\delta = (\alpha, \beta)$ ، Ω ماتریس واریانس-کوارینانس، $\hat{u}_{GLS} = y - Z\hat{\delta}_{GLS}$ و $w = E(u_{i,T+S}u)$ است. برای دوره‌ی T+S خواهیم داشت:

$$u_{i,T+S} = \mu_i + v_{i,T+S} \quad (3)$$

و $w = \frac{1}{2}(l'_i \otimes T)$ است که l_i ستون $1 \times T$ از ماتریس یکه I_N می‌باشد. برای مثال، l_i برداری است که دارای عدد یک برای آمین مشاهده و دارای عدد صفر برای سایر مشاهدات است. در این حالت، خواهیم داشت:

$$w' \Omega^{-1} = \frac{1}{2}(l'_i \otimes T) \left[\frac{1}{2} P + \frac{1}{2} Q \right] = \frac{1}{2}(l'_i \otimes T) \quad (4)$$

زیرا $(l'_i \otimes T) P = (l'_i \otimes T)$ و $(l'_i \otimes T) Q = 0$ می‌باشد. با استفاده از رابطه (۴)، جز

$$\hat{u}_{i, GLS} = \sum_{t=1}^T \hat{u}_{it, GLS} / T \quad \text{که } \left(\frac{1}{2} P + \frac{1}{2} Q \right) \hat{u}_{i, GLS} \text{ تبدیل به } w' \Omega^{-1} \hat{u}_{GLS}$$

می‌باشد. بنابراین، در رابطه (۴)، بهترین تخمین‌زننده بدون تورش خطی برای $y_{i,T+S}$

²⁴ Baltagi

توسط نسبتی از میانگین باقیمانده‌ها موجب تصحیح پیش‌بینی می‌شود. در مدل جزء خطای دو طرفه، برای دوره‌ی T+S خواهیم داشت:

$$u_{i,T+S} = \mu_i + \epsilon_{T+S} + v_{i,T+S} \quad (5)$$

و

$$E(u_{i,T+S} u_{jt}) = \sigma_\mu^2 \quad \text{برای } i=j \quad (6)$$

$$E(u_{i,T+S} u_{jt}) = 0 \quad \text{برای } i \neq j$$

بنابراین، برای بهترین تخمین‌زننده بدون تورش خطی ارائه شده در رابطه (۲)،
 $w = E(u_{i,T+S} u) = \frac{1}{N} \sum_{i=1}^N (l_i \otimes 1_T)$ ثابت باقی می‌ماند و l_i ستون i ام از ماتریس یک‌به‌یک با ابعاد $N \times N$ است. در این حالت خواهیم داشت:

$$w' w^{-1} = \frac{1}{N} \sum_{i=1}^N \left[\frac{1}{l_i} Q_i \right] \quad (7)$$

با توجه به این که

$$(l_i \otimes 1_T) Q_1 = 0 \quad (l_i \otimes 1_T) Q_2 = (l_i \otimes 1_T) - \frac{1}{NT} N \quad (8)$$

$$(l_i \otimes 1_T) Q_3 = 0 \quad (l_i \otimes 1_T) Q_4 = \frac{1}{NT} N$$

عبارت زیر حاصل می‌شود:

$$w' w^{-1} = \frac{1}{N} \left[(l_i \otimes 1_T) - \frac{1}{NT} N \right] + \frac{1}{4} \left(\frac{1}{NT} N \right) \quad (9)$$

بنابراین، جزء معمول $w' w^{-1} \hat{u}_{GLS}$ (که $\hat{u}_{GLS} = y - Z'_{GLS}$) به صورت زیر است:

$$\frac{T}{\left(\frac{T}{\mu} + \frac{2}{\nu} \right)} \left(\bar{\hat{u}}_{i, GLS} - \bar{\hat{u}}_{\dots, GLS} \right) + \frac{T}{\left(\frac{T}{\mu} + N \frac{2}{\nu} + \frac{2}{\nu} \right)} \bar{\hat{u}}_{\dots, GLS} \quad (10)$$

که $\bar{\hat{u}}_{i, GLS} = \sum_{i=1}^T \hat{u}_{i, GLS} / T$ و $\bar{\hat{u}}_{\dots, GLS} = \sum_i \sum_t \hat{u}_{i, GLS} / NT$ است. بنابراین، برای

مدل جزء خطای دو طرفه، بهترین برآوردکننده بدون تورش خطی برای $y_{i,T+S}$ با استفاده از بخشی از میانگین باقیمانده‌ها موجب تصحیح تخمین می‌شود:

$$\hat{y}_{i,T+S} = Z'_{i,T+S} \hat{u}_{GLS} + \left(\frac{T}{\frac{T}{\mu} + \frac{2}{\nu}} \right) \bar{\hat{u}}_{i, GLS} \quad (11)$$

۳-۳- پیش‌بینی با مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا

شبکه‌های عصبی مصنوعی یک مدل پردازش توزیع‌شده موازی است که از چندین تابع یا واحدهای پردازش اصلی تشکیل شده است. توابع فعال‌ساز مورد استفاده در شبکه عصبی اغلب از نوع خطی، سیگموئید و هایپربولیک می‌باشند. تصریح مدل شبکه عصبی مصنوعی بر اساس مشاهدات صورت می‌پذیرد و با توجه به متناهی بودن تعداد نقاط، توابع بسیاری را می‌توان یافت که به خوبی برازش را انجام دهند. بنابراین لازم است که از این وضعیت، که تحت عنوان بیش‌برازش نامیده می‌شود، اجتناب نمود؛ زیرا، این امر منجر به باز آفرینی داده‌ها می‌شود، بدون آن که از قدرت تعمیم لازم برخوردار باشد (کنتارلا و لوکا^{۲۵}، ۲۰۰۵؛ کو و بوسرونگسه، ۲۰۰۷).

در این مطالعه، برای طراحی مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا، از ساختار داده‌های پانل به عنوان ورودی‌های شبکه استفاده می‌گردد. این امر با اضافه نمودن متغیرهای اثرات کشوری و زمانی صورت می‌پذیرد تا از این طریق ناهمگنی میان مقاطع در مدل هیبرید در نظر گرفته شود. بر این اساس، ورودی‌های شبکه شامل ۲۱ متغیر اثر زمانی (به تعداد سال‌های مورد مطالعه)، ۱۰ متغیر اثر کشوری (تعداد بازارهای مقصد) و ۱۰ نرخ ارز دوجانبه برای هر یک از خشکبار مورد بررسی است. تعداد نرون‌های لایه‌های خروجی برابر با یک و تعداد نرون‌های لایه‌ی ورودی برابر با تعداد متغیرهای توضیحی (۴۱ متغیر اشاره شده) است.

همچنین، از روش توقف زودرس برای بهبود قابلیت تعمیم‌پذیری شبکه استفاده می‌گردد. بر اساس این روش داده‌ها به سه دسته آموزش، اعتبارسنجی و آزمون تقسیم می‌شوند. از داده‌های آموزش (۸۵-۱۳۷۱) و داده‌های اعتبارسنجی (۸۸-۱۳۸۶) به ترتیب برای تعدیل وزن‌ها و اطمینان از عملکرد شبکه عصبی و از داده‌های آزمون (۹۱-۱۳۸۹) برای مشخص نمودن این مسأله استفاده می‌گردد که آیا شبکه طراحی شده به تولید مجدد داده‌ها پرداخته است یا خیر.

در لایه پنهان از تابع فعال‌ساز هایپربولیک و در لایه خروجی از تابع فعال‌ساز خطی استفاده شده است. همچنین، از تبدیل زیر برای نرمال‌سازی داده‌ها استفاده شده است:

$$pn = 2 \times [(p - \min p) / (\max p - \min p)] - 1$$

²⁵ Cantarella and Luca

که p ورودی اصلی، pn ورودی نرمال شده، $\min p$ مقدار حداقل هر ورودی و $\max p$ مقدار حداکثر هر ورودی است. با استفاده از تبدیل فوق، داده‌های ورودی نرمال شده در محدوده‌ای بین -1 تا $+1$ قرار می‌گیرند.

۳-۴- معرفی معیارهای مقایسه و ارزیابی دقت در روش‌های پیش‌بینی
 به منظور مقایسه و ارزیابی روش‌های مختلف پیش‌بینی از معیارهایی نظیر میانگین مجذور خطا^{۲۶}، مربع مجذور میانگین خطا^{۲۷}، میانگین قدر مطلق خطا^{۲۸} و میانگین درصد قدر مطلق خطا^{۲۹} استفاده می‌شود که در جدول (۱) اطلاعات مربوط به این معیارها گزارش شده است (مقادیر \hat{y}_i ، y_i و n به ترتیب نشان‌دهنده مقادیر پیش‌بینی شده، مقادیر واقعی و تعداد داده‌ها می‌باشد).

جدول ۱: معیارهای مقایسه و ارزیابی دقت در پیش‌بینی

فرمول	معیار
$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$	میانگین مربعات خطا
$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$	مجذور میانگین مربعات خطا
$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	میانگین قدر مطلق خطا
$MAPE = \frac{1}{n} \sum_{i=1}^n \left \frac{y_i - \hat{y}_i}{y_i} \right \times 100$	میانگین درصد قدر مطلق خطا

۴- نتایج و بحث

در این بخش از مطالعه، در ابتدا به مدل‌سازی پانل دیتا (مدل رگرسیونی جز خطای دو طرفه) و مدل هیبرید پرداخته می‌شود و سپس خروجی‌های دو روش مذکور مقایسه و بهترین مدل برای پیش‌بینی صادرات خشکبار مورد بررسی انتخاب می‌گردد.

²⁶ Mean Squared Error (MSE)

²⁷ Root Mean Square Error (RMSE)

²⁸ Mean Absolute Error (MAE)

²⁹ Mean Absolute Percentage Error (MAPE)

۴-۱- مدل پانل دیتا

به منظور برآورد و پیش‌بینی صحیح الگوی (۱)، از آزمون‌های ریشه واحدیم-پسران و شین^{۳۰}، چاو و هاسمن استفاده شده است. در این مقاله به چند دلیل از آزمون ریشه واحد IPS استفاده شده است: (۱) در آزمون ریشه واحد IPS نیازی نیست که داده‌های تابلویی متوازن باشند؛ (۲) آزمون ریشه واحد IPS اجازه می‌دهد تا روند ایجاد داده‌ها در میان کشورها با توجه به ضرایب ADF و ساختار جملات خطا متفاوت باشد؛ (۳) آماره t -بار در آزمون IPS برای نمونه‌هایی با حجم محدود N و T دارای عملکرد بهتری است؛ (۴) آزمون IPS نمونه‌ها را به صورت جدا از یکدیگر در نظر می‌گیرد و در محاسبات طوری عمل می‌کند که ویژگی خاص هر یک از کشورهای مورد بررسی لحاظ شود. نتایج آزمون ریشه واحد IPS برای پسته، کشمش و خرما در جدول (۲) گزارش شده است. بر اساس نتایج جدول (۲)، فرض صفر مبنی بر وجود ریشه واحد در سطح اطمینان ۹۵ درصد برای تمام متغیرهای مورد بررسی رد می‌شود و در نتیجه متغیرهای الگوی (۱) ایستا می‌باشند.

لزوم استفاده از داده‌های پانل و الگوی جزء خطای دو طرفه با استفاده از آزمون چاو مورد بررسی قرار می‌گیرد. در جدول (۳)، نتایج آزمون چاو برای هر یک از خشکبار مورد بررسی ارائه شده است. نتایج آزمون چاو در جدول (۳) نشان می‌دهد که اثرات زمانی (λ_t) و اثرات کشوری (μ_i) به طور همزمان در سطح اطمینان ۹۵ درصد معنی‌دار هستند و دو طرفه بودن مدل جزء خطا در الگوی (۱) مورد تأیید قرار می‌گیرد.

مرحله‌ی بعد انتخاب روش برآورد الگوی (۱) است. نتایج آزمون هاسمن برای هر یک از خشکبار مورد بررسی در جدول (۴) گزارش شده است. مقدار آماره هاسمن برای سه محصول پسته، کشمش و خرما در جدول (۴) نشان می‌دهد که فرض صفر مبنی بر وجود اثرات تصادفی در سطح اطمینان ۹۵ درصد رد می‌شود و بهتر است برآورد الگوی (۱) به روش اثرات ثابت انجام شود.

³⁰ Im, Pesaran and Shin (IPS)

جدول ۲: نتایج آزمون ریشه واحد IPS

خشکبار مورد بررسی						نام متغیر
پسته		کشمش		خرما		
ارزش احتمال	مقدار آماره آزمون	ارزش احتمال	مقدار آماره آزمون	ارزش احتمال	مقدار آماره آزمون	
۰/۰۰۰	-۵/۰۰۱	۰/۰۰۰	-۵/۰۳۰	۰/۰۰۰	-۵/۷۲۲	قیمت صادرات
۰/۰۰۰	-۸/۶۳۷	۰/۰۰۰	-۷/۶۴۲	۰/۰۰۰	-۸/۲۲۲	نرخ ارز

مأخذ: محاسبات تحقیق

جدول ۳: نتایج آزمون چاو برای هر یک از خشکبار مورد بررسی

آزمون اثرات مقطعی و زمانی			
محصول	مقدار آماره آزمون	درجه آزادی	ارزش احتمال
پسته	۴۰۶/۸۰۹	(۱۷۰،۲۹)	۰/۰۰۰
کشمش	۵۳۰/۴۵۳	(۱۷۰،۲۹)	۰/۰۰۰
خرما	۵۷/۸۰۴	(۱۷۰،۲۹)	۰/۰۰۰

مأخذ: محاسبات تحقیق

جدول ۴: نتایج آزمون هاسمن برای هر یک از خشکبار مورد بررسی

محصول	مقدار آماره آزمون	درجه آزادی	ارزش احتمال
پسته	۶۷/۴۵	۱۰	۰/۰۰۰
کشمش	۸۳/۴۳	۱۰	۰/۰۰۰
خرما	۱۹/۳۷	۱۰	۰/۰۳۵


مأخذ: محاسبات تحقیق

با توجه به آزمون‌های آماری انجام شده، الگوی جز خطای دوطرفه (الگوی ۱) با استفاده از روش اثرات ثابت برآورد گردید و سپس، پیش‌بینی قیمت صادرات پسته، کشمش و خرما بر اساس مدل داده‌های پانل صورت پذیرفت.

۲-۴- مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا

همانطور که اشاره گردید؛ مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا رهیافت دیگری است که در این مطالعه برای پیش‌بینی قیمت صادرات پسته، کشمش و خرما استفاده شده است. با توجه به موارد مطرح شده، ساختار مدل هیبرید مطابق با شکل (۱) است.

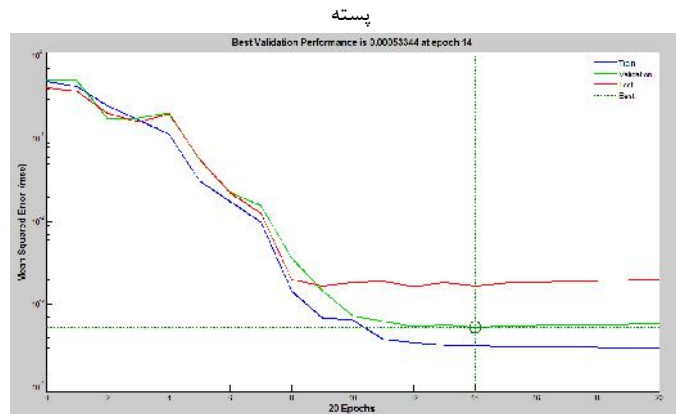
شکل ۱: ساختار مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا برای هر یک از خشکبار مورد




با توجه به شکل (۱)، برای هر یک از خشکبار مورد بررسی، مدل هیبرید مورد استفاده شامل ۴۱ متغیر ورودی و یک متغیر خروجی است. مطابق با شکل (۱)، در لایه پنهان از تابع فعال‌ساز هایپربولیک با ۴ نرون و در لایه خروجی از تابع فعال‌ساز خطی با یک نرون استفاده گردیده است.

پس از طراحی و اجرای مدل هیبرید با مشخصات مذکور، برای هر یک از خشکبار مورد بررسی، روند تغییرات میانگین مربعات خطا برای سه مجموعه داده (آموزش، اعتبارسنجی و آزمون) در شکل (۲) نشان داده شده است.

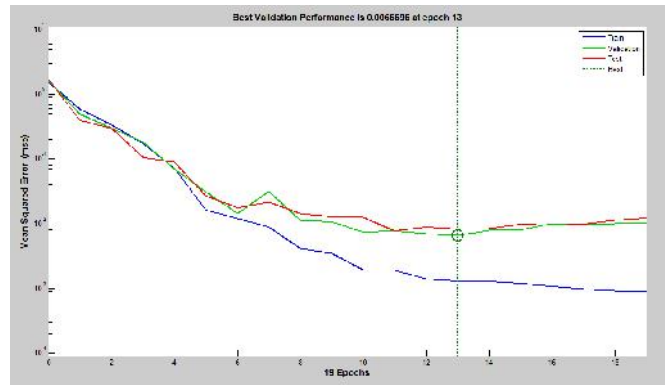
شکل ۲: میانگین مربعات خطا برای سه مجموعه آموزش، اعتبارسنجی و آزمون



کشمش



خرما



مطابق با شکل (۲)، با توجه به مشابه بودن روند تغییرات خطا در مجموعه‌های اعتبارسنجی و آزمون، عملکرد شبکه مطلوب است و مشکل بیش برآزش در مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا وجود ندارد.

۳-۴- مقایسه عملکرد مدل‌های پیش‌بینی

پس از انجام پیش‌بینی‌های مربوط به مدل رگرسیونی جز خطای دو طرفه و مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا، عملکرد پیش‌بینی این دو مدل بر اساس معیارهای دقت، مورد ارزیابی قرار گرفته است که نتایج آن به تفکیک خشکبار مورد بررسی، در جدول (۵) گزارش گردیده است.

جدول ۵: مقایسه و ارزیابی دقت پیش‌بینی برای هر یک از خشکبار مورد بررسی

خشکبار مورد بررسی	معیارهای ارزیابی دقت			
	MAPE	MAE	RMSE	MSE
پسته	۰/۶۵۹۵	۰/۰۶۱۸	۰/۰۸۷۰	۰/۰۰۷۵
	۰/۲۱۹۳	۰/۰۱۵۵	۰/۰۲۳۶	۰/۰۰۰۵
کشمش	۰/۷۳۸۰	۰/۰۵۳۴	۰/۰۸۸۵	۰/۰۰۷۸
	۰/۵۹۸۷	۰/۰۱۵۳	۰/۰۲۳۰	۰/۰۰۰۵
خرما	۲/۱۴۵۷	۰/۱۵۴۰	۰/۲۰۱۶	۰/۰۴۰۶
	۱/۳۵۲۰	۰/۰۳۷۵	۰/۰۵۶۰	۰/۰۰۳۱

مأخذ: محاسبات تحقیق

نتایج جدول (۵) نشان می‌دهد که روش ترکیبی شبکه عصبی مصنوعی-پانل دیتا در مقایسه با روش پانل دیتا (مدل جز خطای دو طرفه) از توانایی و دقت بیشتری در پیش‌بینی قیمت صادرات خشکبار مورد بررسی برخوردار است. یافته قابل توجه دیگر این است که دقت پیش‌بینی قیمت صادرات کشمش و خرما با استفاده از دو روش مذکور در مقایسه با قیمت صادرات خرما به طور نسبی بهتر می‌باشد. اما، مسأله‌ای که باید به آن توجه نمود این است که مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا به دلیل در نظر گرفتن روابط غیرخطی و ناهگمنی میان بازارهای مقصد از دقت بالاتر و عملکرد بهتری در مقایسه با مدل پانل دیتا برخوردار است^{۳۱}. بنابراین، برتری شبکه‌های عصبی مصنوعی تنها محدود به روش‌های سری‌زمانی یا مقطع زمانی نمی‌باشد و این روش از برتری قابل توجهی نسبت به روش‌های پیشرفته‌تری همچون روش‌های داده‌های پانل برخوردار است.

۵- نتیجه‌گیری

جایگاه و اهمیت بخش کشاورزی در اقتصاد ایران به دلیل سهم قابل توجه آن در توسعه و گسترش صادرات غیرنفتی، تأمین امنیت غذایی و افزایش اشتغال است. در میان محصولات کشاورزی؛ پسته، کشمش و خرما به عنوان گیاهان استراتژیک و مهم در اقتصاد ملی شناخته می‌شوند. لذا، ارزیابی و مقایسه عملکرد روش ترکیبی شبکه عصبی مصنوعی-پانل دیتا و رگرسیون پانل دیتا (مدل جز خطای دو طرفه) در پیش‌بینی اثر نرخ ارز بر قیمت صادرات خشکبار ایران (پسته، کشمش و خرما)

^{۳۱} با استفاده از مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا برای هر یک از خشکبار مورد بررسی، پیش‌بینی قیمت صادرات تحت سناریوهای مختلف ارزی صورت پذیرفته است که به دلیل طولانی بودن جداول، از ذکر آن‌ها در متن مقاله خودداری شده است.

هدف اصلی این مطالعه می‌باشد. با استفاده از داده‌های پانل مربوط به ده بازار مقصد برای هریک از خشکبار مورد بررسی طی دوره‌ی ۹۱-۱۳۷۱، نتایج مطالعه نشان داد که مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا به منظور پیش‌بینی قیمت صادرات پسته، کشمش و خرما در مقایسه با مدل رگرسیون پانل دیتا دارای دقت بالا و عملکرد بهتری است. لذا، استفاده از روش ترکیبی شبکه عصبی مصنوعی-پانل دیتا باعث کاهش حجم قابل ملاحظه‌ای از محاسبات و افزایش دقت خواهد شد. با توجه به گسترش روز افزون مدل‌های شبکه عصبی مصنوعی و رویکرد پانل دیتا، به محققین پیشنهاد می‌گردد که برای استفاده از ویژگی‌های منحصر به فرد هر یک از این روش‌ها، از مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا در پیش‌بینی متغیرهای اقتصادی استفاده نمایند. در واقع، استفاده از مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا از یک سو می‌تواند عملکرد و دقت پیش‌بینی را به طور قابل توجهی افزایش دهد و از سوی دیگر، یک روش مناسب در مطالعاتی است که محدودیت دسترسی به آمار و اطلاعات سری‌زمانی وجود دارد. انجام پیش‌بینی‌های جداگانه برای هر یک از مناطق مورد بررسی، ویژگی دیگر مهم مدل هیبرید شبکه عصبی مصنوعی-پانل دیتا است.

فهرست منابع:

- زارع مهرجردی، محمدرضا و امیرحسین توحیدی. (۱۳۹۲). رابطه انتقالی نرخ ارز در بازارهای صادراتی پسته ایران: رویکرد داده‌های تابلویی. ۵، (۲): ۱۸۵-۱۶۵.
- نجفی، بهالدین و محمدحسن طرازکار. (۱۳۸۵). پیش‌بینی میزان صادرات پسته ایران: کاربرد شبکه عصبی مصنوعی. پژوهشنامه بازرگانی، ۱۰، (۳۹): ۲۱۴-۱۹۱.
- Adhikari, R. & R.K. Agrawal. (2014). A Combination of Artificial Neural Network and Random Walk Models For Financial Time Series Forecasting. *Neural Computing and Applications*, 24(6): 1441-1449.
- Areekul, P., T. Senjyu, H. Toyama & A. Yona. (2010). Notice of Violation of IEEE Publication Principles A Hybrid ARIMA and Neural Network Model for Short-Term Price Forecasting In Deregulated Market. *Power Systems, IEEE Transactions on*, 25(1): 524-530.
- Baltagi, B.H. (2005). *Econometric Analysis of Panel Data*. 3rd Edition, New York: John Wiley and Sons.
- Bildirici, M. & Ö.Ö. Ersin. (2009). Improving Forecasts of GARCH Family Models with The Artificial Neural Networks: An Application to The Daily Returns in Istanbul Stock Exchange. *Expert Systems with Applications*, 36(4): 7355-7362.
- Cantarella, G.E. & S.DE. Luca. (2005). Multilayer Feedforward Networks for Transportation Mode Choice Analysis: An Analysis and a Comparison with Random Utility Models. *Transportation Research Part C: Emerging Technologies*. 13(2): 121-155.
- Co, H.C. & R. Boosarawongse. (2007). Forecasting Thailand's Rice Export: Statistical Techniques Vs. Artificial Neural Networks. *Computers & industrial engineering*. 53(4): 610-627.
- Diaz-Robles, L. A., J. C. Ortega, Fu, J.S. Reed, G.D. Chow, J.C. Watson, J.G. & J.A. Moncada-Herrera. (2008). A Hybrid ARIMA and Artificial Neural Networks Model to Forecast Particulate Matter in Urban Areas: The Case of Temuco, Chile. *Atmospheric Environment*, 42(35): 8331-8340.
- Faruk, D.Ö. (2010). A Hybrid Neural Network and ARIMA Model for Water Quality Time Series Prediction. *Engineering Applications of Artificial Intelligence*, 23(4): 586-594.
- Goldberg, P.K. & M.M. Knetter. (1997). Goods Prices and Exchange Rates: What Have We Learned?. *Journal of Economic Literature*. 35(3):1243-1272.

- Gujarati, D.N. (2003). *Basic econometrics*. 4th edition, New York: McGraw-Hill.
- Hoque, M.M. & A. Razzaque. (2004). Exchange Rate Pass-Through in Bangladesh's Export Prices: An Empirical Investigation. *The Bangladesh Development Studies*. 30 (1/2): 35-64.
- Jain, A. & A.M. Kumar. (2007). Hybrid Neural Network Models for Hydrologic Time Series Forecasting. *Applied Soft Computing*, 7(2): 585-592.
- Kaastra, I. & M. Boyd. (1996). Designing a Neural Network for Forecasting Financial and Economic Time Series. *Neurocomputing*, 10(3): 215-236.
- Khashei, M. & M. Bijari. (2011). A novel Hybridization of Artificial Neural Networks and ARIMA models for time series forecasting. *Applied Soft Computing*, 11(2): 2664-2675.
- Khashei, M., S. R. Hejazi & M. Bijari. (2008). A new Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting. *Fuzzy Sets and Systems*, 159(7): 769-786.
- Kim, K. H., J.K. Park, K.J. Hwang & S. H. Kim. (1995). Implementation of Hybrid Short-Term Load Forecasting System Using Artificial Neural Networks and Fuzzy Expert Systems. *Power Systems, IEEE Transactions on*, 10(3): 1534-1539.
- Lee, E.W., C. P. Lim, R.K. Yuen & S.M. Lo. (2004). A Hybrid Neural Network Model for Noisy Data Regression. *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, 34(2): 951-960.
- Leng, G., T. M. McGinnity & G. Prasad. (2005). An approach for on-Line Extraction of Fuzzy Rules Using A Self-Organising Fuzzy Neural Network. *Fuzzy Sets and Systems*, 150(2): 211-243.
- Liu, Z. K. & J.Y. Xiao. (1991). Classification of remotely-Sensed Image Data Using Artificial Neural Networks. *Remote Sensing*, 12(11): 2433-2438.
- Ruiz-Aguilar, J.J., I.J. Turias & M.J. Jiménez-Come. (2014). Hybrid Approaches Based on SARIMA and Artificial Neural Networks for Inspection Time Series Forecasting. *Transportation Research Part E: Logistics and Transportation Review*, 67: 1-13.
- Tseng, C.H., S.T. Cheng, Y. H. Wang & J.T. Peng. (2008). Artificial Neural Network Model of The Hybrid EGARCH Volatility of The Taiwan Stock Index Option Prices. *Physica A: Statistical Mechanics and its Applications*, 387(13): 3192-3200.

Tseng, F.M., Yu, H.C. & G.H. Tzeng. (2002). Combining Neural Network Model with Seasonal Time Series ARIMA model. *Technological Forecasting and Social Change*, 69(1): 71-87.

Wooldridge, J.M. (2006). *Introductory Econometrics: A Modern Approach*. 3rd Edition, New York: South-Western.

Zhang, G.P. (2003). Time Series Forecasting Using A Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50: 159-175.