

تأثیر سیستم پیش‌بینی تقاضای متلاطم بر اثر شلاقی در زنجیره تأمین: یک رویکرد مقایسه‌ای

رضا یوسفی زنوز*، محمدباقر منهج**

چکیده

یک مبحث مهم در مدیریت زنجیره تأمین، پدیده اثر شلاقی است. این مهم بیانگر افزایش تغییرپذیری تقاضای طی حرکت در طول زنجیره می‌باشد. در این مقاله تأثیر چندین روش کلاسیک و هوشمند در فرایند پیش‌بینی تقاضای متلاطم، در وقوع پدیده اثر شلاقی بررسی می‌شود. نتیجه این تحقیق حاکی از آن است که شبکه‌های عصبی در مقایسه با روش‌های معمول کلاسیک همچون روش هموارسازی نمایی با توجه به رفتار غیرخطی، نوسانی و حتی آشوبی تقاضای متلاطم، توان بیشتری در مدل‌سازی و پیش‌بینی این رفتار دارند. در انتهای مقاله به کمک یک مثال عددی، کاربرد بهره‌گیری از شبکه‌های عصبی در پیش‌بینی تقاضای متلاطم، در کاهش موفقیت آمیز پدیده اثر شلاقی به تصویر درآمده است.

کلید واژه‌ها: پیش‌بینی، مدیریت زنجیره تأمین، شبکه‌های عصبی مصنوعی، تقاضای متلاطم.

تاریخ دریافت مقاله: ۹۰/۲/۲۰، تاریخ پذیرش مقاله: ۹۰/۷/۲۸.

* دکتری مدیریت - تحقیق در عملیات دانشگاه تهران (نویسنده مسئول).

email: Reza_zenouz@yahoo.com

** استاد دانشکده مهندسی برق دانشگاه صنعتی امیرکبیر.

مقدمه

زنجیره‌تأمین، شبکه‌ای از تسهیلات و مکان‌های توزیع همچون تأمین‌کنندگان، تولیدکنندگان، توزیع‌کنندگان، خرده‌فروشان و مشابه آنها می‌باشد. این شبکه شامل کارکردهایی همچون خرید مواد خام، تبدیل این مواد به محصولات میانی و تمام‌شده و توزیع محصولات نهایی به مشتریان می‌باشد. نوعاً یک زنجیره تأمین با جریان رو به جلوی مواد و جریان روبه عقب اطلاعات مشخص می‌شود. مدیریت کارای زنجیره تأمین می‌تواند از یک سو، منجر به کاهش هزینه‌های مربوط به فرایند تولید، موجودی و حمل و نقل شده و از سوی دیگر موجب بهبود خدمت رسانی به مشتری در تمامی مراحل زنجیره تأمین گردد [۱۲]. یکی از پدیده‌های بسیار معمول در زنجیره‌های تأمین، پدیده اثر شلاقی است که اولین بار توسط فارستر شناسایی شد.

اثر شلاقی اشاره به این مسأله دارد که تغییرپذیری در تقاضا در طی حرکت در طول زنجیره تأمین از گره‌های پایین دست به سمت گره‌های بالادست، افزایش یافته و به صورت تقویت شده منتشر می‌شود [۹]. پدیده شلاقی به صورت بالقوه سبب ناکارآمدی‌های زیادی خواهد شد که عبارت اند از: انبارش موجودی بیش از نیاز در زنجیره به دلیل تغییرپذیری و عدم اطمینان از تقاضا، سطح خدمت ضعیف به مشتری به دلیل از دست دادن برنامه تولید و فروش، پیش‌بینی ضعیف تقاضا، تاخیرهای طولانی مدت، برنامه تولید نامطمئن، از دست دادن درآمد، انحراف در برنامه‌های ظرفیت و حمل‌ونقل غیر اثربخش. سؤالی که در این خصوص، رودروی سازمان‌ها قرار می‌گیرد، چگونگی بروز نوسانات زیاد در سفارشات دریافتی و راهکارهای موجود جهت کاهش تأثیر این نوسانات است. در این میان، ذکر این نکته حائز اهمیت است که پدیده اثر شلاقی نه تنها ناشی از رفتار غیرمنطقی بازیگران زنجیره نمی‌باشد، بلکه از رفتار کاملاً منطقی و معقول آنها در بستر زنجیره تأمین ناشی می‌شود [۱۱]. بدین منظور برای حل این مسأله ابتدا باید سازمان‌ها عوامل به وجود آورنده این مهم را شناسایی کنند. عوامل مهم شناخته شده در این حوزه به شرح زیر می‌باشند:

۱. به‌روز رسانی پیش‌بینی تقاضا یا پردازش سیگنال تقاضا؛

۲. دسته‌بندی سفارشات؛

۳. نوسانات قیمت؛

۴. جیره‌بندی در شرایط کمبود.

هریک از عوامل چهارگانه یاد شده، به همراه زیرساختار زنجیره تأمین و تصمیم‌گیری منطقی مدیران در صدور سفارش، اثر شلاقی را خلق می‌کنند [۱۱].

هر چند به استناد مقاله لی و دیگران، این چهار عامل، به وجود آورنده پدیده اثر شلاقی برشمرده شده‌اند، ولی در سال‌های اخیر، قریب به اتفاق مقالاتی که پدیده اثر شلاقی را در

زنجیره تأمین مورد بررسی و تحلیل قرار داده‌اند، فقط به بررسی یک یا حداکثر دو عامل پرداخته و بقیه عوامل را ثابت در نظر گرفته‌اند. در این بین، از میان این عوامل، پردازش سیگنال‌های تقاضا یا پیش‌بینی صحیح تقاضا مهمترین عامل محسوب می‌شود. لذا در این تحقیق نیز به تأثیر بهره‌گیری از روش‌های مختلف پیش‌بینی تقاضای متلاطم در کاهش اثر شلاقی در زنجیره تأمین پرداخته می‌شود. بخش‌های بعدی مقاله به صورت زیر سازماندهی شده‌اند؛ در بخش دوم به تشریح پیش‌بینی تقاضا و به ویژه تقاضای متلاطم پرداخته شده است. در ادامه به بررسی مقایسه‌ای روش‌های پیشرفته‌تر پیش‌بینی تقاضا، همچون شبکه‌های عصبی، شبکه‌های عصبی بازگشتی، و روش‌های کلاسیک پیش‌بینی همچون هموارسازی نمایی و سینتوس بر روی یک سری زمانی واقعی پرداخته شده است. در بخش بعدی مقاله، با توجه به خطای معیار کمینه برای پیش‌بینی رفتار تقاضای آتی، اقدام به گزینش روش برتر از میان موارد تشریح شده، گردیده است. سری زمانی به کار رفته در مثال عددی، مجموعه داده‌های واقعی است که تقاضای روزانه یک قطعه خاص خودرو را نشان می‌دهد. رفتار تقاضا، آشوبی و متلاطم است و نوسانات خیلی بالاست بدین معنا که در برخی دوره‌ها، تقاضا به صورت متوالی و متناوب، صفر بوده و در دوره‌ای دیگر بالاست. این رفتار به عنوان یک رفتار پیچیده، درجه غیرخطی بالایی دارد. لازم به ذکر است که ویژگی اساسی مجموعه داده به کار رفته، متلاطم بودن و نوسانات بسیار زیاد داده‌های تقاضا می‌باشد. انتظار این است که روش‌های پیشرفته همچون روش‌های هوشمند، بهتر از روش‌های سنتی پیش‌بینی عمل نمایند. روش‌های پیشرفته، مدل‌های غیرخطی را در محاسبه‌ها و تخمین‌ها دخیل نموده و می‌توانند به عنوان تقریب‌های بهتری از مدل‌های خطی عمل کنند. در بخش‌های ششم و هفتم نیز، خروجی سیستم‌های پیش‌بین متفاوت و مقدار عددی پدیده اثر شلاقی در آنها، محاسبه شده است. در انتها به جمع‌بندی و نتیجه‌گیری در این خصوص پرداخته شده است.

پیش‌بینی

طبق نظر لی، یکی از عوامل اصلی ایجاد اثر شلاقی، پردازش سیگنال‌های تقاضا می‌باشد (a,b1۹۹۷). بخش تولید در طی سالیان سعی در مدیریت عدم اطمینان در تخمین تقاضا داشته است. سعی در کاهش این عدم اطمینان، خود منجر به توسعه روش‌ها و فنون پیش‌بینی شده است [۷].

یکی از مسائل مهم در ایجاد اثر شلاقی، الگوریتم پیش‌بینی به کار گرفته شده از سوی بازیگران مختلف در زنجیره است. حتی اگر اصل اساسی به کار رفته در زنجیره، "انتقال سفارشات دریافت شده" باشد و دقیقاً همان مقدار سفارش دریافت شده از گره پایین‌دست به گره

بالادستی صادر شود نیز، اثر شلاقی می‌تواند ایجاد شود؛ کما اینکه این سیاست قبلاً در بازی نوشابه به عنوان موقعیت عقبگرد خوب، کارایی خود را نشان داده است. دلیل این وضعیت خلاف شهود، آن است که، اعضای زنجیره فراموش می‌کنند که ممکن است بهره‌گیری از الگوریتم‌های هموارسازی نمایی ساده، منجر به تقویت حداقل بخشی از طیف فرکانس شود. تحقیقات پیشین حاکی از آن است که بهره‌گیری از الگوریتم‌های هموارسازی نمایی خطی یا کوآدراتیک، نه فقط وقوع اثر شلاقی را ممکن می‌سازد بلکه بروز پدیده اثر شلاقی را قطعی می‌کند. در این میان باید متذکر شد که ماهیت اثر شلاقی در زنجیره‌های تامین، ضربی بوده و ماهیت جمعی ندارد [۴]. در این بین چنانچه میانگین و انحراف معیار تقاضا به دقت مشخص باشد، اثر شلاقی مشاهده نمی‌شود. این پدیده، زمانی بروز می‌کند که در هر دوره میانگین و انحراف معیار تقاضا، به‌روز گردد [۲].

هر چند که هموارسازی نمایی، ابزار پیش‌بینی بهینه بسیاری از فرایندهای تقاضا محسوب نمی‌شود، اما در عمل یکی از معمول‌ترین روش‌ها به حساب می‌آید. بررسی مروری ۳۵ تحقیق در خصوص بهره‌گیری از فنون پیش‌بینی، در عمل حاکی از آن است که کاربران با روش‌های ساده‌تر پیش‌بینی همچون میانگین متحرک، رگرسیون و هموارسازی نمایی آشنا تر بوده و رضایت آنها نیز بیشتر است. به طور متقابل، کمتر با روش‌های پیچیده‌تری چون باکس-جنکینز آشنا بوده و در عمل از آنها بهره می‌برند.

به هرحال چن و دیگران (۲۰۰۰) به این نتیجه رسیدند که، حتی در مقایسه هموارسازی نمایی و میانگین متحرک افزایش تغییرپذیری در نوسانات تقاضا در روش هموارسازی نمایی بیشتر است [۲]. از دیگر سو کراستون (۱۹۷۲) نشان داد که روش هموارسازی نمایی، یک روش پیش‌بینی اریب‌دار می‌باشد. این امر به ویژه زمانی که تقاضا متلاطم است، عینیت بیشتری دارد. این حالت در واحدهای تولیدی و خدماتی معمول است. وی بیان می‌دارد که با اینکه روش هموارسازی نمایی روش استاندارد است و به وفور جهت پیش‌بینی در سیستم‌های کنترل موجودی به کار برده شده است، ولی نوسان تقاضا کلاً به سطوح نامناسب موجودی می‌انجامد. وی اریبی را شناسایی می‌کند که با دادن بالاترین وزن به داده‌های تقاضای جدید مرتبط است. این اریب به برآوردهای تقاضایی منجر می‌شود که پس از وقوع تقاضا، بالاترین مقدار را دارا بوده و فقط تا قبل از آن، کمترین هستند. کراستون جهت نمایش این اریب، روش جدیدی برای پیش‌بینی تقاضای متلاطم با بهره‌گیری از هر دوی اندازه متوسط رخدادهای تقاضای غیرصفر و متوسط بازه بین چنین رخدادهایی، ارائه کرد [۷].

روش‌های کلاسیک پیش‌بینی

روش هموارسازی نمایی

این پیش‌بینی تنها یک مجموع وزنی بین آخرین مشاهده x_t و پیش‌بینی دوره ماقبل آخر F_t می‌باشد. در این روش تقاضای دوره بعد، با استفاده از رابطه شماره ۱، برآورد می‌گردد که در آن $0 < \alpha < 1$ ثابت هموارسازی نامیده می‌شود.

$$F_{t+1} = \alpha x_t + (1 - \alpha) F_t \quad (\text{رابطه ۱})$$

به دلیل وجود این روابط بازگشتی بین F_t و F_{t+1} ، می‌توان F_{t+1} را، به صورت دیگری نیز مشابه رابطه شماره ۲، نمایش داد. واضح است که در این شکل از بیان رابطه، هموارسازی نمایی بیشترین وزن را به x_t و وزن‌های کمتری را به مشاهدات قبل‌تر اختصاص می‌دهد. علاوه بر آن، این رابطه به این دلیل که، نیاز به نگهداری داده‌های قبل از دوره t ندارد در برآورد تقاضای دوره بعد، روش ساده‌ای خواهد بود.

$$F_{t+1} = \alpha x_t + \alpha(1 - \alpha)x_{t-1} + \alpha(1 - \alpha)^2 x_{t-2} + \dots \quad (\text{رابطه ۲})$$

تمامی آنچه که مورد نیاز است x_t و پیش‌بینی قبلی F_t می‌باشد. رابطه هموارسازی نمایی را به صورت دیگری مشابه رابطه شماره ۳، می‌توان بیان نمود:

$$F_{t+1} = F_t + \alpha(x_t - F_t) \quad (\text{رابطه ۳})$$

این رابطه نشان می‌دهد که پیش‌بینی برای دوره $t+1$ برابر مجموع پیش‌بینی دوره ماقبل آخر t و حاصل ضرب خطای پیش‌بینی در دوره t در یک ضریب تنزیل α می‌باشد [۸].

روش کراستون

این روش به طور جداگانه فاصله زمانی بین تراکنش‌های قبلی (P_i) و اندازه هر تراکنش (Z_i) را برآورد می‌کند. در دوره بازبینی t ، اگر هیچ تقاضایی اتفاق نیافتاده باشد، آنگاه در انتهای دوره t ، برآورد P_t ، Z_t تغییر نمی‌کند. اگر تراکنش اتفاق بیافتد، یعنی $Z_t > 0$ آنگاه برآوردها به صورت رابطه شماره ۴، به روز می‌شود:

$$\hat{Z}_t = \alpha Z_t + (1 - \alpha)\hat{Z}_{t-1}, \quad (\text{رابطه ۴})$$

$$\hat{P}_t = \alpha P_t + (1 - \alpha)\hat{P}_{t-1} \quad 0 \leq \alpha \leq 1$$

α ثابت هموارسازی می‌باشد. بنابراین پیش‌بینی تقاضای هر دوره در زمان t یعنی C_t به صورت زیر محاسبه می‌شود:

$$C_t = \frac{\hat{Z}_t}{\hat{P}_t} \quad (\text{رابطه ۵})$$

بیشتر نویسندگان معتقدند که روش کراستون برای پیش‌بینی تقاضای متلاطم از روش‌های سنتی مانند میانگین متحرک و هموارسازی نمایی ساده مناسب‌تر است. در روش کراستون (CR) برای پیش‌بینی تقاضای متناوب هم باید اندازه تقاضا و هم فاصله زمانی بین دریافت تقاضاها را در نظر گرفت، اما می‌توان اثبات کرد که روش کراستون یقیناً اریب دارد (اریب مثبت). جانسون و بویلان (۱۹۹۶) روش کراستون را مجدداً مورد بررسی قرار دادند. آنها با بهره‌گیری از تحلیل شبیه‌سازی دریافتند که متوسط بازه بین رخداد تقاضا باید از $1/25$ برابر دوره‌های اصلاح پیش‌بینی بزرگتر باشد تا مزیت روش کراستون بر هموارسازی نمایی درک شود [۱۳].

روش سینتوس

محققان مختلف، برخی تعدیل‌ها و بهبودها بر روش هموارسازی نمایی ارائه نموده‌اند و برای از بین بردن اریب این روش کوشیده‌اند، برخی از این روش‌ها همچون روش کراستون، روش سینتوس و بویلان، روش لون و سگرستد در عمل چندان موفق نبوده‌اند. در این بین، روش سینتوس عملکرد بسیار بهتری داشته زیرا هم واریانس پیش‌بینی کمتری داشته و هم، تقریباً ناریب می‌باشد. لذا، به عنوان یک روش کلاسیک برای پیش‌بینی تقاضای متلاطم، انتخاب شد. در این روش، در دوره بازبینی t ، اگر هیچ تقاضایی اتفاق نیافتاده باشد، آنگاه در انتهای دوره t ، برآورد P_t, Z_t تغییر نمی‌کند. اگر تراکنش اتفاق بیافتد، یعنی $Z_t > 0$ آنگاه برآوردها به صورت زیر به روز می‌شود:

$$\begin{aligned} \hat{Z}_t &= \alpha Z_t + (1 - \alpha) \hat{Z}_{t-1}, \\ \hat{P}_t &= \alpha P_t + (1 - \alpha) \hat{P}_{t-1} \end{aligned} \quad 0 \leq \alpha \leq 1 \quad (\text{رابطه ۶})$$

پیش‌بینی تقاضای هر دوره در زمان t یعنی S_t به صورت رابطه شماره ۷، محاسبه می‌شود [۱۳].

$$S_t = \left(1 - \frac{\alpha}{2}\right) \frac{\hat{Z}_t}{\hat{P}_t - \frac{\alpha}{2}} \quad (\text{رابطه ۷})$$

روش‌های هوشمند در پیش‌بینی تقاضای متلاطم

زنجیره تأمین را می‌توان در سطوح مختلف مانند پردازش مواد، تولید، توزیع، مشتریان و غیره مدل قرار دارد. روش‌های آماری فقط برای داده‌هایی که الگوهای فصلی یا روند دارند، مفیدند، در حالی که، روش‌های هوش محاسباتی برای داده‌های موارد خاص مانند ارتقاء یا بحران عجیب هم کاربرد دارند [۶]. از بین روش‌های مختلف هوش محاسباتی فقط به بررسی شبکه‌های عصبی در پیش‌بینی سری‌های زمانی پرداخته می‌شود.

شبکه‌های عصبی


طی دهه‌های اخیر علاقه بسیار زیادی در استفاده از شبکه‌های عصبی در مدل‌سازی و پیش‌بینی سری‌های زمانی نشان داده شده است. شبکه‌های عصبی دارای چندین ویژگی برجسته می‌باشند که آنها را در امر پیش‌بینی جذاب و ارزشمند ساخته است. مزیت و برتری عمده آنها را می‌توان توانایی مدل‌سازی انعطاف‌پذیر غیرخطی دانست. این ویژگی شبکه‌های عصبی را توانمند می‌سازد تا هر تابع پیوسته قابل اندازه‌گیری را با دقت بسیار بالایی تقریب بزند. به علاوه بر خلاف روش‌های سنتی مبتنی بر مدل، شبکه‌های عصبی روش‌های خودسازمانده داده‌محور می‌باشند که پیش‌فرض‌های بسیار کمی را از قبل در خصوص مسأله مورد بررسی اعمال می‌کنند. علیرغم برتری‌های یاد شده، این مدل‌ها نیز دارای نقاط ضعفی هستند که مهم‌ترین آن محدودیت داده، می‌باشد. به علاوه هیچ قاعده قطعی و معینی برای حجم نمونه مورد نیاز برای یک مسأله وجود ندارد. اندازه داده برای یادگیری شبکه به ساختار شبکه، روش یادگیری و پیچیدگی مسأله خاص یا مقدار اختلال در داده‌های در دست، وابسته است [۱۰].

شبکه‌های عصبی بازگشتی

در شبکه‌های عصبی بازگشتی سیگنال‌های خروجی برخی از نرون‌ها به عقب بازگشته و به عنوان ورودی برای نرون‌های همان لایه یا لایه‌های قبل عمل می‌کنند. شبکه‌های عصبی بازگشتی ابزار قدرتمندی در حل مسائل پیچیده می‌باشند، به ویژه زمانی که هدف پیش‌بینی داده‌های سری‌های زمانی باشد [۱].

داده‌ها

به منظور بررسی و مقایسه اثربخشی روش‌های مختلف پیش‌بینی یک مجموعه داده واقعی ۱۰۰۰ تایی مربوط به زنجیره تأمین شرکت ساپکو گردآوری گردید. این داده‌ها نشانگر تقاضای روزانه یک قطعه خاص خودرو می‌باشد. ویژگی خاص این مجموعه داده، متلاطم بودن و رفتار بسیار نوسانی آن است که امر پیش‌بینی را پیچیده ساخته و عدم اطمینان را افزایش می‌دهد. تقریباً مقادیر ۱۰٪ داده‌های تقاضا، صفر بوده و تغییرات در مقادیر تقاضا بین دوره‌های مختلف بسیار بالاست، داده‌ها در شکل شماره یک، به تصویر در آمده است، همان‌گونه که از شکل، نمایان است، رفتار داده‌ها کاملاً متلاطم، آشوبی و غیرخطی است.



شکل ۱. نمایش داده‌های سری زمانی تقاضا

برخی ویژگیهای آماری داده‌ها نیز در جدول شماره یک، نمایش داده شده است. داده‌ها رفتار سیکلی با روند صعودی را از خود نشان می‌دهند. در این میان حجم داده‌ها به منظور پیش‌بینی از سوی شبکه‌های عصبی نیز کافی می‌باشد.

جدول ۱. ویژگیهای آماری سری زمانی تقاضا

تعداد داده‌های غیرصفر	دامنه	بیشینه مقدار	مقدار کمینه	میانگین	انحراف استاندارد
۹۰۰	۲۲۲۳۰	۲۲۲۳۰	۰	۱۰۶۸۰	۴۵۲۲

خروجی سیستم‌های پیش‌بین مختلف

در بررسی و تحلیل مقایسه‌ای رویکردهای مختلف پیش‌بینی جهت پیش‌بینی تقاضای متلاطم از چندین سیستم پیش‌بین، بهره گرفته شد. این سیستم‌ها شامل روش‌های سنتی مانند: نایو، هموارسازی نمایی، روش سینتوس و رویکردهای مبتنی بر یادگیری ماشین همچون شبکه‌های عصبی و شبکه‌های عصبی بازگشتی می‌باشد. در ادامه نتایج به کارگیری فنون مختلف پیش‌بینی در پیش‌بینی تقاضای متلاطم ارائه می‌شود.

روش نایو

نایو همان گونه که گفته شد، یکی از ساده‌ترین روش‌های پیش‌بینی است و اغلب به عنوان یک روش پایه‌ای برای مقایسه عملکرد سایر روش‌های پیش‌بینی به کار می‌رود.

روش هموارسازی نمایی

غبار و فرند (۲۰۰۳) روش هموارسازی نمایی را روشی استاندارد برای پیش‌بینی تقاضای متلاطم قلمداد کرده‌اند. ارزیابی روش هموارسازی نمایی به عنوان یک ابزار پیش‌بینی، روشی معمول در ادبیات پیش‌بینی تقاضای متلاطم می‌باشد. استفاده از مقادیر پایین ضریب هموارسازی نمایی (α) در بازه بین $0/2 - 0/05$ معمول بوده و در ادبیات تقاضای متلاطم نیز، پیشنهاد شده است. در بررسی مقایسه‌ای روش‌های پیش‌بینی در تحقیق حاضر نیز از ضریب $\alpha = 0.2$ بهره گرفته شده است [۷].

روش سینتتوس

همانگونه که گفته شد، محققان مختلف، برخی تعدیله‌ها و بهبودها بر روش هموارسازی نمایی ارائه کردند و برای از بین بردن اریب این روش کوشیده‌اند. از این بین، روش سینتتوس عملکرد بسیار بهتری داشته زیرا هم واریانس پیش‌بینی کمتری داشته و هم، تقریباً ناریب می‌باشد، لذا، به عنوان یک روش کلاسیک برای پیش‌بینی تقاضای متلاطم، انتخاب شد.

شبکه‌های عصبی

یکی از رویکردهای معمول در معتبرسازی سیستم‌های عصبی، تفکیک داده‌ها است که معمولاً سه مجموعه داده را شامل می‌شود: یادگیری، تست و معتبرسازی. این روش به طور تصادفی، داده‌ها را به سه دسته: مجموعه داده یادگیری، مجموعه داده تست و مجموعه داده معتبرسازی تقسیم می‌کند. مجموعه داده آموزش یا یادگیری، برای ساخت شبکه به کار می‌رود در حالی که مجموعه داده تست، برای تعیین شبکه‌ای که برآزش بیش از حد^۱ دارد و مجموعه داده معتبرسازی برای بررسی قابلیت تعمیم شبکه در هر دوره، به کار می‌رود. در مجموعه داده مورد بررسی، که سری زمانی تقاضای یک قطعه خودرو می‌باشد، صفر شدن مقدار تقاضا در برخی دوره‌ها یکی از ویژگی‌های فیزیکی سیستم است؛ بنابراین در پیش‌بینی تقاضای آتی نمی‌توان صفرها را از بررسی کنار گذاشت. از داده چهار دوره قبل برای پیش‌بینی دوره پنجم بهره گرفته می‌شود زیرا که تحلیل و بررسی داده‌ها نشان می‌دهد که، مقدار داده پنجم تنها به چهار دوره قبل خود بستگی دارد. این نتیجه با انجام چند نمونه آزمون خودهمبستگی به دست آمد.

جدول شماره ۲، بهترین معماری شبکه را برای سه مجموعه داده مختلف، نشان می‌دهد؛ معماری بهینه همانگونه که گفته شد، بر اساس معیار حداقل خطای ارزیابی با بهره‌گیری از

داده‌های تست، انتخاب شد. I ($i=1,2,\dots,20$) شماره انتخاب پارامترهای شبکه و ($j=1,2,\dots,40$) تعداد نرون‌ها در لایه میانی است.

جدول ۲. بهترین معماری شبکه برای مجموعه داده‌های مختلف

تعداد نورون بهینه لایه میانی	پرسپترون چندلایه		شبکه بازگشتی	
	i	J	i	J
مجموعه داده ۱	۲۰	۴۰	۱	۱۶
مجموعه داده ۲	۲۰	۱۹	۱	۹
مجموعه داده ۳	۱۱	۱۰	۱	۱۷

انتخاب معیار خطا

به منظور مقایسه روش‌های مختلف پیش‌بینی، معیار میانگین قدرمطلق درصد خطا^۱ به عنوان یک معیار کلی، در نظر گرفته شد. به دلیل اینکه در تقاضای متلاطم، میزان تقاضا در دوره‌هایی صفر است، تعریف اصلی MAPE که در برخی دوره‌ها به صورت $|E_t|/D_t$ که E_t و D_t به

ترتیب تقاضای واقعی و خطای پیش‌بینی را در دوره t نمایش می‌دهد و نمی‌تواند عمل کند زیرا، مخرج کسر برای برخی دوره‌های زمانی صفر می‌شود، پس به جای تعریف سنتی MAPE، از تعریف جایگزین دیگری که در رابطه شماره ۸، به نمایش در آمده است، بهره گرفته می‌شود:

$$MAPE = \frac{\sum_{t=1}^n |E_t|}{\sum_{t=1}^n D_t} \quad (\text{رابطه ۸})$$

البته برای پایدار بودن مقایسه‌ها، معیارهای خطای دیگری نیز غیر از MAPE باید مورد توجه قرار می‌گرفت. مطالعه قبلی (آرمسترانگ و کولوبی ۱۹۹۲) معیارهای مقایسه خطاها بین ۹۰ داده سری زمانی سالانه و ۱۰۱ داده سری زمانی فصلی را ارزیابی نمود. آن مطالعه استنتاج می‌کند که اگر خطاهای ممکن پیش‌بینی بزرگ باشد، MAPE نایستی به عنوان معیار ارزیابی انتخاب شود زیرا MAPE پیش‌بینی‌های کمتر از واقع را نمایش می‌دهد. آنها همچنین استنباط می‌کنند که مجذور میانگین مربعات خطا^۲ نیز اگرچه در عمل بسیار مورد استفاده قرار می‌گیرد ولی آن هم، معیار قابل اطمینانی نیست. مطالعه توصیه می‌کند که زمانی که داده سری‌های زمانی زیادی در دست باشد، معیار میانه درصد خطای مطلق^۳، معیار خوبی برای مقایسه و انتخاب بهترین روش پیش‌بینی است اما، محاسبه MAPE نیز، برای داده‌های تقاضای متلاطم نیز به دلیل اینکه در برخی دوره‌ها تقاضای صفر را داریم، دشوار است [۷].

1. Mean Absolute Percentage Error-MAPE
2. Root Mean Square Error-RMSE
3. Median Absolute Percentage Error-MdAPE

البته معیارهای خطای دیگری نیز، همچون درصد برتری^۱، در ادبیات برای مقایسه روش‌های مختلف پیش‌بینی تقاضای متلاطم، پیشنهاد شده است لذا، در اینجا فقط به معیار میانگین قدرمطلق درصد خطا، برای مقایسه روش‌های مختلف پیش‌بینی به کار برده شده، اکتفا گردید. جدول زیر مقایسه چهار روش به کار گرفته شده برای پیش‌بینی را بر اساس معیار خطای MAPE نشان می‌دهد:

جدول ۳. مقایسه روش‌های مختلف پیش‌بینی بر اساس معیار خطا

میانگین قدرمطلق درصد خطا (%)	نایو	هموارسازی نمایی	سینتوس	پرسپترون چند لایه	شبکه بازگشتی
مجموعه داده ۱	۴۳/۱۷	۳۴/۱۵	۲۶/۱۲	۲۱/۶۱	۲۱/۲۸
مجموعه داده ۲	۴۱/۱۱	۳۳/۴۷	۲۵/۹۶	۲۱/۵۳	۲۱/۲۱
مجموعه داده ۳	۴۴/۸۹	۳۴/۹۹	۲۹/۵۶	۲۵/۶۵	۲۶/۵۷

همان‌گونه که از جدول بالا پیداست، روش سینتوس به وضوح، در مقایسه با روش‌های کلاسیک دیگر همچون روش نایو و هموارسازی نمایی، عملکرد بسیار بهتری نشان می‌دهد. شبکه‌های عصبی به طور کلی عملکرد بهتری نسبت به سه روش کلاسیک پیش‌بینی، در هر سه مجموعه داده داشته است. در مقایسه عملکرد شبکه بازگشتی و شبکه عصبی پرسپترون در مجموعه داده اول و دوم شبکه بازگشتی و در مجموعه داده سوم شبکه عصبی پرسپترون عملکرد نسبتاً بهتری داشته است. البته این اختلاف عملکردی بین دو نوع شبکه، بسیار ناچیز است در حالی که شبکه عصبی بازگشتی نیازمند حجم محاسبات بالاتری می‌باشد. تمامی پنج روش پیش‌بین به کار رفته، بهترین عملکرد خود را بر روی مجموعه داده شماره ۲ نشان دادند.

سنجه اثر شلاقی

همانگونه که گفته شد اثر شلاقی تشدید نوسانات تقاضا در حرکت به سمت گره‌های بالادستی در زنجیره تأمین را گویند. روش سنتی سنجش اثر شلاقی، استفاده از نسبت واریانس (یا انحراف معیار یا ضریب تغییرات) سفارشات ایجادشده (خروجی) به واریانس (یا انحراف معیار یا ضریب تغییرات) تقاضا (ورودی) است. سنجه نسبت واریانس^۲ به معنای واریانس سفارشات در بلندمدت به واریانس تقاضا در بلندمدت، وقتی که n یعنی زمان به بی‌نهایت میل می‌کند، یکی از سنجه‌های اصلی اثر شلاقی می‌باشد [۳]. این نسبت در رابطه شماره ۹، به تصویر در آمده است:

$$VR = \frac{\sigma_{Output}^2}{\sigma_{Input}^2} = \frac{\sigma_D^2}{\sigma_D^2} \quad (\text{رابطه ۹})$$

1. Percentage Better
2. Variance Ratio- VR

σ_{OR}^2 واریانس سفارشات و σ_D^2 واریانس تقاضا را نشان می‌دهد. این سنجه می‌تواند بر یک قاعده تصمیم یا بر یک موجودی چندسطحی در زنجیره اعمال شود؛ حال اگر $VR > 1$ آنگاه اثر شلاقی اتفاق می‌افتد و اگر $VR < 1$ آنگاه هموارسازی اتفاق می‌افتد و اگر $VR = 1$ ممکن است و نه لزوماً سیاست انتقال را خواهیم داشت [۵]. اگر سیاست انتقال سفارشات را داشته باشیم، یعنی مقدار سفارش دقیقاً با مقدار تقاضای برآورد شده برابر باشد آنگاه $\bar{D} = OR$. جدول شماره ۴ این سنجه را در خصوص پنج روش پیش‌بینی به کار رفته، مقایسه می‌کند.

جدول ۴. مقایسه عملکرد روش‌های مختلف پیش‌بینی در سنجه اثر شلاقی

روش پیش‌بینی	نایو	هموارسازی نمایی	سینتوس	پرسپترون چندلایه	شبکه بازگشتی
نسبت واریانس	۲/۳۳	۱/۳۱۴۷	۰/۵۶۹۸	۰/۳۴۷۵	۰/۳۴۷۴

همان‌گونه که در جدول شماره ۴، به نمایش در آمده است، بکارگیری شبکه عصبی موجب شده تا سیگنال تقاضای متلاطم هموارتر گردیده و بنابراین تغییرات در داده‌های سری زمانی کاهش یابد. در نتیجه σ_{OR}^2 برابر با ۷۱۰۷۰۲۳ و σ_D^2 برابر با ۲۰۴۴۶۶۷۵ شده است. بنابراین نسبت واریانس یا اثر شلاقی برابر با ۰/۳۴۷۵ شد. با به کارگیری روش‌های هموارسازی نمایی و نایو در پیش‌بینی تقاضای متلاطم وقوع پدیده اثر شلاقی تضمین شده است.

نتیجه‌گیری

در این مقاله، به منظور پیش‌بینی تقاضا به ادبیات علمی مسأله ارجاع شد و سیستم‌های پیش‌بین به کار گرفته شده، مورد مطالعه و بررسی قرار گرفت. در این میان، یکی از معمول‌ترین روش‌های پیش‌بینی، روش هموارسازی نمایی است که به دلایل مختلف از محبوبیت بسیار زیادی در صنعت برخوردار است. اما این رویکرد پیش‌بینی خود یکی از علل پدیدآورنده مشکلات و ظهور پدیده‌ای به نام اثر شلاقی می‌باشد. این پدیده ناکارایی‌های عمده‌ای را در سیستم برنامه‌ریزی تولید، موجب می‌شود. لذا در این خصوص باید سیستم پیش‌بین بهتری که خطای عملکردی کمتری داشته و پیش‌بینی دقیق‌تری ارائه داده، نا اریب بوده و جایگزین روش هموارسازی نمایی شود. تلاش برای حل این مسأله محقق را به بهره‌گیری مقایسه‌ای از روش‌های پیشرفته‌تر همچون شبکه‌های عصبی رهنمون ساخت. تحلیل مقایسه‌ای روش‌ها، نتیجه زیر را داشت؛ شبکه‌های عصبی در مقایسه با روش‌های کلاسیک همچون هموارسازی نمایی، بهتر توانستند رفتار غیرخطی، نوسانی و حتی آشوبی تقاضای متلاطم را مدل‌سازی و پیش‌بینی نمایند. در نتیجه سیگنال تقاضای متلاطم هموارتر شده و بنابراین تغییرات در داده‌های سری زمانی کاهش یافت. این امر نیز به نوبه خود موجب کاهش اثر شلاقی شد.

منابع

1. Carbonneau R, Laframboise K, Vahidov R, Application of machine learning techniques for supply chain demand forecasting, *European Journal of Operational Research*, 2008, 184, 1140-1154
2. Chen, F., Ryan, J. K., & Simchi-Levi, D. The impact of exponential smoothing forecasts on the bullwhip effect. *Naval Research Logistics*, 2000. 47(4), 269-28
3. Dejonckheere, J., Disney, S.M., Lambrecht, M.R., Towill, D.R.,. Measuring and avoiding the bullwhip effect: A control theoretic approach. *European Journal of Operational Research* ,2003, 147, 567-590.
4. Dejonckheere, J., Disney, S.M., Lambrecht, M.R., Towill, D.R Transfer function analysis of forecasting induced bullwhip in supply chains. *International Journal of Production Economics* 2002, 78, 133-144
5. Disney, S.M, Towill, D.R, Velde W. Van de, Variance amplification and the golden ratio in production and inventory control. *International Journal of Production Economics* ,2004, 90, 295-309
6. Efindigil T, Onut S, Kahraman C, A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis, *Expert Systems with Applications* 2009, 36, 6697-6707
7. Gutierrez R S, Solis A O, Mukhopadhyay S. Lumpy demand forecasting using neural networks. *International Journal of Production Economics* , 2008, 111, 409-420.
8. Hillier, F S., Liberman, G. J, Introduction to operations Research, 7th edition, *McGraw Hill*, 2001.
9. Hong L, Ping W, Bullwhip effect analysis in supply chain for demand forecasting technology, *System engineering - Theory & Practice*, Volume 27, issue 7, July 2007
10. Khashei M, Bijari M, Raissi Ardali G A, Improvement of Auto-Regressive Integrated Moving Average models using Fuzzy logic and Artificial Neural Networks (ANNs), *Neurocomputing* 2009, 72, 956-967
11. Lee, H.L., Padmanabhan, V., Whang, S., a" The Bullwhip effect in supply chains". *Sloan Management Review* ,1997; 38 (3), 93-102.
12. Sarimveis. H et al. Dynamic modeling and control of supply chain systems: A review. *Computers & operations research*. 2008;35: 3530-61
13. Teunter R, Sani B, On the bias of Crostons Forecasting method, *European Journal of Operational Research* ,2009, 194, 177-183.