

## تحلیل حساسیت مدل میزان اقتصادی سفارش در حالت اثرات تعاملی دوفاکتوری با استفاده از شبکه عصبی مصنوعی

علی سرورخواه<sup>۱</sup>، زهرا جوربنیان<sup>۲</sup>

۱- گروه مدیریت، موسسه آموزش عالی آیندگان، تنکابن، ایران

۲- مدیریت، موسسه آموزش عالی آیندگان، تنکابن، ایران

### چکیده

در این مقاله چگونگی استفاده از متامدل شبکه عصبی مصنوعی برای تحلیل حساسیت مدل مقدار اقتصادی سفارش در حالت اثرات تعاملی دو فاکتوری ارائه و نشان داده شده است که استفاده از این متامدل برای تحلیل حساسیت مقدار اقتصادی سفارش در مقایسه با روش فعلی (یک فاکتور در هر بار) مناسب تر است. برای این منظور، از یک شبکه عصبی پیشرو پس انتشار با یک لایه مخفی، توابع محرک سیگموئید در لایه مخفی، فاکتورهای مؤثر بر EOQ به عنوان ورودی و مقدار اقتصادی سفارش به عنوان خروجی مدل استفاده شده است. معیارهای حساسیت بر اساس وزنهای اتصال تعریف شده و رویه متدولوژی در یک مثال عددی نشان داده شده است. با ظهور نظامهای هوشمند، پردازش دادهها و مدل‌های مرتبط با آنها از قبیل شبکه‌های عصبی مصنوعی، الگوریتم ژنتیک، منطق فازی و نظایر آنها که با الهام از گوشه‌ای از طبیعت طراحی و مدل‌سازی شده‌اند، پیشرفت مهمی در تجزیه و تحلیل داده‌ها صورت گرفته است. یکی از اصلی‌ترین ویژگی‌های شبکه عصبی مصنوعی، که از ساختار و عملکرد شبکه‌های عصبی طبیعی الهام گرفته است، پردازش موازی اطلاعات ورودی توسط واحدهای پردازش نرونی است.

تاریخ دریافت: ۱۴۰۲/۰۹/۱۲


تاریخ بازنگری: ۱۴۰۲/۱۰/۲۸

تاریخ پذیرش: ۱۴۰۲/۱۱/۲۱

### کلید واژه‌ها:

مقدار اقتصادی سفارش، تحلیل حساسیت، شبکه عصبی مصنوعی، کاهش هزینه تولید.

لطفاً به این مقاله استناد کنید (APA): سرورخواه، علی، جوربنیان، زهرا. (۱۴۰۲). تحلیل حساسیت مدل میزان اقتصادی سفارش در حالت اثرات تعاملی دوفاکتوری با استفاده از شبکه عصبی مصنوعی. دو فصلنامه رویکردهای نوین در مدیریت و بازاریابی، ۲(۲)، ۱۴۹-۱۵۸.

 <https://doi.org/10.22034/jnamm.2024.428461.1040>



Creative Commons: CC BY 4.0



ناشر: انجمن مدیریت کسب و کار ایران

ایمیل: [ali.sorourkhah@gmail.com](mailto:ali.sorourkhah@gmail.com)

نویسنده مسئول: علی سرورخواه

## مقدمه

استفاده از مدل ریاضی در کمینه کردن هزینه‌های موجودی در سال ۱۹۱۵، وقتی که مدل EOQ<sup>۱</sup> برای اولین بار توسط هریس<sup>۲</sup> معرفی شد (Harris, F, 1915) شروع گردید. این مدل که در تصمیمات موجودی به‌طور وسیعی کار برد دارد، به شرح فرآیند نگهداری موجودی و تعیین مقدار بهینه سفارش می‌پردازد. EOQ طبق فرمول (۱) محاسبه می‌شود:

$$C^* = \sqrt{\frac{2DC_0}{C_h}} \quad (1)$$

در (۱)،  $D$  تقاضای سالیانه،  $C_0$  هزینه سفارش، و  $C_h$  هزینه نگهداری موجودی است. مدار بهینه سفارش در سطحی که هزینه سفارش و هزینه نگهداری تقریباً برابر هستند، هزینه کل موجودی را حداقل می‌کند. هزینه کل از طریق فرمول (۲) محاسبه می‌شود:

$$TC = \frac{1}{2}QC_h + \frac{D}{Q}C_0 \quad (2)$$

پیش از این اظهار شده بود که مدل EOQ نیاز به آنالیز حساسیت ندارد (سید حسینی & صفاکش، ۱۳۸۴). در این مقاله نشان داده می‌شود که تحلیل حساسیت EOQ با روش مناسب می‌تواند به‌عنوان سدی در مقابل هزینه‌های مضاعف موجودی سازمان باشد.

## ۱- تحلیل حساسیت<sup>۳</sup> و شبکه عصبی<sup>۴</sup>

### ۱-۲- تحلیل حساسیت

بنا به تعریف، تحلیل حساسیت عبارت است از مطالعه چگونگی تأثیر تغییرات در ورودی‌های یک مدل به‌صورت کمی یا کیفی بر تغییرات خروجی‌های مدل. مهم‌ترین هدف تحلیل حساسیت را می‌توان تعیین اهمیت هر ورودی در مدل دانست. در تحلیل حساسیت، میزان و نوع تأثیرگذاری ورودی‌ها از طریق بررسی چگونگی و میزان تغییرات خروجی در اثر تغییرات در ورودی‌ها مشخص می‌شود (saltli, chang, & scott, 2000) این کار در مدل‌های ورودی-خروجی برای شناسایی روابط میان ورودی‌ها و خروجی‌ها انجام می‌گیرد. روش‌های مختلفی برای تحلیل حساسیت وجود دارد که روش یک فاکتور در هر بار، ساده‌ترین و متداول‌ترین تحلیل حساسیت EOQ می‌باشد. در این روش برای هر یک از فاکتورها یک دامنه تغییرات در نظر گرفته و با هر بار تغییر یک فاکتور در دامنه مربوطه و ثابت نگه داشتن سایر فاکتورها، مقادیر EOQ در ازای هر تغییر محاسبه می‌شود. این فرآیند برای همه فاکتورها تکرار می‌گردد. این روش نوع و میزان تأثیر فاکتورها را در مدل‌های خطی به‌خوبی نشان می‌دهد. با این وجود، در مدل‌های غیرخطی مانند EOQ، این شیوه از کارایی چندانی برخوردار نیست. علاوه بر این، در این روش تغییر فاکتورها به‌طور جداگانه مورد بررسی قرار می‌گیرد که نسبت به تغییرات هم‌زمان فاکتورها اطلاعات کمتری ارائه می‌دهد. بنابراین برای تحلیل حساسیت EOQ لزوم استفاده

<sup>1</sup> Economic Order Quantity

<sup>2</sup> Harris

<sup>3</sup> Sensitivity Analyses

<sup>4</sup> Neural Network

از یک متامدل که روابط ورودی‌ها و خروجی‌ها را به شکلی ساده، دقیق و با کمترین میزان خطا بیان کند ضروری به نظر می‌رسد (Sartori, & Smith 1977).

متامدل<sup>۱</sup> به مدل ریاضی یا آماری گفته می‌شود که با استفاده از اطلاعات اخذشده از یک مدل پیچیده دیگر ایجاد می‌شود. متامدل‌ها از مدل‌های اولیه ساده‌تر بوده و امکان انجام آنالیزهایی که نمی‌توان به‌طور مطلوب بر روی مدل اولیه انجام داد را فراهم می‌کنند. مفهوم متامدل نخستین بار در سال ۱۹۷۳ مطرح شد (Miesel, & Collins, 1973). در متامدل‌بندی هر چه اختلاف  $y$  (بردار خروجی‌های مدل) با  $y'$  (بردار خروجی‌های متامدل) کمتر باشد، متامدل مذکور دقیق‌تر بوده و می‌توان به نتایج حاصل از آن اطمینان بیشتری داشت (Kleijnen, & Sergeant, 2000). از متداول‌ترین متامدل‌ها می‌توان به مدل‌های رگرسیونی و شبکه‌های عصبی مصنوعی اشاره کرد. استفاده از شبکه‌های عصبی مصنوعی به‌عنوان متامدل برای نخستین بار در سال ۱۹۸۹ صورت گرفت (Pierval, & Hunstiger, 1989). پژوهش‌های زیادی در مورد شبکه‌های عصبی مصنوعی انجام پذیرفته است. لیاو اظهار می‌دارد حجم انبوه پژوهش‌های علمی که هم اکنون در سراسر دنیا با بهره‌گیری از شبکه‌های عصبی مصنوعی در حال انجام است، نشان‌دهنده توانمندی بالای آن‌ها در درک روابط ذاتی بین داده‌هاست (Liao, 2005). ضعف پژوهش‌های پیشین می‌تواند مربوط به تکنیک‌های رگرسیون باشد که نیاز به اطلاعات گذشته دارند. در حالی که شبکه‌های عصبی این ضعف را ندارند (Wary, Palmer, & Beiou, 1994). بحث شده است که شبکه‌های عصبی از لحاظ سادگی کاربرد و قدرت تقریب برتری نسبت به مدل‌های رگرسیونی مرتبه‌های اول و دوم دارند (Klimer, smith, & shuman, ۱۹۹۴) و همچنین، متامدل‌بندی بر اساس شبکه‌های عصبی مصنوعی (برخلاف مدل‌های رگرسیونی) نیاز به جمع‌آوری داده‌های منظم از طریق طرح‌های آزمایشی و همچنین، انجام فرضیات یا برقرار بودن شرایط خاص ندارد (Padget, & Roppel, 1996). با در نظر گرفتن نیاز به آنالیز حساسیت مدل EOQ و توانایی بالای شبکه‌های عصبی مصنوعی در مقایسه با متامدل‌های دیگر، در این مقاله متدولوژی تحلیل حساسیت EOQ با استفاده از شبکه‌های عصبی مصنوعی ارائه می‌شود.

## ۲-۲- شبکه‌های عصبی مصنوعی

در خلال چند دهه اخیر، با ظهور نظام‌های هوشمند<sup>۲</sup>، پردازش داده‌ها و مدل‌های مرتبط با آن‌ها از قبیل شبکه‌های عصبی مصنوعی، الگوریتم ژنتیک<sup>۳</sup>، منطق فازی<sup>۴</sup> و نظایر آن‌ها که با الهام از گوشه‌ای از طبیعت طراحی و مدل‌سازی شده‌اند، پیشرفت مهمی در تجزیه و تحلیل داده‌ها صورت گرفته است.

یکی از اصلی‌ترین ویژگی‌های شبکه عصبی مصنوعی، که از ساختار و عملکرد شبکه‌های عصبی طبیعی الهام گرفته است، پردازش موازی اطلاعات ورودی توسط واحدهای پردازش نرونی است. نرون<sup>۵</sup> کوچک‌ترین واحد پردازش اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد. برای هر نرون یک یا چند ورودی، وزن یا

<sup>1</sup> Meta-Model


<sup>2</sup> Intelligent System

<sup>3</sup> Genetic Algorithm

<sup>4</sup> Fuzzy Logic

<sup>5</sup> Neuron

وزن‌هایی که نرون را به ورودی‌ها متصل می‌کنند، یک عبارت اریب، یک تابع محرک و یک خروجی می‌توان در نظر گرفت. طرح شماتیک یک نرون با یک ورودی در شکل ۱ نشان داده شده است.



شکل ۱. ساختار یک نرون با یک ورودی


در شکل ۱،  $x$  ورودی نرون،  $w$  وزن اتصال ورودی نرون،  $b$  عبارت اریب،  $p$  مقداری که به تابع محرک  $f$  وارد می‌شود و  $y$  نیز خروجی نرون بوده که روابط میان آن‌ها به صورت (۳) است:

$$y = f(p) = f(xw + b) \quad (3)$$

در حالتی که  $x$  و  $w_i$  ( $i=1,2,\dots,5$ )، به ترتیب، ورودی‌ها و وزن‌های اتصال به نرون با تابع محرک  $f$  و اریب  $b$  باشند، خروجی نرون به صورت (۴) خواهد بود:

$$y = f(p) = f(\sum_{i=1}^k x_i w_i + b) \quad (4)$$

پارامترهای  $w$  و  $b$  قابل تنظیم بوده و در ایجاد شبکه‌های عصبی به گونه‌ای تغییر می‌کنند که رابطه ورودی-خروجی نرون با اهداف مشخصی مطابقت نمایند. تعداد ورودی‌ها و مقادیر آن‌ها در مسائل مشخص است. نوع تابع محرک بر اساس نیاز خاص مساله‌ای که به وسیله شبکه عصبی حل می‌شود، انتخاب می‌گردد. شبکه‌های عصبی مصنوعی با توجه به نوع اتصالات به دو دسته کلی تقسیم می‌شوند: شبکه‌های عصبی پیشرو که در آن تمام اتصالات رو به جلو (از لایه‌ی ورودی به سمت لایه خروجی) است. در شکل ۲ ساختار یک شبکه عصبی پیشرو با ساختار (۱-۲-۳) نشان داده شده است که دارای ۳ ورودی، ۲ نرون در تنها لایه‌ی مخفی و یک نرون در لایه خروجی است.



شکل ۲. شبکه عصبی با ساختار (۱-۲-۳)

در شبکه عصبی شکل ۲ خروجی شبکه به صورت (۵) است:


$$y = f(w_i[f(w_i x_i + w_{2i} x_2 + w_{3i} x_3 + b_i)] + w_2[f_2(w_{i2} x_i + w_{22} x_2 + w_{32} x_3 + b_2)] + b) \quad (5)$$

در شبکه‌های عصبی پس‌خورده، حداقل یک سیگنال برگشتی از یک نرون به همان نرون یا سایر نرون‌های همان لایه یا لایه‌های قبلی وجود دارد. در شبکه‌های عصبی مصنوعی، مقصود از قانون یادگیری روندی است که طی آن پارامترهای

شبکه (وزن‌ها و اریب‌ها) تنظیم می‌شوند. از مهم‌ترین قوانین یادگیری، قانون یادگیری پس‌انتشار است که توسط روملهارت و همکارانش ارائه شده است (Rumelhart, Hilton, & Williams, 1986). از شبکه‌های عصبی پیشرو آموزش داده‌شده با الگوریتم یادگیری پس‌انتشار برای ترقیب توابع استفاده می‌شود. سینکو با ارائه قضیه ترقیب عمومی نشان داده است که برای ترقیب توابع با استفاده از شبکه‌های عصبی پیشرو، یک لایه مخفی کافیست (Cybenko, 1989).

## ۲- متدولوژی

برای تحلیل حساسیت مدل EOQ با متامدل شبکه عصبی مصنوعی با توجه به مطالب ارائه‌شده در بخش پیش، از شبکه عصبی پیشرو با یک لایه مخفی استفاده می‌شود. از آنجا که مدل EOQ برحسب فاکتورهای اساسی مؤثر بر آن (تقاضای سالیانه، هزینه سفارش، و هزینه نگهداری) مشخص است، مشکلی در فراهم نمودن داده‌های یادگیری وجود ندارد. برای انتخاب نوع تابع محرک در لایه مخفی با توجه به این که مدل EOQ یک مدل غیرخطی است، نیاز به تابع محرکی است که خروجی را به صورت یک تابع غیرخطی از تابع ورودی‌ها نشان دهد؛ بنابراین، از تابع محرک سیگموئید در لایه مخفی استفاده می‌شود. شکل ۱ را در نظر بگیرید. در ساختار نرون، عبارت اریبی است که به تابع محرک وارد می‌شود. در این مقاله، برای این که اثرات ورودی‌ها در تعیین مقدار خروجی به تنهایی و بدون تأثیر عوامل دیگر مورد بررسی قرارگیرد، عبارت اریب در توابع محرک صفر در نظر گرفته می‌شود. برای تعیین تعداد نرون‌ها در شبکه‌های عصبی هیچ رویه کامل و مشخصی وجود ندارد و باید براساس سعی و خطا با چندین شبکه معتبر با تعداد نرون‌های مختلف ایجاد و با تست آن‌ها، شبکه با کم‌ترین خطا به ازای داده‌های تست را به عنوان بهترین شبکه انتخاب نمود. در لایه‌ی خروجی، از آنجا که نیازی به برآورد غیرخطی مقدار لایه‌ی خروجی نیست، تابع محرک خطی استفاده می‌شود. در این مدل، قانون یادگیری پس‌انتشار خطا استفاده شده است. در شکل ۳ شبکه عصبی پیشرو پس‌انتشار با ساختار (۳-۲-۱) نشان داده شده است که دارای ۳ ورودی، ۲ نرون در تنها لایه مخفی و ۱ نرون در لایه خروجی است.



شکل ۳. شبکه عصبی پیشرو با خروجی EOQ

شبکه عصبی شکل ۳ مدل EOQ در (۶) را به صورت (۷) تقریب می‌زند:

$$EOQ = \left[ \frac{2x_1x_2}{x_3} \right]^{1/2} \quad (6)$$

$$EOQ = w_1 \left( \frac{1}{1} + e^{-[w_{11}x_1 + w_{21}x_2 + w_{31}x_3 + b_1]} \right) + w_2 \left( \frac{1}{1} + e^{-[w_{12}x_1 + w_{22}x_2 + w_{32}x_3 + b_2]} \right) \quad (7)$$

در  $(V)$ ،  $w_{ij}$  ( $i=1,2,3$ ) ( $j=1,2$ ) وزن اتصال ورودی  $x_i$  به نرون مخفی  $j$  است. ممکن است به نظر رسد متامدل شبکه عصبی در  $(V)$  پیچیده‌تر از مدل اولیه EOQ در  $(6)$  باشد؛ اما باید توجه داشت که متامدل مذکور برای تحلیل انجام حساسیت به وجود آمده و در حین ایجاد آن، تحلیل حساسیت هم‌زمان براساس همه فاکتورها انجام شده است. حال باید معیارهای حساسیت خروجی شبکه عصبی نسبت به ورودی‌های شبکه عصبی را تعریف کنیم. معیار حساسیت نشان‌دهنده نوع و میزان تأثیر فاکتورها (ورودی‌های شبکه عصبی) بر EOQ (خروجی شبکه عصبی) است. روش‌های زیادی برای تعیین تأثیر ورودی‌های شبکه عصبی مصنوعی در ایجاد خروجی آن ارائه شده‌اند. روش وزن‌های اتصال (که در این مقاله از آن استفاده می‌شود) ساده‌ترین روش است که نوع و میزان تأثیر ورودی‌ها را ارائه می‌کند. این روش توسط الدن و همکاران در سال ۲۰۰۴ ارائه شده است (Olden, & Joy, & Death, 2004). لازم به ذکر است برای آنالیز دقیق‌تر مدل EOQ، هزینه سفارش به دو دسته  $x_1$ : هزینه حمل و نقل (معادل ۷۵٪ کل هزینه سفارش) و  $x_2$ : شامل هزینه‌های تکمیل فرم، انتخاب عرضه‌کنندگان، پردازش اسناد و بازرسی کالا (معادل ۲۵٪ کل هزینه سفارش) تقسیم شده‌اند.  $x_3$ : تقاضای سالیانه و هزینه‌های نگهداری نیز در دو دسته  $x_4$ : هزینه‌های اجاره، برق و گرمایش (معادل ۶۰٪ هزینه‌های نگهداری و  $x_5$ : شامل هزینه‌های بیمه، مالیات، ضایعات و ... (معادل ۴۰٪ هزینه‌های نگهداری) نشان داده شده‌اند. میزان تغییرات برای فاکتورها برای تحلیل حساسیت ۲۰٪ مقدار پایه در نظر گرفته شده است.

### ۳- مثال عددی

در حالت اثرات تعاملی دوفاکتوری، شبکه ۱۵ ورودی خواهد داشت که ۵ ورودی آن مربوط به اثرات اصلی  $(x_1, x_2, \dots, x_5)$  و ۱۰ ورودی دیگر به صورت  $x_{ij}$  ( $i=1, 2, \dots, 5$ ) و  $(j=i+1, \dots, 5)$  می‌باشند. اطلاعات مربوط به فاکتورهای مؤثر بر EOQ در **جدول ۱** آمده است. تقاضای سالانه برابر ۶۲۴۰ است:

جدول ۱. اطلاعات مربوط به مقادیر فاکتورها و تغییرات آنها

پارامترهای مؤثر بر EOQ	ورودی	مقادیر پایه	درصد تغییرات	حد پایین تغییرات	حد بالای تغییرات
هزینه سفارش $C_0$	$x_1$	525000	20٪	420000	630000
هزینه سفارش $C_0$	$x_2$	175000	20٪	140000	210000
تقاضای سالیانه $D$	$x_3$	6240	20٪	4992	7488
هزینه نگه‌داری $C_h$	$x_4$	470	20٪	376	564
هزینه نگه‌داری $C_h$	$x_5$	300	20٪	240	360

مقدار EOQ در حالت پایه، بنا بر فرمول (۱)، برابر ۳۳۶۸ و هزینه کل موجودی مطابق فرمول (۲) برابر ۲۵۹۳۵۹۲ تومان است.

برای ایجاد شبکه عصبی مورد نظر با ۱۵ ورودی و ۱ خروجی، ۱۴۵۰۰ الگوی یادگیری در نظر گرفته شده که از ۱۲۰۰۰ الگو برای آموزش و ۲۵۰۰ الگو برای اعتبارسنجی شبکه عصبی استفاده شده است. برای تعیین تعداد نرون‌ها از روش سعی و خطا مطابق **جدول ۲**، تعداد ۴۸ نرون انتخاب می‌شود:

جدول ۲. شبکه‌های عصبی ایجادشده با تغییرات نرون

خطا \ تعداد نرون	15	32	48
MAE	6.58	3.8	3.18
MSE	80	23.6	17.2

در **جدول ۳** معیارهای حساسیت حاصل از ۴۸ نرون در حالت اصرات تعاملی نشان داده شده است.

جدول ۳. معیارهای حساسیت حاصل از ۴۸ نرون

SC <sub>1</sub>	-2.58E-05
SC <sub>2</sub>	-9.11E-04
SC <sub>3</sub>	1.14E-02
SC <sub>4</sub>	-2.04E-01
SC <sub>5</sub>	-3.74E-01
SC <sub>1,2</sub>	1.89E-07
SC <sub>1,3</sub>	4.18E-06
SC <sub>1,4</sub>	2.20E-05
SC <sub>1,5</sub>	-1.91E-06
SC <sub>2,3</sub>	1.01E-05
SC <sub>2,4</sub>	1.07E-04
SC <sub>2,5</sub>	-3.04E-06
SC <sub>3,4</sub>	2.59E-04
SC <sub>3,5</sub>	-9.67E-06
SC <sub>4,5</sub>	1.30E-03

با بررسی **جدول ۳**، مشاهده می‌شود که به ترتیب،  $x_3$  و  $x_4$ ،  $x_5$  بیشترین تأثیر را بر EOQ می‌گذارند. این مطلب بیانگر آن است که در حالت اثرات تعاملی، تقاضای سالیانه و هزینه نگهداری بیشترین تأثیر را بر EOQ دارند؛ در حالی که در حالت اثرات اصلی،  $x_3$  و  $x_1$  بیشترین تأثیر را در مدل دارند. این موضوع بیانگر این مطلب است که در صورت تغییرات هم‌زمان در ورودی‌ها، فاکتورهای مؤثر متفاوت خواهند بود و این نکته‌ای است که تحلیل حساسیت یک فاکتور در هر بار قادر به نشان دادن آن نیست.

**جدول ۴** مقایسه هزینه کل در حالت دوفاکتوری و تک فاکتوری را نشان می‌دهد:



جدول ۴. مقایسه هزینه‌های کل

$TC_{max}$	$TC_{min}$	هزینه کل مدل مورد استفاده
3,215,084	2,015,809	دوفاکتور
2,870,016	2,593,592	یک فاکتور

با توجه به اطلاعات جدول ۴، ملاحظه می‌شود که تحلیل حساسیت یک فاکتور در هر بار تلورانس حداقل و حداکثر هزینه را در صورت تغییر ۲۰٪ در ورودی، ۲۷۶۴۲۴ تومان و شبکه عصبی مصنوعی این تلورانس را ۱۱۹۹۲۷۵ تومان، یعنی حدود ۴/۵ برابر نشان می‌دهد.

#### ۴- نتیجه‌گیری و پیشنهادات

در این مقاله، ایده استفاده از شبکه‌های عصبی مصنوعی به عنوان یک متامدل در آنالیز حساسیت EOQ مطرح شد. با استفاده از شبکه عصبی پیشرو پس‌انتشار با یک لایه مخفی، توابع محرک سیگموئید در لایه مخفی و تابع محرک خطی در لایه خروجی، نشان داده شد که مدل EOQ نسبت به فاکتورهای  $x_4$  و  $x_5$  دارای حساسیت بیشتری بوده و همچنین، بحث شد که متامدل شبکه عصبی مصنوعی در پیش‌بینی میزان تغییرات مدل، در مقایسه با روش یک فاکتور در هر بار، از کارایی بیشتری برخوردار است.

پیشنهاد می‌شود، از آن‌جا که ممکن است نتیجه‌گیری وابسته به مثال عددی باشد، در پژوهش‌های بعدی با مثال‌های دیگر، به خصوص در زمانی با اندازه بزرگ، این مدل بررسی شود. در این مطالعه، اندازه سازمان متوسط بوده است و ممکن است در زمانی با اندازه بزرگ‌تر و هزینه‌های زیادتر، این تغییرات محسوس‌تر باشد. با توجه به این که مقادیر فاکتورهای مؤثر بر EOQ (هزینه سفارش و نگهداری) به صورت تخمین و برآورد هستند و در مورد آن‌ها عدم اطمینان وجود دارد، از این رو می‌توان مقادیر را به صورت فازی مطرح نمود. بنابراین، چگونگی استفاده از مجموعه‌های فازی در تحلیل حساسیت EOQ می‌تواند موضوعی برای پژوهش‌های آتی باشد. و در آخر، استفاده از شبکه عصبی مصنوعی برای تحلیل حساسیت سایر مدل‌ها (به خصوص مدل‌های غیر خطی) می‌تواند ایده مناسبی برای پژوهش‌های آتی باشد.

#### منابع

سرور خواه، علی، متدولوژی تحلیل حساسیت EOQ با استفاده از شبکه‌های عصبی مصنوعی، پایان نامه کارشناسی ارشد،

۱۳۸۹، ۷۸-۸۱

سید حسینی، محمد، صفاکیش، سعید، مبانی جامع و پیشرفته مدیریت تولید و عملیات، جلد دوم، انتشارات سازمان

مدیریت صنعتی، تهران، ۱۳۸۴، ۵۳-۵۵

Cybenco, G. (1989), "Approximation by superpositions of a sigmoidal function", *Mathematics of control, Signals and Systems*, 2, 303-314.

Harris, F. (1915), "Operations and Cost factory management series, A.W. Shaw Co, Chicago, 8-52.



- Kilmer, R. A., and Smith, A. E., and Shuman, L. J. (1994), "Neural network as a metamodeling technique for discrete even stochastic simulation", *Intelligent Engineering Systems Through Artificial Neural Networks*, Vol .A, 631-636.
- Kleijnen, J. P., and Sargent, R.G. (2000), "A methodology for fitting and validating metamodels in simulation", *European journal of operational research*, 120, 14-29.
- Liao, S. H. (2005), "Expert system methodologies and applications:A decade review from 1995 to 2004", *Expert systems with applications*, 28(1), 93-103.
- Miesel, W. S., and Collins, D. C. (1973), "Repro-modelling approach to efficient model utilization and interpretation", *IEEE transaction of systems, Man and Cybernetics, SMC*, 3, 349-358.
- Olden, J. D., and Joy, K., and Death, R.G. (2004), "An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data", *Ecological Modeling*, 78, 389-397.
- Padget, M., and Roppel, T. A. (1996), "Neural network and simulation: modeling for applications", *Mathematical and Computer modeling*, 23, 91-99.
- Pierval, H., and Hunstiger, R. C., (1989), "An investigation on neural networks capabilities as simulation metamodels", *Proceeding of the 1989 winter simulation conference*, 702-710.
- Rumelhart, D. E., and Hilton, G. E., and Williams, R. J., (1986), "Learning representations by backpropagation error", *Nature*, 323, PP. 533-536.
- Sartio, D. E., and Smith, A. E. (1997), "A metamodel approach to sensitivity analysis of capital project valuation", *The Engineering Economic*, 43(1), 1-24.
- Wray, B., and Palmer, A., and Bejou, D. (1994), "Using neural network analysis to evaluate buyer-seller relationships", *European Journal of Marketing*, 28(1) 32-48.

Original Article (Quantified)

# Sensitivity analysis of the order economic value model in the case of two-factor interactive effects using artificial neural network

Ali Sarwarkhah<sup>1</sup>, Zahra Jorbanian<sup>2</sup>

1- Department of Management, Future Higher Education Institute, Tonkabon, Iran

2- Management, Ayendag Institute of Higher Education, Tonkabon, Iran

**Receive:**

03 December 2023

**Revise:**

18 January 2024

**Accept:**

11 January 2024

**Keywords:**

economic order quantity, sensitivity analysis, artificial neural network, Reduce production cost.

**Abstract**

In this article, how to use the metamodel of the artificial neural network to analyze the sensitivity of the order economic value model in the case of two-factor interactive effects is presented and it is shown that the use of this metamodel to analyze the sensitivity of the economic value of the order compared to the current method (one factor in each load) is more suitable. For this purpose, a back-propagation forward neural network with a hidden layer, sigmoid driving functions in the hidden layer, factors affecting EOQ as input and economic order value as output of the model have been used. The sensitivity criteria are defined based on connection weights and the methodology procedure is shown in a numerical example. With the emergence of intelligent systems, data processing and models related to them, such as artificial neural networks, genetic algorithms, fuzzy logic, and the like, which are designed and modeled with inspiration from a corner of nature, an important progress has been made in data analysis. One of the main features of the artificial neural network, which is inspired by the structure and function of natural neural networks, is the parallel processing of input information by neural processing units.

**Please cite this article as (APA):** Sorourkhah, A., Jorbanian, Z. (2024). Sensitivity analysis of the order economic value model in the case of two-factor interactive effects using artificial neural network. *New Approaches in Management and Marketing*, 2(2), 149-158.



<https://doi.org/10.22034/jnamm.2024.428461.1040>



**Publisher:** Iranian Business Management Association

**Creative Commons:** CC BY 4.0



**Corresponding Author:** Ali Sarwarkhah

**Email:** ali.sorourkhah@gmail.com