

تخمین نقطه‌ی تغییر پله‌ای در میانگین پروفایل‌های خطی چندگانه با استفاده از شبکه‌ی عصبی احتمالی

نگین فروزنده

دانشجوی کارشناسی ارشد مهندسی صنایع، دانشکده فنی و مهندسی، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران
neginforouzandeh@yahoo.com

مونا ایوبی

(نویسنده مسئول) استادیار گروه مهندسی صنایع، دانشکده فنی و مهندسی، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران*

معصومه زینال‌نژاد

استادیار گروه مهندسی صنایع، دانشکده فنی و مهندسی، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران
zeinalnejad@wtiau.ac.ir

چکیده: تخمین نقطه‌ی تغییر با کاهش مدت زمان لازم و هزینه‌ی تشخیص عامل اثرگذار، به مهندسين کیفیت در جستجوی مؤثر برای کشف انحرافات با دلیل و بهبود کیفیت یک محصول یا یک فرآیند کمک می‌کند. در این مقاله، از رویکرد شبکه‌ی عصبی مصنوعی احتمالی برای تخمین نقطه‌ی تغییر پله‌ای در فاز ۲ پایش پروفایل‌های چندگانه استفاده می‌شود. عملکرد شبکه‌ی عصبی احتمالی پیشنهادی برای تخمین نقطه‌ی تغییر با استفاده از شبیه‌سازی مونت‌کارلو مورد سنجش قرار می‌گیرد. نتایج شبیه‌سازی‌ها بیانگر این است که شبکه‌ی پیشنهادی در تخمین نقطه‌ی تغییر، در تغییرات کوچک از رویکرد حداکثر درست‌نمایی بهتر عمل می‌کند. اما در تغییرات متوسط تا بزرگ رویکرد حداکثر درست‌نمایی بهتر عمل می‌کند. به علاوه، مزیت دیگر رویکرد پیشنهادی این است که بر خلاف رویکرد حداکثر درست‌نمایی نیازی به هیچ گونه پیش‌آگاهی از نوع تغییر ندارد و به خوبی قادر به تخمین انواع نقاط تغییر نیز هست.

کلمات کلیدی: کنترل فرآیند آماری، تخمین نقطه‌ی تغییر، پایش پروفایل‌ها، پروفایل خطی چندگانه، شبکه‌ی عصبی مصنوعی احتمالی

۱- مقدمه

خارج از کنترل را نشان می‌دهد، لحظه‌ی واقعی رخ دادن تغییر نیست و فرآیند در نقطه‌ای نامعلوم قبل از کشف حالت خارج از کنترل تغییر کرده است. لحظه‌ی واقعی شروع تغییر در فرآیند را اصطلاحاً نقطه‌ی تغییر می‌نامند. تخمین نقطه‌ی تغییر با محدود کردن بازه‌ی احتمالی زمان تغییر، علاوه بر کاهش وابستگی تشخیص نقطه‌ی تغییر به تجربه، مدت زمان و هزینه‌ی تشخیص عامل اثرگذار را نیز کاهش می‌دهد.

از آنجایی که بحث تخمین نقطه‌ی تغییر به منظور کاهش هزینه‌های کیفیت از اهمیت بالایی برخوردار است، روشهای متعددی برای تخمین نقطه‌ی تغییر در ادبیات موضوع ارائه شده است. از جمله‌ی این روش‌ها می‌توان روش تخمین‌زنده‌های درونی نمودار کنترل جمع تجمعی (CUSUM) و میانگین متحرک موزون

کنترل فرآیند آماری یک تکنیک آماری است که جهت کاهش پراکندگی و در نتیجه بهبود کیفیت مورد استفاده قرار می‌گیرد. ابزارهای هفت‌گانه‌ی کنترل فرآیند آماری عبارتند از: هیستوگرام، برگه‌ی کنترل، نمودار پارتو، نمودار علت و معلول، نمودار پراکندگی، نمودار تمرکز نقص‌ها و نمودار کنترل.

نمودارهای کنترل، یکی از روش‌های کنترل فرآیند در حین تولید هستند که در پی بردن سریع به وجود انحرافات با دلیل یا تغییرات در فرآیند مؤثر هستند و در واقع از بین ابزارهای هفت‌گانه برای پایش مسائل کیفی، پرقدردترین هستند. نمودارهای کنترل به دو دسته‌ی تک‌متغیره و چندمتغیره تقسیم می‌شوند. در کنترل فرآیند آماری هنگامی که از نمودارهای کنترل برای پایش کیفیت یک محصول یا یک فرآیند استفاده می‌شود، زمانی که نمودار حالت

تاریخ دریافت: ۱۳۹۸/۱۱/۲۴ / تاریخ پذیرش: ۱۳۹۹/۰۵/۰۴

دوره ۱۰ / شماره ۱

صفحات: ۳۴ - ۴۸

* (Corresponding author) ayoubi.m@wtiau.ac.ir

از طرفی، در بسیاری از موارد در عمل، کیفیت یک محصول یا فرآیند توسط یک رابطه‌ی رگرسیونی که یک یا چند متغیر پاسخ (متغیر وابسته) را به یک یا چند متغیر پیشگو (متغیر مستقل) مرتبط می‌کند، تعریف می‌شود. این رابطه‌ی رگرسیونی اصطلاحاً پروفایل نامیده می‌شود. لازم به ذکر است که پروفایل به رابطه‌ی رگرسیونی اطلاق می‌شود که در هر نمونه (زیرگروه) از فرآیند یا محصول تکرار می‌شود. یعنی مشخصه‌ی کیفی مورد نظر یک رابطه‌ی رگرسیونی است که در طول زمان (در هر نمونه) باید پایش شود. به منظور پایش پروفایل‌ها همانند دیگر مشخصه‌های کیفی از نمودارهای کنترل استفاده می‌شود. با توجه به این که انواع مختلفی از روابط رگرسیونی وجود دارد، می‌توان انواع مختلفی از پروفایل‌ها را بر اساس آن‌ها تعریف نمود. از میان آن‌ها می‌توان به پروفایل‌های خطی ساده، خطی چندگانه، چندجمله‌ای، خطی چندمتغیره، غیرخطی، اسپیلیان و موجی شکل اشاره کرد. محققین بسیاری تا کنون در حوزه‌ی پایش پروفایل‌ها هر دو فاز ۱ و ۲ را مد نظر قرار دادند. در فاز ۱، پروفایل‌های خطی ساده، مورد تمرکز کنگ و آلباین [۲۴]، محمود و وودال [۲۵]، محمود و همکاران [۲۶] و یه و زره‌ساز [۲۷] قرار گرفتند. فاز ۲ پایش پروفایل‌های خطی ساده توسط محققینی نظیر کنگ و آلباین [۲۴]، کیم و همکاران [۲۸] و گوپتا و همکاران [۲۹] مورد توجه قرار گرفته است. حسینی‌فرد و همکاران [۳۰] سه رویکرد با استفاده از شبکه‌ی عصبی مصنوعی پرسپترون برای پایش پروفایل‌های خطی ساده مطرح کردند. ژنگ و همکاران [۳۱] نیز پایش پروفایل‌های خطی ساده را با تنها یک نمودار کنترل مبتنی بر آماره‌های نسبت درست‌نمایی و EWMA مد نظر قرار دادند. و اخیراً محمود و همکاران [۳۲] برای پایش پارامترهای پروفایل خطی ساده نمودارهای کنترل MAX-EWMA-3 و SS-EWMA-3 را طراحی کردند. عباسی و همکاران [۳۳] نیز با در نظر گرفتن متغیرهای مستقل تصادفی و با استفاده از نمودار میانگین متحرک موزون نمایی دوگانه^۱ به پایش پروفایل‌های خطی ساده پرداختند. از آنجایی که در این تحقیق پروفایل‌های چندگانه مدنظر هستند و پروفایل‌های چندگانه حالت خاصی از پروفایل‌های چندمتغیره هستند، در ادامه چند مورد از تحقیقات انجام شده در حوزه‌ی پایش پروفایل‌های چندمتغیره و چندگانه مطرح می‌شوند. نورالسنا و همکاران [۳۴] نیز سه روش نمودار کنترل MEWMA، نمودارهای کنترل ترکیبی MEWMA-کای دو و استفاده از سه نمودار کنترل MEWMA را برای پایش پروفایل‌های خطی چندمتغیره مطرح کردند. امیری و همکاران [۳۵] با تمرکز بر فاز ۲، سه روش برای پایش هم‌زمان پروفایل‌های خطی چندمتغیره و خطی تعمیم یافته (GLM) پیشنهاد کردند. کردستانی و همکاران [۳۶] سه روش تخمین استوار^۲ شامل تخمین‌زنده‌های M، S و MM را برای تخمین پارامترهای

نمایی (EWMA)، تخمین‌زنده‌ی حداکثر درست‌نمایی، روش خوشه‌بندی و رویکرد شبکه‌های عصبی مصنوعی را نام برد. پیچ [۱] تخمین‌زنده‌ی درونی نمودار کنترل تجمعی را پیشنهاد داد. نیشینا [۲] تخمین‌زنده‌ی درونی میانگین متحرک موزون نمایی را معرفی کرد. نقطه‌ی تغییر انواع مختلفی دارد که عبارتند از: پله‌ای، تدریجی، یکنوا که شامل یکنوای افزایشی و یکنوای کاهشی می‌باشد و تغییرات بی‌نظم. تخمین نقطه‌ی تغییر پله‌ای با استفاده از رویکرد حداکثر درست‌نمایی (MLE) توسط ساموئل و همکاران [۳]، [۴] پیگناتیلو و ساموئل [۵] و نورالسنا و همکاران [۶] در نظر گرفته شده است. شیخ‌رابری و همکاران [۷] رویکرد MLE را برای تخمین نقطه‌ی تغییر که در آن مدل AR(1) ایستا به فرآیند غیرایستا تغییر پیدا می‌کند، توسعه دادند. آنها همچنین از فیلترینگ و هموارسازی به عنوان دو روش تخمین در مدل‌های خطی پویا برای تخمین پارامترهای ناشناخته‌ی بعد از نقطه‌ی تغییر استفاده کردند. شیخ‌رابری و همکاران [۸] نیز تخمین نقطه‌ی تغییر پله‌ای را از حالت ایستا به غیر ایستا در سری‌های زمانی مدل ARMA(1,1) مد نظر قرار دادند. به منظور تخمین نقطه‌ی تغییر تدریجی، پری و پیگناتیلو [۹] و پری و همکاران [۱۰] رویکرد حداکثر درست‌نمایی را توسعه دادند. پری و همکاران [۱۱]، نورالسنا و شادمان [۱۲] برای شناسایی نقطه‌ی تغییر یکنوا از رویکرد MLE استفاده کردند. در فرآیندهای چندمتغیره‌ی کمی و وصفی نیز محققانی نظیر موفق و امیری [۱۳] و نیایکی و خدمتی [۱۴] برآورد نقطه‌ی تغییر یکنوای افزایشی را مد نظر قرار دادند. غضنفری و همکاران [۱۵] و علاء‌الدینی و همکاران [۱۶] برای تخمین نقطه‌ی تغییر پله‌ای، یک رویکرد خوشه‌بندی پیشنهاد کردند. امیری و همکاران [۱۷] برای تخمین زمان تغییر پله‌ای در میانگین فرآیندی با ویژگی چندمتغیره از دو روش شبکه‌ی عصبی مصنوعی و MLE استفاده کردند که نتایج بدست آمده عملکرد بسیار مناسب هر دو روش را تحت مقادیر مختلف تغییر، به صورت جداگانه و هم‌زمان در میانگین فرآیند نشان داد. آتشگر و نورالسنا [۱۸]، نورالسنا و همکاران [۱۹] و آتشگر و نورالسنا [۲۰] با استفاده از شبکه‌ی عصبی پرسپترون چندلایه اقدام به برآورد نقاط تغییر پله‌ای، خطی تدریجی و یکنوای افزایشی در میانگین فرآیندهای نرمال چندمتغیره کرده‌اند. همچنین امیری و همکاران [۲۱] نیز از شبکه‌ی عصبی احتمالی جهت تخمین نقطه‌ی تغییر پله‌ای در پراکندگی یک فرآیند نرمال استفاده کردند. احمدزاده [۲۲] جهت تخمین نقطه‌ی تغییر پله‌ای در میانگین یک فرآیند نرمال چندمتغیره، رویکردی مبتنی بر شبکه‌ی عصبی پرسپترون چندلایه ارائه کرده است و در پایان امیری و اللهیاری [۲۳] مروری جامع بر ادبیات حوزه‌ی تخمین نقطه‌ی تغییر انجام داده‌اند که علاقمندان جهت کسب اطلاعات بیشتر می‌توانند به این مقاله مراجعه کنند.

کازم‌زاده و همکاران [۴۵]، ایوبی و همکاران [۴۶]، هوانگ و همکاران [۴۷]، وانگ و هوانگ [۴۸]، نای و دو [۴۹]، استوارد و ریگدون [۵۰]، سوگندی و امیری [۵۱]، ملکی و همکاران [۵۲] و مقدم و همکاران [۵۳] از مفهوم نقطه‌ی تغییر در حوزه‌ی پیش پروفایل‌ها استفاده کردند.

در این تحقیق، با استفاده از رویکرد شبکه‌ی عصبی مصنوعی تخمین نقطه‌ی تغییر پله‌ای در پروفایل‌های چندگانه مد نظر قرار داده شده است. ساختار مقاله به این ترتیب است، در بخش دوم مدل پروفایل چندمتغیره و مفروضات آن مطرح می‌شود. رویکرد پیش در بخش سوم بیان می‌شود. مدل تغییر پله‌ای در بخش چهارم ذکر می‌شود. در بخش پنجم ابتدا شبکه‌ی عصبی پیشنهادی به طور مختصر شرح داده می‌شود و سپس نحوه‌ی آموزش و آزمون شبکه برای تخمین نقطه‌ی تغییر به طور کامل بیان می‌شود. نتایج بدست آمده از شبیه‌سازی‌ها در بخش ششم مورد بررسی قرار می‌گیرد و در پایان نتیجه‌گیری و پیشنهادات برای تحقیقات آتی در بخش هفتم ارائه می‌شود.

پروفایل خطی ساده‌ی چندمتغیره در دو فاز ۱ و ۲ به کار گرفتند. رحیمی و همکاران [۳۷] پیش پروفایل‌های خطی چندمتغیره را هنگامی که فرض مستقل بودن مشاهدات در هر پروفایل نقض شده است، در فاز ۲ در نظر گرفتند و سپس دو نمودار کنترل $SS-EWMA$ و $MAX-EWMA$ را برای پیش هم‌زمان بردار میانگین و ماتریس کوواریانس در پروفایل‌های خطی چندمتغیره‌ی خودهمبسته پیشنهاد دادند. بهرامی و همکاران [۳۸] با استفاده از سه روش $MEWMA$ ، $MAX-MEWMA$ و $MEWMA$ کای‌دو، پیش پروفایل‌های خطی ساده‌ی چندمتغیره در فرآیند-های چندمرحله‌ای در فاز ۲ را مد نظر قرار دادند. در حوزه‌ی پیش پروفایل‌های خطی چندگانه نیز تحقیقاتی در ادبیات موضوع انجام شده است. محمود [۳۹] روش جدیدی را برای پیش پروفایل‌های خطی چندگانه در فاز ۱ ارائه کرد. در روش پیشنهادی وی، صرف-نظر از تعداد متغیرهای مستقل، متغیر پاسخ با استفاده از سه پارامتر شیب، عرض از مبدأ و واریانس پیش می‌شود. همچنین، پیش پروفایل‌های چندگانه در فاز ۲ مورد تمرکز برخی محققین نظیر زو و همکاران [۴۰]، امیری و همکاران [۴۱] و محمود و همکاران [۴۲] قرار گرفته است. در سال‌های اخیر برخی از محققین نظیر ایوزیان و همکاران [۴۳]، ایوبی و همکاران [۴۴]

۲- مدل پروفایل چندگانه در فاز ۲ و مفروضات آن

در این تحقیق، مدل تحت کنترل مفروض پروفایل خطی چندگانه در نمونه‌ی j ام با مفروض بودن مقادیر ثابت برای متغیرهای مستقل X (تعداد متغیرهای مستقل با نماد q نشان داده می-شود) و n مشاهده‌ی $(x_{i1}, x_{i2}, \dots, x_{iq}, y_{ij})$ به صورت زیر است:

$$\mathbf{y}_j = \mathbf{X}\boldsymbol{\beta}_j + \boldsymbol{\varepsilon}_j \quad (1)$$

رابطه‌ی (۱) را می‌توان به صورت برداری و ماتریسی طبق رابطه‌ی (۲) بازنویسی کرد:

$$\begin{bmatrix} y_{1j} \\ y_{2j} \\ \vdots \\ y_{nj} \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1q} \\ 1 & x_{21} & x_{22} & \cdots & x_{2q} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nq} \end{bmatrix} \begin{bmatrix} \beta_{1j} \\ \beta_{2j} \\ \vdots \\ \beta_{qj} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1j} \\ \varepsilon_{2j} \\ \vdots \\ \varepsilon_{nj} \end{bmatrix} \quad (2)$$

به طوری که \mathbf{y}_j یک بردار $n \times 1$ بعدی شامل مقادیر متغیرهای پاسخ، \mathbf{X} ماتریس مقادیر متغیرهای مستقل به ابعاد $n \times (q+1)$ و $\boldsymbol{\beta}_j$ بردار ضرایب پروفایل به ابعاد $(q+1) \times 1$ هستند. همچنین $\boldsymbol{\varepsilon}_j$ برداری $n \times 1$ بعدی شامل عناصر خطای مستقل است که عناصر آن یعنی ε_{ij} (برای $i=1, 2, \dots, n$) از توزیع نرمال با میانگین صفر و واریانس ثابت σ^2 تبعیت می‌کند.

۳- رویکرد پایش: نمودارهای کنترل ترکیبی EWMA-کای دو

در این رویکرد، ابتدا آماره‌ی زیر برای نمونه‌ی j ام تعریف می‌شود:

$$z_j = \lambda \bar{\mathbf{E}}_j + (1-\lambda)z_{j-1}, \quad j=1,2,\dots \quad (3)$$

که در آن λ ضریب هموارسازی است و z مقدار صفر در نظر گرفته می‌شود. $\bar{\mathbf{E}}_j$ نیز همان میانگین خطا است که از

$$\bar{\mathbf{E}}_j = \frac{\sum_{i=1}^n \mathbf{E}_{ij}}{n}$$

طریق $\bar{\mathbf{E}}_j$ حاصل می‌شود و از توزیع نرمال با

بردار میانگین صفر و واریانس $\sigma_{\bar{\mathbf{E}}}^2 = \frac{\sigma^2}{n}$ تبعیت می‌کند.

واریانس z_j آماره‌ی z_j نیز به صورت

$$\sigma_z^2 = \frac{\lambda}{(2-\lambda)} \sigma_{\bar{\mathbf{E}}}^2 = \frac{\lambda}{n(2-\lambda)} \sigma^2$$

در نهایت،

آماره‌ی نمودار کنترل EWMA با استفاده از رابطه‌ی زیر حاصل می‌شود:

$$T_{z_j}^2 = \frac{z_j^2}{\sigma_z^2}, \quad j=1,2,\dots \quad (4)$$

حد کنترل بالا برای نمودار کنترل EWMA با استفاده از ۱۰۰۰۰ تکرار شبیه‌سازی و به گونه‌ای محاسبه می‌شود که متوسط طول دنباله‌ی مشخصی در حالت تحت کنترل به دست آید. همچنین، آماره‌ی نمودار کنترل کای دو برای نمونه‌ی j ام طبق رابطه‌ی زیر تعریف می‌شود:

$$\chi_j^2 = \sum_{i=1}^n \left(\frac{\mathbf{E}_{ij}^2}{\sigma^2} \right) \quad (5)$$

از آنجایی که آماره‌ی χ_j^2 از توزیع کای دو با n درجه‌ی آزادی پیروی می‌کند، حدکنترل بالای نمودار کنترل کای دو با در نظر گرفتن خطای نوع اول (α) مشخص از رابطه‌ی $\chi_{n,\alpha}^2$ حاصل می‌شود.

لازم به ذکر است که در این تحقیق، نماد T نمایش‌دهنده‌ی زمانی است که نمودار کنترل EWMA-کای دو هشدار خارج از کنترل بودن فرآیند را صادر می‌کند.

۴- مدل تغییر پله‌ای

از آنجایی که تمرکز این تحقیق بر تخمین نقطه‌ی تغییر در فاز ۲ است، بنابراین بردار ضرایب پروفایل، β ، و همچنین واریانس عناصر خطا، σ^2 ، دارای مقادیر مشخص و شناخته شده هستند. به منظور استفاده از رویکرد پیشنهادی، فرض می‌شود تا قبل از نقطه‌ی واقعی تغییر، τ ، فرآیند تحت کنترل است، بنابراین، $\beta_j = \beta$ برای $j=1,2,\dots,\tau$ است. با فرض این که تغییری در ماتریس واریانس-کوواریانس رخ نمی‌دهد، تغییر پله‌ای در پارامترهای فرآیند برطبق رابطه‌ی زیر ایجاد می‌شود:

$$\beta_j = \beta + \mathbf{k}, \quad j = \tau+1, \tau+2, \dots, T \quad (6)$$

همچنین، \mathbf{k} برداری شامل مقادیر تغییر پله‌ای در هر یک از پارامترهای مدل پروفایل و هم‌بعد با بردار β است. به طور معادل، برای پروفایل خطی چندگانه مدل برداری تغییر پله‌ای به صورت زیر است:

$$\begin{bmatrix} \beta_{.j} \\ \beta_{.j} \\ \vdots \\ \beta_{.qj} \end{bmatrix} = \begin{bmatrix} \beta_{.} \\ \beta_{.} \\ \vdots \\ \beta_{.q} \end{bmatrix} + \begin{bmatrix} k_{.} \\ k_{.} \\ \vdots \\ k_{.q} \end{bmatrix} \quad (7)$$

بنابراین، $k_{.}, k_{.1}, \dots, k_{.q}$ به ترتیب میزان تغییر پله‌ای در پارامترهای پروفایل یعنی $\beta_{.}, \beta_{.1}, \dots, \beta_{.q}$ هستند.

۵- شبکه‌های عصبی احتمالی (PNN)

امیری و همکاران [۲۱] برای تخمین نقطه‌ی تغییر پله‌ای در واریانس یک فرآیند نرمال تک‌متغیره از شبکه‌های عصبی مصنوعی احتمالی^۲، پیشخور چندلایه^۴ و انتشار بازگشتی^۵ با ساختار مختلف نظیر تعداد لایه‌های مختلف، تعداد مختلف نرون‌های هر لایه، تابع انتقال‌های گوناگون، تابع یادگیری^۶، فرآیند آموزش و تعداد ورودی‌ها و خروجی‌های مختلف استفاده کردند. آنها اظهار داشتند که در نهایت از شبکه‌های عصبی پیشخور چندلایه و انتشار بازگشتی نتایج قابل قبولی حاصل نشد و فرآیند آموزش این دو شبکه نیازمند زمان بسیار زیادی است ولی از شبکه‌ی عصبی احتمالی در مقایسه با دو شبکه‌ی مذکور، نتایج بهتری حاصل شد و فرآیند آموزش این

است، بنابراین در فرآیند آموزش شبکه‌ی PNN پیشنهادی از آماره‌ی کای دو استفاده نخواهد شد.

همچنین، تعداد نرون‌های ورودی و خروجی شبکه به اندازه‌ی ۱۰۰ در نظر گرفته می‌شود (یعنی ۱۰۰ نرون ورودی و ۱۰۰ نرون خروجی). در این تحقیق به منظور تولید داده‌های آموزشی شبکه گام‌های زیر انجام شده است:

گام ۱: تولید یک عدد صحیح تصادفی بین صفر و ۱۰۰ برای ایجاد نقطه‌ی تغییر فرضی (به عنوان مثال اگر عدد صحیح تولید شده ۴۰ باشد، یعنی نمونه‌ی ۴۰ام اولین نمونه‌ی خارج از کنترل است، پس $\tau = 39$ نقطه‌ی تغییر یا آخرین نمونه‌ی تحت کنترل در نظر گرفته می‌شود).

گام ۲: تولید نمونه‌های تحت کنترل به تعداد τ نمونه و محاسبه‌ی آماره‌های مرتبط با هر نمونه (مقدار τ از گام ۱ به دست آمده است). با توجه به اینکه τ نمونه‌ی تحت کنترل می‌بایست ایجاد شود، بنابراین در این τ نمونه نباید هشدار اشتباهی^{۱۱} وجود داشته باشد. (از آنجایی که در آماره‌ی نمودار کنترل EWMA اطلاعات نمونه‌های قبل نیز دخیل هستند، نمی‌توان تنها آخرین نمونه‌ای که رویکرد پیش در آن هشدار اشتباه می‌دهد را حذف نمود. زیرا در این نمودار به دلیل وابستگی آماره‌ها ممکن است چندین نمونه با هم سبب ایجاد هشدار اشتباه در نمودار کنترل شده باشند. بنابراین، همه‌ی نمونه‌های پیش از هشدار اشتباه حذف می‌شوند و اولین نمونه‌ی بعد از آن به عنوان اولین نمونه‌ی فرآیند در نظر گرفته می‌شود).

گام ۳: تولید نمونه‌های خارج از کنترل با ایجاد تغییر پله‌ای در یکی از عناصر بردار β از نمونه‌ی $\tau + 1$ به بعد تا زمان دریافت هشدار خارج از کنترل بودن فرآیند از رویکرد پیش ترکیبی EWMA-کای دو یعنی زمان T ، سپس محاسبه‌ی آماره‌های هر نمونه. (اندازه‌ی تغییر پله‌ای به صورت تصادفی از توزیع یکنواخت پیوسته در بازه‌ی $[a, b]$ تولید می‌شود. بازه‌های

$[1, 2]$ ، $[0.5, 1]$ ، $[0.1, 0.5]$ ، $[0.05, 0.1]$ ، $[0, 0.05]$ برای تولید عدد تصادفی برای ایجاد تغییر پله‌ای مد نظر قرار می‌گیرد).

گام ۴: مقادیر نرون‌های خروجی برای نمونه‌های تحت کنترل، صفر و برای نمونه‌های خارج از کنترل ۱ در نظر گرفته می‌شود.

شبکه به زمان بسیار کوتاه‌تری نیاز دارد. بنابراین ما بر اساس نتایج این تحقیق از شبکه‌ی عصبی احتمالی برای تخمین نقطه‌ی تغییر استفاده کردیم. همچنین شبکه‌های عصبی احتمالی، دارای ساختار موازی تفکیک‌ناپذیر هستند و هرچه اندازه‌ی مجموعه‌ی آموزشی نماینده افزایش پیدا کند، شبکه‌ی عصبی احتمالی، همگرا شدن برای رسیدن به یک طبقه-بندی بهینه را تضمین می‌کند. این نوع شبکه‌ی عصبی مصنوعی علیرغم داشتن مزایا، معایبی نیز دارند. یکی از معایب این نوع شبکه این است که دقیقاً به یک نمونه‌ی نماینده از مجموعه‌ی داده، به عنوان مجموعه‌ی آموزشی نیاز دارد.

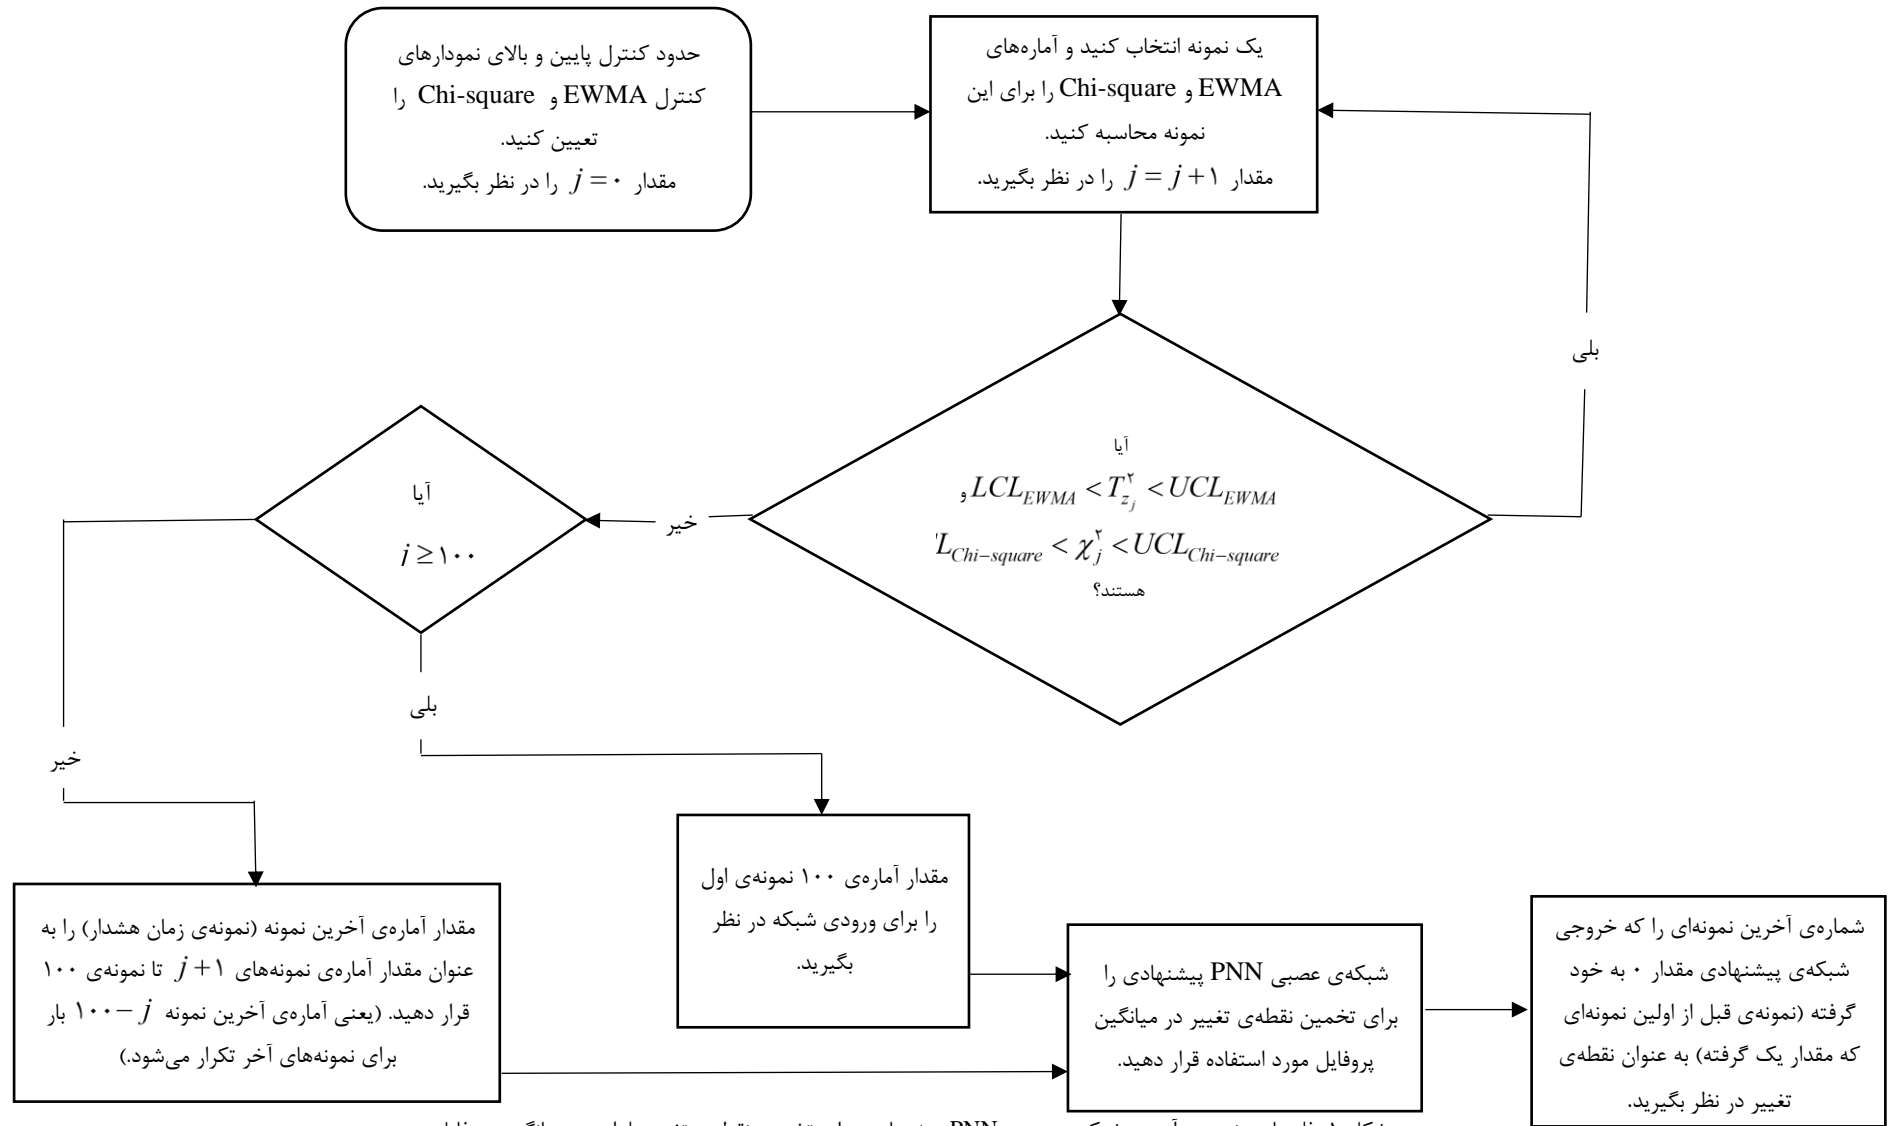
از شبکه‌های عصبی احتمالی در مورد مسائل طبقه‌بندی استفاده می‌شود. زمانی که یک بردار ورودی به شبکه اعمال می‌شود، لایه‌ی اول فاصله‌ی بردار ورودی را از ورودی‌های آموزشی محاسبه می‌کند و به این ترتیب برداری را فراهم می‌کند که عناصر آن تعیین‌کننده‌ی میزان فاصله‌ی بین ورودی و ورودی آموزشی هستند. لایه‌ی دوم با استفاده از خروجی لایه‌ی اول، برداری از احتمال‌ها را به عنوان خروجی شبکه تولید می‌کند. در نهایت تابع انتقال رقابتی^۷ موجود در لایه‌ی دوم، حداکثر مقدار احتمال‌ها را از بردار احتمال‌ها انتخاب می‌کند و به ازای آن خروجی ۱ و به ازای بقیه‌ی احتمال‌ها خروجی صفر تولید می‌نماید. شبکه‌ی عصبی احتمالی مورد استفاده در این تحقیق یک شبکه‌ی دو لایه است که لایه‌ی اول دارای تابع انتقال پایه شعاعی^۸ است و ورودی‌های موزون را با تابع وزنی فاصله‌ی اقلیدسی^۹ محاسبه می‌کند. لایه‌ی دوم نیز دارای تابع انتقال رقابتی است که ورودی‌های موزون را با استفاده از تابع وزنی ضرب نقطه‌ای^{۱۰} محاسبه می‌کند.

۵-۱- آموزش شبکه‌ی عصبی احتمالی پیشنهادی

برای تخمین نقطه‌ی تغییر در میانگین پروفایل

چندگانه

از آنجایی که در این تحقیق، ما بر تخمین نقطه‌ی تغییر در میانگین پروفایل‌های چندگانه تمرکز کرده‌ایم، بنابراین مقادیر آماره‌های $T_{z_j}^2$ ، بر اساس رابطه‌ی (۴)، که آماره‌های نمودار EWMA هستند و برای پیش میانگین پروفایل چندگانه در فاز ۲ به کار می‌روند، به عنوان ورودی‌های شبکه‌ی عصبی احتمالی پیشنهادی در نظر گرفته می‌شوند. ضمناً به دلیل اینکه تمرکز این تحقیق بر روی شناسایی تغییر در میانگین فرآیند است و آماره‌ی کای دو مربوط به پایش واریانس فرآیند



شکل ۱. فلوچارت نحوه‌ی آزمون شبکه‌ی عصبی PNN پیشنهادی برای تخمین نقطه‌ی تغییر پله‌ای در میانگین پروفایل

۶- ارزیابی عملکرد شبکه‌ی عصبی پیشنهادی در تخمین نقطه‌ی تغییر

در این بخش، عملکرد شبکه‌ی عصبی پیشنهادی با عملکرد تخمین‌زننده‌های نقطه‌ی تغییر مبتنی بر رویکرد MLE که توسط کاظم‌زاده و همکاران [۴۵] ارائه شده است، مقایسه می‌شود. بدین منظور، از ۵۰۰۰ تکرار شبیه‌سازی مونت کارلو استفاده شده است. در هر تکرار هنگامی که نمودارهای کنترل ترکیبی EWMA-کای دو هشدار خارج از کنترل بودن فرآیند را بدهند، شبکه‌ی عصبی مورد نظر، مورد استفاده قرار می‌گیرد. همچنین، مقدار $\lambda = 0/2$ برای ضریب هموارسازی نمودار کنترل EWMA انتخاب می‌شود که مطابق با مقدار انتخاب شده در ادبیات پروفایل‌ها است. همچنین، ARL تحت کنترل کلی ۲۰۰ برای رویکرد پایش مدنظر قرار می‌گیرد. بنابراین، مقدار ARL تحت کنترل هر یک از نمودارهای کنترل EWMA و کای دو باید به تنهایی ۴۰۰ باشد.

نقطه‌ی تغییر $\tau = 25$ فرض می‌شود. همانطور که قبلاً اشاره شد، به منظور مواجه شدن با هشدارهای اشتباهی، رویکرد پیگناتیلو و ساموئل [۵] و پری و پیگناتیلو [۹] به کار گرفته می‌شود. از آنجایی که در آماره‌ی نمودار کنترل EWMA اطلاعات نمونه‌های قبل نیز دخیل هستند، نمی‌توان تنها آخرین نمونه‌ای که رویکرد پایش در آن هشدار اشتباه می‌دهد را حذف نمود. زیرا در این نمودار به دلیل وابستگی آماره‌ها ممکن است چندین نمونه با هم سبب ایجاد هشدار اشتباه در نمودار کنترل شده باشند. بنابراین، همه‌ی نمونه‌های پیش از هشدار اشتباه حذف می‌شوند و اولین نمونه‌ی بعد از آن به عنوان اولین نمونه‌ی فرآیند در نظر گرفته می‌شود. بدین‌گونه، نقطه‌ی تغییر می‌تواند از یک تکرار به تکرار بعد تغییر کند. به عنوان مثال، در این تحقیق، $\tau = 25$ فرض می‌شود، بنابراین ۲۵ نمونه‌ی تحت کنترل در هر تکرار تولید می‌شود. اگر در یک تکرار یک هشدار اشتباه در نمونه‌ی ۱۵ رخ دهد، ۱۵ نمونه اول حذف می‌شوند و نمونه‌ی ۱۶ به عنوان اولین نمونه‌ی فرآیند در نظر گرفته می‌شود. در صورتی که در مابقی نمونه‌ها هشدار اشتباه نداشته باشیم، ۱۰ نمونه‌ی دیگر تولید می‌شود. در نتیجه، در تکرار مربوطه

$\tau = 10$ در نظر گرفته می‌شود. سپس نمونه‌های خارج از کنترل تحت تغییر پله‌ای آن قدر تولید می‌شوند تا رویکرد پایش هشدار خارج از کنترل بدهد. در این هنگام از شبکه‌ی عصبی پیشنهادی برای شناسایی زمان تغییر استفاده می‌شود. مدل تحت کنترل مورد استفاده، به صورت زیر است:

$$Y = 3 + 2x_1 + x_2 + \varepsilon, \quad \varepsilon \sim N(0, 1) \quad (8)$$

همچنین، مقادیر $(1, 2)$ ، $(3, 4)$ و $(4, 1)$ به عنوان مقادیر متغیرهای مستقل (x_1, x_2) در نظر گرفته شده‌اند. جهت پایش مدل پروفایل فوق، مقدار $8/3$ برای حدکنترل بالای نمودار کنترل EWMA و مقدار $23/7745$ برای حدکنترل بالای نمودار کای دو در نظر گرفته می‌شوند.

برای آموزش شبکه‌ی عصبی گام‌های بخش ۵-۱ انجام می‌گیرند. برای تولید آماره‌های خارج از کنترل که در بخش ۵-۱ در گام ۳ شرح داده شد، در هر یک از بازه‌های ذکر شده توزیع یکنواخت، به طور مجزا، ابتدا باید در هر یک از ۳ پارامتر β_1 ، β_2 و β_3 به میزان یک عدد تصادفی یکنواخت در بازه‌ی مورد نظر، تغییر ایجاد کرد و برای ایجاد این تغییر در هر یک از پارامترها، به طور جداگانه به ۵۰۰۰ داده‌ی آموزشی نیاز است و این بدان معناست که به ازای هر بازه برای هر سه پارامتر بردار β تعداد ۱۵۰۰۰ داده‌ی آموزشی و در مجموع با در نظر گرفتن ۵ بازه‌ی توزیع یکنواخت که در گام ۸ بخش ۵-۱ آورده شد، ۷۵۰۰۰ داده‌ی آموزشی برای آموزش شبکه مورد نیاز است. سپس آماره‌ی $T_{\tau_j}^2$ در حالت خارج از کنترل محاسبه می‌شود و تولید آماره‌های خارج از کنترل تا زمانی که نمودارهای کنترل ترکیبی EWMA-کای دو هشدار خارج از کنترل بودن فرآیند را صادر کند ادامه خواهد داشت. پس از دریافت هشدار توسط نمودار کنترل، شبکه‌ی عصبی احتمالی (PNN) برای تخمین نقطه‌ی تغییر پله‌ای در میانگین فرآیند به کار گرفته می‌شود.

نقطه‌ی تغییر پله‌ای را نشان می‌دهند. در بخش عملکرد صحت، میانگین مربعات خطای شبکه‌ی عصبی پیشنهادی داخل پرانتز گزارش می‌شوند. در بخش دقت نیز

$$\hat{P}_1 = \hat{p}(|\hat{\tau} - \tau| \leq 1), \quad \hat{P}_0 = \hat{p}(|\hat{\tau} - \tau| = 0)$$

$$\hat{P}_\delta = \hat{p}(|\hat{\tau} - \tau| \leq \delta), \quad \hat{P}_\tau = \hat{p}(|\hat{\tau} - \tau| \leq \tau)$$

$$\hat{P}_\gamma = \hat{p}(|\hat{\tau} - \tau| \leq \gamma) \quad \text{و} \quad \hat{P}_1 = \hat{p}(|\hat{\tau} - \tau| \leq 1.0)$$

دقت شبکه‌عصبی پیشنهادی را گزارش می‌کند.

نتایج شبیه‌سازی‌ها به ازای تغییرات پله‌ای در پارامترهای پروفایل در جداول ۱ و ۲ خلاصه شده‌اند که به ترتیب عملکرد دو رویکرد مورد ارزیابی را به ازای تغییرات موجود در پارامترهای پروفایل نشان می‌دهند. در این جداول، رویکرد MLE پله‌ای که توسط کاظم‌زاده و همکاران [۴۵] مطرح شد نیز برای مقایسات عملکرد مورد استفاده قرار می‌گیرد. در این تحقیق، گزارش نتایج در هر جدول شامل دو بخش است که عملکرد صحت و دقت رویکردهای تخمین

جدول ۱. صحت و دقت شبکه‌ی عصبی پیشنهادی و رویکرد MLE تحت تغییر پله‌ای در تنها یک پارامتر مدل، $\tau = 25$ و $N = 5000$

$\mathbf{k} = \begin{bmatrix} k_{.1} \\ k_{11} \\ k_{\tau 1} \end{bmatrix}$		$\begin{bmatrix} 0/1 \\ \cdot \\ \cdot \end{bmatrix}$	$\begin{bmatrix} 0/2 \\ \cdot \\ \cdot \end{bmatrix}$	$\begin{bmatrix} 0/4 \\ \cdot \\ \cdot \end{bmatrix}$	$\begin{bmatrix} 0/6 \\ \cdot \\ \cdot \end{bmatrix}$	$\begin{bmatrix} 0/8 \\ \cdot \\ \cdot \end{bmatrix}$	
		صحت شبکه‌ی پیشنهادی	ARL	۸۳/۶۴۴۰	۲۷/۲۹۶۲	۷/۸۷۰۲	۴/۲۷۸۲
$\bar{\tau}_{PNN}$ (MSE)	۶۰/۷۳۹۴ (۲۱۰۲/۱۰۰۰)		۳۸/۷۹۴۸ (۵۳۵/۴۸۳۶)	۲۸/۳۸۱۴ (۴۴/۳۵۹۸)	۲۶/۱۸۵۸ (۱۳/۲۲۸۶)	۲۵/۳۷۹۶ (۷/۱۳۲۸)	
$\bar{\tau}_{MLE}$ (MSE)	۶۰/۷۳۳۲ (۳۷۰۸/۵۰۰۰)		۳۱/۴۹۲۸ (۲۵۱/۳۳۵۶)	۲۴/۸۸۵۰ (۲۷/۵۰۹۸)	۲۴/۲۶۲۸ (۱۴/۹۱۶۴)	۲۴/۳۸۹۶ (۹/۱۴۴۴)	
دقت شبکه‌ی پیشنهادی	\hat{P}_0	PNN	۰/۰۰۶۶	۰/۰۲۰۲	۰/۰۷۴۰	۰/۱۸۰۸	۰/۲۸۳۰
		MLE	۰/۰۲۵۸	۰/۰۸۹۰	۰/۲۷۵۰	۰/۴۶۹۰	۰/۶۳۸۶
	\hat{P}_1	PNN	۰/۰۲۴۲	۰/۰۶۱۸	۰/۲۲۰۰	۰/۴۵۷۰	۰/۶۶۱۰
		MLE	۰/۰۶۴۴	۰/۱۹۸۶	۰/۴۹۴۲	۰/۷۱۰۶	۰/۸۴۳۴
	\hat{P}_τ	PNN	۰/۰۵۹۰	۰/۱۴۷۲	۰/۵۱۸۸	۰/۸۴۲۰	۰/۹۴۶۸
		MLE	۰/۱۳۵۸	۰/۳۴۷۴	۰/۷۱۲۸	۰/۸۶۹۴	۰/۹۳۴۲
	\hat{P}_δ	PNN	۰/۰۸۷۶	۰/۲۳۴۰	۰/۷۲۲۰	۰/۹۴۳۰	۰/۹۷۴۸
		MLE	۰/۱۸۴۶	۰/۴۵۹۸	۰/۸۲۹۴	۰/۹۲۴۰	۰/۹۵۸۲
	\hat{P}_γ	PNN	۰/۱۲۲۸	۰/۳۱۵۲	۰/۸۲۷۰	۰/۹۷۲۰	۰/۹۸۲۴
		MLE	۰/۲۳۴۴	۰/۵۴۴۰	۰/۸۹۴۶	۰/۹۴۷۰	۰/۹۶۸۸
	\hat{P}_1	PNN	۰/۱۷۶۸	۰/۴۲۵۶	۰/۹۲۳۴	۰/۹۸۴۸	۰/۹۸۸۴
		MLE	۰/۳۰۳۶	۰/۶۴۲۴	۰/۹۳۷۲	۰/۹۶۴۲	۰/۹۷۸۰

جدول ۲. صحت و دقت شبکه‌ی عصبی پیشنهادی و رویکرد MLE تحت تغییر پله‌ای در چند پارامتر مدل به‌طور هم‌زمان، $\tau = 25$ و $N = 5000$

$\mathbf{k} = \begin{bmatrix} k_{\cdot 1} \\ k_{11} \\ k_{\tau 1} \end{bmatrix}$		$\begin{bmatrix} 0/05 \\ 0/01 \\ 0 \end{bmatrix}$	$\begin{bmatrix} 0/1 \\ 0/02 \\ 0 \end{bmatrix}$	$\begin{bmatrix} 0/2 \\ 0/025 \\ 0 \end{bmatrix}$	$\begin{bmatrix} 0/4 \\ 0/025 \\ 0 \end{bmatrix}$	$\begin{bmatrix} 0/6 \\ 0/05 \\ 0 \end{bmatrix}$	
صحت شبکه‌ی پیشنهادی	\widehat{ARL}	۹۳/۹۵۹۸	۳۳/۴۰۴۸	۱۲/۸۱۷۰	۵/۵۹۸۶	۳/۰۹۷۸	
	$\widehat{\tau}_{PNN}$ (MSE)	۶۳/۷۹۴۶ (۲۳۳۵/۰۰۰۰)	۴۱/۹۱۱۶ (۷۴۳/۲۵۸۸)	۳۱/۳۷۰۴ (۱۲۳/۷۸۰۴)	۲۶/۸۹۰۰ (۱۷/۱۵۵۲)	۲۵/۳۳۱۸ (۸/۱۰۰۲)	
	$\widehat{\tau}_{MLE}$ (MSE)	۶۸/۲۶۵۰ (۵۰۸۵/۰۰۰۰)	۳۳/۳۳۱۴ (۳۵۷/۷۵۵۴)	۲۶/۳۵۴۶ (۵۶/۳۵۹۴)	۲۴/۵۵۸۸ (۱۶/۲۸۰۴)	۲۴/۴۱۰۶ (۸/۵۱۰۶)	
دقت شبکه‌ی پیشنهادی	\widehat{P}	PNN	۰/۰۰۶۶	۰/۰۱۴۸	۰/۰۴۲۶	۰/۱۱۶۰	۰/۲۹۰۸
		MLE	۰/۰۲۲۴	۰/۰۷۵۰	۰/۱۸۰۸	۰/۳۸۸۰	۰/۶۴۵۲
	\widehat{P}_1	PNN	۰/۰۲۳۶	۰/۰۴۶۴	۰/۱۲۵۰	۰/۳۲۲۸	۰/۶۵۸۶
		MLE	۰/۰۵۹۶	۰/۱۷۳۴	۰/۳۴۳۲	۰/۶۲۰۸	۰/۸۴۶۰
	\widehat{P}_τ	PNN	۰/۰۵۷۶	۰/۱۱۸۰	۰/۳۱۸۲	۰/۷۰۳۰	۰/۹۴۰۴
		MLE	۰/۱۲۴۸	۰/۳۱۰۰	۰/۵۴۵۰	۰/۸۲۵۸	۰/۹۳۴۸
	\widehat{P}_δ	PNN	۰/۰۸۲۸	۰/۱۸۵۰	۰/۴۷۸۴	۰/۸۸۱۲	۰/۹۷۱۰
		MLE	۰/۱۷۲۶	۰/۴۰۶۲	۰/۶۷۶۴	۰/۹۰۱۶	۰/۹۵۶۲
	\widehat{P}_ν	PNN	۰/۱۱۵۴	۰/۲۵۳۰	۰/۶۰۱۴	۰/۹۴۱۶	۰/۹۸۰۸
		MLE	۰/۲۱۹۰	۰/۴۹۱۶	۰/۷۶۶۲	۰/۹۳۸۸	۰/۹۶۸۶
	\widehat{P}_1	PNN	۰/۱۶۲۲	۰/۳۵۴۴	۰/۷۳۷۸	۰/۹۷۹۸	۰/۹۸۵۶
		MLE	۰/۲۷۶۸	۰/۵۹۰۸	۰/۸۵۹۶	۰/۹۶۶۰	۰/۹۸۰۶

مزیت دیگری که شبکه‌ی عصبی پیشنهادی نسبت به روش MLE دارد این است که برای استفاده از روش MLE باید در ابتدا نوع تغییر مشخص باشد که این مسئله به شدت تخمین نقطه‌ی تغییر را به تجربه‌ی مهندسان کیفیت وابسته می‌کند، اما شبکه‌ی عصبی پیشنهادی بدون نیاز به دانستن نوع تغییر می‌تواند برای همه‌ی انواع تغییر آموزش داده شود و مورد استفاده قرار گیرد (یعنی در گام ۳ بخش ۵-۱ می‌تواند برای تولید داده‌های خارج از کنترل علاوه بر تغییر پله‌ای، تغییر تدریجی و دیگر انواع تغییر را نیز به پارامترهای فرآیند اعمال کرد و شبکه را آموزش داد، در این صورت موقع آزمون شبکه اگر تغییر از هر نوعی باشد، شبکه به راحتی می‌تواند نقطه‌ی تغییر را برآورد کند). بدین منظور، ما ۷۵۰۰۰ داده‌ی آموزشی نیز تحت تغییر تدریجی در پارامترها به داده‌های آموزشی اضافه کردیم و نتایج ارزیابی عملکرد شبکه‌ی پیشنهادی و روش MLE تدریجی کاظم‌زاده و همکاران [۴۵] به ازای تغییرات تدریجی در جداول ۳ و ۴ گزارش می‌شود.

نتایج شبیه‌سازی‌های جداول ۱ و ۲ به ازای تغییرات پله‌ای در میانگین پروفایل، نشان می‌دهند که شبکه‌ی عصبی احتمالی در تخمین نقطه‌ی تغییر عملکرد مناسب و قابل قبولی دارد. همچنین با افزایش میزان تغییر عملکرد صحت و دقت شبکه بهبود می‌یابد. در مقایسه با رویکرد MLE، به طور کلی در مجموع با در نظر گرفتن معیار میانگین مربعات خطا (MSE) می‌توان گفت، شبکه‌ی پیشنهادی در کشف تغییرات کوچک عملکرد بهتری نسبت به روش MLE دارد، زیرا در تغییرات کوچکتر تخمین‌زنده‌ی پیشنهادی شبکه‌ی عصبی مقدار میانگین مربعات خطای کمتری نسبت به تخمین‌زنده‌ی MLE دارد. ولی در تغییرات متوسط تا بزرگ در مجموع (معیار میانگین مربعات خطا)، عملکرد روش MLE بهتر است، زیرا در تغییرات متوسط تا بزرگ تخمین‌زنده‌ی MLE مقدار میانگین مربعات خطای کمتری نسبت به تخمین‌زنده‌ی شبکه‌ی عصبی دارد.

جدول ۳. صحت و دقت شبکه‌ی عصبی پیشنهادی و رویکرد MLE تحت تغییر تدریجی در تنها یک پارامتر مدل، $\tau = 25$ و $N = 5000$

$\mathbf{k} = \begin{bmatrix} k_{\cdot 1} \\ k_{11} \\ k_{\tau 1} \end{bmatrix}$		$\begin{bmatrix} \cdot \\ \cdot \\ \cdot / 0.0005 \end{bmatrix}$	$\begin{bmatrix} \cdot \\ \cdot \\ \cdot / 0.00075 \end{bmatrix}$	$\begin{bmatrix} \cdot \\ \cdot \\ \cdot / 0.0025 \end{bmatrix}$	$\begin{bmatrix} \cdot \\ \cdot \\ \cdot / 0.01 \end{bmatrix}$	$\begin{bmatrix} \cdot \\ \cdot \\ \cdot / 0.05 \end{bmatrix}$	
صحت شبکه‌ی پیشنهادی	ARL	۹۰/۱۶۰۸	۷۳/۸۷۰۸	۳۶/۷۶۵۸	۱۵/۵۸۷۶	۵/۸۹۴۸	
	$\hat{\tau}_{PNN}$ (MSE)	۷۰/۴۷۹۴ (۲۸۰۵/۹۰۰۰)	۶۶/۸۱۸۸ (۲۴۹۳/۱۰۰۰)	۴۷/۲۴۷۸ (۸۳۲/۶۶۷۰)	۳۲/۷۵۷۶ (۱۲۶/۶۸۱۶)	۲۶/۵۲۱۴ (۲۳/۰۷۵۴)	
	$\hat{\tau}_{MLE}$ (Drift) (MSE)	۷۰/۰۹۴۲ (۳۹۲۳/۸۰۰۰)	۵۹/۲۵۸۰ (۲۳۴۴/۶۰۰۰)	۳۷/۴۵۵۶ (۴۵۹/۱۵۸۰)	۲۷/۸۳۱۸ (۸۴/۸۶۴۲)	۲۴/۶۵۰۲ (۲۰/۳۳۹۴)	
دقت شبکه‌ی پیشنهادی	\hat{P}	PNN	۰/۰۰۴۶	۰/۰۰۵۴	۰/۰۰۶۲	۰/۰۱۶۸	۰/۰۷۶۲
		MLE	۰/۰۱۰۴	۰/۰۰۹۶	۰/۰۱۶۸	۰/۰۵۲۰	۰/۱۷۹۰
	\hat{P}_1	PNN	۰/۰۱۴۴	۰/۰۱۴۲	۰/۰۲۱۶	۰/۰۵۲۶	۰/۲۳۲۲
		MLE	۰/۰۲۸۲	۰/۰۲۳۸	۰/۰۵۵۰	۰/۱۳۸۰	۰/۴۶۲۰
	\hat{P}_τ	PNN	۰/۰۳۶۲	۰/۰۳۶۰	۰/۰۵۵۴	۰/۱۴۳۰	۰/۶۵۹۸
		MLE	۰/۰۵۷۴	۰/۰۵۵۶	۰/۱۲۵۸	۰/۳۰۶۰	۰/۷۸۵۲
	\hat{P}_δ	PNN	۰/۰۵۸۶	۰/۰۵۶۰	۰/۰۸۳۴	۰/۲۳۸۴	۰/۹۲۱۸
		MLE	۰/۰۸۲۸	۰/۰۸۵۶	۰/۱۸۸۴	۰/۴۵۴۶	۰/۹۱۱۰
	\hat{P}_ν	PNN	۰/۰۷۷۰	۰/۰۷۴۲	۰/۱۱۶۰	۰/۳۵۹۴	۰/۹۶۳۶
		MLE	۰/۱۰۹۰	۰/۱۱۷۰	۰/۲۵۵۲	۰/۵۸۴۰	۰/۹۴۶۴
	\hat{P}_1	PNN	۰/۱۰۸۴	۰/۱۰۴۰	۰/۱۵۹۶	۰/۵۶۴۶	۰/۹۷۸۶
		MLE	۰/۱۴۲۲	۰/۱۶۴۸	۰/۳۴۳۶	۰/۷۴۸۲	۰/۹۶۴۴

زیرا در تغییرات کوچکتر مقدار MSE شبکه‌ی عصبی کمتر از MSE روش MLE است و بنابراین روش شبکه‌ی عصبی در تغییرات کوچکتر بهتر عمل می‌کند ولی روش MLE در تغییرات متوسط و بزرگ عملکرد بهتری دارد.

نتایج جداول ۳ و ۴ نشان می‌دهند که شبکه‌ی عصبی پیشنهادی این قابلیت را دارد که بدون نیاز به دانستن نوع تغییر، نقطه‌ی تغییر را به خوبی برآورد کند. عملکرد شبکه تحت تغییرات تدریجی هم همانند تغییرات پله‌ای است و در مجموع (معیار میانگین مربعات خطا) شبکه‌ی عصبی پیشنهادی در تغییرات کوچک از روش MLE بهتر و در تغییرات متوسط تا بزرگ روش MLE بهتر عمل می‌کند،

جدول ۴. صحت و دقت شبکه‌ی عصبی پیشنهادی و رویکرد MLE تحت تغییر تدریجی در چند پارامتر مدل به‌طور هم‌زمان، $\tau = 25$ و $N = 5000$

$\mathbf{k} = \begin{bmatrix} k_{\tau_1} \\ k_{\nu_1} \\ k_{\tau_1} \end{bmatrix}$		$\begin{bmatrix} 0/0002 \\ 0/0002 \\ 0/0002 \end{bmatrix}$	$\begin{bmatrix} 0/0005 \\ 0/0005 \\ 0/0005 \end{bmatrix}$	$\begin{bmatrix} 0/00075 \\ 0/00075 \\ 0/00075 \end{bmatrix}$	$\begin{bmatrix} 0/001 \\ 0/001 \\ 0/001 \end{bmatrix}$	$\begin{bmatrix} 0/002 \\ 0/002 \\ 0/002 \end{bmatrix}$	
صحت شبکه‌ی پیشنهادی	$\hat{A}RL$	۸۲/۴۲۹۸	۴۹/۳۹۸۶	۳۸/۷۸۸۶	۳۲/۶۰۴۰	۲۱/۳۷۷۲	
	$\hat{\tau}_{PNN}$ (MSE)	۶۹/۵۵۵۲ (۲۷۵۳/۶۰۰۰)	۵۵/۳۱۱۸ (۱۵۰۵/۷۰۰۰)	۴۸/۵۷۸۸ (۹۴۹/۶۷۵۶)	۴۴/۹۶۴۲ (۶۴۹/۴۷۹۴)	۳۶/۹۷۸۴ (۲۶۴/۳۳۲۸)	
	$\hat{\tau}_{MLE}$ (Drift) (MSE)	۶۶/۳۵۰۶ (۳۲۱۱/۵۰۰۰)	۴۵/۸۵۱۲ (۹۸۵/۶۳۴۴)	۳۹/۴۳۹۰ (۵۶۵/۵۸۳۰)	۳۶/۲۲۱۶ (۳۸۲/۴۶۲۸)	۳۰/۵۷۹۴ (۱۶۱/۱۰۶۶)	
دقت شبکه‌ی پیشنهادی	\hat{P}	PNN	0/0070	0/0060	0/0068	0/0084	0/0120
		MLE	0/0074	0/0144	0/0170	0/0218	0/0302
	\hat{P}_1	PNN	0/0192	0/0228	0/0248	0/0268	0/0428
		MLE	0/0228	0/0386	0/0498	0/0604	0/0902
	\hat{P}_τ	PNN	0/0406	0/0480	0/0526	0/0626	0/0972
		MLE	0/0532	0/0882	0/1140	0/1358	0/2104
	\hat{P}_δ	PNN	0/0596	0/0718	0/0804	0/0918	0/1504
		MLE	0/0834	0/1344	0/1684	0/2036	0/3152
	\hat{P}_ν	PNN	0/0850	0/0938	0/1128	0/1278	0/2158
		MLE	0/1120	0/1794	0/2226	0/2674	0/4156
	\hat{P}_1	PNN	0/1092	0/1218	0/1574	0/1780	0/3326
		MLE	0/1448	0/2348	0/3018	0/3584	0/5534

۷- نتیجه‌گیری و پیشنهادات برای مطالعات آتی

در این مقاله با توجه به اینکه تخمین نقطه‌ی تغییر با محدود کردن بازه‌ی احتمالی زمان تغییر، منجر به کاهش هزینه‌های کشف علل ریشه‌ای تغییر، خواهد شد و همچنین با توجه به کاربرد وسیع پروفایل‌ها در عمل از رویکرد شبکه‌ی عصبی مصنوعی جهت تخمین نقطه‌ی تغییر پله‌ای در فاز ۲ پایش میانگین پروفایل‌های خطی چندگانه استفاده شده است. نتایج ارزیابی عملکرد شبکه‌ی عصبی پیشنهادی، حاکی از آن بود که شبکه‌ی پیشنهادی در تخمین نقطه‌ی تغییر، در مجموع با در نظر گرفتن معیار میانگین مربعات خطا، در تغییرات کوچک از روش MLE بهتر است اما در تغییرات

متوسط تا بزرگ روش MLE بهتر عمل می‌کند. به علاوه، با توجه به نتایج بدست آمده از شبیه‌سازی، ثابت شد که رویکرد شبکه‌ی پیشنهادی بر خلاف رویکرد MLE نیازی به هیچ گونه پیش آگاهی از نوع تغییر ندارد و به خوبی قادر به تخمین نقاط تغییر پله‌ای و تدریجی به صورت هم‌زمان نیز هست. از آنجایی که تمرکز این تحقیق بر رویکرد مبتنی بر شبکه‌ی عصبی مصنوعی است، از جمله مهمترین پیشنهادات برای تحقیقات آینده می‌توان به تخمین انواع نقاط تغییر در ماتریس واریانس-کوواریانس پروفایل‌های چندمتغیره و تخمین انواع نقاط تغییر در فاز ۱ پایش میانگین پروفایل‌های خطی چندگانه‌ی چندمتغیره با استفاده از رویکرد شبکه‌ی عصبی مصنوعی اشاره کرد.

rate parameter with a linear trend disturbance. *Quality and Reliability Engineering International*, 22(4), 371-384.

[11] Perry, M. B., Pignatiello Jr, J. J., & Simpson, J. R. (2007). Estimating the change point of the process fraction non-conforming with a monotonic change disturbance in SPC. *Quality and Reliability Engineering International*, 23(3), 327-339.

[12] Noorossana, R., & Shadman, A. (2009). Estimating the change point of a normal process mean with a monotonic change. *Quality and Reliability Engineering International*, 25(1), 79-90.

[13] Movaffagh, A., & Amiri, A. (2013). Monotonic change point estimation in the mean vector of a multivariate normal process, *The International Journal of Advanced Manufacturing Technology*, 69(5-8), 1895-1906.

[14] Niaki, S. T. A., & Khedmati, M. (2014). Monotonic change-point estimation of multivariate Poisson processes using a multi-attribute control chart and MLE. *International Journal of Production Research*, 52(10), 2954-2982.

[15] Ghazanfari, M., Alaeddini, A., Niaki, S.T.A., & Aryanezhad, M.B. (2008). A clustering approach to identify the time of a step change in shewhart control charts. *Quality and Reliability Engineering International*, 24(7), 765-778.

[16] Alaeddini, A., Ghazanfari, M., & Nayeri, M. A. (2009). A hybrid fuzzy-statistical clustering approach for estimating the time of changes in fixed and variable sampling control charts. *Information Sciences*, 179(11), 1769-1784.

[17] Amiri, A., Maleki, M. R., & Sogandi, F. (2018). Estimating the time of a step change in the multivariate-attribute process mean using ANN and MLE. *IJDATS*, 10(1), 81-98.

[18] Atashgar, K., & Noorossana, R. (2011). An integrating approach to root cause analysis of a bivariate mean vector with a linear trend disturbance. *The International Journal of Advanced Manufacturing Technology*, 52(1-4), 407-420.

[19] Noorossana, R., Atashgar, K., & Saghaei, A. (2011). An integrated supervised learning solution for monitoring process mean vector. *The International Journal of Advanced Manufacturing Technology*, 56(5-8), 755-765.

[20] Atashgar, K., & Noorossana, R. (2012). Diagnosing the source (s) of a monotonic change in

مراجع

[1] Page, E.S. (1954). Continuous inspection schemes. *Biometrika*, 41(1-2), 100-115.

[2] Nishina, K. (1992). A comparison of control charts from the viewpoint of change point estimation. *Quality and Reliability Engineering International*, 8(6), 537-541.

[3] Samuel, T. R., Pignatiello Jr, J. J., & Calvin, J. A. (1998a). Identifying the time of a step change with X control charts. *Quality Engineering*, 10(3), 521-527.

[4] Samuel, T. R., Pignatiello Jr, J. J., & Calvin, J. A. (1998b). Identifying the time of a step change in a normal process variance. *Quality Engineering*, 10(3), 529-538.

[5] Pignatiello Jr, J. J., & Samuel, T. R. (2001). Estimation of the change point of a normal process mean in SPC applications. *Journal of Quality Technology*, 33(1), 82-95.

[6] Noorossana, R., Saghaei, A., Paynabar, K., & Abdi, S. (2009). Identifying the period of a step change in High yield processes. *Quality and Reliability Engineering International*, 25(7), 875-883.

[7] Sheikhrabori, R., Aminnayeri, M., & Ayoubi, M. (2018). Maximum likelihood estimation of change point from stationary to nonstationary in autoregressive models using dynamic linear model. *Quality and Reliability Engineering International*, 34(1), 27-36.

[8] Sheikhrabori, R., Aminnayeri, M., & Ayoubi, M. (2019). Change Point Estimation of the Stationary State in Auto Regressive Moving Average (ARMA) Models, using Maximum Likelihood Estimation and singular value decomposition based Filtering. *International Journal of Engineering- Transactions B*, 32 (5), 726-736.

[9] Perry, M. B., & Pignatiello Jr, J. J. (2006). Estimation of the change point of a normal process mean with a linear trend disturbance in SPC. *Quality Technology and Quantitative Management*, 3(3), 325-334.

[10] Perry, M. B., Pignatiello Jr, J. J., & Simpson J. R. (2006). Estimating the change point of a poisson

- [32] Mahmood, T., Riaz, M., Omar, M. H., & Xie, M. (2018). Alternative methods for the simultaneous monitoring of simple linear profile parameters. *The International Journal of Advanced Manufacturing Technology*, 97(5-8), 2851-2871.
- [33] Abbasi, S. A., Abbas, T., Riaz, M., & Gomaa, A. S. (2018). Bayesian Monitoring of Linear Profiles Using DEWMA Control Structures with Random X. *IEEE Access*, 6, 78370-78385.
- [34] Noorossana, R., Eyvazian, M., & Vaghefi, A. (2010). Phase II monitoring of multivariate simple linear profiles. *Computers & Industrial Engineering*, 58(4), 563-570.
- [35] Amiri, A., Sogandi, F., & Ayoubi, M. (2018). Simultaneous monitoring of correlated multivariate linear and GLM regression profiles in Phase II. *Quality Technology & Quantitative Management*, 15(4), 435-458.
- [36] Kordestani, M., Hassanvand, F., Samimi, Y., & Shahriari, H. (2019). Monitoring multivariate simple linear profiles using robust estimators. Published online in *Communications in Statistics-Theory and Methods*, <https://doi.org/10.1080/03610926.2019.1584314>.
- [37] Rahimi, S. B., Amiri, A., & Ghashghaei, R. (2019). Simultaneous monitoring of mean vector and covariance matrix of multivariate simple linear profiles in the presence of within profile autocorrelation. Published online in *Communications in Statistics-Simulation and Computation*, <https://doi.org/10.1080/03610918.2019.1588314>.
- [38] Bahrami, H., Niaki, S. T. A., & Khedmati, M. (2019). Monitoring multivariate profiles in multistage processes. Published online in *Communications in Statistics-Simulation and Computation*, <https://doi.org/10.1080/03610918.2019.1626882>.
- [39] Mahmoud, M. A. (2008). Phase I analysis of multiple linear regression profiles. *Communications in Statistics-Simulation and Computation*, 37(10), 2106-2130.
- [40] Zou, C., Tsung, F., & Wang, Z. (2007). Monitoring general linear profiles using multivariate exponentially weighted moving average schemes. *Technometrics*, 49(4), 395-408.
- [41] Amiri, A., Eyvazian, M., Zou, C., & Noorossana, R. (2012). A parameters reduction method for monitoring multiple linear regression profiles. *The International Journal of Advanced Manufacturing Technology*, 58(5-8), 621-629.
- the process mean vector. *The International Journal of Advanced Manufacturing Technology*, 60(9-12), 1175-1183.
- [21] Amiri, A., Niaki, S. T. A., & Moghadam, A. T. (2015). A probabilistic artificial neural network-based procedure for variance change point estimation. *Soft Computing*, 19(3), 691-700.
- [22] Ahmadzadeh, F. (2018). Change point detection with multivariate control charts by artificial neural network. *The International Journal of Advanced Manufacturing Technology*, 97(9-12), 3179-3190.
- [23] Amiri, A., & Allahyari, S. (2012). Change point estimation methods for control chart postsignal diagnostics: a literature review. *Quality and Reliability Engineering International*, 28(7), 673-685.
- [24] Kang, L., Albin, S. L. (2000). On-line monitoring when the process yields a linear profile. *Journal of Quality Technology*, 32(4), 418-426.
- [25] Mahmoud, M. A., & Woodall, W. H. (2004). Phase I analysis of linear profiles with calibration applications. *Technometrics*, 46(4), 380-391.
- [26] Mahmoud, M. A., Parker, P. A., Woodall, W. H., & Hawkins, D. M. (2007). A change point method for linear profile data. *Quality and Reliability Engineering International*, 23(2), 247-268.
- [27] Yeh, A., & Zerehsaz, Y. (2013). Phase I Control of Simple Linear Profiles with Individual Observations. *Quality and Reliability Engineering International*, 29(6), 829-840.
- [28] Kim, K., Mahmoud, M. A., & Woodall, W. H. (2003). On the monitoring of linear profiles. *Journal of Quality Technology*, 35(3), 317-328.
- [29] Gupta, S., Montgomery, D. C., & Woodall, W. H. (2006). Performance evaluation of two methods for online monitoring of linear calibration profiles. *International journal of production research*, 44(10), 1927-1942.
- [30] Hosseinfard, S.Z., Abdollahian, M., Zeephongsekul, P. (2011). Application of artificial neural networks in linear profile monitoring. *Expert Systems with Applications*, 38(5), 4920-4928.
- [31] Zhang, J., Li, Z., & Wang, Z. (2009). Control chart based on likelihood ratio for monitoring linear profiles. *Computational Statistics and Data Analysis*, 53(4), 1440-1448.

- [48] Wang, Y. H. T., & Huang, W. H. (2017). Phase II monitoring and diagnosis of autocorrelated simple linear profiles. *Computers & Industrial Engineering*, 112, 57-70.
- [49] Nie, B., & Du, M. (2017). Identifying change-point in polynomial profiles based on data-segmentation. *Communications in Statistics-Simulation and Computation*, 46(4), 2513-2528.
- [50] Steward, R. M., & Rigdon, S. E. (2017). Risk-adjusted Monitoring of Healthcare Quality: Model Selection and Change-point Estimation. *Quality and Reliability Engineering International*, 33(5), 979-992.
- [51] Sogandi, F., & Amiri, A. (2017). Monotonic change point estimation of generalized linear model-based regression profiles. *Communications in Statistics-Simulation and Computation*, 46(3), 2207-2227.
- [52] Maleki, M. R., Amiri, A., Taheriyoun, A. R., & Castagliola, P. (2018). Phase I monitoring and change point estimation of autocorrelated poisson regression profiles. *Communications in Statistics-Theory and Methods*, 47(24), 5885-5903.
- [53] Moghadam, G., Ardali, G. A. R., & Amirzadeh, V. (2018). A novel phase I fuzzy profile monitoring approach based on fuzzy change point analysis. *Applied Soft Computing*, 71, 488-504.
- [42] Mahmoud, M. A., Saad, A. E. N., & El Shaer, R. (2015). Phase II multiple linear regression profile with small sample sizes. *Quality and Reliability Engineering International*, 31(5), 851-861.
- [43] Eyvazian, M., Noorossana, R., Saghaei, A., & Amiri, A. (2011). Phase II monitoring of multivariate multiple linear regression profiles. *Quality and Reliability Engineering International*, 27(3), 281-296.
- [44] Ayoubi, M., Kazemzadeh, R. B., & Noorossana, R. (2014). Estimating multivariate linear profiles change point with a monotonic change in the mean of response variables. *The International Journal of Advanced Manufacturing Technology*, 75(9-12), 1537-1556.
- [45] Kazemzadeh, R. B., Noorossana, R., & Ayoubi, M. (2015). Change point estimation of multivariate linear profiles under linear drift. *Communications in Statistics-Simulation and Computation*, 44(6), 1570-1599.
- [46] Ayoubi, M., Kazemzadeh, R. B., & Noorossana, R. (2016). Change point estimation in the mean of multivariate linear profiles with no change type assumption via dynamic linear model. *Quality and Reliability Engineering International*, 32(2), 403-433.
- [47] Huwang, L., Wang, Y. H. T., Yeh, A. B., & Huang, Y. H. (2016). Phase II profile monitoring based on proportional odds models. *Computers & Industrial Engineering*, 98, 543-553.

پیوست

- ¹ Double Exponentially Weighted Moving Average (DEWMA)
- ² Robust
- ³ Probabilistic Neural Network (PNN)
- ⁴ Multilayer Feed-Forward Network
- ⁵ Back Perceptron Network (BPN)
- ⁶ Learning function
- ⁷ Competitive transfer function
- ⁸ Radial Basis
- ⁹ Euclidean distance weight function
- ¹⁰ Dot product weight function
- ¹¹ False alarm
- ¹² Spread
- ¹³ Accuracy
- ¹⁴ Precision