

تخمین نقطه تغییر در ماتریس کواریانس فرآیند نرمال چند متغیره با استفاده از شبکه عصبی

امیرحسین امیری

(نویسنده مسئول) دانشیار گروه مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه شاهد، تهران،

محمد رضا ملکی

دانشجوی دکتری مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه شاهد، تهران،

محمد حسین کلانی

کارشناس ارشد مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه شاهد، تهران،

چکیده در اکثر مواقع، هشدار که از یک نمودار کنترل دریافت می‌شود نشان‌دهنده زمان واقعی تغییر در فرآیند نیست که علت آن وجود تأخیر بین زمان واقعی تغییر و زمان دریافت هشدار از نمودار کنترل است. در نتیجه نیاز است که زمان واقعی تغییر که از آن به عنوان "نقطه تغییر" یاد می‌شود، بررسی شود. با بررسی ادبیات موضوع شناسایی زمان واقعی تغییر در فرآیند می‌توان نتیجه گرفت که اکثر تحقیقات انجام شده در این حوزه بر فرآیندهای تک متغیره متمرکز بوده و تحقیقات اندکی به فرآیندهای چند متغیره اختصاص یافته است. علاوه بر این، بیش‌تر تحقیقات انجام شده در حوزه تخمین زمان تغییر در فرآیندهای چند متغیره معطوف به تغییرات در بردار میانگین فرآیند بوده و تنها یک تحقیق در خصوص ماتریس کواریانس انجام شده است. در این مقاله مدلی مبتنی بر شبکه عصبی مصنوعی برای تخمین نقطه تغییر در ماتریس کواریانس فرآیندهای نرمال چند متغیره پیشنهاد شده است. روش ارائه شده در فاز ۲ نمودارهای کنترل می‌باشد و نوع تغییر رخ داده در واریانس مشخصه‌های کیفی از نوع تغییرات تک پله‌ای فرض شده است. روش ارائه شده در این مقاله تنها تغییرات ماتریس کواریانس را که حاصل تغییر در واریانس هر یک از مشخصه‌های کیفی است در نظر می‌گیرد. عملکرد روش پیشنهادی در تخمین نقطه تغییر براساس دو معیار توزیع تجربی برآوردها و هم‌چنین میانگین و انحراف استاندارد تخمین‌زننده نقطه تغییر به ازای شیفت‌های تک پله‌ای مختلف در واریانس متغیرهای فرآیند در قالب مطالعه شبیه‌سازی ارزیابی شده است. در نهایت به منظور توضیح بیشتر روش ارائه شده یک مثال عددی ارائه شده است. نتایج حاصل نشان‌دهنده عملکرد مناسب روش پیشنهادی در تخمین نقطه تغییر در ماتریس کواریانس فرآیندهای نرمال چند متغیره است.

کلمات کلیدی کنترل فرآیند آماری، نقطه تغییر، فرآیند نرمال چند متغیره، تغییرات تک پله‌ای، ماتریس کواریانس، شبکه عصبی

۱- مقدمه

توسعه یافته‌اند. به منظور کسب اطلاعات بیش‌تر در خصوص نمودارهای کنترل چند متغیره به مقاله مروری برسیمیس و همکاران [۱] مراجعه شود. همچنین به منظور کسب اطلاعات بیش‌تر در خصوص کاربرد شبکه‌های عصبی مصنوعی در کنترل فرآیند آماری و پایش فرآیندهای چند متغیره به ترتیب به مقالات مروری ساراکیس [۲] و آتشگر [۳] مراجعه شود. در فرآیندهای چند متغیره معمولاً هشدار که از نمودار کنترل دریافت می‌شود نشان‌دهنده زمان واقعی تغییر در فرآیند نیست و علت آن وجود تأخیر بین زمان واقعی تغییر تا دریافت هشدار

در بسیاری از کاربردهای تولیدی، کیفیت محصول به وسیله چندین متغیر همبسته بیان می‌شود. به این گونه فرآیندها فرآیندهای چند متغیره گفته می‌شود. در فرآیندهای چند متغیره با توجه به همبستگی بین متغیرها و به منظور جلوگیری از رخ دادن خطا، باید تمامی متغیرها به منظور تعیین وضعیت تحت کنترل یا خارج از کنترل به صورت همزمان پایش شوند. برای این منظور نمودارهای کنترل چندمتغیره و همچنین روش‌های مبتنی بر شبکه عصبی مصنوعی توسط محققین

* (Corresponding author) amiri@shahed.ac.i

تغییر پله‌ای ساده را در بردار میانگین یک فرآیند پواسان چند متغیره برآورد نموده‌اند. ایشان ابتدا با استفاده از اعمال دو تبدیل بر روی داده‌ها، چولگی ذاتی و همبستگی داده‌های جمع‌آوری شده از فرآیند پواسان چند متغیره را از بین برده و آن‌ها را به داده‌های نرمال چند متغیره تبدیل کردند. بدین ترتیب ابتدا با استفاده از تبدیل ریشه‌ای که در نیاکی و عباسی [۱۰] مورد بررسی قرار گرفته است چولگی و سپس با استفاده از تبدیل ارائه شده توسط گلنبی و هوشمند [۱۱] همبستگی بین داده‌ها را از بین می‌برند، سپس با استفاده از برآورد کننده حداکثر درست‌نمایی نقطه تغییر پله‌ای بردار میانگین را تخمین می‌زنند. همچنین از آنجایی که با تغییر بردار میانگین فرآیند پواسان، ماتریس کواریانس نیز تغییر می‌کند، در طی محاسبات مربوط به تابع حداکثر درست‌نمایی، به ازای هر نقطه کاندیدای نقطه تغییر، ماتریس کواریانس تخمین زده می‌شود. الهیاری و امیری [۱۲] با استفاده از رویکرد خوشه‌بندی به تخمین نقطه تغییر در یک فرآیند چند متغیره با وجود شیفت‌های پله‌ای پرداختند. نیاکی و خدمتی [۱۳] روشی را جهت برآورد نقطه تغییر بردار میانگین فرآیند پواسان چند متغیره در حالتی که نوع تغییر روند خطی باشد ارائه نمودند و سپس عملکرد برآوردکننده روند خطی را با برآوردکننده نقطه تغییر پله‌ای مقایسه نمودند. موفق و امیری [۱۴] با استفاده از روش MLE به تخمین نقطه تغییر در بردار میانگین فرآیندهای نرمال چند متغیره با در نظر گرفتن شیفت مونوتونیک پرداختند. دوگو و کواکوکچ [۱۵] با استفاده از تخمین زنده حداکثر درست‌نمایی، نقطه تغییر پله‌ای منفرد را در ماتریس کواریانس فرآیند نرمال چند متغیره که در آن از نمودار کنترل چند متغیره $|S|$ برای دریافت هشدار خارج از کنترل استفاده می‌شود، برآورد کردند. دوگو و کواکوکچ [۱۶] نقطه تغییر پله‌ای ساده که به صورت همزمان در بردار میانگین و ماتریس کواریانس فرآیند نرمال چند متغیره اتفاق می‌افتد را با استفاده از تخمین زنده حداکثر درست‌نمایی برآورد نمودند. بدین صورت که پس از دریافت هشدار خارج از کنترل از نمودار کنترل ترکیبی همزمان T^2 هتلینگ و نمودار کنترل پراکندگی تعمیم یافته، رویه برآورد نقطه تغییر آغاز می‌شود.

یکی دیگر از روش‌های تخمین نقطه تغییر، روش شبکه‌های عصبی مصنوعی است. اخیراً استفاده از شبکه‌های عصبی مصنوعی در شناسایی نقطه تغییر با توجه به عملکرد مناسب این آنها مورد توجه قرار گرفته است که تمامی آن‌ها تغییرات در بردار میانگین در فرآیندهای نرمال چند متغیره را مدنظر قرار داده‌اند. لازم به ذکر است چنگ و چنگ [۱۷]، چنگ و چنگ [۱۸] و همچنین امیری و همکاران [۱۹] پیش تغییرات در

از نمودار کنترل است. در نتیجه نیاز است که زمان واقعی تغییر که از آن به عنوان "نقطه تغییر" یاد می‌شود، تعیین شود. تخمین نقطه واقعی تغییر در فرآیند سبب کاهش زمان و هزینه لازم برای یافتن علل انحراف در فرآیند می‌شود. تحقیقات صورت گرفته در زمینه تخمین نقطه تغییر در فرآیندهای چند متغیره با استفاده از روش‌های آماری در ذیل مورد اشاره قرار می‌گیرند: سالیوان و وودال [۴] یک نمودار کنترل را بر اساس آماره آزمون نسبت درست‌نمایی (LRT) ارائه کردند که علاوه بر پایش فرآیند و شناسایی حالات خارج از کنترل، توانایی تخمین نقطه تغییر را نیز دارد. زامبا و هاکینز [۵] از روش تعمیم آزمون نسبت درست‌نمایی (GLRT) و تکنیک تخمین‌های پی در پی برای ارائه چهارچوب جدیدی جهت پایش فرآیند چند متغیره و تخمین زمان واقعی تغییر پله‌ای در حالت نامعلوم بودن پارامترها استفاده کردند. ایشان فرض کردند که پارامترهای فرآیند نامعلوم هستند و تنها تغییر پله‌ای در بردار میانگین رخ می‌دهد و ماتریس کواریانس بدون تغییر باقی می‌ماند. در این روش به صورت پویا پس از ثبت هر مشاهده جدید و محاسبه آماره مربع تی (T^2) اختلافات استاندارد شده میان مشاهدات قبل و بعد از تغییر و مقایسه آن با حدود کنترل، متغیر وضعیت خارج از کنترل کشف و سپس با به کارگیری تخمین زنده ماکزیمم درست‌نمایی (MLE) بر روی این آماره، نقطه تغییر برآورد می‌شود. لی و همکاران [۶] از یک یادگیرنده تحت نظارت برای کشف نقطه تغییر و شناسایی متغیرهایی که دچار تغییر در میانگین شده‌اند، استفاده کردند. در این روش تنها تغییر در بردار میانگین مد نظر قرار گرفته است و هیچ فرضی در مورد نوع توزیع داده‌ها وجود ندارد و مسأله نقاط تغییر چندگانه نیز مورد توجه قرار گرفته است. آن‌ها از درخت تصمیم به عنوان یادگیرنده تحت نظارت استفاده نمودند.

زرنندی و علاالدینی [۷] با استفاده از روش خوش‌بندی فازی به برآورد نقطه تغییر در انواع مختلف نمودارهای کنترل (تک متغیره، تک مشخصه وصفی و چند متغیره) و با اندازه نمونه‌های ثابت و متغیر پرداختند. ایشان عملکرد روش پیشنهادی خود را در برآورد نقطه تغییر واریانس توزیع نرمال در نمودار کنترل S و همچنین در برآورد نقطه تغییر بردار میانگین یک فرآیند نرمال چند متغیره در نمودار کنترل T^2 مورد ارزیابی قرار دادند. ندوماران و همکاران [۸] تخمین زنده MLE را برای تخمین نقطه تغییر پله‌ای در میانگین یک فرآیند نرمال چند متغیره با فرض معلوم بودن پارامترهای حالت تحت کنترل ارائه نمودند. ایشان برای کشف حالت خارج از کنترل از نمودار کنترل چند متغیره مربع کای استفاده نمودند. نیاکی و خدمتی [۹] نقطه

رویکرد یکپارچه براساس یادگیری تحت نظارت متشکل از چندین شبکه عصبی، برای کشف نقطه تغییر با تغییر پله‌ای منفرد در بردار میانگین یک فرآیند نرمال دو متغیره استفاده کردند. روش پیشنهادی ایشان توانایی مواردی چون کشف شرایط خارج از کنترل، تخمین نقطه تغییر در متغیر عامل انحراف، تعیین متغیر یا متغیرهایی که در ایجاد تغییر سهمیه بوده‌اند و همچنین شناسایی جهت تغییر در بردار میانگین متغیرها را دارا می‌باشد. نورالسنا و آتشگر [۲۴] در ادامه مدلی جامع مشتمل بر مجموعه‌ای از شبکه‌های عصبی ارائه دادند که می‌تواند علاوه بر تخمین نقطه تغییر، متغیرهای عامل انحراف در بردار میانگین فرآیند را نیز شناسایی کند. این مدل با فرض یکنوا بودن نوع تغییرات، اعم از کاهشی یا افزایشی در هر یک از متغیرها، توانایی دارد علاوه بر تشخیص متغیری که موجب خارج از کنترل شدن فرآیند شده است، نقطه تغییر را برای انواع تغییرات بردار میانگین فرآیند نرمال دو متغیره شناسایی کند. امیری و همکاران [۲۵] دو روش MLE و شبکه عصبی مصنوعی را برای تخمین نقطه تغییر در فرآیندهایی با مشخصه‌های کیفی همبسته آمیخته (شامل متغیر و وصفی) توسعه دادند و به مقایسه نتایج حاصل پرداختند. جهت اطلاعات بیشتر در خصوص روش‌های تخمین نقطه تغییر به مقاله‌های مروری امیری و الهیاری [۲۶] و آتشگر [۲۷] مراجعه شود. علی-رغم این که پیش ماتریس کواریانس در فرآیندهای چند متغیره از اهمیت بسزایی برخوردار است، با این حال توجه کمتری به تخمین نقطه تغییر در آن شده است. در حالی که ممکن است در یک فرآیند چند متغیره علیرغم تحت کنترل بودن بردار میانگین، ماتریس کواریانس مشخصه‌های کیفی به دلیل ایجاد انحراف در واریانس یک یا بیش از یک مشخصه کیفی دچار تغییر شود. در چنین شرایطی کشف زمان واقعی که انحراف در ماتریس کواریانس آغاز شده است، سبب می‌شود که عوامل ایجاد انحراف سریع‌تر شناسایی شده و فرآیند زودتر به شرایط تحت کنترل بازگردد. تنها تحقیق انجام شده در تخمین نقطه تغییر در ماتریس کواریانس فرآیندهای چند متغیره در فاز ۲ نمودارهای کنترل، مربوط به سال ۲۰۱۱ می‌باشد. دوگو و کواکوج در مقاله فوق از روش برآورد کننده حداکثر درستی، زمانی که هشدار خارج از کنترل از نمودار کنترل |S| دریافت می‌شود، استفاده نموده‌اند.

با توجه به مرور ادبیات انجام شده و ضرورت شناسایی زمان واقعی ایجاد انحراف در تغییرپذیری فرآیند و همچنین توانایی شبکه‌های عصبی مصنوعی در حوزه کنترل فرآیند آماری و به طور خاص تخمین نقطه تغییر، در این مقاله هدف ارائه روشی

ماتریس کواریانس فرآیندهای چندمتغیره را با استفاده از رویکرد شبکه عصبی بررسی کرده‌اند. لیکن تخمین نقطه تغییر در ماتریس کواریانس فرآیندهای چندمتغیره با استفاده از شبکه عصبی مورد غفلت واقع شده است.

نتایج حاصل از کاربرد شبکه‌های عصبی در تخمین نقطه تغییر در فرآیندهای چند متغیره حاکی از عملکرد مناسب روش‌های پیشنهادی در مقایسه با روش‌های مرسوم تخمین نقطه تغییر مانند روش برآورد کننده حداکثر درستی است. از جمله تحقیقات اندکی که در زمینه استفاده از شبکه عصبی مصنوعی در تخمین نقطه تغییر در فرآیندهای چند متغیره صورت گرفته است می‌توان به مقالات زیر اشاره نمود: احمدزاده [۲۰] اولین بار استفاده از شبکه‌های عصبی مصنوعی را برای تخمین نقطه تغییر پله‌ای در بردار میانگین یک فرآیند نرمال چند متغیره پیشنهاد نمود که در آن هشدار خارج از کنترل بودن توسط یک نمودار کنترل چند متغیره میانگین متحرک موزون نمایی (MEWMA) دریافت می‌شود. شبکه پیشنهادی احمدزاده یک شبکه عصبی سه لایه است که با الگوریتم یادگیری پس انتشار خطا آموزش می‌بیند. تعداد نرون‌های لایه ورودی و خروجی برابر با n می‌باشد که n تعداد نمونه‌گیری‌ها تا دریافت هشدار خارج از کنترل توسط نمودار کنترل MEWMA است. احمدزاده و همکاران [۲۱] به بررسی نقطه تغییر پله‌ای در بردار میانگین یک فرآیند نرمال چند متغیره با استفاده از شبکه‌های عصبی پرداختند. ایشان از یک نمودار کنترل MEWMA توسعه یافته بر مبنای شبکه‌های عصبی استفاده کردند که علاوه بر تخمین نقطه تغییر پله‌ای در بردار میانگین، متغیرهای عامل انحراف را نیز شناسایی می‌نمود. در تحقیق فوق فرض شده است که مشخصه‌های کیفی فرآیند از یک توزیع نرمال چهار متغیره با بردار میانگین و ماتریس کواریانس معلوم تبعیت می‌کنند. همچنین تنها یک تغییر پله‌ای در بردار میانگین رخ می‌دهد و تا کشف حالت خارج از کنترل و انجام اقدام اصلاحی میانگین فرآیند در همان سطح باقی می‌ماند. آتشگر و نورالسنا [۲۲] یک رویکرد یادگیری تحت نظارت مبتنی بر شبکه‌های عصبی را برای کشف نقطه تغییر با روند خطی در بردار میانگین یک فرآیند نرمال دو متغیره پیشنهاد نمودند که علاوه بر تخمین نقطه تغییر قادر به کشف متغیر عامل انحراف نیز بود. روش پیشنهادی ایشان متشکل از سه شبکه عصبی می‌باشد که این شبکه‌ها قادرند مواردی همچون کشف شرایط خارج از کنترل، تعیین متغیر یا متغیرهایی که سبب ایجاد تغییر بوده‌اند و همچنین تخمین نقطه تغییر با روند خطی در بردار میانگین فرآیند را تشخیص دهند. نورالسنا و همکاران [۲۳] از یک

برای شناسایی متغیر (متغیرهای) عامل انحراف بعد از وقوع خطا از روش مبتنی بر شبکه عصبی ارائه شده توسط امیری و همکاران [۱۹] استفاده می‌گردد. در قدم نهایی نیز بر اساس متغیر یا متغیرهایی که باعث بروز هشدار خارج از کنترل شده‌اند، یک شبکه عصبی برای شناسایی زمان تغییر در واریانس آن متغیرها طراحی می‌شود.

فرض کنید که در یک فرآیند چند متغیره کیفیت محصول به وسیله p متغیر نرمال همبسته بازنمایی می‌شود. بنابراین تعداد حالت‌های خارج از کنترل در فرآیند مورد نظر برابر $2^p = \sum_{i=1}^p \binom{p}{i}$ خواهد بود. در روش پیشنهادی به تعداد تمامی حالت‌های خارج از کنترل در فرآیند، شبکه عصبی مصنوعی برای تخمین نقطه تغییر در ماتریس کوواریانس طراحی می‌گردد. سپس بسته به این که کدام یک از متغیرها عامل ایجاد انحراف در ماتریس کوواریانس فرآیند باشند (کدام حالت خارج از کنترل رخ داده است)، تنها یکی از شبکه‌های عصبی طراحی شده فعال خواهد شد و نقطه تغییر در حالت خارج از کنترل مورد نظر توسط آن برآورد می‌شود. شایان ذکر است که در روش پیشنهادی فقط تغییرات مثبت در واریانس هر یک از مشخصه‌های کیفی فرآیند مورد توجه قرار گرفته است، زیرا شیفت کاهشی در واریانس مشخصه‌های کیفی معمولاً به معنای بهبود در فرآیند است و لذا از بررسی شیفت‌های کاهشی در این مقاله چشم‌پوشی شده است. به عنوان مثال در فرآیندی با سه متغیر شامل x_1 ، x_2 و x_3 مجموعاً هفت حالت خارج از کنترل وجود دارد (تغییر در واریانس یک متغیر در سه حالت، تغییر در واریانس دو متغیر در سه حالت و نهایتاً تغییر در واریانس هر سه متغیر در یک حالت). در نتیجه متناظر با هر یک از حالات خارج از کنترل به منظور تخمین نقطه تغییر در واریانس توزیع‌های حاشیه‌ای مشخصه‌های کیفی فرآیند، هفت شبکه عصبی مصنوعی (شبکه‌های ۱ الی ۷) استفاده خواهد شد. حال اگر تنها یک متغیر عامل انحراف تشخیص داده شود، یکی از شبکه‌های عصبی ۱ تا ۳ جهت تخمین نقطه تغییر فعال خواهد شد. همچنین اگر دو متغیر عامل انحراف شناخته شوند، یکی از شبکه‌های عصبی ۴ تا ۶ فعال خواهد شد و در نهایت اگر هر سه متغیر عامل انحراف باشند، شبکه ۷ فعال می‌شود.

۲-۱ انتخاب نوع شبکه

یکی از مسائل مهم در طراحی شبکه‌های عصبی، انتخاب نوع شبکه است. انتخاب یک معماری مناسب برای شبکه عصبی، کار آسانی نیست. چون معماری‌های گوناگونی در عمل، بسته به نوع

مبتنی بر شبکه‌های عصبی مصنوعی برای تخمین نقطه تغییر در ماتریس کوواریانس فرآیندهای نرمال چند متغیره می‌باشد. تغییر در عناصر ماتریس کوواریانس فرآیند چند متغیره می‌تواند به دلیل تغییر در واریانس یک یا چند متغیر و یا تغییر در ضریب همبستگی بین دو یا بیش از دو متغیر رخ دهد که در این مقاله تغییر از نوع اول (تغییر در واریانس مشخصه‌های کیفی) در نظر گرفته شده است. همچنین از بین انواع تغییر شامل تغییر تک پله‌ای، تغییر تدریجی، تغییر مونوتونیک و تغییر پله‌ای چندگانه در این مقاله تنها تغییر تک پله‌ای در نظر گرفته شده است. شایان ذکر است که روش ارائه شده در فاز ۲ نمودارهای کنترل می‌باشد که در آن پارامترهای فرآیند اعم از بردار میانگین و ماتریس کوواریانس براساس تجزیه و تحلیل از فاز ۱ معلوم فرض می‌شود. ساختار این مقاله بدین صورت است که در بخش دوم مدل پیشنهادی جهت تخمین نقطه تغییر در ماتریس کوواریانس فرآیندهای چند متغیره بیان می‌شود. در این بخش ابتدا مواردی شامل انتخاب نوع، ساختار، نحوه آموزش شبکه عصبی و همچنین شبه کد تولید داده‌های آموزشی مورد نیاز هر یک از شبکه‌های عصبی تشریح می‌گردد. سپس الگوریتم تخمین نقطه تغییر در ماتریس کوواریانس فرآیند به وسیله مدل پیشنهادی بیان می‌گردد. در بخش سوم نیز عملکرد مدل پیشنهادی مبتنی بر شبکه عصبی در تخمین زمان واقعی تغییر در ماتریس کوواریانس فرآیندهای چند متغیره به وسیله مطالعه شبیه‌سازی مورد بررسی قرار می‌گیرد. در بخش چهارم نیز یک مثال عددی برای توضیح بیشتر روش پیشنهادی ارائه می‌گردد. در نهایت در بخش پنجم به نتیجه‌گیری و ارائه پیشنهاداتی برای مطالعات آتی پرداخته می‌شود.

۲-۲ مدل پیشنهادی جهت تخمین نقطه تغییر

در این بخش رویکرد پیشنهادی مبتنی بر شبکه عصبی مصنوعی برای برآورد زمان واقعی تغییر در ماتریس کوواریانس یک فرآیند نرمال چند متغیره تشریح می‌گردد. در روش پیشنهادی، در قدم اول ابتدا از نمودار کنترل MEWMS_{AS} که توسط معمار و نیاکی [۲۸] برای کشف تغییر در ماتریس کوواریانس فرآیندهای چند متغیره ارائه شده استفاده می‌گردد. پس از آن که یک هشدار خارج از کنترل، توسط نمودار کنترل MEWMS_{AS} دریافت گردید، در قدم دوم متغیر (متغیرهایی) که سبب بروز وضعیت خارج از کنترل شده‌اند، شناسایی می‌شوند. لازم به ذکر است که حدود کنترل نمودار کنترل MEWMS_{AS} با شبیه‌سازی به نحوی تنظیم می‌شوند که مقدار متوسط طول دنباله در حالت تحت کنترل (ARL_0) حدوداً برابر ۲۰۰ گردد.

برای به دست آوردن تعداد نرون‌های لایه ورودی (p) شبکه عصبی‌ای که برای تخمین نقطه تغییر متناظر با وضعیت خارج از کنترلی که در آن تنها یک متغیر عامل انحراف است به ترتیب زیر عمل می‌کنیم. اگر متغیر q ام عامل انحراف باشد (انحراف معیار آن δ_q برابر شده باشد)، در این صورت $\delta_q > 1$ و $\delta_k = 1$ ($k = 1, \dots, p$ & $k \neq q$) بار شبیه سازی، مقادیر طول دنباله نمودار کنترل MEWMS_{AS} را به ازای یک شیفت کوچک معین در انحراف استاندارد متغیر q ام در حالی که انحراف استاندارد بقیه متغیرها ثابت است، محاسبه نموده و آن‌ها را در یک بردار ذخیره می‌کنیم. حال تعداد نرون‌های لایه ورودی در شبکه عصبی مربوطه را برابر با ماکزیمم مقدار عناصر بردار فوق در نظر می‌گیریم. روند فوق را برای تک تک وضعیت‌های خارج از کنترلی که یک متغیر عامل انحراف است نیز انجام می‌دهیم. لازم به ذکر است از آنجا که نمودار کنترل MEWMA_{AS} نسبت به کشف حالت خارج از کنترل حتی به ازای شیفت‌های کوچک بسیار حساس است، تعداد نرون‌های لایه ورودی عدد بزرگی نخواهد بود. این مطلب در بخش ۳ به تفصیل توضیح داده خواهد شد. برای به دست آوردن تعداد نرون‌های لایه ورودی (p) شبکه عصبی‌ای که برای تخمین نقطه تغییر متناظر با وضعیت خارج از کنترلی که در آن دو متغیر عامل انحراف هستند به ترتیب زیر عمل می‌کنیم. اگر متغیرهای q ام و s ام عامل انحراف باشند (دچار شیفتی به اندازه δ_q و δ_s شده باشند)، در این صورت $\delta_q, \delta_s > 1$ و $\delta_k = 1$ ($k = 1, \dots, p$ & $k \neq q, s$) خواهد بود. حال با استفاده از ۱۰۰۰۰ بار شبیه سازی، مقادیر طول دنباله نمودار کنترل MEWMS_{AS} را به ازای یک شیفت معین کوچک در انحراف استاندارد متغیرهای q ام و s ام در حالی که انحراف استاندارد بقیه متغیرها ثابت است، محاسبه نموده و آن‌ها را در یک بردار ذخیره می‌کنیم. حال تعداد نرون‌های لایه ورودی در شبکه عصبی مربوطه را برابر با ماکزیمم مقدار عناصر بردار فوق در نظر می‌گیریم. روند فوق را برای تک تک وضعیت‌های خارج از کنترلی که دو متغیر عامل انحراف است نیز انجام می‌دهیم.

روند معرفی شده در قدم‌های ۱ و ۲ را به ترتیب برای حالت‌هایی که انحراف استاندارد سه متغیر، چهار متغیر الی p متغیر دچار تغییر شود، ادامه می‌دهیم. مثلاً در حالتی که تمامی متغیرها عامل انحراف باشند، آنگاه $\delta_1, \delta_2, \dots, \delta_p > 1$ خواهد بود. حال با استفاده از ۱۰۰۰۰ بار شبیه سازی، مقادیر طول دنباله نمودار کنترل MEWMS_{AS} را به ازای یک شیفت کوچک معین در انحراف استاندارد تمامی متغیرها محاسبه نموده و آن‌ها را در یک بردار ذخیره می‌کنیم. حال تعداد نرون‌های لایه ورودی در

مساله مورد بررسی، قابل استفاده است. شبکه‌های پیشخور چند لایه^۱ که از متداول‌ترین شبکه‌های عصبی هستند با استفاده از الگوریتم پس انتشار خطا^۲ برای حل مسائل پیچیده به کار گرفته می‌شوند. الگوریتم پس انتشار خطا برای استفاده در شبکه‌های چند لایه و توابع انتقال غیرخطی ایجاد شده است و این الگوریتم به عنوان عمومی‌ترین و متداول‌ترین الگوریتم در آموزش با ناظر در شبکه‌های عصبی پرسپترون چند لایه ظاهر شده است. مقالات مرتبط با تشخیص الگوی نمودارهای کنترل نیز دلالت بر موفقیت بکارگیری این الگوریتم دارد، به طوریکه شبکه پس انتشار^۳ در بیشتر مقالات مرتبط با کنترل فرآیند آماری استفاده شده است. از این رو تمامی شبکه‌های معرفی شده برای تخمین نقطه تغییر در ماتریس کواریانس فرآیند نرمال چند متغیره در این مقاله نیز از نوع شبکه‌های پرسپترون چند لایه با الگوریتم آموزشی پس انتشار خطا می‌باشند.

۲-۲ ساختار شبکه

در این بخش ساختار شبکه عصبی پیشنهادی از قبیل تعداد لایه‌های پنهان، تعداد نرون‌های موجود در هر لایه پنهان، تعداد نرون‌های لایه ورودی و تعداد نرون‌های لایه خروجی بیان می‌شوند. همچنین بردارهای ورودی و مقادیر متناسب با بردارهای ورودی و تابع محرک استفاده شده مورد بررسی قرار می‌گیرند. برای بدست آوردن تعداد نرون‌های لایه ورودی در هر یک از شبکه‌های عصبی در فرآیند نرمال چند متغیره از رویکرد شبیه‌سازی استفاده می‌کنیم. فرض کنید یک فرآیند نرمال p متغیره در حالت تحت کنترل دارای ماتریس کواریانس Σ_0 به صورت رابطه ۱ باشد.

$$\Sigma_0 = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{12} & \sigma_2^2 & \dots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1p} & \sigma_{2p} & \dots & \sigma_p^2 \end{bmatrix}, \quad (1)$$


که در آن عناصر قطری ماتریس که با σ_k^2 نشان داده می‌شوند، بیانگر واریانس متغیر k ام و عناصر غیر قطری نشان دهنده کواریانس بین متغیرها هستند. حال اگر در یک زمان نامشخص واریانس یکی یا بیش از یکی از متغیرها دچار تغییر شود، آن گاه ماتریس کواریانس فرآیند نیز از حالت تحت کنترل Σ_0 خارج می‌شود. با توجه به موارد ذکر شده برای تعیین تعداد نرون‌های ورودی در هر شبکه به ترتیب زیر عمل می‌کنیم:

همبستگی بین مشخصه‌های کیفی، ماتریس کواریانس مشاهدات را محاسبه می‌کنیم. سپس با محاسبه دترمینان ماتریس کواریانس مشاهدات قادر خواهیم بود که ورودی‌های شبکه عصبی را تولید کنیم. شایان است که تولید بردارهای ورودی شبکه‌های عصبی طراحی شده در این بخش براساس شبیه سازی و با استفاده از تابع گاوسی کاپولا^۴ که توسط چروبینی و همکاران [۲۱] ارائه شده است در نرم‌افزار متلب ۲۰۱۰ انجام شده است. موارد عنوان شده در شکل ۱ به طور شماتیک نشان داده شده است.

۲-۳ آموزش شبکه عصبی

فرآیندی دارای p متغیر همبسته است که باید وضعیت تحت کنترل یا خارج از کنترل بودن آن تعیین شود. فرض کنید $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_r, \mathbf{X}_{r+1}, \dots, \mathbf{X}_r$ ماتریس‌هایی مستقل از مشاهدات باشند که در آن \mathbf{X} از یک توزیع نرمال p متغیره پیروی می‌کند. تا زمان τ فرآیند تحت کنترل بوده و از توزیع نرمال $N_p(\boldsymbol{\mu}_0, \boldsymbol{\Sigma}_0)$ پیروی می‌کند. از زمان τ به بعد شیفتی در ماتریس کواریانس فرآیند رخ می‌دهد. در این صورت توزیع فرآیند به $N_p(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1)$ تغییر می‌کند که $\boldsymbol{\Sigma}_1$ ماتریس کواریانس فرآیند در حالت خارج از کنترل است. فرض می‌شود که تا کشف حالت خارج از کنترل و انجام اقدام اصلاحی، انحراف استاندارد متغیرهای خارج از کنترل در سطح جدید باقی بمانند. در نتیجه نمودار کنترل MEWMS_{AS} تغییر رخ داده در ماتریس تغییرپذیری را در زمان T کشف می‌کند. به منظور آموزش شبکه عصبی $1 - 2^j, j=1, \dots, 2^j$ متناظر با وضعیت خارج از کنترلی که در آن $i, i=1, \dots, p$ متغیر عامل هشدار هستند به ترتیب زیر عمل می‌کنیم:

شبکه عصبی مربوطه را برابر با ماکزیمم مقدار عناصر بردار فوق در نظر می‌گیریم. بعد از بدست آوردن تعداد نرون‌های لایه ورودی در هر شبکه، تعداد نرون‌های لایه خروجی هر شبکه را نیز برابر با تعداد نرون‌های لایه ورودی در نظر می‌گیریم. این بدان علت است که کل داده‌ها تا زمان هشدار به عنوان ورودی به صورت یکجا به شبکه داده می‌شود و روش طراحی شبکه در این مقاله به گونه‌ای است که بایستی متناسب با هر داده ورودی یک نرون در لایه خروجی در نظر گرفته شود و زمان اخذ نمونه متناظر با نرون خروجی با بیش‌ترین مقدار به عنوان نقطه تغییر در نظر گرفته شود. در ادبیات موضوع تصریح شده است که روش مشخصی برای تعیین تعداد لایه‌های پنهان وجود ندارد و تعداد این لایه‌ها با استفاده از سعی و خطا بدست می‌آید. ولی به طور کلی بسته به نوع مسأله، تعداد لایه‌های پنهان معمولاً از یک الی دو لایه تجاوز نمی‌کند. این امر در مورد تعداد نرون‌های موجود در هر لایه پنهان نیز صادق است. در مورد تعداد نرون‌های هر لایه پنهان باید توجه داشت که تعداد کم نرون‌ها منجر به عدم آموزش و کارایی شبکه و تعداد زیاد آن نیز باعث مختل شدن آموزش شبکه خواهد شد و تعداد این نرون‌ها نیز با سعی و خطا بدست می‌آید. بردار ورودی در هر یک از شبکه‌های عصبی پیشنهادی نیز عبارتست از یک بردار ستونی $m \times 1$ از دترمینان ماتریس کواریانس مشخصه‌های کیفی فرآیند در m زیر گروه آخر از مشاهدات است، که در آن m نشان دهنده تعداد نرون‌های لایه ورودی یا همان حداکثر طول دنباله (RL_{max}) در شبکه مربوطه می‌باشد. فرض کنید $\mathbf{X}_{ij} = (x_{ij1}, x_{ij2}, \dots, x_{ijp})$ برداری از مشاهدات باشد که در آن x_{ijk} نشان دهنده مقدار مشاهده شده برای متغیر k ام، $(k=1, 2, \dots, p)$ ، در مشاهده j ام، $(j=1, 2, \dots, n)$ ، از زیر گروه i ام است. برای هر یک از متغیرها در هر زیر گروه، به ازای تمامی مشاهدات، مقدار واریانس نمونه را حساب کرده و سپس با توجه به ضریب



شکل ۱: ساختار هر شبکه عصبی پیشنهادی

که شبکه عصبی آموزش داده شده نسبت به بزرگی شیفت رخ داده در واریانس متغیر اول، پایدار^۵ باشد. برای آموزش شبکه‌های عصبی متناظر با هر یک از وضعیت‌های خارج از کنترل ماتریس کواریانس فرآیند، باید به تعداد مناسب، داده آموزشی ایجاد گردد. بدین منظور مقدار متوسط دنباله را برای حالت‌های خارج از کنترل مذکور از ۱ تا m زیاد نموده و برای هر مقدار ۱۰۰ بردار ورودی به ترتیبی که بیان شد تولید می‌کنیم. در نتیجه برای هر شبکه عصبی به تعداد $100m$ بردار ستونی به صورت $\mathbf{S} = (|s_1|, \dots, |s_m|)^T$ ایجاد می‌شود. بعد از تولید بردارهای ورودی شبکه عصبی، باید مقادیر هدف خروجی‌های شبکه نیز متناسب با هر بردار ورودی تعیین گردد. با توجه به این که تعداد نرون‌های خروجی در شبکه عصبی پیشنهادی با تعداد نرون‌های لایه ورودی یکسان بوده و برابر با m است، لذا بردار هدف نیز یک بردار $m \times 1$ خواهد بود که عناصر آن صفر و یک خواهند بود. در بردار هدف مورد نظر، عنصر مربوط به اولین نمونه خارج از کنترل در فرآیند یک بوده و بقیه عناصر صفر می‌باشند. عنصر متناظر با مقدار ۱ در بردار هدف فوق نشان دهنده زمان $\tau + 1$ می‌باشد. با توضیحات فوق برای ایجاد بردار مقادیر هدف در نرون‌های خروجی به ترتیب زیر عمل می‌کنیم: زمانی که طول دنباله h باشد، با توجه به این که لایه ورودی h نمونه خارج از کنترل تولید شده و آماره مربوط به آن (دترمینان ماتریس کواریانس) به h نرون آخر لایه ورودی تخصیص یافته است و آماره‌های مربوط به نرون‌های ۱ تا $m-h$ از فرآیند تحت کنترل آمده‌اند، لذا مقدار هدف نرون $m-h+1$ ام برابر یک و مقدار هدف سایر خروجی‌های شبکه برابر صفر در نظر گرفته می‌شوند. مثلاً اگر شبکه عصبی طراحی شده ۵۰ نرون خروجی داشته باشد و مقدار طول دنباله حاصل از نمودار کنترل MEWMS_{AS} برابر ۱۰ باشد، در این صورت ۴۱ امین عنصر هدف را برابر ۱ و بقیه عناصر را برابر صفر در نظر می‌گیریم. در نهایت با استفاده از بردارهای ورودی و مقادیر هدف متناظر آن‌ها، شبکه عصبی را با استفاده از الگوریتم پس انتشار خطا آموزش می‌دهیم.

۲-۴ شبه کد تولید داده‌های آموزشی مورد نیاز شبکه‌های عصبی پیشنهادی

شبه کد زیر بیانگر نحوه تولید بردارهای ورودی و مقادیر هدف متناظر برای هر بردار، در مرحله آموزش شبکه‌های عصبی پیشنهادی، برای برآورد زمان واقعی تغییر در ماتریس کواریانس فرآیند است. شایان ذکر است که m نشان‌دهنده تعداد نرون‌های لایه ورودی شبکه عصبی طراحی شده است.

ابتدا طول دنباله را برابر با یک در نظر می‌گیریم. یعنی فرض می‌کنیم که نمودار کنترل MEWMS_{AS} حالت خارج از کنترل را بلافاصله بعد از این که اولین نمونه از فرآیند گرفته شود، تشخیص خواهد داد. برای تولید بردارهای ورودی شبکه، با استفاده از شبیه سازی، یک نمونه n تایی از متغیرهای فرآیند در حالت خارج از کنترل متناظر تولید می‌کنیم. سپس دترمینان ماتریس کواریانس نمونه مورد نظر را محاسبه و به عنوان ورودی آخرین نرون ورودی شبکه در نظر می‌گیریم. در مرحله بعد به تعداد $m-1$ نمونه n تایی از متغیرهای فرآیند، در حالتی که فرآیند تحت کنترل است، تولید می‌کنیم و دترمینان ماتریس کواریانس آن‌ها را به $m-1$ نرون اول شبکه وارد می‌کنیم. بدین ترتیب ورودی شبکه عبارت از بردار ستونی $\mathbf{S} = (|s_1|, \dots, |s_m|)^T$ است که $|s_i|$ دترمینان ماتریس کواریانس متناظر با نرون ورودی i ام است.

حال مقدار طول دنباله را برابر با دو در نظر می‌گیریم. یعنی فرض می‌کنیم که نمودار کنترل MEWMS_{AS} حالت خارج از کنترل را در دومین نمونه که از فرآیند گرفته شود، تشخیص خواهد داد. برای تولید بردارهای ورودی شبکه، با استفاده از شبیه سازی، دو نمونه n تایی از متغیرهای فرآیند در حالت خارج از کنترل متناظر تولید می‌کنیم. سپس دترمینان ماتریس کواریانس دو نمونه مورد نظر را محاسبه و به عنوان ورودی دو نرون آخر شبکه در نظر می‌گیریم. در مرحله بعد به تعداد $m-2$ نمونه n تایی از متغیرهای فرآیند، در حالتی که فرآیند تحت کنترل است، تولید می‌کنیم و دترمینان ماتریس کواریانس آن‌ها را به $m-2$ نرون اول شبکه وارد می‌کنیم. رویه معرفی شده را برای طول دنباله‌های مختلف تا مقدار m ادامه می‌دهیم. در حالت کلی زمانی که طول دنباله برابر با h باشد به ترتیب زیر عمل می‌کنیم. برای تولید بردارهای ورودی شبکه، با استفاده از شبیه سازی، h نمونه n تایی از مشخصه‌های کیفی فرآیند در حالت خارج از کنترل متناظر تولید می‌کنیم. سپس دترمینان ماتریس کواریانس h نمونه مورد نظر را محاسبه و به عنوان ورودی نرون‌های آخر شبکه در نظر می‌گیریم. در مرحله بعد به تعداد $m-h$ نمونه n تایی از متغیرهای فرآیند، در حالتی که فرآیند تحت کنترل است، تولید و دترمینان ماتریس کواریانس آن‌ها را به $m-h$ نرون اول شبکه وارد می‌کنیم.

شایان ذکر است که در هر یک از قدم‌های بالا، برای تولید داده‌های خارج از کنترل در نمونه‌های n تایی، مقدار بزرگی شیفت ایجاد شده در انحراف استاندارد متغیرهای خارج از کنترل به صورت تصادفی انتخاب می‌شوند. این امر سبب می‌شود

طراحی شده در عمل از این قاعده تبعیت نمی‌کنند و مقدار نرون‌های خروجی معمولاً به طور دقیق برابر صفر یا یک نخواهد بود. بلکه مقدار این نرون‌ها در بازه [۱ و ۰] هستند. برای رفع این مشکل هنگام به‌کارگیری هر یک از شبکه‌های عصبی طراحی شده در تخمین زمان تغییر در فرآیند، ماکزیمم مقدار مشاهده شده در لایه خروجی را به عنوان نقطه تغییر در نظر می‌گیریم برای مثال فرض می‌شود که با ورود داده‌های ورودی به شبکه، مقدار خروجی نرون $m-h$ ام حداکثر شود. در این صورت این نرون بیانگر زمانی است که اولین نمونه خارج از کنترل از فرآیند برداشته شده است. به عبارت دیگر این زمان، نشان دهنده زمان $\tau+1$ بوده و زمان تغییر در فرآیند دقیقاً یک نمونه قبل از این نمونه است.

۳- ارزیابی عملکرد

در این بخش عملکرد مدل پیشنهادی مبتنی بر شبکه عصبی در تخمین نقطه تغییر در ماتریس کواریانس که به دلیل تغییر در واریانس هر یک از مشخصه‌های کیفی فرآیند نرمال چند متغیره ایجاد می‌شود در قالب یک مثال عددی و با استفاده از رویکرد شبیه سازی مورد ارزیابی قرار می‌گیرد. برای این منظور فرض می‌شود که پارامترهای مشخصه‌های کیفی فرآیند اعم از بردار میانگین و ماتریس کواریانس و هم‌چنین ضریب همبستگی بین متغیرهای فرآیند براساس اطلاعات حاصل از تجزیه و تحلیل فاز ۱ معلوم هستند. بر این اساس کیفیت محصول مورد نظر به وسیله بردار نرمال دو متغیره $\mathbf{X} = (x_1, x_2)^T$ بازنمایی می‌شود. در این بردار، توزیع حاشیه‌ای متغیر x_1 نرمال با میانگین ۴ و انحراف استاندارد ۲ بوده و توزیع حاشیه‌ای متغیر x_2 نیز از نوع نرمال با میانگین ۵ و انحراف استاندارد ۲ است. هم‌چنین ضریب همبستگی بین دو متغیر نرمال برابر 0.2 بوده و از نمونه‌هایی به بزرگی ۱۰ برای کنترل فرآیند استفاده می‌شود. با توجه به این که در مثال ارائه شده، تخمین نقطه تغییر در ماتریس کواریانس یک فرآیند نرمال دو متغیره مورد بررسی می‌باشد، لذا از سه شبکه عصبی برای کشف زمان واقعی تغییر در فرآیند استفاده شده است. زمانی که براساس اطلاعات بدست آمده در فاز تشخیصی عامل انحراف، متغیر اول عامل انحراف در فرآیند شناخته شود، شبکه عصبی اول (A) برای تخمین نقطه تغییر در وضعیت خارج از کنترل متناظر فعال می‌شود. اگر متغیر دوم عامل بروز هشدار خارج از کنترل باشد، شبکه عصبی دوم (B) و اگر هر دو متغیر عامل انحراف باشند، شبکه عصبی سوم (C) فعال خواهد شد. متدولوژی پیشنهادی در تخمین نقطه تغییر در

۱. $t=1$
۲. $RL=1$
۳. به تعداد RL نمونه n تایی در حالت خارج از کنترل از یک توزیع نرمال $N_p \sim (\mu_0, \Sigma_0)$ تولید کنید و مقدار دترمینان ماتریس کواریانس را در هر نمونه محاسبه کنید.
۴. به تعداد $m-RL$ نمونه n تایی در حالت تحت کنترل از یک توزیع نرمال $N_p \sim (\mu_0, \Sigma_0)$ تولید کنید و مقدار دترمینان ماتریس کواریانس را در هر نمونه محاسبه کنید.
۵. در بردار هدف عنصر $m-RL+1$ را مساوی یک و سایر نرون‌ها را مساوی صفر قرار دهید.
۶. قرار دهید $RL = RL+1$.
۷. اگر $RL \leq m$ بود به قدم ۳ برو، در غیر این صورت به قدم ۸ بروید.
۸. قرار دهید $t=t+1$.
۹. اگر $t < 100$ بود به قدم ۲ بروید، در غیر این صورت به قدم ۱۰ بروید.
۱۰. پایان تولید داده‌های آموزشی.

۲-۵ تخمین نقطه تغییر در ماتریس کواریانس با استفاده از شبکه‌های عصبی طراحی شده

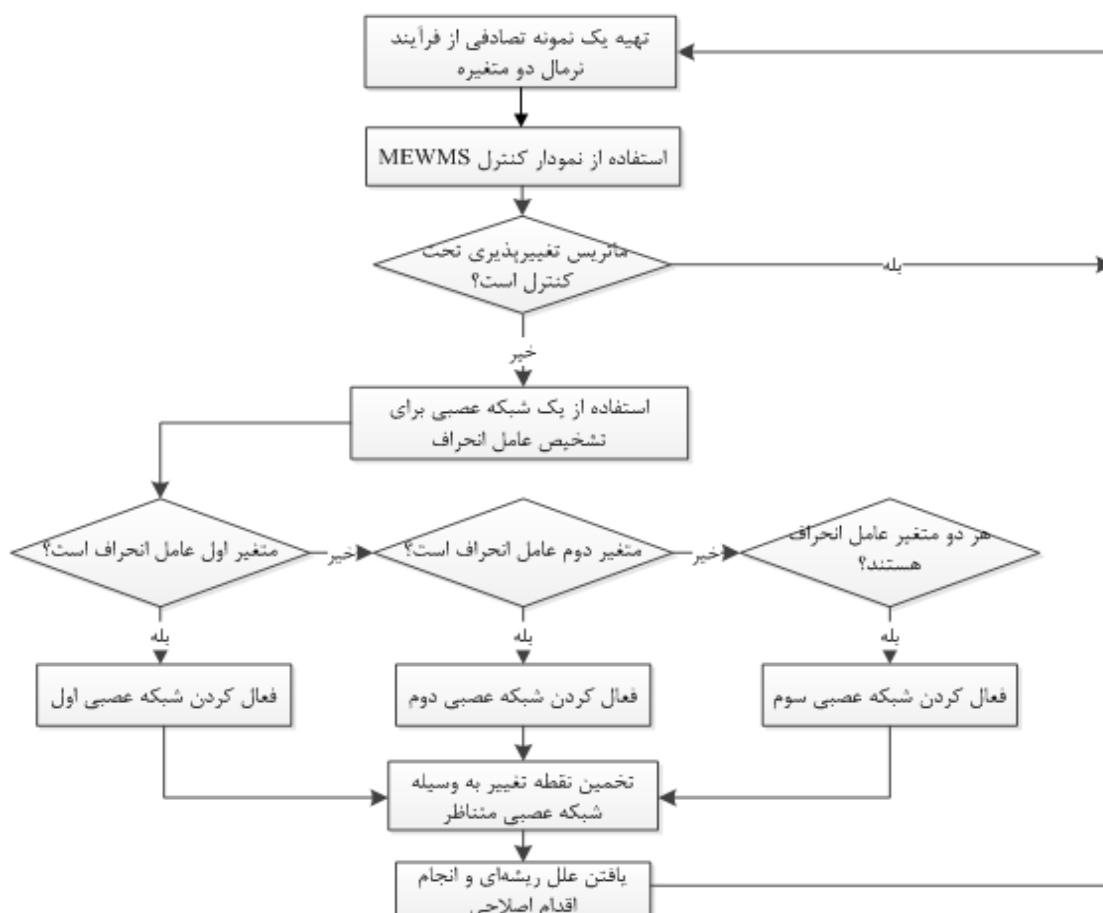
پس از مرحله آموزش، شبکه‌های عصبی طراحی شده باید توانایی تخمین نقطه تغییر در ماتریس کواریانس یک فرآیند نرمال چند متغیره را داشته باشند. تغییر رخ داده ممکن است تنها در واریانس یک یا بیش از یکی از مشخصه‌های کیفی باشد. تشخیص این که متغیر یا متغیرهای عامل انحراف کدام است بر عهده یک شبکه عصبی می‌باشد که قبل از فعال شدن شبکه‌های عصبی پیشنهادی برای تخمین نقطه تغییر به کار می‌رود. بعد از این که متغیر عامل انحراف مشخص شد، بسته به اینکه کدام یک از مشخصه‌های کیفی عامل ایجاد انحراف بوده‌اند، تنها یکی از شبکه‌های عصبی فعال خواهد شد. اگر شبکه‌های عصبی به خوبی آموزش دیده باشند، باید بتوانند با ورود داده‌های تست به شبکه یک بردار با عناصر صفر و یک در خروجی ایجاد کنند که در آن عنصر یک نشان دهنده زمانی است که اولین نمونه خارج از کنترل ایجاد شده است و سایر عناصر مقدار صفر خواهند داشت. ولی باید توجه داشت که به علت خطا شبکه‌های عصبی

سه لایه با ۴۰ نرون در لایه ورودی و ۴۰ نرون نیز در لایه خروجی می‌باشند. همچنین بر اساس سعی و خطا در هر سه شبکه عصبی از یک لایه پنهان به ترتیب با ۱۸، ۲۰ و ۱۸ نرون استفاده شده است و از تابع محرک سیگموئید در هر سه شبکه عصبی پیشنهادی استفاده شده است.

پس از مشخص شدن ساختار هر سه شبکه عصبی، باید آن‌ها را به منظور تخمین صحیح زمان وقوع تغییر در فرآیند نرمال دو متغیره مورد نظر آموزش دهیم. به منظور آموزش هر سه شبکه عصبی مورد نظر ابتدا بردارهای ورودی و مقادیر هدف متناظر به ترتیبی که در زیر بخش ۲-۳ اشاره گردید، تولید می‌شوند. سپس شبکه‌های عصبی مورد نظر را با استفاده از الگوریتم پس‌انتشار خطا آموزش می‌دهیم. لازم به ذکر است که برای تولید داده‌های خارج از کنترل در شبکه عصبی A از شیفت‌هایی استفاده شده است که در آن‌ها نسبت انحراف معیار متغیر اول در حالت خارج از کنترل به انحراف معیار آن در حالت تحت کنترل $3 \leq \delta_1 \leq 1.5$ برابر شده است. پس از آموزش شبکه عصبی A مقدار میانگین مربعات خطای آن برابر 0.180 حاصل

فرآیند نرمال دو متغیره متناظر با این مثال در شکل ۲ به طور شماتیک خلاصه شده است.

اولین گام در طراحی سه شبکه عصبی بیان شده به منظور تخمین نقطه تغییر، تعیین ساختار شبکه‌ها می‌باشد. برای تعیین تعداد نرون‌های ورودی شبکه عصبی اول، مقادیر طول دنباله نمودار کنترل MEWMS_{AS} را به ازای ۱۰۰۰۰ بار شبیه‌سازی به ازای شیفت $(1.4\sigma_1, 0)$ به دست می‌آوریم. با توجه به اینکه $p(RL > 40) = 0.0034$ محاسبه می‌شود تعداد نرون‌های لایه ورودی شبکه عصبی اول برابر ۴۰ در نظر گرفته می‌شود. برای تعیین تعداد نرون‌های لایه ورودی شبکه‌های عصبی دوم و سوم نیز به همین ترتیب عمل می‌کنیم. در این صورت مقدار $p(RL > 40) = 0.0034$ حاصل از ۱۰۰۰۰ بار شبیه‌سازی به ازای شیفت‌های $(0, 1.4\sigma_2)$ و $(1.4\sigma_1, 1.4\sigma_2)$ به ترتیب برابر 0.0036 و 0 محاسبه می‌گردد. در نتیجه تعداد نرون‌های لایه ورودی شبکه‌های عصبی دوم و سوم نیز برابر ۴۰ در نظر گرفته می‌شوند. بنابراین هر سه شبکه طراحی شده از نوع پرسپترون



شکل ۲: فلوچارت الگوریتم پیشنهادی

وضعیت خارج از کنترلی که متغیر اول عامل انحراف است برآورد کند. برای تخمین نقطه تغییر، خروجی‌های شبکه را مد نظر قرار می‌دهیم. نرونی که در آن مقدار خروجی حداکثر شود، برآوردی از اولین نمونه خارج از کنترل در فرآیند خواهد بود و در واقع نرون فوق نشان‌دهنده زمان $\tau+1$ است. در نتیجه زمان تغییر در فرآیند درست قبل از زمان فوق است. به منظور ارزیابی عملکرد شبکه عصبی اول رویه فوق را برای شیفت‌هایی که در آن $\delta_1=1.4, 1.6, 1.8, 2, 2.2, 2.4, 2.6, 2.8, 3$ و برای هر شیفت به تعداد ۱۰۰۰۰ بار تکرار می‌کنیم. سپس میانگین و انحراف استاندارد برآوردها را در ۱۰۰۰۰ بار شبیه‌سازی محاسبه می‌کنیم. همچنین می‌توان برای ارزیابی عملکرد روش پیشنهادی از توزیع تجربی برآوردهای نقطه تغییر نیز استفاده نمود. در جدول (۱) سطر اول و دوم به ترتیب میانگین و انحراف معیار اختلاف زمان وقوع تغییر تعیین شده به وسیله شبکه عصبی از زمان واقعی تغییر در فرآیند را نشان می‌دهد. پنج سطر انتهایی جدول نیز نشان دهنده معیار توزیع تجربی برآوردهای نقطه تغییر است. نتایج جدول (۱) نشان می‌دهد که شبکه عصبی اول به ازای وضعیت‌های مختلفی که متغیر x_1 عامل انحراف است عملکرد مناسبی در تخمین زمان وقوع تغییر در ماتریس کوواریانس فرآیند دارد (نقطه تغییر برآورد شده نزدیک به زمان واقعی وقوع تغییر در فرآیند است). برای مثال زمانی که $\delta_1=1.8$ است، شبکه عصبی طراحی شده تغییر در واریانس متغیر اول را به طور متوسط در فاصله ۱/۰۸ نمونه از زمان واقعی تغییر تخمین می‌زند همچنین نتایج بدست آمده نشان می‌دهد که شبکه عصبی پیشنهادی در تمامی شیفت‌ها غیر از شیفت اول، نقطه تغییر را به طور متوسط در فاصله‌ای کمتر از ۲ نمونه از زمان واقعی تغییر در فرآیند تشخیص می‌دهد. این موضوع نشان از صحت بالای روش پیشنهادی در تخمین نقطه تغییر دارد و افزایش اندازه شیفت در واریانس x_1 باعث بهبود عملکرد شبکه عصبی اول در تخمین صحیح زمان وقوع انحراف در فرآیند می‌شود. به منظور ارزیابی عملکرد شبکه عصبی دوم نیز نمونه‌هایی به اندازه ۱۰ از فرآیندی که در آن واریانس متغیر دوم

می‌شود. برای تولید داده‌های خارج از کنترل در شبکه عصبی B نیز از شیفت‌هایی استفاده شده است که در آن‌ها نسبت انحراف معیار متغیر دوم در حالت خارج از کنترل به انحراف معیار آن در حالت تحت کنترل $1.5 \leq \delta_2 \leq 3$ برابر شده است. مقدار میانگین مربعات خطای حاصل از آموزش شبکه عصبی B نیز برابر ۰/۰۱۸۹ حاصل می‌شود. همچنین مقدار میانگین مربعات خطای حاصل از فرآیند آموزش شبکه عصبی C نیز برابر ۰/۰۱۶۷ می‌شود. شایان ذکر است که زمان مورد نیاز برای آموزش سه شبکه عصبی A، B و C به ترتیب برابر ۹۶۱، ۴۱۵۵ و ۲۶۶۸ ثانیه می‌باشد. پس از آموزش سه شبکه عصبی عملکرد هر یک در تخمین زمان تغییر در فرآیند نرمال دو متغیره مورد نظر را با استفاده از دو معیار مرسوم در ادبیات تخمین نقطه تغییر که عبارتند از میانگین و انحراف استاندارد برآوردهای نقطه تغییر و همچنین توزیع تجربی برآوردها ارزیابی می‌کنیم. برای ارزیابی عملکرد شبکه عصبی A نمونه‌هایی به بزرگی ۱۰ از فرآیندی که در آن واریانس متغیر اول دچار شیفتی به اندازه δ_1 شده است، تولید می‌کنیم. در این حالت ماتریس کوواریانس بین دو مشخصه کیفی از رابطه ۲ تبعیت می‌کند:

$$\Sigma_1 = \begin{bmatrix} \delta_1^2 \sigma_1^2 & \rho \delta_1 \sigma_1 \sigma_2 \\ \rho \delta_1 \sigma_1 \sigma_2 & \sigma_2^2 \end{bmatrix} \quad (2)$$

با تولید داده‌ها از فرآیند خارج از کنترل مورد نظر، مقادیر طول دنباله نمودار کنترل MEWMS_{AS} را نیز محاسبه نموده و آن‌ها را برابر با RL قرار می‌دهیم. از آن جا که تعداد نرون‌های ورودی را برابر با ۴۰ در نظر گرفته‌ایم، در نتیجه با استفاده از شبیه‌سازی به تعداد $RL-40$ نمونه ۱۰ تایی از یک فرآیند تحت کنترل تولید می‌کنیم. حال دترمینان ماتریس کوواریانس را در هر نمونه محاسبه کرده و دترمینان ماتریس کوواریانس داده‌های خارج از کنترل را به نرون‌های آخر شبکه عصبی می‌دهیم و دترمینان ماتریس کوواریانس مربوط به نمونه‌های تحت کنترل را به نرون‌های اول می‌دهیم. بعد از این که ورودی‌های شبکه آماده شد، شبکه عصبی قادر خواهد بود که نقطه تغییر را برای

جدول ۱: میانگین برآوردهای نقطه تغییر و توزیع تجربی برآوردها در شبکه عصبی اول

اندازه شیفت	(۱/۴σ,۰)	(۱/۶σ,۰)	(۱/۸σ,۰)	(۲σ,۰)	(۲/۲σ,۰)	(۲/۴σ,۰)	(۲/۶σ,۰)	(۲/۸σ,۰)	(۳σ,۰)
$E(\tilde{\tau} - \tau)$	۴/۴۰	۱/۶۶	۱/۰۸	۰/۸۷	۰/۸۰	۰/۷۹	۰/۸۳	۰/۸۱	۰/۸۵
$Std(\tilde{\tau} - \tau)$	۶/۱۱	۲/۴۳	۱/۷۱	۱/۵۵	۱/۲۹	۱/۱۷	۱/۴۴	۱/۲۳	۱/۴۱
$p(\tilde{\tau} - \tau \leq 1)$	۴۵/۸۸	۶۲/۰۶	۷۲/۰۳	۷۹/۰۴	۸۲/۹۶	۸۵/۰۰	۸۶/۲۳	۸۷/۶۷	۸۷/۱۴
$p(\tilde{\tau} - \tau \leq 2)$	۵۳/۷۳	۷۵/۸۴	۸۷/۴۲	۹۳/۰۴	۹۶/۱۹	۹۷/۰۹	۹۷/۷۸	۹۷/۶۷	۹۷/۹۸
$p(\tilde{\tau} - \tau \leq 3)$	۶۰/۷۶	۸۴/۷۹	۹۴/۲۰	۹۸/۰۷	۹۸/۸۲	۹۸/۷۸	۹۹/۰۰	۹۸/۷۹	۹۸/۹۰
$p(\tilde{\tau} - \tau \leq 4)$	۶۶/۰۳	۸۹/۹۵	۹۷/۰۰	۹۹/۰۸	۹۹/۴۱	۹۹/۳۳	۹۹/۵۰	۹۹/۳۷	۹۹/۲۶
$p(\tilde{\tau} - \tau \leq 5)$	۷۱/۱۷	۹۳/۴۶	۹۸/۵۴	۹۹/۳۹	۹۹/۵۸	۹۹/۵۷	۹۹/۶۰	۹۹/۶۵	۹۹/۵۶

جدول ۲: میانگین برآوردهای نقطه تغییر و توزیع تجربی برآوردها در شبکه عصبی دوم

اندازه شیفت	(۰,۱/۴σ _۲)	(۰,۱/۶σ _۲)	(۰,۱/۸σ _۲)	(۰,۲σ _۲)	(۰,۲/۲σ _۲)	(۰,۲/۴σ _۲)	(۰,۲/۶σ _۲)	(۰,۲/۸σ _۲)	(۰,۳σ _۲)
$E(\tilde{\tau} - \tau)$	۵/۲۵	۲/۱۵	۱/۲۷	۱/۰۰	۰/۹۲	۰/۸۹	۰/۸۶	۰/۷۹	۰/۷۶
$Std(\tilde{\tau} - \tau)$	۶/۳۵	۲/۶۵	۱/۲۹	۰/۸۲	۰/۷۵	۰/۷۵	۰/۸۱	۰/۸۵	۰/۸۹
$p(\tilde{\tau} - \tau \leq ۱)$	۴۵/۵۲	۶۱/۰۱	۷۴/۶۶	۸۲/۸۶	۸۶/۱۰	۸۶/۳۶	۸۶/۲۳	۸۷/۲۳	۸۷/۵۴
$p(\tilde{\tau} - \tau \leq ۲)$	۵۱/۷۴	۷۳/۶۲	۸۸/۷۶	۹۵/۷۸	۹۶/۶۷	۹۶/۴۰	۹۵/۴۶	۹۵/۸۵	۹۵/۷۱
$p(\tilde{\tau} - \tau \leq ۳)$	۵۷/۵۱	۸۲/۶۳	۹۵/۳۴	۹۹/۰۱	۹۹/۳۳	۹۹/۲۷	۹۸/۶۲	۹۸/۳۶	۹۸/۱۲
$p(\tilde{\tau} - \tau \leq ۴)$	۶۲/۶۵	۸۸/۷۴	۹۸/۲۰	۹۹/۷۷	۹۹/۹۶	۹۹/۹۹	۱/۰۰	۹۹/۹۷	۹۹/۹۷
$p(\tilde{\tau} - \tau \leq ۵)$	۶۷/۳۵	۹۱/۷۶	۹۹/۰۴	۹۹/۹۳	۹۹/۹۷	۹۹/۹۹	۱/۰۰	۹۹/۹۷	۹۹/۹۸

جدول ۳: میانگین برآوردهای نقطه تغییر و توزیع تجربی برآوردها در شبکه عصبی سوم

اندازه شیفت	(۱/۴σ _۲ , ۱/۴σ _۲)	(۱/۶σ _۲ , ۱/۶σ _۲)	(۱/۸σ _۲ , ۱/۸σ _۲)	(۲σ _۲ , ۲σ _۲)	(۲/۲σ _۲ , ۲/۲σ _۲)
$E(\tilde{\tau} - \tau)$	۲/۳۹	۱/۲۴	۰/۹۱	۰/۷۹	۰/۷۴
$Std(\tilde{\tau} - \tau)$	۲/۷۱	۱/۴۰	۰/۹۶	۰/۸۴	۰/۶۴
$p(\tilde{\tau} - \tau \leq ۱)$	۴۷/۳۶	۶۱/۷۸	۷۲/۲۷	۸۱/۰۳	۸۹/۳۲
$p(\tilde{\tau} - \tau \leq ۲)$	۵۹/۹۵	۸۴/۱۶	۹۶/۱۸	۹۹/۴۴	۹۹/۹۵
$p(\tilde{\tau} - \tau \leq ۳)$	۷۱/۰۲	۹۳/۸۵	۹۹/۴۹	۹۹/۹۹	۱
$p(\tilde{\tau} - \tau \leq ۴)$	۸۰/۴۲	۹۷/۴۰	۹۹/۸۸	۹۹/۹۹	۱
$p(\tilde{\tau} - \tau \leq ۵)$	۸۶/۷۰	۹۸/۸۶	۹۹/۹۳	۹۹/۹۹	۱

ادامه جدول ۳: میانگین برآوردهای نقطه تغییر و توزیع تجربی برآوردها در شبکه عصبی سوم

اندازه شیفت	(۲/۴σ _۲ , ۲/۴σ _۲)	(۲/۶σ _۲ , ۲/۶σ _۲)	(۲/۸σ _۲ , ۲/۸σ _۲)	(۳σ _۲ , ۳σ _۲)
$E(\tilde{\tau} - \tau)$	۰/۶۹	۰/۶۷	۰/۸۰	۱/۱۵
$Std(\tilde{\tau} - \tau)$	۰/۶۷	۰/۶۴	۲/۰۴	۳/۹۷
$p(\tilde{\tau} - \tau \leq ۱)$	۹۴/۶۲	۹۶/۴۵	۹۴/۶۹	۸۹/۸۵
$p(\tilde{\tau} - \tau \leq ۲)$	۹۹/۹۹	۹۹/۹۹	۹۹/۷۱	۹۸/۸۲
$p(\tilde{\tau} - \tau \leq ۳)$	۹۹/۹۹	۹۹/۹۹	۹۹/۷۱	۹۸/۸۲
$p(\tilde{\tau} - \tau \leq ۴)$	۹۹/۹۹	۹۹/۹۹	۹۹/۷۱	۹۸/۸۲
$p(\tilde{\tau} - \tau \leq ۵)$	۹۹/۹۹	۹۹/۹۹	۹۹/۷۱	۹۸/۸۲

تغییر در واریانس متغیر دوم را به طور متوسط در فاصله ۱ نمونه از زمان واقعی تغییر تخمین می‌زند. بر اساس نتایج جدول (۲) می‌توان نتیجه گرفت که شبکه عصبی طراحی شده برای تخمین نقطه تغییر در x_2 ، در تمامی شیفت‌ها غیر از شیفت اول و دوم نقطه تغییر را در فاصله‌ای کمتر از ۲ نمونه از زمان واقعی تغییر در فرآیند تشخیص می‌دهد. همچنین با افزایش شیفت در واریانس x_2 عملکرد شبکه عصبی دوم در برآورد زمان تغییر بهبود می‌یابد. همان‌طور که گفته شد، شبکه عصبی C زمانی فعال می‌شود که هر دو متغیر به عنوان عامل انحراف شناخته شوند. ماتریس کواریانس در حالت خارج از کنترل متناظر از طریق رابطه (۴) محاسبه می‌شود:

دچار شیفتی به اندازه δ_2 شده است، تولید می‌کنیم. در این حالت ماتریس کواریانس بین دو مشخصه کیفی از رابطه ۳ تبعیت می‌کند:

$$\Sigma_1 = \begin{bmatrix} \sigma_1^2 & \rho\delta_2\sigma_1\sigma_2 \\ \rho\delta_2\sigma_1\sigma_2 & \delta_2^2\sigma_2^2 \end{bmatrix} \quad (۳)$$

جدول (۲) نتایج بکارگیری شبکه عصبی دوم در تخمین نقطه تغییر در حالتی که x_2 متغیر عامل انحراف است را به ازای $\delta_2 = 1.4, 1.6, 1.8, 2.2, 2.4, 2.6, 2.8, 3$ نشان می‌دهد. نتایج جدول (۲) نشان از دقت بالای شبکه عصبی B در تخمین زمان تغییر در ماتریس کواریانس فرآیند، زمانی که x_2 عامل انحراف است، دارد. برای مثال زمانی که $\delta_2 = 2$ است، شبکه عصبی B

شرایط خارج از کنترل به سر می‌برد. پس نقطه تغییر تخمین زده شده توسط شبکه عصبی، در لحظه $t=31$ بوده که این زمان، زمان واقعی تغییر در فرآیند است. یعنی شبکه عصبی سوم زمان واقعی تغییر در فرآیند را به درستی تخمین زده است.

۴- نتیجه‌گیری و پیشنهادات آتی

در این مقاله مدلی مبتنی بر شبکه عصبی به منظور تخمین نقطه تغییر در ماتریس کواریانس فرآیندهای نرمال چند متغیره تحت شیفت تک پله‌ای ارائه گردید. روش پیشنهادی مبتنی بر مجموعه‌ای از شبکه‌های عصبی پرسپترون سه لایه می‌باشد که پس از دریافت هشدار خارج از کنترل توسط نمودار کنترل $MEWMS_{AS}$ و تشخیص متغیر (متغیرهای) عامل انحراف در ماتریس کواریانس فرآیند، توانایی برآورد زمان واقعی تغییر را در وضعیت‌های مختلف خارج از کنترل دارا می‌باشد. رویکرد ارائه شده در این مقاله بدین صورت است که پس از اخذ هر نمونه از فرآیند، ابتدا دترمینان ماتریس کواریانس نمونه مورد نظر محاسبه می‌شود. سپس مقادیر محاسبه شده برای هر نمونه به صورت یکجا به نرون‌های ورودی شبکه اعمال می‌شوند. پس از ورود داده‌های مورد نظر، متناظر با هر نرون ورودی (هر نمونه اخذ شده) یک نرون نیز در لایه خروجی در نظر گرفته می‌شود. حال روش ارائه شده نرون خروجی با بیشترین مقدار در لایه خروجی را شناسایی نموده و به عنوان نقطه تغییر شناسایی می‌کند. پس از طراحی و آموزش شبکه‌های عصبی مورد نیاز، با استفاده از شبیه سازی نرم افزاری به بررسی عملکرد روش ارائه شده در تخمین زمان واقعی تغییر در تغییرپذیری فرآیند پرداخته شد. در مطالعه شبیه‌سازی ارائه شده از یک فرآیند نرمال دو متغیره جهت بررسی عملکرد روش پیشنهادی جهت تخمین نقطه تغییر استفاده شد. برای این منظور عملکرد روش پیشنهادی با استفاده از دو معیار مرسوم در ادبیات نقطه تغییر یعنی توزیع تجربی برآوردها تحت شیفت‌های مختلف و معیار میانگین و انحراف استاندارد برآوردهای نقطه تغییر، زمانی که یکی از دو متغیر یا هر دو متغیر عامل ایجاد انحراف در ماتریس کواریانس فرآیند باشند، مورد بررسی قرار گرفت. در انتها به منظور توضیح بیشتر روش مبتنی بر شبکه عصبی پیشنهادی، یک مثال عددی ارائه شد. نتایج حاصل نشان از عملکرد مناسب و دقت بالای روش پیشنهادی در تخمین نقطه تغییر در ماتریس کواریانس یک فرآیند نرمال چند متغیره دارد. به عنوان پیشنهادات آتی ارائه مدلی مبتنی بر شبکه عصبی برای تخمین نقطه تغییر تدریجی و مونوتونیک در ماتریس کواریانس فرآیندهای چند متغیره نرمال پیشنهاد می‌شود.

$$\Sigma_1 = \begin{bmatrix} \delta_1^2 \sigma_1^2 & \rho \delta_1 \delta_2 \sigma_1 \sigma_2 \\ \rho \delta_1 \delta_2 \sigma_1 \sigma_2 & \delta_2^2 \sigma_2^2 \end{bmatrix} \quad (4)$$

جدول (۳) عملکرد شبکه عصبی C در تخمین نقطه تغییر در حالتی که هر دو متغیر x_1 و x_2 عامل انحراف در ماتریس کواریانس فرآیند هستند را به ازای شیفت‌هایی که در آن بار تکرار شبیه‌سازی نشان می‌دهد. نتایج جدول (۳) عملکرد مناسب سومین شبکه عصبی طراحی شده در کشف زمان تغییر در ماتریس کواریانس فرآیند برای حالتی که هر دو متغیر عامل انحراف هستند را ثابت می‌کند. برای مثال زمانی که انحراف استاندارد هر دو متغیر $1/6$ برابر شود، شبکه عصبی سوم تغییر رخ داده را به طور متوسط در فاصله $1/24$ نمونه از زمان واقعی تغییر تخمین می‌زند. نتایج جدول (۳) نشان می‌دهد که شبکه عصبی C برای تخمین نقطه تغییر وقتی واریانس هر دو متغیر تغییر می‌کند، نسبت به دو شبکه اول و دوم برآورد دقیق‌تری ارائه می‌دهد. از طرف دیگر شبکه عصبی C برای تمامی شیفت‌ها غیر از شیفت اول، نقطه تغییر را به طور متوسط در فاصله‌ای کمتر از ۲ نمونه از زمان واقعی تغییر تشخیص می‌دهد. همچنین برای هر یک از سه جدول بالا، معیار توزیع تجربی برآوردها که در سطرهای سوم تا هفتم هر جدول خلاصه شده‌اند حاکی از دقت بالای هر یک از شبکه‌های عصبی طراحی شده در تخمین نقطه تغییر برای حالات خارج از کنترل متناظر دارد.

۴- مثال عددی

به منظور تشریح روش پیشنهادی در این بخش یک مثال عددی با استفاده از داده‌های بخش قبل ارائه می‌شود. برای این منظور حالت خارج از کنترلی در نظر گرفته می‌شود که در آن هر دو متغیر عامل انحراف باشند و شیفتی به بزرگی $1/4$ در انحراف استاندارد هر دو متغیر رخ داده است. براساس شبیه سازی مقدار طول دنباله حاصل از نمودار کنترل $MEWMS_{AS}$ برابر ۹ شده است. در نتیجه به تعداد ۳۱ نمونه تحت کنترل تولید و دترمینان ماتریس کواریانس آن‌ها به نرون‌های ۱ الی ۳۱ اختصاص می‌یابد. سپس دترمینان ماتریس کواریانس ۹ نمونه خارج از کنترل به نرون‌های ۳۲ الی ۴۰ اختصاص داده می‌شود. جدول (۴) ورودی‌ها و خروجی‌های شبکه عصبی سوم را به همراه مقادیر هدف متناظرشان نشان می‌دهد. همان‌طور که از جدول (۴) مشخص است، مقدار خروجی شبکه عصبی سوم در نرون ۳۲ نسبت به سایر خروجی‌ها، دارای بیشترین مقدار است. این موضوع بیانگر این است که فرآیند از نمونه ۳۲ در

جدول ۴. ورودی‌ها و خروجی‌های شبکه عصبی سوم در مثال عددی

شماره نرون	مقدار S	خروجی شبکه	مقدار هدف	شماره نرون	مقدار S	خروجی شبکه	مقدار هدف
۱	۸/۱۱	-۰/۰۰۱	۰	۲۱	۱۳/۶۹	۰/۰۰۳	۰
۲	۵/۶۰	۰/۰۰۴	۰	۲۲	۱۱/۰۶	-۰/۰۰۲	۰
۳	۹/۳۷	-۰/۰۱۸	۰	۲۳	۵/۱۱	-۰/۰۰۳	۰
۴	۳/۸۱	۰/۰۰۳	۰	۲۴	۱۶/۰۰	-۰/۰۰۵	۰
۵	۱۱/۴۹	۰/۰۳۱	۰	۲۵	۱۰/۱۰	-۰/۰۰۴	۰
۶	۱۲/۱۵	۰/۰۰۶	۰	۲۶	۱۱/۲۴	۰/۰۰۷	۰
۷	۱۱/۱۳	۰/۰۰۴	۰	۲۷	۹/۲۴	-۰/۰۲۵	۰
۸	۱۸/۸۱	۰/۰۰۳	۰	۲۸	۶/۰۵	-۰/۰۲۷	۰
۹	۱۳/۵۱	-۰/۰۰۱	۰	۲۹	۱۳/۸۰	-۰/۰۲۲	۰
۱۰	۲۱/۱۵	۰/۰۳۲	۰	۳۰	۵/۲۴	-۰/۰۵۵	۰
۱۱	۳۴/۷۰	۰/۰۴۲	۰	۳۱	۶/۶۰	۰/۱۰۱	۰
۱۲	۷/۱۷	۰/۰۱۱	۰	۳۲	۲۰۵/۷۶	-۰/۱۱۸	۱
۱۳	۴۱/۱۱	-۰/۰۰۳	۰	۳۳	۲۷/۷۶	-۰/۰۹۹	۰
۱۴	۹/۵۸	-۰/۰۱۳	۰	۳۴	۶۱/۵۶	-۰/۱۱۳	۰
۱۵	۱۱/۵۸	-۰/۰۳۲	۰	۳۵	۵۹/۹۳	-۰/۰۹۳	۰
۱۶	۵/۹۶	-۰/۰۲۰	۰	۳۶	۱۴۷/۱۰	۰/۰۸۶	۰
۱۷	۵/۳۸	-۰/۰۱۲	۰	۳۷	۲۱۸/۳۴	-۰/۰۹۲	۰
۱۸	۲۴/۹۲	-۰/۰۰۶	۰	۳۸	۱۲۳/۲۰	۰/۰۵۷	۰
۱۹	۷/۴۴	۰	۰	۳۹	۷۹/۳۶	-۰/۰۳۵	۰
۲۰	۱۲/۰۵	۰/۰۰۶	۰	۴۰	۱۱۹/۹۰	-۰/۰۲۸	۰

مراجع

[۵] Zamba, K. D., & Hawkins, D. M. (۲۰۰۶). A multivariate change-point model for statistical process control, *Technometrics*, ۴۸(۴), ۵۳۹-۵۴۹.

[۶] Li, F., Runger, G. C., & Tuv, E. (۲۰۰۶). Supervised learning for change-point detection, *International Journal of Production Research*, ۴۴(۱۴), ۲۸۵۳-۲۸۶۸.

[۷] Zarandi, M. H. F., & Alaeddini, A. (۲۰۱۰). A general fuzzy-statistical clustering approach for estimating the time of change in variable sampling control charts, *Information Sciences*, ۱۸۰(۱۶), ۳۰۳۳-۳۰۴۴.

[۸] Nedumaran, G., Pignatiello Jr, J. J., & Calvin, J. A. (۲۰۰۰). Identifying the time of a step-change with χ^2 control charts, *Quality Engineering*, ۱۳(۲), ۱۵۳-۱۵۹.

[۹] Niaki, S. T. A., & Khedmati, M. (۲۰۱۲). Detecting and estimating the time of a step-change in multivariate Poisson processes, *Scientia Iranica*, ۱۹(۳), ۸۶۲-۸۷۱.

[۱۰] Niaki, S. T. A., & Abbasi, B. (۲۰۰۷). Skewness reduction approach in multi-attribute process

[۱] Bersimis, S., Psarakis, S., & Panaretos, J. (۲۰۰۷). Multivariate statistical process control charts: an overview. *Quality and Reliability Engineering International*, ۲۳(۵), ۵۱۷-۵۴۳.

[۲] Psarakis, S. (۲۰۱۱). The use of neural networks in statistical process control charts, *Quality and Reliability Engineering International*, ۲۷(۵), ۶۴۱-۶۵۰.

[۳] Atashgar, K. (۲۰۱۵). Monitoring multivariate environments using artificial neural network approach: An overview. *Scientia Iranica*, ۲۲(۶), ۲۵۲۷-۲۵۴۷.

[۴] Sullivan, J. H., & Woodall, W. H. (۲۰۰۰). Change-point detection of mean vector or covariance matrix shifts using multivariate individual observations, *IIE transactions*, ۳۲(۶), ۵۳۷-۵۴۹.

- [۲۰] Ahmadzadeh, F. (۲۰۱۱). *Change point detection with multivariate control charts by artificial neural network*, *The International Journal of Advanced Manufacturing Technology*, ۱-۱۲.
- [۲۱] Ahmadzadeh, F., Lundberg, J., & Strömberg, T. (۲۰۱۳). *Multivariate process parameter change identification by neural network*, *The International Journal of Advanced Manufacturing Technology*, ۶۹(۹-۱۲), ۲۲۶۱-۲۲۶۸.
- [۲۲] Atashgar, K., & Noorossana, R. (۲۰۱۱). *An integrating approach to root cause analysis of a bivariate mean vector with a linear trend disturbance*, *The International Journal of Advanced Manufacturing Technology*, ۵۲(۱-۴), ۴۰۷-۴۲۰.
- [۲۳] Noorossana, R., Atashgar, K., & Saghaei, A. (۲۰۱۱). *An integrated supervised learning solution for monitoring process mean vector*, *The International Journal of Advanced Manufacturing Technology*, ۵۶(۵-۸), ۷۵۵-۷۶۵.
- [۲۴] نورالسناء، ر. و آتشگر، ک. (۱۳۸۹). شناسایی نقطه تغییر در بردار میانگین فرآیند نرمال دو متغیره با تغییرات مونوتونیک، نشریه بین المللی مهندسی صنایع و مدیریت تولید، ۲۱(۱)، ۱-۱۳.
- [۲۵] Amiri, A., Maleki, M. R., & Sogandi, F. (۲۰۱۶). *Estimating the Time of a Step Change in the Multivariate-attribute Process Mean Using ANN and MLE*, To appear in *International Journal of Data Analysis Techniques and Strategies*.
- [۲۶] Amiri, A., & Allahyari, S. (۲۰۱۲). *Change point estimation methods for control chart post signal diagnostics: a literature review*, *Quality and Reliability Engineering International*, ۲۸(۷), ۶۷۳-۶۸۵.
- [۲۷] Atashgar, K. (۲۰۱۳). *Identification of the change point: an overview*, *The International Journal of Advanced Manufacturing Technology*, ۶۴(۹-۱۲), ۱۶۶۳-۱۶۸۳.
- [۲۸] Memar, A. O., & Niaki, S. T. A. (۲۰۱۱). *Multivariate variability monitoring using EWMA control charts based on squared deviation of observations from target*, *Quality and Reliability Engineering International*, ۲۷(۸), ۱۰۶۹-۱۰۸۶.
- monitoring, *Communications in Statistics-Theory and Methods*, ۳۶(۱۲), ۲۳۱۳-۲۳۲۵.
- [۱۱] Golnabi, S., & Houshmand, A. A. (۱۹۹۹). *Multivariate shewhart x-bar chart*^۱. *Inter Stat* ۴.
- [۱۲] Allahyari, S., & Amiri, A. (۲۰۱۱). *Clustering Approach for Change Point Estimation in Multivariate Normal Processes*, Proceedings of the ۴th International Conference on Computers & Industrial Engineering.
- [۱۳] Niaki, S. T. A., & Khedmati, M. (۲۰۱۳). *Estimating the change point of the parameter vector of multivariate Poisson processes monitored by a multi-attribute T^r control chart*, *The International Journal of Advanced Manufacturing Technology*, ۶۴(۹-۱۲), ۱۶۲۵-۱۶۴۲.
- [۱۴] Movaffagh, A., & Amiri, A. (۲۰۱۳). *Monotonic change point estimation in the mean vector of a multivariate normal process*, *The International Journal of Advanced Manufacturing Technology*, ۶۹(۵-۸), ۱۸۹۵-۱۹۰۶.
- [۱۵] Doğ u, E., & Kocakoc, I. D. (۲۰۱۱). *Estimation of change point in generalized variance control chart*, *Communications in Statistics—Simulation and Computation*, ۴۰(۳), ۳۴۵-۳۶۳.
- [۱۶] Doğu, E., & Kocakoç, İ. D. (۲۰۱۳). *A Multivariate Change Point Detection Procedure for Monitoring Mean and Covariance Simultaneously*, *Communications in Statistics-Simulation and Computation*, ۴۲(۶), ۱۲۳۵-۱۲۵۵.
- [۱۷] Cheng, C. S., & Cheng, H. P. (۲۰۰۸). *Identifying the source of variance shifts in the multivariate process using neural networks and support vector machines*, *Expert Systems with Applications*, ۳۵(۱), ۱۹۸-۲۰۶.
- [۱۸] Cheng, C. S., & Cheng, H. P. (۲۰۱۱). *Using neural networks to detect the bivariate process variance shifts pattern*, *Computers & Industrial Engineering*, ۶۰(۲), ۲۶۹-۲۷۸.
- [۱۹] امیری، ا.، ملکی، م. ر. و درودیان، م. ه. (۱۳۹۳). پایش تغییرپذیری فرآیندهای چند مشخصه وصفی و متغیر با استفاده از شبکه عصبی مصنوعی، نشریه مدیریت تولید و عملیات، ۲۹(۲)، ۳۶-۲۱.

^۱ Multilayer Feed-Forward Network

^۲ Back Propagation Algorithm

^۳ Back Propagation Network (BPN)

^۴ Gaussian copula

^۵ Robust