

طراحی یک شبکه‌ی عصبی فازی برای کنترل کیفیت فرایندهای چندمتغیره - چندمرحله‌یی

سعید قفقازی (کارشناس ارشد)

سیدتقی اخوان‌نیاکی (استاد)

دانشکده‌ی مهندسی صنایع، دانشگاه صنعتی شریف

در زمینه‌ی کنترل آماری فرایند چندمتغیره، و به منظور کنترل یک مرحله از فرایند تولید، تحقیقات زیادی صورت گرفته است. هدف اصلی این تحقیقات، در نظر گرفتن همبستگی بین چندین مشخصه‌ی کیفی برای یک مرحله از فرایند است. اما در صنایعی نظیر صنایع شیمیایی با موارد زیادی مواجهیم که در آنها تولید شامل چند مرحله است. بنابراین، وجود روشی برای کنترل کیفیت فرایند چندمتغیره - چندمرحله‌یی ضرورت می‌یابد. در این نوشتار ایجاد روشی برای تشخیص بزرگی انتقال میانگین به وجود آمده در متغیرها در مسئله‌ی کنترل کیفیت فرایند چندمتغیره - چندمرحله‌یی چنان هدف گرفته شده است که علاوه بر در نظر گرفتن خاصیت آشکاری مراحل، همبستگی متغیرها را در هر یک از مراحل نیز در نظر بگیرد. روش پیشنهادی استفاده از یک شبکه‌ی عصبی خودآرینده^۱ (خودسازمانده) برای خوشه‌بندی^۲ دسته‌های مختلف انتقال است. این شبکه از قابلیت نمایش بصری روند حرکت فرایند نیز برخوردار است و برای تفسیر نهایی وضعیت انتقال متغیرها در فرایند، از یک سیستم استنتاج فازی استفاده شده است. در سنجش کارایی روش پیشنهادی،^۳ معیار: متوسط طول دنباله تحت کنترل، متوسط طول دنباله خارج از کنترل، و متوسط طول دنباله برای تشخیص دقیق طبقه، در نظر گرفته شده است. روش پیشنهادی از طریق یک مثال از فرایند چندمرحله‌یی خودهمبسته با ۲ متغیر و ۳ مرحله که توسط سری زمانی VAR(۱) شبیه‌سازی شده، ارزیابی شده است. ارزیابی‌ها نشان می‌دهد که روش پیشنهادی نسبت به تحقیقات قبلی انجام شده در این زمینه، خصوصاً در شناسایی انحرافات کوچک، کارایی بهتری دارد.

واژگان کلیدی: کنترل کیفیت چندمتغیره-چندمرحله‌یی، شبکه‌های عصبی خودآرینده، سیستم استنتاج فازی.

saeedghaf61@yahoo.com
niaki@sharif.edu

۱. مقدمه و بررسی ادبیات

در بسیاری از صنایع تولیدی کیفیت محصول معمولاً از طریق چند مشخصه‌ی کیفی به صورت همزمان بررسی می‌شود. تمرکز همزمان بر روی چند شاخص کیفی، به بروز مسائل کنترل کیفی فرایندهای چندمتغیره می‌انجامد. موضوع اصلی در کنترل کیفیت چندمتغیره که این نوع مسائل را از کنترل کیفیت تک‌متغیره جدا می‌کند همبستگی بین متغیرها است، به‌گونه‌یی که کنترل‌های جداگانه‌ی هر متغیر و عدم توجه به این همبستگی‌ها عواقب نامطلوبی به بار می‌آورد. تلاش برای استفاده از نمودارهای

کنترلی در مسئله‌ی کنترل کیفیت چندمتغیره موجب پیدایش و بسط نمودارهای کنترلی چندمتغیره شده است. رویکرد چندمتغیره در کنترل کیفیت اولین بار در سال ۱۹۴۷ در مطالعه‌ی دقت بمباران یک سایت دشمن مورد بررسی قرار گرفت.^۱ در بررسی مذکور، هاتلینگ آماره T^2 را به عنوان مبنایی برای نمایش کیفیت کلی بمباران و توزیع آماری آن ارائه داد. در سال ۱۹۸۵ نیز نمودار جمع تجمعی^۲ یک متغیره را به مسائل چندمتغیره تعمیم دادند.^۳ در سال ۱۹۹۲، نمودارهای میانگین متحرک

موزون نمایی تک‌متغیره به مفاهیم چندمتغیره بسط داده شد.^۴ این نمودار نیز عملکرد مشابهی نسبت به نمودارهای جمع تجمعی چندمتغیره^۴ دارد و در برابر شیفت‌های کوچک حساس است.

در بسیاری از صنایع تولیدی، که در آنها کاربردهای کنترل کیفیت چندمتغیره مطرح است، محصول در چند مرحله تولید می‌شود. مثلاً فرایند تولید بسیار (پلیمر) و تخمیر نمونه‌هایی از عملیات گروهی با فازهای چندگانه‌اند؛ و فرایند تولید نیمه‌هادی‌ها و تولید قرص‌های دارویی نیز از جمله فرایندهای چندمرحله‌یی محسوب می‌شوند.^۵

در فرایندهای تولیدی چندمرحله‌یی، محصولات در یک خط لوله‌یی^۵ جریان می‌یابند. مدل این حرکت متوالی در شکل ۱ نشان داده شده است. در این فرایند خروجی مرحله‌ی i ام ورودی مرحله‌ی $i+1$ ام خواهد بود.

در تحقیق حاضر، حالت خاصی از فرایند چندمرحله‌یی تحت عنوان «فرایند چندمرحله‌یی خودهمبسته»^۶ برای شبیه‌سازی فرایند چندمتغیره - چندمرحله‌یی به

آماری در آنها کارایی قابل قبولی ندارند)، همواره به‌عنوان ابزاری قدرتمند کاربرد داشته است.^[۷]

شبکه‌های عصبی در تشخیص الگوهای نمودار کنترل استفاده‌ی گسترده داشته‌اند. ادبیات تحقیق در این حیطه را می‌توان به دو گروه تقسیم کرد. در اولین گروه، از شبکه‌های عصبی برای تشخیص یک الگوی غیرطبیعی ویژه، تحت عنوان «تشخیص الگوهای نمودار کنترل با هدف خاص»^[۹]، استفاده می‌شود. چنگ^[۸] دو شبکه‌ی عصبی پس انتشار خطا^{۱۰}، یکی برای تشخیص الگوهای متفاوت انتقال و دیگری برای تشخیص الگوهای نمودار کنترل ارائه کرد. وی از میانگین طول دنباله^{۱۱} (ARL) به‌عنوان شاخص عملکرد استفاده کرد و با مقایسه‌هایی که به‌روش‌های مختلف انجام داد نشان داد که عملکرد شبکه‌های عصبی نسبت به نمودارهای ترکیب‌شده‌ی شوهارت و جمع تجمعی -- هم در تغییرات فرایند کوچک و هم در تغییرات متوسط -- بهتر است. چانگ و او^[۷] از یک دیدگاه عصبی - فازی برای تشخیص انتقال میانگین و دسته‌بندی بزرگی آن استفاده کردند. روش پیشنهادی آنها به‌مراتب از نمودارهای سنتی \bar{X} و جمع تجمعی برحسب معیار میانگین طول دنباله برای اندازه‌ی نمونه‌ی برابر ۵، کارایی بهتری داشت. هوارنگ^[۹] دیدگاهی منحصر به فرد را برای آموزش شبکه‌ی عصبی معرفی کرد تا شبکه به‌تهایی قادر به تجزیه و تحلیل الگوهای چرخشی در نمودارهای کنترلی باشد.

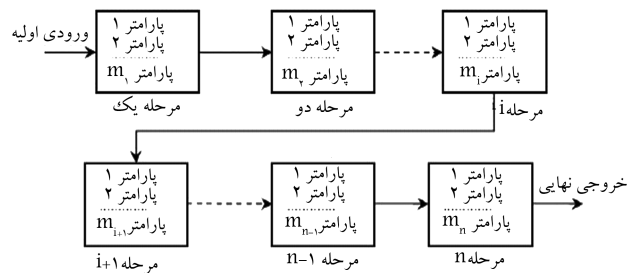
در گروه دوم، از شبکه‌های عصبی به‌عنوان تشخیص‌دهنده‌ی همزمان چندین الگو استفاده می‌شود. فام و ازتمل^[۱۱] از شبکه‌ی عصبی پس‌انتشار خطا و یادگیری تدریجی برداری^{۱۲} برای شناسایی الگوهای انتقال و الگوهای چرخشی در نمودارهای کنترلی استفاده کردند. هوارنگ و هیل^[۱۳] یک شبکه‌ی عصبی پس‌انتشار خطا برای شناسایی ۶ الگوی غیرمعمول انتقال‌های ناگهانی، روند، چرخه، چندشاخه، نظام‌دار و مخلوط ایجاد کردند. گو و تانوک^[۱۴] نیز یک شبکه‌ی عصبی برای تشخیص الگوهای همزمان (مخلوط) ارائه کردند که از قابلیت شناسایی الگوهایی که همزمان با هم به وجود می‌آیند، برخوردار بودند. به‌علاوه، گو و همکاران^[۱۵] این مدل را در یک کارخانه‌ی شیر خشک به‌طور آزمایشی به کار بردند.

با توجه به خواص و کاربرد شبکه‌های عصبی خودآرینده، و این که تاکنون از این شبکه در تشخیص بزرگی انتقال میانگین به وجود آمده در متغیرها -- در کنترل کیفیت فرایند چندمتغیره - چندمرحله‌ی -- استفاده نشده است، در این نوشتار یک شبکه‌ی عصبی خودآرینده طراحی و پیشنهاد می‌شود، چنان‌که علاوه بر در نظر گرفتن خاصیت آشناری مراحل، همبستگی متغیرها را در هر یک از مراحل در نظر می‌گیرد. این شبکه قابلیت نمایش بصری روند حرکت فرایند را نیز دارد و برای تفسیر نهایی در خصوص وضعیت انتقال متغیرها در فرایند، از یک سیستم استنتاج فازی استفاده می‌شود.

بخش دوم این نوشتار به معرفی شبکه‌های عصبی خودآرینده و خلاصه‌ی از خواص آن اختصاص دارد. در بخش سوم، مختصری از سیستم‌های فازی (به‌دلیل کاربردشان در این نوشتار) خواهیم گفت. در بخش چهارم نیز به مدل‌سازی فرایندهای تولید چندمتغیره - چندمرحله‌ی می‌پردازیم؛ و بخش پنجم به روش پیشنهادی برای پایش این فرایندها اختصاص دارد. ارزیابی روش پیشنهادی در بخش ششم انجام می‌شود و بالاخره در بخش هفتم به نتیجه‌گیری خواهیم پرداخت.

۲. شبکه‌های عصبی خودآرینده

از شبکه‌های عصبی می‌توان برای خوشه‌بندی الگوها (شبکه‌های خودآرینده)،



شکل ۱. مدل فرایند مرحله‌ی یا ترتیبی.

کار گرفته شده است، با این فرض که:

- در هر مرحله‌ی تولید چند مشخصه‌ی کیفی وجود دارد؛
- تعداد مشخصه‌های کیفی در همه‌ی مراحل ثابت و برابر p است؛
- مشخصات کیفی یک مرحله‌ی خاص همبسته‌اند؛
- مراحل کنترل کیفی فرایند به هم وابسته‌اند. این وابستگی از آن رو است که ورودی یک مرحله در حقیقت خروجی مرحله‌ی قبلی است و کیفیت مرحله‌ی جاری نمی‌تواند به کیفیت مرحله‌ی قبلی وابسته نباشد.
- تأثیر مراحل بر یکدیگر به‌گونه‌ی است که انحراف در یک مشخصه از مرحله‌ی جاری، می‌تواند بر مشخصات کیفی مراحل بعدی تأثیرگذار باشد، ولی بر مشخصات کیفی مراحل قبلی تأثیر نخواهد گذاشت. به عبارت ساده‌تر، هر مشخصه‌ی کیفی علاوه بر همبستگی با دیگر مشخصات کیفی در یک مرحله، با مشخصه‌ی کیفی نظیرش در مراحل قبلی خود همبسته است. نتیجتاً کیفیت یک محصول در انتهای هر مرحله، نه فقط به آنچه که در مرحله‌ی جاری وجود دارد، بلکه به آنچه که در مراحل قبلی انجام می‌شود نیز وابسته است. این خاصیت در فرایندهای چندمرحله‌ی به «خاصیت آشناری» معروف است.
- فرض استقلال بین مشاهدات هر مرحله‌ی خاص برای هر یک از مشخصات کیفی برقرار است.

عمده‌ترین روش‌های به‌کار گرفته شده برای کنترل فرایندهای چندمرحله‌ی تک‌متغیره عبارت‌اند از: نمودار انتخاب علت^۶ (CSC) و نمودار کنترل مدل - مینا که هر دو روش بر پایه‌ی رگرسیون عمل می‌کنند. چنانچه متغیر خروجی Y در مرحله‌ی جاری تابعی از m مشخصه‌ی کیفی مرحله‌ی قبل مانند x_1, x_2, \dots, x_m باشد، آنگاه نمودار انتخاب علت چندگانه^۷ (MCSC) به کار می‌رود.^[۶]

صرف‌نظر از تک‌متغیره، چندمتغیره و یا چندمرحله‌ی بودن یک فرایند، ممکن است موارد غیرمعمول و غیرتصادفی در آنها رخ دهد. موارد غیرتصادفی ممکن است خود را به‌صورت‌های مختلف نشان دهند، مثلاً مقادیر پارامترهای فرایند یا آماره‌های مربوطه در کنترل فرایند می‌توانند تغییر کنند. موارد غیرمعمول به‌صورت شرایط خروج از کنترل و/ یا الگوهای سری زمانی غیر معمول رخ می‌دهند. الگوهای سری زمانی در تشخیص الگوهای نمودار کنترل (CCP)^۸، بیان‌گر انحرافات میانگین فرایند از مقادیر نرمال است. این مسئله تحت عنوان شناسایی الگو شناخته می‌شود.

شبکه‌های عصبی نیز از اواخر دهه ۸۰ میلادی در کنترل آماری فرایند به کار گرفته شده‌اند. یکی از دلایل اصلی به‌کارگیری شبکه‌های عصبی در کنترل فرایند، خودکار کردن تفسیر نمودارهای کنترل است. امروزه کاربرد شبکه‌های عصبی در نمودارهای کنترل بیشتر در نمودارهای تک‌متغیره مطرح است، ولی در برخورد با مسائل بزرگ‌تر و پیچیده‌تر (نظیر حالت‌های چندمتغیره یا چندمرحله‌ی، که روش‌های

نورون برنده با توجه به رابطه‌ی ۳ مشخص می‌شود:

$$c = \arg \text{Min}_t \{d(X, m_t)\} \quad (3)$$

که در آن c نشان‌دهنده‌ی نورون برنده و $d(X, m_t)$ فاصله‌ی اقلیدسی میان رکورد و بردار وزنی نورون t ام است که از رابطه‌ی ۴ به دست می‌آید:

$$d(x, m_t) = \|x - m_t\| \quad (4)$$

۳. به‌هنگام کردن بردار وزنی متناظر با هر نورون با استفاده از رابطه‌ی ۵:

$$m_i(t+1) = m_i(t) + a(t)h_{ci}(t)[x(t) - m_i(t)] \quad (5)$$

که در آن $0 < \alpha < 1$ نرخ یادگیری و $h_{ci}(t)$ نمایانگر میزان همسایگی نورون i ام و c ام (نورون برنده) هستند. میزان همسایگی نورون برنده و نورون i ام از رابطه‌ی ۶ به دست می‌آید:

$$h_{ci} = e^{-\frac{\|r_{ci} - r_i\|^2}{2\sigma^2(t)}} \quad (6)$$

که در آن σ کنترل‌کننده‌ی دامنه‌ی تابع است و به‌تدریج در طول فرایند یادگیری کاهش داده می‌شود. همچنین r_{ci}, r_i به‌ترتیب موقعیت نورون‌های i ام و c ام (برنده) در نقشه‌ی شبکه است.

۴. بررسی شرط خاتمی الگوریتم؛ اگر این شرط برقرار نباشد، الگوریتم از قدم دوم ادامه می‌یابد.

از آنجا که الگوریتم آموزش شبکه‌های خودآراینده بر فاصله‌ی اقلیدسی بنا شده است، باید داده‌های هر بعد فضای مورد بررسی را مستقلاً به متغیرهای تصادفی نرمال استاندارد تبدیل کرد.

۳. سیستم‌های فازی

تئوری فازی برای اولین بار توسط پروفیسور زاده، استاد دانشگاه برکلی در سال ۱۹۶۵ میلادی مطرح شد. مجموعه‌های فازی، هسته‌ی اولیه‌ی نظریه‌ی فازی را تشکیل می‌دهند. یک مجموعه‌ی فازی، مجموعه‌ی از عناصر است که مرز مشخصی را نمی‌توان برای آن تعریف کرد. در واقع هر عنصر از این مجموعه ممکن است تا حدودی به این مجموعه‌ی فازی تعلق داشته باشد یا نداشته باشد. قواعد فازی یا گزاره‌های شرطی فازی، گزاره‌هایی به‌صورت (اگر $x \in A$ آنگاه $y = B$) هستند که در آنها A, B مجموعه‌ی فازی هستند که با توابع عضویت مناسبی تعریف می‌شوند.^[۲۸] در ادبیات موضوع معمولاً از سه نوع سیستم فازی خالص، سیستم فازی تاکاگی - سوکینو و کانگ (TSK)، و سیستم‌های فازی‌ساز^{۱۵} و فازی‌زدا^{۱۶} (ممدانی) یاد می‌شود.

ساختار اصلی یک سیستم فازی خالص در شکل ۳ نشان داده شده است. موتور استنتاج فازی، قواعد ساخته شده را از یک نگاهت از مجموعه‌های فازی در فضای ورودی به مجموعه‌های فازی در فضای خروجی براساس اصول منطق فازی ترکیب می‌کند. هر سیستم استنتاج دارای بخش‌هایی مختلف، نظیر فازی‌ساز، موتور استنتاج فازی یا پایگاه دانش فازی^{۱۷}، انباشتگی خروجی‌ها^{۱۸}، و غیر فازی‌ساز است.

دسته‌بندی الگوها (شبکه‌های عصبی احتمالی، پرسپترون، و پیش‌خور)، تخمین غیر خطی شبکه‌های پیش‌خور چندلایه^{۱۳} (MLFF)، و بهینه‌یابی (شبکه‌های هاپفیلد و ماشین بولتزمن) استفاده کرد.^[۱۷، ۱۶] شبکه‌های خودآراینده در سال ۱۹۸۴ معرفی، و برای تشخیص صدا و تبدیل آن به متن به‌طور عملی مورد استفاده قرار گرفت.^[۱۹، ۱۸] اکنون شبکه‌های خودآراینده به‌طور گسترده‌ی در داده‌کاوی^[۲۰]، نمایش فضاهای پیچیده^[۲۱]، و خوشه‌بندی فضاهای با ابعاد گسترده و به‌طور خاص در پردازش تصویر، کنترل فرایند^[۲۲-۲۵]، آنالیزهای مالی^[۲۶] و تشخیص‌های صنعتی و پزشکی مورد استفاده قرار می‌گیرد. فهرست جامعی از کاربردهای مهندسی نقشه‌های خودآراینده توسط کوهن و همکاران^[۲۷] ارائه شده است.

اساس فلسفه‌ی شبکه‌های خودآراینده، نگاهت فضاهای با تعداد ابعاد (مشخصه‌ی) بالا به فضایی دو یا سه‌بعدی است به‌گونه‌ی که کم‌ترین اطلاعات از بین برود و اطلاعات نهفته در ارتباط میان داده‌ها نیز قابل کشف و نمایش باشد. این توانایی‌ها با نگاهت ارتباطات غیرخطی میان اطلاعات با استفاده از یک واسط هندسی بر روی یک شبکه‌ی دو یا سه‌بعدی از نورون‌ها حاصل می‌شود. یک شبکه‌ی دو بعدی از نورون‌ها اصطلاحاً یک نقشه از نورون‌ها نامیده می‌شود. هر نقشه، متشکل از مجموعه‌ی نورون‌هاست که به‌شیوه‌ی نظام‌مند کنار هم چیده شده‌اند و ساختار شبکه را به‌گونه‌ی شکل داده‌اند که نورون‌های شبیه‌تر کنار یکدیگر قرار گیرند. هر نورون متناظر با یک بردار اطلاعات با تعداد عناصر برابر با تعداد ابعاد فضای اطلاعاتی مورد تحلیل است. به بیانی دیگر، هر نورون به‌مثابه نماینده‌ی یک قسمت از فضای اطلاعات است. این نماینده به‌گونه‌ی انتخاب می‌شود که به بهترین صورت معرف مشخصات اطلاعات بخش متناظر با خود باشد. شکل ۲ یک شبکه‌ی کوهن معمولی شامل یک لایه‌ی ورودی و یک لایه‌ی کوهن دو بعدی را نشان می‌دهد. الگوریتم آموزش شبکه‌های خودآراینده شامل چهار مرحله است:^[۱۷]


- انتخاب پارامترهای نقشه‌مانند ابعاد و بردار وزنی ابتدایی متناظر با هر نورون؛
- ارائه‌ی داده‌های مورد تحلیل به شبکه و یافتن بهترین نورون نظیر برای هر بردار داده و ورودی (رکورد). رکوردها می‌توانند هم‌زمان به شبکه ارائه شوند، یا به‌ترتیب هر بار رکورد به شبکه ارائه و عملیات آموزش شبکه انجام شود. هر رکورد مانند X ، متشکل از مقادیر کمی n مشخصه است که به‌صورت رابطه‌ی ۱ نمایش داده می‌شود:

$$x = [x_1, x_2, \dots, x_n] \in \mathfrak{R}^n \quad (1)$$

بردار وزنی نورون t ام به‌صورت رابطه‌ی ۲ تعریف می‌شود:

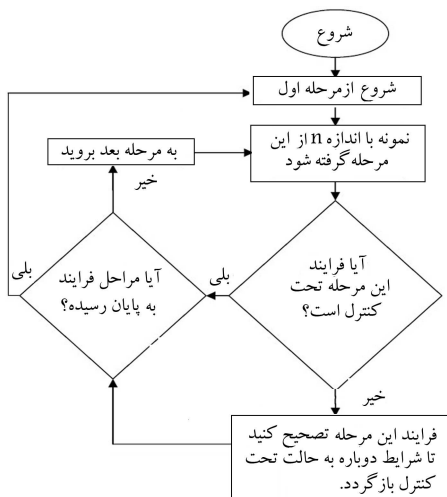
$$m_t = [m_{t1}, m_{t2}, \dots, m_{tm}] \in \mathfrak{R}^m \quad (2)$$

آنگاه متناظر با هر رکورد ورودی، بهترین واحد تطبیقی^{۱۴} (BMU) یا اصطلاحاً



بردار ورودی x_1, \dots, x_n

شکل ۲. ساختار شبکه‌ی کوهن.



شکل ۴. نمودار جریان فرایند کنترل ترتیبی.

مرحله‌ی اول با اندازه‌ی نمونه‌ی n آغاز می‌شود. در صورتی که نمونه‌ی گرفته شده از مرحله‌ی اول نشان‌گر تحت کنترل بودن فرایند باشد، به نمونه‌گیری در مرحله‌ی بعدی می‌رویم. در غیر این صورت، فرایند در مرحله‌ی اول تصحیح می‌شود تا شرایط تحت کنترل حاصل شود. برای دیگر مراحل نیز به همین ترتیب عمل می‌کنیم. شکل ۴ نشان‌گر عملکرد این رویکرد است.

۱.۵. تبدیل مسئله به مسئله‌ی تشخیص الگو

در ادبیات موضوع، کاربرد شبکه‌های عصبی در کنترل آماری فرایند چندمتغیره اکثراً با دیدگاه تشخیص الگو یا خوشه‌بندی نگریسته می‌شود. هدف این تحقیق کشف میزان انتقال به وجود آمده در میانگین هر متغیر در هر مرحله است. فرض کنید هر متغیر در هر مرحله از فرایند به لحاظ انتقال میانگین (به صورت ضریبی از انحراف استاندارد خود σ) بتواند در ۹ طبقه به صورت جدول ۱ قرار گیرد.


حال در مسئله‌ی که دارای m متغیر و r مرحله است مجموعاً $m \cdot r$ مشخصه‌ی کیفی باید تحت بررسی قرار گیرد که با طبقه‌بندی ذکر شده، تعداد $9^{m \cdot r}$ الگوی متفاوت از ترکیبات مختلف انتقال در میانگین می‌توان تصور کرد. واضح است که حتی برای نمودهای کوچکی از مسئله، نظیر نمود مورد بررسی در این تحقیق که شامل ۲ متغیر و ۳ مرحله است، 9^6 الگوی انتقال وجود دارد که کم‌تر ابزار تشخیص الگویی قادر به شناسایی مستقیم این تعداد الگو خواهد بود. در این تحقیق برای غلبه بر مشکل موجود، ضمن معرفی فرایند کنترل ترتیبی اشاره شده در شکل ۴، ابعاد مسئله چندمتغیره - چندمرحله‌ی تا حد یک مسئله چندمتغیره کاهش می‌یابد.

۲.۵. ابزار کنترل کیفیت پیشنهادی

ابزار کنترل کیفی مورد استفاده برای هر مرحله متشکل از دو قسمت است. قسمت اول از یک شبکه‌ی عصبی خودآراینده به عنوان ابزاری قدرتمند در طبقه‌بندی الگوها

جدول ۱. ۹ طبقه‌ی انتقال برای مشخصه‌ی کیفی با انحراف استاندارد σ .

۴σ	۳σ	۲σ	۱σ	۰	-۱σ	-۲σ	-۳σ	-۴σ	میزان انتقال به وجود آمده در میانگین متغیر
----	----	----	----	---	-----	-----	-----	-----	--



شکل ۳. ساختار سیستم‌های فازی خالص.

۴. مدل‌سازی فرایند چندمتغیره چندمرحله‌ی [۲۹]

در یک فرایند تولیدی که از چند مرحله‌ی وابسته تشکیل شده است و در آن کیفیت محصول در هر مرحله در قالب چندین مشخصه‌ی کیفی (متغیر) هم‌بسته تعریف می‌شود، می‌توان مقادیر این متغیرها را با استفاده از فرم برداری مدل‌های $VARMA$ ^{۱۹} (چندمتغیره) مدل‌سازی کرد. برای این کار فرض کنید بردار تصادفی $\mathbf{x}_t = [x_{t,1}, x_{t,2}, \dots, x_{t,m}]$ متغیر در زمان t و بردار تصادفی $\mathbf{z}_t = [z_{t,1}, z_{t,2}, \dots, z_{t,m}]$ نویز سفید^{۲۰} با میانگین صفر و ماتریس کواریانس Σ_z باشد. در این صورت یک مدل m متغیره $VARMA(p, q)$ میانگین صفر که توسط معادله‌ی ۷ مشخص می‌شود را در نظر بگیرید:

$$\mathbf{x}_t - \varphi_1 \mathbf{x}_{t-1} - \dots - \varphi_p \mathbf{x}_{t-p} = \mathbf{z}_t + \theta_1 \mathbf{z}_{t-1} + \dots + \theta_q \mathbf{z}_{t-q} \quad (7)$$

که در آن $\{\theta_i\}_{m \times m}; (i = 1, 2, \dots, q), \{\varphi_i\}_{m \times m}; (i = 1, 2, \dots, p)$ به ترتیب ضرایب AR و MA نام دارند. حال اگر $q = 0$ باشد، آنگاه فرایند برداری $AR(1)$ ^{۲۱}، به صورت معادله‌ی ۸ به دست می‌آید:

$$\mathbf{x}_t - \varphi_1 \mathbf{x}_{t-1} - \dots - \varphi_p \mathbf{x}_{t-p} = \mathbf{z}_t \quad (8)$$

و اگر فرض کنیم تعداد متغیرهای یک مدل اتورگرسیو مرتبه ۱ برابر ۲ باشد، $(m = 2)$ معادله‌ی ۸ به معادله‌ی ۹ تبدیل خواهد شد.

$$\begin{pmatrix} x_{t,1} \\ x_{t,2} \end{pmatrix} = \begin{pmatrix} \phi_{11} & \phi_{12} \\ \phi_{21} & \phi_{22} \end{pmatrix} \begin{pmatrix} x_{t-1,1} \\ x_{t-1,2} \end{pmatrix} + \begin{pmatrix} z_{t,1} \\ z_{t,2} \end{pmatrix} \quad (9)$$

که می‌توان آن را به صورت معادله‌ی ۱۰ نوشت.

$$\begin{aligned} x_{t,1} &= \phi_{11}x_{t-1,1} + \phi_{12}x_{t-1,2} + z_{t,1} \\ x_{t,2} &= \phi_{21}x_{t-1,1} + \phi_{22}x_{t-1,2} + z_{t,2} \end{aligned} \quad (10)$$

در این تحقیق یک فرایند چندمرحله‌ی خودهمبسته دارای دو متغیر و سه مرحله در نظر گرفته شده است و از مدل $VAR(1)$ (معادله‌ی ۱۰) برای تولید داده در شبکه استفاده می‌شود. برای این کار روش دلر و نلسون^[۲۰] در نرم‌افزار Matlab به کار گرفته شده که در آن ماتریس ضرایب اتورگرسیو (AR) عبارت است از:

$$\varphi = \begin{bmatrix} 0.9 & 0 \\ 0 & 0.95 \end{bmatrix}$$

۵. روش پیشنهادی برای کنترل کیفیت فرایندهای

چندمتغیره - چندمرحله‌ی


در این تحقیق برای کنترل فرایندهای چندمتغیره - چندمرحله‌ی، رویکردی تحت عنوان «کنترل ترتیبی»^[۲۳] پیشنهاد می‌شود. در این رویکرد نمونه‌گیری به ترتیب از

دیدگاه عملی، انتقال میانگین از حالت تحت کنترل به حالت خارج از کنترل صورت می‌پذیرد. بنابراین در معرفی الگوهای انتقال به شبکه، داده‌های مربوط به هر یک از ۸۰ الگوی انتقال در میانگین پس از داده‌های تحت کنترل (بردار میانگین (۰ و ۰)) تولید و به شبکه معرفی می‌شوند.

درخصوص تعداد داده‌های آموزش در هر الگو نمی‌توان روش مشخصی در نظر گرفت. هرچه تعداد داده‌ها در یک الگو بیشتر باشد، توانایی شبکه در شناسایی الگوها افزایش می‌یابد ولی افزایش بیش از حد داده‌های آموزش موجب افزایش زمان آموزش شبکه و همچنین افزایش ابعاد نقشه‌ی شبکه می‌شود که هر دو، از جمله عوامل نامناسب محسوب می‌شوند. در این تحقیق تعداد داده‌های آموزش در هر الگوی انتقال یافته، برابر ۱۰۰۰۰ است و برای شرایط تحت کنترل نیز ۵۰۰۰۰ داده تولید می‌شود. ملاحظه می‌شود که تعداد داده‌های آموزش در حالت تحت کنترل ۵ برابر داده‌های معرفی شده در دیگر الگوها در نظر گرفته می‌شود؛ علت آن است که بیشتر بودن تعداد داده‌های تحت کنترل در مقایسه با تعداد داده‌های الگوهای خارج از کنترل موجب کاهش خطای نوع اول شبکه، و افزایش متوسط طول دنباله تحت کنترل می‌شود.

۳.۳.۵. تفسیر خروجی شبکه

پس از آموزش شبکه در مراحل اول، دوم و سوم فرایند تولیدی، نقشه‌های آنها تماماً شبیه به آنچه که در شکل ۵ برای مرحله‌ی اول نشان داده شده، به دست آمد. درمورد پارامترهای کیفی شبکه‌ی آموزش داده‌شده، در حالی که ابعاد نقشه برای همه‌ی مراحل 44×51 است، خطای مقداردهی شبکه برای مراحل یک تا سه به ترتیب برابر 0.2583 ، 0.2584 و 0.2586 و خطای نقشه‌برداری شبکه در مراحل سه‌گانه به ترتیب برابر 0.425 ، 0.427 و 0.422 است. در شکل ۶ الگوهای تشخیص داده‌شده توسط شبکه برای مرحله‌ی اول به صورت شماتیک نشان داده شده‌اند. الگوهای مراحل دیگر نیز نظیر همین مرحله به دست می‌آید. همان‌گونه که از شکل ۶ برمی‌آید در مرکز نقشه الگوی بدون انتقال یا بردار میانگین انتقال (۰ و ۰) قرار می‌گیرد. بزرگ‌تر بودن خوشه‌ی این الگو نسبت به الگوهای دیگر به دلیل بیشتر بودن تعداد داده‌های آموزشی در این الگو است. خوشه‌های الگوهای انتقال کوچک به صورت حلقه‌ی دور تا دور این خوشه را احاطه کرده‌اند. خوشه‌های الگوهای انتقال متوسط نیز به همین ترتیب خوشه‌های الگوهای انتقال کوچک را احاطه کرده‌اند و نهایتاً وضع برای خوشه‌های انتقال بزرگ نیز به همین منوال است. نحوه‌ی قرارگرفتن و رنگ عناصر (نورون‌های) نقشه برحسب فاصله‌ی آنها از یکدیگر است. بنابراین رنگ‌های آبی پررنگ تعلق زیاد عنصر را به یک دسته و رنگ‌های روشن‌تر تعلق کم‌تر یک عنصر به یک دسته‌ی خاص را نشان می‌دهد.



شکل ۵. نقشه‌ی U-MAT مرحله اول.

تشکیل شده است و قسمت دوم شامل یک سیستم استنتاج فازی است که برای تصمیم‌گیری نهایی درخصوص وضعیت متغیرها در هر مرحله به کار می‌رود.

۳.۳.۵. آموزش شبکه

برای آموزش شبکه‌ی عصبی لازم است که داده‌های مربوط به حالت‌های تحت کنترل و خارج از کنترل فرایند تولید شود. برای این کار از رابطه‌ی ۱۱ استفاده می‌شود:

$$x_t = \varphi x_{t-1} + Z_t + S_t \quad (11)$$

که در آن دو جمله‌ی S_t (انحراف ایجادشده در میانگین فرایند) و x_{t-1} عوامل مؤثر در مقدار x_t هستند. چنان که در قسمت‌های قبل مشاهده شد، داده‌های آموزش برای ارائه به شبکه در مرحله‌ی اول، بدون تأثیرپذیری از متغیرهای مرحله‌ی قبل ایجاد می‌شود و مرحله‌ی دوم تحت شرایطی کنترل خواهد شد که مرحله‌ی اول در شرایط تحت کنترل باشد. بنابراین در حالت کلی، داده‌های آموزش برای شبکه در مرحله‌ی t ام شامل همه‌ی الگوهای انتقال متغیرهای همان مرحله خواهد بود.

۱.۳.۵. بردار ورودی شبکه

در این تحقیق دو عامل اساسی در تشکیل بردار ورودی شبکه مد نظر قرار گرفته است که مستقیماً در کارایی روش پیشنهادی مؤثر خواهد بود:

- اندازه‌ی نمونه: با معرفی اندازه‌ی نمونه‌ی مناسب می‌توان محدوده‌ی تغییرات داده‌ها در الگوهای مختلف را چنان کنترل کرد که شبکه قادر به تشخیص الگوها شود. با روش سعی و خطا و با در نظر گرفتن اندازه‌ی نمونه‌ی ۵، معیارهای ارزیابی کارایی روش پیشنهادی در حد مطلوبی قرار می‌گیرند.
- تعداد مشاهدات قبلی: در تشکیل بردار ورودی لازم است که علاوه بر مشاهده‌ی فعلی، تعدادی از مشاهدات قبلی نیز به شبکه ارائه شوند. تعداد مشاهدات قبلی دخیل در تشکیل بردار ورودی بسیار شدیدتر از تأثیر اندازه‌ی نمونه، کارایی شبکه را تحت تأثیر قرار می‌دهند. بدین ترتیب که افزایش تعداد مشاهدات قبلی، متوسط طول دنباله تحت کنترل را به شدت افزایش می‌دهد ولی متوسط طول دنباله خارج از کنترل و متوسط طول دنباله برای تشخیص دقیق طبقه (ARL_{DDC})، خصوصاً درمورد انتقال‌های کوچک افزایش می‌یابند و در نتیجه روش پیشنهادی قابلیت خود را برای کشف انتقال میانگین خصوصاً درمورد انتقال‌های کوچک از دست می‌دهد. بنابراین تعداد مشاهدات قبلی باید به صورتی در نظر گرفته شود که رابطه‌ی جایگزین 2^4 (تبادل) بین قابلیت شناسایی انتقال و متوسط طول دنباله تحت کنترل برقرار شود. وارد کردن مقدار مشاهده‌ی قبل در بردار ورودی و همچنین استفاده از یک سیستم استنتاج فازی در تحلیل خروجی شبکه نهایتاً نتیجه‌ی مطلوب را به دست می‌دهد. بنابراین بردار ورودی برای معرفی به شبکه‌ی خودآراینده در مرحله‌ی t ام به صورت زیر خواهد بود:

$$\text{بردار ورودی} = (X_{1jk}, X_{2jk}, X_{1j(k-1)}, X_{2j(k-1)})$$

که در آن X_{ijk} مشاهده‌ی k ام از مشخصه‌ی کیفی i ام در مرحله‌ی j ام، $(j = 1, 2, 3)$ ، $(i = 1, 2)$ ، $(k = 1, 2, \dots, N)$ است.

۲.۳.۵. آموزش شبکه

با توجه به این که مقادیر مشخصه‌های کیفی در زمان t به همراه این مقادیر در زمان $(t-1)$ در بردار ورودی به شبکه ارائه می‌شوند، ترتیب داده‌ها از نظر انتقال از یک الگو به الگوی دیگر، یادگیری شبکه برای کشف الگوها را تحت تأثیر قرار می‌دهد. از

۴.۵. سیستم استنتاج فازی

علاوه بر نقشه‌ی شبکه، ابزار مناسبی برای تصمیم‌گیری نهایی درخصوص خروجی شبکه درمورد وضعیت انتقال یا عدم انتقال -- به‌ویژه هنگامی که یک نورون برنده در مرز قرار می‌گیرد -- مورد نیاز است. برای این منظور، در این بخش از سیستم استنتاج فازی استفاده شده است. سیستم استنتاج فازی را می‌توان براساس دانش خیرگان^{۲۵} یا داده‌های مشاهده‌شده^{۲۶} ساخت. نحوه‌ی استخراج قوانین از این روش‌ها را کوسکو^[۲۸] شرح داده است. قوانین تصمیم‌گیری براساس خروجی‌های شبکه عبارت‌اند از:

۱. اگر احتمال تعلق نورون برنده به یک دسته بیش از ۹۵٪ باشد، می‌پذیریم که آن مشاهده به آن دسته متعلق است.

۲. اگر احتمال تعلق نورون برنده به یک دسته کم‌تر از ۵٪ باشد، مشاهده به آن دسته تعلق ندارد.

۳. اگر احتمال تعلق نورون برنده به یک دسته در محدوده‌ی (۹۵٪ و ۵٪) قرار گرفت، تصمیم‌گیری نمی‌کنیم و تا مشاهده‌ی بعدی صبر می‌کنیم. سپس هر دو مشاهده را به‌عنوان ورودی به سیستم استنتاج فازی می‌سپاریم تا سیستم تصمیم‌گیری را انجام دهد.

در ادامه، تعریف ورودی‌ها، خروجی‌ها و قوانین این سیستم ارائه شده است.

۱.۴.۵. ورودی‌های سیستم استنتاج فازی

احتمال‌های تعلق نورون‌های برنده در دو مشاهده‌ی پیاپی به دسته‌های ۸۱ گانه به‌عنوان ورودی به سیستم استنتاج فازی معرفی می‌شوند. بنابراین ۱۶۲ ورودی خواهیم داشت. برای هر یک از ورودی‌ها ۵ تابع عضویت پی ۲۷ (۵ سطح) در نظر گرفته می‌شود که به‌ترتیب عبارت‌اند از: خیلی کم، کم، متوسط، بزرگ و خیلی بزرگ. در شکل ۸ توابع عضویت ۵ گانه برای هر یک از ورودی‌ها نمایش داده شده است.


۲.۴.۵. خروجی‌های سیستم استنتاج فازی

خروجی‌های مورد انتظار از سیستم فازی عبارت است از این که «مشاهده‌ی دوم، به چه دسته‌ی تعلق دارد؟». بنابراین خروجی سیستم استنتاج فازی، شامل ۸۱ خروجی است که هر کدام از خروجی‌ها بیانگر دسته‌ی مشاهده‌ی دوم است. برای هر یک از عناصر خروجی ۲ تابع عضویت پی تعریف می‌شود که به‌ترتیب بیانگر عدم تعلق و تعلق به آن دسته‌اند (شکل ۹).


۳.۴.۵. قوانین سیستم استنتاج فازی

قواعد مورد استفاده برای سیستم استنتاج فازی عبارت‌اند از:


۱. اگر میزان احتمال تعلق به یک دسته در دو داده‌ی پیاپی در یک سطح (به‌جز سطح خیلی کم) باقی ماند، آنگاه مشاهده‌ی آخر متعلق به آن دسته است. برای



شکل ۸. توابع عضویت ۵ گانه برای هر یک از ورودی‌های سیستم استنتاج فازی.



شکل ۶. الگوهای قابل شناسایی بر روی نقشه مرحله اول.



شکل ۷. نمایش وضعیت فرایند بر روی نقشه U-MAT.

برای درک بهتر مطلب، رنگ روشن‌تر موجود در مرز خوشه‌های الگوی بدون انتقال (دسته‌ی صفر) و الگوهای انتقال کوچک، بیانگر این مطلب است که عناصر موجود در این قسمت می‌توانند هم به دسته‌ی صفر و هم به الگوهای انتقال کوچک در میانگین تعلق داشته باشند. با استفاده از این ایده، احتمال تعلق یک عنصر (نورون) به هر یک از الگوها محاسبه می‌شود. برای این منظور ۱۰۰۰۰ داده در هر یک از الگوها تولید می‌شود و نورون‌های برنده برای این داده‌ها محاسبه می‌شوند. با این عمل هر نورون به‌ازای یک یا چند الگو، نورون برنده خواهد بود و با تقسیم تعداد دفعات برنده‌بودن هر نورون در هر الگوی انتقال بر بیشینه‌ی آن، احتمال تعلق هر نورون به هر یک از الگوها محاسبه می‌شود. سپس با واردکردن این احتمال‌ها در یک سیستم استنتاج فازی، می‌توان یک ابزار تصمیم‌گیری برای خروجی‌های شبکه تشکیل داد.

یکی از عمده‌ترین خواص شبکه‌ی خودآراینده، برخورداری از قابلیت نمایش الگوی حرکت فرایند در طی زمان است. با ارائه‌ی هر بردار ورودی به شبکه یک نورون برنده در نقشه مشخص می‌شود؛ و با نمایش این عنصر روی نقشه در طی زمان الگوی حرکتی فرایند به‌خوبی قابل مشاهده خواهد بود. برای مثال، در شکل ۷ مشاهده می‌شود که سه نمونه‌ی اول کاملاً تحت کنترل‌اند ولی از نمونه‌ی چهارم به بعد فرایند به سمت انتقال به‌اندازه‌ی 1σ در متغیر x_1 ، و 1σ در متغیر x_2 متغیر شده است. در بین تحقیقات انجام‌شده در زمینه‌ی استفاده از شبکه‌های عصبی در کنترل آماری فرایند، تاکنون موفق به یافتن روشی برای مشاهده‌ی روند حرکت فرایند در طی زمان (نظیر آنچه که از نمودارهای کنترلی شوهارت می‌توان دریافت) نشده‌ایم.

اتفاق ممکن است ناشی از تأثیر آشناری مراحل بر یکدیگر باشد. با اضافه شدن نوز متراکم در مراحل بالاتر، متوسط طول دنباله تحت کنترل کاهش می‌یابد. همچنین مشاهده می‌شود که در همه‌ی مراحل، متوسط طول دنباله تحت کنترل در روش پیشنهادی بیشتر از تحقیق قبلی است.

۲.۶. متوسط طول دنباله خارج از کنترل


در جداول ۳ و ۴ مقادیر متوسط طول دنباله خارج از کنترل، به‌ارای انتقال‌های متفاوت در میانگین فرایند در روش‌های مختلف ارائه شده است. مشاهده می‌شود که روش پیشنهادی به‌مراتب از قابلیت بالاتری برای کشف انحراف‌های کوچک میانگین فرایند (نسبت به روش‌های دیگر) برخوردار است. همچنین قدرت روش پیشنهادی در کشف انحراف‌های مختلف با تحقیق انجام‌شده‌ی قبلی^[۵] قابل رقابت است؛ هرچند در تحقیق قبلی صرفاً قابلیت کشف انحراف متغیرها در هر مرحله با فرض تحت کنترل بودن متغیرها در مراحل دیگر انجام شده که حالت خاصی از روش پیشنهادی در تحقیق حاضر است. کم‌تر بودن متوسط طول دنباله خارج از کنترل در مراحل بالاتر به‌دلیل افزایش خطای نوع اول شبکه در مراحل بالاتر و در نتیجه کاهش خطای نوع دوم در این مراحل است که موجب کاهش متوسط طول دنباله خارج از کنترل می‌شود.

۳.۶. متوسط طول دنباله برای کشف صحیح طبقه‌ی انتقال

هدف روش پیشنهادی، کشف و طبقه‌بندی صحیح بزرگی انتقال به وجود آمده در میانگین مشخصه‌های کیفی است. با داشتن این اطلاع مفید، کاربر قادر خواهد بود که برحسب تجربه علل خروج از کنترل فرایند را تشخیص دهد. از این رو برای ارزیابی کارایی روش پیشنهادی در این خصوص، شاخص «متوسط طول دنباله برای کشف صحیح طبقه‌ی انتقال» معرفی می‌شود. در جداول ۵ و ۶ و ۷ مشاهده می‌شود که روش ارائه‌شده در مراحل مختلف حداکثر پس از ۲/۵۸۸ داده به‌طور میانگین، طبقه‌ی صحیح انتقال را کشف می‌کند و این حاکی از کارایی خوب روش پیشنهادی در کشف طبقه‌ی انتقال است. کاهش این شاخص با بالاتر رفتن مرحله به‌دلیل ذکر شده‌ی کاهش خطای نوع دوم روش در مراحل بالاتر است.

۷. نتیجه‌گیری

در این تحقیق، برای تشخیص انحراف میانگین یک فرایند چندمتغیره - چندمرحله‌ی، روشی مبتنی بر دیدگاه عصبی - فازی معرفی شده که از قابلیت تشخیص بزرگی انتقال رخ داده در هریک از متغیرها برخوردار است. کارایی این روش با ۳ معیار: متوسط طول دنباله تحت کنترل، متوسط طول دنباله خارج از کنترل و متوسط طول دنباله برای تشخیص دقیق طبقه، سنجیده شده است. روش پیشنهادی توسط یک مثال از فرایند چندمرحله‌ی خودهمبسته با ۲ متغیر و ۳ مرحله که توسط سری زمانی اتورگرسیو مرتبه ۱ شبیه‌سازی شده، ارزیابی شده است. نتایج حاصل از ارزیابی‌ها نشان می‌دهد که روش پیشنهادی نسبت به تحقیقات قبلی انجام‌شده در این زمینه، خصوصاً در شناسایی انحرافات کوچک، کارایی بهتری دارد. همچنین روش ارائه‌شده برخلاف تحقیقات قبلی که به بررسی حالت خاصی از فرایند چندمتغیره با چندمرحله‌ی می‌پرداختند، مسئله‌ی چندمتغیره - چندمرحله‌ی را به‌طور عام در نظر می‌گیرد.



شکل ۹. توابع عضویت هر یک از خروجی‌های سیستم استنتاج فازی.

جدول ۲. مقایسه متوسط طول دنباله‌ی تحت کنترل در روش پیشنهادی با روش انجام‌شده‌ی قبلی.^[۵]

روش انجام‌شده‌ی قبلی	روش پیشنهادی	
۱۸۸/۶۶	۲۳۶/۲۵	مرحله اول
۱۷۸/۹۶	۲۰۶/۴۵	مرحله دوم
۱۵۴/۳۱	۱۷۳/۸۵	مرحله سوم

مثال، اگر احتمال تعلق به دسته‌ی صفر در دو داده‌ی پیاپی در سطح متوسط باقی ماند، مشاهدات به دسته‌ی صفر تعلق دارند.

۲. اگر میزان احتمال تعلق به یک دسته در دو داده‌ی پیاپی کاهش یافت (در صورتی که مشاهده‌ی اول در سطح خیلی زیاد نباشد)، آنگاه مشاهده‌ی آخر به آن دسته تعلق ندارد.

۳. اگر میزان احتمال تعلق به یک دسته در دو داده‌ی پیاپی افزایش یافت، آنگاه مشاهده‌ی آخر به آن دسته تعلق دارد.

راسل و کمبل دریافته‌اند که با افزایش تعداد ورودی‌های سیستم استنتاج فازی، تعداد قوانین بیش از اندازه بزرگ و غیر قابل کنترل می‌شود.^[۳۱] در این تحقیق به‌دلیل این که هر قانون، فقط ۲ عدد از ورودی‌ها را در هر زمان و به‌صورت منحصراً به‌فرد فعال می‌کند، تعداد قوانین بیش از حد به دست نمی‌آید. همچنین قوانین بر روی یک سری از ورودی‌ها، خروجی خاصی را فعال می‌کند که این امر از برهم کنش قوانین و تناقضاتی که بعضاً ممکن است در قوانین با تعداد زیاد رخ دهد، جلوگیری می‌کند.

۹. ارزیابی روش

برای ارزیابی نحوه‌ی عملکرد روش پیشنهادی در این تحقیق از سه معیار: متوسط طول دنباله تحت کنترل، متوسط طول دنباله خارج از کنترل و متوسط طول دنباله برای تشخیص دقیق طبقه‌ی خروجی از کنترل، استفاده شده است.^[۳۲] همچنین نتایج به دست آمده با نتایج تحقیقات انجام‌شده‌ی قبلی^[۳۳] و نیز با نمودار چندمتغیره‌ی هاتلینگ مقایسه شده است.

۱.۶. متوسط طول دنباله تحت کنترل

در جدول ۲ متوسط طول دنباله تحت کنترل در مراحل سه‌گانه‌ی فرایند در روش پیشنهادی با روش انجام‌شده‌ی قبلی ارائه شده است. همان‌طور که از جدول ۲ برمی‌آید با پیش‌روی هر مرحله، متوسط طول دنباله تحت کنترل کاهش می‌یابد. این

جدول ۳. متوسط طول دنباله خارج از کنترل برای روش پیشنهادی و تحقیقات قبلی در مرحله‌ی اول (خطای نوع یک برابر 0.0063 است).

	انتقال میانگین	روش پیشنهادی	روش نیاکي - داودی	روش جن-وانگ	نمودار کنترل چندمتغیره هتالینگ
انتقال کوچک	(۱, ۰)	۱,۴۶۹	۲,۱۱	۲,۲۵۲	۲,۹۲۴
	(۰, ۱)	۱,۴۲۷	۲,۶۵	۱,۴۴۷	۲,۹۳۳
	(-۱, ۰)	۱,۴۴	۲	۲,۶۱۸	۳,۰۱۲
	(۰, -۱)	۱,۴۴۳	۱,۹۵	۲,۷۴	۳,۰۲۱
	(-۱, ۱)	۱,۰۸۳	۱,۳	۱,۴۴۷	۱,۰۸۸
	(۱, -۱)	۱,۰۷۹	۱,۲۷	۱,۳۴۳	۱,۰۸۱
	(-۱, -۱)	۱,۳۸۷	۱,۵	۱,۸۴۵	۳,۰۹۶
	(۱, ۱)	۱,۴۱	۱,۶	۱,۶۲۹	۲,۸۵۷
	میانگین	۱,۳۴۲	۱,۷۹۸	۱,۹۱۱	۲,۵۰۲
	ماکزیمم	۱,۴۶۹	۲,۶۵۰	۲,۷۴۰	۳,۰۹۶
	مینیمم	۱,۰۷۹	۱,۲۷۰	۱,۳۴۳	۱,۰۸۱
انتقال متوسط	(۰, ۲)	۱,۰۳۶	۱,۰۵۰	۱,۰۶۳	۱,۰۱۰
	(۰, -۲)	۱,۰۱۶	۱	۱,۰۷۴	۱,۰۱۳
	(۲, ۰)	۱,۰۵۱	۱,۰۳۰	۱,۰۵۴	۱,۰۱۲
	(-۲, ۰)	۱,۰۳۶	۱	۱,۰۸۱	۱,۰۲۲
	(۱, ۲)	۱,۰۵۰	۱,۰۲۰	۱,۰۵۹	۱,۰۷۴
	(۱, -۲)	۱,۰۰۳	۱,۰۱۰	۱,۰۱۶	۱
	(۲, ۱)	۱,۰۷۱	۱,۰۶۰	۱,۰۵۴	۱,۰۸۱
	(۲, -۱)	۱,۰۰۱	۱	۱,۰۰۹	۱
	(-۱, ۲)	۱	۱	۱,۰۱۳	۱
	(-۱, -۲)	۱,۰۵۶	۱,۰۲۰	۱,۰۸۳	۱,۰۸۱
	(-۲, ۱)	۱,۰۰۱	۱	۱,۰۲۱	۱
	(-۲, -۱)	۱,۰۵۳	۱,۰۲۰	۱,۰۸۸	۱,۰۸۹
	(۲, ۲)	۱,۰۱۴	۱,۰۱۰	۱,۰۲۲	۱,۰۲۲
	(۲, -۲)	۱	۱	۱	۱
	(-۲, ۲)	۱	۱	۱	۱
	(-۲, -۲)	۱,۰۰۸	۱	۱,۰۲۷	۱,۰۱۸
	میانگین	۱,۰۲۵	۱,۰۱۴	۱,۰۴۲	۱,۰۲۶
	ماکزیمم	۱,۰۷۱	۱,۰۶۰	۱,۰۸۸	۱,۰۸۹
	مینیمم	۱	۱	۱	۱
انتقال بزرگ	(۰, ۳)	۱	۱	۱	۱
	۰	۰	۰	۰	۰
	۰	۰	۰	۰	۰
	۰	۰	۰	۰	۰
	(-۴, -۴)	۱	۱	۱	۱
	میانگین	۱	۱	۱	۱
	ماکزیمم	۱	۱	۱	۱
مینیمم	۱	۱	۱	۱	

جدول ۴. مقایسه متوسط طول دنباله خارج از کنترل برای روش پیشنهادی و روش تحقیق قبلی (خطای نوع یک برابر ۰/۰۰۶۳ است).

ب) در مرحله‌ی سوم			الف) در مرحله‌ی دوم			
	انتقال میانگین	روش پیشنهادی	روش نیایکی-داودی	انتقال میانگین	روش پیشنهادی	روش نیایکی-داودی
انتقال کوچک	(۱, ۰)	۱,۳۷۵	۲,۲۹۰	(۱, ۰)	۱,۴۴۳	۲,۲۴۰
	(۰, ۱)	۱,۴۷۵	۲,۵۴۰	(۰, ۱)	۱,۴۴۳	۱,۹۵۰
	(-۱, ۰)	۱,۴۸۶	۲,۵۳۰	(-۱, ۰)	۱,۴۵۰	۲,۵۷۰
	(۰, -۱)	۱,۴۲۹	۲,۵۳۰	(۰, -۱)	۱,۴۲۵	۲,۲۶۰
	(-۱, ۱)	۱,۱۰۲	۱,۲۹۰	(-۱, ۱)	۱,۰۹۵	۱,۲۷۰
	(۱, -۱)	۱,۰۷۷	۱,۱۵۰	(۱, -۱)	۱,۰۹۲	۱,۳۲۰
	(-۱, -۱)	۱,۴۰۷	۱,۶۴۰	(-۱, -۱)	۱,۳۵۴	۱,۶۴۰
	(۱, ۱)	۱,۳۵۰	۲,۲۳۰	(۱, ۱)	۱,۳۸۶	۱,۴۴۰
	میانگین	۱,۳۳۸	۲,۰۲۵	میانگین	۱,۳۳۶	۱,۸۳۶
	ماکزیمم	۱,۴۸۶	۲,۵۴۰	ماکزیمم	۱,۴۵۰	۲,۵۷۰
	مینیمم	۱,۰۷۷	۱,۱۵۰	مینیمم	۱,۰۹۲	۱,۲۷۰
انتقال متوسط	(۰, ۲)	۱,۰۲۹	۱,۰۲۰	(۰, ۲)	۱,۰۲۴	۱,۰۴۰
	(۰, -۲)	۱,۰۳۷	۱,۰۲۰	(۰, -۲)	۱,۰۳۰	۱,۰۵۰
	(۲, ۰)	۱,۰۱۴	۱,۰۵۰	(۲, ۰)	۱,۰۲۲	۱,۰۸۸
	(-۲, ۰)	۱,۰۳۷	۱,۰۴۰	(-۲, ۰)	۱,۰۲۱	۱,۰۲۰
	(۱, ۲)	۱,۰۵۰	۱,۰۶۰	(۱, ۲)	۱,۰۵۳	۱,۰۲۰
	(۱, -۲)	۱,۰۰۱	۱	(۱, -۲)	۱,۰۰۲	۱
	(۲, ۱)	۱,۰۵۴	۱,۰۷۰	(۲, ۱)	۱,۰۶۵	۱,۰۷۰
	(۲, -۱)	۱,۰۰۱	۱,۰۱۰	(۲, -۱)	۱,۰۰۲	۱
	(-۱, ۲)	۱,۰۰۳	۱,۰۱۰	(-۱, ۲)	۱	۱
	(-۱, -۲)	۱,۰۶۰	۱,۰۳۰	(-۱, -۲)	۱,۰۴۹	۱,۰۲۰
	(-۲, ۱)	۱,۰۰۳	۱	(-۲, ۱)	۱,۰۰۲	۱
	(-۲, -۱)	۱,۰۷۱	۱,۰۷۰	(-۲, -۱)	۱,۰۴۸	۱,۰۵۰
	(۲, ۲)	۱,۰۱۱	۱,۰۲۰	(۲, ۲)	۱,۰۱۷	۱
	(۲, -۲)	۱	۱	(۲, -۲)	۱	۱
	(-۲, ۲)	۱	۱	(-۲, ۲)	۱	۱
	(-۲, -۲)	۱,۰۱۱	۱	(-۲, -۲)	۱,۰۱۱	۱
	میانگین	۱,۰۲۴	۱,۰۲۵	میانگین	۱,۰۲۲	۱,۰۲۲
	ماکزیمم	۱,۰۷۱	۱,۰۷۰	ماکزیمم	۱,۰۶۵	۱,۰۸۸
	مینیمم	۱	۱	مینیمم	۱	۱
انتقال بزرگ	(۰, ۳)	۱,۰۰۰	۱,۰۰۰	(۰, ۳)	۱	۱
	۰	۰	۰	۰	۰	۰
	۰	۰	۰	۰	۰	۰
	۰	۰	۰	۰	۰	۰
	(-۴, -۴)	۱,۰۰۰	۱,۰۰۰	(-۴, -۴)	۱	۱
	میانگین	۱,۰۰۰	۱,۰۰۰	میانگین	۱	۱
	مینیمم	۱,۰۰۰	۱,۰۰۰	مینیمم	۱	۱

جدول ۵. متوسط طول دنباله برای کشف صحیح طبقه‌ی انتقال در مرحله‌ی اول.

X_1	-۴	-۳	-۲	-۱	۰	۱	۲	۳	۴	ماکزیم	مینیم	میانگین
X_2												
-۴	۲,۰۸۷	۲,۱۶۵	۲,۲۲۴	۲,۱۷	۲,۲۲۸	۲,۱۹۲	۲,۱۹۶	۲,۳۳۷	۲,۱۳۳	۲,۳۳۷	۲,۰۸۷	۲,۱۹۲
-۳	۲,۲۷۵	۲,۲۹۷	۲,۲۷۵	۲,۲۶۸	۲,۲۶۱	۲,۲۰۸	۲,۳۴۳	۲,۲۵۳	۲,۴۰۷	۲,۴۰۷	۲,۲۵۳	۲,۲۹۹
-۲	۲,۲۳۴	۲,۲۵۹	۲,۲۹۱	۲,۱۴۱	۲,۲۵۵	۲,۲۷۹	۲,۲۲۶	۲,۲۳۵	۲,۱۸	۲,۲۹۱	۲,۱۴۱	۲,۲۳۳
-۱	۲,۲۳۶	۲,۲۴	۲,۱۴۸	۱,۸۱	۱,۶۵۷	۲,۰۵۱	۲,۲۶۷	۲,۳۰۱	۲,۲۱۳	۲,۳۰۱	۱,۶۵۷	۲,۱۰۳
۰	۲,۱۹۶	۲,۳۲۳	۲,۱۹۴	۱,۶۹۱		۱,۷۹۱	۲,۲۰۸	۲,۲۹۲	۲,۲۴۶	۲,۳۲۳	۱,۶۹۱	۲,۱۱۸
۱	۲,۱۷۳	۲,۲۹۹	۲,۲۳۵	۲,۱۴۳	۱,۷۲۸	۱,۷۴۲	۲,۲۱	۲,۲۵۱	۲,۱۶۹	۲,۲۹۹	۱,۷۲۸	۲,۱۰۶
۲	۲,۲۱۹	۲,۲۹۴	۲,۳۲۱	۲,۲۲۶	۲,۲۶۳	۲,۱۰۹	۲,۳۹۴	۲,۳۳۸	۲,۲۰۱	۲,۳۹۴	۲,۱۰۹	۲,۲۶۳
۳	۲,۲۴۱	۲,۲۴۱	۲,۳۳۳	۲,۳۳۴	۲,۲۱۷	۲,۲۶۶	۲,۲۸۵	۲,۳۲۶	۲,۱۶۴	۲,۳۳۴	۲,۱۶۴	۲,۲۶۷
۴	۲,۱۹۸	۲,۵۸۸	۲,۱۶۵	۲,۲۳۶	۲,۲۲۵	۲,۱۴۵	۲,۱۸۷	۲,۲۱۷	۲,۱۹	۲,۵۸۸	۲,۱۴۵	۲,۲۳۹
ماکزیم	۲,۲۷۵	۲,۵۸۸	۲,۳۳۳	۲,۳۳۴	۲,۲۶۳	۲,۳۰۸	۲,۳۹۴	۲,۳۳۸	۲,۴۰۷	۲,۵۸۸		
مینیم	۲,۰۸۷	۲,۱۶۵	۲,۱۴۸	۱,۶۹۱	۱,۶۵۷	۱,۷۴۲	۲,۱۸۷	۲,۲۱۷	۲,۱۳۳		۱,۶۵۷	
میانگین	۲,۲۰۷	۲,۳۰۱	۲,۲۴۳	۲,۱۱۳	۲,۱۰۴	۲,۰۹۸	۲,۲۵۷	۲,۲۸۳	۲,۲۱۱			۲,۲۰۲

جدول ۶. متوسط طول دنباله برای کشف صحیح طبقه‌ی انتقال در مرحله‌ی دوم.

X_1	-۴	-۳	-۲	-۱	۰	۱	۲	۳	۴	ماکزیم	مینیم	میانگین
X_2												
-۴	۲,۲۴۵	۲,۲۱	۲,۲۱۹	۲,۱۵۸	۲,۲۲۱	۲,۲۳۳	۲,۱۴۵	۲,۳۹۸	۲,۱۵۲	۲,۳۹۸	۲,۱۴۵	۲,۲۲۰
-۳	۲,۲۲۹	۲,۲۳۲	۲,۲۴۱	۲,۲۳	۲,۳۱۱	۲,۲۷۷	۲,۲۴۳	۲,۲۹۵	۲,۳۵۱	۲,۳۵۱	۲,۲۲۹	۲,۲۶۸
-۲	۲,۱۹۸	۲,۳۱۵	۲,۲۸۹	۲,۲۳۳	۲,۲۸۱	۲,۳۳۱	۲,۲۵۴	۲,۲۱	۲,۲۲۳	۲,۳۳۱	۲,۱۹۸	۲,۲۵۹
-۱	۲,۱۴۱	۲,۲۵۴	۲,۱۶۵	۱,۷۵۴	۱,۷۹۲	۲,۱۳۳	۲,۲۴۸	۲,۲۸۱	۲,۱۹۷	۲,۲۸۱	۱,۷۵۴	۲,۱۰۷
۰	۲,۱۸۲	۲,۲۹۵	۲,۲۱۹	۱,۷۲۹		۱,۷۴۱	۲,۱۹۲	۲,۲۹۲	۲,۱۵۵	۲,۲۹۵	۱,۷۲۹	۲,۱۰۱
۱	۲,۳۱۳	۲,۲۲۲	۲,۲۴۳	۲,۱۱۶	۱,۶۶۷	۱,۷۵۷	۲,۱۹۵	۲,۲۵۶	۲,۲۰۷	۲,۳۱۳	۱,۶۶۷	۲,۱۰۸
۲	۲,۱۷۷	۲,۱۹۳	۲,۲۴۸	۲,۲۵۷	۲,۱۹۵	۲,۱۲	۲,۳۳۳	۲,۲۴۴	۲,۲۱	۲,۳۳۳	۲,۱۲	۲,۲۲۰
۳	۲,۵۰۴	۲,۳۰۸	۲,۲۷۹	۲,۲۹	۲,۲۹۲	۲,۲۶۶	۲,۳۰۴	۲,۲۴۷	۲,۲۱۴	۲,۵۰۴	۲,۲۱۴	۲,۳۰۰
۴	۲,۱۵۴	۲,۲۷۶	۲,۲۴۲	۲,۲۳۳	۲,۱۵۶	۲,۲۳۵	۲,۱۹۶	۲,۲۴۷	۲,۰۷۱	۲,۲۷۶	۲,۰۷۱	۲,۲۰۱
ماکزیم	۲,۵۰۴	۲,۳۱۵	۲,۲۸۹	۲,۲۹	۲,۳۱۱	۲,۳۳۱	۲,۳۳۳	۲,۳۹۸	۲,۳۵۱	۲,۵۰۴		
مینیم	۲,۱۴۱	۲,۱۹۳	۲,۱۶۵	۱,۷۲۹	۱,۶۶۷	۱,۷۴۱	۲,۱۴۵	۲,۲۱	۲,۰۷۱		۱,۶۶۷	
میانگین	۲,۲۳۸	۲,۲۵۶	۲,۲۳۸	۲,۱۱۱	۲,۱۱۴	۲,۱۲۱	۲,۲۳۴	۲,۲۷۴	۲,۱۹۸			۲,۱۹۸

جدول ۷. متوسط طول دنباله برای کشف صحیح طبقه‌ی انتقال در مرحله‌ی سوم.

X_1	-۴	-۳	-۲	-۱	۰	۱	۲	۳	۴	ماکزیم	مینیم	میانگین
X_2												
-۴	۲,۲۱۷	۲,۲۴۴	۲,۱۹۸	۲,۱۴۷	۲,۲۴۶	۲,۲۰۸	۲,۱۶۴	۲,۴۱۳	۲,۱۵	۲,۴۱۳	۲,۱۴۷	۲,۲۲۱
-۳	۲,۲۴۲	۲,۲۹۳	۲,۲۶۹	۲,۲۸۴	۲,۲۷۸	۲,۲۶۴	۲,۲۷۱	۲,۳۶۱	۲,۳۲۸	۲,۳۶۱	۲,۲۴۲	۲,۲۸۸
-۲	۲,۱۵۹	۲,۲۳۳	۲,۳۰۵	۲,۰۸۸	۲,۱۷۳	۲,۳۴	۲,۲۰۹	۲,۲۶	۲,۱۶۴	۲,۳۴	۲,۰۸۸	۲,۲۱۵
-۱	۲,۱۱۴	۲,۲۸	۲,۱۴۳	۱,۷۵۲	۱,۷۷۳	۲,۱۲۷	۲,۲۷۵	۲,۲۷	۲,۲۳	۲,۲۸	۱,۷۵۲	۲,۱۰۷
۰	۲,۲۱۳	۲,۲۷	۲,۱۶۶	۱,۷۹۱		۱,۶۱۲	۲,۱۶۴	۲,۳۰۲	۲,۱۸۲	۲,۳۰۲	۱,۶۱۲	۲,۰۸۸
۱	۲,۲۱۷	۲,۳۰۱	۲,۳۱۸	۲,۱۴۳	۱,۷۹۱	۱,۷۳۹	۲,۲۲۲	۲,۲۹۶	۲,۱۸۲	۲,۳۱۸	۱,۷۳۹	۲,۱۳۴
۲	۲,۲۰۶	۲,۲۹۸	۲,۲۳۹	۲,۳۱۱	۲,۱۸۹	۲,۱۳۲	۲,۳۸۷	۲,۳۰۱	۲,۱۹۲	۲,۳۸۷	۲,۱۳۲	۲,۲۵۱
۳	۲,۲۵۹	۲,۲۹۱	۲,۲۵۵	۲,۲۲۹	۲,۲۸۵	۲,۲۳۶	۲,۳۰۴	۲,۲۴۱	۲,۲۵۳	۲,۳۰۴	۲,۲۲۹	۲,۲۶۱
۴	۲,۱۹۵	۲,۵۰۴	۲,۳۵۱	۲,۲۳۶	۲,۲۱۷	۲,۱۶۸	۲,۲۲۸	۲,۱۵۴	۲,۲۰۷	۲,۵۰۴	۲,۱۵۴	۲,۲۵۱
ماکزیم	۲,۲۵۹	۲,۵۰۴	۲,۳۵۱	۲,۳۱۱	۲,۲۸۵	۲,۳۴	۲,۳۸۷	۲,۴۱۳	۲,۳۲۸	۲,۵۰۴		
مینیم	۲,۱۱۴	۲,۲۳۳	۲,۱۴۳	۱,۷۵۲	۱,۷۷۳	۱,۶۱۲	۲,۱۶۴	۲,۱۵۴	۲,۱۵		۱,۶۱۲	
میانگین	۲,۲۰۲	۲,۳۰۲	۲,۲۴۹	۲,۱۰۹	۲,۱۱۹	۲,۰۹۲	۲,۲۴۷	۲,۲۸۹	۲,۲۱۰			۲,۲۰۲

پانوشت

1. Self Organizing Maps (SOM)
2. clustering
3. Cumulative Sum (CUSUM)
4. Multivariate Cumulative Sum (MCUSUM)
5. pipeline
6. Cause-Selecting Chart (CSC)
7. Multiple Cause-Selecting Chart
8. Control Chart Patterns (CCP)
9. Special-purpose CCP recognition
10. error back propagation
11. Average Run length (ARL)
12. learning vector quantization
13. multi-layer feed forward networks
14. Best Matching Unit (BMU)
15. fuzzifier
16. defuzzifier
17. fuzzy knowledge-base
18. output aggregation
19. vector autoregressive moving average
20. white noise
21. auto regressive
22. vector auto regressive
23. sequential control
24. trade-off
25. expert system
26. observed data
27. pi-membership function

منابع

1. Hotteling, H. Multivariate Quality Control in Techniques of statistical Analysis, edited by Eisenhart, Hastay and Walls, McGraw-Hill, New York, N.Y. (1947).
2. Woodall, W.H. and Ncube, M.M. "Multivariate CUSUM quality control procedures", *Technometrics*, **27**, pp. 285-292 (1985).
3. Lowry, C.A.; Woodall, W.H.; Champ, C.W. and Rigdon, S.E. "A multivariate exponentially weighted moving average control chart", *Technometrics*, **34**, pp. 46-53 (1992).
4. Cenk, Undey and Cinar, A. "Statistical monitoring of multistage, multiphase batch process", *IEEE Control System Magazine*, pp. 40-53 (2002).
5. Davoudi, M. "Designing a multi-stage-quality control system using artificial neural networks" Master of Science thesis, Dept. of Industrial Engineering, Sharif University of Technology, (2006).
6. Zhang, G.X. Cause-Selecting Control Chart and Diagnosis, Theory and Practice, Aarhus School of Business, Department of Total Quality Management, Aarhus, Denmark, (1992).
7. Chang, S.I. and Aw, C.A., "A neural fuzzy control chart for detecting and classifying process mean shifts", *International Journal of Production Research*, **34**, pp. 2265-2278 (1996).
8. Cheng, C.S. "A multi-layer neural network model for detecting changes in the process mean", *Computers & Industrial Engineering*, **28**, pp. 51-61 (1995).
9. Hwang, H.B. "Proper and effective training of a pattern recognizer for cyclic data", *IIE Transactions*, **27**, pp. 746-756 (1996).
10. Pham, D.T. and Oztemel, E. "Control chart pattern recognition using neural networks", *Journal of Systems Engineering*, **2**, pp. 256-262 (1992).
11. Pham, D.T. and Oztemel, E. "Control chart pattern recognition using learning vector quantization networks", *International Journal of Production Research*, **32**, pp. 721-729 (1994).
12. Hwang, H.B. and Hubele, N.F. "X-bar control chart pattern identification through efficient off-line neural network training", *IIE Transactions*, **25**, pp. 27-40 (1993a).
13. Hwang, H.B. and Hubele, N.F. "Back-propagation pattern recognizers for X-bar control chart: methodology and performance", *Computers & Industrial Engineering*, **24**, pp. 219-35 (1993b).
14. Guh, R.S. and Tannock, J.D.T. "Recognition of control chart concurrent patterns using a neural network approach", *International Journal of Production Research*, **37**, pp. 1743-1765 (1999).
15. Guh, R.S.; Tannock, J.D.T.; and O'Brien, C. "Intelli-SPC, a hybrid intelligent tool for on-line economical statistical process control", *Expert Systems with Applications*, **17**, pp. 195-212 (1999).
16. Haykin, S. Neural Networks, a comprehensive foundation, Prentice Hall, Englewood Cliffs, N.J., (1998).
17. Kohonen, T. Self- Organizing Maps, Springer series in Information Sciences, 3rd ed., Springer, Berlin, Heidelberg, New York, (2001).
18. Kohonen, T. Automatic formation of topological maps of patterns in a self-organizing system, Oja, E. and Simula, O. (Eds), Proceedings of 2SCIA, Scand. Conference on Image Analysis, Helsinki, Finland, pp. 182-185, (1984).
19. Kohonen, T.; Makisara, K.; and Saramaki, T. "Phonetic maps-insightful representation of phonological features for speech recognition", In Proceedings of 7ICPR, International Conference on Pattern Recognition, Los Alamitos, CA. IEEE Computer Soc. Press, pp. 182-185 (1984).
20. Vesanto, J. Data mining techniques based on the Self-Organizing Map, MS Thesis, Helsinki university of Technology, (1997).
21. Vesanto, J. "SOM-based data visualization methods", *Intelligent Data Analysis Journal*, **3**, pp. 111-126 (1999).
22. Simula, O.; Alhoniemi, E.; Hollmen, J.; and Vessanto, J. "Monitoring and modeling of complex processes using hierarchical SOM", *Proceedings of the IEEE Introduction Symposium on Circuits and Systems*, pp. 73-76 (1996).
23. Simula, O.; Vesanto, J.; and Vasara, P. "Analysis of industrial systems using the self-organizing map", *Proceedings of the integration Conference on knowledge-based Intelligent System*, Adelaide, Australia, pp. 61-68 (1998).
24. Trakesh, H. Bijari, M., and Ebranimi, A., "Analysing the time-effect of different input of high-furnace on the quality of grey iron", Technical report, (4086), The Soft-Computing Group, Dept. of Ind. Eng., (2005).
25. Parviainen, J.K., Data mining for Finding in Surface Defects in Strips, BS Thesis, Helsinki university of Technology, (2000).
26. Kiviluoto, K.; Bergius, P. and Maarancan, J. Neural Networks for Analysis of Financial Statements, Singapore, Lisboa, P., Edisbury, B. & Vellido, A. (Eds), Business Applications of Neural Networks, World Scientific, pp. 73-84, (2000).

27. Kohonen, T.; Oja, E.; Simula, O.; Visa, A.; and Kangas, J. "Engineering applications of the self-organizing map", *Proceedings of IEEE*, **84**, pp. 1258-1284 (1996).
28. Kosko, B. *Neural Networks and Fuzzy Systems*, Prentice-Hall, Englewood Cliffs, N.J., (1992).
29. Anderson, T.W. *The statistical analysis of time series*, John Wiley & Sons, INC., New York, (1994).
30. Deler, B. and Nelson, B.L. "Modeling and generating multivariate time series with arbitrary marginals and autocorrelation structures", *Proceedings of the Winter Simulation Conference*, (2001).
31. Russel, S.O., and Campbell, P.F. "Reservoir operating rules with fuzzy programming", *J. Water Resource Plan Management*, **123**, pp. 165-170 (1996).
32. Montgomery, D.C. *Introduction to Statistical Quality Control*, 5th edition, John Wiley and Sons, New York, N.Y., U.S.A., (2005).
33. Wang, T.Y. and Chen, L.H. "Mean shifts detection and classification in multivariate processes: a neural-fuzzy approach", *Journal of Intelligent Manufacturing*, **13**, pp. 211-221 (2002).