



## مروری کاربردی بر طرح‌های پایش مدیریت فرآیندهای چندمتغیره

کریم آتشگر (نویسنده مسؤل)

استادیار مجتمع مهندسی صنایع دانشگاه مالک اشتر

Email: Atashgar@iust.ac.ir

کاظم نقدریان

استادیار دانشکده مهندسی صنایع دانشگاه علم و صنعت ایران

تاریخ دریافت: ۹۰/۶/۱۱ \* تاریخ پذیرش: ۹۱/۲/۱۰

### چکیده

زمانی که بواسطه عوامل ناخواسته و غیر ذاتی، تغییری در پارامترهای توزیع یک فرآیند ظاهر می شود و فرآیند از شرایط تحت کنترل به شرایط خارج از کنترل منتقل می گردد، تجزیه و تحلیل ریشه ی و شناسایی عامل و یا عوامل انحراف فرآیند فوق برای مدیران فرآیند اهمیت زیادی دارد. در صورت تحقق شرایط خارج از کنترل در یک فرآیند چند متغیره، تجزیه و تحلیل برای شناسایی عوامل انحراف در مقایسه با یک فرآیند تک متغیره بسیار سخت تر و پیچیده تر می گردد. در یک فرآیند چند متغیره که در شرایط خارج از کنترل قرار دارد، زمانی می توان به یک تجزیه و تحلیل ریشه ی و اثربخش امید داشت که مدل بکارگرفته شده برای پایش فرآیند، علاوه بر قابلیت شناسایی شرایط خارج از کنترل، بتواند به طور همزمان نقطه تغییر فرآیند، عامل و یا عواملی را که باعث انحراف فرآیند شده است را به همراه جهت تغییر تحمیل شده به آن فرآیند را شناسایی نماید. بررسی ها در ادبیات موضوع نشان می دهد، که هرچند رویکرد آماری در فرآیندهای تک متغیره نسبتاً اثربخش ظاهر شده است، ولی رویکرد آماری در فرآیندهای چند متغیره تاکنون نتوانسته است نیاز فوق را برای مدیران فرآیند تامین نماید. بررسی ادبیات پایش فرآیندها مؤید این مهم است که روشهای محاسبات نرم مانند شبکه های عصبی توانسته است به نیاز اساسی مدیران فرآیند در پایش و شناسایی عوامل انحراف به صورت اثربخش تری پاسخ دهد. بطوریکه، در میان طرح های موجود در ادبیات موضوع، فقط یک مدل جامع پیشنهادی وجود دارد که توانسته با استفاده از رویکرد شبکه عصبی در تئوری نشان دهد که می تواند با شناسایی چهار عامل کلیدی فوق مهندسی کیفیت و مدیران فرآیند را در ریشه یابی اثربخش عوامل انحراف در فرآیندهایی با بیش از یک متغیر یاری نماید. در این تحقیق با رویکرد کاربردی، مروری نسبتاً جامع که بتواند برای محققان و مدیران فرآیند قابل استفاده باشد، مدل های پایش فرآیندهای چند متغیره بررسی می شود. به علاوه، از آنجایی که هنگامی محققان زمانی می توانند به توسعه مدل های پیشنهادی تئوریک همت گمارند که قابلیت بکارگیری طرح ها، در مقایسه با روش های سنتی و معمول، در عرصه های واقعی فرآیندها نیز به اثبات رسیده باشد، در این تحقیق پس از مرور ادبیات، کامل ترین و جامع ترین مدل های موجود انتخاب و در یکی از فرآیندهای واقعی تولید خودرو بکارگرفته شده است. تجزیه و تحلیل داده ها و نتایج حاصل از عملکرد مدل فوق، برای ریشه یابی و تشخیص علت واقعی شرایط خارج از کنترل فرآیند و مقایسه آن با یکی از مدل های مرسوم بر اساس شاخص مهم طول دنباله خارج از کنترل، در این مقاله مورد توجه قرار گرفته است.

**واژه‌های کلیدی:** نقطه تغییر، پایش فرآیند، تجزیه و تحلیل ریشه‌ی، نمودار، متوسط طول دنباله.

## ۱- مقدمه

زمانی که یک نمودار کنترل شرایط خارج از کنترل را برای فرآیندی تک متغیره و یا چند متغیره نشان می دهد، از نمودار کنترلی فوق نمی توان زمان واقعی شروع تغییر در فرآیند را استنباط نمود. به علاوه، امکان تشخیص عامل و یا عواملی که موجب انحراف فرآیند چند متغیره شده اند نیز در نمودار فوق وجود ندارد. به عبارت دیگر، زمانی که با استفاده از سیگنال های موجود در نمودار کنترل، خارج از کنترل آماری بودن فرآیند استنتاج می گردد، فقط وجود یک خرابی غیر تصادفی بعنوان عامل اصلی شرایط خارج از کنترل بودن فرآیند، به اثبات می رسد. زمانی را که واقعاً فرآیند بواسطه عامل خرابی به شرایط خارج از کنترل منتقل می شود، با عنوان نقطه تغییر<sup>۱</sup> شناخته می شود. هر چند که در فرآیندهای تک متغیره که در آن فقط یک مشخصه کیفی کنترل می شود، شناسایی نقطه تغییر یک گام بسیار اساسی و تعیین کننده در شناسایی عامل اصلی خرابی در فرآیند می باشد، ولی در فرآیندهایی که با بیش از یک مشخصه کیفی با ضریب همبستگی غیر صفر، تحت کنترل آماری قرار می گیرد، شناسایی نقطه تغییر به تنهایی، بدون تشخیص<sup>۲</sup> مشخصه (یا مشخصه های) کیفی که موجب انحراف فرآیند شده است، نمی تواند مدیران فرآیند را بسوی یک تجزیه و تحلیل اثربخش هدایت نماید. به علاوه، شناسایی جهت تغییر نیز در تجزیه و تحلیل ریشه ی<sup>۳</sup> یک فرآیند بویژه در فرآیندهای چند متغیره خارج از کنترل، مؤلفه ی با اهمیت و تأثیرگذار محسوب می گردد. بررسی ادبیات موضوع و گزارشات ارائه شده توسط محققین نشان می دهد که هرچند اهمیت بررسی همه جانبه یک فرآیند چند متغیره خارج از کنترل مورد توجه و تأکید قرار گرفته است، ولی مدل های پیشنهادی ارائه شده کمتر توانسته تمامی ابعاد مورد نیاز مدیران فرآیند را برای یک تجزیه و تحلیل ریشه ایی اثربخش در فرآیندهای واقعی پوشش دهد.

در این مقاله پس از بررسی جامع طرح های پیشنهادی پایش فرآیندهای چند متغیره که در منابع معتبر گزارش شده است، جامع ترین مدل پیشنهادی در ادبیات برای کنترل فرآیند تولید بدنه یک نوع خودرو لوکس که در یکی از کارخانجات ایران تولید می شود، انتخاب و با بکارگیری آن در عرصه اجرا، قابلیت های آن برای یافتن عوامل غیر تصادفی، ارزیابی شده و عملکرد آن بر اساس شاخص متوسط طول دنباله خارج از کنترل<sup>۴</sup> با یکی از طرحهای مرسوم که معمولاً در فرآیندهای تولید بکارگرفته می شود، مقایسه می شود.

در بخش بعدی این مقاله به بررسی طرح های پایش فرآیندهای چند متغیره، که در مراجع معتبر توسط محققین پیشنهاد شده است، پرداخته می شود و پس از مقایسه قابلیت های آنها، جامع ترین مدل موجود در ادبیات موضوع انتخاب می گردد. در فصل سوم ضمن به تصویر کشیدن فرآیند واقعی مورد مطالعه، گزارش عملکرد مدل گزینش شده در فرآیند تولید بدنه خودرو تشریح و با یکی از طرح های مرسوم مقایسه می شود. آخرین فصل انعکاس دهنده نتایج حاصل از تحقیق ارائه شده می باشد. در ادبیات موضوع، موضوعات مرتبط با پایش و تجزیه و تحلیل فرآیندهای چند متغیره در سر فصل های زیر مورد بررسی قرار می گیرد:

الف- نمودارهای کنترل

ب- نقطه تغییر

ج- تشخیص عامل تغییر

نمودارهای کنترل فرآیندهای چند متغیره تاریخ علمی خود را با نمودار کنترل  $T^2$  هاتلینگ (Hotelling, 1947) آغاز می کند. هاتلینگ (Hotelling, 1947) پایش فرآیندهای چند متغیره را وارد فضای جدیدی نمود، به طوری که با پیشنهاد فوق، امکان پایش فرآیندهای چند متغیره با ملاحظه واقعیت رابطه کوواریانس بین مشخصه های کیفی در فرآیندهای چند متغیره فراهم آمد و رویکرد استفاده از چند نمودار تک متغیره که در فرآیندهای چند متغیره بدون ملاحظه واقعیت کوواریانس آنها پیشنهاد می شد، پشت سر نهاده شد. در روش هاتلینگ (Hotelling, 1947) اگر بجای  $\mu$  و  $\Sigma$  که به ترتیب نشان دهنده بردار میانگین و

<sup>1</sup>. Change point

<sup>2</sup>. Diagnose

<sup>3</sup>. Root cause analysis

<sup>4</sup>. Out-of-control average run length (ARL)

ماتریس کوواریانس می باشند از برآورد کننده های نارایب آنها یعنی  $\bar{X}$  و  $S$  استفاده گردد، آنگاه آماره  $T^2$  بصورت زیر می باشد:

$$T_i^2 = n (\bar{X}_i - \bar{X})' S^{-1} (\bar{X}_i - \bar{X}) \quad (1)$$

طرح پیشنهادی فوق اشکالات نمودارهای تک متغیره شوهارت را نیز در ذات خود به همراه داشت. بعبارت دیگر، سیگنال های نمودار کنترلی هاتلینگ (Hotelling, 1947) با استفاده از اطلاعات موجود در آخرین نمونه جمع آوری شده از فرآیند، در صفحه نمودار ظاهر می شود و آماره  $T^2$  فقط از طریق اطلاعات نمونه آخر محاسبه می شود، لذا این مهم باعث می شود تا نمودار  $T^2$  نیز مانند نمودارهای تک متغیره شوهارت نسبت به تغییرات کوچک و متوسط حساسیت های لازم را از خود نشان ندهد. برای غالب آمدن بر این نقطه ضعف نمودارهای کنترول جمع تجمعی چند متغیره<sup>۵</sup> و نمودارهای متحرک موزون نمایی چند متغیره<sup>۶</sup> از سوی محققین پیشنهاد گردید. محققین متعددی طرح های پیشنهادی خود را بر اساس نمودارهای فوق ارائه کردند. نمودارهای جمع تجمعی چند متغیره به دو گروه اصلی تقسیم می شوند. گروه اول طرحهایی هستند که جهت تغییر (یا تغییرات) را معلوم فرض می کنند<sup>۷</sup> و گروه دوم جهت تغییر را معلوم فرض نمی کند<sup>۸</sup>. "وودال" و "ان کیوبی" Woodall, & Ncube, (1985) با فرض معلوم بودن جهت تغییر، نشان دادند که چگونه یک فرآیند نرمال با  $p$  متغیر را می توان با استفاده از  $p$  نمودار جمع تجمعی تک متغیره پایش نمود. آنها همچنین نشان دادند همین روش را می توان برای  $p$  عنصر اصلی<sup>۹</sup> فرآیند نیز بکار برد. در این روش برای کنترول میانگین هریک از مشخصه های کیفی فرآیند، از یک نمودار کنترول جمع تجمعی تک متغیره دو طرفه استفاده می گردد. در این روش زمانی که حداقل یکی از نمودارها اعلام هشدار دهد، فرآیند خارج از کنترول اعلام می گردد. بدین ترتیب احتمال خطای نوع اول روش جمع تجمعی تک متغیره چندگانه از احتمال خطای نوع اول هر یک از نمودارها بیشتر است. در این روش علاوه بر ثابت نبودن احتمال خطای نوع اول، ساختار همبسته متغیرها نیز نادیده گرفته شده است. "هیلی" (Healy, 1985) با استفاده از این واقعیت که می توان نمودارهای جمع تجمعی را بعنوان آزمون های نسبت احتمال پی در پی در نظر گرفت، یک نمودار MCUSUM پیشنهاد نمود. در این روش اندازه تغییر نیز از قبل معلوم می باشد. "هاوکینز" (Hawkins, 1991) نیز با فرض دانستن جهت تغییر، نمودارهای جمع تجمعی را برای متغیرهای رگرسیون تنظیم شده<sup>۱۰</sup> با این پیش فرض ارائه داد که در بیشتر موارد اجرایی، فرآیندها با ساختار شناخته شده ی از حالت تحت کنترول، تغییر شرایط می دهند. اما "کرایزر" (Crosier, 1988) بدون دانسته فرض کردن جهت تغییر دو طرح MCUSUM پیشنهاد کرد. اولین طرح او بر مبنای ریشه دوم آماره  $T^2$  هاتلینگ بود و دومین طرح پیشنهادی او از جایگزینی مقادیر اسکالر در روش جمع تجمعی تک متغیره با بردارها بدست می آید. "پیگناتیلو" و "رانگر" (Pignatillo & Runger, 1990) نیز برای روش جمع تجمعی چند متغیره دو طرح ارائه دادند که جهت تغییر را دانسته فرض نمی کنند. طرح اول آنها شبیه طرح اول "کرایزر" (Crosier, 1988) می باشد. "پیگناتیلو" و "رانگر" (Pignatillo & Runger, 1990) نمودار طرح دوم خود را بر اساس آزمونهای نسبت احتمال پی در پی طراحی کردند و عملکرد طرح تنها به واسطه پارامتر غیر مرکزی  $\lambda$  به پارامترهای حالت خارج از کنترول وابسته است. نمودار ارائه شده توسط آنها که  $MC_i$  نام دارد، آماره زیر را جهت کنترول میانگین فرآیند معرفی نموده است:

$$MC_i = \max \{ [D_i' \Sigma_0^{-1} D_i]^{1/2} - kn_i, 0 \}, \quad i = 1, 2, 3, \dots \quad (2)$$

که در رابطه فوق،  $MC_0 = 0$ ،  $k$  پارامتر نمودار  $MC_i$  می باشد و  $n_i$  تعداد مشاهدات اخیر در نمودار CUSUM می باشد. به

5. Multivariate Cumulative Sum (MCUSUM)

6. Multivariate Exponentially Weighted Moving Average (MEWMA)

7. Direction-specific schemes

8. Directionally invariant schemes

9. Principal component

10. Regression-adjusted variables

طوری که:

$$n_i = \begin{cases} n_{i-1} + 1 & \text{if } MC_{i-1} > 0 \\ 1 & \text{otherwise} \end{cases} \quad (۳)$$

$$D_i = \sum_{j=i-n+1}^i (X_j - \mu_0) \quad (۴)$$

برای استفاده از نمودارهای MCUSUM، "ان گی" و "زنگ" (Ngai & Zhang, 2001) نیز یک نمودار دو طرفه MCUSUM برای کنترل میانگین در فرآیند چند متغیره ارائه دادند. لازم بذکر است که، "رانگر" و "تستیک" (Runger & Testik, 2004) در مقاله خود مزیتها و نقاط ضعف هریک از طرحهای ارائه شده MCUSUM را بررسی و ارتباط میان آنها را نیز بررسی کرده‌اند.

نمودارهای میانگین متحرک موزون نمایی چند متغیره دومین گروه از طرحهایی است که برای برطرف کردن نقطه ضعف نمودار هاتلینگ (Hotelling, 1947) ارائه گردید. "لوری" و همکاران (Lowry et al. 1992) یک نمودار MEWMA به صورت زیر پیشنهاد کردند:

$$Z_i = \mathbf{R}X_i + (\mathbf{I} - \mathbf{R}) Z_{i-1} = \sum_{j=1}^i \mathbf{R}(\mathbf{I} - \mathbf{R})^{i-j} X_j, \quad i=1,2,3,\dots \quad (۵)$$

در این رابطه  $X_i$  بردار مشاهدات انفرادی به ازاء نمونه  $i$  ام و  $\mathbf{R}$  ماتریس قطری اوزان نمایی است که مؤلفه  $r_j$  قطر اصلی آن یعنی  $r_j$  معرف وزن متناظر با مشخصه کیفی  $j$  ام می باشد:

$$\mathbf{R} = \text{diag}(r_1, r_2, r_3, \dots, r_p), \quad 0 < r_j \leq 1, \quad i=1,2,3,\dots \quad (۶)$$

مقدار اولیه برای  $Z_i$  در زمان تحت کنترل بودن فرآیند نیز صفر در نظر گرفته شده است. در این طرح اگر  $\mathbf{R} = \mathbf{I}$ ، در این صورت نمودار کنترل MEWMA معادل نمودار  $T^2$  می باشد. طرح این موضوع سبب شد تا نویسندگان زیادی در ارتباط با MEWMA تحقیق کرده و مقالات خود را ارائه نمایند. "ریدون" (Rigdon, 1995)، "رانگر" و "پرابو" (Runger & Prabhu, 1996)، "کرامر" و "اسمید" (Kramer & Schmid, 1997)، "فاسو" (Fasso, 1999) و "یه" (Yeh & et al., 2003) از جمله این نویسندگان می باشند. "تستیک" و همکاران (Testick & et al., 2003) نیز در رابطه با مشخصه های پایداری<sup>۱۱</sup> نمودارهای کنترل را MEWMA برای شرایطی که داده های متغیرها از توزیع  $t$  چند متغیره و توزیع گامای چند متغیره پیروی می کنند بررسی و نتایج تحقیق خود را ارائه دادند. در این میان "پن" (Pan, 2005) رویکرد جدیدی را برای شناخت نمودار MEWMA ارائه نمود. "پن" (Pan, 2005) طرح پیشنهادی خود را M\_EWMA نامیده است.

بدین ترتیب هرچند که نمودارهای کنترل همواره مورد توجه محققین و پژوهشگران قرار داشته اند و نمودارهای کنترل از زمان پیدایش و بکارگیری، نقش مهمی را در کنترل فرآیندها و در نتیجه بهبود آنها ایفا کرده اند، ولی در فرآیند تجزیه و تحلیل ریشه ایی فرآیندهای خارج از کنترل، نمودارهای کنترل فقط تا مرحله اعلام هشدار خارج از کنترل می توانند نقش ایفا نمایند. نکته قابل توجه آنست که معمولا نمودارهای کنترل با یک تاخیر زمانی، شرایط خارج از کنترل فرآیند را شناسایی می کنند. این در حالی است که، تشخیص تفاوت بین زمانی که فرآیند تغییر خود را واقعا شروع کرده با زمانی که نمودار کنترل هشدار می دهد، برای اقدامات بهبود فرآیند بسیار با اهمیت است. هشدار فرآیند توسط نمودارهای کنترل، حاصل اثرات تجمع شده خرابی های فرآیند در گذشته می باشد. به عبارت دیگر اول نقطه تغییر ایجاد می شود و سپس نمودار کنترل هشدار می دهد. حال اگر نمودار کنترل حساس باشد زمان هشدار به نقطه تغییر نزدیک می باشد و اگر نمودار حساس نباشد، زمان هشدار با فاصله زمانی زیادتری اعلام می گردد. بنابراین بین نقطه تغییر و زمان هشدار نمودار کنترل یک فاصله زمانی وجود دارد. برای تخمین نقطه تغییر در فاز دو فرآیندهای چند متغیره، "ندوماران" و همکاران (Nedumaran & et al., 2000) با فرض آنکه بردار میانگین فرآیند نرمال تحت تاثیر تغییر پله ی یگانه<sup>۱۲</sup> قرار می گیرد و ماتریس کوواریانس بدون تغییر می باشد، برآورد کننده ماکسیم

<sup>۱۱</sup>. Robustness

<sup>۱۲</sup>. Step change

درست‌نمایی<sup>۱۳</sup> نقطه تغییر  $\tau$  را ارائه کردند. در تخمین زنده فوق  $\tau$  عبارتست از مقداری از  $t$  که آماره  $M_t$  را حداکثر می کند:

$$\hat{\tau} = \operatorname{argmax} M_t, \quad t = 0, 1, \dots, T-1 \quad (7)$$

در اینجا  $M_t$  از رابطه زیر بدست می آید:

$$M_t = (T-t) (\bar{X}_{t,T} - \mu_0)' \Sigma_0^{-1} (\bar{X}_{t,T} - \mu_0) \quad (8)$$

در رابطه فوق  $\bar{X}_{t,T}$  میانگین  $T-t$  مشاهده آخر می باشد و عبارتست از:

$$\bar{X}_{t,T} = \frac{1}{T-t} \sum_{i=t+1}^T \bar{X}_i \quad (9)$$

"ندوماران" و همکاران (Nedumaran, 2000) هنگامی مدل تخمین زنده پیشنهادی خود را برای شناسایی نقطه تغییر بردار فرآیند می توانند بکار گیرند که قبلا با استفاده از آماره  $\chi^2$  در زمان  $T$  هشدار خارج از کنترل دریافت کرده باشند. لذا مدل پیشنهادی فوق امکان اعلام هشدار خارج از کنترل را برای مدیران فرآیند فراهم نمی آورد. "سالیوان" و "وودال" (Sullivan & Woodal, 2000) نیز برای شناسایی نقطه تغییر در فرآیند چند متغیره طرحی را برای مرحله اول فاز یک پیشنهاد دادند که بر اساس تعریف "آلت" (Alt, 1985) و با فرض نامعلوم بودن پارامترهای توزیع فرآیند ارائه شده است. آنها با استفاده از آماره نرخ درست‌نمایی، یک نمودار کنترلی برای یک فرآیند چند متغیره نرمال ارائه کردند که قادر است تغییرات در بردار میانگین، تغییرات در واریانس و یا هر دو را در مرحله اول فاز یک شناسایی نماید. "زامبا" و "هاکینز" (Zamba & Hawkins, 2006) نیز با فرض نامعلوم بودن پارامترهای فرآیند، و تغییر نکردن ماتریس کوواریانس و اینکه بردار میانگین تحت تأثیر تغییر پله ای یگانه قرار می گیرد، با استفاده از تعمیم آزمون نسبت درست‌نمایی<sup>۱۴</sup> و روش تخمین های پی در پی، چهارچوب جدیدی را برای کنترل فرآیند چند متغیره و تخمین نقطه تغییر ارائه کردند. "لی" و همکاران (Li & et al., 2006) نیز از یک روش یادگیری تحت ناظر با استفاده از درخت تصمیم، بدون پیش فرض وجود تابع توزیع خاصی، برای شناسایی نقطه تغییر در بردار فرآیندهای چند متغیره استفاده کردند. "لی" و همکاران (Li & et al., 2006) در مقاله ارائه شده به چگونگی انجام آموزش اشاره نکردند و ابعاد مختلف آموزش برای خواننده مقاله ترسیم نشده است. بدین ترتیب مدل فوق برای بکارگیری واقعی فرآیندها با ابهامات جدی روبرو می باشد.

علاوه بر تغییر پله ای، نوع دیگری از تغییر که ممکن است بردار میانگین فرآیند را تحت تأثیر قرار دهد، تغییر خطی<sup>۱۵</sup> است. تغییر خطی در شرایطی مانند سایش تدریجی ابزار در یک فرآیند ماشین کاری، و یا افزایش تدریجی ترکیبات در یک فرآیند شیمیایی می تواند در فرآیندها ظاهر شود. نورالسناء و همکاران (Noorossana et al., 2009) طرحی را برای تخمین نقطه تغییر در بردار میانگین یک فرآیند نرمال چند متغیره، زمانی که تغییر فوق از نوع خطی باشد، با استفاده از روش تخمین ماکزیمم درست‌نمایی، ارائه نمودند. در مدل فوق فرض شده است که:

$$\mu_i = \mu_0 + (i-\tau) b \quad i = \tau+1, \tau+2, \dots, T \quad (10)$$

در معادله بالا  $\mu$  بردار میانگین،  $b$  بردار  $p$  بعدی است که بردار اندازه روند خطی است، و  $\tau$  معرف شماره آخرین زیر گروه از فرآیند تحت کنترل می باشد.

در فرآیندهایی که در آن فقط یک متغیر کیفی پایش می شود، مهندسین کیفیت با اعلام هشدار نمودار کنترل و سپس با شناسایی نقطه تغییر می توانند تجزیه و تحلیل ریشه ای را برای شناسایی و حذف عامل انحراف فرآیند آغاز نمایند. ولی در فرآیندهای چند متغیره با ساختار همبسته که متغیرها به طور همزمان پایش می گردند، مدیران فرآیند برای شناسایی و حذف عوامل انحراف فرآیند، علاوه بر هشدار خارج از کنترل و دانش نقطه تغییر فرآیند، نیازمند دانش لازم در رابطه با شناسایی متغیر یا متغیرهایی که موجب خارج از کنترل شدن فرآیند گردیده اند نیز می باشند. این مهم در سالهای اخیر یکی از موضوعات جذاب برای محققین بوده است. ایده اولیه ای که در این رابطه مطرح گردید استفاده از  $p$  نمودار تک متغیره به تعداد  $p$  متغیر فرآیند بود.

<sup>13</sup>. Maximum Likelihood Estimator (MLE)

<sup>14</sup>. Generalized Likelihood Ratio Test

<sup>15</sup>. Linear trend

در این راستا، "آلت" (Alt, 1985) استفاده از نامعادله "بونفرونی"<sup>۱۶</sup> را پیشنهاد نمود. طبیعی است که نتایج حاصل از استفاده اینگونه روشها، به دلیل نادیده گرفتن وجود کوواریانس بین متغیرها، می تواند موجب گمراهی مدیران فرآیند گردد. سپس "هایتر" و "تی سوی" (Hayter & Tsui, 1994) ایده حدود کنترل "بونفرونی" را توسعه دادند. آنها با فرض دانستن ماتریس کوواریانس، نقطه بحرانی  $C_{R,\alpha}$  معرفی کردند، به طوری که  $R$  ماتریس همبستگی و  $\alpha$  احتمال انتخاب شده می باشد. آنها برای انتخاب نقطه بحرانی جداول متعددی را ارائه کردند. استفاده از ناحیه بیضی کنترل یکی دیگر از روشهای معرفی شده برای شناسایی عامل یا عوامل انحراف فرآیند چند متغیره می باشد. این روش توسط "آلت" (Alt, 1985) و "جکسون" (Jakson, 1991) نیز مورد بحث قرار گرفته است. "سپولدودا" و "ناکلاس" (Sepilveda & Nachlas, 1997) نموداری را با عنوان "حداقل - حداکثر شبیه سازی شده"<sup>۱۷</sup> معرفی کردند. این نمودار بر اساس پایش حداکثر و حداقل متوسط نمونه استاندارد شده برای نمونه های داده شده از یک فرآیند چند متغیره می باشد. آنها فرض کردند که فرآیند از توزیع نرمال پیروی می کند و ماتریس کوواریانس شناخته شده و مقادیر آن تغییر نمی کند. اما مشهورترین روش شناسایی متغیر یا متغیرهای انحراف فرآیند، روش تجزیه  $T^2$ <sup>۱۸</sup> می باشد که توسط "ماسون" و همکاران (Mason et al., 1995) معرفی گردیده است. ایده اصلی این روش بر اساس تجزیه کردن آماره  $T^2$  به قسمتهای متعامد<sup>۱۹</sup> شکل گرفته است. این روش توسط نویسندگان  $MTY^{20}$  نامگذاری گردید. بطوریکه:

$$T^2 = T_1^2 + T_{2,1}^2 + \dots + T_{p,1,2,\dots,p-1}^2 \quad (11)$$

اولین عبارت این تجزیه عمومی ( $T_1^2$ ) برای اولین متغیر مشاهده بردار  $X$  عبارت است از:

$$T_1^2 = \frac{(x_j - \bar{x}_j)^2}{s_j^2} \quad (12)$$

و برای عبارتهای دیگر برابر است با:

$$T_{j,1,2,\dots,j-1}^2 = \frac{(x_j - \bar{x}_{j,1,2,\dots,j-1})^2}{S_{j,1,2,\dots,j-1}^2} \quad (13)$$

این عبارت مربع  $J$  امین متغیر تنظیم شده توسط تخمین زنده های متوسط و انحراف استاندارد توزیع شرطی  $x_j$  می باشد. مهمترین اشکال این روش آنست که تجزیه کردن آماره  $T^2$  به تعداد  $p$  جزء  $T^2$ ، معادل تعداد  $p!$  بخش غیر مستقل نمی باشد. سپس "ماسون" و همکاران (Mason et al., 1997) برای کاهش محاسبات طرح "ماسون" و همکاران (Mason et al., 1995)، در همان چهارچوب طرحی مناسب تر پیشنهاد کردند. "ماسون" و "یانگ" (Mason & Young, 1999) با استفاده از تجزیه  $T^2$  نشان دادند که با بهبود مشخصات مدل در زمانی که مجموعه داده ها شکل می گیرد، می توان حساسیت آماره  $T^2$  را افزایش داد. نکته مهمی که در مقالات مربوط به روش تجزیه  $T^2$  وجود دارد عدم ارزیابی طرح با یک شاخص معین است. استفاده از ایده تجزیه  $T^2$  را در کار محققینی مانند "مورفی" (Murphy, 1987) و "دوگاناکسوی" و همکاران (Doganaksoy et al., 1991) نیز می توان مشاهده کرد.

یکی دیگر از روشهایی که در تشخیص عامل یا عوامل انحراف در فرآیندهای چند متغیره با رویکرد آماری بکار گرفته شده است، روش "متغیرهای تنظیم شده رگرسیون"<sup>۲۱</sup> می باشد. "وید" و "وودال" (Wade & Woodal, 1993) یک فرآیند دو مرحله ی که از یکدیگر مستقل نبودند، را بررسی کردند. "هاوکینز" (Hawkins, 1991) و "هاوکینز" (Hawkins, 1993) نیز با استفاده از همین مفهوم مدل پیشنهادی خود را ارائه کرده است. "کالاگونا" و "کولکارنی" (Kalagonda & Kulkarni, 1993) نیز با استفاده از همین مفهوم مدل پیشنهادی خود را ارائه کرده است.

16. Bonferroni

17. Simulated Mini Max control chart

18. Decomposition of  $T^2$

19. Orthogonal

20. Meson, Tracy and Young

21. Regression Adjusted Variables

(2003) نیز با استفاده از روش رگرسیون متغیر مجازی<sup>۲۲</sup> یک روش برای تشخیص عامل یا عوامل انحراف فرآیند به واسطه تغییر در بردار میانگین ارائه کردند. در ادبیات موضوع، برای شناسایی متغیر یا متغیرهایی که موجب خارج از کنترل شدن فرآیند شده است، استفاده از عناصر اصلی<sup>۲۳</sup> نیز مورد توجه قرار گرفته است. نویسندگانی مانند "کورتی" و "ماک گرگور" (Kourti & MacGregor, 1996)، "واسترهویس" و همکاران (Wasterhuis et al., 2000)، "ماراولاکیس" و همکاران (Maravelakis et al., 2002) و "چوی" و همکاران (Choi et al., 2005) با استفاده از این رویکرد طرحهایی را برای شناسایی عوامل انحراف فرآیند ارائه کرده اند.

جذابیت موضوع تشخیص متغیر یا متغیرهای تأثیرگذار در انحراف فرآیندهای چند متغیره موجب گردیده که روشهای ترسیمی<sup>۲۴</sup> نیز توسط محققین برای پاسخ به این نیاز اساسی مهندسين کیفیت پیشنهاد شود. محققینی مانند "فاج" و "بنجامینی" (Fuch & Benjamini, 1994)، "اسپارکس" و همکاران (Spark et al., 1997)، "اتینزا" و همکاران (Atienza et al., 1998) و "ناتینگهام" و همکاران (Nottingham et al., 2001) رویکرد فوق را برای ارائه طرحهای خود برگزیده اند. "آپاریزی" و همکاران (Aparisi et al., 2006) با بررسی روشهای ترسیمی نقاط ضعف اینگونه طرح ها را مشخص نموده اند. خسته کننده بودن و سنگین بودن عملیات روشهای گرافیکی به دلیل ماهیت و طبیعت آنها، از عمده ترین نقاط ضعف روشهای گرافیکی شمرده شده است. اما مشکل اساسی که "آپاریزی" و همکاران (Aparisi et al., 2006) به آن اشاره می کنند، نیازمندی تفسیر نتایج توسط استفاده کننده است. آنها این الزام را بعنوان یک کار پیچیده در مسیر اثربخش نمودن محاسبات نهفته در این رویکرد تفسیر کرده اند.

قابلیتهای مبتنی بر دانش محوری شبکه های عصبی، برای تامین مشخصه های مطلوب یک سیستم کنترل آماری فرآیند<sup>۲۵</sup> در فرآیندهای با درجه اتوماسیون بالا و محیط های تولیدی یکپارچه<sup>۲۶</sup>، از دلایل اصلی و اولیه بکارگیری شبکه های عصبی برای پایش فرآیندها بوده است. ولی توسعه نیازهای مدیران فرآیند و مهندسين کیفیت و الزام بکارگیری طرحهای جامع تر نسبت به طرح های موجود، جهت اتخاذ تصمیمات ریشه ی و جامع، حتی در فرآیندهای با درجه اتوماسیون پایین و یا دستی، موجب توسعه نظری و عملی شبکه های عصبی گردیده است. پیچیدگی روزافزون مؤلفه های تصمیم گیری نیز مزید بر علت گردید تا قابلیت های نهفته در روشهای محاسبات نرم<sup>۲۷</sup>، از جمله شبکه های عصبی، در جایگاه روشهای سنتی، مانند روشهای آماری، بواسطه پیچیدگی و حجم محاسبات متوقف و یا طاقت فرسا می شوند، بتوانند نقش تعیین کننده ایفا نمایند. اولویت سرعت بر دقت پایش، حتی در جایی که روشهای آماری، بالقوه می توانند نتایج دقیقتری ارائه دهند، می تواند موجب ترجیح روشهایی مانند شبکه عصبی در فرآیندهای حساس و یا پرهزینه، گردد. مجموعه شرایط فوق موجب گردیده تا شبکه های عصبی بتوانند روز به روز جایگاه خود را در عرصه فعالیت کنترل آماری فرآیندها توسعه دهند.

طبیعتاً بکارگیری قابلیت های شبکه های عصبی در کنترل آماری فرآیندها، از فرآیندهای تک متغیره آغاز گردید. "پاف" (Pugh, 1989)، "اسمیت" (Smith, 1994)، "گی یو" و "دوولی" (Guo & Dooly, 1992)، "چنگ" (Cheng, 1995) و "چانگ" و "آو" (Change & Aw, 1996)، "هوانگ" و "هابل" (Hwang & Hubele, 1993a, 1993b)، "چنگ" (Chenge, 1997)، "گاه" و "تانوک" (Guh & Tannock, 1999)، "فام" و "ازتمل" (Pham & Oztemel, 1994)، "هوانگ" و "چونگ" (Hwang & Chong, 1994. 1995) و "هوانگ" (Hwang, 1995, 1997)، "گرجانی"، نورالسنا و سقایی (Garjani, Noorossana, & Saghaie 2010) محققانی هستند که شبکه های عصبی پیشنهادی خود را فقط برای اعلام هشدار در فرآیندهای تک متغیره ارائه نمودند. ولی به تدریج محققین شبکه های عصبی پیشنهادی را برای محیطهایی با بیش از یک متغیره با ساختار همبسته نیز ارائه نمودند. "ذوالریاستین" و همکاران

22. Dummy variable

23. Principal Component

24. Graphical Technique

25. Statistical Process Control (SPC)

26. Integrated Manufacturing Environment

27. Soft computing

(Zorriasatine et al., 2003) یک شبکه عصبی را به منظور شناسایی شرایط خارج از کنترل برای فرآیندهای دو متغیره معرفی کردند. آنها شبکه پیشنهادی خود را با هدف شناسایی الگوی تغییر پله ی یگانه معرفی کردند. به طوری که اگر در بردار میانگین تغییری مثبت یا منفی ایجاد شود، ولی ماتریس کوواریانس ثابت بماند، شبکه عصبی فوق می تواند خارج از کنترل بودن فرآیند را تشخیص دهد. آنها در گزارش خود میزان درصد درست تشخیص دادن<sup>۲۸</sup> مدل را مورد توجه قرار دادند و میزان صحت عملکرد شبکه پیشنهادی خود را با این شاخص به تصویر کشیدند. "ذوالریاستین" و همکاران (Zorriasatine et al., 2003) در گزارش خود "متوسط طول دنباله"<sup>۲۹</sup> را به عنوان یک شاخص مهم در پایش و کنترل آماری فرآیندها، مورد توجه قرار ندادند. لذا در گزارش آنها مشخص نیست "طول متوسط دنباله تحت کنترل" شبکه طراحی شده چه میزان می باشد. همچنین در گزارش فوق مشخص نیست که با چه میزان "طول متوسط دنباله خارج از کنترل"، شبکه طراحی شده شرایط خارج از کنترل فرآیند را شناسایی می نماید. مضافا آنکه، در گزارش فوق با این استدلال که در شرایط واقعی هر دو متغیر با یکدیگر تغییر می کنند و تغییر هر یک از متغیرها به تنهایی کمتر اتفاق می افتد، گزارشی از عملکرد شبکه برای زمانی که فقط یکی از متغیرها تغییر می کند و یا یک متغیر دارای تغییر مثبت و دیگری دارای تغییر منفی است، ارائه نشده است. سپس "ذوالریاستین" و همکاران (Zorriasatine et al., 2005) مدلی را که "ذوالریاستین" و همکاران (Zorriasatine et al., 2003) ارائه داده بودند را برای سریهای زمانی چند متغیره توسعه دادند. آنها با ارائه مطالعه موردی به اثبات توانمندی مدل خود در حوزه فرآیندهای چند متغیره پرداختند ولی اشکالات اساسی مرتبط با ارزیابی مدل بر اساس شاخص مهم "طول متوسط دنباله" را مرتفع نمودند. "نیاکی" و "عباسی" (Niaki & Abbasi, 2005) نیز برای شناسایی عامل / عوامل تغییر در بردار میانگین یک فرآیند نرمال چند متغیره، با فرض ثابت بودن ماتریس کوواریانس مشخص که در فاز یک بدست آمده است، یک مدل بر مبنای شبکه عصبی ارائه کردند. مدل ارائه شده فقط برای شناسایی عامل / عوامل تغییر در فرآیند، کاربرد دارد، بطوریکه پس از آنکه شرایط خارج از کنترل توسط یکی از روشهای موجود مانند  $T^2$  شناسایی گردید مدل پیشنهادی آنها می تواند فعال شود. بنابراین برای شناسایی عامل / عوامل تغییر در یک شرایط واقعی، با استفاده از مدل فوق، باید از دو طرح مجزا استفاده نمود. بطوریکه اولی شرایط خارج از کنترل تشخیص دهد و مدل پیشنهادی "نیاکی" و "عباسی" (Niaki & Abbasi, 2005) متغیری را که سبب خارج از کنترل شدن فرآیند شده است را تشخیص دهد. این نقطه ضعف مهم در عمل، کاربرد مدل را با مشکل روبرو می سازد. مدل پیشنهادی "نیاکی" و "عباسی" (Niaki & Abbasi, 2005) برای تغییرات پله ی یگانه متوسط به بالا یعنی  $2\sigma$ ,  $2.5\sigma$  و  $3\sigma$  آزمایش شده است، و تعداد محدودی از ترکیبات محتمل در گزارش گنجانیده شده است. برای شناسایی عامل / عوامل تغییر در فرآیند، "آپاریزی" و همکاران (Aparasi et al., 2006) نیز یک مدل بر مبنای شبکه عصبی ارائه کردند، که پس از شناسایی شرایط خارج از کنترل یک فرآیند چند متغیره توسط یک طرح دیگر مانند  $T^2$ ، می تواند فعال گردد. این مدل نیز برای فاز دو با فرض ثابت بودن ماتریس کوواریانس و برای تغییرات پله ایی در بردار میانگین طراحی شده است. "آپاریزی" و همکاران (Aparasi et al., 2006) مدل پیشنهادی خود را فقط برای ضرایب همبستگی مثبت آزمایش کرده اند، لذا عملکرد مدل فوق برای شرایطی با ضرایب همبستگی منفی مشخص نیست. از آنجایی که "آپاریزی" و همکاران (Aparasi et al., 2006) نتیجه گرفته اند که مدل "ماسون" و همکاران (Mason et al., 1997) برای سطح تشخیص ۳٪ بهترین عملکرد را دارد. لذا مبنای ارزیابی و مقایسه مدل خود را نیز سطح تشخیص ۳٪ قرار دادند. سطح تشخیص فوق بمعنی اندازه "متوسط طول دنباله"  $33/3333$  می باشد که مقداری بسیار پایین برای ارزیابی عملکرد یک مدل می باشد. حال آنکه به طور معمول در مقالات متعدد، مدل ها بر پایه "متوسط طول دنباله" حداقل ۲۰۰ مورد ارزیابی قرار می گیرند. آنها مدل خود را برای فرآیندهای دو و سه متغیره گزارش کردند. "گاه" (Guh, 2007) نیز یک مدل بر پایه شبکه عصبی ارائه نمود که برای فرآیند دو متغیره طراحی شده است. در مدل او پنج شبکه عصبی قرار داده شده است، که دارای دو فاز کلی عملیاتی است. او در طراحی مدل پیشنهادی خود فرض کرد که مقادیر بردار میانگین و ماتریس کوواریانس در زمانی که فرآیند در شرایط تحت

<sup>28</sup>. Percentage of correctly identified patterns

<sup>29</sup>. Average run length (ARL)



کنترل می باشد، شناخته شده است. به عبارت دیگر مدل برای فاز دو طراحی گردیده است. این مدل با فرض عدم تغییر در ماتریس کوواریانس، زمانی که تغییر پله‌ای یگانه، بردار میانگین فرآیند را تحت تأثیر قرار دهد، توانایی دارد علاوه بر شناسایی شرایط خارج از کنترل فرآیند، عاملی را که موجب شرایط خارج از کنترل شده را شناسایی و جهت تغییر و مقدار تغییر هر یک از متغیرها را نیز تشخیص دهد. ابهامات مهمی در مدل "گاه" (Guh, 2007) وجود دارد که مدلسازی و بکارگیری آنرا با تردید جدی روبرو می کند. تعداد زیاد نرون های خارجی شبکه پیشنهادی، که ۹ عدد می باشد، یکی از آن ابهامات مهم می باشد. هرچند که برای تعیین تعداد نرون های لایه خارجی نمی توان عدد مشخصی را معرفی نمود، و این تعداد با توجه به نوع ماموریت شبکه شکل می گیرد، ولی مرور تحقیقات گذشته و مدل‌های معرفی شده بر کم بودن تعداد نرون های خارجی متمرکز شده است. زیرا که افزایش تعداد نرون های خارجی که بیانگر نتیجه نهایی تشخیص شبکه می باشد، موجب می گردد دقت شبکه بسیار پایین بیاید. عبارت دیگر در مدل پیشنهاد شده "گاه" (Guh, 2007)، پیش بینی تعداد زیاد نرون های لایه خارجی، با یک حد آستانه واحد، در صدد است تا انواع گوناگونی از الگوها را تشخیص و از هم تفکیک نماید که این مهم، بسیار بر دقت و صحت عملکرد شبکه تأثیر منفی می گذارد. "گاه" (Guh, 2007) در عین حال که در مقاله خود به اهمیت "حد آستانه" اشاره کرده است، ولی مشخص نموده که در مدل ارائه شده چگونه "حد آستانه" را پیدا کرده است. مضافاً آنکه او فقط حد آستانه اولین شبکه خود را با عدد  $0/8$  معرفی نموده و حد آستانه چهار شبکه دیگر را ذکر نکرده است.

لذا با توجه به گزارش ارائه شده، بنظر می رسد عدد  $0/8$  حد آستانه تمام شبکه ها در مدل پیشنهادی "گاه" (Guh, 2007) می باشد. در اینصورت با توجه به اینکه "ذوالریاستین" و "تانوک" (Zorriassatine & Tannock, 1998) به واسطه طبیعت خروجی شبکه های عصبی، حد آستانه را به عنوان یک عامل مهم در شبکه های عصبی نام برده، و با توجه به این مهم که حد آستانه براساس رفتار عملیاتی و کلیه مشخصات شبکه تعیین می شود، به طوری که "چنگ" (Cheng, 1997) مقدار حد آستانه را به طبیعت فرآیند عملیاتی و رفتاری شبکه عصبی وابسته می داند، لذا این بخش از گزارش "گاه" (Guh, 2007) که یک حد آستانه مساوی برای پنج شبکه مختلف معرفی کرده است با ابهام جدی روبرو می باشد. عدم توانایی تخمین نقطه تغییر، نیز یکی دیگر از نقاط ضعف طرح پیشنهادی "گاه" (Guh, 2007) می باشد. "هوانگ" (Hwang, 2008) نیز یک مدل بر پایه شبکه عصبی معرفی کرد که می تواند تغییرات در بردار میانگین یک فرآیند دو متغیره را به همراه عامل تغییر آن شناسایی نماید. او نیز مدل پیشنهادی خود را برای فاز دو طراحی نمود. او با فرض پیروی فرآیند از توزیع نرمال که دارای ماتریس کوواریانس شناخته شده است و در زمان تغییر ثابت می ماند، مدل پیشنهادی خود را برای تغییرات در بردار میانگین فرآیند دو متغیره ارائه نمود. بدلیل آنکه او هدف را طراحی شبکه عصبی برای شناسایی تغییرات کوچک قرار داده بود، از تغییرات  $2\sigma$  و  $3\sigma$  در داده های آموزشی استفاده نکرد. او تأکید کرد که اگر چه این ملاحظه در آموزش شبکه موجب نمی شود که شبکه تغییرات بزرگ را شناسایی نکند ولی کارایی شبکه برای تغییرات بزرگ تضمین نمی شود. او شبکه پیشنهادی خود را با تغییرات منفی در بردار میانگین ارزیابی و بررسی نکرده است و گزارشی نیز ارائه نکرده است، لذا مشخص نیست، اگر زمانی فرآیند با تغییرات منفی و یا ترکیبی از تغییرات منفی و مثبت در بردار میانگین مواجه شود چه میزان به صحت عملکرد شبکه پیشنهادی "هوانگ" (Hwang, 2008) می توان اطمینان داشت. همچنین با گزارش ارائه شده نمی توان به پایداری مدل پیشنهاد شده اطمینان داشت. مدل فوق نیز قابلیت شناسایی نقطه تغییر را ندارد.

برای تخمین نقطه تغییر در یک فرآیند چند متغیره "احمدزاده" و "نورالسنا" (Ahmadzade & Noorossana, 2008) نیز یک شبکه عصبی ارائه کردند که پس از آنکه شرایط خارج از کنترل توسط یک نمودار MEWMA شناسایی می شود، می تواند نقطه تغییر را برای فرآیند فوق برآورد نماید. در گزارش فوق محققین پایداری شبکه عصبی را برای ضرایب همبستگی متعددی که ممکن است مشخصه های کیفی فرآیند از آن برخوردار باشند، ارزیابی نکرده اند. به طوری که، گزارش ارائه شده فوق فقط مختص به زمانی است که ضریب همبستگی برابر  $0/5$  باشد. بر اساس گزارش ارائه شده مدل فوق توانایی شناسایی شرایط خارج از کنترل و همچنین شناسایی عامل انحراف فرآیند را ندارد.

	دریف	زیرمحدوده ها	تعداد ترکیبات	تعداد تکرار	جمع
شبکه A	۱	$(-0.75 \leq x_1 \leq 0.75) \vee (-0.75 \leq x_2 \leq 0.75)   (x_1, x_2 \neq 0)$	۲۹۴۰	۲۰	۵۸۸۰۰
	۲	$(x_1 > 0.75 \vee x_1 < -0.75) \wedge (x_2 > 0.75 \vee x_2 < -0.75)   (x_1, x_2 \neq 0)$	۱۱۵۶	۱۱	۱۲۷۱۶
	۳	$(x_1 = 0) \vee (x_2 = 0)$	۱۲۸	۲۰۰	۲۵۶۰۰
	۴	In-control	۱	۸۰۰۰	۸۰۰۰
جمع			۴۲۲۵		۱۰۵۱۱۶
شبکه B	۱	$x_1 > 1/5 \vee x_1 < -1/5$	۱۲	۲۵۰	۳۰۰۰
	۲	$-1/5 \leq x_1 \leq 1/5$	۵۲	۸۵۰	۴۴۲۰۰
	۳	In-control	۱	۱۷۰۰۰	۱۷۰۰۰
	جمع			۶۵	
شبکه C	۱	$(1/25 \geq x_1 \geq -1/25) \vee (1/25 \geq x_2 \geq -1/25)$	۳۹۰۰	۲۲	۸۵۸۰۰
	۲	$(1/25 < x_1 \vee x_1 < -1/25) \wedge (1/25 < x_2 \vee x_2 < -1/25)$	۱۹۶	۶۰	۱۱۷۶۰
	۳	In-control	۱	۶۵۰۰۰	۶۵۰۰۰
	جمع			۴۰۹۷	

جدول شماره (۱): زیرمحدوده ها و تعداد تکرار آموزشی آنها در مدل "آتشگر" و "نورالسنا" (Atashgar & Noorossana, 2011)

بر خلاف اکثر طرح های ارائه شده فوق، که فقط یک بخش از اطلاعات مورد نیاز مدیران فرآیند و با فرض نوع خاصی از تغییر، مورد توجه قرار گرفته است، "آتشگر" و "نورالسنا" (Atashgar & Noorossana, 2010a) طرحی را بدون پیش فرض خاصی از تغییر بر مبنای شبکه عصبی پیشنهاد دادند که بهنگام تغییرات در بردار میانگین فرآیند، تمامی اطلاعات مورد نیاز مهندسين کیفیت را همزمان، در هنگام خارج از کنترل رفتن فرآیند، فراهم می آورد. در عین حال، "آتشگر" و "نورالسنا" (Atashgar & Noorossana, 2011) مدلی را بر مبنای شبکه های عصبی با رویکرد یادگیری با ناظر<sup>۳۰</sup> ارائه کردند که می تواند فقط در شرایطی که تغییرات در بردار میانگین از نوع خطی باشد، تمامی اطلاعات مورد نیاز مدیران کیفیت را برای یک تجزیه و تحلیل ریشه ی فراهم آورد. این اطلاعات شامل پایش همزمان هشدار خارج از کنترل، شناسایی نقطه تغییر و تشخیص عامل انحراف فرآیند می باشد. آنها با ابتکار بکارگیری زیرمحدوده ها<sup>۳۱</sup> مدل خود را بر اساس جدول شماره یک پیشنهاد دادند. همچنین "آتشگر" و "نورالسنا" (Atashgar & Noorossana, 2010b) یک شبکه عصبی پیشنهاد کردند که می تواند شرایط خارج از کنترل و همچنین عامل تغییر را هنگامی که فرآیند تحت کنترل آماری نمی باشد و این عدم کنترل ناشی از تغییرات در بردار میانگین باشد شناسایی نماید. "نورالسنا"، "آتشگر" و "سقایی" (Noorossana, Atashgar & Saghaie 2011) با تغییراتی در مدلی که "آتشگر" و "نورالسنا" (۱۳۸۹) ارائه کرده بودند، توانستند عملکرد مدل را بهبود دهند و آنرا برای تغییرات پله ایی یگانه در بردار میانگین پیشنهاد دهند. جدول ۲ مشخصه مدل فوق را براساس زیرمحدوده ها نشان می دهد. این مدل زمانی که فرآیند در شرایط خارج از کنترل قرار می گیرد، ضمن اعلام هشدار خارج از کنترل فرآیند، می تواند همزمان نقطه تغییر، عامل انحراف فرآیند و جهت و یا جهت های تغییر مشخصه های کیفی همبسته را شناسایی و اعلام نماید.

	ردیف	زیر محدوده ها	تعداد ترکیبات	تعداد تکرار	جمع
شبکه A	۱	$(-1/25 < x_1 < 1/25) \vee (-1/25 < x_2 < 1/25)   (x_1, x_2 \neq 0)$	۲۸۸۰	۳۵	۱۰۰۸۰۰
	۲	$(x_1 \geq 1/25 \vee x_1 \leq -1/25) \wedge (x_2 \geq 1/25 \vee x_2 \leq -1/25)   (x_1, x_2 \neq 0)$	۲۵۶	۳۸۰	۹۷۲۸۰
	۳	$(x_1 = 0) \vee (x_2 = 0)$	۱۱۲	۵۵۰	۶۱۶۰۰
	۴	In-control	۱	۱۵۰۰۰۰	۱۵۰۰۰۰
جمع			۳۹۴۹		۴۰۹۶۸۰
شبکه B	۱	$(x_1 \neq 0) \wedge (x_2 \neq 0)$	۶۷۶	۱۶	۱۰۸۱۶
	۲	$(x_1 = 0) \vee (x_2 = 0)$	۵۲	۶۸۵	۳۵۶۲۰
	۳	In-control	۱	۱۰۰۰	۱۰۰۰
اجمع			۷۲۹		۴۷۴۳۶
شبکه C	۱	$(x_1 \neq 0) \wedge (x_2 \neq 0)$	۶۷۶	۱۰۰	۶۷۶۰۰
	۲	In-control	۱	۲۰۰۰	۲۰۰۰
جمع			۶۷۷		۶۹۶۰۰
شبکه	۱	$(x_1 = 0) \vee (x_2 = 0)$	۵۲	۱۰۰	۵۲۰۰

<sup>30</sup>. Supervised learning

<sup>31</sup>. Subinterval

D	۲	In-control	۱	۲۰۰۰	۲۰۰۰
	جمع		۵۳		۷۲۰۰
شبکه	۱	$(-1/75 < x_1 < 1/75) \vee (-1/75 < x_2 < 1/75)   ((x_1 = 0) \vee (x_2 = 0))$	۸۸	۳۰	۲۶۴۰
	۲	$(x_1 \geq 1/75 \vee x_1 \leq -1/75) \wedge (x_2 \geq 1/75 \vee x_2 \leq -1/75)   ((x_1 = 0) \vee (x_2 = 0))$	۲۴	۴۰۰	۹۶۰۰
E	۳	In-control	۱	۱۷۰۰۰۰	۱۷۰۰۰۰
	جمع		۴۰۹۷		۱۸۲۲۴۰
شبکه	۱	$(-1/75 < x_1 < 1/75) \vee (-1/75 < x_2 < 1/75)   (x_1, x_2 \neq 0)$	۲۹۹۲	۳۰	۸۹۷۶۰
	۲	$(x_1 \geq 1/75 \vee x_1 \leq -1/75) \wedge (x_2 \geq 1/75 \vee x_2 \leq -1/75)   (x_1, x_2 \neq 0)$	۱۴۴	۴۰۰	۵۷۶۰۰
F	۳	In-control	1	۳۰۰۰۰	۳۰۰۰۰
	جمع		۳۱۳۷		۱۷۷۳۴۰

جدول شماره (۲): زیرمحدوده‌ها و تعداد تکرار آموزشی آنها در مدل "نورالسنا" و همکاران (Noorossana, Atashgar & Saghaie 2011)

با توجه به مرور ادبیات فوق، قابلیت مهم‌ترین مدل‌های موجود در ادبیات موضوع در جدول ۳ نشان داده شده است. براساس بررسی فوق همانگونه که در جدول شماره ۳ مشاهده می‌شود، مدل "نورالسنا" و همکاران (Noorossan et al., 2011) به عنوان کامل‌ترین و بهترین مدل برای مطالعه موردی این تحقیق شناخته می‌شود.

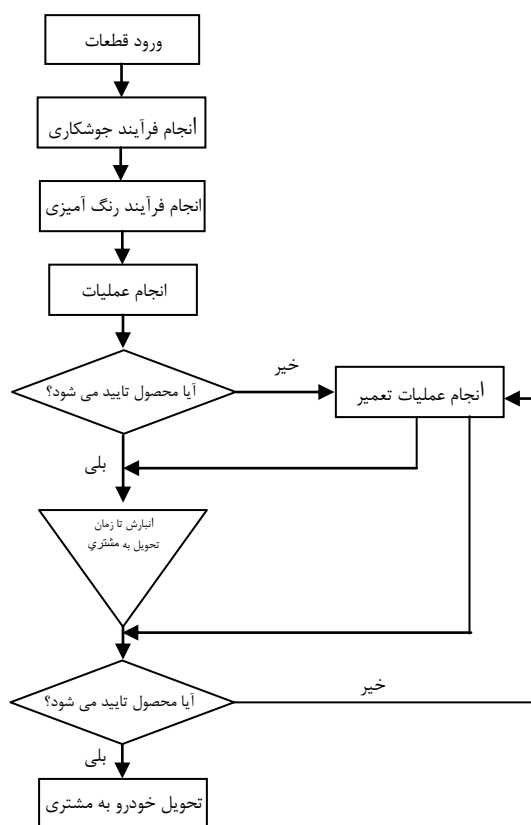
در این قسمت به بکارگیری مدل در فرآیند تولید بدنه خودرو می‌پردازیم. در کارخانجات تولید اتومبیل یکی از مشخصات کیفی با اهمیت که از مرحله ساخت بدنه خودرو تا مرحله تأیید نهایی خودرو به آن توجه جدی می‌شود، و در دو مرحله ساخت بدنه و بازرسی نهایی توسط بازرسان کنترل کیفیت بازرسی و نتایج آن ثبت می‌شود، مشخصه‌های "فاصله"<sup>۳۲</sup> و "اختلاف سطح"<sup>۳۳</sup> بین اجزاء بدنه و درها می‌باشد. "فاصله" به درز بین در موتور و گلگیرها، در صندوق عقب و ساید‌ها، درهای جلو و گلگیرها، درهای جلو و فریم ساید‌ها و درهای عقب و فریم ساید‌ها گفته می‌شود. فاصله‌های فوق در صورتی که از حدود مشخص طراحی شده تجاوز نماید علاوه بر مشکلاتی که در رگلاژ اجزاء بدنه بویژه درها ایجاد می‌کند، می‌تواند در نفوذ آب به خودرو نیز تأثیرگذار باشد. در خطوط تولید اتومبیل‌های لوکس و گران قیمت، به دلیل آنکه اندازه مشخصه‌های فوق در زیبایی خودرو نیز تأثیر مستقیم دارد، حساسیت‌های اندازه‌گیری نسبت به آنها بیشتر می‌شود.

	Hotelling (1947)	MCUSUMMEWMA	Mason 1997	Nedumaran 2000	Sullivan (2000)	Niaki (2005)	Aparasi (2006)	Hwarng 2008	نورالسنا (2009)	Zorriasatine (2005)	آتشگر (2010)	Noorossana (2011)
شناسایی شرایط خارج از کنترل	✓	✓	✓		✓			✓		✓	✓	✓
شناسایی نقطه تغییر				✓	✓				✓			✓
تشخیص عامل انحراف			✓			✓	✓	✓			✓	✓
شناسایی جهت تغییر												✓

جدول شماره (۳): قابلیت مهم‌ترین مدل‌های موجود در ادبیات

<sup>32</sup>. Gap

<sup>33</sup>. Step



شکل شماره (۱): فرآیند کلی تولید خودرو

مورد کاوی بررسی شده در این مقاله بر تمرکز بر فاصله های جانبی در صندوق عقب بدنه یکی از خطوط تولید خودروهای لوکس در ایران، به پایش فرآیند فوق با استفاده از شبکه عصبی مدل سازی شده که قابلیت های آن توسط "نورالسنا" و همکاران (Noorossan et al., 2011) گزارش شده، پرداخته است.

خط تولید خودروی مورد بررسی از چهار مرحله اصلی تشکیل شده است. ابتدا قطعات<sup>۳۴</sup> CKD بدنه که شامل سقف، سایدها، کف و قطعات جانبی، گلگیرها و قطعات جانبی، در صندوق عقب، در موتور و درهای جانبی خودرو می باشد در خط تولید بدنه در ایستگاه های متعدد که در آنها فیکسچرهای لازم استقرار یافته از طریق فرآیند جوشکاری به یکدیگر متصل شده و بدنه خودرو تولید می گردد. در فرآیند فوق از آنجاییکه قطعات به صورت کاملاً CKD از خارج وارد می شود و پس از باز کردن از بسته بندی<sup>۳۵</sup> و تأیید ظاهری، قطعات به ایستگاه های مربوطه تزریق می گردد، لذا فیکسچرها، دستگاه های جوشکاری و نیروی کارگر مهمترین نقش را در کیفیت تولید بدنه ایفا می نمایند. بدنه های تولیدی پس از بازرسی به بخش رنگ منتقل می شوند. رنگ خودرو نیز به واسطه اهمیت آن از لحاظ ابعاد فنی و انتظارات مشتری، از اهمیت بسیار بالایی برخوردار است. پس از فرآیند رنگ، بدنه خودرو به بخش تریم<sup>۳۶</sup> و مونتاژ منتقل می گردد. مونتاژ خودرو نیز در ایستگاه های متعدد با استفاده از قطعات CKD انجام می شود. در طول خط مونتاژ رگلاژ درها نیز انجام می پذیرد. پس از مونتاژ نهایی، خودرو به بخش تأیید نهایی<sup>۳۷</sup> منتقل می گردد. در این بخش بازرسی های ظاهری و فنی متعددی روی خودرو انجام می پذیرد، به گونه ایی که در صورت وجود

34. Completed Knock Down

35. Unpacking

36. Trim

37. Final OK

هر گونه اشکال مونتاژی، فنی و یا عیوب مربوط به بدنه اعم از رنگ، قوری، رگلاژ و یا نفوذ آب، عیوب برطرف می‌گردد و پس از تأیید نهایی، خودرو به انبار محصول تحویل می‌گردد. قبل از تحویل خودرو به مشتری یکبار دیگر بازرسی های مشخصی در قسمت PDI<sup>۳۸</sup> انجام می‌پذیرد و پس از تایید و یا رفع عیوب احتمالی، خودرو به مشتری تحویل می‌گردد. شکل شماره ۱ فرآیند کلی تشریح شده فوق را نشان می‌دهد. در فرآیند فوق کارگاه ساخت بدنه نقش اساسی در کیفیت عملکرد آتی خودرو ایفا می‌نماید، زیرا که بدنه در مقام مبنای<sup>۳۹</sup> اساسی محصول و قرار گیری دیگر اجزاء بر روی آن نقش مهمی در کیفیت خودرو ایفا می‌نماید. صدا دادن اتاق، عدم امکان مونتاژ مناسب بعضی از قطعات در خط مونتاژ، نفوذ آب در اتاق خودرو و عملکرد نامناسب بعضی از مجموعه های خودرو، به فرآیند تولید بدنه آن بازگشت می‌کند. لذا فرآیند تولید بدنه خودرو باید با حساسیت بالایی کنترل گردد. در میان فیکسچرهای موجود در خط تولید بدنه نیز فسکچر اصلی<sup>۴۰</sup> نقش محوری تری دارد.

در فرآیند تولید بدنه، فاصله بین اجزاء مختلف بدنه که در بالا تشریح گردید، در مواضع مختلف از حساسیت های فرآیندی متفاوتی برخوردار می‌باشند. به عنوان مثال، فاصله خارج از حد استاندارد درهای جانبی غالباً ناشی از لولاها می‌باشد که براحتی با رگلاژ مرتفع می‌گردد. ولی مواردی مانند خارج از حد استاندارد بودن فاصله در صندوق عقب و یا در موتور با سایدها از حساسیت بالاتری برخوردار است و رفع ریشه ی آن نیز باید فرآیندی انجام پذیرد. لذا مورد کاوی بررسی شده در این مقاله به مؤلفه کیفی فاصله در صندوق عقب متمرکز شده است. شکل ۲ از نماهای لازم، فاصله های در صندوق عقب را در بدنه خودرو مورد مطالعه نشان می‌دهد. در ضمن، به منظور کنترل فرآیند تشریح شده فوق، مقادیر پارامترهای مربوط به فاصله بین صندوق عقب خودرو با فریم ساید سمت راست و فریم سمت چپ (گلگیرها) بر حسب میلیمتر در فاز یک به شرح زیر بر اساس اطلاعات ثبت شده، گزارش شده است:

$$\mu_0 = \begin{bmatrix} 3.6086 \\ 3.6686 \end{bmatrix} \quad \Sigma = \begin{bmatrix} 0.0602 & 0.0356 \\ 0.0356 & 0.0528 \end{bmatrix} \quad R = \begin{bmatrix} 1 & 0.6308 \\ 0.6308 & 1 \end{bmatrix} \quad (14)$$

برای کنترل و پایش فرآیند ساخت بدنه خودرو فوق از زمان مشخصی به عنوان زمان صفر شروع به ورود داده ها به شبکه عصبی طراحی شده گردید و همزمان فرآیند با استفاده از نمودار  $\chi^2$  پایش گردید. برای زمانی که بردار میانگین دارای مقدار مشخص  $\mu_0$  و اندازه نمونه  $n$  باشد، آماره  $\chi^2$  برای پایش تحت کنترل بودن فرآیند از فرمول زیر محاسبه می‌شود

$$\chi^2 = n (\bar{X} - \mu_0)' \Sigma^{-1} (\bar{X} - \mu_0) \quad (15)$$

در معادله فوق  $X$  یک بردار  $1 \times P$  می‌باشد که  $Z$  امین عنصر  $Z$  امین مشخصه کیفی را نشان می‌دهد. همچنین  $X$  از یک توزیع  $p$  متغیره نرمال پیروی می‌کند که دارای ماتریس کوواریانس  $\Sigma$  است. اگر آماره  $\chi^2$  از نقطه درصد مشخص توزیع مربع کای، یعنی  $\chi_{\alpha, \nu}^2$  با  $\alpha$  درصد بالایی توزیع مربع کای و  $\nu$  درجه آزادی، تجاوز نماید، آنگاه نتیجه گیری می‌شود که فرآیند در شرایط خارج از کنترل قرار دارد. در فرآیند مورد مطالعه با توجه به آنکه  $\alpha = 0.05$  و  $\nu = 2$  می‌باشد،  $\chi^2 = 10.597$  است.

شبکه های عصبی که برای کنترل فرآیند فوق استفاده گردید از سه ماژول اصلی تشکیل شده است. اولین ماژول شامل دو شبکه عصبی  $A$  و  $B$  می‌باشد. شبکه  $A$  پس از آموزش شرایط خارج از کنترل را شناسایی می‌کند و شبکه  $B$  پس از آموزش توانایی آنرا می‌یابد تا تشخیص دهد که یکی از مؤلفه های کیفی عامل انحراف فرآیند بوده یا هر دو مؤلفه عامل انحراف بوده اند. دومین ماژول اصلی شامل دو شبکه عصبی  $C$  و  $D$  می‌باشد. این دو شبکه پس از طراحی و آموزش قابلیت شناسایی عامل / عوامل انحراف فرآیند را به همراه جهت تغییر بردار میانگین را دارا می‌باشند. ماژول اصلی سه نیز شامل دو شبکه عصبی  $E$  و  $F$  می‌باشد که بعد از سیگنال صادره از ماژول اصلی دو، وظیفه شناسایی نقطه تغییر را بر عهده دارد. به طوری که، اگر یکی از متغیرها عامل انحراف فرآیند باشد شبکه  $E$  برای شناسایی نقطه تغییر فعال خواهد شد و اگر هر دو متغیر عامل انحراف باشند شبکه عصبی  $F$  برای شناسایی نقطه تغییر فعال خواهد شد.


با ورود داده های فرآیند به شبکه عصبی، در حالی که در بعد از ظهر روز دوازدهم نمودار  $\chi^2$  با استفاده از همان ورودی های

<sup>38</sup>. Pre delivery inspection


<sup>39</sup>. Base

<sup>40</sup>. Main jig

شبکه عصبی، شرایط تحت کنترل را برای فرآیند تولید بدنه خودرو گزارش می نمود، شبکه عصبی با ورود اطلاعات خودرو شماره ۳۴۹، سیگنال شرایط خارج از کنترل با نقطه تغییر در ۳۴۸ امین بدنه خودرو را به همراه اطلاعاتی مبنی بر اینکه هر دو مشخصه کیفی موجب شرایط خارج از کنترل شده اند پایش نمود. این گزارش در حالی بود که نمودار  $\chi^2$  هیچ سیگنالی را مبنی بر انحراف فرآیند را نشان نمی داد. حال آنکه گزارش شبکه عصبی نشان دهنده تغییر مثبت در هر دو مشخصه کیفی بود. گزارش نمودار  $\chi^2$  برای فرآیند تشریح شده، در شکل ۳ نشان داده شده است. این نمودار برخلاف شبکه عصبی نشان می هد که فرآیند در شرایط تحت کنترل است.



شکل شماره (۲): موقعیت فاصله های در صندوق عقب در بدنه خودرو مورد مطالعه



شکل شماره (۳): پایش فرآیند تولید بدنه خودرو با استفاده از نمودار  $\chi^2$

با استفاده از گزارش شبکه عصبی، بررسی ها نشان داد که کلمپ فیکسچری که متعلقات گلگیر زیر ساید را به هم متصل می نماید و در نهایت در فیکسچر اصلی به یکدیگر جوش می شوند، از بدنه ۳۴۷ به بعد نیروی لازم را برای نگهداشتن قطعات وارد نکرده است و فاصله ایی که در هنگام جوشکاری آنها الزامی است عملاً اتفاق نمی افتد. با رفع ایراد کلمپ فیکسچر فرآیند دوباره به شرایط طبیعی تحت کنترل بازگشت.

بدین ترتیب مورد کاوی فوق نشان داد که شبکه عصبی استفاده شده در فرآیند بدنه خودرو علاوه بر آنکه از روش مرسوم نمودار  $\chi^2$  حساس تر می باشد، بلکه اطلاعات نقطه تغییر، عامل تغییر و جهت تغییر را که نمودار مرسوم  $\chi^2$  توانایی پایش آنرا ندارد علاوه بر سیگنال شرایط خارج از کنترل، در اختیار مدیران فرآیند قرار می دهد.

### ۳- نتایج و بحث

پیچیدگی پایش فرآیندهای چند متغیره موجب گردیده است تا در ادبیات موضوع تعداد اندکی طرح برای پایش جامع و مدیریت همه جانبه فرآیندهای با بیش از یک متغیر ارائه شده باشد. در فرآیندهای با بیش از یک متغیر با ساختار همبسته، هنگامی که فرآیند در شرایط خارج از کنترل قرار می گیرد، مدیران فرآیند برای شناسایی و حذف عوامل تغییر در فرآیند نیازمند مدلی جامع هستند تا بتوانند شرایط خارج از کنترل فرآیند را به همراه نقطه تغییر، جهت تغییر و عوامل تغییر همزمان شناسایی نمایند. همزمانی دسترسی به اطلاعات فوق موجب اثربخش نمودن تجزیه و تحلیل ریشه ی فرآیند با کمترین هزینه در مقایسه با استفاده از طرح های متعدد می گردد.

در این تحقیق ضمن مروری جامع و کاربردی بر طرح های پایش فرآیندهای چند متغیره و مقایسه قابلیت های آنها، برترین مدل کاربردی موجود در ادبیات معرفی گردید. برای اثبات قابلیت های تئوریک مدل برتر، در عرصه فعالیت های واقعی، مدل فوق که با رویکرد شبکه عصبی طراحی شده است برای پایش خط تولید بدنه یک نوع اتومبیل گران قیمت در ایران بکارگرفته شد. بکارگیری مدل جامع فوق نشان داد که در عرصه اجرا و فعالیت واقعی فرآیندها می توان از مدل طراحی شده فوق به شکل بسیار مؤثری سود جست. به طوری که، با دسترسی به اطلاعات جامع و همزمان در شبکه عصبی فوق، امکان شناسایی و حذف سریع عوامل تغییر ناخواسته تحمیل شده به میانگین فرآیند فراهم میگردد.

### ۴- منابع

- 1- Ahmadzade, F., & Noorossana, R. (2008). Identifying the time of a step change with MEWMA control charts by artificial neural network. The 8th International Industrial Engineering and Engineering Management Conference, Singapore.
- 2- Alt, FB. (1985). Multivariate quality control. New York: Wiley.
- 3- Aparisi, F., Avendano G., & Sanz J. (2006). Techniques to interpret  $T^2$  control chart signal. IIE Transactions, 38,647-657.
- 4- Atashgar, K., & Noorossana, R. (2010a). Identifying change point in a bivariate normal process mean vector with monotonic change. International Journal of Industrial Engineer and Production Management. 1(21), 1-13.
- 5- Atashgar K., & Noorossana R. (2010b). Identifying and root cause analysis of monotonic change in mean vector using artificial neural network. 8<sup>th</sup> International Conference on Management, Iran, Tehran.
- 6- Atashgar, K., & Noorossana, R. (2011). An integrating approach to root-cause analysis of a bivariate mean vector with a linear trend disturbance. International Journal of Advance Manufacturing Technology, 52(1), 407-420
- 7- Atienza OO., & Ching, LT., & Wah, BA. (1998). Simultaneous monitoring of univariate and multivariate SPC information using boxplots. International Journal of Quality Science, 3(2), 194-204.
- 8- Chang SI., & Aw, CA. (1996). A neural fuzzy control chart for detecting and classifying process mean shifts. International Journal of Production Research, 34(8), 2265-2278.
- 9- Cheng, SC. (1995). A Multi-Layer Neural Network Model for Detecting Changes in the Process Mean. Computers industrial Engineering, 28(1), 51-61.
- 10- Cheng, CS. (1997). A neural network approach for the analysis of control chart patterns. International Journal of Production Research, 35(3), 667-697.
- 11- Choi, SW., Martin, EB., & Morris, AJ. (2005). Fault detection based on maximum-likelihood principal component analysis mixture. Industrial and Engineering Chemistry Research, 44, 2316-2327.
- 12- Crosier, RB. (1988). Multivariate generalizations of cumulative sum quality-control schemes. Technometrics, 30(3), 291-303.

- 13-Doganaksoy, N., Faltin, FW., & Tucker, WT. (1991). Identification of out-of-control multivariate characteristic in a multivariable manufacturing environment. *Communications in Statistics – Theory and Method*, 20, 2775-2790.
- 14-Fasso, A. (1999). One-sided MEWMA control charts. *Communications in Statistics-Theory and Methods*, 28(2), 381-401.
- 15-Fuch, C., & Benjamini, Y. (1994). Multivariate profile charts for statistical process control. *Technometrics*, 36(2), 182-195.
- 16-Garjani, M., Noorossana, R., & Saghaei, A. (2010). A neural network-based control scheme for monitoring start-up processes and short run. *International Journal of Advanced Manufacturing Technology*, 51(9-12), 1023-1032.
- 17-Guh, RS., & Tannock, TD. (1999). A neural network approach to characterize pattern parameters in process control charts. *Journal of Intelligent Manufacturing*, 10(5), 449-462.
- 18-Guh, RS.(2007).On-line Identification and Quantification of Mean Shifts in Bivariate Processes using a Neural Network-based Approach. *Quality and Reliability Engineering International*,23(3), 367-385.
- 19-Guo, Y., Dooly, KJ. (1992). Identification of change structure in statistical process control. *International Journal of Production Research*, 30(7) , 1655-1669.
- 20-Hawkins, DM. (1991). Multivariate quality control based on regression-adjusted variables. *Technometrics*, 33(1), 61-75.
- 21-Hawkins, DM. (1993). Regression adjustment for variables in multivariate quality control. *Journal of Quality Technology*, 25(3), 170–182.
- 22-Hayter, AJ. & Tsui, KL. (1994). Identification and quantification in multivariate quality control problems. *Journal of Quality Technology*, 26(3), 197–208.
- 23-Healy, JD. (1987). A note on multivariate CUSUM procedures. *Technometrics*, 29(4), 409-412.
- 24-Hotelling, H. (1947).*Multivariate quality control*. McGraw-Hill: New York.
- 25-Hwarng, H.B. & Hubele, NF. (1993). Back-Propagation pattern Recognizers for  $\bar{x}$  Control Charts: Methodology and Performance. *Computers industrial Engineering*, 24(2), 219-235.
- 26-Hwarng, HB., & Hubele, NF. (1993).  $\bar{x}$  control chart pattern identification through off-line neural network training. *IIE Transactions*, 25(3), 27-40.
- 27-Hwarng, HB., & Chong, CW. (1994). A fast-learning identification system for SPC: An adaptive resonance theory approach. *Intelligent Engineering System Artificial Network in Engineering*, 4, 1097-1102.
- 28-Hwarng, HB., & Chong, CW. (1995). Detecting process non-randomness through a fast and cumulative learning ART-based pattern recognizer. *International Journal of Production Research*, 33(7), 1817-1833.
- 29-Hwarng, HB. (1995). Multilayer perceptions for detecting cyclic data on control charts. *International Journal of Production Research*, 33(11) 3101-3117.
- 30-Hwarng, HB. (1997). A neural network approach to identifying cyclic behavior on control charts: A comparative study. *International Journal of Systems Science*, 28(1), 99-112.
- 31-Hwarng, HB. (2008). Toward identifying the source of mean shifts in multivariate SPC: a neural network approach. *International Journal of Production Research*, 46(20), 5531-5559.
- 32-Jackson, JE. (1991).*A user guide to principal components*. New York, John Wiley.
- 33-Kalagonda, AA., & Kulkarni, SR. (2003). Diagnosis of multivariate control chart signal based on dummy variable regression technique. *Communications in Statistics – Theory and Methods*, 32(8) 1665-1684.



- 34- Kourti, T., & MacGregor, JF. (1996). Multivariate SPC methods for process and product monitoring. *Journal of Quality Technology*, 28(4), 409–428.
- 35- Kramer, HG., & Schmid, W. (1997). EWMA charts for multivariate time series. *Sequential Analysis*, 16(2), 131-154.
- 36- Li, F., Runger, GC., & Tuv., E. (2006). Supervised learning for change-point detection. *International Journal of Production Research*, 44(14), 2853-2868.
- 37- Lowry, CA., Woodall, WH., Champ, CW., & Rigdon, SE. (1992). A multivariate Exponentially Weighted Moving Average control chart. *Technometrics*, 34(1), 46-53.
- 38- Maravelakis, PE., Bersimis, S., Panaretos, J., & Psarakis, S. (2002). Identifying the out of control variable in a multivariate control chart. *Communications in Statistics—Theory and Methods*, 31(12), 2391–2408.
- 39- Mason, RL., Tracy, ND., & Young, JC. (1995). Decomposition of  $T^2$  for multivariate control chart interpretation. *Journal of Quality Technology*, 27(2), 109–119.
- 40- Mason, RL., Tracy, ND., & Young, JC. (1997). A practical approach for interpreting multivariate  $T^2$  control chart signals. *Journal of Quality Technology*, 29(4), 396-406.
- 41- Mason, RL., & Young, JC. (1999). Improving the sensitivity of the  $T^2$  statistic in multivariate process control. *Journal of Quality Technology*, 31(2), 155-165.
- 42- Murphy, BJ. (1987). Selecting out-of-control variables with  $T^2$  multivariate quality procedures. *The Statistician*, 36, 571-583.
- 43- Nedumaran, G., Pignatiello, JJ., & Calvin, JA. (2000). Estimation of the Time of a Step Change with  $\chi^2$  Control Chart. *Quality Engineering*, 13(2), 153-159.
- 44- Ngai, HM., & Zhang, J. (2001). Multivariate cumulative sum control charts based on projection pursuit. *Statistica Sinica*, 11(3), 747-766.
- 45- Niaki, STA., & Abbasi, B. (2005). Fault diagnosis in multivariate control charts using artificial neural network. *Quality and reliability Engineering International*, 21(8), 825-840.
- 46- Noorossana, R., Atashgar, Karim., & Saghaei, A. (2011). An integrated supervised learning solution for monitoring process mean vector. *International Journal of Advance Manufacturing Technology*, 56, 755-765.
- 47- Noorossana, R., Arbabzadeh, N., Saghaie, A., & Paynabar, K. (2009). Developing the method to identifying the change point in a multivariate environment. 6<sup>th</sup> International Conference on Industrial Engineering, Iran, Tehran.

