

## استفاده از شبکه عصبی مصنوعی برای پایش پروفایل‌های پواسون و شناسایی پارامتر عامل هشدار

محسن رسولی

(نویسنده مسئول) دانشجوی کارشناسی ارشد، دانشکده مهندسی صنایع، دانشگاه صنعتی اصفهان، اصفهان، ایران،  
mohsen.rasouli@in.iut.ac.ir

غلامعلی رئیسی اردلی

استادیار دانشگاه صنعتی اصفهان، دانشکده مهندسی صنایع، اصفهان، ایران، raissi@cc.iut.ac.ir

امیرحسین امیری

استادیار دانشگاه شاهد، دانشکده فنی و مهندسی، تهران، ایران، amiri@shahed.ac.ir

علیرضا شرفی

کارشناس ارشد، دانشکده مهندسی صنایع، دانشگاه صنعتی امیرکبیر، تهران، ایران، a.sharafi@aut.ac.ir

**چکیده** گاهی اوقات رابطه بین یک متغیر پاسخ و یک یا چند متغیر مستقل، کیفیت یک محصول یا عملکرد یک فرآیند را تعیین می‌کند. محققان علم کنترل فرآیند آماری این رابطه را پروفایل می‌نامند. انواع مختلف پروفایل‌ها توسط محققان مختلف مورد بررسی قرار گرفته است. یک نوع از این پروفایل‌ها مبتنی بر الگوهای خطی تعمیم‌یافته می‌باشد. در پروفایل‌های خطی تعمیم‌یافته، متغیر پاسخ از توزیع‌های خانواده نمایی شامل دوجمله‌ای، پواسون، نمایی و گاما پیروی می‌کند. در این مقاله یک شبکه عصبی مصنوعی پرسپترون چند لایه برای پایش پروفایل‌های پواسون و تشخیص پارامتر عامل هشدار طراحی شده است. عملکرد شبکه پیشنهادی با استفاده از شبیه‌سازی و یک مثال عددی مورد بررسی قرار گرفته است. نتایج حاصله نشان‌دهنده عملکرد مناسب شبکه طراحی شده در پایش فرآیند و تشخیص پارامتر عامل هشدار است. در انتها عملکرد شبکه عصبی پیشنهادی با نمودار کنترل مبتنی بر آماره  $T^2$  در کشف شیفت در پارامترهای پروفایل پواسون مقایسه گردیده است.

**کلمات کلیدی** کنترل فرآیند آماری، پروفایل پواسون، شبکه عصبی مصنوعی، پرسپترون چندلایه، الگوی خطی تعمیم‌یافته

### 1- مقدمه

متغیر مستقل مورد بررسی قرار می‌گیرند. این رابطه که در طی سال‌های اخیر مورد توجه بسیاری از محققان قرار گرفته است، پروفایل نامیده می‌شود. این رابطه می‌تواند خطی، چندجمله‌ای، غیرخطی، و خطی تعمیم‌یافته باشد.

در دهه‌های گذشته در حوزه کنترل فرآیند آماری، نمودارهای کنترل (ارائه شده توسط شوهارت<sup>۱</sup> در سال 1924) ویژگی‌های کیفی فرآیند را مورد پایش قرار می‌دهد. نمودارهای کنترل مورد استفاده با توجه به تعداد ویژگی‌های مورد بررسی به دو دسته تک‌متغیره و چندمتغیره طبقه‌بندی شده‌اند. بعضی از نمودارهای کنترل از قبیل نمودار کنترل  $\bar{X}$ ، جمع تجمعی و میانگین متحرک موزون نمایی، تک‌متغیره و نمودارهای جمع تجمعی چندمتغیره، میانگین متحرک موزون نمایی چندمتغیره و  $T^2$ ، چندمتغیره هستند [1]. گاهی اوقات ویژگی‌های کیفی یک محصول یا فرآیند بوسیله رابطه بین متغیر پاسخ و یک یا چند

مستک<sup>۲</sup> و همکاران [2]، استور<sup>۳</sup> و بریل<sup>۴</sup> [3]، محمود<sup>۵</sup> و وودال<sup>۶</sup> [4]، گوپتا<sup>۷</sup> و همکاران [5]، وانگ<sup>۸</sup> و تی‌سانگ<sup>۹</sup> [6]، جین<sup>۱۰</sup> و شی<sup>۱۱</sup> [7 و 8]، وودال و همکاران [9]، کاظم‌زاده و همکاران

<sup>2</sup>Mestek

<sup>3</sup>Stover

<sup>4</sup>Brill

<sup>5</sup>Mahmoud

<sup>6</sup>Woodall

<sup>7</sup>Gupta

<sup>8</sup>Wang

<sup>9</sup>Tsung

<sup>10</sup>Jin

<sup>11</sup>Shi

<sup>1</sup>Shewhart

در این مقاله یک شبکه عصبی مصنوعی برای تشخیص و شناسایی شیفت‌ها در پروفایل پواسون توسعه داده می‌شود. شبکه عصبی مصنوعی مورد بررسی برای پایش پروفایل پواسون در فاز دوم پیشنهاد شده است. در بخش دوم این مقاله مروری کوتاه به رگرسیون پواسون و نمودار کنترل چندمتغیره  $T^2$  خواهیم داشت. در بخش سوم، شبکه عصبی مصنوعی و کاربرد آن در کنترل فرآیند آماری مورد بحث واقع خواهد شد. در بخش چهارم، درباره کاربرد شبکه عصبی مصنوعی در پروفایل پواسون بحث خواهد شد. در بخش پنجم یک مثال عددی برای بررسی عملکرد شبکه پیشنهادی استفاده می‌شود. مقایسه بین عملکرد شبکه پیشنهادی و نمودار کنترل  $T^2$  نیز در بخش پنجم ارائه خواهد شد. نتیجه‌گیری و پیشنهادات آتی نیز در بخش ششم ارائه می‌شود.

## 2- کلیات

در این بخش مدل رگرسیون پواسون و نمودار کنترل چندمتغیره  $T^2$  توضیح داده می‌شود.

### 2-1- مدل رگرسیون پواسون

رگرسیون پواسون یک تکنیک مناسب برای مطالعه داده‌های شمارشی است (کلنوم<sup>۱</sup> و همکاران ۱۹۹۷) [22]. وقتی متغیر پاسخ در مسئله تنها مقادیر صحیح نامنفی (0, 1, 2, ...) را اخذ کند از رگرسیون پواسون استفاده می‌شود. در این الگو متغیرهای پاسخ  $y_1, y_2, \dots, y_n$  از توزیع مستقل با  $E(y_i) = \lambda_i$  و  $var(y_i) = \lambda_i$  تبعیت می‌کنند. در یک مدل رگرسیون پواسون فرض می‌شود  $n$  آزمایش مستقل صورت می‌گیرد. در هر آزمایش  $p$  متغیر مستقل  $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})^T$  در نظر گرفته شده است. متغیر پاسخ به صورت  $y_i$  ( $i = 1, 2, \dots, n$ ) نشان داده می‌شود. هر  $y_i$  از توزیع پواسون با پارامتر  $\lambda_i$  پیروی می‌کند و مقادیر آن نمی‌تواند منفی باشد. تابع پیوند این مدل به صورت رابطه (1) بیان می‌شود.

$$g(\lambda_i) = \log(\lambda_i) = \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} \quad (1)$$

در رابطه (1)،  $\beta = (\beta_1, \beta_2, \dots, \beta_p)^T$  بردار پارامترهای مدل است. معمولاً  $x_{i1} \equiv 1$  در نظر گرفته می‌شود.  $\beta_1$  نیز عرض از مبدأ است. مدل رگرسیون پواسون را می‌توان به صورت رابطه (2) ساده کرد.

[10]، سلیمانی و همکاران [11] و کنک<sup>۱</sup> و آلبین<sup>۲</sup> [12] کاربردهای عملی مختلف پروفایل‌ها را در صنعت بیان کردند.

واکر<sup>۳</sup> و رایت<sup>۴</sup> [13] یک مدل رگرسیون غیرخطی را برای بیان تراکم عمودی تخته نئوپان به عنوان تابعی از عمق مورد استفاده قرار دادند. کنگ و آلبین [12] یک رگرسیون خطی را بین فشار اندازه‌گیری شده توسط کنترل‌کننده جریان گاز و جریان گاز به کار بردند. امیری و همکاران [14] رابطه بین گشتاور و دور موتور خودرو را از طریق یک رگرسیون چندجمله‌ای مورد بررسی قرار دادند.

در رابطه با پایش پروفایل‌های خطی مطالعات گسترده‌ای در فازهای اول و دوم مورد بررسی قرار گرفته است. کیم<sup>۵</sup> و همکاران [15] سه نمودار کنترل میانگین متحرک موزون نمایی برای پایش عرض از مبدأ، شیب و واریانس باقی‌مانده‌ها به کار بردند. نیاکي و همکاران [16] بر پایه یک مدل آماری خطی تعمیم‌یافته و نمودار کنترل دامنه به پایش پروفایل‌های خطی ساده پرداختند. زو<sup>۶</sup> و همکاران [17] بر اساس آماره نسبت درست‌نمایی به پایش پروفایل‌های خطی ساده در فازهای اول و دوم اقدام نمودند. سقایی و همکاران [18] از نمودارهای کنترل جمع تجمعی برای پایش پروفایل خطی استفاده کردند.

برای پایش پروفایل‌های پیچیده‌تر از قبیل پروفایل‌های چندجمله‌ای، غیرخطی و خطی تعمیم‌یافته بعضی از روش‌ها پیشنهاد شده است. کاظم‌زاده و همکاران [10] با استفاده از روش‌های طراحی شده به پایش پروفایل‌های لجستیک پرداختند. یه<sup>۷</sup> و همکاران [19] چندین نمودار کنترل  $T^2$  را برای پایش پروفایل لجستیک مورد بررسی قرار دادند. شرفی و همکاران [20] با استفاده از روش برآوردکننده حداکثر درست‌نمایی به شناسایی زمان واقعی تغییر پله‌ای در پایش فاز دوم پروفایل‌های لجستیک پرداخته‌اند. کوشا و امیری [21] اثر حضور خودهمبستگی بین مشاهدات در سطوح مختلف متغیر مستقل در رگرسیون لجستیک را مورد بررسی قرار داده و روشی مبتنی بر مدل‌های ترکیبی خطی تعمیم‌یافته را برای در نظر گرفتن خود همبستگی و پایش این نوع از پروفایل‌ها ارائه دادند.

<sup>1</sup> Kang

<sup>2</sup> Albin

<sup>3</sup> Walker

<sup>4</sup> Wright


<sup>5</sup> Kim

<sup>6</sup> Zou

<sup>7</sup> Yeh

<sup>8</sup> Kleinbaum





شکل 2: ساختار شبکه پرسپترون چندلایه با یک لایه پنهان

با تعیین تعداد لایه‌ها مطالعاتی انجام دادند. این مطالعات نشان داد که برای حل هر مسئله پچیده حداکثر پنج لایه نیاز است. برای شروع، استفاده از یک شبکه عصبی مصنوعی سه لایه که دارای یک لایه ورودی، یک لایه پنهان و یک لایه خروجی است، مناسب می‌باشد. تعداد نورون‌ها در این لایه پنهان از طریق سعی و خطا تعیین می‌گردد [26].

وزن‌ها و ارب‌های شبکه باید به گونه‌ای انتخاب گردد که خطای پیش‌بینی در شبکه عصبی مصنوعی به حداقل رسد. برای این منظور از داده‌های گذشته که توسط کاربر تهیه شده است، استفاده می‌گردد. این فرایند معادل با برازش مدل ارائه شده توسط شبکه برای داده‌های آموزشی موجود است. خطای شبکه می‌تواند به صورت مقایسه خروجی واقعی با خروجی مطلوب تعیین گردد. رایج‌ترین تابع خطای مورد استفاده در ادبیات، مجموع مربعات خطا است. در این تابع هر خطا به صورت مجزا مجذور می‌گردد و سپس مجذور تمام خطاها با یکدیگر جمع می‌گردد.

### 3-2- الگوریتم آموزشی پس‌انتشار خطا

این الگوریتم در سال 1986 توسط روملهارت<sup>1</sup> و همکاران [27] مورد استفاده قرار گرفت. یکی از بهترین الگوریتم‌های آموزشی، الگوریتم آموزشی پس‌انتشار است [25] و [28]. اگرچه الگوریتم‌های جدید مانند گرادیان کاهشی مزدوج و لوبنرگ مارکوات [24] در بسیاری از مسائل به خوبی رفتار می‌کنند اما هنوز الگوریتم آموزشی پس‌انتشار در بسیاری از شرایط مزیت بیشتری دارد. همچنین الگوریتم ساده‌ای برای درک کردن است. در این مقاله از الگوریتم پس‌انتشار استفاده شده است.

به دلیل تشابه نحوه محاسبه ضرایب رگرسیون پواسون و رگرسیون لجستیک و هم خانواده بودن هر دو توزیع (خانواده نمایی) و استفاده از نمودار کنترل  $T_1^2$  برای رگرسیون لجستیک، در این مقاله نیز از نمودار کنترل  $T_1^2$  برای رگرسیون پواسون جهت شبیه‌سازی و مقایسه استفاده شده است.

### 3- شبکه‌های عصبی مصنوعی و کاربرد آن در کنترل فرآیند آماری

شبکه عصبی مصنوعی پیشنهادی در این مقاله یک شبکه پرسپترون چندلایه با الگوریتم آموزشی پس‌انتشار است. اکنون به ارائه توضیحی مختصر در مورد شبکه پرسپترون چندلایه و الگوریتم آموزشی پس‌انتشار خطا می‌پردازیم.

#### 3-1- شبکه عصبی پرسپترون چندلایه

شبکه‌های عصبی پرسپترون یکی از معروف‌ترین ساختارهای شبکه عصبی مصنوعی است [24]. در شبکه پرسپترون چندلایه، نورون‌ها در یک ساختار پیشخور مرتب شده‌اند. نورون‌ها جمع وزنی ارب‌های مرتبط با ورودی‌های خود را انجام می‌دهند. سپس این سطح فعالیت از تابع تحریک برای تولید لایه خروجی مرتبط با خود عبور می‌کند. بنابراین شبکه یک تفسیر ساده از مدل ورودی - خروجی است. در یک شبکه عصبی پرسپترون چندلایه، هر ورودی به هر نورون در لایه پنهان متصل شده است. شکل 2 ساختار یک شبکه عصبی پرسپترون چند لایه با یک لایه پنهان را نشان می‌دهد. خروجی هر نورون در لایه اول به هر نورون در لایه دوم متصل شده است و خروجی لایه دوم به ورودی لایه سوم متصل گردیده است. موضوع مهم در طراحی شبکه عصبی پرسپترون چندلایه، تخصیص تعداد لایه‌های پنهان و تعداد نورون‌ها در این لایه‌های پنهان می‌باشد [24 و 25].

تعداد نورون‌های لایه ورودی و خروجی توسط مسئله مورد بررسی تعیین می‌شوند. البته ممکن است در رابطه با تعداد نورون‌های ورودی عدم قطعیت وجود داشته باشد. در تعیین تعداد لایه‌های پنهان هیچ محدودیتی وجود ندارد، اما معمولاً یک یا دو لایه در نظر گرفته می‌شود. بعضی از محققان در رابطه

<sup>1</sup>Rumelhart

تعیین شیفیت در میانگین فرآیند پیشنهاد داد. چنگ<sup>۲</sup> [33] یک شبکه عصبی مصنوعی پیشخور سه لایه با الگوریتم یادگیری پس‌انتشار برای تشخیص روندهای تدریجی و تغییرات ناگهانی در میانگین فرآیند پیشنهاد داد. ولاسکو<sup>۳</sup> و روئی<sup>۴</sup> [34] یک شبکه عصبی مصنوعی برای اندازه‌گیری خودکار<sup>۵</sup> ثبات فرآیند و طبقه‌بندی الگوهای غیرطبیعی برای دسته‌بندی‌هایی از قبیل روندهای صعودی<sup>۶</sup>، روندهای نزولی<sup>۷</sup>، الگوهای دوره‌ای<sup>۸</sup>، الگوهای ترکیبی<sup>۹</sup> و الگوهای لایه‌بندی<sup>۱۰</sup> پیشنهاد دادند. لگر<sup>۱۱</sup> و همکاران [35]، امکان‌پذیری استفاده همزمان از نمودارهای کنترل جمع تجمعی و شبکه عصبی مصنوعی با یکدیگر را جهت ردیابی و تشخیص عیب بررسی کردند. استراتژی لگر و همکاران [35] شامل یک فرآیند سه مرحله‌ای است. مرحله اول، به تشخیص یک انحراف با دلیل توسط یک نمودار کنترل جمع تجمعی می‌پردازد. مرحله دوم، الگویی برای توصیف فرآیند در زمان تشخیص انحراف با دلیل ایجاد می‌کند. مرحله سوم، با استفاده از یک مدل شبکه عصبی مصنوعی به تشخیص الگو می‌پردازد. وانگ و چن [36] یک مدل عصبی - فازی برای تشخیص تغییرات میانگین در فرآیند چندمتغیره و طبقه‌بندی بزرگی تغییرات پیشنهاد دادند. نیاک و عباسی [37] برای شناسایی متغیر عامل انحراف در زمانی که حالت خارج از کنترل توسط یکی از نمودارهای کنترل چندمتغیره شناسایی می‌شود، شبکه عصبی پرسپترون چندلایه را پیشنهاد دادند. احمدزاده [38] دو روش را برای شناسایی زمان تغییرات پله‌ای در میانگین فرآیند چندمتغیره با استفاده از نمودار کنترل میانگین متحرک موزون نمایی چندمتغیره ارائه کرد. این دو روش، برآوردکننده حداکثر درست‌نمایی و شبکه عصبی مصنوعی است. آتشگر و نورالسنا [39] یک شبکه عصبی مصنوعی پرسپترون چندلایه به منظور شناسایی نقطه تغییر در یک فرآیند دو متغیره در زمانی که تغییرات میانگین فرآیند به‌طور خطی و همزمان است ارائه دادند. نورالسنا و همکاران [40] با استفاده از شبکه عصبی مصنوعی، به‌طور همزمان به تشخیص یک وضعیت خارج از کنترل، شناسایی نقطه تغییر در بردار میانگین و تعیین متغیرهای عامل هشدار پرداختند.

در روش پس‌انتشار، بردار گرادینان سطح خطا با توجه به وزن‌های قابل اصلاح شبکه محاسبه می‌شود. سپس اگر مسیر کوتاه طی شود، خطا کاهش می‌یابد. گاهی اوقات این حرکت به آهستگی صورت می‌گیرد، به طوری که به کمترین مقدار نزدیک می‌شود و در نهایت حداقل مقدار ترتیبی پدیدار می‌گردد. بخش مشکل تصمیم‌گیری در مورد اندازه گام‌ها است. گام‌های بلند ممکن است به سرعت همگرا شود؛ اما همچنین ممکن است از جواب عبور کند یا در مسیر اشتباه حرکت کند (اگر سطح خطا نامتعارف باشد). نمونه کلاسیک پس‌انتشار در آموزش شبکه عصبی جایی است که در امتداد یک شیب تند خیلی آهسته حرکت می‌کند و از یک سمت به سمت دیگر جهش می‌یابد. بر عکس آن اگرچه گام‌های خیلی کوچک ممکن است در جهت صحیح حرکت کند اما نیازمند تعداد زیاد از دوره‌های تکرار است. در عمل اندازه گام‌ها نسبتی از شیب و مقداری ثابت است.

به طور کلی الگوریتم پس‌انتشار با گذشت دوره پیشرفت می‌کند. در هر دوره، موارد آموزشی بر حسب شبکه و خروجی‌های واقعی هدف پیشنهاد می‌شوند. سپس مقدار خطا محاسبه و مقایسه می‌شود. این خطا همراه به گرادینان سطح خطا برای تنظیم وزن‌ها استفاده می‌شود. در نهایت این فرآیند تکرار می‌شود. پیکره اولیه شبکه، تصادفی است. آموزش زمانی متوقف می‌شود که تعداد دوره‌ها به پایان برسد، یا مقدار خطا به سطح قابل قبولی برسد، یا بهبود خطا متوقف شود. کاربرد شبکه‌های پرسپترون چندلایه شامل انتخاب بردارهای مشخصه، ایجاد طراحی شبکه، انتخاب تابع فعال‌سازی و آموزش است [25].

### 3-4- به‌کارگیری شبکه‌های عصبی مصنوعی در کنترل فرآیند آماری

نمودارهای کنترل فرآیند آماری از رایج‌ترین ابزارها برای پایش ثبات و تغییرپذیری فرآیند است. گاهی اوقات این نمودار قادر به تشخیص و طبقه‌بندی درست خطاهای فرآیند نیست. بسیاری از محققان کنترل کیفیت روش‌های جایگزینی از جمله شبکه‌های عصبی مصنوعی برای پایش فرآیند پیشنهاد داده‌اند [29 و 30]. شبکه‌های عصبی مصنوعی از سال 1989 در کنترل کیفیت مورد استفاده قرار گرفت [31]. پوق<sup>۱</sup> [31] یک شبکه عصبی مصنوعی پیشخور سه لایه با الگوریتم یادگیری پس‌انتشار برای تعیین تغییرات در میانگین فرآیند پیشنهاد داد. از طرفی پوق [32] یک شبکه عصبی مصنوعی پس‌انتشار چهار لایه برای

<sup>2</sup>Cheng

<sup>3</sup> Velasco

<sup>4</sup> Rowe

<sup>5</sup> Automatic

<sup>6</sup> Upward trends

<sup>7</sup> downward trends

<sup>8</sup> cycle patterns

<sup>9</sup> mixture patterns

<sup>10</sup> stratification patterns

<sup>11</sup> Leger

<sup>1</sup> Pugh

نورون در لایه خروجی انتخاب می‌شود. از طرفی برای شناسایی پارامترهای عامل هشدار در زمانی که وضعیت خارج از کنترل رخ می‌دهد دو نورون دیگر در لایه خروجی در نظر گرفته می‌شود. بنابراین در مجموع برای لایه خروجی سه نورون انتخاب می‌شود. برای شبکه عصبی پیشنهادی یک لایه پنهان انتخاب شده است. تعداد نورون‌ها در این لایه پنهان از طریق سعی و خطا انتخاب می‌شوند.

#### 4-2- آموزش داده‌ها در شبکه عصبی مصنوعی پیشنهادی

برای طراحی و آموزش شبکه عصبی مصنوعی لازم است از داده‌های آموزشی مناسب استفاده شود. بنابراین از داده‌های تحت کنترل و خارج از کنترل استفاده می‌کنیم. در شبکه پیشنهادی، نمونه‌هایی به اندازه 900 از یک فرآیند تحت کنترل تولید می‌شود. سپس عرض از مبدأ و شیب برای هر نمونه برآورد می‌گردد. این دو مقدار برآورد شده مولفه‌های ورودی برای آموزش داده‌ها است. هدف متناظر برای هر یک از این مولفه‌ها برابر با مقدار صفر است. از طرفی نمونه‌هایی به اندازه 900 از یک فرآیند خارج از کنترل تولید می‌شود. انحرافات با دلیل می‌تواند منجر به شیفت در عرض از مبدأ، شیب و یا به‌طور همزمان شیفت در عرض از مبدأ و شیب شود. برای هر یک از این انحرافات با دلیل تعداد نمونه‌های برابر در نظر گرفته می‌شود. برای نمونه‌های تولید شده از فرآیند خارج کنترل، مقادیر هدف آموزش داده‌ها برابر با مقدار یک است. در شرایطی که فرآیند در حالت خارج از کنترل است، نه تنها مقدار هدف اولین نورون خروجی برابر با مقدار یک است، بلکه مقدار هدف نورون‌های خروجی متناظر با پارامترهایی که مقدار آن‌ها شیفت پیدا کرده است نیز برابر با مقدار یک است. در این شرایط مقادیر هدف نورون‌هایی که مشخصه‌های نظیر آن‌ها شیفت نیافته است همگی برابر با مقدار صفر خواهد بود. تعداد نمونه‌های تولیدی برای حالت تحت کنترل برابر با مجموع تعداد نمونه‌های تولیدی برای همه حالت‌های خارج از کنترل است. ورودی‌های شبکه عصبی مصنوعی پیشنهادی طبق الگوریتمی که در شکل (1) نشان داده شده است بدست می‌آید.

#### 4-3- مرحله آموزش شبکه عصبی مصنوعی پیشنهادی

واقفی [41] رویکردهای پارامتری، ناپارامتری و هوش مصنوعی مبتنی بر شبکه عصبی را جهت پایش پروفایل‌های غیرخطی در فاز دوم پیشنهاد داد. زرندی و علاالدینی [42] برای پایش پروفایل خطی ساده در فاز دوم دو روش را با استفاده سیستم‌های استنتاج عصبی - فازی تطبیقی<sup>۱</sup> مورد بررسی قرار داده‌اند. پاسلا<sup>۲</sup> و سمیرارو<sup>۳</sup> [43] به ارائه روش شبکه عصبی تئوری تشدید تطبیقی<sup>۴</sup> فازی برای پایش پروفایل غیرخطی در فاز دوم پرداختند. حسینی‌فرد و همکاران [44] پایش پروفایل‌های خطی ساده را با استفاده از شبکه‌های عصبی مصنوعی مورد بررسی قرار داده‌اند و شبکه عصبی پرسپترون چندلایه با ورودی‌های متفاوت برای کشف تغییر در پارامترهای پروفایل خطی ساده ارزیابی نمودند.

#### 4-4- استفاده از شبکه‌های عصبی پرسپترون برای پایش پروفایل پواسون

با به‌کارگیری شبکه عصبی پرسپترون، تشخیص شیفت‌ها در پایش پروفایل همانند یک مسئله طبقه‌بندی مدل می‌شود. بنابراین انتظار می‌رود که شبکه عصبی پرسپترون داده‌های خارج از کنترل را از داده‌های تحت کنترل تفکیک کند. شبکه عصبی مصنوعی برای پایش پروفایل پواسون در این مقاله توسعه داده شده است. این شبکه، یک شبکه عصبی پرسپترون چندلایه برای تشخیص تحت کنترل بودن یا نبودن فرآیند و شناسایی پارامتر عامل هشدار (عرض از مبدأ، شیب یا هر دو) با استفاده از مقادیر برآورد شده ضرائب رگرسیون است.

#### 4-1- ساختار شبکه عصبی مصنوعی پیشنهادی

برای اینکه بتوان یک شبکه عصبی پرسپترون چندلایه را طراحی نمود نیاز است تعداد نورون‌های هر لایه تعیین گردد. تعداد نورون‌های لایه ورودی و خروجی با توجه به مسئله مورد بحث تعیین می‌گردند. تعداد نورون‌های لایه پنهان از طریق سعی و خطا در مرحله آموزش تعیین می‌شود. برای شبکه پیشنهادی، دو متغیر ورودی در نظر گرفته می‌شود. اولین و دومین ورودی به ترتیب عرض از مبدأ و شیب برآورد شده هستند. بنابراین دو نورون در لایه ورودی قرار می‌گیرد. برای اینکه بتوان وضعیت‌های تحت کنترل و خارج از کنترل را طبقه‌بندی نمود یک

<sup>1</sup> Adaptive neuro-Fuzzy Inference Systems - ANFIS

<sup>2</sup> Pacella

<sup>3</sup> Semeraro

<sup>4</sup> Adaptive Resonance Theory - ART

در این بخش برای ارزیابی عملکرد شبکه عصبی مصنوعی پیشنهادی مثالی ارائه شده است. نتایج حاصل از این شبکه با روش  $T_1^2$  مقایسه شده است. در این مقاله، برای برآورد مقدار متوسط طول دنباله نمودار کنترل  $T_1^2$  از 10000 تکرار شبیه-سازی استفاده شده است. در این مثال فرض می‌شود تعداد متغیرهای پیش‌گو در پروفایل رگرسیون پواسون برابر با دو است. بنابراین تابع رابط به صورت  $g(\lambda_i) = \beta_1 + \beta_2 x_i$  است، که  $\beta_1$  و  $\beta_2$  به ترتیب عرض از مبدأ و شیب تابع رگرسیون پواسون است و به صورت بردار  $\beta = (\beta_1, \beta_2)^T$  نمایش داده می‌شود. همچنین ماتریس  $X$  بدین صورت در نظر گرفته شده است:

$$X = \begin{pmatrix} 1 & 1 & \dots & 1 & 1 \\ \log(0.1)\log(0.2) & \dots & \log(0.8)\log(0.9) \end{pmatrix}^T$$

برای این مثال فرض می‌شود که مقدار  $\beta$  اولیه برآورد شده از داده‌های گذشته در فاز اول،  $(4, -1)^T$  است. بردار ماتریس کواریانس پارامترهای رگرسیون پواسون ( $\Sigma$ ) در فاز دوم طبق رابطه (9) بدین صورت است:

$$\Sigma = \begin{pmatrix} 0.0029 & 0.0016 \\ 0.0016 & 0.0011 \end{pmatrix}$$

در این مقاله فرآیند خارج از کنترل برای بردار  $\beta$  که از  $\beta_0$  به  $\tilde{\beta} = \beta_0 + \Delta$  تغییر می‌کند، در نظر گرفته شده است. به طوری که  $\Delta = (\delta_1 \sigma_1, \delta_2 \sigma_2)^T$  و  $\delta_1$  و  $\delta_2$  مقادیری ثابت هستند. در اینجا، میزان شیفت در بردار  $\beta$  بر اساس پارامتر غیرمرکزی (ncp) که به صورت رابطه (10) تعریف شده است، در نظر گرفته شده است.

$$ncp = \Delta^T \Sigma_0^{-1} \Delta \quad (10)$$

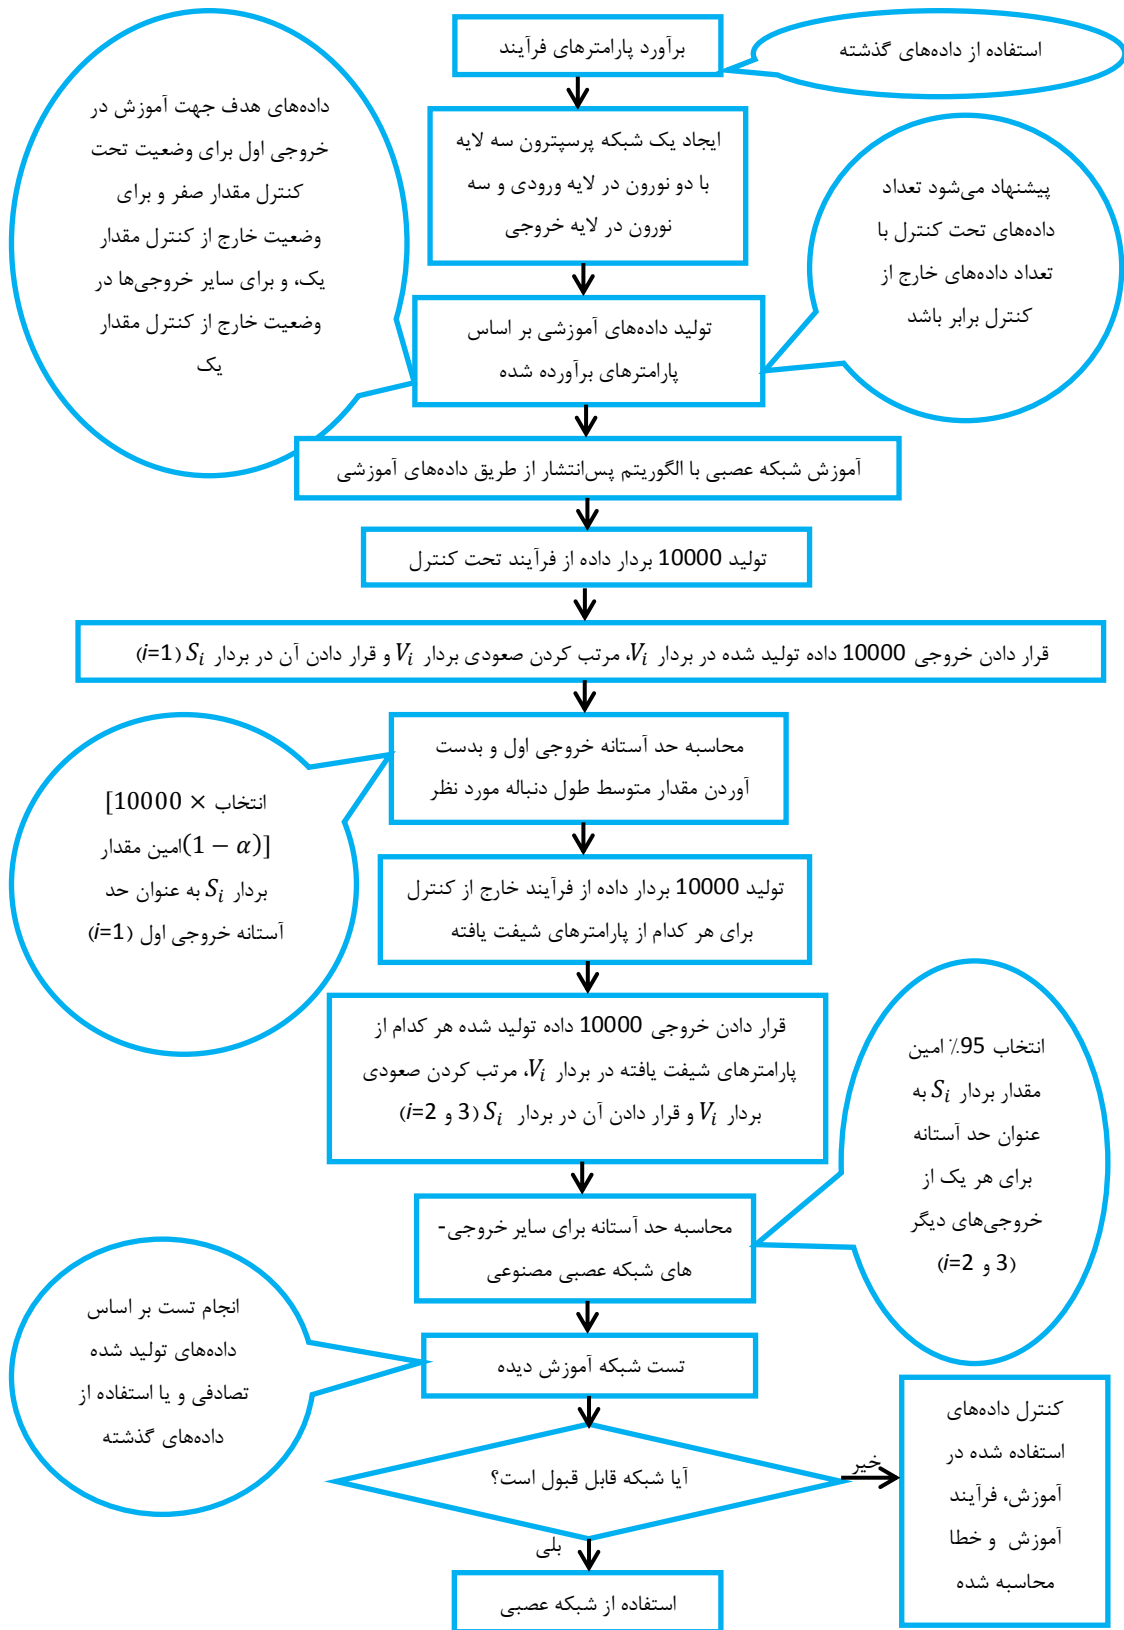
برای تشخیص و شناسایی، شیفت‌هایی در حد سه انحراف استاندارد مد نظر قرار گرفته است. انواع طبقه‌بندی‌هایی که انتظار می‌رود شبکه عصبی مصنوعی آن‌ها را شناسایی کند عبارتند از: 1- فرآیند تحت کنترل است و پارامترهای فرآیند هیچ تغییری نکرده‌اند. 2- پارامتر عرض از مبدأ به اندازه سه انحراف استاندارد خود شیفت یافته است. 3- پارامتر شیب به اندازه سه انحراف استاندارد خود شیفت یافته است. 4- پارامترهای عرض از مبدأ و شیب هر دو به اندازه سه انحراف استاندارد خود شیفت یافته‌اند.

در این مقاله از الگوریتم آموزشی پس‌انتشار خطا برای آموزش شبکه عصبی مصنوعی استفاده می‌شود. برای ارزیابی عملکرد شبکه عصبی، از معیار مجموع مربعات خطا استفاده شده است. تعداد تکرارهای آموزش تا زمانی ادامه دارد که مجموع مربعات خطا به اندازه کافی کوچک شود و در تکرارهای بعدی کاهش خطا رخ ندهد.

#### 4-4- پیاده‌سازی شبکه عصبی مصنوعی آموزش دیده

بعد از آموزش شبکه عصبی مصنوعی، این شبکه باید قادر باشد وضعیت‌های تحت کنترل را شناسایی و متوسط طول دنباله تحت کنترل را تعیین کند. بدین منظور یک حد آستانه برای شناسایی وضعیت خارج از کنترل برای اولین خروجی مورد نیاز است. هنگامی که یک بردار ورودی به شبکه عصبی مصنوعی وارد می‌شود و خروجی‌ها محاسبه می‌شوند در ابتدا فقط باید به خروجی اول شبکه عصبی توجه داشت. اگر خروجی اول در شبکه عصبی طراحی شده از مقدار حد آستانه برای حالت خارج از کنترل بیشتر باشد فرآیند خارج از کنترل تشخیص داده می‌شود و برای تعیین پارامترهای عامل هشدار مربوط به وضعیت خارج از کنترل به مقادیر دیگر نوروها در لایه خروجی توجه می‌شود. برای اینکه بتوانیم مقدار حد آستانه در نورو اول لایه خروجی را بر اساس احتمال خطای نوع اول و  $ARL_0$  تعیین کنیم، 10000 داده تحت کنترل تولید کرده و این داده‌ها را به عنوان ورودی‌های شبکه عصبی مصنوعی آموزش دیده در نظر می‌گیریم. سپس مقدار مشاهده شده نورو اول لایه خروجی در برداری به نام  $S_1$  به صورت صعودی مرتب می‌گردد. مقدار حد آستانه نورو اول عددی است که  $100(1 - \alpha)\%$  خروجی‌ها از آن کمتر باشد. برای تعیین مقادیر حد آستانه دیگر خروجی‌های شبکه به غیر از نورو اول لایه خروجی، برای هر وضعیت خارج از کنترل که تنها یک پارامتر شیفت یافته است، 10000 بردار تصادفی تولید می‌شود. مقدار برش برای نورو خروجی که در بردار ورودی پارامتر متناظرش شیفت یافته است برابر با عددی است که  $99/5\%$  خروجی‌های آن از مقدار برش بیشتر باشد. شکل 3 به طور خلاصه مراحل شبکه عصبی پیشنهادی را نشان می‌دهد.

#### 5- ارزیابی و مقایسه





شکل 3: فلوجارت گام به گام روش استفاده از شبکه عصبی مصنوعی در پایش پروفایل پواسون

کنترل برای  $T_1^2$  برابر با 193/94 است که تقریباً با متوسط طول دنباله تحت کنترل شبکه عصبی طراحی شده یکسان بوده و می‌توان عملکرد دو روش را در کشف شیفت در پارامترهای مدل رگرسیون پواسون با یکدیگر مقایسه کرد. سه سطح مختلف شیفت در مطالعات شبیه‌سازی در نظر گرفته شده است.

برای تعیین پارامترهای عامل وضعیت خارج از کنترل باید مقادیر حد آستانه در خروجی‌های دوم و سوم محاسبه شود. بدین منظور 10000 بردار در حالتی که پارامتر اول به اندازه سه انحراف استاندارد شیفت نموده است تولید می‌شود. این بردارها وارد شبکه عصبی پیشنهادی می‌شود. خروجی دوم شبکه عصبی پیشنهادی در بردار  $S_2$  به صورت صعودی قرار می‌گیرد. مقدار حد آستانه خروجی دوم برابر است با عددی که 0/995 مقادیر بردار  $S_2$  از آن بزرگتر است. در این مثال مقدار حد آستانه خروجی دوم شبکه پیشنهادی برابر با 0/57566 است. مقدار حد آستانه خروجی سوم نیز مشابه مقدار حد آستانه خروجی دوم بدست می‌آید. 10000 بردار در حالتی که پارامتر دوم به اندازه سه انحراف استاندارد شیفت نموده است تولید می‌شود. این بردارها وارد شبکه عصبی پیشنهادی می‌شود. خروجی سوم شبکه عصبی پیشنهادی در بردار  $S_3$  به صورت صعودی قرار می‌گیرد. مقدار حد آستانه خروجی سوم برابر است با عددی که 0/995 مقادیر بردار  $S_3$  از آن بزرگتر است. در این مثال مقدار حد آستانه خروجی سوم شبکه پیشنهادی برابر با 0/54876 است. اکنون با مشخص شدن مقادیر حد آستانه، شبکه عصبی پیشنهادی برای کنترل فرآیند مورد استفاده قرار می‌گیرد. اگر یک بردار طبق مقادیر برآورد شده از پارامترها به شبکه عصبی وارد شود، شبکه عصبی پیشنهادی سه خروجی را نتیجه می‌دهد. در ابتدا مقدار خروجی اول شبکه مورد بررسی قرار می‌گیرد. اگر مقدار خروجی اول از مقدار 0/6199 بزرگتر باشد، فرآیند خارج از کنترل است. اگر مقدار خروجی کمتر از 0/6199 باشد، فرآیند تحت کنترل است. هرگاه شبکه عصبی پیشنهادی فرآیند را خارج از کنترل تشخیص دهد، آنگاه مقادیر خروجی‌های دوم و سوم مورد توجه قرار می‌گیرد. در این حالت اگر مقدار خروجی دوم بزرگتر از 0/57566 و مقدار خروجی سوم کوچکتر از 0/54876 باشد پارامتر اول (عرض از مبدأ) به عنوان عامل هشدار شناخته می‌شود. اما اگر مقدار خروجی دوم کمتر از 0/57566 و مقدار خروجی سوم بزرگتر از 0/54876 باشد، آنگاه پارامتر دوم (شیب) به عنوان عامل هشدار معرفی خواهد شد. هرگاه مقدار خروجی دوم از 0/57566 بزرگتر و مقدار خروجی سوم از 0/54876 باشد آنگاه هر دو پارامتر اول و

خطای نوع اول برابر با 0/005 در نظر گرفته شده است. با توجه به توضیحات بخش (2-2) مقدار حد کنترل بالا بر اساس روش  $T_1^2$  برابر با 10/59 است. طبق حد کنترل بالای بدست آمده، با 10000 تکرار متوسط طول دنباله تحت کنترل بر اساس روش  $T_1^2$  برابر با 193/94 (  $ARL_0 = 193/94$  ) است.

برای تهیه داده‌های آموزشی مورد نیاز شبکه عصبی پیشنهادی، 900 نمونه بردار تصادفی از فرآیند تحت کنترل تولید شده و بردار خروجی متناظر آن‌ها بردار صفر در نظر گرفته می‌شود. برای هر یک از الگوهای خارج کنترل نیز 300 نمونه بردار تصادفی که هر کدام از پارامترها به اندازه 3 انحراف استاندارد شیفت پیدا کرده است تولید می‌شود. اگر فقط پارامتر عرض از مبدأ شیفت پیدا کرده باشد، بردار هدف شبکه به صورت  $(1,1,0)^T$  است. اگر فقط پارامتر شیب، شیفت یافته باشد بردار هدف،  $(1,0,1)^T$  است. در شرایطی که هر دو پارامتر عرض از مبدأ و شیب به طور همزمان شیفت یابند، بردار هدف شبکه به صورت  $(1,1,1)^T$  می‌باشد. برای حالتی که هیچ پارامتری شیفت نیافته است، بردار هدف متناظر را  $(0,0,0)^T$  در نظر گرفته می‌شود. بدین ترتیب در مجموع 1800 بردار برای آموزش شبکه تولید شده است. در مرحله بعد، هر مجموعه از نمونه‌های تولید شده به صورت منفرد به عنوان یک ورودی به شبکه عصبی مصنوعی اعمال می‌گردد و خروجی آن با بردار هدف متناظر مقایسه شده و میانگین مربع خطا محاسبه می‌گردد. 13 نرون در لایه پنهان شبکه عصبی پیشنهادی در نظر گرفته می‌شود. بعد از 806 دوره در مرحله آموزش، مقدار مجموع مربعات خطا برای شبکه پیشنهادی 0/0040589 است. به این ترتیب مرحله آموزش شبکه عصبی به پایان می‌رسد.

بعد از تولید 10000 نمونه تصادفی تحت کنترل و محاسبه خروجی متناظر از شبکه عصبی، خروجی‌های مرتب شده در بردار  $S_1$  ذخیره می‌شوند. برای تعیین  $ARL_0$  روش شبکه عصبی، مقدار حد آستانه شبکه عصبی پیشنهادی در خروجی اول برابر با 0/6199 است. در مطالعه شبیه‌سازی با استفاده از نرم‌افزار *MATLAB 7*، برای 10000 تکرار، متوسط طول دنباله تحت کنترل برای شبکه پیشنهادی، مقدار 189/5427 بدست می‌آید. از طرفی باید توجه داشت که متوسط طول دنباله تحت

دوم و سوم متناظر خودشان کوچکتر نباشند، یک قاعده ایجاد می کنیم.

(0,3)	40/69	1/00	1/00
-------	-------	------	------

جدول 3: متوسط طول دنباله خارج از کنترل در شیفتهای  $\beta_1$  و  $\beta_2$  به طور همزمان

$\delta_1, \delta_2$	npc	$T_I^2$	ANN
(0/1,0/1)	0/010624	193/85	148/45
(0/2,0/2)	0/042497	181/61	119/22
(0/1,0/2)	0/066459	148/3	110/89
(0/5,0/2)	0/51314	95/60	79/26
(0/1,0/5)	0/7765	44/96	38/91
(0/5,1)	1/6615	20/53	13/80
(0/2,1)	3/106	8/94	9/52
(0/1,1)	3/7683	6/74	8/39
(2,0/2)	15/073	1/28	1/23
(2,0/1)	16/534	1/21	1/16
(3,0/5)	29/85	1/00	1/00
(3,0/2)	36/083	1/00	1/00
(0/1,3)	38/341	1/00	1/00

جدول 3 نشان می دهد هنگامی که شیفتهای عرض از مبدأ و شیب به طور همزمان رخ می دهد، عملکرد شبکه عصبی پیشنهادی در تشخیص شیفتهای کوچک و متوسط نسبت به نمودار کنترل  $T_I^2$  دارای عملکرد بهتری است. عملکرد هر دوروش در زمانی که شیفتهای بزرگ است تقریباً یکسان می باشد.

نتایج حاصل از تشخیص عوامل انحراف در شیفتهای مختلف با استفاده از شبکه عصبی پیشنهادی در جداول 4 و 5 نشان داده شده است. نتایج نشان می دهد که شبکه عصبی پیشنهادی عملکرد مناسبی در تشخیص عوامل هشدار دارد و در بسیاری از موارد شبکه عصبی پیشنهادی عوامل هشدار را به درستی تشخیص داده است.

### 6- نتیجه گیری و پیشنهادات آتی

در این مقاله یک شبکه عصبی برای پایش پروفایل های پواسون و شناسایی عامل هشدار توسعه داده شد. عملکرد شبکه عصبی پیشنهادی با عملکرد نمودار کنترل  $T_I^2$  در کشف شیفتهای

دوم به عنوان عامل هشدار شناخته خواهند شد. هنگامی که مقادیر خروجی های دوم و سوم به ترتیب از مقادیر حد آستانه این صورت که پارامتری که دارای مقدار خروجی متناظر بزرگتری است به عنوان عامل هشدار شناخته شود.

نتایج جدول 1 عملکرد متوسط طول دنباله شبکه پیشنهادی برای شیفتهای در عرض از مبدأ (بر حسب انحراف استاندارد) و متوسط طول دنباله متناظر با نمودار کنترل  $T_I^2$  را نشان می دهد. نتایج نشان می دهد که برای تمام شیفتهای در نظر گرفته شده، روش شبکه عصبی پیشنهادی عملکرد بهتری در تشخیص شیفتهای عرض از مبدأ نسبت به نمودار کنترل  $T_I^2$  دارد.

نتایج جدول 2 متوسط طول دنباله خارج از کنترل محاسبه شده برای هر دو شبکه عصبی پیشنهادی و نمودار کنترل  $T_I^2$  را در زمانی که یک شیفتهای در پارامتر شیب (بر حسب انحراف استاندارد) وجود دارد نشان می دهد. نتایج نشان می دهد شبکه عصبی پیشنهادی در تشخیص شیفتهای کوچک عملکرد مناسبی نسبت به نمودار کنترل  $T_I^2$  دارد. در تشخیص شیفتهای متوسط عملکرد نمودار کنترل  $T_I^2$  نسبت به شبکه عصبی پیشنهادی بهتر است. در شیفتهای بزرگ و بسیار بزرگ عملکرد هر دو روش شبکه عصبی پیشنهادی و نمودار کنترل  $T_I^2$  تقریباً یکسان است.

جدول 1: متوسط طول دنباله خارج از کنترل به ازای

شیفتهای در پارامتر  $\beta_1$

$\delta_1, \delta_2$	npc	$T_I^2$	ANN
(0/1,0)	0/045211	192/45	181/47
(0/2,0)	0/18084	164/73	148/11
(0/5,0)	0/1303	45/39	43/56
(1,0)	4/5211	6/31	5/74
(2,0)	18/084	1/13	1/11
(3,0)	40/69	1/00	1/00

جدول 2: متوسط طول دنباله خارج از کنترل به ازای

شیفتهای در پارامتر  $\beta_2$

$\delta_1, \delta_2$	npc	$T_I^2$	ANN
(0,0/1)	0/045211	155/99	138/47
(0,0/2)	0/18084	106/76	98/19
(0,0/5)	1/1303	30/58	33/70
(0,1)	4/5211	5/24	7/10
(0,2)	18/084	1/16	1/32

خصوص در شیفت در عرض از مبدأ دارد. همچنین عملکرد شبکه در تشخیص پارامتر عامل هشدار نیز با یک مثال عددی

پارامترهای پروفایل پواسون با استفاده از معیار متوسط طول دنباله مقایسه گردید. نتایج نشان داد که شبکه عصبی پیشنهادی عملکرد بهتری نسبت به نمودار کنترل  $T_1^2$  به

جدول 4: شناسایی عوامل هشدار با استفاده از شبکه عصبی پیشنهادی با شیفت در عرض از مبدأ

40/629	18/057	4/5143	1/1286	0/18057	0/045143	میزان شیفت بر اساس شاخص $n_{cp}$ ← پارامتر عامل هشدار ↓
10000	10000	9979	9218	5376	3322	عرض از مبدأ
0	0	0	33	467	972	شیب
0	0	21	749	4157	5706	عرض از مبدأ و شیب به طور همزمان
100	100	100	99/67	95/33	90/28	درصد تشخیص‌هایی که شامل عامل هشدار است

جدول 5: شناسایی عوامل هشدار با استفاده از شبکه عصبی پیشنهادی با شیفت در شیپ

40/629	18/057	4/5143	1/1286	0/18057	0/045143	میزان شیفت بر اساس شاخص $n_{cp}$ ← پارامتر عامل هشدار ↓
0	0	1	3	241	699	عرض از مبدأ
9965	9414	6715	4189	2629	2089	شیب
35	586	3284	5808	7130	7212	عرض از مبدأ و شیب به طور همزمان
100	100	99/99	99/97	97/59	93/01	درصد تشخیص‌هایی که شامل عامل هشدار است

مورد بررسی قرار گرفت. نتایج نشان داد که شبکه عصبی پیشنهادی در شناسایی پارامتر عامل هشدار بعد از کشف حالت خارج از کنترل نیز عملکرد مناسبی از خود نشان می‌دهد. به عنوان تحقیقات آتی در این حوزه، شبکه عصبی مصنوعی می‌تواند برای شناسایی نقطه تغییر، تشخیص جهت شیفت و بزرگی میزان شیفت در پایش پروفایل پواسون به کار گرفته شود. همچنین می‌توان این پیشنهادات را در سایر پروفایل‌های خطی تعمیم یافته مورد بررسی قرار داد.

## مراجع

[4] Mahmoud, A.M., Woodall, W.H. (2004). *Phase I analysis of linear profiles with calibration applications*. *Technometrics*, Vol(46), 380-391.

[5] Gupta, S., Montgomery, D.C., & Woodall, W.H. (2006). *Performance evaluation of two methods for online monitoring of calibration profiles*. *International Journal of Production Research*, Vol(44), 1927-1942.

[6] Wang, K., Tsung, F. (2005). *Using profile monitoring techniques for a data-rich environment with huge sample size*. *Quality and Reliability Engineering International*, Vol(21), 677-688.

[7] Jin, J., Shi, J. (1999). *Feature-preserving data compression of stamping tonnage information using wavelets*. *Technometrics*, Vol(41), 327-339.

[8] Jin, J., Shi, J. (2001). *Automatic feature extraction of waveform signals for in-process diagnostic performance improvement*. *Journal of Intelligent Manufacturing*, Vol(12), 257-268.

[9] Woodall, W.H., Spitzner, D.J., Montgomery, D.C., & Gupta, S. (2004). *Using control charts to monitor process and product quality profiles*. *Journal of Quality Technology*, Vol(36), 309-320.

[1] Montgomery, D.C. (2005). *Introduction to statistical quality control*. 5th Edition, New York, USA: Wiley

[2] Mestek, O., Pavlik, J., & Suchanek, M. (1994). *Multivariate control charts: control charts for calibration curves*. *Fresenius' Journal of Analytical Chemistry*, Vol(350), 344-351.

[3] Stover, F.S., Brill, R.V. (1998). *Statistical quality control applied to ion chromatography calibrations*. *Journal of Chromatography A*, Vol(804), 37-43.

*International Journal of Advanced Manufacturing Technology*, DOI:10.1007/s00170-012-4018-2.

[22] Kleinbaum, D.G., Lawrence, L.k., Keith, E.M., & Azhar, N. (1997). *Applied regression analysis and multivariable methods*. 3<sup>rd</sup> Edition, Bolment: Duxbury Press.

[23] Myers, R.H., Montgomery, D.C., Vining, G.G., Robinson, T.J. (2010). *Generalized linear models: with applications in engineering and the sciences*, 2<sup>nd</sup> Edition, New York, USA: Wiley

[24] Bishop, C. (1995). *Neural networks for pattern recognition*. United Kingdom: Oxford University Press.

[25] Haykin, S. (1994). *Neural networks: a comprehensive foundation*. New York, USA: Macmillan Publishing.

[26] Chester, D. (1990). *Why two hidden layers are better than one*. In: *Proceedings of international Joint Conference on Neural Networks*. Washington, D.C, USA, 265-268.

[27] Rumelhart, D.E., Hinton, G.E., & Williams, R.J. (1986). *Learning representations by back-propagation errors*, *Nature Publishing Group*. Vol(323), 533-536.

[28] Patterson, D. (1996). *Artificial neural networks*. Singapore: Prentice Hall.

[29] Zorriassatine, F., Tannock, J.D.T. (1998). *A review of neural networks for statistical process control*. *Journal of Intelligent Manufacturing*, Vol(9), 209-224.

[30] Psarakis, S.(2011). *The use of neural networks in statistical process control charts*. *Quality and Reliability Engineering International*, Vol(27), 609-731.

[31] Pugh, G.A., (1989). *Synthetic neural networks for process control*. *Computers & industrial engineering*, Vol(17), 24-26.

[32] Pugh, G.A.(1991). *A comparison of neural networks to SPC charts*. *Computers & industrial engineering*, Vol(21), 253-255.

[33] Cheng, C.S. (1995). *A multi-layer neural network model for detecting changes in the process mean*. *Computers and Industrial Engineering*, Vol(28), 51-61.

[34] Velasco, R., Rowe, R.M. (1993). *Back propagation artificial neural networks for the analysis of quality control charts*. *Computers and Industrial Engineering*, Vol(25), 397-400.

[10] Kazemzadeh, R.B., Noorossana, R., & Amiri, A. (2009). *Monitoring polynomial profiles in quality control applications*. *The International Journal of Advanced Manufacturing Technology*, Vol(42), 703-712.

[11] Soleimani, P., Noorossana, R., & Amiri, R. (2009). *Simple linear profiles monitoring in the presence of within profile autocorrelation*. *Computers & Industrial Engineering*, Vol(57), 1015-1021.

[12] Kang, L., Albin, S.L. (2000). *On-line monitoring when the process yields a linear profile*. *Journal of Quality Technology*, Vol(32), 418-426.

[13] Walker, E. Wright, S. (2002). *Comparing Curves Using Additive Models*. *Journal of Quality Technology*, Vol(34), 118-129.

[14] Amiri, A., Jensen, W.A., & Kazemzadeh, R.B. (2010). *A case study on monitoring polynomial profiles in the automotive industry*. *Quality and Reliability Engineering International*. Vol(26), 509-520.

[15] Kim, K., Mahmoud, M.A., & Woodall, W.H. (2003). *On the monitoring of linear profiles*. *Journal of Quality Technology*, Vol(35), 317-328.

[16] Niaki, S.T.A., Abbasi, B., & Arkat, J. (2007). *A generalized linear statistical model approach to monitor profiles*. *International Journal of Engineering, Transactions A: Basics, Islamic Republic of Iran*, Vol(20), 233-242.

[17] Zou, C., Tsung, F., & Wang, Z. (2007). *Monitoring general linear profiles using multivariate exponentially weighted moving average schemes*. *Technometrics*, Vol(49), 395-408.

[18] Saghaei A., Mehrjoo, M., & Amiri, A. (2009). *A CUSUM-based method for monitoring simple linear profiles*. *The International Journal of Advanced Manufacturing Technology*, Vol(45), 1252-1260.

[19] Yeh, B., Huwang, L., & Li, Y.M. (2009). *Profile monitoring for a binary response*. *IIE Transactions* Vol(41), 931-994.

[20] Sharafi, A., Aminnayeri, M., & Amiri, A. (2012). *Identifying the time of step change in binary profiles*, Published online in *The International Journal of Advanced Manufacturing Technology*. DOI: 10.1007/s00170-012-3899-4.

[21] Koosha, M., Amiri, A. (2012). *Generalized linear mixed model for monitoring autocorrelated logistic regression profiles*. Published online in *The*

- [35] Leger, R.P., Garland, W.J., & Phoehlman, W.F.S. (1996). *Fault detection and diagnosis using statistical control charts and artificial neural networks*. *Artificial Intelligence in Engineering*, Vol(12), 35-47.
- [36] Wang, T.Y., Chen, L.H. (2001). *Mean shifts detection and classification in multivariate process: A neural-fuzzy approach*. *Journal of Intelligence Manufacturing*, Vol(13):211-221.
- [37] Niaki, S.T.A., Abbasi, B. (2005). *Fault diagnosis in multivariate control charts using artificial neural networks*. *Quality and Reliability Engineering International*, Vol(21), 825-840.
- [38] Ahmadzadeh, F. (2009). *Change point detection with multivariate control charts by artificial neural network International*. Published online in *The International Journal of Advanced Manufacturing Technology*, DOI: 10.1007/s00170-009-2193-6.
- [39] 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 Advanced Manufacturing Technology*, Vol(52), 407-420.
- [40] Noorossana, R., Atashgar, K., & Saghaei, A. (2011). *An integrated supervised learning solution for monitoring process mean vector*. *The International Journal of Advanced Manufacturing Technology*, Vol(56), 755-765.
- [41] Vaghefi, A., Tajbakhsh, S.D., & Noorossana, R. (2009). *Phase II monitoring of nonlinear profiles*. *Communications in Statistics -Theory and Methods*, Vol(38), 1834-1851.
- [42] Fazel Zarandi, M.H., Alaeddini, A. (2010). *Using adaptive nero-fuzzy systems to monitor linear quality profiles*. *Journal of Uncertain Systems*, Vol(4), 147-160.
- [43] Pacella, M., Semeraro, Q. (2011). *Monitoring roundness profiles based on an unsupervised neural network algorithm*. *Computers and Industrial Engineering*, Vol(60), 677-689.
- [44] Hosseinifard, S.Z., Abdollahian, M., Zeepongsekul, P. (2011). *Application of artificial neural networks in linear profile monitoring*. *Expert Systems with Applications*, Vol(38), 4920-4928.

## Using artificial neural network for Poisson profiles monitoring and diagnostic

**Mohsen Rasouli**

(corresponding author) M.S.Student, Department of Industrial Engineering, Isfahan University of Technology, Isfahan, Iran, mohsen.rasouli@in.iut.ac.ir

**Gholam Ali Raissi Ardali**

Assistant Professor, Department of Industrial Engineering, Isfahan University of Technology, Isfahan, Iran, raissi@cc.iut.ac.ir

**Amirhossein Amiri**

Assistant Professor, Department of Industrial Engineering, Faculty of Engineering, Shahed University, Tehran, Iran, amiri@shahed.ac.ir

**Alireza Sharafi**

M.S.C. Department of Industrial Engineering, Amirkabir University, a.sharafi@aut.ac.ir

**Abstract** Sometimes relationship between a response variable and one or more dependent variables, determine the quality of a product or performance of a process. The relationship is referred to as profile in the literature of statistical process control. Different types of profiles have been considered by researchers. One of these types of profiles is generalized linear models based regression profiles. In these profiles, response variable follows distributions of exponential family such as Binomial, Poisson, Exponential and Gamma. In this paper, a multilayer perceptron artificial neural network is designed to monitor Poisson regression profiles and diagnose the regression parameter(s) responsible for out-of-control signal. The performance of the proposed neural network is investigated through simulation. The results show appropriate performance of the designed neural network in monitoring the Poisson regression profiles and diagnosing the parameter(s) responsible for out-of-control signal. In addition, the performance of the proposed neural network is compared with  $T^2$  based control chart in monitoring the Poisson regression profiles. The results show the superiority of the proposed neural network rather than the  $T^2$  control chart in terms of average run length criterion.

**Keywords** Statistical process control, Poisson profile, Artificial neural network, Multilayer perceptron, Generalized linear model