



Analysis of Concurrent Patterns in Statistical Process Control (SPC) Charts using Neural Networks

Ellips Masehian* & Hamid Amraei

Ellips Masehian, Assistant Professor, Department of Industrial Eng., Tarbiat Modares University

Hamid Amraei, M.Sc. graduate, Department of Industrial Eng., Tarbiat Modares University

Keywords

Statistical Process Control Charts, Neural Networks, Wavelet Transform, Concurrent Patterns, Pattern Recognition

ABSTRACT

Statistical Process Control (SPC) charts play a major role in quality control systems, and their correct interpretation leads to discovering probable irregularities and errors of the production system. In this regard, various artificial neural networks have been developed to identify mainly singular patterns of SPC charts, while having drawbacks in handling multiple concurrent patterns. In this paper, a new compound method is proposed for automatic identification of concurrent patterns of SPC charts. First, by using a wavelet transform the complex concurrent pattern is decomposed into its underlying singular patterns, and then by implementing the Principal Component Analysis (PCA) jointly with a Probabilistic Neural Network (PNN), pattern types are identified. The results obtained from simulated data exhibited a success rate of 94.83% in recognizing concurrent multiple patterns.

© (نشریه بین المللی مهندسی صنایع و مدیریت تولید) شماره ۳، جلد ۲۰، ۱۳۸۸

تحلیل الگوهای همزمان در نمودارهای کنترل فرآیند آماری با استفاده از شبکه عصبی

الیپس مسیحی و حمید امرائی

چکیده:

کلمات کلیدی

نمودارهای کنترل فرآیند آماری نقش بسزایی را در سیستم های کنترل کیفیت بر عهده دارند که تحلیل صحیح آنها، منجر به کشف خطاهای موجود در فرآیند خواهد شد. در این راستا شبکه های عصبی متنوعی به منظور تشخیص الگوهای موجود در نمودارهای کنترل به کار گرفته شده اند که اکثراً قادر به تشخیص الگوهای منفرد بوده و در مورد الگوهای همزمانی که ناشی از رخداد بیش از یک خطا در فرآیند می باشند ناتوان بوده اند. در این مقاله، ابتدا با به کارگیری تبدیل موجک، الگوی همزمان به الگوهای منفرد تشکیل دهنده تفکیک شده و در ادامه با به کارگیری تحلیل مولفه های اصلی (PCA) در کنار یک شبکه عصبی احتمالی (PNN)، نوع الگوها مشخص می گردد. نتایج بدست آمده با استفاده از داده های شبیه سازی شده، نرخ تشخیص صحیح الگوهای همزمان را برابر ۹۴٫۸۳٪ نشان می دهد.

کنترل فرآیند آماری، شبکه عصبی، تبدیل موجک، الگوهای همزمان، تشخیص الگو

تاریخ وصول: ۸۸/۶/۲۲

تاریخ تصویب: ۸۸/۱۰/۲۷

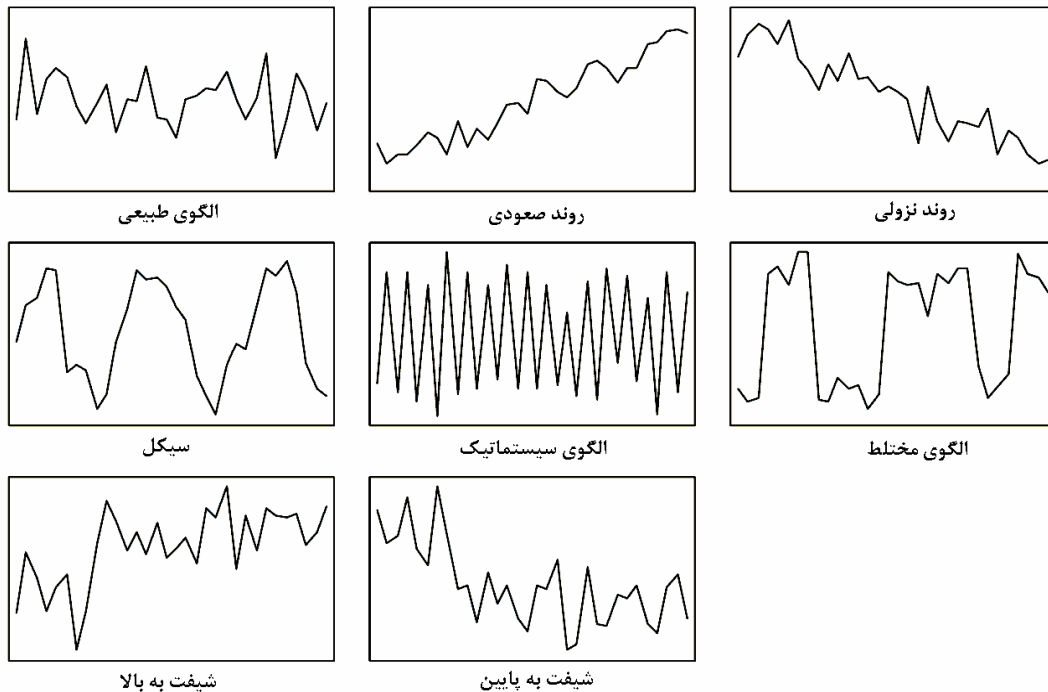
دکتر الیپس مسیحی، استادیار، بخش مهندسی صنایع، دانشکده فنی و مهندسی، دانشگاه تربیت مدرس، masehian@modares.ac.ir

حمید امرائی، کارشناس ارشد، بخش مهندسی صنایع دانشکده فنی و مهندسی، دانشگاه تربیت مدرس amraei@modares.ac.ir

معنی دار در این نمودارها نشان دهنده وجود علت مشخصی است که می تواند باعث اختلال در کارایی فرآیند گردد. مهمترین الگوهای غیر تصادفی شناخته شده عبارتند از: شیفت ناگهانی در میانگین، روند صعودی یا نزولی میانگین، رفتار سیکلی میانگین، و نوسانات سیستماتیک میانگین (شکل ۱).

۱. مقدمه

نمودارهای کنترل فرآیند آماری ابزاری مناسب جهت تشخیص خطاهای موجود در یک فرآیند می باشند که از سالیان دور مورد استفاده قرار گرفته اند تا با کنترل شرایط فرآیند، کیفیت خروجی های فرآیند را تضمین نمایند. هر الگوی غیر تصادفی و



شکل ۱. انواع مختلف الگوها در نمودارهای کنترلی

Pham و Oztmel یک شبکه پرسپترون چند لایه به همراه آموزش شبکه پس انتشار^۲ را به کار بردند [۱]. همین محققین در تحقیقی دیگر با بکارگیری یک شبکه پله ای بردار یادگیری^۳ راهکاری برای افزایش دقت دسته بندی الگوها و نیز کاهش زمان یادگیری شبکه مذکور ارائه نمودند [۲].

در این راستا Hwang و Hubele نیز با استفاده از یک شبکه عصبی پرسپترون با آموزش پس انتشار، توانستند الگوهای همچون روند و سیکل را در نمودارهای شوهارت^۴ شناسایی نمایند [۳]. در یک تحقیق کم و بیش مشابه دیگر، الگوهای منفرد نمودارهای SPC توسط شبکه های عصبی بازشناسی شده اند [۴].

از سایر تحقیقات انجام شده می توان به مقاله Cheng اشاره نمود که در آن با مقایسه عملکرد شبکه عصبی پرسپترون چند لایه و شبکه عصبی پیمانه ای، برتری نسبی شبکه عصبی پیمانه ای^۵ را نشان داده است [۵]. همچنین AI-Ghanim ضمن استفاده از یک

در روش های سنتی تحلیل این نمودارها به عهده افراد مجرب بوده است، ولی بعلت محدودیت در رویکردهای مبتنی بر قواعد تجربی و اجرائی، اخیراً رویکردهای تشخیص الگوی مبتنی بر سیستم های هوشمند برای تشخیص الگوهای غیر تصادفی بسیار مورد توجه محققین واقع شده اند.

با گسترش کاربرد روش های نرم رایانش در تحلیل این نمودارها، گامی در راستای خودکارسازی سیستم های کنترل کیفیت برداشته شده است. اکثر رویکردهای هوشمند تنها محدود به تشخیص الگوهای منفرد بوده و در تشخیص وقوع الگوهای همزمان ضعیف می باشند، بطوریکه نرخ تشخیص گزارش شده در حدود ۸۵٪ است. با توجه به ماهیت و توانایی های شبکه های عصبی در یادگیری، با آموزش الگوها به یک شبکه عصبی امکان تشخیص الگوها فراهم می گردد. شبکه های عصبی به تنهایی در شناسایی الگوهای منفرد موفق بوده اند، و معماری های مختلفی از شبکه های عصبی به منظور تشخیص الگوهای غیر طبیعی گزارش شده اند که از میان آنها می توان به این موارد اشاره نمود:

² Backpropagation Network (BPN)

³ Learning Vector Quantization (LVQ)

⁴ Shewhart

⁵ Modular Neural Network (MNN)

نتایج بکارگیری داده های شبیه سازی شده، نرخ تشخیص صحیح را برای حالات مختلف الگوهای غیر تصادفی همزمان، بطور میانگین برابر ۹۴/۸۳٪ نشان می دهند.

۲. اجزای روش پیشنهادی

به منظور پیاده سازی روش مورد نظر در این تحقیق نیاز به تعداد زیادی از انواع متنوع الگوهای نمودارهای کنترل فرآیند آماری می باشد که از میان آنها شش نوع از رایج ترین الگوها مورد استفاده قرار گرفته اند، که عبارتند از: روند صعودی، روند نزولی، شیفت بالا رونده، شیفت پائین رونده، سیکل و سیستماتیک.

روش توسعه داده شده از مراحل و بخش های مختلف و مرتبطی تشکیل شده که لازم است در هر مرحله تجزیه و تحلیل مناسبی صورت پذیرفته و عملیات مشخصی بر روی داده ها انجام شود، که در ادامه به تفصیل مورد بحث قرار خواهند گرفت. ساختار کلی روش و ارتباط بین بخش های مختلف در قالب شکل ۲ ارائه می گردد. از آنجا که هدف اصلی از انجام این تحقیق، تحلیل و تشخیص الگوهای همزمان نمودارهای SPC می باشد، روش پیشنهادی برای انجام این مهم، به کارگیری شبکه عصبی مصنوعی به همراه تبدیل موجک و تحلیل مولفه های اصلی در نظر گرفته شده، و به منظور تولید الگوهای مورد نیاز جهت آموزش و آزمون شبکه عصبی، از محیط شبیه سازی مونت کارلو^۹ بهره گیری شده است.

همان طور که در شکل ۲ نشان داده شده است برای آموزش شبکه عصبی مورد نظر، ابتدا الگوهای تولید شده نرمال سازی شده و سپس به منظور حذف داده های کم اهمیت تر، تحت تاثیر تحلیل مولفه های اصلی قرار می گیرند، و در انتها شبکه عصبی آموزش داده می شود. در فرآیند تشخیص الگوهای همزمان، این الگوها ابتدا توسط تبدیل موجک به الگوهای منفرد تفکیک شده و سپس هر یک بطور جداگانه پس از نرمال سازی و تحلیل مولفه های اصلی، جهت تشخیص نوع الگو به شبکه عصبی ارسال می گردند.

۲-۱. تولید داده ها

با توجه به ساختار کلی تحقیق، نقطه شروع انجام رویکرد جاری تولید سیگنال های مربوط به الگوها و در ادامه نرمال سازی آنها می باشد. جهت آموزش و آزمون شبکه عصبی و نیز تشکیل الگوهای همزمان، نیاز به تعداد نسبتاً زیادی از هر یک از الگوها وجود دارد. با توجه به مقیاس مورد نیاز الگوها که دارای مقادیری بسیار کوچک با پارامترهای نزدیک به هم هستند، پر واضح است که تولید تک تک الگوها به صورت دستی امری دشوار خواهد بود. از

شبکه تشدید انطباقی بدون ناظر^۶، مقایسه آن را با رویکردهای یادگیری با ناظر را گزارش نموده است [۶].

از جمله تحقیقات انجام شده در محیط واقعی می توان به تحقیق انجام شده توسط Atienza و همکاران اشاره نمود [۷]. این محققین با هدف تشخیص نارسائی در بیماران قلبی، از یک شبکه عصبی پس انتشار به منظور دسته بندی و تشخیص سه گروه از نارسائی های ممکن بهره جستند که نتایج امر قابلیت های بالای شبکه عصبی در این راستا را نشان می دهد.

در تحقیق Perry و Pignatiello [۸]، مرور ادبیات نسبتاً جامعی از کاربردهای شبکه عصبی در بازشناسی الگوهای نمودارهای کنترل آماری تا سال ۲۰۰۲ میلادی انجام شده و نتیجه گیری شده است که روش های مبتنی بر شبکه عصبی صرف هیچگاه نمی توانند ۱۰۰٪ دقت داشته باشند، و بایستی با روش هایی مانند الگوریتم ژنتیک یا منطق فازی ترکیب شوند تا نتایج مطلوب بدهند.

علی رغم موفقیت شبکه های عصبی در بازشناسی الگوهای منفرد، در مورد الگوهای همزمان با توجه به تعداد زیاد حالت های ممکن همزمانی (از لحاظ پارامترهای مختلف الگوها) نیاز به داده های آموزشی زیادی جهت آموزش شبکه می باشد. Tannok و Guh نشان دادند که این امر علاوه بر نیاز به شبکه های بزرگتر و افزایش زمان های آموزش و تشخیص در شبکه، منجر به کاهش توانایی شبکه در تشخیص الگوهای منفرد خواهد شد [۹].

جهت حل این مشکل، Chen و همکاران با به کارگیری تبدیل موجک^۷ و یک شبکه BPN توانستند الگوهای همزمان را تشخیص دهند. آنها مقایسه ای بین عملکرد شبکه های BPN، LVQ، RBF، PNN و GRNN انجام دادند که نتایج آن برتری شبکه BPN را نشان می دهد [۱۰]. همچنین AI-assaf با استفاده از یک شبکه FNN و آموزش آن با ضرائب تبدیل موجک به نتایج درخور توجهی دست یافت [۱۱]. از تحقیقات اخیر نیز می توان به مقاله Cheng و Cheng اشاره نمود که در آن تلفیقی از روش شبکه عصبی با تحلیل موجک برای بازشناسی الگوهای منفرد به کار گرفته شده است [۱۲].

در این مقاله با ترکیب چند ابزار ریاضی با روش شبکه عصبی گامی در راستای بهبود تحقیقات گذشته در شناسایی الگوهای همزمان برداشته شده است. ابتدا الگوهای همزمان با بکارگیری تبدیل موجک تلفیقی دو مرحله ای به الگوهای منفرد تشکیل دهنده تفکیک می شوند. در ادامه با بکارگیری روش تحلیل اجزای اصلی^۸ نویزهای پنهان در آرایه مشاهدات حذف شده و نتایج وارد شبکه عصبی می شوند که خروجی آن تشخیص نوع الگوهای منفرد تشکیل دهنده موردنظر می باشد.

^۶ Unsupervised Adaptive Resonance

^۷ Wavelet

^۸ Principal Component Analysis (PCA)


^۹ Monte Carlo

با توجه به اینکه ممکن است مقادیر پارامترهای میانگین و انحراف معیار در یک فرآیند تحت تاثیر علل غیر طبیعی تغییر یابند، برای اجتناب از نیاز به آموزش مجدد شبکه با میانگین و انحراف معیار جدید، لازم است که داده های آموزشی و آزمون به صورت استاندارد در آمده و بر اساس (۲) نرمال سازی شوند. اگر داده های آموزشی نرمال سازی نشوند در این صورت شبکه تنها قادر به تشخیص الگوهای با میانگین و انحراف استاندارد ثابت اولیه خواهد بود.

$$x_s(t) = \frac{x - \mu}{\sigma} \quad (2)$$

در رابطه فوق t زمان، x_s مقدار نرمال شده، x داده مورد نظر، μ میانگین داده ها و σ انحراف معیار آنها می باشد. با توجه به اینکه الگوهای همزمان ناشی از اتفاق افتادن دو الگوی منفرد با هم می باشند، با جمع دو الگوی منفرد می توان به الگوهای همزمان مورد نظر دست یافت.

این رو نیاز به یک نرم افزار شبیه ساز می باشد که توانایی ایجاد تعداد زیادی از الگوهای مشابه با پارامترهای تصادفی را دارا باشد.



شکل ۲. ساختار کلی روش پیشنهادی

۲-۲. به کارگیری تحلیل مولفه های اصلی (PCA)

پس از تولید الگوها توسط شبیه ساز مونت کارلو و نرمال سازی آنها لازم است که بخشی (حدود ۸۰ درصد) از الگوهای تولید شده به شبکه عصبی طراحی شده جهت آموزش ارسال گردند. با آگاهی از وجود نویزهای طبیعی در دنیای واقعی پیرامون خود و نظر به اینکه در الگوهای تولید شده ما نیز چنین نویزهای طبیعی در نظر گرفته شده است، لزوم ابزاری جهت استخراج بخش های با اهمیت تر الگوها جهت آموزش شبکه و حذف مقادیر کم اهمیت تر (نویزهای طبیعی) به شدت احساس می شود. بدین منظور تحلیل مولفه های اصلی (PCA) ابزاری است که پیش از آموزش شبکه و همچنین آزمون الگوهای مورد نظر به کار گرفته شده است.

پارامتری که در تحلیل مولفه های اصلی بایستی معین شود، درصد داده هایی است که از دید ما چندان با اهمیت نبوده و بایستی حذف شوند. به منظور بررسی این پارامتر و تاثیر آن در میزان کارایی شبکه در راستای تشخیص صحیح الگوی مورد نظر، می بایست مقادیر مختلف این پارامتر مورد بررسی قرار گیرد تا بهترین مقدار انتخاب شده و اعمال گردد. در راستای نیل به این مقصود در فرآیند تحلیل مولفه های اصلی، بر اساس داده های آموزش شبکه، ماتریسی به نام ماتریس تحلیل مولفه های اصلی تشکیل می گردد که با ضرب آن در ماتریس داده های ورودی، مولفه های اصلی مورد نظر (داده های بدون نویز) جهت آموزش به شبکه به دست خواهند آمد. در ادامه این ماتریس در کلیه داده های مورد نظر جهت آزمون شبکه ضرب خواهد شد تا تحلیل مولفه های اصلی در مورد آنها نیز اعمال گردد و نویزهای موجود در این داده ها نیز حذف گردد.

در این تحقیق مقادیر مختلف پارامتر مربوط به درصد داده های کم اهمیت تر (غیر اصلی) در بازه [۰.۸ - ۰.۱] برای شبکه های عصبی

برای این منظور از نرم افزار شبیه ساز مونت کارلو استفاده شده است و با کمک آن تعداد ۱۰۰۰ الگو (منفرد) برای هر یک از شش نوع مورد بررسی (که هر یک مشتمل بر ۲۴ نمونه می باشند) تولید می گردد. تولید این الگوها بر اساس (۱) صورت می پذیرد:

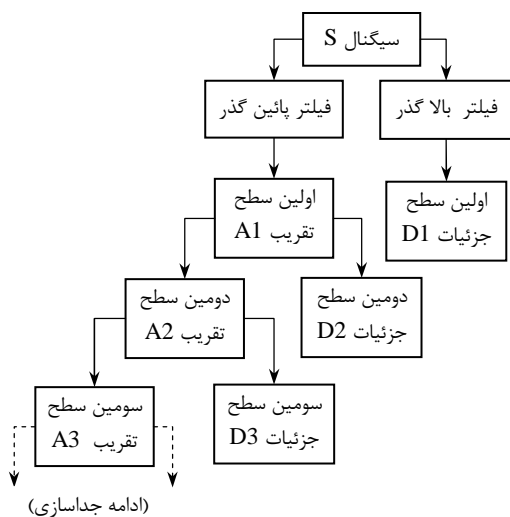
$$x(t) = \mu + n(t) + d(t) \quad (1)$$

که در آن $x(t)$ مقدار الگو در زمان t ، نویز تصادفی موجود در سیگنال، μ میانگین فرآیند، و $d(t)$ الگوی مورد نظر می باشد که برای هر الگو بر اساس فرمول های موجود در جدول ۱ تعیین می گردد [۹]. در روابط جدول ۱، d اندازه شیب روند، s اندازه دامنه شیب، u پارامتر تعیین موقعیت شروع شیب (با مقادیر صفر یا یک)، a اندازه دامنه سیکل، Ω فرکانس سیکل و m اندازه نوسانات سیستماتیک می باشند.

جدول ۱. فرمول های تولید الگو

فرمول $d(t)$	نوع الگو
$d \times t$	روند صعودی
$-d \times t$	روند نزولی
$u \times s$	شیفت
$a \times \sin(\frac{2\pi t}{\Omega})$	سیکل
$m \times (-1)^t$	سیستماتیک

همزمان در هر سطح از تبدیل تحت فیلترهای بالا گذر و پائین گذر پردازش شده که داده های فیلتر شده بالا گذر معرف جزئیات و داده های فیلتر شده پائین گذر معرف تقریب (یا تخمین) می باشند (شکل ۳).



$$S = A1 + D1 = A2 + D2 + D1 = \dots$$

شکل ۳. تجزیه و بازسازی در تبدیل موجک

با توجه به ماهیت معکوس پذیری الگوریتم تبدیل موجک، با به کارگیری ضرایب می توان سیگنال های تشکیل دهنده را بازسازی نمود و از این طریق الگوهای منفرد تشکیل دهنده الگوی همزمان را بدست آورده و جهت تشخیص نوع الگو به شبکه عصبی ارسال نمود. برای انجام تبدیل موجک و محاسبه ضرایب C نیاز به تعیین پارامترهایی از جمله نوع خانواده موجک، تابع موجک مورد نیاز و تعداد سطوح تجزیه می باشد.

به منظور تعیین نوع خانواده موجک، انواع مختلف آنها مورد بررسی قرار گرفتند که نتایج امر به طور کلی برتری نسبی خانواده های Daubechies, Coiflet و Biorthogonal را نسبت به سایر خانواده های موجک نشان داد. با توجه به اینکه هر یک از این سه نوع خانواده موجک برتر، خود مشتمل بر چندین نوع تابع متفاوت هستند، چهار نوع تابع db1 و db3 (از خانواده Daubechies)، تابع coif1 (از خانواده Coiflet) و تابع bior1.5 (از خانواده Biorthogonal) مورد بررسی قرار گرفتند. از آنجا که تعداد سطوح تجزیه اهمیت تاثیر به سزایی در میزان دقت جداسازی سیگنال های تشکیل دهنده دارد، تعداد سطوح مختلفی، از ۳ تا ۱۰ سطح، در چهار نوع تابع فوق الذکر مورد بررسی اولیه قرار گرفت که در نهایت تعداد ۳، ۴ و ۵ سطح تجزیه، نتایج بهتری را از خود نشان دادند.

مورد نظر آزمایش شد که در نهایت مشخص گردید مقدار ۲٪ بهترین نتیجه را در تشخیص صحیح الگوها ارائه می نماید.

۲-۳. تبدیل موجک

یکی از مهم ترین بخش های رویکرد جاری، به کارگیری تبدیل موجک به منظور جداسازی الگوهای منفرد (تشکیل دهنده الگوهای همزمان) می باشد. در نتیجه استفاده از این تبدیل، الگوی همزمان به بخش های تخمین و جزئیات تقسیم می گردد. در تحقیق جاری، با استفاده از چنین امکانی است که الگوهای منفرد مورد نظر در یکی از این بخش های تخمین یا جزئیات ظاهر می شوند تا پس از استخراج، جهت تشخیص به شبکه عصبی ارسال گردند. یکی از رایج ترین روش های ریاضی جهت تبدیل سیگنال از دامنه زمان به دامنه فرکانس، تبدیل فوریه^{۱۰} می باشد. بدین صورت که با به کارگیری این تبدیل، مؤلفه های فرکانسی موجود در سیگنال استخراج می شوند. ولی اشکال جدی که در تبدیل فوریه وجود دارد این است که پس از انجام آن، اطلاعات مربوط به حوزه زمان از دست داده می شوند. به طور واضح تر، مشکل اینجا است که مشخص نیست مؤلفه های فرکانسی بدست آمده در چه زمان یا بازه زمانی اتفاق افتاده اند.

مزیت اصلی تبدیل موجک بر تبدیل فوریه این است که در آن اطلاعات حوزه زمان را نیز در اختیار خواهیم داشت. در تبدیل موجک این امکان وجود دارد که الگوهای همزمان را به سطوحی مختلف تفکیک نماییم که هر یک از این سطوح متعلق به یک حوزه فرکانسی مشخص بوده و از این طریق الگوهای همزمان را به الگوهای اولیه مورد نظر تشکیل دهنده آن در موقعیت ها (حوزه زمان) و مقیاس های (حوزه فرکانس) مختلف تجزیه نموده و الگوهای اولیه را استخراج نماییم. در این تحقیق با به کارگیری تبدیل موجک از دو خاصیت مهم آن، یعنی استخراج خصیصه و نویز زدایی، به خوبی استفاده شده است.

در تبدیل موجک، ضرایب C که تابعی از مقیاس و موقعیت مؤلفه های مختلف فرکانسی هستند بر اساس (۳) محاسبه می شوند که در آن t زمان، s پارامتر مقیاس، p پارامتر موقعیت، $f(t)$ سیگنال مورد نظر، و φ تابع موجک می باشند [۱۰].

$$C(s, p) = \int_{-\infty}^{+\infty} f(t) \cdot \varphi(s, p, t) \cdot dt \quad (3)$$

مهمترین کار در استفاده از تبدیل موجک، محاسبه ضرایب C می باشد. همچنین خاطر نشان می گردد که در این تحقیق از الگوریتم تبدیل موجک گسسته که در کاربردهای عملی مشابه پردازش سیگنال در دنیای واقعی نتایج خوبی را از خود نشان داده است استفاده شده است. در اینجا سیگنال مربوط به الگوهای

¹⁰ Fourier

برای تخمین) بطور متوالی و در دو مرحله به کار گرفته شود، ممکن است نتایج مورد نظر (جداسازی هر دو الگوی منفرد) حاصل گردد. خوشبختانه این رویکرد تلفیقی دو مرحله ای نتایج خوبی را ارائه نمود. بدین ترتیب که به عنوان مثال برای جداسازی الگوهای همزمان روند و شیفت، در مرحله اول تبدیل موجک با تابع db1 برای استخراج تخمین و تابع db3 برای استخراج جزئیات به خوبی باعث استخراج الگوی شیفت می شود و در مرحله دوم با تابع db3 برای استخراج تخمین و تابع db1 برای استخراج جزئیات، الگوی روند صعودی را استخراج خواهد نمود که نتیجه دو مرحله انجام شده، هر دو الگوی مورد نظر را جداسازی و استخراج می نماید (شکل های ۴ و ۵ دو مرحله جداسازی الگوهای روند و شیفت را نشان می دهند).

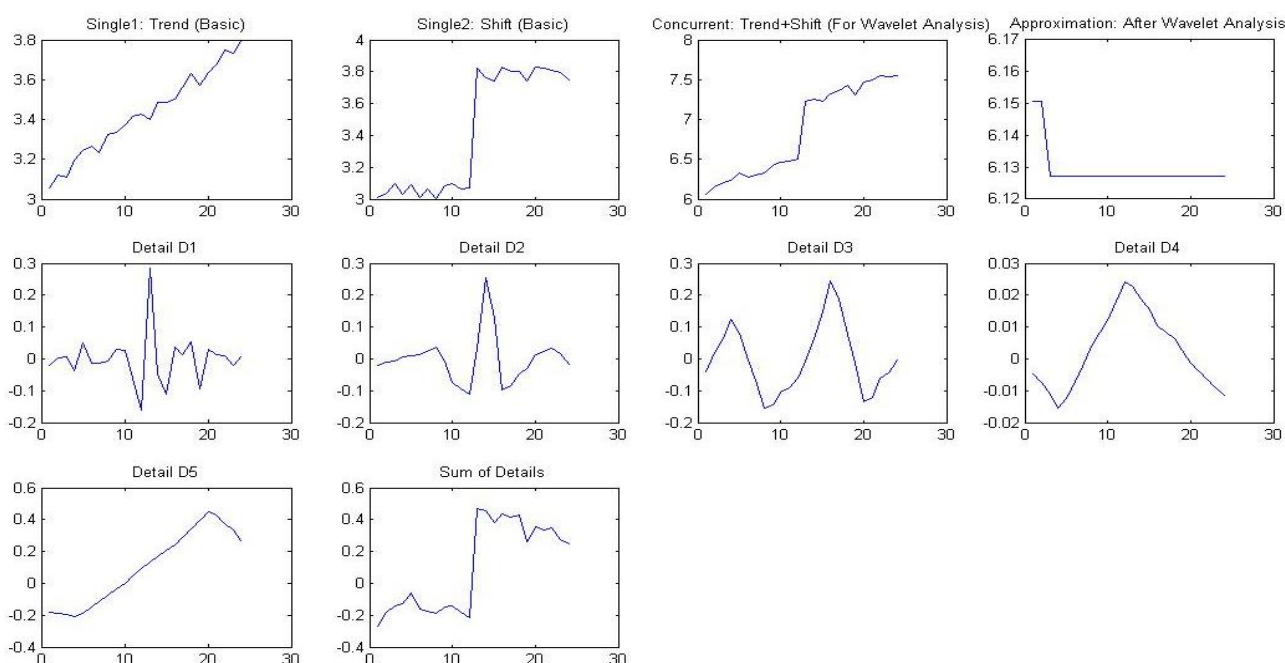
بررسی های بیشتر در مورد کلیه حالات ممکن هم زمانی الگوها نشان می دهد که برای استخراج کلیه الگوها تنها مجموع جزئیات (در مرحله اول) و تخمین (در مرحله دوم) کافی نبوده و در برخی حالات هم زمانی، الگوهای منفرد مورد نظر در یک و یا مجموعی از برخی جزئیات ظاهر می گردند که نتایج نهایی آن در جداول ۲ و ۳ به خوبی نشان داده شده است.

همان طور که در این جداول ملاحظه می شود، روش تلفیقی دو مرحله ای از تبدیل موجک، در کلیه حالات مختلف هم زمانی پاسخگو بوده و قادر به تشخیص همه الگوهای منفرد تشکیل دهنده الگوهای همزمان می باشد.


با عنایت به اینکه تعداد حالت های مختلف نهایی در بررسی پارامترهای تبدیل موجک، وابسته به حالت های مختلف برتر در هر یک از پارامترهای نوع خانواده موجک، نوع تابع موجک و تعداد سطوح تجزیه در آنها می باشد، بنابراین در نهایت با ۱۲ حالت مختلف برتر از پارامترها روبرو هستیم که عملکرد هر یک از این حالات بر روی شش نوع الگوی همزمان ممکن مورد توجه قرار گرفت. با بررسی نتایج بدست آمده، مشاهده گردید که در بین آنها تابعی که به تنهایی قادر به عمل جداسازی هر دو الگوی منفرد از الگوی همزمان باشد یافت نمی شود. بنابراین راهکار دیگری که برگرفته از نتایج این بررسی می باشد، مورد استفاده قرار گرفت که در ادامه به آن می پردازیم.

۲-۳-۱. به کارگیری حالت تلفیقی توابع موجک

با بررسی دقیق تر در نتایج بررسی شده از حالات مختلف توابع، مشخص می گردد که نتایج حاصل از توابع db1 و db3 در ۵ سطح، بهتر از سایر توابع بوده و این دو تابع تا حدودی نسبت به هم همپوشانی دارند، بدین ترتیب که اکثر الگوهای تشخیص داده شده توسط db1 در قسمت جزئیات و نیز الگوهای تشخیص داده شده توسط db3، بیشتر در قسمت تخمین مشاهده می گردند. بنابراین با توجه به موفقیت هر تابع در جداسازی الگوهای خاص، این ایده در ذهن متبلور شد که در صورتیکه دو تبدیل موجک با استفاده از توابع db1 (در تبدیل اول تخمین و در تبدیل دوم برای جزئیات) و db3 (در تبدیل اول برای جزئیات و در تبدیل دوم



شکل ۴. مرحله اول تبدیل موجک (استخراج شیفت)



شکل ۵. مرحله دوم تبدیل موجک (استخراج روند)

جدول ۲. نتایج به کارگیری مرحله اول تبدیل موجک بر الگوهای همزمان

تعداد سطوح	الگوهای همزمان	الگوهای منفرد استخراج شده از تبدیل موجک در:
۵	روند - شیف	D1
	روند - سیکل	D2 + D3 + D5
	روند - سیستماتیک	مجموع جزئیات
	شیف - سیکل	-
	شیف - سیستماتیک	شیف
	سیکل - سیستماتیک	سیکل

جدول ۳. نتایج به کارگیری مرحله دوم تبدیل موجک بر الگوهای همزمان

تعداد سطوح	الگوهای همزمان	الگوهای منفرد استخراج شده از تبدیل موجک در:
۵	روند - شیف	تخمین
	روند - سیکل	D1
	روند - سیستماتیک	مجموع جزئیات
	شیف - سیکل	-
	شیف - سیستماتیک	سیستماتیک
	سیکل - سیستماتیک	سیستماتیک

۴-۲. شبکه عصبی مصنوعی

بخش انتهایی و بسیار مهم فرایند، به کارگیری شبکه عصبی می باشد که وظیفه دسته بندی و تشخیص نهایی نوع الگو را به عهده دارد. در این تحقیق معماری های متفاوتی مورد بررسی قرار گرفتند که در میان آنها، معماری شبکه های عصبی احتمالی (PNN) برتری های نسبی خود را نسبت به سایرین نشان داد. شبکه های PNN یکی از انواع شبکه های مبتنی بر انشعاب (RBF)

و از شبکه های برجسته در زمره دسته بندی کننده ها می باشند که الگوهای ورودی را به یکی از دسته های موجود نگاشت نموده و از این طریق به عنوان عملگرهای عمومی تقریب زنده با توانایی بالا ایفای نقش می نمایند. از جمله مزایای به کارگیری این نوع شبکه می توان به فرآیند سریع آموزش، ساختار موازی ذاتی، تضمین همگرایی در صورت افزایش داده های آموزشی و نیز امکان افزایش و کاهش داده های آموزشی بدون نیاز به باز آموزشی گسترده اشاره

۲-۵. آزمون نتایج در تشخیص الگوهای همزمان


به منظور بررسی دقیق عملکرد روش پیشنهادی در این تحقیق، یک نرم افزار واسط کاربری (در محیط Matlab GUI) جهت آزمایش میزان دقت عمل در فرآیندهای تفکیک الگوها توسط تبدیل موجک و نیز تشخیص و دسته بندی الگوها توسط شبکه عصبی طراحی و پیاده سازی گردید (شکل ۶).

خاطر نشان می گردد که بدین منظور از الگوهای همزمان ایجاد شده از ترکیب حالات مختلف همزمانی الگوهای آزمون (۲۰۰ حالت متفاوت تصادفی برای هر الگوی همزمان که متمایز از داده های آموزشی شبکه می باشند) که توسط شبیه ساز مونت کارلو تولید شده اند، استفاده گردید، و نتایج امر نرخ دسته بندی و تشخیص صحیح الگوها را با میانگین بالایی ($CR=0.9483$) نشان می دهد که جزئیات آن در جدول ۵ نشان داده شده است.

نمود. شبکه عصبی طراحی شده یک شبکه عصبی PNN چهار لایه ای با لایه های ورودی، الگو، تجمیع و خروجی است که دارای ۲۴ گره در لایه ورودی، یک گره در لایه خروجی با مقادیر مندرج در جدول ۴، توابع انتقال رقابتی و پارامتر انتشار ۰/۰۱ می باشد. به منظور آموزش شبکه عصبی مذکور برای هر الگو، از ۸۰۰ الگوی تولید شده استفاده گردیده و ۲۰۰ الگوی باقیمانده نیز به منظور آزمون شبکه عصبی طراحی شده به کار گرفته شد.

جدول ۴. خروجی های مورد انتظار از شبکه عصبی

خروجی	الگو
۱	روند صعودی
۲	روند نزولی
۳	شیفت بالا رونده
۴	شیفت پائین رونده
۵	سیستماتیک
۶	سیکل



شکل ۶. تولید و نمایش الگوها در نرم افزار واسط کاربری توسعه داده شده

۲-۶. مقایسه نتایج

بررسی نتایج حاصل از این تحقیق با سایر تحقیقات گذشته از جمله Chen و همکاران [۲] و Al-assaf [۳]، بهبود قابل توجهی را در نرخ تشخیص صحیح الگوهای همزمان نشان می دهد. بر اساس مقالات مذکور، Chen و همکاران میانگین کلی نرخ تشخیص صحیح الگوهای همزمان را برابر ۸۵٪ (که این نرخ در صورت وجود یک الگوی سیکل با پیوند زمانی ۷ در الگوی همزمان به ۹۱/۴۱٪ نیز می رسد)، و Al-assaf این نرخ را برای الگوهای همزمان شیفت-سیکل، شیفت-روند و سیکل-روند به ترتیب برابر ۸۴٪، ۸۴٪ و ۸۸٪

جدول ۵. نرخ دسته بندی صحیح الگوهای همزمان

الگوی همزمان	نرخ دسته بندی صحیح
روند- سیکل	۰/۹۵
روند- شیفت	۰/۹۴
روند- سیستماتیک	۰/۹۷
سیکل- شیفت	۰/۹۲
سیکل- سیستماتیک	۰/۹۵
شیفت- سیستماتیک	۰/۹۶
میانگین کل	۰/۹۴۸۳

Approaches”, Computers & Industrial Engineering, Vol. 32, No. 3, 1997, pp. 627-639.

- [7] Atienza, F., Martinez-Alzamora, N., De Velasco, J.A., Dreiseitl, S., Ohno-Machado, L., “*Risk Stratification in Heart Failure Using Artificial Neural Networks*”, in Proc. AMIA Symposium, 2000, pp. 32–36.
- [8] Perry, M., Pignatiello, J.J., “*A Review of Artificial Neural Network Applications in Control Chart Pattern Recognition*,” Proc. of the Industrial Engineering Research Conference, Orlando, FL, 2002.
- [9] Guh, R.S., Tannock, J.D.T., “*Recognition of Control Chart Concurrent Pattern Using a Neural Network approach*”, International Journal of Production Research, Vol. 37, No. 8, 1999, pp. 1743-1765.
- [10] Chen, Z., Lu, S., Lam, S., “*A Hybrid System for SPC Concurrent Pattern Recognition*”, Advanced Engineering Informatics, Vol. 21, 2007, pp. 303-310.
- [11] Al-assaf, Y., “*Multi-Resolution Wavelets Analysis Approach for the Recognition of Concurrent Control Chart Patterns*”, Quality Engineering, Vol. 17, 2005, pp. 11-21.
- [12] Cheng, H.P., Cheng, C-S., “*Control Chart Pattern Recognition Using Wavelet Analysis and Neural Networks*”, Journal of Quality, Vol. 16, No. 5, 2009, pp. 311-321.

گزارش نموده اند. همان طور که در جدول ۵ نشان داده شده است میانگین نرخ تشخیص بدست آمده برای الگوهای همزمان در این تحقیق برابر ۹۴٫۸۳٪ می باشد.

۳. نتیجه گیری

الگوهای همزمان در نمودارهای کنترل فرآیند ناشی از دو الگوی منفرد و مجزا می باشند که در یک بازه زمانی و بطور همزمان رخ می دهند. در اکثر تحقیقات گذشته، برای تشخیص الگوهای همزمان، انواع محدودی از الگوهای موجود در نظر گرفته شده اند که این امر باعث می گردد که تشخیص ماهیت اصلی الگوهای تشکیل دهنده جهت اصلاح فرآیند امکان پذیر نگردد. در این مقاله روش جدیدی برای تشخیص الگوهای همزمان و پیچیده خارج از کنترل نمودارهای SPC با مقادیر مختلف پارامترهای تشکیل دهنده توسعه داده شده است. در این روش، با به کارگیری تبدیل موجک، الگوی همزمان به الگوهای منفرد تشکیل دهنده تفکیک شده و با به کارگیری تحلیل مؤلفه‌های اصلی (PCA) در کنار یک شبکه عصبی احتمالی (PNN)، نوع هر یک از الگوهای منفرد موجود به طور اتوماتیک تشخیص داده می شود تا اقدامات اصلاحی مربوط به هر یک اعمال گردد. نتایج بکارگیری روش پیشنهادی جدید در بازشناسی ۲۰۰ حالت متفاوت و مقایسه آن با روش های موجود نشان دادند که نرخ متوسط تشخیص صحیح الگوهای همزمان در روش پیشنهادی به مراتب بهبود یافته است.

مراجع

- [1] Pham, D.T., Oztmel, E., “*Control Chart Pattern Recognition Using Combinations of Multi-Layer Perceptrons*”, Journal of Systems and Control Engineering, Vol. 207, 1993, pp. 113-118.
- [2] Pham, D.T., Oztmel, E., “*Control Chart Pattern Recognition Using Learning Vector Quantization Networks*”, International Journal of Production Research, Vol. 32, 1994, pp. 721-729.
- [3] Hwang, H.B., Hubele, N.F., “*X-bar Control Chart Pattern Identification Through Efficient Off-Line Neural Network Training*”, IIE Transactions, Vol. 25, No. 3, 1993, pp. 27-40.
- [4] Smith, A.E., “*X-bar and R Control Chart Interpretation Using Neural Computing*”, International Journal of Production Research, Vol. 32, 1994, pp. 309-320.
- [5] Cheng, C-S., “*A Neural Network Approach for the Analysis of Control Chart Patterns*”, International Journal of Production Research, Vol. 35, No. 3, 1997, pp. 667-697.
- [6] Al-Ghanim, A., “*An Unsupervised Learning Neural Algorithm for Identifying Process Behavior on Control Chart and a Comparison with Supervised Learning*