

تشخیص الگوهای نمودار کنترل با استفاده از شبکه‌های عصبی مصنوعی و نرم افزار R

جواد نقدبیشی^۱، مهدی جباری نوقایی، بهرام صادق پور، یاسمن زینتی
گروه آمار دانشگاه فردوسی مشهد

چکیده: تشخیص الگوهای نمودار کنترل به طور دقیق و سریع به منظور نظارت بر فرآیند تولید برای دستیابی به کنترل مناسب و تولید محصولات با کیفیت دارای اهمیت است. نمودارهای کنترل می‌توانند شش نوع الگوی نرمال، سیکل، روند افزایشی، روند کاهش، شیفت به بالا و شیفت به پایین را نشان دهند. به جز الگوی نرمال، تمام الگوهای دیگر نشان می‌دهد که فرآیند تحت نظارت عملکرد درستی نبوده و نیاز به اصلاح مجدد دارد. در این مقاله از دو شبکه عصبی پرسپترون و شبکه تابع شعاع مدار جهت تشخیص الگوهای نمودار کنترل استفاده شده است. برای این منظور از نرم افزار آماری R جهت بالا بردن سرعت فرآیند آموزش شبکه و تولید حجم زیادی از الگوها با پارامترهای مختلف استفاده شده است. نتایج به دست آمده با استفاده از داده‌های شبیه‌سازی شده و خروجی دو شبکه عصبی، نرخ تشخیص صحیح الگوهای مورد نظر را برای شبکه‌های عصبی MLP و RBF به ترتیب برابر با ۹۹/۳۳ و ۹۵/۶۶ درصد نشان می‌دهد. واژه‌های کلیدی: نمودار کنترل، کنترل فرآیند آماری، شبکه عصبی، نرم افزار R. کد موضوع بندی ریاضی (۲۰۱۰): 62M45، 62N10.

مقدمه

در روش کلاسیک نمودارهای کنترل تنها از اطلاعات نمونه اخیر استفاده می‌کنند تا وضعیت روند را که تنها بر اساس حدود کنترل است تعیین نمایند. آن‌ها هیچ‌گونه اطلاعات مرتبط با الگو را ارائه نمی‌دهند. برای افزایش حساسیت یک نمودار کنترل قوانین تکمیلی بسیاری مانند آزمون‌های منطقه‌ای^۱ و یا قوانین اجرا^۲ که توسط گرانت و لیونورت^۳ (۱۹۹۶)، نلسون^۴ (۱۹۸۴) و وسترن الکتریک^۵ (۱۹۵۶) پیشنهاد شده است، وجود دارد که می‌توان جهت تشخیص الگوهای غیرطبیعی از آن‌ها استفاده کرد اما مشکل عمده استفاده از تمام قوانین موجود این است

^۱ جواد نقدبیشی: javad.naghdbish@stu.um.ac.ir

^۱ Zone Tests

^۲ Run Rules

^۳ Grant and Leavenworth

^۴ Nelson

^۵ Western Electric

که استفاده به‌طور هم‌زمان از آن‌ها می‌تواند، هشدارهای کاذب بیش از حدی را به دلیل تغییرپذیری طبیعی در روند عملکرد تولید کنند. از این رو بسیاری از محققان تلاش کردند تا تجزیه و تحلیل الگوهای نمودار کنترل را خودکار کنند تا دخالت انسان در فرآیند تجزیه و تحلیل نمودار کنترل کمتر شود. اخیراً روش مبتنی بر شبکه‌های عصبی مصنوعی^۶ مورد توجه قرار گرفته است که این شبکه‌ها اطلاعات در مورد چگونگی شناسایی الگوها را با استفاده از یادگیری به دست می‌آورند و بر خلاف روش‌های کلاسیک به هیچ کدام از آزمون‌های آماری که اغلب برای روش‌های سنتی مورد استفاده قرار می‌گیرد، نیاز ندارند. همچنین هنگام استفاده از شبکه‌های عصبی به هیچ‌گونه دخالت انسانی نیاز نیست و بنابراین شناسایی الگو می‌تواند به آسانی با سرعت بیشتری صورت گیرد با توجه به ماهیت و توانایی‌های شبکه‌های عصبی در یادگیری، با آموزش الگوها به یک شبکه عصبی امکان تشخیص الگوها فراهم می‌گردد. معماری‌های مختلفی از شبکه‌های عصبی به منظور تشخیص الگوهای غیر طبیعی گزارش شده‌اند که از میان آن‌ها می‌توان به این موارد اشاره نمود:

گروهی از محققان مطالعات مقایسه‌ای از الگوریتم‌های آموزش پرسپترون چند لایه^۷ انجام داده‌اند. به عنوان مثال، کارلامبوس (۱۹۹۲)^۸ الگوریتم پس انتشار خطا^۹ را در مقابل الگوریتم گرادیان مزدوج^{۱۰} مورد بررسی قرار داده است. نتایج برای سه آزمایش نشان داده است که عملکرد گرادیان مزدوج برتر از الگوریتم پس انتشار خطا بوده است. آلپسان و همکارانش (۱۹۹۵)^{۱۱} الگوریتم‌های پس انتشار خطا، گرادیان مزدوج و گوس-نیوتن^{۱۲} را در کاربردهای پزشکی مقایسه کردند و دریافتند که الگوریتم پس انتشار خطا هم به اندازه کافی سریع است و هم تحمل خطای قابل قبولی را دارد. فام و اوزتمل (۱۹۹۳)^{۱۳} یک شبکه پرسپترون چند لایه به همراه آموزش شبکه پس انتشار را به کار بردند. همچنین این دو محقق در تحقیقی دیگر با به‌کارگیری یک شبکه پله‌ای بردار یادگیری^{۱۴} راهکاری برای افزایش دقت دسته‌بندی الگوها و نیز کاهش زمان یادگیری شبکه مذکور ارائه نمودند. در این راستا وارنگ و هوبل (۱۹۹۳)^{۱۵} نیز با استفاده از یک شبکه عصبی پرسپترون با آموزش پس انتشار، توانستند الگوهایی همچون روند و سیکل را در نمودارهای شوهارت^{۱۶} شناسایی نمایند. از جمله تحقیقات انجام شده در محیط واقعی می‌توان به تحقیق انجام شده توسط آتینزا و همکارانش (۲۰۰۰)^{۱۷} اشاره نمود. این محققین باهدف تشخیص

^۶Artificial Neural Networks (ANN)

^۷Multi Layer Perceptron (MLP)

^۸Charalambous

^۹Error Back Propagation Algorithm

^{۱۰}Conjugate Gradient

^{۱۱}Alpsan

^{۱۲}Gauss-Newton

^{۱۳}Pham and Oztemel

^{۱۴}Learning Vector Quantization (LVQ)

^{۱۵}Hwarng and Hubele

^{۱۶}Shewhart

^{۱۷}Atienza

نارسایی در بیماران قلبی، از یک شبکه عصبی پس انتشار به منظور دسته‌بندی و تشخیص سه گروه از نارسایی‌های ممکن بهره جستند که نتایج امر قابلیت‌های بالای شبکه عصبی در این راستا را نشان می‌دهد. حسن و همکاران (۲۰۰۳)^{۱۸} یک روش پیشنهاد داده‌اند که شاخص‌های آماری مثل میانگین، انحراف معیار، عدم تقارن، همبستگی و غیره را استخراج می‌کند. سپس این شاخص‌ها به عنوان ورودی‌های پرسپترون چندلایه (MLP) استفاده می‌شوند ولی با این حال، مشکلاتی مانند روش‌های اکتشافی وقتی که یک یا چند نوع از الگوهای نمودار کنترل اضافه یا حذف شوند می‌توانند به وجود آیند.

اجزای روش پیشنهادی

به منظور پیاده‌سازی روش موردنظر در این تحقیق و آموزش شبکه عصبی، نیاز به تعداد زیادی از انواع مختلف الگوهای نمودارهای کنترل فرآیند آماری می‌باشد که از میان آن‌ها شش نوع از رایج‌ترین الگوها مورد استفاده قرار گرفته‌اند که عبارتند از: الگوی نرمال، سیکل، روند افزایشی، روند کاهشی، شیفت به بالا و شیفت به پایین. از آن‌جا که هدف اصلی از انجام این تحقیق، تحلیل و تشخیص الگوهای نمودارهای کنترل است، روش پیشنهادی برای انجام این هدف به کارگیری شبکه عصبی مصنوعی با الگوریتم یادگیری مناسب جهت آموزش شبکه عصبی می‌باشد، و به منظور تولید الگوهای موردنیاز جهت آموزش و آزمون شبکه عصبی از تکنیک شبیه‌سازی مونت کارلو^{۱۹} بهره‌گیری شده است. جهت آموزش شبکه عصبی موردنظر، ابتدا الگوهای تولید شده نرمال‌سازی می‌شوند و سپس شبکه عصبی آموزش داده می‌شود.

داده‌های آموزشی شبکه

شبکه‌های عصبی نمی‌توانند عملکردشان را بدون آموزش به انجام برسانند. در این مقاله روش یادگیری با ناظر به منظور بهینه‌سازی اوزان شبکه اتخاذ شده است. این روش توسط محققان زیادی مورد استفاده قرار گرفته است. فرآیند آموزش با معرفی نمونه‌های آموزشی به شبکه انجام شده است و سپس ارزش نورون خروجی با یک مقدار هدف مقایسه شده است. آن‌گاه تفاوت بین هدف و مقادیر واقعی توسط میانگین مربعات خطا^{۲۰} محاسبه و نشان داده شده است. با کمک الگوریتم آموزشی، اوزان شبکه برای به حداقل رساندن MSE باید بهینه‌سازی شوند. این فرآیند تا زمانی که یک مقدار MSE رضایت بخش به دست آید ادامه می‌یابد لذا تعداد کافی از مجموعه‌های نمونه‌های آموزشی برای آموزش شبکه‌های عصبی مورد نیاز است. در ابتدا باید سیگنال‌های مربوط به هر یک از الگوها جهت آموزش و آزمون شبکه عصبی تولید شوند. از طرفی برای به حداقل رساندن MSE به تعداد نسبتاً زیادی از هریک از الگوها نیاز است. لذا، با توجه به مقیاس بزرگ الگوهای موردنیاز، واضح است که تولید تک تک الگوها به صورت دستی امری دشوار خواهد بود. از این رو، نیاز به یک تکنیک شبیه‌سازی می‌باشد که توانایی

^{۱۸}Hassan

^{۱۹}Monte-Carlo

^{۲۰}Mean Square Error (MSE)

ایجاد تعداد زیادی از الگوهای مشابه با پارامترهای تصادفی را دارا باشد. برای این منظور از تکنیک شبیه‌سازی مونت کارلو جهت تولید داده‌های آموزشی و آزمایشی برای شش نوع الگوی نمودار کنترل استفاده شده است. تولید این الگوها بر اساس رابطه زیر صورت می‌گیرد:

$$x(t) = \mu + r(t)\sigma + d(t)$$

که در آن $x(t)$ مقدار میانگین نمونه در زمان t را نشان می‌دهد، μ و σ به ترتیب میانگین و انحراف معیار فرآیند می‌باشند، $r(t)$ جزء تغییرپذیری طبیعی در فرآیند می‌باشد که از توزیع نرمال استاندارد پیروی می‌کند و $d(t)$ الگوی موردنظر می‌باشد که برای هر الگو براساس فرمول‌های موجود در جدول شماره ۱ تعیین می‌گردد. در روابط جدول شماره ۱، g اندازه شیب روند، s اندازه دامنه شیفت، a اندازه دامنه سیکل و T فرکانس سیکل می‌باشد. با توجه به این که ممکن است مقادیر پارامترهای میانگین و انحراف معیار در یک فرآیند تحت تاثیر

جدول ۱: فرمول‌های تولید الگو

علل غیرطبیعی تغییر یابند، برای اجتناب از نیاز به آموزش مجدد شبکه با میانگین و انحراف معیار جدید، لازم است که داده‌های آموزشی و آزمایشی استاندارد شوند. زیرا اگر داده‌های آموزشی نرمال‌سازی نشوند در این صورت شبکه تنها قادر به تشخیص الگوهایی با میانگین و انحراف استاندارد ثابت اولیه خواهد بود که بر اساس رابطه زیر نرمال‌سازی صورت می‌گیرد:

$$x_j(t) = \frac{x - \mu}{\sigma} \quad (1)$$


در این رابطه t زمان، x_j مقدار نرمال شده الگوی j ام، x داده موردنظر، μ میانگین داده‌ها و σ انحراف معیار آن‌ها می‌باشد. طراحی محتویات مجموعه داده‌های آموزشی بسیار مهم است و تأثیر زیادی بر عملکرد شبکه دارد. هیچ قانون خاصی برای طراحی مجموعه داده‌های آموزشی مناسب در تئوری دنبال نشده است. محققان قبلی نمونه‌های آموزشی را در پارامترهای متعدد برای یک الگوی واحد به منظور پوشش طیف وسیعی از پارامترهای الگو تولید کردند تا شبکه آموزش لازم را جهت شناسایی الگوهایی با پارامترهای مختلف را داشته باشد. به عنوان مثال گاه (۲۰۰۵)^{۲۱} مجموعه‌هایی آموزشی برای الگوی شیفت به منظور پوشش دامنه مقادیر 1σ تا 3σ را تولید کرد.

طراحی شبکه عصبی

یک شبکه عصبی مصنوعی عمدتاً شامل یک لایه ورودی، لایه‌های پنهان و لایه خروجی است. هر لایه شامل یک مجموعه از عناصر پردازشی به نام نورون‌ها هستند. شکل شماره ۱ یک شبکه عصبی تک نورونه با بردار ورودی شامل R مؤلفه را نشان می‌دهد. ورودی‌های P_1 ، P_2 ، P_3 ، ... در وزن‌های $W_{1,1}$ ، $W_{1,2}$ ، $W_{1,3}$ ، ... ضرب می‌شوند و مقادیر وزن دار شده به محل اتصال جمع تغذیه می‌شوند. هر نورون یک بایاس b دارد که با ورودی‌های وزن دار شده جمع می‌شود تا ورودی خالص n را شکل دهد. سپس نورون با توجه به ورودی

^{۲۱}Guh

خالص n و تابع محرک f ، مقدار خروجی a را می‌دهد. ساختار تک نورونی در شکل شماره ۱ برای همه نورون‌ها موجود در شبکه مشابه می‌باشد. وزن‌های شبکه و بایاس‌ها جهت یادگیری و همگرایی شبکه بهینه‌سازی می‌شوند.



شکل ۱: شبکه عصبی تک نورونه

طراحی یک شبکه برای یک کاربرد خاص شامل تعیین تعداد لایه‌های پنهان، تعداد نورون‌ها در هر لایه و نوع تابع محرک است که انواع زیادی از توابع انتقالی وجود دارند که با توجه به ماهیت مسأله مورد استفاده قرار می‌گیرند. طراحی یک شبکه مناسب کار آسانی نیست، همان‌طور که معماری‌های زیادی از شبکه عصبی وجود دارند که برای یک برنامه خاص مورد استفاده قرار می‌گیرند.

ساگیروگل، بسدوک و ارلر (۲۰۰۰)^{۲۲} تاکید کردند که هیچ روش نظام‌مندی برای انتخاب پارامترهای مناسب وجود ندارد. گاه (۲۰۰۴) الگوریتم ژنتیک برای تعیین تنظیمات شبکه‌های عصبی و پارامترهای آموزشی به جای استفاده از روش آزمون و خطا استفاده کرد اما در کار اخیرش از پارامترهای انتخاب شده توسط روش آزمون و خطا استفاده کرد تا شبکه خود را بسازد. در این مقاله از دو شبکه عصبی مصنوعی جهت تشخیص الگوهای نمودار کنترل استفاده شده است. یک شبکه عصبی پرسپترون چند لایه پیش‌خور که با الگوریتم پس انتشار خطا و دیگری یک شبکه عصبی پیش‌خور تابع شعاع مدار^{۲۳} با الگوریتم آموزشی پایه شعاعی می‌باشد. تابع محرک یک عنصر ضروری در شبکه‌های عصبی است و اثر زیادی بر عملکرد آن‌ها دارد. در تئوری تابع تانژانت هایپربولیک و تابع محرک سیگموئید توسط محققان بسیاری در توسعه شبکه‌های خود مورد استفاده قرار گرفته است. تابع تانژانت هایپربولیک یک ورودی را دریافت می‌کند و به یک خروجی در محدوده بین -۱ و ۱ انتقال می‌دهد و تابع سیگموئید ورودی را در محدوده ۰ و ۱ انتقال می‌دهد. این دو تابع با الگوریتم BP به خوبی عمل می‌کنند، چراکه آن‌ها توابع مشتق‌پذیر هستند و BP اوزان شبکه را مبتنی بر گرادیان توابع MSE تنظیم می‌کند که توسط اولین مشتقات جزئی تابع MSE

^{۲۲} Sagioglu, Besdok and Erler

^{۲۳}Radial Basis Function

محاسبه شده است. گاه و همکارانش (۱۹۹۹) تابع محرک سیگموئید را برای لایه‌های خروجی و پنهان انتخاب کردند. اما گری و چاکرابورتی (۲۰۰۶) تابع محرک تانژانت هایپربولیک را برای لایه‌های پنهان و سیگموئید را برای لایه خروجی انتخاب کردند. بر اساس مجموعه‌ای از آزمایش‌های مقدماتی از تابع محرک سیگموئید برای هر دو لایه پنهان و خروجی شبکه عصبی MLP و از یک تابع پایه شعاعی گوسی برای لایه پنهان و یک تابع سیگموئید برای لایه خروجی شبکه عصبی RBF در این مطالعه استفاده شده است.

در این تحقیق، مجموع همه نمونه‌های آموزشی ۵۰۰۰ مورد می‌باشد که نشان دهنده اندازه مجموعه داده‌های آموزشی است که همه مشاهدات نمونه در یک نمونه خاص از توزیع نرمال به صورت تصادفی تولید شد و هر نمونه واحد شامل ۶۰ مشاهده بود. این ۶۰ نقطه در واقع نمونه‌های به تازگی کشیده شده در فرآیند را نشان می‌دهند. هریک از الگوهای غیر تصادفی با پارامترهای مختلفی تولید شده‌اند تا شبکه عصبی قادر به شناسایی الگوهای مختلف را داشته باشد. در این تحقیق الگوی نرمال با میانگین صفر و انحراف معیار یک شبیه‌سازی شد، الگوی روند با ۴ پارامتر، الگوی شیفت با ۳ پارامتر و الگوی سیکل با ۶ جفت پارامتر شبیه‌سازی شدند. جزئیات مجموعه داده آموزشی و مقادیر هدف مرتبط به آن برای نورون‌های خروجی در جدول شماره ۲ ثبت شده است.

جدول ۲: ساختار مجموعه داده‌های آموزش

الگو مورد نظر	پارامترها	تعداد الگوهای شبیه‌سازی شده
نرمال	$\mu = 0, \sigma = 1$	۱۰۰۰
روند	$g = 0.5\sigma, 0.1\sigma, 0.3\sigma, 0.5\sigma$	۱۶۰۰
شیفت	$s = 1\sigma, 2\sigma, 3\sigma$	۱۲۰۰
سیکل	$a = 1, 2, 3$ $T = 4, 5$	۱۲۰۰

شبکه عصبی در R با استفاده از بسته RSNNs

به منظور بررسی دقیق عملکرد روش پیشنهادی در این تحقیق، از نرم افزار آماری R جهت آزمایش میزان دقت عمل در فرآیندهای تشخیص و دسته‌بندی الگوها توسط شبکه عصبی استفاده گردید. بسته‌های زیادی در R وجود دارد که با نصب آن‌ها می‌توان بسیاری از الگوریتم‌های شبکه عصبی را فراخوانی و اجرا نمود.

^{۲۴}Gauri and Chakraborty

شبیه‌ساز شبکه عصبی اشتوتگارت^{۲۵} مجموعه‌ای است که حاوی تعداد زیادی از نمونه‌های استاندارد پیاده‌سازی شده از شبکه‌های عصبی می‌باشد که با نصب و فراخوانی این بسته می‌توان انواع شبکه عصبی موجود در آن را پیاده‌سازی کرد. (برگمر و بنیتز ۲۰۱۲)^{۲۶}. همان‌طور که قبلاً گفته شد، به منظور دسته‌بندی الگوها از دو شبکه عصبی مصنوعی MLP و RBF استفاده می‌کنیم. که دستورات این دو شبکه در بسته RSNNNS وجود دارد و فقط کافی است که این بسته را نصب و فراخوانی کرد.

آزمون تشخیص الگوهای نمودار کنترل

کد برنامه دو شبکه عصبی مورد نظر با تنظیم مؤلفه‌هایی چون نوع تابع محرک، تعداد نرون‌های لایه‌های پنهان، تعداد تکرارهای شبکه جهت یادگیری و سایر پارامترهای مورد نیاز شبکه‌های عصبی، نوشته و اجرا گردید. به منظور آموزش شبکه عصبی مذکور برای هر الگو، ۸۰ درصد از الگوهای شبیه‌سازی شده یعنی ۴۰۰۰ الگو را جهت آموزش و ۲۰ درصد باقیمانده را جهت آزمایش به شبکه در نظر گرفته شد و هر دو مجموعه داده عیناً به هر دو شبکه عصبی اعمال گردید. جدول شماره ۳ شش الگوی هدف و درصد موفقیت دو شبکه عصبی MLP و RBF را نشان می‌دهد.

جدول ۳: نرخ دسته‌بندی صحیح دو شبکه عصبی MLP و RBF

بحث و نتیجه‌گیری

بررسی نتایج حاصل از این تحقیق با سایر تحقیقات گذشته از جمله گاه (۲۰۰۵)، الاساف (۲۰۰۴)^{۲۷}، گری و چاکرابورتی (۲۰۰۶) مقایسه شده است. بر اساس مقالات مذکور، گری و چاکرابورتی میانگین کلی نرخ تشخیص صحیح ۹۴/۹۳ درصد، الاساف ۹۲/۱۳ درصد و گاه ۹۳/۱۱ درصد گزارش نموده‌اند. میانگین نرخ تشخیص صحیح بدست آمده در این تحقیق برای شبکه‌های عصبی MLP و RBF به ترتیب برابر با ۹۹/۳۳ و ۹۵/۶۶ درصد می‌باشد. نتایج به کارگیری شبکه‌های عصبی MLP و RBF و پیاده‌سازی آن‌ها با استفاده از نرم افزار آماری R با مقایسات انجام شده مشخص می‌کند که نرخ تشخیص صحیح الگوها در این تحقیق به مراتب بهتر از سایر روش‌های انجام شده می‌باشد و همچنین، میزان موفقیت تشخیص صحیح الگوهای نمودار کنترل توسط شبکه عصبی MLP با الگوریتم پس انتشار خطا بیشتر از شبکه عصبی RBF بوده است.

^{۲۵}Stuttgart Neural Network Simulator

^{۲۶}Bergmeir and Benitez

^{۲۷}Al-Assaf

- Al-Assaf, Y. "Recognition of control chart patterns using multi-resolution wavelets analysis and neural networks," *Computers and Industrial Engineering*, Vol. 47, pp. 17–29, 2004.
- Alpsan, D., Towsey, M., Ozdamar, O., Tsoi, A. C. and Ghista, D. N. "Efficacy of modified backpropagation and optimisation methods on a real-world medical problem", *Neural Networks*, 8(6), pp.945-62, 1995.
- 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*, pp. 32-36, 2000.
- Bergmeir, C. and Benitez, J.M., "Neural Networks in R Using the Stuttgart Neural Network Simulator: RSNNS", *Journal of Statistical Software*, 46(7), 1-26, 2012.
- Charalambous, C. "Conjugate-gradient algorithm for efficient training of artificial neural networks", *IEE Proceedings- G Circuits Devices and Systems*, 139, pp.301-310, 1992.
- Gauri, S. K. and Chakraborty, S. "Feature-based recognition of control chart patterns," *Computers and Industrial Engineering*, Vol. 51, pp. 726–742, 2006.
- Grant, E. L. and Leavenworth, R. S. "Statistical quality control," 7th Edition, McGraw-Hill, New York, 1996.
- Guh, R. S. "A hybrid learning-based model for on-line detection and analysis of control chart patterns," *Computers and Industrial Engineering*, Vol. 49, pp. 35–62, 2005.
- Guh, R. S. "Optimizing feedforward neural networks for control chart pattern recognition through genetic algorithms," *International Journal of Pattern Recognition and Artificial Intelligence*, Vol. 18, No. 2, pp. 75–99, 2004.
- Guh, R. S., Zorriassatine, F. Tannock, J. D. T. and Brien, C. O. "On-line control chart pattern detection and discrimination: A neural network approach," *Artificial Intelligence in Engineering*, Vol. 13, pp. 413–425, 1999.

Hassan, A., Baksh, M., Shaharoun, A. and Jamaluddin, H. "Improved spc chart pattern recognition using statistical features", *International Journal of Production Research*, Vol. 41, no. 7, pp. 1587–1603, 2003.

Hwarng, H.B., Hubele, N.F., "X-bar Control Chart Pattern Identification Through Efficient Off-Line Neural Network Training", *IIE Transactions*, Vol. 25, No. 3, pp. 27-40, 1993.

Nelson, L. S. "The Shewhart control chart: Tests for special causes," *Journal of Quality Technology*, Vol. 16, pp. 237–239, 1984.

Pham, D.T., Oztemel, E., "Control Chart Pattern Recognition Using Combinations of Multi-Layer Perceptrons", *Journal of Systems and Control Engineering*, Vol. 207, pp. 113-118, 1993.

Sagiroglu, S., Besdok, E. and Erler, M. "Control chart pattern recognition using artificial neural networks," *Turkish Journal of Electrical Engineering*, Vol. 8, No. 2, pp. 137–147, 2000.

Western Electric. "Statistical quality control handbook," AT&T, Princeton, 1956.