

به کارگیری شبکه‌های عصبی در فناوری گروهی و مقایسه با نتایج روش‌های خوشه‌بندی K میانگین، ضریب شباهت و آرایش رتبه‌ای

علیرضا پویا*، احسان جوان راد**

چکیده

مهم‌ترین مسئله هنگام پیاده‌سازی فناوری گروهی در واحدهای صنعتی، در درجه‌ی اول تشکیل خانواده‌ی قطعات و دسته‌بندی قطعات براساس آن و در مرحله دوم حفظ سازگاری و ثبات این دسته‌بندی در طول زمان است. برای دسته‌بندی قطعات، رویکردهای مختلفی وجود دارد و اگر رویکرد استفاده از خصوصیات قطعات برای دسته‌بندی آن‌ها مورد استفاده قرار گیرد، اولین و مهم‌ترین گام، طراحی و پیاده‌سازی ساختاری برای کدگذاری و شناخت قطعات براساس خصوصیات آن‌ها است. در این پژوهش، کاربرد یک شبکه عصبی پس‌انتشار برای دسته‌بندی قطعات در قالب یک مطالعه‌ی موردی برای پین‌های کانکتورها و براساس خصوصیات آن‌ها مورد بررسی قرار گرفته و نتایج حاصل از آن با دسته‌بندی‌های صورت‌گرفته توسط تحلیل خوشه‌ای K میانگین، روش ضریب شباهت و خوشه‌بندی آرایش رتبه‌ای (ROC) برای همان قطعات مقایسه شده است. نتایج نشان‌دهنده قابلیت شبکه‌های عصبی برای دسته‌بندی قطعات براساس خصوصیات آن‌ها و برتری آن نسبت به روش تحلیل خوشه‌ای K میانگین است.

کلیدواژه‌ها: شبکه‌های عصبی؛ فناوری گروهی؛ دسته‌بندی و کدینگ قطعات.

تاریخ دریافت مقاله: ۹۲/۷/۱ تاریخ پذیرش مقاله: ۹۳/۱۱/۲۳

* استادیار، دانشگاه فردوسی مشهد

** دانشجوی دکتری، پردیس دانشگاه فردوسی (نویسنده مسئول).

E-mail: e_javanrad@yahoo.com

۱. مقدمه

تنوع تولیدات در عصر حاضر سبب شده است که حجم تولید در بیشتر صنایع، کم و یا متوسط باشد که این امر باعث تغییر مکرر تنظیم تجهیزات، زمان بالای تولید، قطعات در جریان ساخت زیاد و طی مسیر طولانی برای تولید قطعات شده است. در همین راستا، سیستم‌های تولید انعطاف‌پذیر برای پاسخگویی به نیازهای پیچیده امروزی و محیط‌های پویا طراحی شده‌اند که از آن جمله می‌توان به تولید سلولی^۱ (CMS) به‌عنوان یک کاربرد از فناوری گروهی در حوزه‌ی تولید اشاره کنیم [۳۱]. فناوری گروهی یک فلسفه‌ی تولیدی است که می‌تواند برای افزایش کارایی تولید، کاهش هزینه‌های تولید و مدیریت سیستم تولید دسته‌ای استفاده شود [۱۵]. این تکنیک قطعات/فرآیندهای مشابه را شناسایی می‌کند و آن‌ها را برای استفاده از شباهتشان در طراحی و تولید کنار هم می‌آورد [۲۳، ۲۴]. مفهوم فناوری گروهی در حوزه‌های مختلفی، از جمله طراحی قطعه، طرح‌ریزی فرآیند، طراحی سلول تولیدی، چیدمان تجهیزات، برنامه‌زمان‌بندی و ... تأثیرگذار خواهد بود. با پیاده‌سازی فناوری گروهی و تولید قطعات مشابه با یکدیگر، شرکت‌های تولیدی به مزایای زیادی، شامل کاهش تغییر تنظیم تجهیزات، زمان آماده‌سازی کمتر، کاهش زمان عملیات، کاهش موجودی کالای در جریان تولید، کاهش سطح موجودی، کاهش هزینه حمل مواد، استفاده بهتر از فضا، کاهش تنوع ابزارها، کاهش تنوع جیگ و فیکسچرها، کاهش ضایعات و کاهش تنوع طراحی قطعات دست می‌یابند.

دو مسئله مهم مرتبط با پیاده‌سازی فناوری گروهی، تشکیل خانواده‌ی قطعات و دسته‌بندی قطعات هستند که بسیار به هم وابسته هستند و معمولاً رویکرد واحدی برای حل آن‌ها استفاده می‌شود [۱۷]. گروه‌بندی قطعات ممکن است براساس مطالعه جریان فرآیند تولید باشد که به آن تجزیه و تحلیل جریان تولید^۲ و یا به‌اختصار PFA گویند، یا براساس مطالعه جنبه‌های طراحی و تولید و خصوصیات قطعات باشد که به آن تحلیل دسته‌بندی و کدینگ قطعات^۳ و یا به اختصار PCA گویند و یا براساس بازرسی چشمی و ظاهری معمول صورت پذیرد [۲۷].

تاکنون بیشتر تحقیقات انجام‌شده در حوزه‌ی فناوری گروهی مرتبط با بخش‌بندی در قالب PFA بوده است که در آن‌ها با استناد به ماتریس قطعه-ماشین، به گروه‌بندی قطعات و تشکیل سلول‌های تولیدی پرداخته می‌شود. با ظهور تجهیزات چندکاره و انعطاف‌پذیر تولیدی که هر یک می‌توانند عملیاتی را که در گذشته توسط چندین ماشین صورت می‌گرفت به‌تنهایی انجام دهند (به‌ویژه در حوزه‌ی قطعات کوچک و با دقت‌های بالا که حوزه مورد مطالعه در این پژوهش

1. Cellular Manufacturing System
 2. Production Flow Analysis
 3. Parts Coding and Classification Analysis

هستند)، مهم‌ترین عامل، کاهش زمان‌های آماده‌سازی و تنظیم مجدد تجهیزات است. یک ابزار کارآمد برای حل این‌گونه مسائل، استفاده از تکنیک‌های مطرح‌شده در حوزه‌ی PCA است. در استفاده از رویکرد PCA، مهم‌ترین و اولین مرحله طراحی، یک ساختار کدینگ مناسب است که به بهترین وجه نشان‌دهنده‌ی خصوصیات طراحی و تولید هر قطعه باشد.

علاوه بر دو مسئله ذکرشده در بالا (تشکیل خانواده قطعات و دسته‌بندی آن‌ها)، مسئله مهم دیگر در فناوری گروهی، چگونگی حفظ سازگاری و ثبات در ادامه کار است که اگر این امر به عهده فرد گذاشته شود، بسیار تحت تأثیر قضاوت شخصی خواهد بود و در این حالت نیز یک شخص واحد باید برای انجام این کار در تمامی زمان‌ها در نظر گرفته شود که باز هم حفظ سازگاری برای کلیه شروط و در زمان‌های طولانی زیر سؤال خواهد بود. برای دسته‌بندی قطعات و همچنین حفظ سازگاری، الگوریتم‌ها و راهکارهای مختلفی ارائه شده است که یکی از آن‌ها آموزش یک شبکه عصبی برای انجام این کار است [۱۷].

در این پژوهش، برای اثبات کارایی استفاده از شبکه‌های عصبی برای گروه‌بندی قطعات در فناوری گروهی با استناد به خصوصیات قطعات، خروجی‌های حاصل از آموزش یک شبکه عصبی پیشخور^۱ با الگوریتم پس‌انتشار^۲ (BP) و دسته‌بندی قطعات براساس آن با نتایج حاصل از گروه‌بندی صورت‌گرفته توسط تحلیل خوشه‌ای K میانگین، روش ضریب شباهت با الگوریتم خوشه‌بندی مبتنی بر همبستگی منفرد^۳ (SLC) و همچنین خوشه‌بندی آرایش رتبه‌ای (ROC) مقایسه شده است.

کانکتور یک وسیله الکترومکانیکی است که یک اتصال جاشدنی را میان دو زیرمجموعه از یک سیستم الکتریکی و یا الکترونیکی برقرار می‌کند؛ بدون اینکه تأثیر منفی بر کارکرد سیستم بگذارد. کانکتورها به شکل‌های مختلف نری، مادگی، کابلی و پنبلی استفاده می‌شوند که به‌طور کلی شامل قطعات اصلی زیر هستند: پین‌ها، مقر دی‌الکتریک، بدنه و ملحقات.

در صنعت کانکتورسازی، تولید پین‌ها به‌دلیل ظرافت و ویژگی‌های خاص آن‌ها و تنوع، از اهمیت خاصی برخوردار هستند و به‌عنوان یک فرآیند کلیدی شناسایی می‌شوند. در این پژوهش کوشیده‌ایم تکنیک‌های معرفی‌شده فناوری گروهی برای شناسایی و دسته‌بندی این قطعه‌ی مهم از کانکتور را مورد بحث و بررسی قرار دهیم.


در بیشتر مقالات موجود در حوزه گروه‌بندی قطعات، تکنولوژی گروهی و کاربرد شبکه‌های عصبی در آن‌ها، هدف تشکیل سلول‌های تولیدی با استناد به ماتریس قطعه-ماشین است؛ اما در این مقاله با توجه به استفاده از ماشین‌های چندکاره، چیدمان آن‌ها موضوعیت ندارد و برای

1. Feed Forward
2. Back Propagation
3. Single Linkage Clustering

گروه‌بندی قطعات از ماتریس قطعه-خصوصیت استفاده شده است و جنبه نوآوری آن به کارگیری شبکه‌های عصبی در این حوزه و مقایسه نتایج آن با چند روش دیگر ذکر شده در مقاله است. همچنین نوآوری دیگر، ارائه یک ساختار کدینگ جدید برای شناسایی پین‌ها با رویکرد PCA بوده است که در شبکه‌های عصبی نیز استفاده می‌شود.

۲. مبانی نظری و پیشینه پژوهش

شبکه‌های عصبی پس‌انتشار (BP)، شبکه‌های چندلایه‌ای هستند، با یک لایه ورودی، یک لایه خروجی و چند لایه پنهان بین لایه‌های ورودی و خروجی. در شکل ۱ یک ساختار شماتیک از یک شبکه پیش‌خور چندلایه، شامل یک لایه ورودی، یک لایه خروجی و یک لایه پنهان را نشان داده‌ایم [۱۷].



شکل ۱. ساختار یک شبکه عصبی پیش‌خور [۱۷]

ابتدا وزن‌ها به صورت تصادفی تعیین و ورودی‌ها به شبکه عصبی وارد می‌شوند و سپس هر نرون در لایه خودش خروجی‌ها را از همه نرون‌های لایه قبلی جمع‌آوری می‌کند. مقادیر خروجی برای هر نرون در هر لایه از درون شبکه و رو به جلو انتشار داده می‌شود تا خروجی‌های واقعی و خطای هر نرون در لایه خروجی محاسبه شود. فرآیند یادگیری یک شبکه عصبی پس‌انتشار در دو مرحله اتفاق می‌افتد؛ در فاز اول خروجی هر نرون در هر لایه و مقادیر خطا بین خروجی

واقعی از لایه خروجی و خروجی‌های هدف محاسبه می‌شود و در فاز دوم وزن‌ها از طریق خطاهای پس‌انتشار اصلاح می‌شوند که در هر لایه شبکه اتفاق می‌افتد [۱۲].
توضیحات زیر کارکرد یک نمونه الگوریتم پس‌انتشار را تشریح می‌کنند [۱۷].

net_{pi} : ورودی شبکه به واحد پردازش i با الگوی p (یک الگو مانند یک لیست از خصوصیات قطعات)

w_{ij} : وزن اتصال بین واحد پردازش i و واحد پردازش j

a_{pi} : ارزش فعال‌سازی واحد پردازش i در الگوی p

δ_{pi} : اثر یک تغییر روی خروجی واحد i در الگوی p

t_{pi} : مقدار هدف یا مقدار مورد انتظار از واحد پردازش i

ε : پارامتر یادگیری

در ابتدا، یک الگو به شبکه ساخته شده اعمال می‌شود. ورودی‌های شبکه و مقادیر فعال‌سازی از واحد پردازش میانی، به ترتیب از رابطه‌های ۱ و ۲ محاسبه می‌شوند. ورودی شبکه جمع وزن‌دار مقادیر فعال‌سازی از واحدهای ورودی متصل به اضافه یک مقدار پیش‌فرض است. وزن‌های اتصال به صورت تصادفی ابتدا تخصیص داده شده‌اند و به‌طور پیوسته تغییر می‌کنند. این مقادیر فعال‌سازی به صورت گردشی برای محاسبه ورودی‌های شبکه استفاده می‌شوند و مقادیر فعال‌سازی واحدهای پردازش خروجی همان روابط ۱ و ۲ را استفاده می‌کنند.

$$net_{pi} = \sum_j w_{ij} a_{pj} \quad \text{رابطه ۱}$$

$$a_{pi} = \frac{1}{1 - e^{-net_{pi}}} \quad \text{رابطه ۲}$$

یک‌بار که با مقادیر فعال‌سازی واحدهای پردازش خروجی محاسبه شد، مقادیر هدف مورد انتظار با مقادیر فعال‌سازی هر خروجی مقایسه می‌شود. اختلاف بین این دو مقدار اکنون با استفاده از رابطه ۳ به سمت عقب انتشار داده می‌شود.

$$\delta_{pi} = (t_{pi} - a_{pi}) f'_i(net_{pi}) \quad \text{رابطه ۳}$$

برای واحدهای پردازش لایه میانی که مقادیر هدف برای آن‌ها نامشخص است، رابطه ۴ به‌جای رابطه ۳ برای محاسبه اختلاف استفاده می‌شود.

$$\delta_{pi} = f'_i(net_{pi}) \sum_k \delta_{pk} W_{ki} \quad \text{رابطه ۴}$$

با استفاده از رابطه ۵ و نتایج روابط ۳ و ۴، وزن‌ها بین واحدهای پردازش تنظیم می‌شوند. هر قدر پارامتر یادگیری بزرگ‌تر باشد، تغییرات در وزن‌ها بیشتر خواهد بود؛ بنابراین داشتن یک نرخ یادگیری تا حد امکان بزرگ و بدون آثار نوسانی مطلوب است.

$$\Delta W_{ij} = \delta \varepsilon_{pi} a_{pj} \quad \text{رابطه ۵}$$

برای بحث بیشتر در مورد شبکه‌های عصبی پیش‌خور سه لایه و قوانین یادگیری پس‌انتشار به منابع شماره ۲۹ و ۲۱ مراجعه کنید.

در روش PFA یک ماتریس تلاقی قطعه-ماشین به صورت باینری (شامل ۰ و ۱) تشکیل می‌شود. این ماتریس نشان می‌دهد که برای تولید هر قطعه از چه ماشین‌هایی استفاده شده است و سپس خوشه‌های قطعه-ماشین توسط یک الگوریتم مناسب شکل می‌گیرند [۲۴].

بریدج‌این تکنیک را در چندین سیستم تولیدی مورد استفاده قرار داد [۷، ۸]. مک آلی نیز این روش را با استفاده از تحلیل خوشه‌ای در قالب الگوریتم خوشه‌بندی با همبستگی منفرد ابداعی خود (SLC) برای تشکیل خانواده قطعات و گروه‌بندی آن‌ها مورد توجه قرار داد [۲۰]. آنلر و گونگور از روش خوشه‌بندی K میانگین هارمونیک که جزو روش‌های غیرسلسله‌مراتبی است، برای دسته‌بندی قطعات و تشکیل سلول‌های تولیدی استفاده کردند [۳۱]. روش‌های دیگری نیز توسط سایر نویسندگان برای حل این مسئله توسعه داده شده است که برای مطالعه بیشتر می‌توانیم به منابع اشاره شده رجوع کنیم [۲۲، ۹، ۲۸، ۱۹، ۱۰، ۶، ۱۱].

یک رویکرد که در برخی از موارد ذکر شده قبلی برای حل مسئله گروه‌بندی ماشین-قطعه در PFA استفاده شده است، کاربرد محاسبه ضریب شباهت است که نشان می‌دهد قطعات یا ماشین‌ها چقدر به یکدیگر شبیه و نزدیک هستند. استفاده از روش ضریب شباهت در فناوری گروهی بسیار انعطاف‌پذیر است و به راحتی قابلیت کامپیوتری شدن را دارد و به همین دلیل بیشتر اقدامات در حوزه تشکیل گروه‌های قطعه-ماشین بر این اساس بوده است که در آن ماتریس قطعه-ماشین PFA به عنوان ورودی در نظر گرفته می‌شود [۲۴، ۲۰، ۹].

برای اولین بار، مک آلی از تکنیک ضریب شباهت در این حوزه استفاده کرد که در آن براساس رابطه تعریف شده، ضریب شباهت بین هر دو ماشین را محاسبه کرد و طبق الگوریتم SLC خوشه‌بندی آن‌ها را انجام داد [۲۰]. محاسبه ضریب شباهت همچنین می‌تواند به جای ماشین‌ها براساس قطعات، بین قطعات براساس ماشین‌ها صورت پذیرد [۲۳]. الیویرا و همکاران از یک الگوریتم خوشه‌بندی برپایه مدل نمایش دو قسمتی استفاده کردند که در آن دو ماتریس شباهت یکی برای قطعات و یکی برای ماشین‌ها ساخته می‌شود و برای شناسایی خانواده قطعات

و سلول‌های تولیدی الگوریتم خوشه‌بندی طیفی به‌طور جداگانه روی هریک اعمال می‌شود [۲۵]. برای مطالعه بیشتر و یک دسته‌بندی کامل از روش‌های مختلف استفاده‌شده در این حوزه برای گروه‌بندی قطعات و تشکیل سلول‌های تولیدی به تحقیق صورت‌گرفته توسط بین و یاسودا مراجعه کنید [۳۴].

مطالعات انجام‌شده در حوزه‌ی استفاده از رویکرد PCA برای دسته‌بندی قطعات در فناوری گروهی نسبت به رویکرد PFA بسیار ناچیز و محدود است. در روش PCA که براساس تجزیه و تحلیل دسته‌بندی و کدینگ قطعات است، باید ابتدا برای هریک از قطعات براساس خصوصیات آن کد معناداری استخراج شود. ارقام این کد برخلاف ماتریس قطعه-ماشین می‌تواند مقادیری غیر از صفر و یک داشته باشد، که این وزن‌ها می‌توانند نشان‌دهنده نسبی برخی خصوصیات به‌کاررفته در کد قطعه باشند؛ به همین دلیل PCA اطلاعات بیشتری را نسبت به PFA ارائه می‌کند [۲۴]. رویکرد PCA به فناوری گروهی مرتبط با کاربرد جنبه‌های طراحی قطعه و تکنیک‌های تولید برای تشکیل گروه‌ها است. این جنبه‌ها معمولاً از طریق ارائه یک کد عددی شامل تیرانس‌ها، نیازمندی‌های مواد و شکل و سایز قطعات برآورده می‌شود. اوفودیل در پژوهشی رویکرد PCA را برای دسته‌بندی قطعات به کمک روش ضریب شباهت مورد استفاده قرار داده است که در این مقاله از اعداد وزن‌دار در تشکیل ماتریس قطعه-خصوصیت اولیه استفاده شده است [۲۴].

تاکنون چندین سیستم کدینگ که قطعات کاری را توصیف می‌کنند در پژوهش‌های گذشته ارائه شده‌اند که برخی از آن‌ها عبارت‌اند از: OPITZ, SAGT, MICLASS, CODE. انواع سیستم‌های کدینگ به سه دسته کلی تقسیم می‌شوند که عبارت‌اند از: سلسله‌مراتبی^۱، زنجیری^۲ و ترکیبی^۳. در سیستم سلسله‌مراتبی یا تک‌کدی^۴ هر رقم در ارتباط با رقم قبلی خود معنا پیدا می‌کند؛ ولی در سیستم زنجیری یا چندکدی^۵ هر رقم به‌تنهایی معنا و مفهوم خاص خود را دارد. سیستم‌های ترکیبی نیز آمیخته‌ای از دو سیستم قبلی هستند که بارزترین نوع آن سیستم کدینگ OPITZ است. معمولاً تعداد ارقام کدهای سلسله‌مراتبی کمتر از زنجیری است؛ اما مزیت عمده سیستم زنجیری نسبت به سلسله‌مراتبی آسان‌تر بودن کامپیوتری کردن آن است [۲۴]. درنهایت، کدهای PCA ایجادشده باید از طریق الگوریتم‌هایی به فرمتی تبدیل شوند که قابل استفاده در تشکیل گروه‌های مورد نظر باشد.

-
1. Hierarchical
 2. Chain Type
 3. Hybrid
 4. Mono Code
 5. Poly Code

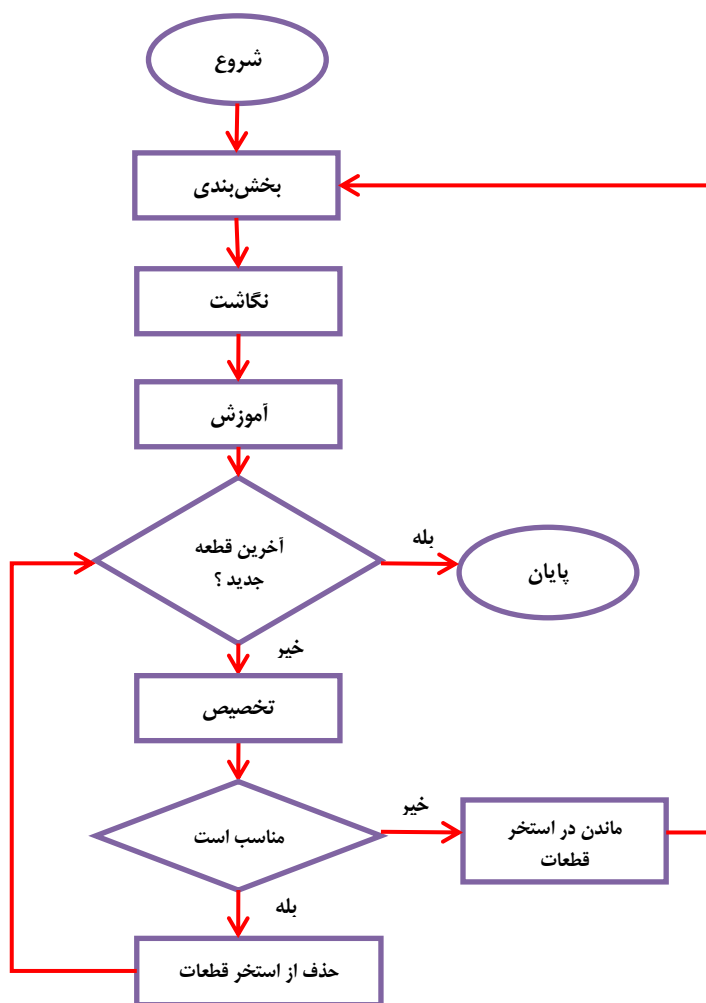
پویا و همکاران برای گروه‌بندی قطعات براساس عوامل مشترک بین آن‌ها (عوامل موثر در سیستم انبارش) از روش تحلیل خوشه‌ای K میانگین استفاده کردند [۱]. ناظمی و همکاران برای طبقه‌بندی اقلام انبار از تلفیق روش ABC و طبقه بندی فازی، تحت عنوان ABC-Fuzzy استفاده کردند [۴].

کاپارتی و سورش شبکه‌های عصبی را برای دسته‌بندی و کدینگ قطعات دوار برمبنای شکل آن‌ها از طریق یک کد سه‌رقمی برای توصیف قطعه، مورد استفاده قرار دادند [۱۸]. آووال و همکاران یک شبکه عصبی را برای تشخیص شکل قطعات در فرمت تصاویر باینری مورد استفاده قرار دادند [۵]. کامارتی و همکاران یک شبکه عصبی پس‌انتشار را برای بازیابی اطلاعات قطعات استفاده کردند [۱۶]. روملهارت و همکاران یک مکانیزم یادگیری اثربخش با استفاده از شبکه‌های عصبی پیش‌خور با الگوریتم پس‌انتشار را به اثبات رساندند. این شبکه قادر است الگوهای ورودی (در این مقاله الگوهای خصوصیات قطعات) را به الگوهای خروجی (در این مقاله خانواده قطعات) پیوند دهد [۲۹] و و جن یک شبکه عصبی پس‌انتشار را برای حل مسئله دسته‌بندی قطعات منشوری سه‌بعدی استفاده کردند [۳۲]. چونگ و کوسیاکیک شبکه عصبی پس‌انتشار را برای دسته‌بندی قطعات دوار مورد استفاده قرار دادند [۱۲]. کائو و مون یک شبکه عصبی پس‌انتشار را برای دسته‌بندی قطعات بر پایه خصوصیات قطعه مورد استفاده قرار دادند [۱۷] و مون و چی تلفیق شبکه‌های عصبی با روش ضریب شباهت در مدل PFA را برای تشکیل خانواده قطعات مورد استفاده قرار دادند. در این مقاله علاوه بر ماتریس قطعه-ماشین، طرح‌های فرآیند چندگانه و توالی عملیات نیز در قالب یک مدل تعمیم‌یافته به‌عنوان ورودی مدل مورد توجه قرار گرفته‌اند [۲۳]. سوداکارا و ماهاپاترا برای گروه‌بندی قطعات و تشکیل سلول‌های تولیدی با استفاده از شبکه‌های عصبی علاوه بر ماتریس قطعه-ماشین به‌عنوان ورودی، پارامترهای دیگری از جمله توالی عملیات و زمان عملیات را نیز مورد توجه قرار دادند [۳۰]. مین شن و جین هوآی یانگ شبکه عصبی ART1 را با برخی اصلاحات در الگوریتم مربوطه برای دسته‌بندی قطعات و تشکیل سلول‌های تولیدی با استفاده از ماتریس قطعه-ماشین مورد استفاده قرار دادند [۳۳]. محمدی و همکاران برای جداسازی پوسته از مغز و دسته‌بندی مغز گردها از شبکه‌های عصبی و روش آنالیز تشخیصی استفاده کردند [۳]. ماکویی و همکاران نیز از شبکه‌های عصبی خودسازمان‌دهنده برای دسته‌بندی داده‌های مربوط به اندازه لباس استفاده کردند [۲]. برای مطالعه بیشتر و یک دسته‌بندی کامل از روش‌های مختلف استفاده‌شده در این حوزه برای گروه‌بندی قطعات و تشکیل سلول‌های تولیدی، به تحقیق پاپایونو و ویلسون مراجعه کنید [۲۷].

۳. روش‌شناسی پژوهش

در این پژوهش برای گروه‌بندی قطعات با استفاده از رویکرد PCA، از چهار روش شبکه عصبی پس‌انتشار، تحلیل خوشه‌ای k میانگین، روش ضریب شباهت و خوشه‌بندی آرایش رتبه‌ای (ROC) به شرح ذیل استفاده کرده‌ایم:

الگوریتم استفاده از شبکه عصبی پس‌انتشار. در این بخش رویکردی برای استفاده از توانایی یادگیری شبکه عصبی برای خودکار کردن فرآیند تشکیل خانواده جدید از قطعات در حین فرآیند دسته‌بندی ارائه کرده‌ایم. این الگوریتم دارای ۴ فاز، طبق نمودار ۱ و توضیحات زیر است [۱۷]:



نمودار ۱. فلوجارت دسته‌بندی قطعات جدید

فاز بخش‌بندی^۱: در این فاز ۳ تا ۵ قطعه کاملاً متمایز از یکدیگر، از استخر قطعات انتخاب می‌شود و به هریک از این قطعات یک شماره گروه اختصاص داده می‌شود.

فاز نگاشت^۲: در این فاز مطابق با یک سیستم کدینگ که براساس تعریف خصوصیات قطعات طراحی شده است، به تمامی قطعات (اعم از قطعات درون استخر و موارد بخش‌بندی شده به‌عنوان گروه‌های اولیه) یک کد اختصاص داده می‌شود. سپس یک شبکه عصبی پس‌انتشار طراحی می‌شود که در آن هر واحد ورودی شبکه، یک خصوصیت از قطعه را نشان می‌دهد و هر واحد خروجی آن یک خانواده یا گروه قطعات را نشان می‌دهد.

فاز آموزش^۳: در این فاز اطلاعات قطعات متمایز انتخاب‌شده از استخر قطعات (شامل کد قطعات یا خصوصیات آن‌ها و گروه هریک) به‌عنوان داده آموزش به شبکه عصبی اعمال می‌شود. پس از این مرحله، شبکه آموزش‌دیده برای دسته‌بندی قطعات باقی‌مانده به مناسب‌ترین گروه‌ها آماده است.

فاز تخصیص^۳: در این مرحله اطلاعات یا خصوصیات قطعات باقی‌مانده به شبکه آموزش‌دیده اعمال می‌شود. این مرحله دو دسته خروجی دارد؛ یک دسته قطعات مشابه با گروه قطعات اولیه هستند که در آموزش شبکه از آن‌ها استفاده می‌شود و برای این موارد شبکه عصبی کد گروه مربوطه را به آن‌ها تخصیص می‌دهد و دسته دیگر قطعاتی هستند که شباهتی با آن گروه‌های اولیه ندارند و کدی به آن‌ها اختصاص داده نمی‌شود. از این موارد باید برای شکل‌دهی گروه قطعات جدید استفاده شود و سیکل ذکرشده در بالا برای آن‌ها تکرار شود. الگوریتم ذکرشده در بالا و پارامترهای به‌کار رفته در آن به شرح زیر خلاصه و فرموله‌بندی می‌شود:

F_n : خانواده (گروه) m

I : شماره سیکل تکرار

m : بیشترین رقم در کد الگوی هدف

N : تعداد خانواده‌های بخش‌بندی جدید

NF_n : تعداد اعضای خانواده جدید در F_n

NP : تعداد قطعات در استخر قطعه

NS : تعداد قطعات بخش‌بندی (سیدها)

P : استخر قطعه، $\{P_1, P_2, \dots, P_i\}$

S : استخر قطعات بخش‌بندی و همچنین مجموعه آموزش، $\{S_1, S_2, \dots, S_j\}$

T_i : مقدار فعال‌سازی یک رقم در کد الگوی هدف (۰ یا ۱)

1. Seeding
2. Mapping
3. Assigning

X_i : مقدار فعال‌سازی یک رقم در کد الگوی خروجی (قدرمطلق آن کوچک‌تر از ۱)

TT : مقدار آستانه

مرحله صفر:

$$\begin{aligned} I &= 1 \\ NS &= 0 & S &= \{\} \\ NP &= NP & P &= \{P_1, P_2, \dots, P_{NP}\} \end{aligned}$$

مرحله ۱: تعیین مقدار N (بزرگ‌تر از ۲ و کوچک‌تر از ۶)

مرحله ۲: انتخاب N قطعه بخش‌بندی از استخر قطعه

مرحله ۳: تخصیص شماره شناسایی گروه به هریک از قطعات

$$\begin{aligned} NS &= NS + N \\ NP &= NP - N \end{aligned}$$

مرحله ۴: ارائه مجموعه آموزش به شبکه عصبی پس‌انتشار برای آموزش آن

مرحله ۵: ارائه قطعات باقی‌مانده در استخر قطعه به شبکه عصبی آموزش‌دیده برای مرحله

تخصیص. برای هر قطعه اگر $|T_i - X_i| < TT \quad i = 1, 2, \dots, m$ ، قطعه به خانواده متناظر

تخصیص می‌یابد و در غیر این صورت به هیچ خانواده‌ای اختصاص داده نمی‌شود.

مرحله ۶: حذف تعداد اعضای خانواده انتخاب‌شده در این سیکل از استخر قطعه (پایان سیکل I)

$$NP = NP - \sum NFn \quad n = 1, \dots, NS$$

مرحله ۷: اگر $NP > 0$ ، آنگاه $I = I + 1$ و مراجعه به مرحله ۲ و در غیر این صورت پایان.

تحلیل خوشه‌ای K میانگین. در این روش خوشه‌بندی که یکی از روش‌های غیرسلسله‌مراتبی

است، باید از ابتدا تعداد خوشه‌های (گروه‌های قطعات) مورد نظر (K) تعیین شود. پس از تعیین

تعداد گروه‌ها، سایر گام‌های این الگوریتم به شرح ذیل است:

K : تعداد گروه‌های (خانواده‌های) قطعات

P : تعداد پارامترها یا خصوصیات قطعات

n : تعداد کل قطعات

d_{jz} : فاصله بین قطعه z و قطعه j

x_{pj} : مقدار خصوصیت p برای قطعه j

x_{pj} : مقدار خصوصیت p برای قطعه j

مرحله ۱: تمام قطعات به K گروه (خوشه) افراز شده و مراکز ثقل هر گروه محاسبه می‌شود. بهتر است این کار به صورت تصادفی و به تعداد برابر در گروه‌ها انجام شود.

مرحله ۲: فاصله اقلیدسی همه n قطعه با مراکز ثقل K گروه با استفاده از رابطه ۶ محاسبه می‌شود.

$$d_{jj'} = \left[\sum_{p=1}^P (x_{pj} - x_{pj'})^2 \right]^{\frac{1}{2}} \quad \text{رابطه ۶}$$

مرحله ۳: بر مبنای فاصله‌ها، هر آزمودنی به نزدیک‌ترین گروه منتقل می‌شود و مراکز ثقل K گروه به روز می‌گردد.

مرحله ۴: مراحل بالا تا انتقالی بین گروه‌ها اتفاق نیفتد، ادامه می‌یابد.

روش ضریب شباهت. در این روش که ورودی آن ماتریس قطعه-خصوصیت است، هدف این است که برای هر جفت از قطعات و براساس خصوصیات آن‌ها یک مقدار ضریب شباهت استخراج شود تا از آن بتوان در تشکیل گروه‌ها استفاده کرد. با توجه به اینکه درایه‌های ماتریس مورد استفاده از نوع باینری (۰ و ۱) است، با الگوبرداری از نحوه محاسبه ضریب شباهت قطعات با استفاده از ماتریس قطعه-ماشین، ضرایب شباهت قطعات با استفاده از ماتریس قطعه-خصوصیت، به شرح رابطه ۷ محاسبه می‌شود.

S_{ij} : ضریب شباهت بین قطعه i و قطعه j

M: تعداد خصوصیات استفاده شده

β_i : مجموعه خصوصیات استفاده شده برای شناسایی قطعه i

β_j : مجموعه خصوصیات استفاده شده برای شناسایی قطعه j

$$S_{ij} = \frac{M(\beta_i \cap \beta_j)}{M(\beta_i \cup \beta_j)} \quad \text{رابطه ۷}$$

سپس مطابق با الگوریتم دسته‌بندی زیر عمل می‌شود که بر مبنای الگوریتم خوشه‌بندی

همبستگی منفرد (SLC) است [۲۴]:

مرحله ۱: محاسبه S_{ij} ها و تشکیل ماتریس ضرایب شباهت بین قطعات.

مرحله ۲: انتخاب بیشترین S_{ij} از ماتریس بالا (مشابه‌ترین قطعات) و تشکیل گروه اول (ترکیب دو قطعه‌ای که در سطر و ستون منتخب قرار دارند).

مرحله ۳: محاسبه مجدد ضرایب شباهت و تشکیل ماتریس جدید و انتخاب بیشترین S_{ij} .

مرحله ۴: اگر i یا j در S_{ij} جدید برابر با همان گروه قبلی بود، اضافه کردن این قطعه به گروه قبلی و در غیر این صورت تشکیل گروه جدید.
 مرحله ۵: اگر تمام قطعات به گروه‌ها تخصیص یافته‌اند، اتمام سیکل و در غیر این صورت رجوع به مرحله ۳.

خوشه‌بندی آرایش رتبه‌ای (ROC). ورودی این روش در حالت عادی ماتریس قطعه-ماشین است که در این مقاله به جای آن از ماتریس قطعه-خصوصیت استفاده کرده‌ایم. گام‌های روش به شرح زیر هستند:

مرحله ۱: تخصیص وزن به هر ستون j از ماتریس براساس رابطه ۸ (m تعداد ستون‌های ماتریس است).

$$BW_j = 2^{m-j} \quad \text{رابطه ۸}$$

مرحله ۲: تعیین امتیاز هر سطر i از ماتریس براساس رابطه ۹.

$$DE_i = \sum_{j=1}^m 2^{m-j} a_{ij} \quad \text{رابطه ۹}$$

مرحله ۳: مرتب‌سازی سطرها به صورت کاهشی براساس مقادیر DE .

مرحله ۴: تخصیص وزن به هر سطر i از ماتریس براساس رابطه ۱۰ (n تعداد سطرهای ماتریس است).

$$BW_i = 2^{n-i} \quad \text{رابطه ۱۰}$$

مرحله ۵: تعیین امتیاز هر ستون j از ماتریس بر اساس رابطه ۱۱.

$$DE_j = \sum_{i=1}^n 2^{n-i} a_{ij} \quad \text{رابطه ۱۱}$$

مرحله ۶: مرتب‌سازی ستون‌ها به صورت کاهشی براساس مقادیر DE . برگشت به گام ۱.

سیکل بالا تا زمانی ادامه پیدا می‌کند که دیگر تغییری در ترتیب سطرها و ستون‌ها ایجاد نشود.

۴. تحلیل داده‌ها و یافته‌های پژوهش

پس از بررسی ساختارهای کدینگ مختلف ارائه شده در ادبیات تحقیق و در نظر گرفتن مزایا و معایب هریک، در این پژوهش از ساختار کدینگ زنجیری با ۲۲ رقم که در آن هریک از ارقام

به‌تنهایی دارای معنا و مفهوم خاص خود است، مطابق جدول ۱ استفاده کردیم. گفتنی است که با توجه به مزایایی که روش تحلیل دسته‌بندی و کدینگ قطعات (PCA) دارد (از جمله جلوگیری از دوباره‌کاری در طراحی قطعه و طراحی فرآیند تولید از همان ابتدای مراحل شناسایی و کدگذاری هر قطعه در قالب جدول قطعه - خصوصیت^۱)، در این پژوهش در طراحی سیستم کدینگ قطعات، استفاده از این روش مورد توجه قرار گرفته است.

جدول ۱. جدول خصوصیات قطعات استفاده‌شده در ساختار کدینگ

| رقم | مقدار ممکن | خصوصیات |
|-----|------------|--|
| ۱ | ۰ یا ۱ | سطح مقطع دایره‌ای (بین استاندارد) |
| ۲ | ۰ یا ۱ | صافی سطح بالاتر از RZ 6/3 (بین تماسی) |
| ۳ | ۰ یا ۱ | خاصیت ارتجاعی (فتری) |
| ۴ | ۰ یا ۱ | فتر پیچ هذلولی (هایپربولید) ^۲ |
| ۵ | ۰ یا ۱ | فورج‌شده |
| ۶ | ۰ یا ۱ | سایز بزرگ‌تر یا مساوی ۱۶ (انتقال دیتا) |
| ۷ | ۰ یا ۱ | سایز کوچک‌تر از ۱۶ (انتقال قدرت) |
| ۸ | ۰ یا ۱ | انتهای شیب‌دار (لحیمی) |
| ۹ | ۰ یا ۱ | انتهای شیاردار (پرسی) |
| ۱۰ | ۰ یا ۱ | انتهای استوانه‌ای (نری) |
| ۱۱ | ۰ یا ۱ | انتهای لوله‌ای (مادگی) |
| ۱۲ | ۰ یا ۱ | انتهای سیم‌پیچی ^۳ |
| ۱۳ | ۰ یا ۱ | انتهای سوراخ‌دار (چشمی) ^۴ |
| ۱۴ | ۰ یا ۱ | نیاز به عملیات حرارتی |
| ۱۵ | ۰ یا ۱ | نوک استوانه‌ای (نری) |
| ۱۶ | ۰ یا ۱ | نوک لوله‌ای (مادگی) |
| ۱۷ | ۰ یا ۱ | نوک مادگی با هود |
| ۱۸ | ۰ یا ۱ | نوک دوجنسیتی |
| ۱۹ | ۰ یا ۱ | شیب مثبت‌گاه محل قفل (از عقب آزادشونده) |
| ۲۰ | ۰ یا ۱ | شیب منفی‌گاه محل قفل (از جلو آزادشونده) |
| ۲۱ | ۰ یا ۱ | دارای فتر قفل‌کن (خود قفل‌شونده) |
| ۲۲ | ۰ یا ۱ | پله‌دار (ثابت و بدون قفل‌کن) |

1. Part-Attribute
2. Hyperbolid
3. wir-wrap/pc-tail
4. Eyelet

در این مطالعه موردی برای امکان مقایسه خروجی‌های ۳ مدل ذکرشده و با هدف اثبات کارایی شبکه‌های عصبی برای گروه‌بندی قطعات با رویکرد PCA، ۱۵ عدد پین با مشخصات مختلف را که طبق نظر خبرگان صنعت قابل دسته‌بندی به ۴ گروه بودند انتخاب کردیم و طبق سیستم کدینگ توضیح داده‌شده در قبل، کدهای آن‌ها را براساس خصوصیاتشان به شرح جدول ۲ استخراج کردیم.

جدول ۲. جدول قطعه-خصوصیت

| خصوصیات قطعه | | | | | | | | | | | | | | | شماره قطعه | | | | | |
|--------------|----|---|---|---|---|---|---|---|----|----|----|----|----|----|------------|----|----|----|----|----------|
| 1 | *2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 | |
| 1 | | | | | | 1 | | 1 | | | 1 | | | | | 1 | | | | P_{01} |
| 1 | | | | | | | 1 | | | | 1 | | | | | | 1 | 1 | | P_{02} |
| | | | | 1 | 1 | | | | | 1 | | | 1 | | | | | | 1 | P_{03} |
| | | 1 | | | 1 | | | | | 1 | | | 1 | | | | | | 1 | P_{04} |
| 1 | | | | | 1 | | | 1 | | | | 1 | | | | | | 1 | | P_{05} |
| | | 1 | | | 1 | | | | | 1 | | | 1 | | | | | | 1 | P_{06} |
| | | | | 1 | 1 | | | | | | 1 | | 1 | | | | | | 1 | P_{07} |
| | | 1 | | | | 1 | | | | 1 | | | 1 | | | | | | 1 | P_{08} |
| | | | | 1 | 1 | | | | | | 1 | | 1 | | | | | | 1 | P_{09} |
| 1 | | | | | | 1 | 1 | | | | 1 | | | | | 1 | | | | P_{10} |
| | | 1 | | | 1 | | | | | 1 | | | 1 | | | | | | 1 | P_{11} |
| 1 | | | | | 1 | | | 1 | | | | 1 | | | | 1 | | | | P_{12} |
| 1 | | | | | | 1 | | | | | 1 | | 1 | | | | | 1 | | P_{13} |
| | | 1 | | | | 1 | | | | | 1 | | 1 | | | | | | 1 | P_{14} |
| | | | | 1 | 1 | | | | | 1 | | | 1 | | | | | | 1 | P_{15} |

* از آنجا که در این بررسی کلیه قطعات مورد مطالعه بررسی نشده‌اند، ستون‌های ۲، ۱۰ و ۱۱ که برخی خصوصیات مربوط به قطعات بررسی نشده را نشان می‌دهند، خالی هستند.

حل با استفاده از شبکه عصبی

تکرار اول:

مرحله ۰: در اولین تکرار تعداد قطعات درون استخر ۱۵ عدد است و مقدار آستانه ۰/۱ تعیین می‌شود. در این مرحله هنوز قطعه‌ای برای بخش‌بندی انتخاب نشده است.

$$I = 1$$

$$\begin{aligned} NS &= 0 & S &= \{\} \\ NP &= 15 & P &= \{P_1, P_2, \dots, P_{15}\} \\ TT &= 0.1 \end{aligned}$$

مرحله ۱: تعداد گروه‌ها برابر ۳ تعیین می‌شود. پس داریم: $N=3$
 مرحله ۲: قطعات P_1, P_2, P_3 به دلیل تفاوت‌هایشان به عنوان قطعات بخش‌بندی انتخاب می‌شوند.

مرحله ۳: به هر یک از قطعات بخش‌بندی یک گروه اختصاص داده می‌شود، P_1 به گروه $G1$ ، P_2 به گروه $G2$ و P_3 به گروه $G3$ و داریم:

$$\begin{aligned} NS &= 0 + 3 = 3 & S &= \{P_1, P_2, P_3\} \\ NP &= 15 - 3 = 12 & P &= \{P_4, P_5, \dots, P_{15}\} \end{aligned}$$

مرحله ۴: در این مرحله به تعریف یک شبکه عصبی از نوع تابع شعاع‌مدار^۱ (RBF) در نرم‌افزار SPSS 19 پرداخته شد که در آن متغیرهای ورودی (متغیرهای مستقل) همان خصوصیات ۲۲گانه که در کدینگ قطعات به کار رفته بودند تعریف شدند و متغیر خروجی (متغیر وابسته) گروه قطعات تعریف شد. سپس داده‌های ۱۵ قطعه مورد نظر وارد شبکه عصبی شد و سه قطعه مشخص شده در مراحل ۲ و ۳ و گروه‌های آن‌ها به عنوان داده‌های آموزش برای شبکه معرفی شدند تا شبکه براساس آن‌ها آموزش ببیند.

مرحله ۵: قطعات باقی‌مانده در استخر قطعات به شبکه عصبی آموزش دیده ارائه شد تا دسته‌بندی قطعات توسط آن صورت پذیرد. با توجه به آستانه تعریف شده فقط مواردی که احتمال پیش‌بینی آن‌ها در نرم‌افزار بیش از ۹۰ درصد محاسبه شده بود، انتخاب شدند که نتایج به شرح ذیل است:

$$G1 = \{P_1, P_5, P_{12}\} \quad G2 = \{P_2, P_{13}\} \quad G3 = \{P_3, P_7, P_9, P_{15}\}$$

مرحله ۶: حذف تعداد قطعات تخصیص داده شده از استخر قطعات.

$$NP = 12 - (2 + 1 + 3) = 6$$

مرحله ۷: سیکل اول پایان یافت و آغاز سیکل دوم به دلیل $NP > 0$.
 تکرار دوم:

$$I = I + 1 = 2 \quad \text{مرحله ۱:}$$

مرحله ۲: قطعه P_4 به عنوان قطعه بخش‌بندی جدید انتخاب می‌شود.

مرحله ۳: قطعه P_4 به گروه $G4$ تخصیص داده می‌شود.

$$NS = 3 + 1 = 4$$

1. Radial Basis Function

$$NP = 6 - 1 = 5$$

مرحله ۴: ارائه داده‌های جدید به شبکه عصبی (به‌همراه داده‌های قبلی) برای آموزش مجدد شبکه.

مرحله ۵: ارائه قطعات باقی‌مانده در استخراج قطعات به شبکه آموزش‌دیده برای گروه‌بندی آن‌ها که نتیجه به شرح ذیل است:

$$G1 = \{P_1, P_5, P_{12}, P_{10}\} \quad G2 = \{P_2, P_{13}\} \quad G3 = \{P_3, P_7, P_9, P_{15}\}$$

$$G4 = \{P_4, P_6, P_8, P_{11}, P_{14}\}$$

مرحله ۶: حذف قطعات تخصیص داده شده از استخراج قطعات.

$$NP = 5 - (1 + 4) = 0$$

مرحله ۷: سیکل دوم پایان یافت و پایان حل مسئله به دلیل $NP=0$.

گروه‌بندی انجام‌شده نهایی این روش به شرح جدول ۳ است.

جدول ۳. نتایج گروه‌بندی شبکه عصبی

| | 20 | 8 | 9 | 15 | 19 | 1 | 7 | 18 | 14 | 21 | 5 | 16 | 12 | 6 | 3 | 13 | 17 | 22 | 10 | 11 | 2 | 4 | |
|----------|----|---|---|----|----|---|---|----|----|----|---|----|----|---|---|----|----|----|----|----|---|---|--|
| P_{01} | | | 1 | 1 | 1 | 1 | 1 | | | | | | | | | | | | | | | | |
| P_{05} | 1 | | 1 | 1 | | 1 | | | | | | | | 1 | | | | | | | | | |
| P_{10} | | 1 | | 1 | 1 | 1 | 1 | | | | | | | | | | | | | | | | |
| P_{12} | | | 1 | 1 | 1 | 1 | | | | | | | | 1 | | | | | | | | | |
| P_{02} | | | | | 1 | 1 | 1 | 1 | 1 | 1 | | | | | | | | | | | | | |
| P_{13} | | | | | | 1 | 1 | 1 | 1 | 1 | | | | | | | | | | | | | |
| P_{03} | | | | | | | | | | 1 | 1 | 1 | 1 | 1 | 1 | | | | | | | | |
| P_{07} | | | | | | | | | | 1 | 1 | 1 | 1 | | 1 | | | | | | | | |
| P_{09} | | | | | | | | | | 1 | 1 | 1 | 1 | | 1 | | | | | | | | |
| P_{15} | | | | | | | | | | | 1 | 1 | 1 | 1 | 1 | | | | | | | | |
| P_{04} | | | | | | | | | | | | | | | 1 | 1 | 1 | 1 | 1 | 1 | | | |
| P_{06} | | | | | | | | | | | | | | | 1 | 1 | 1 | | 1 | 1 | | | |
| P_{08} | | | | | | | 1 | | | | | | | | | 1 | 1 | 1 | 1 | | | | |
| P_{11} | | | | | | | | | | 1 | | | | | | 1 | 1 | 1 | 1 | | | | |
| P_{14} | | | | | | | 1 | | | | | | | | | 1 | 1 | 1 | 1 | | | | |

همان‌طور که در جدول ۳ می‌بینیم، قطعات قرارگرفته درون هر گروه بیشترین خصوصیات مشترک را با یکدیگر دارند.

حل با استفاده از تحلیل خوشه‌ای K میانگین. برای خوشه‌بندی قطعات با استفاده از روش K میانگین، خصوصیات ۲۲گانه قطعات به‌عنوان متغیر به نرم‌افزار SPSS19 معرفی شدند و سپس داده‌های مربوط به جدول قطعه-خصوصیت (جدول ۲) به نرم‌افزار وارد شدند و تعداد گروه

قطعات برای خوشه‌بندی داده‌ها ۴ تعریف شد که پس از انجام تحلیل خوشه‌ای نتایج خروجی به شرح زیر به‌دست آمدند:

$$G1 = \{P_1, P_5, P_{12}\} \quad G2 = \{P_2, P_{10}, P_{13}\} \quad G3 = \{P_3, P_7, P_9, P_{15}\}$$

$$G4 = \{P_4, P_6, P_8, P_{11}, P_{14}\}$$

نتایج مطابق جدول ۴ است.

جدول ۴: نتایج دسته‌بندی k میانگین

| | 20 | 8 | 9 | 15 | 19 | 1 | 7 | 18 | 14 | 21 | 5 | 16 | 12 | 6 | 3 | 13 | 17 | 22 | 10 | 11 | 2 | 4 | |
|----------|----|---|---|----|----|---|---|----|----|----|---|----|----|---|---|----|----|----|----|----|---|---|--|
| P_{01} | | | 1 | 1 | 1 | 1 | 1 | | | | | | | | | | | | | | | | |
| P_{05} | 1 | | 1 | 1 | | 1 | | | | | | | | | 1 | | | | | | | | |
| P_{12} | | | 1 | 1 | 1 | 1 | | | | | | | | | 1 | | | | | | | | |
| P_{02} | | | | | 1 | 1 | 1 | 1 | 1 | 1 | | | | | | | | | | | | | |
| P_{10} | | 1 | | | 1 | 1 | 1 | 1 | | | | | | | | | | | | | | | |
| P_{13} | | | | | | 1 | 1 | 1 | 1 | 1 | 1 | | | | | | | | | | | | |
| P_{03} | | | | | | | | | | 1 | 1 | 1 | 1 | 1 | 1 | | | | | | | | |
| P_{07} | | | | | | | | | | 1 | 1 | 1 | 1 | | 1 | | | | | | | | |
| P_{09} | | | | | | | | | | 1 | 1 | 1 | 1 | | 1 | | | | | | | | |
| P_{15} | | | | | | | | | | | 1 | 1 | 1 | 1 | 1 | | | | | | | | |
| P_{04} | | | | | | | | | | | | | | | 1 | 1 | 1 | 1 | 1 | 1 | | | |
| P_{06} | | | | | | | | | | | | | | | 1 | 1 | 1 | | 1 | 1 | | | |
| P_{08} | | | | | | | 1 | | | | | | | | | 1 | 1 | 1 | 1 | | | | |
| P_{11} | | | | | | | | | | 1 | | | | | | 1 | 1 | 1 | 1 | | | | |
| P_{14} | | | | | | | 1 | | | | | | | | | 1 | 1 | 1 | 1 | | | | |

همان‌طور که در جدول بالا می‌بینیم، قطعه P_{10} اشتراک زیادی با قطعات قرارگرفته در آن گروه ندارد.

حل با استفاده از روش ضریب شباهت. براساس داده‌های جدول قطعه-خصوصیت (جدول ۲) ضرایب شباهت طبق رابطه ۷ محاسبه شد. جدول ۵ ضرایب شباهت همه قطعات را نشان می‌دهد؛ برای نمونه، ضریب شباهت قطعه ۱ و قطعه ۵ عبارت است از:

$$S_{15} = \frac{M(\beta_1 \cap \beta_5)}{M(\beta_1 \cup \beta_5)} = \frac{3}{7} = 0/43$$

جدول ۵. ماتریس ضرایب شباهت قطعات

| | P_{01} | P_{02} | P_{03} | P_{04} | P_{05} | P_{06} | P_{07} | P_{08} | P_{09} | P_{10} | P_{11} | P_{12} | P_{13} | P_{14} | P_{15} |
|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| P_{01} | | 0/43 | 0/00 | 0/00 | 0/43 | 0/00 | 0/00 | 0/11 | 0/00 | 0/67 | 0/00 | 0/67 | 0/25 | 0/11 | 0/00 |
| P_{02} | | | 0/00 | 0/00 | 0/11 | 0/00 | 0/11 | 0/11 | 0/11 | 0/43 | 0/00 | 0/25 | 0/67 | 0/11 | 0/00 |
| P_{03} | | | | 0/11 | 0/11 | 0/25 | 0/67 | 0/00 | 0/67 | 0/00 | 0/25 | 0/11 | 0/11 | 0/00 | 1/00 |
| P_{04} | | | | | 0/11 | 0/67 | 0/11 | 0/67 | 0/11 | 0/00 | 0/67 | 0/11 | 0/00 | 0/67 | 0/11 |
| P_{05} | | | | | | 0/11 | 0/11 | 0/00 | 0/11 | 0/25 | 0/11 | 0/67 | 0/11 | 0/00 | 0/11 |
| P_{06} | | | | | | | 0/11 | 0/43 | 0/11 | 0/00 | 0/43 | 0/11 | 0/00 | 0/43 | 0/25 |
| P_{07} | | | | | | | | 0/00 | 1/00 | 0/00 | 0/25 | 0/11 | 0/25 | 0/00 | 0/67 |
| P_{08} | | | | | | | | | 0/00 | 0/11 | 0/43 | 0/00 | 0/11 | 1/00 | 0/00 |
| P_{09} | | | | | | | | | | 0/00 | 0/25 | 0/11 | 0/25 | 0/00 | 0/67 |
| P_{10} | | | | | | | | | | | 0/00 | 0/43 | 0/25 | 0/11 | 0/00 |
| P_{11} | | | | | | | | | | | | 0/11 | 0/11 | 0/43 | 0/25 |
| P_{12} | | | | | | | | | | | | | 0/11 | 0/00 | 0/11 |
| P_{13} | | | | | | | | | | | | | | 0/11 | 0/11 |
| P_{14} | | | | | | | | | | | | | | | 0/00 |
| P_{15} | | | | | | | | | | | | | | | |

در ادامه، طبق فلوچارت مربوطه، بزرگ‌ترین عدد در جدول ۳ که عدد ۱ است مشخص شد که به تشکیل سه گروه اول توسط قطعات (P_3, P_{15}) ، (P_7, P_9) و (P_8, P_{14}) منجر شد. سپس ضرایب شباهت مجدداً برای سطرها و ستون‌های تغییر یافته محاسبه شد که خروجی آن در جدول شماره ۶ ارائه شده است؛ برای نمونه، نحوه محاسبه ضرایب شباهت بین گروه P_{3-15} و قطعه P_6 به شرح زیر است:

$$S_{3\ 15(6)} = \max(S_{3\ 6}, S_{15\ 6}) = 0.25$$

پس از ادامه مراحل مطابق سیکل بالا، خانواده قطعات به شرح زیر محاسبه شد:

$$G1 = \{P_1, P_5, P_{10}, P_{12}\} \quad G2 = \{P_2, P_{13}\} \quad G3 = \{P_3, P_7, P_9, P_{15}\}$$

$$G4 = \{P_4, P_6, P_8, P_{11}, P_{14}\}$$

جدول ۶. ماتریس ضرایب شباهت باز محاسبه شده

| | P_{01} | P_{02} | P_{3-15} | P_{04} | P_{05} | P_{06} | P_{7-9} | P_{8-14} | P_{09} | P_{10} | P_{11} | P_{12} | P_{13} | P_{14} | P_{15} |
|------------|----------|----------|------------|----------|----------|----------|-----------|------------|----------|----------|----------|----------|----------|----------|----------|
| P_{01} | | 0/43 | 0/00 | 0/00 | 0/43 | 0/00 | 0/00 | 0/11 | | 0/67 | 0/00 | 0/67 | 0/25 | | |
| P_{02} | | | 0/00 | 0/00 | 0/11 | 0/00 | 0/11 | 0/11 | | 0/43 | 0/00 | 0/25 | 0/67 | | |
| P_{3-15} | | | | 0/11 | 0/11 | 0/25 | 0/67 | 0/00 | | 0/00 | 0/25 | 0/11 | 0/11 | | |
| P_{04} | | | | | 0/11 | 0/67 | 0/11 | 0/67 | | 0/00 | 0/67 | 0/11 | 0/00 | | |
| P_{05} | | | | | | 0/11 | 0/11 | 0/00 | | 0/25 | 0/11 | 0/67 | 0/11 | | |
| P_{06} | | | | | | | 0/11 | 0/43 | | 0/00 | 0/43 | 0/11 | 0/00 | | |
| P_{7-9} | | | | | | | | 0/00 | | 0/00 | 0/25 | 0/11 | 0/25 | | |
| P_{8-14} | | | | | | | | | | 0/11 | 0/43 | 0/00 | 0/11 | | |
| P_{09} | | | | | | | | | | | | | | | |
| P_{10} | | | | | | | | | | | 0/00 | 0/43 | 0/25 | | |
| P_{11} | | | | | | | | | | | | 0/11 | 0/11 | | |
| P_{12} | | | | | | | | | | | | | 0/11 | | |
| P_{13} | | | | | | | | | | | | | | | |
| P_{14} | | | | | | | | | | | | | | | |
| P_{15} | | | | | | | | | | | | | | | |

حل با استفاده از خوشه‌بندی آرایش رتبه‌ای (ROC). براساس داده‌های جدول قطعه- خصوصیت (جدول ۲) و مطابق توضیحات ذکرشده درخصوص گام‌های خوشه‌بندی آرایش رتبه‌ای در متن مقاله، پس از سه بار انجام سیکل مذکور، نتایج گروه‌بندی قطعات مشابه جدول ۷ به‌دست آمد. گفتنی است که با توجه به اینکه در این مسئله ستون‌ها نماینده خصوصیات قطعات هستند و ترتیب آن‌ها از اهمیت چندانی برخوردار نیست، برای نمایش بهتر صحت گروه‌بندی صورت‌گرفته روی قطعات، برخی ستون‌ها نسبت به خروجی مسئله جابه‌جا شده‌اند.

جدول ۷: نتایج خوشه‌بندی آرایش رتبه‌ای

| | 20 | 8 | 9 | 15 | 19 | 1 | 7 | 18 | 14 | 21 | 5 | 16 | 12 | 6 | 3 | 13 | 17 | 22 | 10 | 11 | 2 | 4 | |
|----------|----|---|---|----|----|---|---|----|----|----|---|----|----|---|---|----|----|----|----|----|---|---|--|
| P_{12} | | | 1 | 1 | 1 | 1 | | | | | | | | 1 | | | | | | | | | |
| P_{05} | 1 | | 1 | 1 | | 1 | | | | | | | | 1 | | | | | | | | | |
| P_{01} | | | 1 | 1 | 1 | 1 | 1 | | | | | | | | | | | | | | | | |
| P_{10} | | 1 | | 1 | 1 | 1 | 1 | | | | | | | | | | | | | | | | |
| P_{02} | | | | | 1 | 1 | 1 | 1 | 1 | 1 | | | | | | | | | | | | | |
| P_{13} | | | | | | 1 | 1 | 1 | 1 | 1 | | | | | | | | | | | | | |
| P_{07} | | | | | | | | | 1 | 1 | 1 | 1 | | | 1 | | | | | | | | |
| P_{09} | | | | | | | | | | 1 | 1 | 1 | 1 | | | 1 | | | | | | | |
| P_{03} | | | | | | | | | | | 1 | 1 | 1 | 1 | 1 | | | | | | | | |
| P_{15} | | | | | | | | | | | | 1 | 1 | 1 | 1 | 1 | | | | | | | |
| P_{11} | | | | | | | | | | 1 | | | | | 1 | 1 | 1 | 1 | | | | | |
| P_{04} | | | | | | | | | | | | | | | 1 | 1 | 1 | 1 | 1 | 1 | | | |
| P_{06} | | | | | | | | | | | | | | 1 | 1 | 1 | | 1 | 1 | | | | |
| P_{08} | | | | | | | | 1 | | | | | | | | 1 | 1 | 1 | 1 | | | | |
| P_{14} | | | | | | | | | 1 | | | | | | | 1 | 1 | 1 | 1 | | | | |

مقایسه تطبیقی نتایج روش‌ها. برای مقایسه نتایج به‌دست آمده از چهار روش حل مختلف، این نتایج را به‌همراه گروه‌بندی صورت‌گرفته توسط خبرگان صنعت در جدول شماره ۸ آورده‌ایم. همان‌طور که می‌بینیم، نتایج روش‌های شبکه عصبی، ضریب شباهت و خوشه‌بندی آرایش رتبه ای یکسان و تنها در قطعه ۱۰ با نتیجه روش تحلیل خوشه‌ای K میانگین متفاوت است؛ به عبارت دیگر، قطعه P_{10} در سه روش دیگر در خانواده قطعات گروه ۱ و در روش تحلیل خوشه‌ای در خانواده قطعات گروه ۲ قرار گرفته است.

جدول ۸: نتایج نهایی گروه‌بندی قطعات

| روش حل مسئله | گروه ۱ | گروه ۲ | گروه ۳ | گروه ۴ |
|-------------------------------|----------------------------|-----------------------|-------------------------|---------------------------------|
| شبکه عصبی | P_1, P_5, P_{10}, P_{12} | P_2, P_{13} | P_3, P_7, P_9, P_{15} | $P_4, P_6, P_8, P_{11}, P_{14}$ |
| تحلیل خوشه‌ای K میانگین | P_1, P_5, P_{12} | P_2, P_{10}, P_{13} | P_3, P_7, P_9, P_{15} | $P_4, P_6, P_8, P_{11}, P_{14}$ |
| روش ضریب شباهت | P_1, P_5, P_{10}, P_{12} | P_2, P_{13} | P_3, P_7, P_9, P_{15} | $P_4, P_6, P_8, P_{11}, P_{14}$ |
| خوشه‌بندی آرایش رتبه‌ای (ROC) | P_1, P_5, P_{10}, P_{12} | P_2, P_{13} | P_3, P_7, P_9, P_{15} | $P_4, P_6, P_8, P_{11}, P_{14}$ |
| نظرات خبرگان صنعت | P_1, P_5, P_{10}, P_{12} | P_2, P_{13} | P_3, P_7, P_9, P_{15} | $P_4, P_6, P_8, P_{11}, P_{14}$ |

۵. نتیجه‌گیری و پیشنهادها

همان‌طور که در جدول ۷ دیدیم، نتایج به‌دست آمده از گروه‌بندی قطعات با استفاده از شبکه‌های عصبی، روش ضریب شباهت و خوشه‌بندی آرایش رتبه‌ای کاملاً با یکدیگر و با دسته‌بندی صورت‌گرفته توسط خبرگان صنعت همخوانی دارد؛ ولی با دسته‌بندی به روش K میانگین متفاوت است. با توجه به اینکه در تحقیقات گذشته کارایی روش ضریب شباهت برای دسته‌بندی قطعات هم با رویکرد PFA و هم با رویکرد PCA به اثبات رسیده است [۲۴]، همخوانی نتایج شبکه عصبی با این نتایج و همچنین نظرات خبرگان بر کارایی شبکه‌های عصبی پس‌انتشار در دسته‌بندی قطعات با رویکرد PCA دلالت دارد و نتایج نشان‌دهنده برتری شبکه‌های عصبی نسبت به تحلیل خوشه‌ای K میانگین در این حوزه است. با وجود یکسان بودن نتایج شبکه عصبی با روش ضریب شباهت و خوشه‌بندی آرایش رتبه‌ای و برتری نسبت به تحلیل خوشه‌ای K میانگین، به دلایلی چند، نحوه استفاده از شبکه‌های عصبی در این پژوهش نسبت به سه روش دیگر برتری دارد. یکی از دلایل این است که در سه روش دیگر نقش عامل انسانی به‌طور کامل حذف شده است و در صورت بروز خطا در سیستم دسته‌بندی، امکان اصلاح

آن به صورت سیستماتیک که در آینده مجدداً تکرار نشود وجود ندارد؛ اما در الگوریتم ذکر شده برای استفاده از شبکه عصبی در صورت بروز خطای محسوس در دسته‌بندی می‌توان این مورد را اصلاح کرد و شبکه را براساس آن آموزش داد تا در آینده نیز مطابق آن عمل کند. دلیل دیگر این است که در روش استفاده از شبکه‌های عصبی به این دلیل که محاسبات و نتایج قبلی در حافظه شبکه حفظ می‌شود، با هرچه بیشتر شدن حجم قطعات به این دلیل که شبکه آموزش بیشتری می‌بیند، به تدریج دقت آن در تشخیص دسته‌بندی‌ها نیز بیشتر و خطا کمتر خواهد شد و اگر وزن و میزان اهمیت برخی خصوصیات قطعات برای گروه‌بندی آن‌ها بیشتر از اهمیت سایر خصوصیات باشد، این آیتیم در دو روش دیگر قابل اعمال نیست، اما در الگوریتم ارائه شده برای استفاده از شبکه عصبی می‌توان این موضوع را با تشکیل گروه‌های اولیه توسط عامل انسانی و با در نظر گرفتن وزن‌های اهمیت خصوصیات به شبکه آموزش داد.

در رویکرد به کار گرفته شده در این پژوهش، از شبکه عصبی تابع شعاع‌مدار (RBF) استفاده کرده‌ایم که الگوریتم یادگیری آن از نوع نظارت‌شده یا باناظر است. با توجه به توسعه‌های زیادی که در سال‌های اخیر در حوزه شبکه‌های عصبی ایجاد شده است، پیشنهاد می‌کنیم که در مطالعات آتی همین الگوریتم با کمک سایر شبکه‌های عصبی از نوع نظارت‌شده مورد استفاده قرار گیرد و نتایج آن با خروجی گروه‌بندی قطعات بدون استفاده از این الگوریتم و توسط شبکه‌های عصبی نظارت‌نشده یا بدون ناظر که به آن‌ها شبکه‌های عصبی خودسازمان‌دهنده نیز گفته می‌شود (از جمله^۱ SOM و کوهنن^۲) مقایسه شود. برای این کار می‌توان از نرم‌افزار Matlab یا سایر نرم‌افزارهای تخصصی در این حوزه استفاده کرد.

1. Self Organizing Map
2. Kohonen

منابع

۱. پویا، علیرضا؛ و کرمانشاهیان، یونس (۱۳۹۱). انبارش و جانمایی اقلام انبار با استفاده از فناوری گروهی و به کارگیری الگوریتم ابتکاری. *چشم/انداز مدیریت صنعتی*، ش ۶، صص ۱۰۹-۱۲۸.
۲. ماکویی، فاطمه؛ میرجلیلی، فرزانه؛ هادی زاده، محسن؛ و پیوندی، پدram (۱۳۹۱). کاربرد شبکه عصبی خودسازمان دهنده براساس داده‌کاوی برای ایجاد جدول اندازه لباس. *علوم و فناوری نساجی*، ش ۲، صص ۹۷-۱۰۳.
۳. محمدی قرمزگلی، خسرو؛ وصالی، فرشاد؛ فعله‌گری، رضا؛ و غفاری، حسین (۱۳۹۰). جداسازی پوسته از مغز گردو و دسته‌بندی مغز براساس رنگ با استفاده از گشتاورهای تغییرناپذیر تصویر، شبکه عصبی مصنوعی و روش آنالیز تشخیصی. *پژوهش‌های صنایع غذایی*. ش ۳ (جلد ۲۱)، صص ۳۰۵-۳۱۵.
۴. ناظمی، شمس‌الدین؛ شمس‌الدینی، رضا؛ و خورسندی اکبرنژاد، محمد حسین (۱۳۹۰). ارائه مدلی برای طبقه‌بندی اقلام مواد و موجودی‌ها با استفاده از روش ABC-Fuzzy. *چشم/انداز مدیریت صنعتی*، ش ۳، صص ۸۳-۹۸.
5. Awwal, A.S., & Karim, M.A. (1989). Machine Parts Recognition Using a Trinary Associative Memory. *Optical Engineering*, 28(5), 537-543.
6. Ballakur, A., & Steudel, H.J. (1987). A Within-Cell Utilization Based Heuristic for Designing Cellular Manufacturing Systems. *International Journal of Production Research*, 25(5), 639-665.
7. Burbidge, J. L. (1971). Production Flow Analysis. *Production Engineering*, 50(4.5), 139-152.
8. Burbidge, J. L. (1977). A Manual Method of Production Flow Analysis. *Production Engineering*, 56(10), 34-38.
9. Carrie, A.S. (1973). Numerical Taxonomy Applied to Group Technology and Plant Layout. *International Journal of Production Research*, 11(4), 399-416.
10. Chan, H.M., & Milner, D.A. (1982). Direct Clustering Algorithm for Group Formation in Cellular Manufacture. *Journal of Manufacturing Systems*, 1(1), 65-75.
11. Chandrasekharan, M.P., & Rajagopalan, R. (1987). ZODIAC—An Algorithm for Concurrent Formation of Part-Families and Machine-Cells. *International Journal of Production Research*, 25(6), 835-850.
12. Chung, Y., & Kusiak, A. (1994). Grouping Parts with a Neural Network. *Journal of Manufacturing Systems*, 13(4), 262-275.
13. Gower, J.C. (1971). A General Coefficient of Similarity and Some of its Properties. *Biometrics*, 27(12), 857-871.
14. Haileyesus, Y. (2002). Group technology based classification and coding system. (Masters of Science dissertation). Addis Ababa University, Addis Ababa.
15. Hyer, N. L., & Wemmerlov, U. (1984). Group Technology and Productivity. *Harvard Business Review*, July-August, pp. 140-149.
16. Kamarthi, S.V., Kumara, S.R.T., Yu, F.T.S., & Ham, I. (1990). Neural Networks and Their Application in Component Design Data Retrieval. *Journal of Intelligent Manufacturing*, 1(2), 125-140.
17. Kao, Y., & Moon, Y. B. (1991). A unified group technology implementation using the back propagation learning rule of neural networks. *Computers and Engng*, 20(4), 425-437.

18. Kaparathi, S., &Suresh, N.C. (1991). A Neural Network System for Shape-Based Classification and Coding of Rotational Parts.*International Journal of Production Research*, 29(9), 1771 - 1784
19. King, J.R. (1980). Machine Component Grouping in Production Flow Analysis: An Approach Using Rank Order Clustering. *International Journal of Production Research*, 18(2), 213-232.
20. McAuley, J. (1972). Machine Grouping for Efficient Production. *Production Engineering*, 51(2), 53-57.
21. McClelland, J. L., &Rumelhart, D. E. (1988). Explorations in Parallel Distributed Processing: A Handbook of Models, Programs, and Exercises. New York: MIT Press.
22. McCormick, W.T., Schweitzer, P.J., &White, T.W. (1972). Problem Decomposition and Data Reorganization by a Clustering Technique.*Operations Research*, 22(5), 993-1009.
23. Moon, Y.B., &Chi, S.C. (1992). Generalized Part Family Formation Using Neural Network Techniques. *Journal of Manufacturing Systems*, 11(3), 149-159.
24. Offodile, O.F. (1991). Application of Similarity Coefficient Method to Parts Coding and Classification Analysis in Group Technology.*Journal of Manufacturing Systems*, 10(6), 442-448.
25. Oliveira, S., Ribeiro, J.F.F., &Seok, S.C. (2008). A comparative study of similarity measures for manufacturing cell formation. *Journal of Manufacturing Systems*, 27, 19-25.
26. Pai, P.F., &Lee, E. S. (2001). Parts Clustering by Self-Organizing Map Neural Network in a Fuzzy Environment. PERGAMON. *Journal of Computers and Mathematics with Applications*, 42, 179-188.
27. Papaioannou, G., &Wilson, J. M. (2010). The evolution of cell formation problem methodologies based on recent studies. *European Journal of Operational Research*, 206, 509-521.
28. Rajagoplan, R., &Batra, J.L. (1975). Design of Cellular Production Systems--A Graph Theoretic Approach. *International Journal of Production Research*, 13, 567-79
29. Rumelhart, D. E., Hinton, G. E., &Williams, R. J. (1986). Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol. 1, Ch. 8, pp. 318-362. New York: MIT Press.
30. Sudhakara, R., &Mahapatra, S.S. (2009). Manufacturing cell formation with production data using neural networks. *Computers & Industrial Engineering*, 56, 1340-1347.
31. Unler, A., &Gungor, Z. (2009). Applying K-harmonic means clustering to the part-machine classification problem. *Expert Systems with Applications*, 36(2), 1179-1194.
32. Wu, M.C., &Jen, S.R. (1996). A neural network approach to the classification of 3D prismatic parts. *International Journal of Advanced Manufacturing Technology*, 11, 325-335.
33. Yang, M. S., &Yang, J. H. (2008). Machine-part cell formation in group technology using a modified ART1 method. *European Journal of Operational Research*, 188, 140-152.
34. Yina, Y., &Yasudab, K. (2006). Similarity coefficient methods applied to the cell formation problem: A taxonomy and review. *Int. J. Production Economics*, 101, 329-352