

پویاسازی خوشه‌بندی مشتریان با استفاده از روش DEA-DA در بستر شبکه عصبی مصنوعی SOM

علی بنیادی نائینی^{*}، سعید یوسفی^{**} محمدعلی فائزی راد^{***}

تاریخ دریافت: ۹۳/۱۱/۸ تاریخ پذیرش: ۹۴/۱۱/۲۶

چکیده

امروزه ارزیابی مشتریان برای ارائه خدمات مناسب یکی از مهم‌ترین چالش‌های مدیران و تصمیم‌گیرندگان در سازمانهای مختلف است. در سازمان‌های مختلف گاه با توجه به حجم سنگین تقاضای مشتریان پاسخ‌گویی به نیازهای تمامی آنان امکان‌پذیر نیست و از سوی دیگر این مشتریان به عنوان سرمایه‌های سازمانها قلمداد می‌شوند. این موضوع هدفمند نمودن مطالعه بر روی گروه‌های مختلف مشتریان در بازارهای رقابتی را با اهمیت کرده است. یکی از شیوه‌های کارآمد برای مطالعه مشتریان و ارائه خدمات بهینه به آنان، گروه‌بندی بازار و خوشه‌بندی مشتریان در آن است. در این پژوهش به منظور هدفمند نمودن ارائه خدمات به مشتریان، ابتدا به کمک تکنیک شبکه عصبی SOM مشتریان در خوشه‌هایی متناسب دسته‌بندی می‌شوند تا بتوان برای هر مشتری با توجه به خوشه آن به ارائه خدمات مناسب پرداخت. سپس با مدل ارائه داده شده در این مقاله می‌توان عضویت مشتری جدید در خوشه متناسب را با استفاده از تکنیک DEA-DA پیش‌بینی کرد. این مدل، فرآیند خوشه‌بندی پویا را برای سازمان رقم می‌زند تا به وسیله آن در هر لحظه بتوان مشتریان جدید را ارزیابی نموده و خوشه متناسب آنها را با دقت مناسبی تعیین کرد.

واژگان کلیدی:

خوشه‌بندی، صفحه متمایز کننده (DA)، تحلیل پوششی داده‌ها (DEA)، شبکه‌های عصبی مصنوعی، نگاشت خودسازمان‌ده (SOM)

* استادیار دانشکده مهندسی پیشرفت، دانشگاه علم و صنعت ایران (نویسنده مسئول) Bonyadi@iust.ac.ir

** کارشناسی ارشد مدیریت صنعتی، دانشگاه علامه طباطبائی

*** دانشجوی دکتری مدیریت تحقیق در عملیات، دانشگاه فردوسی مشهد

مقدمه

شرکت‌ها به صورت روز افزونی به این موضوع پی می‌برند که مشتریان مهم‌ترین دارایی آنها هستند. حفظ مشتریان موثرتر از تلاش برای به دست آوردن مشتریان جدید است؛ زیرا هزینه کسب مشتریان جدید پنج برابر بیشتر از حفظ مشتریان فعلی خواهد بود و این موضوع برای هر سازمانی قابل توجه است (فایفر، ۲۰۰۵). اولویت بندی و دسته‌بندی مشتریان در گروه‌های مختلف یک روش بهبود استراتژی بازاریابی و افزایش سهم بازار است (گارلند، ۲۰۰۵). یکی از گسترده‌ترین زمینه‌های کاربرد داده کاوی برای صنعت مختلف، مدیریت ارتباط با مشتری است. جهت مدیریت مؤثر ارتباط با مشتری، صنایع گوناگون می‌توانند با تجزیه و تحلیل پایگاه داده مشتریان و ارائه خدماتی که مشتریان واقعاً خواهان آن هستند، مبالغ قابل توجه‌ای را برای تبلیغات و ارائه خدمات صرفه‌جویی نمایند (تقوا و حسینی بامکان، ۱۳۹۰).

منابع یک شرکت باید به مشتریانی تخصیص داده شود که بیشترین سود را برای شرکت ایجاد می‌کنند. رسیدگی به تمام مشتریان عملی نیست و یا در صورت عملی بودن، هزینه‌ای به مراتب بیشتر از منافع را برای مؤسسه خواهد داشت؛ لذا مشتریان با سود کمتر می‌توانند نادیده گرفته شوند (ون رایجی، ۲۰۰۵). با خوشه‌بندی بازار می‌توان محصولات و خدمات ویژه را برای مشتریان هدف ارائه داد و به نیازهای بخشی از مشتریان توجه کرد که بیشترین سود را برای سازمان دارند. به طور کلی شرکت باید محصولات و یا خدمات ویژه‌ای برای مشتریان سودمند ارائه دهد تا اگر رقبای جدیدی وارد بازار شوند، این مشتریان به سازمان مربوطه وفادار بمانند (پلکویاناکاکی و سارن، ۲۰۰۶). به منظور درک ارزش مشتریان، هدف‌گیری سودمندترین مشتریان منجر به بالا رفتن بهره‌وری در ارتباطات مناسب با آنان خواهد شد. حفظ و تشویق این مشتریان به عنوان مهم‌ترین عامل در بازاریابی برای هر مؤسسه تلقی می‌شود (جوفانگک و کان یوآن، ۲۰۰۸).

به منظور درک بهتر موقعیت هر واحد تصمیم‌گیر جهت هدف‌گذاری، ارائه راهکارهای متناسب بهبود و بالا بردن بهره‌وری هر واحد تصمیم‌گیر با توجه فضای حاکم بر آن، پیشنهاد روشی جهت

خوشه‌بندی و سپس پیش‌بینی گروهی برای واحدهای جدید توسط مدل DEA-DA ارائه شده است (سویوشی و گوتو، ۲۰۱۲). چون و همکاران (۲۰۰۹) با ارزیابی مشتریان غیر قابل اطمینان به پیش‌بینی این دسته از مشتریان برای بانک‌ها پرداخته‌اند. در این مقاله از تکنیک‌های مختلفی برای پیش‌بینی این نوع از مشتریان استفاده می‌شود و در نهایت اعلام می‌گردد که تکنیک ANN و DEA-DA بهترین و نزدیک‌ترین جواب را در پیش‌بینی آینده داشته‌اند (چون‌تسای و همکاران، ۲۰۰۹).

از سوی دیگر شبکه‌های عصبی مصنوعی (ANN) به عنوان ابزاری کارآمد برای خوشه‌بندی محسوب می‌شوند و شبکه‌های عصبی SOM که شبکه‌های کوهن نیز نامیده می‌شوند، ابزار مناسبی برای تحلیل داده‌های چندبعدی و خوشه‌بندی آنها هستند (قاسمی‌نژاد و کرمی، ۲۰۱۱). تحلیل خوشه‌ای سنتی هنوز کاربردهای متعددی در عمل دارد اما یک شبکه عصبی خودسازمان‌ده (SOM) برتری‌های ویژه‌ای نسبت به خوشه‌بندی سنتی دارد (مازانک، ۱۹۹۲). در این پژوهش ابتدا به کمک تکنیک شبکه عصبی SOM اقدام به خوشه‌بندی مشتریان می‌شود. در این خوشه‌بندی، مشتریان با توجه به معیارهای ارائه شده در خوشه‌های مناسب قرار می‌گیرند و عملاً این خوشه دارای اعضایی هستند که بیشتری تناسب را با یکدیگر دارند و دارای بیشترین تفکیک با اعضای خوشه‌های دیگر خواهند بود. این قسمت مرحله اول از ارزیابی مشتریان است.

در DA از قبل می‌دانیم که کدام مشتری به کدام گروه تعلق دارد و به دنبال مجموعه‌ای از اوزان عوامل به حد آستانه هستیم که بهترین تفکیک گروه را ایجاد نماید. اوزان و حد آستانه منتج که تعریف کننده ابر صفحه‌ای است که سعی می‌کند گروه‌ها را از هم تفکیک کند، به منظور پیش‌بینی عضویت گروهی مشتریان جدید استفاده می‌شود (سویوشی و گوتو، ۲۰۱۲)؛ در حالی که DEA مشتریان را به دو گروه ناکارا و کارا تقسیم می‌کند. در DEA از قبل نمی‌دانیم که کدام مشتریان به چه گروهی تعلق دارند، اما در حد آستانه که ۲ گروه را از هم تفکیک می‌کند گروه‌ها مشخص است؛ که عبارتند از عدد ۱ که کارا می‌باشد و ۰ که ناکارا است. مجموعه‌ای از اوزان و عوامل که تشکیل ابر صفحه را می‌دهند برای هر مشتری تشکیل

می‌شوند که هدف آن طبقه‌بندی واحدهای تصمیم است. از این رو گروهی از ابر صفحه‌ها به دست می‌آیند که مرز کارایی منکسر را تشکیل می‌دهند. با به دست آوردن حدود آستانه در تفکیک خوشه‌ها می‌توان به پیش‌بینی عضویت خوشه مشتریان جدید پرداخت به صورتی که مقادیر اوزان هر معیار می‌تواند میزان مشتری جدید را مشخص کند و با توجه به حدود آستانه در خوشه‌های متفاوت، خوشه متناسب هر مشتری را پیش‌بینی نمود.

در ادامه، در بخش دوم این مقاله، ادبیات و پیشینه پژوهش پیرامون DEA و کاربرد آن در ارزیابی مشتریان و همچنین کلیاتی درباره DEA-DA و شبکه‌های عصبی مصنوعی ارائه می‌شود. در بخش سوم، مدل‌سازی کمی مقاله و گام‌های ارائه شده در این پژوهش بررسی می‌شوند. در بخش بعدی، یک مثال عددی با ذکر جزئیات حل و بررسی آنها می‌آید و در بخش آخر نیز نتیجه‌گیری و ارائه پیشنهادها برای تکمیل این پژوهش ارائه می‌گردد.

ادبیات و پیشینه پژوهش

تحلیل پوششی داده‌ها (DEA) در ارزیابی مشتریان

یکی از تکنیک‌های مطرح در ارزیابی مشتریان، تکنیک تحلیل پوششی داده‌ها (DEA) است. تحلیل پوششی داده‌ها برای اولین بار در سال ۱۹۷۸ توسط چارلز و همکاران ارائه داده می‌شود. این تکنیک توان ارزیابی نسبی واحدهای تصمیم را بر مبنای مقایسات زوجی دارد؛ به این صورت که به ارائه کارایی نسبی واحدهای تصمیم بر مبنای نسبت موزون خروجی به ورودی‌های موزون می‌پردازد. روش کلاسیک DEA، توان رتبه‌بندی واحدهای تصمیم را ندارد و از این رو، در ۱۹۹۳ اندرسون و پترسون مدلی ارائه می‌دهند که به وسیله آن می‌توان به رتبه‌بندی واحدهای تصمیم پرداخت. این مدل‌ها مبنای مدل‌های ابر کارایی را ایجاد می‌کند. لی و همکاران (۲۰۱۲) مدل ابر کارایی را ارائه می‌دهند که می‌تواند بر مبنای مقادیر صفر در ورودی به رتبه‌بندی مشتریان پردازد. در مدل‌هایی که پیش از این در رویکرد ابر کارایی

تحلیل پوششی داده‌ها ارائه شده بودند، در صورتی که یکی از واحدهای تصمیم‌دارای مقدار صفر در یکی از ورودی‌ها باشد، تکنیک ابر‌کارایی توان رتبه‌بندی آن واحدها را ندارد؛ بنابراین لی و همکاران مدلی ارائه می‌دهند که توان رتبه‌بندی را برای این مدلها ایجاد می‌کند (لی و ژو، ۲۰۱۲).

از جمله رویکردهای دیگری که برای رتبه‌بندی واحدهای تصمیم‌دارای در تحلیل پوششی داده‌ها مورد استفاده قرار می‌گیرد تکنیک رتبه‌بندی بر مبنای کارایی متقاطع می‌باشد. نوری زاده و همکاران (۲۰۱۳) با استفاده از تکنیک کارایی متقاطع در تحلیل پوششی داده‌ها به رتبه‌بندی مشتریان می‌پردازند. در این مدل، بر مبنای آن می‌توان مقادیر صفر و یا دارای نسبت را در محاسبات مورد استفاده قرار داد. در این مدل همچنین محدودیتی ارائه می‌شود که در حالت بازدهی نسبت به مقیاس متغیر، به تابع هدف اجازه داده نمی‌شود که کارایی را منفی معرفی کند (نوری زاده و همکاران، ۲۰۱۳).

یکی دیگر از کاربردهای تحلیل پوششی داده‌ها ارزیابی واحدهای تصمیم‌دارای در چندین دوره زمانی می‌باشد. در این رویکرد واحدهای تصمیم‌دارای در چند دوره زمانی متناوب مورد ارزیابی قرار می‌گیرند. تن و همکاران (۲۰۱۴) به ارزیابی واحدهای تصمیم‌طی چند دوره زمانی به صورت شبکه‌ای پرداخته‌اند. کومار و همکاران (۲۰۱۴) با استفاده از تکنیک‌های ارزیابی چند معیاره به انتخاب تأمین‌کنندگان پرداخته و با استفاده از رویکرد ابر‌کارایی تحلیل پوششی داده‌ها بهترین رتبه‌بندی را صورت داده‌اند. یوسفی و همکاران (۲۰۱۴) با استفاده از مدل شبکه‌ای به ایجاد واحد تصمیم‌ایده‌آل پرداخته‌اند. در پژوهش مذکور، با استفاده از رویکرد واحد تصمیم‌ایده‌آل به ارزیابی و ارائه راهکار بهبود برای سایر واحدهای تصمیم‌پرداخته شده است. همچنین در پژوهش دیگری با استفاده از مدل ارائه شده تحلیل پوششی داده‌ها و ترکیب این مدل با رویکرد برنامه‌ریزی آرمانی به ارائه راهکار بهبود به صورت شبکه‌ای پرداخته شده و در آن واحدهای تصمیم‌دارای به صورت شبکه‌ای در نظر گرفته شده و برای هر یک از زیربخش‌ها به ارائه راهکار بهبود بر مبنای نظر خبرگان پرداخته شده است (یوسفی، شعبان‌پور و فرضی‌پور صائن، ۲۰۱۵).

ضرورت خوشه‌بندی مشتریان

به منظور ارزیابی مشتریان، تکنیک‌های متنوعی بر مبنای ارزیابی چند هدفه ارائه داده می‌شود. از آن جمله می‌توان به روش‌های تصمیم‌گیری چندشاخصه (MADM) اشاره نمود. در غالب این تکنیک‌ها بدون توجه به تشابهاتی که مشتریان دارند تنها به رتبه‌بندی آنها پرداخته می‌شود، حال آن‌که گاه نیاز است مشتریان در دسته‌های متناسب قرار گیرند تا بتوان برای ارائه خدمات مناسب برای گروه‌های آنان تصمیم‌گیری شود؛ چرا که نیاز است برخی از خدمات برای پایین آمدن هزینه‌ها به صورت گروهی برای واحدهای تصمیم‌ارائه شود. در رتبه‌بندی واحدهای تصمیم‌نمی‌توان تشخیص داد که چگونه می‌توان مشتریان را در خوشه‌های مناسب قرار داد. لذا برای مرتفع کردن این نقد، در پژوهش حاضر به خوشه‌بندی مشتریان بر مبنای یکی پرکاربردترین تکنیک‌های این حوزه اشاره می‌شود.

DEA-DA

سویوشی در سال ۱۹۹۹ نوع جدیدی از صفحه متمایزکننده ناپارامتریک را ارائه نمود که به کمک آن مجموعه‌ای از اوزان مربوط به توابع متمایزکننده خطی به دست می‌آید و در نتیجه با استفاده از آن شرایط واحدهای تصمیم‌جدید قابل پیش‌بینی خواهد بود. DA ناپارامتریک به نام DEA-DA ارائه گردید، زیرا با حفظ قابلیت متمایزکنندگی، ویژگی ناپارامتریک DEA را در DA تلفیق کرد (سویوشی، ۱۹۹۹). در صورتی که در این مدل از داده‌های منفی استفاده شود، این مدل توان ارائه پاسخ را نخواهد داشت. برای رفع این مشکل، سویوشی در سال ۲۰۰۱ مدل دیگر با نام E-DEA-DA ارائه داد که بتواند داده‌های منفی را نیز در ارزیابی مورد استفاده قرار داد (سویوشی، ۲۰۰۱). این مدل نیز دارای ایراد قابل توجهی بود. در این تکنیک، کمینه‌سازی تعداد مشاهداتی که به غلط طبقه‌بندی می‌گردید و به عنوان معیار طبقه‌بندی DA استفاده می‌شد، صورت نمی‌گرفت و لذا شکافی بین E-DEA-DA و اندازه‌گیری عملکرد آن وجود دارد. به منظور قابلیت متمایزکننده، سویوشی در سال ۲۰۰۴ با

استفاده از برنامه‌ریزی عدد صحیح مختلط مدلی را ارائه می‌دهد که در آن به دنبال حداقل سازی طبقه‌بندی نادرست، است (سویوشی، ۲۰۰۴). در سال ۲۰۱۲ سویوشی و گوتو با استفاده از تکنیک DEA-DA بهینه‌سازی شده به ارزیابی نیروگاه‌های سوخت فسیلی ژاپن می‌پردازند. در این مدل‌ها بر مبنای خروجی‌های نامطلوب مانند خروجی دی‌اکسید کربن نیروگاه‌ها به ارزیابی نیروگاه‌ها پرداخته می‌شوند. در این سال، طی چندین مقاله توان رتبه‌بندی را برای تکنیک DEA-DA ارائه می‌دهند که به کمک صفحه متمایز کننده می‌تواند واحدهای تصمیم را رتبه‌بندی کنند (سویوشی و گوتو، ۲۰۱۲). سویوشی و گوتو در مقاله دیگری با استفاده از این تکنیک به ارزیابی تاثیر تحقیق و توسعه در دو بخش الکترونیک و تکنولوژی ژاپن پرداخته‌اند. مدل ارائه شده در این مقاله توان ارزیابی واحدهای تصمیم را بر مبنای نسبت آماری توین کیو دارد. در این نسبت توان ارزیابی واحدهای تصمیم دارای مقادیر نسبی در معیارهای مختلف را برای تکنیک DEA-DA ایجاد کرده است (سویوشی و گوتو، ۲۰۱۳).

شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANN) تقلیدی از فرآیند یادگیری در مغز انسان است. مؤلفه اساسی در پردازش یک شبکه عصبی، نرون‌ها هستند که ورودی‌ها را دریافت کرده و با استفاده از عملیات غیرخطی بر روی آنها، خروجی‌ها را تولید می‌کنند (گودرزی و همکاران، ۲۰۱۴). یکی از مهم‌ترین فرآورده‌های شبکه عصبی مصنوعی، تحلیل خوشه‌ای و خوشه‌بندی با منطق تحت آن است که الگوریتم رایج شبکه‌های عصبی مصنوعی در این حوزه، تکنیک نگاشت خودسازمان‌ده (SOM) نام دارد (اشتهداردیان و فاضلی راد، ۱۳۹۳). این شبکه‌ها که با نام شبکه‌های عصبی کوهنن (Kohonen) نیز شناخته می‌شوند، دارای خاصیت ویژه‌ای برای ایجاد فضایی سازمان‌یافته از بردارهای ورودی بر اساس ویژگی‌های مختلف آنها می‌باشند؛ به طوری که پاسخ‌هایی استوار را حاصل نماید (وانگ و همکاران، ۲۰۱۳).

SOM به طور معمول، متشکل از یک یا دو لایه نرون‌های ورودی و خروجی است (تیسان و کیرستیا، ۲۰۱۳). لایه خروجی شبکه، به لایه رقابتی نیز مشهور است؛ چراکه نقش رقابتی شبکه طی فرآیند آموزش، در این لایه صورت می‌گیرد. لایه رقابتی، یک صفحه دو بُعدی است که با m نرون ساختاردهی شده است در حالی که لایه ورودی n نرون را در خود جای می‌دهد. هر نرون لایه ورودی با مقادیر وزنی مختلف به نرون‌های لایه رقابتی متصل می‌شوند و همچنین یک سری اتصالات جزئی بین نرون‌های لایه‌های رقابتی برقرار است (وانگ و همکاران، ۲۰۱۳).

در مدل این پژوهش، با استفاده از تکنیک DEA-DA به پیش‌بینی عضویت واحد تصمیم جدید در خوشه مشابه پرداخته می‌شود. تکنیک ارائه شده به سادگی با ارائه اوزان برای معیارهای مورد بررسی و همچنین مشخص کردن آستانه عضویت در هر یک از خوشه‌ها به پیش‌بینی این موضوع می‌پردازد که هر واحد تصمیم که دارای مقدار مشخصی از پارامترهای ارزیابی است در کدام خوشه قرار می‌گیرد. با استفاده از این تکنیک دیگر نیازی به آن نیست که داده‌ها به وسیله شبکه عصبی مصنوعی به صورت مجدد خوشه‌بندی شوند. در انتها به وسیله خوشه‌بندی شبکه عصبی مصنوعی اعتبار مدل ارائه شده مورد سنجش و تایید واقع شده است.

مدل ارائه شده

در این پژوهش با گسترش مدل DEA-DA اقدام به ارائه مدلی می‌شود که توان پیش‌بینی عضویت مشتریان را در خوشه متناسب داشته باشد. به منظور ساده‌سازی ارائه، مدل مذکور در قالب پیش‌فرض چهار خوشه ارائه شده است و به صورتی گسترش داده شده که توان تفکیک بین چهار خوشه برای آن ایجاد شود. همان‌گونه که در مدل نیز مشخص است می‌توان با ایجاد محدودیت‌ها و قیود جدید تعداد خوشه‌ها را بیشتر نیز در نظر گرفت و یا اگر نیاز باشد با حذف محدودیت‌های مربوطه، تعداد خوشه‌ها را

کاهش داد. از این روی، چالش تعداد خوشه‌ها در این پژوهش محل بحث نبوده و با هر تعدادی می‌توان مدل مورد نظر را ارائه نمود.

نوآوری پژوهش به طور خلاصه در عناوین زیر خلاصه می‌شود:

• ارائه سیاست‌های بازاریابی برای مشتریان بر مبنای قرارگیری آنان در خوشه‌های

مختلف

• خوشه‌بندی مشتریان بر مبنای تکنیک شبکه عصبی مصنوعی

• ارائه مدل پیش‌بینی DEA-DA برای عضویت در چهار خوشه

نکته قابل توجه این است که اساساً در این مقاله تحلیل پوششی داده‌ها به خوشه‌بندی نمی‌پردازد، بلکه در فرآیند پیش‌بینی تأثیرگذار است. مدل ارائه شده می‌تواند پیش‌بینی کند که واحد تصمیم تازه‌وارد در کدام خوشه قرار خواهد گرفت.

در ابتدا، شبکه عصبی خوشه‌بندی مناسب را انجام می‌دهد، سپس مدل ارائه شده که ترکیبی است از «برصفحه‌های متمایز کننده» و «تحلیل پوششی داده‌ها» توان تشخیص الگوی خوشه‌بندی را دارد؛ به گونه‌ای که با مشخص شدن مقادیر ابرصفحه‌های متمایز کننده در مقایسات زوجی می‌توان پیش‌بینی کند که واحد تصمیم جدید در کدام خوشه قرار خواهد گرفت.

مدل‌سازی کمی

یک مسأله خوشه‌بندی را در نظر بگیرید که در آن $g = 1, 2, \dots, h$ گروه وجود دارند که مجموع مشتریان عضو این h گروه، کل n مشتری را تشکیل می‌دهند که با $j = 1, 2, \dots, n$ نمایش داده می‌شود. با توجه به این که چند خوشه مد نظر است که هر مشتری توسط k عامل مستقل ($i = 1, 2, \dots, k$) تعریف می‌گردد که با Z_{ij} نشان داده می‌شود.

روش DEA-DA نیاز دارد که از قبل، عضویت هر مشتری به هر گروه مشخص باشد. که با استفاده از روش شبکه عصبی SOM نگرانی‌ئی در این خصوص وجود ندارد و مشتریان از

قبل با استفاده از این روش به تعداد خوشه‌های مد نظر تخصیص داده می‌شوند. مدل تعریف شده برای چهار خوشه در زیر ارائه شده است که قابلیت تعمیم به تعداد گروه‌های بیشتری را نیز دارد. لذا مدل زیر برای چهار خوشه به صورت زیر تعریف می‌شود.

$$\min \sum_{j \in G_1} y_j + \sum_{j \in G_2} y_j + \sum_{j \in G_3} y_j + \sum_{j \in G_4} y_j \quad (۱)$$

Subject to:

$$\sum_{i=1}^k (\lambda_i^+ - \lambda_i^-) z_{ij} - c_1 + My_j \geq 0, \quad j \in G_1 \quad (۲)$$

$$\sum_{i=1}^k (\lambda_i^+ - \lambda_i^-) z_{ij} - c_2 + My_j \geq 0, \quad j \in G_2 \quad (۳)$$

$$\sum_{i=1}^k (\lambda_i^+ - \lambda_i^-) z_{ij} - c_3 + My_j \geq 0, \quad j \in G_3 \quad (۴)$$

$$\sum_{i=1}^k (\lambda_i^+ - \lambda_i^-) z_{ij} - c_4 + My_j \geq 0, \quad j \in G_4 \quad (۵)$$

$$\sum_{i=1}^k (\lambda_i^+ - \lambda_i^-) z_{ij} - c_1 - My_j \leq -\varepsilon, \quad j \in G_1 \quad (۶)$$

$$\sum_{i=1}^k (\lambda_i^+ - \lambda_i^-) z_{ij} - c_2 - My_j \leq -\varepsilon, \quad j \in G_2 \quad (۷)$$

$$\sum_{i=1}^k (\lambda_i^+ - \lambda_i^-) z_{ij} - c_3 - My_j \leq -\varepsilon, \quad j \in G_3 \quad (۸)$$

$$\sum_{i=1}^k (\lambda_i^+ + \lambda_i^-) = 1 \quad (۹)$$

$$\xi_i^+ \geq \lambda_i^+ \geq \varepsilon \xi_i^+, \quad i = 1, 2, \dots, k \quad (۱۰)$$

$$\xi_i^- \geq \lambda_i^- \geq \varepsilon \xi_i^-, \quad i = 1, 2, \dots, k \quad (۱۱)$$

$$\xi_i^+ + \xi_i^- \leq 1, \quad i = 1, 2, \dots, k \quad (12)$$

$$\sum_{i=1}^k (\xi_i^+ + \xi_i^-) = k \quad (13)$$

$$c_1 \geq c_2 + \varepsilon \quad (14)$$

$$c_2 \geq c_3 + \varepsilon \quad (15)$$

$$\xi_i, \xi_i, y_j = 0 \text{ or } 1 \quad (16)$$

$$\lambda_i^+ \geq 0, \quad i = 1, 2, \dots, k \quad (17)$$

$$\lambda_i^- \geq 0, \quad i = 1, 2, \dots, k \quad (18)$$

در مدل ارائه شده، روابط ۲ تا ۸ دارای M هستند که عدد بزرگی را نشان می‌دهد اما بی‌نهایت نیست و در این مقاله آن را ۱۰۰۰۰ در نظر گرفته‌ایم. در روابط ۱۰، ۱۱، ۱۴ و ۱۵ نیز ε را داریم که عددی کوچک است و به این منظور استفاده می‌شود که واحد و یا واحدها روی تابع متمایزکننده قرار نگیرند؛ در این پژوهش مقدار آن ۰/۰۰۰۵ در نظر گرفته شده است. تابع هدف در رابطه ۱ به منظور حداقل‌سازی تعداد کل واحدهایی است که به غلط طبقه‌بندی شده‌اند؛ که این کار با معرفی متغیرهای صفر و یک y_j انجام می‌شود.

مدل فوق سه مقدار متمایزکننده C₁, C₂, C₃ را در خود جای داده است. اولین مقدار متمایزکننده (C₁) جهت تفکیک گروه ۱ (G₁) و گروه ۲ (G₂) استفاده می‌شود. دومین مقدار متمایزکننده (C₂) جهت تفکیک گروه ۲ (G₂) و گروه ۳ (G₃) استفاده می‌شود و در نهایت مقدار متمایزکننده سوم (C₃) جهت تفکیک گروه ۳ (G₃) و گروه ۴ (G₄) استفاده می‌شود. این تفکیک در روابط ۲ تا ۸ با لحاظ کردن رابطه‌های ۱۴ و ۱۵ مشخص شده است.

در این مدل، رابطه ۹ محدودیت نرمالایزسازی است چراکه مدل فزاینده است. محدودیت‌های موجود در رابطه ۱۰ و ۱۱ نیز بیانگر کران‌های بالا و پایین برای λ_i⁻ و λ_i⁺ هستند. رابطه ۱۲ دلالت بر این دارد که مجموع متغیرهای ۰ و ۱ نباید بیش از ۱ گردد. این گروه از محدودیت‌ها از وقوع همزمان 0 ≤ λ_i⁻ و λ_i⁺ جلوگیری می‌نماید. جهت استفاده از تمامی اوزان محدودیت رابطه ۱۳ وارد مدل شده است.

باید توجه نمود که در هنگام حل مدل، لازم است که در جواب بهینه شرط $C_1^* > C_2^* > C_3^*$ برقرار باشد. جهت تضمین برقراری این رابطه محدودیت‌های نشان داده شده در رابطه ۱۴ و ۱۵ به مدل اضافه می‌شود. در مدل ارائه داده شده چهار گروه توسط C_1^*, C_2^*, C_3^* و $\lambda_i^* = \lambda_i^{+*} - \lambda_i^{-*}$ ($i = 1, \dots, k$) تفکیک می‌شوند. عضویت گروهی واحد جدید که دارای مشخصات $Z_r = (Z_{1r}, \dots, Z_{kr})^T$ است، توسط قواعد زیر پیش‌بینی می‌گردد:

الف) اگر $\sum_{i=1}^k \lambda_i^* z_{ir} \geq C_1^*$ باشد، آنگاه واحد جدید به گروه ۱ (G_1) تعلق دارد.

ب) اگر $C_1^* - \varepsilon \geq \sum_{i=1}^k \lambda_i^* z_{ir} \leq C_2^*$ باشد، آنگاه واحد جدید به گروه ۲ (G_2) تعلق دارد.

ج) اگر $C_2^* - \varepsilon \geq \sum_{i=1}^k \lambda_i^* z_{ir} \leq C_3^*$ باشد، آنگاه واحد جدید به گروه ۳ (G_3) تعلق دارد.

د) اگر $C_3^* - \varepsilon \geq \sum_{i=1}^k \lambda_i^* z_{ir}$ باشد، آنگاه مشتری جدید به گروه ۴ (G_4) تعلق دارد.

همان‌طور که در بالا ذکر شد، محدودیت $\xi_i^- \geq \lambda_i^- \geq \varepsilon \xi_i^-$ و $\xi_i^+ \geq \lambda_i^+ \geq \varepsilon \xi_i^+$ بیان‌گر کران‌های بالا و پایین λ_i^+ و λ_i^- است. در محدودیت $\xi_i^- + \xi_i^+ \leq 1$ نشان داده است که مجموع این متغیرهای صفر یا یک، کوچکتر مساوی ۱ است. حال اگر $0 \leq \lambda_i^+ \leq \varepsilon$ و $0 \leq \lambda_i^- \leq \varepsilon$ آنگاه $\sum_{i=1}^4 (\xi_i^+ + \xi_i^-) = 4$ خواهد بود و لذا جواب نشدنی می‌شود و از این رو مثبت شدن همزمان λ_i^+ و λ_i^- محال است.

سایر ترکیبات λ_i^+ و λ_i^- در عبارتهای $\xi_i^+ \geq \lambda_i^+ \geq \varepsilon \xi_i^+$ و $\xi_i^- \geq \lambda_i^- \geq \varepsilon \xi_i^-$ صدق می‌کند. برای غیر صفر شدن همزمان λ_i^+ و λ_i^- محدودیت ریاضی اشکالی ندارد اما سبب می‌شود که یک عامل که در خصوص آن اطلاعات جمع‌آوری کرده‌ایم کلاً از محاسبات حذف شود. تمامی واحدهای Z_{ij} توسط $\sum_{i=1}^k \lambda_i z_{ij}$ به یکدیگر متصل می‌شود که تشکیل تابع متمایز کننده را می‌دهد. λ_i برآورد وزن برای عامل i ام است و در واقع بیانگر اهمیت عامل i ام بر حسب توانایی آن در متمایز کردن می‌باشد. این

اوزان به نحوی تعیین می‌شوند که مجموع قدر مطلق λ_i ($i = 1, \dots, k$) برابر با ۱ است. این روش به این خاطر است که ممکن است مقادیر منفی در داده‌ها وجود داشته باشد؛ توجه کنید که جهت حل مدل DEA-DA مدل تبدیل شده‌ای است که در آن $\lambda_i^+ - \lambda_i^- = \lambda_i$ که $\lambda_i^+ = \frac{|\lambda_i| + \lambda_i}{2}$ و $\lambda_i^- = \frac{|\lambda_i| - \lambda_i}{2}$ به ترتیب بیان‌گر بخش مثبت و منفی آن هستند.

مدل کلی پژوهش

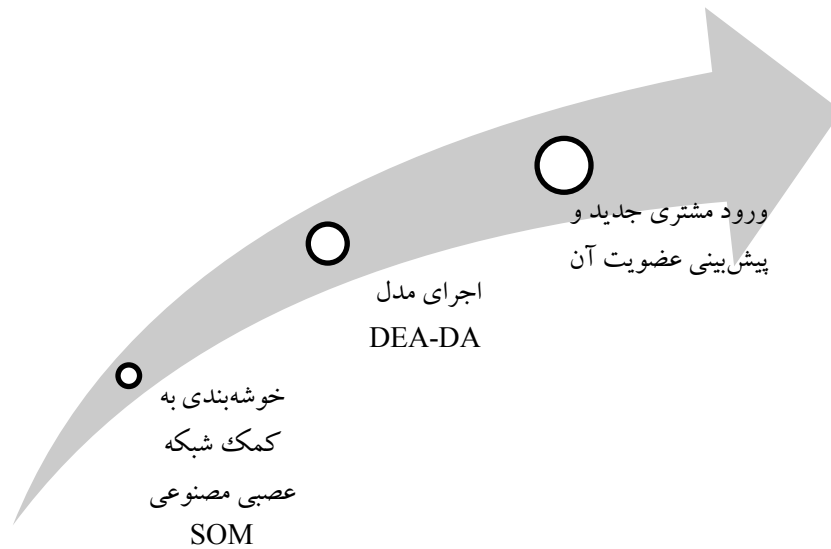
همان‌طور که در شکل (۱) مشخص است، به طور خلاصه برای ارزیابی واحدهای جدید گام‌های زیر طی می‌شود:

گام یکم: خوشه‌بندی با شبکه عصبی مصنوعی SOM. در این گام فرآیند خوشه‌بندی برای همه مشتریان انجام شده که در این پژوهش تعداد خوشه‌های موجود برابر با ۴ در نظر گرفته شده است. تعداد خوشه‌ها قابلیت افزایش یا کاهش را دارد و مدل گام دوم بر اساس هر تعدادی از خوشه‌ها انجام‌پذیر است.

گام دوم: اجرای مدل DEA-DA. پس از خوشه‌بندی مشتریان با اجرای مدل ارائه شده جهت پیدا کردن مقادیر بهینه λ_i^* و C_1^*, C_2^*, C_3^* که در آن $i = 1, \dots, k$ است، اقدام می‌شود.

گام سوم: پیش‌بینی عضویت مشتریان جدید. عضویت مشتریان جدید را می‌توان در گروه مناسب پیش‌بینی کرد. در این گام مقادیر بهینه λ_i^* و C_1^*, C_2^*, C_3^* در قواعد ذکر شده جهت پیش‌بینی واحد جدید در یک گروه استفاده می‌شود.

نمودار سه مرحله‌ای در شکل (۱)، رویه کلی این پژوهش را نشان می‌دهد:



شکل (۱): رویه کلی پژوهش

خوشه‌بندی باعث می‌شود واحدهایی که دارای شباهت زیادی به یکدیگر هستند در کنار یکدیگر در دسته مربوط به خود رتبه‌بندی شوند. در نهایت پیش‌بینی عضویت در هر خوشه کمک می‌کند تا بتوان متناسب با خوشه مدنظر برای آن مشتری خدمات مناسب‌تری ارائه شود. در قسمت تجزیه و تحلیل مثال عددی بیشتر به این موضوع خواهیم پرداخت.

مثال عددی

جهت تشریح روش پیشنهادی خوشه‌بندی مشتریان پیش‌بینی عضویت مشتری جدید در خوشه متناسب، مثال عددی زیر را در این قسمت ارائه می‌دهیم. شرکتی مفروض است که قصد دارد ۴۰ مشتری خود را ارزیابی و خوشه‌بندی کند. شرکت قصد دارد برای هر کدام از مشتریان خدمات ویژه‌ای را برقرار کند. در اولین مرحله با استفاده از تکنیک شبکه عصبی به خوشه‌بندی مشتریان می‌پردازیم. این خوشه‌بندی بر مبنای ۴ معیار

فراوانی خرید، حجم خرید، قدمت مشتری و اعتبار مالی شرکت انجام می‌شود. مقادیر مربوط به هر یک از شاخص‌ها برای هر یک از مشتریان در جدول (۱) گردآوری شده است.

جدول (۱): مقادیر شاخص‌های خوشه‌بندی برای مشتریان

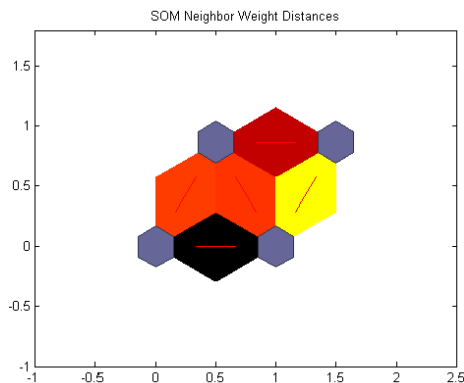
کد مشتری	اعتبار	فراوانی	حجم	سال
۱	۹	۳۰	۸۹,۰۰۰,۰۰۰	۹
۲	۵	۵	۳۲,۰۰۰,۰۰۰	۱
۳	۴	۳	۲۶,۰۰۰,۰۰۰	۱
۴	۸	۲۵	۵۹,۰۰۰,۰۰۰	۵
۵	۵	۶	۲۴,۰۰۰,۰۰۰	۱
۶	۶	۵	۲۷,۰۰۰,۰۰۰	۱
۷	۷	۳	۲۲,۰۰۰,۰۰۰	۱
۸	۵	۳	۲۹,۰۰۰,۰۰۰	۱
۹	۹	۳۳	۹۲,۰۰۰,۰۰۰	۸
۱۰	۳	۲	۳۱,۰۰۰,۰۰۰	۱
۱۱	۴	۵	۲۶,۰۰۰,۰۰۰	۲
۱۲	۶	۱	۱۵,۰۰۰,۰۰۰	۱
۱۳	۸	۲۴	۶۲,۰۰۰,۰۰۰	۴
۱۴	۴	۲	۱۹,۰۰۰,۰۰۰	۲
۱۵	۵	۲	۲۰,۰۰۰,۰۰۰	۲
۱۶	۵	۳	۲۱,۰۰۰,۰۰۰	۱
۱۷	۸	۲۴	۶۱,۰۰۰,۰۰۰	۵
۱۸	۳	۶	۲۴,۰۰۰,۰۰۰	۱
۱۹	۴	۵	۲۷,۰۰۰,۰۰۰	۲
۲۰	۶	۴	۲۶,۰۰۰,۰۰۰	۱
۲۱	۶	۳	۳۱,۰۰۰,۰۰۰	۱
۲۲	۴	۵	۳۳,۰۰۰,۰۰۰	۱

۲	۳۴,۰۰۰,۰۰۰	۴	۵	۲۳
۳	۲۱,۰۰۰,۰۰۰	۳	۵	۲۴
۱	۱۶,۰۰۰,۰۰۰	۳	۵	۲۵
۱	۱۲,۰۰۰,۰۰۰	۳	۶	۲۶
۶	۵۴,۰۰۰,۰۰۰	۲۷	۸	۲۷
۱	۹,۰۰۰,۰۰۰	۱	۱	۲۸
۹	۹۴,۰۰۰,۰۰۰	۳۳	۹	۲۹
۲	۱۹,۰۰۰,۰۰۰	۳	۵	۳۰
۶	۶۴,۰۰۰,۰۰۰	۲۴	۸	۳۱
۲	۲۴,۰۰۰,۰۰۰	۴	۳	۳۲
۱	۲۰,۰۰۰,۰۰۰	۵	۶	۳۳
۱	۲۸,۰۰۰,۰۰۰	۶	۵	۳۴
۵	۵۹,۰۰۰,۰۰۰	۲۷	۸	۳۵
۱	۳۱,۰۰۰,۰۰۰	۳	۳	۳۶
۲	۲۲,۰۰۰,۰۰۰	۳	۲	۳۷
۲	۱۹,۰۰۰,۰۰۰	۴	۶	۳۸
۲	۶,۰۰۰,۰۰۰	۱	۵	۳۹
۸	۹۱,۰۰۰,۰۰۰	۳۰	۹	۴۰

به منظور اجرای فرآیند خوشه‌بندی SOM در این پژوهش، از نرم‌افزار MATLAB (نسخه R2014a) استفاده شده است.

با ورود داده‌های مربوط به ۴۰ مشتری جدول (۱) و قرار دادن چهار شاخص فوق، عملاً ۴۰ بردار ورودی با چهار مؤلفه به شبکه SOM مورد نظر داده می‌شود. در اینجا، شبکه SOM با تعداد ۴ خوشه پیش‌فرض (یعنی با توپولوژی ۲ در ۲) و با توپولوژی شش‌ضلعی (Hexagonal) و تابع فاصله پیوندی (LinkDist) ساختاردهی شده است. با توجه به این موضوع، تعداد نرون‌های شبکه نیز برابر با ۴ خواهد بود. پس از اجرای شبکه، محل قرارگیری

مراکز خوشه‌ها و میزان فواصل بین آنها بر اساس شکل (۲) و جدول (۲) قابل اندازه‌گیری است. در شکل (۲)، نمودار فواصل بین نرون‌ها (خوشه‌ها) نمایان است که هرچه این فواصل تیره‌تر باشد، نشان‌گر بیشتر بودن فاصله است.



شکل (۲): نمودار فواصل همسایگی بین خوشه‌ها در SOM

جدول (۲) نیز خروجی هر خوشه را در قالب مرکز آن نمایان می‌کند. در این جدول، بردار مرکز هر خوشه با استفاده از دستور net.IW در MATLAB محاسبه شده که دارای چهار مؤلفه‌ی متناظر چهار شاخص مورد بررسی است.

جدول (۲): مراکز هریک از خوشه‌ها بر اساس چهار شاخص

خوشه ۱	خوشه ۲	خوشه ۳	خوشه ۴	
۹	۴/۵۳	۸	۴/۶۷	اعتبار
۳۱	۴/۴۷	۲۵/۱۷	۲/۵۸	فراوانی
۹۰,۶۶۶,۶۶۷	۲۸,۱۳۳,۳۳۳	۵۹,۸۳۳,۳۳۳	۱۶,۹۱۶,۶۶۷	حجم
۸/۳۳	۱/۲۷	۵/۱۷	۱/۶۷	سال

با توجه به آنکه مشتریان در این خوشه بندی به ۴ خوشه تقسیم شده است. حال می توان بر مبنای عضویت در هر خوشه به ارائه خدمات مناسب برای هر خوشه پرداخت. بر این مبنا بیشترین هزینه بازاریابی، ارائه خدماتی چون فروش اقساطی و بلند مدت و همچنین ارائه خدمات بیشتر باید برای خوشه های برتر ارائه شود. با توجه به آن که تعداد مشتریان عضو در خوشه برتر (خوشه شماره یکم) تعداد ۴ مشتری است و خوشه رتبه دوم (خوشه شماره سوم) نیز که مشتریان آن نیز نسبتاً سطح بالایی دارند نیز دارای ۶ عضو می باشد و سایر مشتریان که ۳۰ مشتری هستند در خوشه های ضعیف تر قرار گرفته اند. لازم به ذکر است که تحلیل پیرامون ضعف و قوت خوشه ها بر اساس داده های جدول (۲) ذکر شد. میزان عضویت هر خوشه در جدول شماره (۳) مشخص شده است.

جدول (۳): مشتریان عضو شده در هر خوشه

رتبه خوشه	کد مشتریان	خوشه
۱	۴۰، ۲۹، ۹، ۱	۱
۴	۳۵، ۳۱، ۲۷، ۱۷، ۱۳، ۴	۲
۲	۳۹، ۳۸، ۳۷، ۳۳، ۳۰، ۲۸، ۲۶، ۲۵، ۲۴، ۱۶، ۱۵، ۱۴، ۱۲، ۷	۳
۳	۳۶، ۳۴، ۳۲، ۲۳، ۲۲، ۲۱، ۲۰، ۱۹، ۱۸، ۱۱، ۱۰، ۸، ۶، ۵، ۳، ۲	۴

اکنون، به منظور پیش بینی خوشه ای که مشتری جدید در آن قرار می گیرد باید از قواعد پیشنهاد شده در بخش مدل سازی کمی استفاده شود. به این منظور، مقادیر بهینه λ_i, c_1, c_2, c_3 که در آن $i = 1, 2, 3, 4$ است را از مدل شماره (۱) به دست می آوریم. جهت حل این مدل، از نرم افزار Lingo استفاده شده است و مقادیر بهینه آن به صورت زیر گزارش می شوند:

$$\begin{aligned} \lambda_1 &= -0.0023, & \lambda_2 &= 0.0043, \\ \lambda_3 &= -0.6348, & \lambda_4 &= -0.3004 \\ c_1 &= 352,147.02, & c_2 &= 72,183.369, & c_3 &= 435,867 \end{aligned}$$

به عنوان مثال، مشتری جدید با مشخصات زیر درخواست همکاری با این شرکت را دارد. مدیر فروش یا بازاریابی می‌تواند برای ارائه خدمات به این مشتری، به پیش‌بینی عضویت او در خوشه مربوطه پردازد. مقادیر مربوط به ویژگی‌های این مشتری در جدول (۴) ارائه شده است.

جدول (۴): مقادیر شاخص‌ها برای مشتری جدید

سال	حجم	فراوانی	اعتبار	کد مشتری
۵	۵۲,۰۰۰,۰۰۰	۲۰	۶	مشتری جدید

با توجه به مقادیر لاندا و صفحه‌های متمایز کننده چهار خوشه، به پیش‌بینی عضویت این مشتری جدید پرداخته می‌شود.

$$\sum_{i=1}^4 \lambda_i z_{ir} = 223,585.4901$$

با توجه به این که نامساوی زیر برقرار است:

$$352,147.02 > 223,585.4901 > 72,183.369$$

لذا این مشتری در خوشه دوم قرار می‌گیرد و باید متناسب با سیاست‌هایی که برای مشتریان در این خوشه مد نظر است با این مشتری برخورد شود. در خوشه‌بندی که به وسیله شبکه عصبی مصنوعی - جهت تایید و اریابی مدل ارائه شده - صورت پذیرفته شد، این مشتری باز هم در خوشه شماره دوم قرار گرفته است.

نتیجه‌گیری و پیشنهادها

خوشه‌بندی به تصمیم‌گیرنده این اجازه را می‌دهد تا بتواند واحدهای مشابه که نیاز به سیاست‌ها مشابه را دارند، شناسایی کند. این امر به خصوص در زمان‌هایی که حجم مشتریان بسیار زیاد است، اهمیت می‌یابد. در این پژوهش، توانستیم مشتریانی که باید بیشترین توجه به آنها شود را شناسایی کنیم. هر بنگاه یا شرکت با توجه به این که می‌تواند مشتریان برتر خود را شناسایی کند، قادر است که خدمات خود را بر مبنای بخش‌بندی صحیحی در بازار روان نماید. همچنین با پیش‌بینی عضویت مشتری جدید از همان ابتدا تصمیم‌گیرنده می‌داند که

چگونه با این مشتری رفتار کند و برای آن با توجه به پیش‌بینی صورت گرفته مبنی بر این که در چه خوشه‌ای قرار دارد به ارائه خدمات و سیاست‌ها بازاریابی پردازد. این مدل قابل گسترش با خوشه‌های متفاوت می‌باشد. از آنجا که بر مبنای برخی پژوهش‌ها، شبکه‌های عصبی فازی روشی قدرتمند در پیش‌بینی پدیده‌هاست (میرغفوری و همکاران، ۱۳۹۲)، لذا به منظور گسترش این پژوهش، می‌توان با استفاده از شبکه‌های عصبی مصنوعی و تلفیق آن با منطق فازی یا بهینه‌سازی استوار به پیش‌بینی رفتار مشتریان پرداخت. این رهیافت، موجب اتخاذ رویکردی متناسب شرایط عدم قطعیت خواهد شد.

منابع

- اشتهاردیان، احسان‌اله؛ فائضی راد، محمدعلی (۱۳۹۳). به کارگیری شبکه عصبی مصنوعی برای قیمت گذاری شناور مجوز طرح ترافیک تهران جهت مدیریت بهینه شهر با هدف کاهش آلودگی هوا. مدیریت شهری، ۱۱(۳۶)، ۱۴۵-۱۵۴.
- تقوا، محمدرضا؛ حسینی بامکان، سیدمجتبی (۱۳۹۰). ارائه خدمات مناسب به مشتریان بالقوه با استفاده از تکنیک‌های داده کاوی در حوزه بانک‌داری الکترونیک. مطالعات مدیریت صنعتی، ۹(۲۳)، ۱۸۷-۲۰۷.
- میرغفوری، سیدحبيب‌اله؛ مروتی شریف‌آبادی، علی؛ اسدیان اردکانی، فائزه (۱۳۹۲). طراحی مدلی برای ارزیابی ریسک در زنجیره تأمین با رویکرد شبکه‌ی عصبی مصنوعی. مطالعات مدیریت صنعتی، ۱۱(۳۰)، ۱-۲۱.
- Andersen, P., Petersen, N.C., (1993). A procedure for ranking efficient units in data envelopment analysis, *Management Science*, 39(10), 1261-1264.
- Anderson, J., Narus, J. (2004). *Business Market Management: Understanding, Creating and Developing Value* (2nd ed). Prentice Hall, Englewood Cliffs, NJ.
- Charnes, A., Cooper, W.W., Rhodes, E. (1978). Measuring the efficiency of decision making units. *European Journal of Operational Research*, 33(1), 429-444.
- Chun Tsai, M., Ping Lin, S., Chan Cheng, C., Ping Lin, Y. (2009). The consumer loan default predicting model - An application of DEA-DA and neural network. *Expert Systems with Applications*, 36(4), 11682-11690.
- Garland, R. (2005). Segmenting retail banking customers. *Journal of Financial Services Marketing*, 10(2), 179-191.
- Ghaseminezhad, M.H., Karami, A. (2011). A novel self-organizing map (SOM) neural network for discrete groups of data clustering. *Applied Soft Computing*, 11(4), 3771-3778.

Godarzi, A.A., Madadi Amiri, R., Talaei, A., Jamasb, T. (2014). Predicting oil price movements: A dynamic Artificial Neural Network approach. *Energy Policy*, 68, 371-382.

Ju-Fang, C., Kun-Yuan, Y. (2008). Application of activity-based costing in customer profitability analysis. *Proceedings of International Seminar on Business and Information Management*, 1, 494-497.

Kumar, A., Jain, V., Kumar, S. A. (2014). A comprehensive environment friendly approach for supplier selection. *Omega*, 42(1), 109-23.

Lee, H.S., Zhu, J. (2012). Super efficiency infeasibility and zero data in DEA. *European Journal of Operational Research*, 216(10), 429-433.

Mazanec, J. (1992). Classifying Tourist into Market Segments: A Neural Network Approach. *Journal of Travel and Tourism Marketing*, 1, 39-59.

Noorizadeh, A., Mahdiloo, M. and Farzipoor Saen, R. (2013). Evaluating relative value of customers via data envelopment analysis. *Journal of Business & Industrial Marketing*, 28(7), 577-588.

Pfeifer, P. (2005). The optimal ratio of acquisition and retention costs. *Journal of Targeting, Measurement and Analysis for Marketing*, 13(2), 179-188.

Plakoyiannaki, E., Saren, M. (2006). Time and the customer relationship management process: conceptual and methodological insights. *Journal of Business & Industrial Marketing*, 24(4), 218-230.

Sueyoshi, T. (1999). DEA-discriminant analysis in the view of goal programming. *European Journal of Operational Research*, 115, 564-582.

Sueyoshi, T. (2001). Extended DEA-Discriminant Analysis. *European Journal of Operational Research*, 131(2), 324-351.

Sueyoshi, T. (2004). Mixed integer programming approach of extended DEA-discriminant analysis. *European Journal of Operational Research*, 152(1), 45-55.

Sueyoshi, T., Goto, M. (2012). DEA radial measurement for environmental assessment and planning: Desirable procedures to evaluate fossil fuel power plants. *Energy Policy*, 422-432.

Sueyoshi, T., Goto, M. (2012). Efficiency-based rank assessment for electric power industry: A combined use of Data Envelopment Analysis (DEA) and DEA-Discriminant Analysis (DA). *Energy Economics*, 634-644.

Sueyoshi, T., Goto, M. (2012). Returns to Scale and Damages to Scale with Strong Complementary Slackness Conditions in DEA Assessment: Japanese Corporate Effort on Environment Protection. *Energy Economics*, 1422-1434.

Sueyoshi, T., Goto, M. (2013). A use of DEA-DA to measure importance of R&D expenditure in Japanese information technology industry. *Decision Support Systems*, 54(2), 941-952.

Tisan, A., Cirstea, M. (2013). SOM neural network design - A new Simulink library based approach targeting FPGA implementation. *Mathematics and Computers in Simulation*, 91, 134-149.

Tone, K., Tsutsui, M., (2014). Dynamic DEA with network structure: A slacks-based measure approach, *Omega*, 42(1), 124-131.

Van Raaij, E.M. (2005). The strategic value of customer profitability analysis. *Marketing Intelligence & Planning*, 23(4), 372-381.

Wang, Z., Bian, S., Liu, Y., Liu, Z. (2013) The load characteristics classification and synthesis of substations in large area power grid. *International Journal of Electrical Power & Energy Systems*, 48, 71-82.

Yousefi, S., Shabanpour, H., Farzipoor Saen, R., Faramarzi, G. R. (2014). Making an ideal decision making unit using virtual network data envelopment analysis approach. *International Journal of Business Performance Management*, 15(4), 316-328.

Yousefi, S., Shabanpour, H., Farzipoor Saen, R. (2015). Selecting the best supply chain by goal programming and network data envelopment analysis. *RAIRO-Operations Research*, 49, 601-617.