



بیست و چهارمین

کنفرانس بین المللی شبکه‌های توزیع نیروی برق

درم آباد، ۲۰ و ۲۱ اردیبهشت ۱۳۹۸

24<sup>th</sup> Electrical Power Distribution Conference

تعیین سهم الگوهای مختلف مصرف از بار فیدر با استفاده از خوشه‌بندی سری‌های

زمانی

جواد زلقی

شرکت توزیع نیروی برق خوزستان، خوزستان، ایران  
javad.zalaqi@gmail.com

علیرضا حاتمی

استادیار گروه برق، دانشگاه بوعلی‌همدان، ایران  
hatamisharif@gmail.com

سعید هیبت اله پور

شرکت توزیع نیروی برق خوزستان، خوزستان، ایران  
sssf.1355@gmail.com

میثم ابول پور

شرکت توزیع نیروی برق خوزستان، خوزستان، ایران  
maysamabolpour@yahoo.com

چکیده

داده‌ها و الگوهای قابل استخراج از بین آنها، از مهمترین شاخص‌های دنیای اطلاعات هستند و داده‌کاوی یکی از پرکاربردترین روش‌هایی است که می‌تواند الگوهای مفید در داده‌ها را با حداقل دخالت کاربران شناسایی کند. خوشه‌بندی به عنوان یکی از روش‌های داده‌کاوی، مناسب ترین روش برای کار با داده‌ها و استخراج الگوهای موجود در آنها می‌باشد. امروزه با اندازگیری هوشمند، امکان پردازش غیرمتمرکز داده‌ها و نیز مخابرات وسیع برای تحویل اطلاعات به صورت آنی مهیا شده تا به وسیله تحلیل اطلاعات، انرژی مورد نیاز شبکه توزیع پیش‌بینی شود. در پژوهش حاضر، ابتدا کاربرد و روش‌های مختلف خوشه بندی در سری های زمانی مورد ارزیابی قرار خواهد گرفت و همچنین نحوه‌ی جمع آوری داده‌های مصرف کنندگان مورد بررسی قرار می‌گیرد تا با روش‌های مختلف و متنوعی که وجود دارد الگوی بار مشترکین مختلف با توجه به سوابق آنها در سیستم، استخراج گردد. یک روش بهینه‌ی خوشه‌بندی مطرح می‌شود و سپس با استفاده از شبکه عصبی MLP به تعیین سهم خوشه‌ها از بار فیدر می‌پردازد.

واژگان کلیدی: داده‌کاوی، خوشه‌بندی، فیدر، الگوهای بار، سری‌های زمانی.

**۱. مقدمه**

داده‌کاوی یکی از مهمترین این روش‌ها است که به وسیله آن الگوهای مفید در داده‌ها با حداقل دخالت کاربران شناخته می‌شوند و اطلاعاتی را در اختیار کاربران و تحلیلگران قرار می‌دهد تا براساس آنها تصمیمات مهم و حیاتی را اتخاذ کنند. داده‌کاوی به معنای استخراج دانش از حجم عظیم داده‌هاست و به عنوان مهمترین مرحله در فرایند کشف دانش معرفی شده است؛ به تعبیر دیگر داده-کاوی به عنوان فرایند کشف و استخراج الگوهای پنهان از حجم بالایی از داده‌ها تعریف می‌شود [۱-۳]. امروزه داده-کاوی یک گام اساسی در فرآیند کشف دانش در پایگاه‌های داده می‌دانند [۴]. استفاده روزافزون از داده‌های زمانی، به ویژه داده‌های سری زمانی، تلاش‌های مختلف تحقیق و توسعه در زمینه داده‌کاوی را آغاز کرده است.

خوشه‌بندی که یکی از روش‌های داده‌کاوی می‌باشد، از لحاظ فنی، یک یادگیری بدون ناظر است که شامل یافتن خوشه‌هایی است که حداکثر واریانس را با یکدیگر دارند، در حالی که گروه‌های زمان‌بندی شده در هر خوشه دارای حداقل واریانس با یکدیگر هستند [۵]. معمولاً تامین کنندگان بزرگ برق از خوشه‌بندی برای دسته‌بندی کردن مشتری‌هایی که دارای ویژگی‌های الکتریکی مشابه هستند استفاده می‌کند [۶].

این مقاله با مقایسه دو روش خوشه‌بندی  $k$ -means و SOM<sup>۱</sup> با استفاده از شاخص DB<sup>۲</sup> که نسبت فاصله بین خوشه‌ای (یعنی میانگین فاصله همه الگوهای در خوشه به مرکز خوشه) تقسیم بر فاصله بین خوشه‌ای (یعنی فاصله بین مراکز خوشه‌ای مختلف) بیان می‌کند به ارزیابی این روش‌ها برای دسته‌بندی مشترکین برق یک فیدر توزیع می‌پردازد و سهم خوشه‌ها مختلف مصرف را از بار فیدر با استفاده از شبکه عصبی MLP بدست می‌آورد.

**۲. خوشه‌بندی K-means**

K-means از یک فرایند تکرار استفاده می‌کند که مشتریان یا بارهای مصرفی را به گروه‌هایی براساس فاصله بین خود و مرکز خوشه اختصاص می‌دهد. در ابتدا، مراکز خوشه‌ای به صورت تصادفی در مجموعه داده‌های نمونه انتخاب می‌شوند. سپس فاصله بین مشتری نمونه و مراکز خوشه محاسبه می‌شود تا مشتریان یا بار مصرفی به هر خوشه با کمترین فاصله اختصاص داده شود. سپس مرکز خوشه براساس افزودن یک مشتری یا بار جدید دوباره محاسبه می‌شود.

معادله ۱ الگوریتم  $k$ -means را که مجموعه‌ای از مشاهدات  $x_1, x_2, \dots, x_n$  را ارائه می‌دهد، که در آن هر یک از مشاهدات یک بردار  $d$ -dimensional بعدی است. خوشه‌بندی  $k$ -means با هدف تقسیم‌بندی  $n$  مشاهدات به  $k \leq n$  مجموعه  $S = \{S_1, S_2, \dots, S_k\}$  است به طوری که مجموع مربع اختلاف از میانگین (یعنی واریانس) برای هر خوشه حداقل شود [۷]. بنابراین تعریف می‌شود:

$$J = \sum_{j=1}^k \sum_{n \in S_j} \|x_n - \mu_j\|^2 \quad (1)$$

**۳. شبکه‌های عصبی**

شبکه‌های عصبی مصنوعی، جزء دسته از سیستم‌های دینامیکی هستند که با پردازش داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. به همین خاطر به این سیستم‌ها، هوشمند می‌گویند؛ چرا که بر اساس محاسبات روی داده‌های عددی، قوانین کلی را فرا می‌گیرند. این سیستم‌های مبتنی بر هوش محاسباتی سعی در مدل‌سازی ساختار عصبی مغز دارند. شبکه‌های هوشمند عصبی که به عنوان یک انفجار بزرگ در طی چند دهه اخیر مطرح شده‌اند، بطور موفقیت‌آمیزی در حل محدوده بسیار وسیعی از مسائل کاربرد گسترش یافته‌اند. در واقع هر جا که مسأله برآورد،

<sup>1</sup> self-organizing map

<sup>2</sup> Davies-Bouldin



پیشگویی، طبقه بندی و یا کنترل لازم بوده، شبکه‌های عصبی به نوعی در آنجا مطرح شده‌اند [۸-۱۰].

شبکه‌های عصبی بطور معمول در صنعت برق برای پیش-بینی تقاضا مورد استفاده قرار می‌گیرند [۱۱]. یک عبارت ریاضی برای یک نورون تک ورودی در یک شبکه در معادله ۲ زیر نشان داده شده است که در آن سه عملیات متمایز عملیاتی در حال وقوع هستند [۱۲].

$$a=f(w_p+b) \quad (2)$$

اول، ورودی اسکالر  $p$  با وزن اسکالر  $w$  برای تولید  $w_p$  ضرب می‌شود. دوم، ورودی وزنی  $w_p$  به شیب اسکالر  $b$  برای ایجاد ورودی خالص اضافه می‌شود. در نهایت، ورودی خالص از طریق تابع انتقال  $f$  منتقل می‌شود که خروجی اسکالر  $a$  را تولید می‌کند. اسامی داده شده به این سه فرآیند عبارتند از: عملکرد وزن، عملکرد ورودی خالص و عملکرد انتقال. از مهم ترین انواع شبکه‌های عصبی میتوان به شبکه عصبی MLP و SOM اشاره کرد.

#### ۴. مشخصات فیدر

مجموعه داده‌های فیدر مورد مطالعه، توسط گروه یکپارچه سازی سیستم‌های توزیع به عنوان بخشی از مطالعه در مورد ضریب نفوذ بالا PV خورشیدی در شبکه توزیع، جمع آوری شده است [۱۳]. فیدر مورد نظر از میان ۲۴ فیدر طبقه بندی شده‌ی آزمایشگاه ملی شمال غربی اقیانوس آرام (PNNL) انتخاب شده است [۱۴]. این فیدر با نام اختصاصی R1-12.47-4 نماینده یک منطقه حومه شهری در سواحل غربی کشور امریکا می‌باشد و عمدتاً از خانه-های تک خانواده و بارهای سنگین تجاری تشکیل شده است. شبکه توزیع این فیدر رو باز نیست و ۱۰۰٪ زیر زمین می‌باشد. اکثریت بارها در نزدیکی پست قرار دارند. داده‌ها شامل باساعتی در طول یک سال از ۵۰ ترانسفورماتور تجاری و مسکونی هستند و در سال ۲۰۰۹ جمع آوری شده‌اند. بارهای ترانسفورماتورهای تجاری به تفکیک هر فاز مورد ارزیابی قرار می‌گیرند. در جدول ۱ مشخصات فیدر ارائه شده است.

#### جدول ۱- مشخصات فیدر


۳۰۲	نقطه انشعاب
۱۲/۴۷	ولتاژ (KV)
۵۲۰۰	بار (KW)
۰	تنظیم کننده‌های ولتاژ
۰	ریکلوزر
۳۸	ترانسفورماتورهای مسکونی
۱۲	ترانسفورماتورهای تجاری
۰	ترانسفورماتورهای صنعتی
۰	ترانسفورماتورهای کشاورزی

شبیه سازی در این مقاله با استفاده از برنامه matlab R2016a صورت گرفته است.

#### ۵. نتایج شبیه‌سازی

##### ۵.۱. خوشه‌بندی ترانسفورماتورهای مسکونی

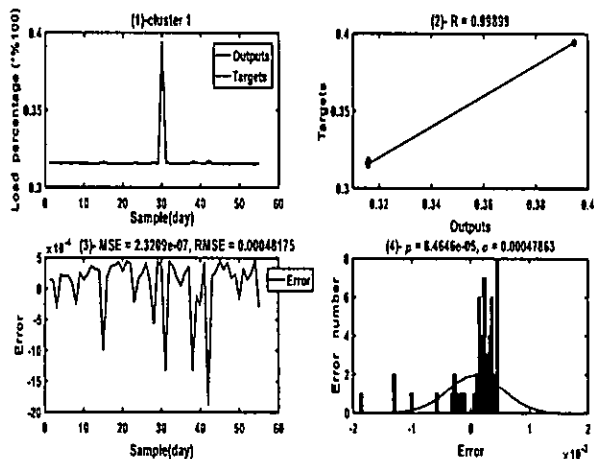
از طریق شاخص DB مطابق شکل به بررسی دو روش SOM و k-means پرداخت شد و شکل ۱ عملکرد بهتر SOM را در زمانی که تعداد خوشه‌ها برابر با دو می‌باشند را نشان می‌دهد.



شکل (۱): شاخص DB برای پروفایل‌های مسکونی

بنابراین نحوه‌ی خوشه‌بندی پروفایل‌های روزانه در طول یک سال ترانسفورماتورهای مطابق شکل ۲ خواهد بود.


MLP برای خوشه‌ی نمونه (خوشه ۱) نشان می‌دهد که بیان‌گر دقت مطلوب شبکه عصبی در تعیین سهم خوشه از بار فیدر می‌باشد و جدول ۲ میانگین درصد سهم بار هر خوشه از بار فیدر در ماه‌های سال را نشان می‌دهد که نشان دهنده‌ی تغییرات در مصرف خوشه‌ها در ماه‌های مختلف است.



شبکه (۵): ارزیابی عملکرد شبکه عصبی MLP برای تعیین سهم خوشه یکم از بار فیدر

جدول (۲): میانگین درصد سهم ماهانه‌ی بار خوشه‌ها از بار فیدر


ماه	تجاری-خوشه ۱		مسکونی-خوشه ۲		تجاری-خوشه ۱		تجاری-خوشه ۱	
	پیش-بار	سهم بار واقعی شده	پیش-بار	سهم بار واقعی شده	پیش-بار	سهم بار واقعی شده	پیش-بار	سهم بار واقعی شده
ژانویه	۳۲/۶	۳۲/۸	۲۱/۵	۲۱/۴	۲۷/۱	۲۷/۲	۱۸/۴	۱۸/۲
فوریه	۳۲	۳۲/۴	۲۱/۹	۲۱/۶	۲۶/۶	۲۶/۶	۱۹/۴	۱۹/۲
مارس	۳۰/۸	۳۰/۷	۲۰/۲	۲۰/۵	۳۱/۲	۳۱/۴	۱۷	۱۷/۱
آوریل	۲۹/۷	۲۹/۶	۱۹/۶	۱۹/۷	۳۲/۵	۳۲/۶	۱۸	۱۷/۸
مه	۲۹/۸	۲۹/۸	۱۹/۴	۱۹/۵	۳۲	۳۲/۱	۱۸/۶	۱۸/۵
ژوئن	۳۰/۲	۳۰/۲	۱۹/۵	۱۹/۵	۳۲/۲	۳۲	۱۷	۱۶/۸
ژوئیه	۳۲/۷	۳۲/۷	۲۰/۲	۲۰/۲	۳۰	۳۰/۲	۱۶/۶	۱۶/۵
اوت	۳۰	۳۰/۱	۲۰/۱	۱۹/۹	۳۲/۸	۳۲/۹	۱۶	۱۵/۹
سپتامبر	۲۹/۸	۲۹/۸	۱۹/۷	۱۹/۸	۳۲	۳۲/۲	۱۷/۲	۱۷
اکتبر	۲۸/۱	۲۸/۲	۱۸/۸	۱۸/۷	۳۵	۳۵/۱	۱۸	۱۷/۹
نوامبر	۳۱	۳۰/۸	۲۰/۶	۲۰/۵	۳۰	۳۰/۱	۱۸/۲	۱۸/۲
دسامبر	۳۵/۷	۳۵/۷	۲۱/۲	۲۱/۴	۲۴/۲	۲۴/۱	۱۸/۵	۱۸/۵



شکل (۲): خوشه بندی ترانسفورماتورهای مسکونی


b. خوشه بندی ترانسفورماتورهای تجاری

همچنین برای ترانسفورماتورهای تجاری شاخص DB مطابق شکل ۳ به بررسی دو روش SOM و k-means پرداخت شد و شکل ۳ عملکرد بهتر SOM را در زمانی که تعداد خوشه‌ها برابر با دو می‌باشند را نشان می‌دهد.



شکل (۳): شاخص DB برای پروفایل های تجاری

بنابراین نحوه خوشه بندی پروفایل های روزانه در طول یک سال ترانسفورماتورهای مطابق شکل ۴ می‌باشد.



شکل (۴): خوشه بندی ترانسفورماتورهای تجاری

c. تعیین درصد سهم خوشه‌ها از بار فیدر

در این بخش سهم خوشه های بدست آمده از بار فیدر برای سال ۲۰۰۹ بدست می‌آید. شکل ۵ عملکرد شبکه عصبی



- [11] H. K. Alfares and M. Nazceruddin, "Electric load forecasting: Literature survey and classification of methods," International Journal of Systems Science, vol. 33,
- [12] M. H. Beale, M. T. Hagan, and H. B. Demuth, "Neural Network Toolbox TM User's Guide," R2013a ed., Matlab.
- [13] Hoke, Anderson, et al. "Steady-state analysis of maximum photovoltaic penetration levels on typical distribution feeders." IEEE Transactions on Sustainable Energy 4.۲ (۲۰۱۳): ۳۵۰-۳۵۷.
- [14] Schneider, Kevin P., et al. Modern grid initiative distribution taxonomy final report. No. PNNL-18035. Pacific Northwest National Laboratory (PNNL), Richland, WA (US), 2008.

#### ۶. بحث و نتیجه‌گیری

در این مقاله با استفاده از خوشه‌بندی که یکی از روش‌ها داده‌کاوی برای تحلیل داده‌ها با حجم زیاد می‌باشد به بررسی الگوهای بار یک فیدر شبکه توزیع پرداخت شد. دو روش خوشه‌بندی k-means و SOM مورد ارزیابی قرار گرفت و خوشه‌های بهینه برای هر کلاس مصرف‌بدست آمد. در پایان با استفاده از شبکه عصبی MLP سهم هر خوشه از بار فیدر به تفکیک هر ماه بدست آمد که نشان دهنده‌ی تغییرات در میزان مصرف خوشه‌هاست و از نتایج این مقاله می‌توان برای اهداف مدیریت مصرف استفاده کرد.

#### ۷. منابع

- [1] Bose, I.; Mahapatra, R.K. .2001 . "Business Data Mining - a Machine Learning Perspective".Information System, 39, 3, 211-225.
- [2] Han, J.; Kamber, M. . 2006 "Data Mining, Concepts and Techniques", Morgan Kaufmannpublisher, second edition.
- [3] Frawley, W.j.; Piatetsky-Shapiro, G.; Matheus, C.J; 1992. "Knowledge Discovery in databases:an Overview", AI Magazine,13, 3, 57-7۰.
- [4] Jiawei Han, Micheline Kamber, Data Mining: Concepts and Techniques, London: Academic Press, 5, 2001
- [5] Vasimalia, Kumar. "A survey on time series data mining." International Journal of Innovative Research in Computer and Communication Engineering (IJIRCCE) 2 (2014): 170-179
- [6] V. Figueiredo, F. Rodrigues, Z. Vale, and J. B. Gouveia, "An Electric Energy Consumer Characterization Framework Based on Data Mining Techniques."IEEE Transactions on Power Systems, vol. 20, no. 2, pp. 596-602, May 2005
- [7] McLoughlin, Fintan. "Characterising domestic electricity demand for customer load profile segmentation." (2013).
- [8] Howard Demuth, Mark Beale, "Neural Network Toolbox for Use with MATLAB", The MathWorks, Inc., 2002.
- [9] L.P.J. Veelenturf, "Analysis and Applications of Artificial Neural Networks", Prentice Hall International, 1995.
- [10] B. Krose, Patrick Smagt, "An Introduction to Neural Networks", University of Amsterdam, 8th ed., 1996.