

خوشه‌بندی سری‌های زمانی برای سهم‌بندی الگوهای مختلف مصرف از بار فیدر

رضا اسلامی^۱

استادیار دانشکده مهندسی برق دانشگاه صنعتی سهند تبریز، eslami@sut.ac.ir

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 اندازه‌گیری هوشمند، امکان پردازش غیر متمرکز 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 خوشه‌بندی در سری‌های زمانی مورد ارزیابی قرار خواهد گرفت و همچنین نحوه جمع‌آوری 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 داشتن الگوهای بارهای هر خوشه، سهم آنها از بار فیدر بدست می‌آید.

کلیدواژه - الگوهای بار، خوشه‌بندی، داده‌کاوی، سری‌های زمانی و فیدر.

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 [۸]. معمولاً تامین کنندگان بزرگ برق از خوشه بندی برای دسته بندی کردن مشتری‌هایی که دارای ویژگی‌های الکتریکی مشابه هستند استفاده می‌کند [۹].

این مقاله با مقایسه دو روش خوشه بندی k-means و SOM با استفاده از شاخص DB 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 دسته بندی مشترکین برق یک فیدر توزیع می‌پردازد و سهم خوشه‌ها مختلف مصرف را از بار فیدر به دست می‌آورد.

۲- خوشه بندی 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.

۱- مقدمه

معرفی و توسعه بازارهای رقابتی برق به سرعت در تعامل بین تامین‌کننده و مصرف‌کننده تغییر یافته است [۲،۱]. در حال حاضر، تفکیک هر کدام از مولفه‌های بار شبکه‌های توزیع، یکی از نیازهای مبرم صنعت برق بوده و نتایج برگرفته از آنها می‌تواند در زمینه‌های مختلف اعم از تأمین الگوی بار الکتریکی، پیش‌بینی بار در زمان اوج مصرف، تعیین ظرفیت مانور شبکه‌های توزیع و از همه مهم‌تر جهت تدوین برنامه‌های مدیریت مصرف در بخش‌های گوناگون به کار گرفته شوند.

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 داده‌کاوی به عنوان فرایند کشف و استخراج الگوهای پنهان از حجم بالایی از داده‌ها تعریف می‌شود [۴-۲]. امروزه داده‌کاوی را یک گام اساسی در فرآیند کشف دانش در پایگاه‌های داده می‌دانند [۵-۷]. 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

ضریب نفوذ بالا PV خورشیدی در شبکه توزیع، جمع آوری شده است [۱۳]. فیدر مورد نظر از میان ۲۴ فیدر طبقه بندی شده آزمایشگاه ملی شمال غربی اقیانوس آرام (PNNL) انتخاب شده است [۱۴]. این فیدر با نام اختصاصی 4-12.47-R1 نماینده یک منطقه حومه شهری در سواحل غربی کشور امریکا می باشد 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 می باشد. اکثریت بارها در نزدیکی پست قرار دارند. داده ها شامل بار ساعتی در طول یک سال از ۵۰ ترانسفورماتور تجاری و مسکونی هستند و در سال ۲۰۰۹ جمع آوری شده اند. بارهای ترانسفورماتورهای تجاری به تفکیک هر فاز مورد ارزیابی قرار می گیرند. در جدول ۱ مشخصات فیدر ارائه شده است.

جدول ۱: مشخصات فیدر


۳۰۲	نقطه انشعاب
۱۲/۴۷	ولتاژ (KV)
۵۳۰۰	بار (KW)
۰	تنظیم کننده های ولتاژ
۰	ریکلوزر
۳۸	ترانسفورماتورهای مسکونی
۱۲	ترانسفورماتورهای تجاری
۰	ترانسفورماتورهای صنعتی
۰	ترانسفورماتورهای تجاری

شبیه سازی در این مقاله با استفاده از برنامه matlab R216a استفاده شده است.

۵- نتایج شبیه سازی

۵-۱- 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 خوشه ها برابر با دو می باشد را نشان می دهد.



معادله (۱) الگوریتم k-means را که مجموعه ای از مشاهدات x_1, x_2, \dots, x_n را ارائه می دهد، که در آن هر یک از مشاهدات یک بردار d dimensional با تعداد ابعاد d است. خوشه بندی k-means با هدف تقسیم بندی 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 [۱۰]. بنابراین تعریف می شود:

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

۳- خوشه بندی SOM

نقشه های خود سازمان دهنده یا SOM گاهی اوقات به عنوان نقشه های Kohonen به عنوان اصول شبکه های عصبی مطرح می شوند اما می توانند به عنوان یک روش خوشه بندی در نظر گرفته شوند [۱۱].

SOM فرآیند شبکه عصبی را اعمال می کند که یادگیری بی نظیری را برای تقسیم داده ها بکار می برد. در ساختار شبکه های مستطیلی یا شش ضلعی معمولاً از گره برای جداسازی داده ها استفاده می شود. هر گره شش ضلعی توسط یک بردار وزن تعریف شده است که شامل مجموعه ای از ابعاد مختلف بسته به بردار ورودی است. فرآیند نقشه برداری با به کارگیری وزن ها با مقادیر تصادفی در هر گره آغاز می شود. همانطور که شبکه پیشرفت می کند، هر بردار ورودی با وزن هر گره مقایسه می شود و گره با بیشترین شباهت، به نام بهترین واحد تطبیقی^۱ BMU نامیده می شود، اختصاص می یابد. سپس وزن هادر BMU و گره ها براساس بردار ورودی تنظیم می شوند. این فرآیند تا زمانی که همه بردارهای ورودی در درون خوشه ها طبقه بندی شوند، تکرار می گردد [۱۲].


۴- مشخصات فیدر

مجموعه داده های فیدر مورد مطالعه، توسط گروه یکپارچه سازی سیستم های توزیع به عنوان بخشی از مطالعه در مورد

^۱ Best Matching Unit

شکل ۱: شاخص DB برای پروفایل‌های مسکونی


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



شکل ۲: خوشه بندی ترانسفورماتورهای مسکونی


۵-۲- 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 پروفایل‌های تجاری

بنابراین نحوه خوشه‌بندی پروفایل‌های روزانه در طول یک سال ترانسفورماتورهای مطابق شکل ۴ می‌باشد.



شکل ۴: خوشه بندی ترانسفورماتورهای تجاری

۵-۳- سهم خوشه‌ها از بار فیدر

در این بخش سهم خوشه‌های بدست آمده از بار فیدر برای

سال ۲۰۰۹ بدست می‌آید. 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 دارد.

جدول ۲: میانگین درصد سهم بار خوشه‌ها از بار فیدر

ماه	تجاری-خوشه ۱	مسکونی-خوشه ۲	تجاری-خوشه ۱	مسکونی-خوشه ۱
ژانویه	18.275	27.282	21.497	32.944
فوریه	19.368	26.614	21.607	32.409
مارس	17.177	31.495	20.531	30.796
آوریل	17.914	32.686	19.7483	29.6511
مه	18.522	32.10	19.5483	29.829
ژوئن	16.993	33.05	19.51	30.43
ژوئیه	16.58	30.29	20.35	32.77
اوت	15.96	33.96	19.95	30.11
سپتامبر	17.09	33.21	19.89	29.8
اکتبر	17.92	35.1	18.76	28.21
نوامبر	18.30	30.16	20.54	30.98
دسامبر	18.54	24.16	21.48	35.79

۶- نتیجه گیری

در این مقاله یا 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 خوشه بندی k-means و SOM مورد ارزیابی قرار گرفت و خوشه‌های بهینه برای هر کلاس مصرف بدست آمد. در پایان سهم هر خوشه از بار فیدر به تفکیک هر ماه حاصل شد که نشان دهنده‌ی تغییرات در میزان مصرف خوشه‌ها بود.

مراجع

- [1] L. Park, S. Jeong, J. Kim, and S. Cho, "Joint Geometric Unsupervised Learning and Truthful Auction for Local Energy Market," IEEE Transactions on Industrial Electronics, vol. 66, pp. 1499-1508, 2019.
- [2] M. D. Somma, G. Graditi, and P. Siano, "Optimal Bidding Strategy for a DER Aggregator in the Day-Ahead Market in the Presence of Demand Flexibility," IEEE Transactions on Industrial Electronics, vol. 66, pp. 1509-1519, 2019.
- [3] Han, J.; Kamber, M. . 2006 "Data Mining, Concepts and Techniques", Morgan Kaufmannpublisher, second edition.
- [4] Frawley, W.j.; Piatetsky-Shapiro, G.; Matheus, C.J; 1992. "Knowledge Discovery in databases:an Overview", AI Magazine,13, 3, 57-70.
- [5] Jiawei Han, Micheline Kamber, Data Mining: Concepts and Techniques, London: Academic Press, 5, 2001.
- [6] S. Kumar and M. Singh, "Big data analytics for healthcare industry: impact, applications, and tools," Big Data Mining and Analytics, vol. 2, pp. 48-57, 2019.
- [7] C. Kong, G. Luo, L. Tian, and X. Cao, "Disseminating authorized content via data analysis in opportunistic social networks," Big Data Mining and Analytics, vol. 2, pp. 12-24, 2019
- [8] Vasimalla, Kumar. "A survey on time series data mining." International Journal of Innovative Research in Computer and Communication Engineering (IJRCCE) 2 (2014): 170-179

- [13] Hoke, Anderson, et al. "Steady-state analysis of maximum photovoltaic penetration levels on typical distribution feeders." *IEEE Transactions on Sustainable Energy* 4.2 (2013): 350-357.
- [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.
- [9] 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
- [10] McLoughlin, Fintan. "Characterising domestic electricity demand for customer load profile segmentation." (2013).
- [11] M. Halkidi, Y. Batistakis, and M. Vazirgiannis, "On Clustering Validation Techniques," *Journal of Intelligent Information Systems*, pp. 107–145, 2001Gffg
- [12] MathWorks, "Neural Network Toolbox Users Guide," no. Version 4, 2002Uky