

یک مرور جامع بر روش‌های خوشه‌بندی عمیق و کاربردهای آن

محمد مهدی سلیمی¹

احمد رضا دوستی ماسوله²

دانشجوی کارشناسی ارشد مهندسی برق - مخابرات سیستم، دانشگاه بین المللی امام خمینی^{1 و 2}

¹ Mahdi.salimi@edu.ikiu.ac.ir

² s4026185004@edu.ikiu.ac.ir

چکیده - خوشه‌بندی یکی از تکنیک‌های اساسی یادگیری ماشین است که هدف آن گروه‌بندی داده‌های بدون برچسب است. روش‌های سنتی خوشه‌بندی در مواجهه با داده‌های پیچیده و با ابعاد بالا دچار چالش می‌شوند. خوشه‌بندی عمیق با ترکیب یادگیری عمیق و الگوریتم‌های خوشه‌بندی، نمایش‌های فشرده و معناداری از داده‌ها را استخراج کرده و عملکرد خوشه‌بندی را بهبود می‌بخشد. این روش‌ها شامل مدل‌های مبتنی بر خودرمزگذار، یادگیری متضاد، شبکه‌های عصبی گرافی و مدل‌های مولد هستند. در این مقاله، یک مرور جامع بر این روش‌ها ارائه شده و چالش‌های کلیدی مانند هزینه محاسباتی بالا، حساسیت به پارامترها و تفسیرپذیری نتایج بررسی می‌شود. همچنین، کاربردهای خوشه‌بندی عمیق در حوزه‌هایی مانند تصویربرداری پزشکی، پردازش زبان طبیعی و بیوانفورماتیک مورد بحث قرار گرفته و مسیرهای پژوهشی آینده پیشنهاد می‌شود.

کلید واژه- خوشه‌بندی، خوشه‌بندی عمیق، داده کاوی، شبکه عصبی عمیق، یادگیری ماشین

1-مقدمه

مدل ترکیبی گاوسی¹، خوشه‌بندی مبتنی بر چگالی مانند DBSCAN²، خوشه‌بندی طیفی، انتقال میانگین³، و خوشه‌بندی سلسله‌مراتبی⁴ می‌شوند. این روش‌ها، اگرچه در مجموعه داده‌های کوچک یا کم‌بعدی کارآمد هستند، اما در مواجهه با داده‌های پیچیده، با بعد زیاد و بزرگ مقیاس با محدودیت‌هایی روبه‌رو می‌شوند. به همین دلیل، پژوهشگران از استراتژی‌هایی مانند کاهش ابعاد خطی (PCA، LDA)، روش‌های کرنلی، و تکنیک‌های غیرخطی مانند t-SNE (برای بهبود خوشه‌بندی بهره گرفته‌اند. با این حال، این روش‌ها اغلب اطلاعات مهمی را از بین می‌برند و ممکن است نسبت به نویز و داده‌های پرت حساس باشند.

برای غلبه بر این چالش‌ها، روش‌های خوشه‌بندی عمیق معرفی شده‌اند که از یادگیری عمیق برای استخراج ویژگی‌های غیرخطی و بهبود فرآیند خوشه‌بندی استفاده می‌کنند. این روش‌ها شبکه‌های عصبی را در خوشه‌بندی

رشد چشمگیر داده‌ها در عصر دیجیتال منجر به انباشت مجموعه‌های بزرگ و بدون برچسب در حوزه‌های متنوعی مانند اینترنت، شبکه‌های اجتماعی، و شبکه‌های حسگر شده است. درک و تحلیل این داده‌ها نیازمند روش‌های کارآمدی است که بتوانند الگوها و ساختارهای درونی را بدون نیاز به برچسب‌های انسانی استخراج کنند. خوشه‌بندی، به عنوان یکی از وظایف اساسی یادگیری بدون نظارت، نقش مهمی در کشف روابط پنهان میان داده‌ها دارد. هدف آن، گروه‌بندی نمونه‌ها به گونه‌ای است که داده‌های داخل هر خوشه دارای ویژگی‌های مشترک باشند، در حالی که داده‌های خوشه‌های مختلف تفاوت معناداری با یکدیگر داشته باشند. این فرآیند در کاربردهایی مانند تشخیص ناهنجاری، بازشناسی مجدد افراد، شناسایی جوامع، و تطبیق دامنه اهمیت دارد.

در دهه‌های اخیر، روش‌های خوشه‌بندی متعددی توسعه یافته‌اند که شامل الگوریتم‌های سنتی مانند K-means،

¹ Gaussian Mixture Model

² Density-based Spatial Clustering of Applications with Noise

³ Mean Shift

⁴ Hierarchical Clustering

DBSCAN-2-2

DBSCAN [2] یک الگوریتم مبتنی بر چگالی است که خوشه‌ها را براساس تراکم نقاط داده شناسایی می‌کند. نقاطی که تعداد مشخصی از همسایگان نزدیک داشته باشند، به عنوان نقاط هسته‌ای در نظر گرفته شده و سایر نقاط بر این اساس خوشه‌بندی می‌شوند. مزیت مهم DBSCAN این است که تعداد خوشه‌ها را از پیش نیاز ندارد و می‌تواند خوشه‌هایی با اشکال نامنظم را شناسایی کند. همچنین در برابر نویز و نقاط پرت مقاوم است. اما در داده‌های با چگالی متغیر، عملکرد آن می‌تواند بهینه نباشد.

2-3- خوشه‌بندی سلسله‌مراتبی

این روش، داده‌ها را به صورت یک ساختار درختی (دندروگرام) مرتب می‌کند. مزیت اصلی خوشه‌بندی سلسله‌مراتبی این است که نیازی به تعیین تعداد خوشه‌ها از پیش ندارد و ساختار سلسله‌مراتبی را نمایش می‌دهد. اما برای مجموعه داده‌های بزرگ، پیچیدگی محاسباتی بالایی دارد و در برابر نویز حساس است. [3]

با وجود مزایای روش‌های سنتی، این الگوریتم‌ها در پردازش داده‌های پربعد، غیرخطی و پیچیده با مشکلاتی روبه‌رو می‌شوند. همچنین، بسیاری از این روش‌ها به تعاریف اولیه‌ای مانند تعداد خوشه‌ها یا پارامترهای خاص وابسته هستند. به همین دلیل، روش‌های خوشه‌بندی عمیق برای مقابله با این محدودیت‌ها توسعه یافته‌اند.

3- روش‌های خوشه‌بندی عمیق

3-1- خوشه‌بندی مبتنی بر شبکه‌های عصبی عمیق (DNNs)

شبکه‌های عصبی عمیق ساختارهای قدرتمندی برای مدل‌سازی روابط غیرخطی در داده‌ها هستند. این شبکه‌ها متشکل از چندین لایه پنهان هستند که هر لایه ویژگی‌های پیچیده‌تری را از داده‌ها استخراج می‌کند. معماری لایه پنهان می‌تواند اشکال مختلفی داشته باشد، از جمله شبکه‌ی عصبی کاملاً متصل (FNN)، شبکه‌ی عصبی کانولوشنال (CNN) و شبکه‌ی باور عمیق (DBN). در سال‌های اخیر، شبکه‌های باقی‌مانده

ادغام کرده و از نمایش‌های یادگیری شده برای دستیابی به نتایج دقیق‌تر بهره می‌برند. امروزه خوشه‌بندی عمیق در حوزه‌های مختلفی از جمله بیوانفورماتیک، پزشکی، تشخیص ناهنجاری‌ها و شناسایی جوامع کاربرد گسترده‌ای یافته است. با توجه به پیشرفت‌های اخیر، مقالات متعددی سعی در دسته‌بندی و تحلیل خوشه‌بندی عمیق داشته‌اند. برخی پژوهش‌ها این حوزه را بر اساس ساختار شبکه‌های عصبی بررسی کرده‌اند، درحالی‌که برخی دیگر بر منابع داده یا تعامل بین یادگیری نمایش و خوشه‌بندی تمرکز داشته‌اند. در این مقاله مروری، خوشه‌بندی عمیق از منظر دانش پیشین بررسی شده و به روش‌های مبتنی بر شبکه‌های عصبی عمیق (⁵DNNs)، مبتنی بر خودرمزگذارها (AEs)⁶، مبتنی بر شبکه‌های عصبی گرافی (⁷GNNs) و روش‌های مبتنی بر مدل‌های مولد (مانند GANs⁸) اشاره می‌شود.

2- روش‌های کلاسیک خوشه‌بندی

روش‌های کلاسیک خوشه‌بندی از الگوریتم‌های پرکاربرد یادگیری بدون نظارت هستند که برای گروه‌بندی داده‌ها بر اساس شباهت استفاده می‌شوند.

K-Means-2-1

K-Means [1] یکی از پرکاربردترین الگوریتم‌های خوشه‌بندی است که داده‌ها را به K خوشه تقسیم می‌کند. این الگوریتم با انتخاب تصادفی مراکز اولیه خوشه‌ها شروع می‌شود، سپس نمونه‌ها را به نزدیک‌ترین مرکز اختصاص داده و مراکز را به‌روزرسانی می‌کند. این فرآیند تا زمانی که همگرایی حاصل شود، تکرار می‌شود. مزیت اصلی این روش سادگی و کارایی آن برای داده‌های بزرگ است، اما تعداد خوشه‌ها باید از قبل مشخص شود و در برابر نقاط پرت و خوشه‌های غیر کروی حساس است.

⁵ Deep Neural Networks

⁶ Autoencoders

⁷ Graph Neural Networks

⁸ Generative Adversarial Networks

عمیق از چندین لایه پردازشی برای یادگیری نمایش‌های سطح بالا از داده‌ها استفاده می‌کنند. در روش‌های خوشه‌بندی، این شبکه‌ها داده‌ها را به نمایش‌هایی تبدیل می‌کنند که برای تفکیک‌پذیری خوشه‌ها مناسب‌تر باشند. روش‌هایی مانند JULE و DeepCluster از این تکنیک استفاده می‌کنند.

خودرمزگذارهای تغییرپذیر [6] (VAE)¹⁶ که بر اساس مدل‌های احتمالاتی، نمایش‌های داده را یاد می‌گیرند. مدل‌های VAE یک توزیع احتمالاتی را بر فضای نهفته داده یاد می‌گیرند. این مدل‌ها از دو شبکه عصبی شامل یک انکودر برای تبدیل داده به فضای نهفته و یک دکودر برای بازسازی داده استفاده می‌کنند. برخلاف DAE، VAE نمایش‌های داده را بر اساس توزیع‌های احتمالاتی یاد می‌گیرد که باعث بهبود عملکرد در داده‌های پیچیده و متغیر می‌شود.

شبکه‌های مولد خصمانه [7] (GANs) که از یادگیری متضاد برای بهبود نمایش‌های داده استفاده می‌کنند. این روش از یک بازی بین دو شبکه عصبی، یکی برای تولید داده (مولد) و دیگری برای تشخیص واقعی بودن داده (تمیزدهنده)، استفاده می‌کند. خوشه‌بندی مبتنی بر GAN با تولید نمایش‌های غنی از داده و تقویت شباهت درون‌خوشه‌ای، بهبود قابل توجهی در عملکرد خوشه‌بندی ایجاد می‌کند. روش‌هایی مانند ClusterGAN و InfoGAN در این زمینه مطرح شده‌اند.

شبکه‌های عصبی گرافی [8] (GNNs) که ساختار گرافی داده‌ها را در نظر می‌گیرند در این روش، داده‌ها به صورت یک گراف نمایش داده می‌شوند و اطلاعات ساختاری بین داده‌ها مورد استفاده قرار می‌گیرد. شبکه‌های عصبی گرافی می‌توانند ارتباطات میان نمونه‌ها را یاد بگیرند و ویژگی‌هایی را استخراج کنند که به بهبود خوشه‌بندی کمک می‌کنند.

(ResNets) مانند ResNet18 و ResNet34 به عنوان معماری غالب در شبکه‌های عصبی عمیق مطرح شده‌اند.

در زمینه خوشه‌بندی، DNN ها به عنوان ابزاری برای یادگیری نمایش‌های غنی و فشرده از داده‌ها استفاده می‌شوند، به طوری که خوشه‌بندی در فضای ویژگی‌های یادگیری شده به مراتب دقیق‌تر از فضای اولیه داده‌ها خواهد بود. در این بخش، این روش‌ها بر اساس ویژگی‌های کلیدی‌شان به پنج دسته‌ی مجزا تقسیم می‌شوند:

بهینه‌سازی تکراری (IO)⁹، یادگیری خودنظارتی (SL)¹⁰، برآورد اطلاعات متقابل (MIE)¹¹، یادگیری متضاد¹² و شبکه‌های چندگانه¹³

2-3- خوشه‌بندی عمیق تک‌نمایی¹⁴

در این روش، فرض بر این است که داده‌ها از یک ساختار و نمای واحد برخوردارند. استخراج ویژگی‌ها توسط شبکه‌های عصبی انجام می‌شود که می‌توانند انواع مختلفی داشته باشند:

خودرمزگذارهای عمیق [4] (DAE)¹⁵ که ویژگی‌های فشرده‌تری را از داده‌ها استخراج می‌کنند. این روش از یک خودرمزگذار برای یادگیری نمایش فشرده داده استفاده می‌کند. خودرمزگذار دارای یک شبکه عصبی کاهشی برای فشرده‌سازی داده و یک شبکه افزایشی برای بازسازی آن است. این مدل بهینه‌سازی می‌شود تا خطای بازسازی را کاهش دهد، در نتیجه ویژگی‌های معناداری را برای خوشه‌بندی استخراج می‌کند.

شبکه‌های عصبی عمیق [5] (DNNs) که نمایش‌های مناسبی را برای خوشه‌بندی ایجاد می‌کنند. شبکه‌های عصبی

⁹ Iterative Optimization

¹⁰ Self Supervised

¹¹ Mutual Information Estimation

¹² Contrastive Learning

¹³ Non-Single Networks

¹⁴ Single-View Deep Clustering

¹⁵ Deep Autoencoders

¹⁶ Variational Autoencoders

داده‌ها از منابع مختلفی مانند تصویر، متن، و صدا جمع‌آوری می‌شوند. روش‌های سنتی خوشه‌بندی نمی‌توانند به طور همزمان اطلاعات را از این نماهای مختلف ادغام کنند. خوشه‌بندی عمیق چندنمایی، با استفاده از شبکه‌های عصبی، قادر است ویژگی‌های مشترک و مکمل از نماهای مختلف داده را استخراج کند و خوشه‌بندی بهتری انجام دهد.

این روش به چند دسته تقسیم می‌شود:

خوشه‌بندی تعبیه‌ای عمیق: در این روش [10]، ابتدا هر نمای داده به یک فضای نهفته مشترک تبدیل می‌شود و سپس خوشه‌بندی در این فضای مشترک انجام می‌گیرد. هدف اصلی این روش، یافتن نمایش بهینه‌ای است که اطلاعات مشترک بین نماها را حفظ کند.

خوشه‌بندی مبتنی بر زیرفضا: این رویکرد [11] تلاش می‌کند تا زیرفضایی را پیدا کند که در آن، داده‌های چندنمایی به صورت خوشه‌های جدا از هم قرار گیرند. این روش معمولاً با استفاده از خودرمزگذارهای عمیق انجام می‌شود.

شبکه‌های عصبی گرافی چندنمایی: در این رویکرد [12]، داده‌های چندنمایی به صورت یک گراف مدل‌سازی می‌شوند و ارتباطات بین نماهای مختلف داده از طریق گره‌ها و یال‌های گراف بررسی می‌شود. این روش به ویژه در تحلیل شبکه‌های اجتماعی و داده‌های پیچیده کاربرد دارد.

3-5- خوشه‌بندی عمیق انتقالی²¹

در این روش، دانش استخراج‌شده از یک دامنه داده (مثلاً داده‌های برچسب‌دار) برای بهبود خوشه‌بندی در دامنه‌ای دیگر (مثلاً داده‌های بدون برچسب) استفاده می‌شود. یادگیری انتقالی یکی از روش‌های مؤثر برای حل مشکل کمبود داده‌های برچسب‌دار در خوشه‌بندی است. این روش

این روش برای داده‌هایی مانند شبکه‌های اجتماعی، بیوانفورماتیک و داده‌های وابسته به گراف بسیار مؤثر است.

3-3- خوشه‌بندی عمیق نیمه‌نظارتی¹⁷

در خوشه‌بندی نیمه‌نظارتی، از مقدار کمی داده‌ی برچسب‌دار در کنار داده‌های بدون برچسب برای بهبود دقت خوشه‌بندی استفاده می‌شود. این روش با بهره‌گیری از قیود زوجی، مدل را راهنمایی کرده و بدون نیاز به برچسب‌گذاری کامل، دقت خوشه‌بندی را افزایش می‌دهد. کاربرد آن در مسائلی است که داده‌های بدون برچسب فراوان ولی داده‌های برچسب‌دار محدود هستند. رویکردهای مختلفی برای خوشه‌بندی نیمه‌نظارتی وجود دارند:

قیود زوجی¹⁸: در این روش، اطلاعات از طریق قیود مبتنی بر شباهت یا عدم شباهت بین جفت داده‌ها اعمال می‌شود. مدل با استفاده از این قیود تلاش می‌کند داده‌هایی را که به یک گروه تعلق دارند، در یک خوشه قرار دهد.

از دست دادن مبتنی بر اطلاعات متقابل¹⁹: در این رویکرد، اطلاعات متقابل بین داده‌های برچسب‌دار و بدون برچسب پیشنهاد شده تا به یک خوشه‌بندی پایدارتر دست یابیم.

ادغام یادگیری نظارت‌شده و بدون نظارت: برخی از روش‌ها از ترکیبی از یادگیری نظارت‌شده و خوشه‌بندی بدون نظارت بهره می‌برند تا مدل بتواند از داده‌های برچسب‌دار برای تقویت ویژگی‌های استخراج‌شده از داده‌های بدون برچسب استفاده کند.

3-4- خوشه‌بندی عمیق چندنمایی²⁰

داده‌های چندنمایی شامل اطلاعاتی از منابع مختلف هستند که می‌توان از همبستگی و اطلاعات مکمل آن‌ها برای بهبود خوشه‌بندی استفاده کرد. در بسیاری از مسائل واقعی،

²¹ Transfer Learning Deep Clustering

¹⁷ Semi-Supervised Deep Clustering

¹⁸ Pairwise Constraints

¹⁹ Mutual Information Loss

²⁰ Multi-View Deep Clustering

توسعه الگوریتم‌های خودتنظیم برای انتخاب بهینه ابرپارامترها یک نیاز مهم در این حوزه محسوب می‌شود.

تفسیرپذیری پایین: یکی از مشکلات اساسی مدل‌های یادگیری عمیق، عدم شفافیت در نحوه تصمیم‌گیری آن‌ها است. این موضوع در خوشه‌بندی عمیق، که بدون برچسب انسانی انجام می‌شود، اهمیت بیشتری پیدا می‌کند. روش‌هایی مانند استفاده از مدل‌های مبتنی بر توجه²² و تکنیک‌های توضیح‌پذیری (مانند SHAP و LIME) می‌توانند به درک بهتر خروجی‌های مدل کمک کنند.

چالش در داده‌های نامتوازن: بسیاری از مجموعه داده‌های واقعی شامل توزیع نامتعادل بین کلاس‌های مختلف هستند که می‌تواند منجر به خوشه‌بندی نادرست شود. روش‌های داده‌افزایی²³ و نمونه‌برداری هوشمند از داده‌ها می‌توانند تا حدی این مشکل را کاهش دهند.

عدم پایداری خوشه‌ها: مدل‌های خوشه‌بندی عمیق گاهی در اجرای مجدد، نتایج متفاوتی ارائه می‌دهند. این عدم پایداری ناشی از وابستگی مدل به مقادیر اولیه پارامترها و ماهیت تصادفی فرآیند یادگیری است. استفاده از روش‌های تنظیم‌کننده²⁴ و یادگیری مقاوم می‌تواند این چالش را کاهش دهد.

4-2- فرصت‌های پژوهشی

ادغام یادگیری خودنظارتی و خوشه‌بندی عمیق: روش‌های جدیدی در حال توسعه هستند که از یادگیری خودنظارتی برای بهبود خوشه‌بندی استفاده می‌کنند. این تکنیک‌ها می‌توانند ویژگی‌های عمیق‌تری را از داده‌ها استخراج کرده و نیاز به داده‌های برچسب‌دار را کاهش دهند.

خوشه‌بندی چندنمایی هوشمند: توسعه مدل‌هایی که بتوانند به‌صورت هوشمند اطلاعات چندنمایی را ادغام کنند، یک

به مدل اجازه می‌دهد تا اطلاعات آموخته‌شده در یک حوزه را به یک حوزه جدید انتقال دهد.

معیار مقایسه	روش کلاسیک	روش عمیق
نوع داده	بعد کم	بعد زیاد
مقیاس‌پذیری	بالا	نیازمند سخت‌افزار قوی
پیچیدگی محاسباتی	معمولاً کمتر	بالا تر به ویژه شبکه عمیق
قابلیت تفسیر	بالا	معمولاً پایین‌تر
حساسیت به نویز	حساس (به جز DBSCAN)	معمولاً مقاوم‌تر

جدول 1: مقایسه روش‌های خوشه‌بندی کلاسیک و روش‌های خوشه‌بندی عمیق

4- چالش‌ها و فرصت‌های پژوهشی

4-1- چالش‌ها

همانطور که در جدول 1 روش‌های کلاسیک و روش‌های عمیق مقایسه شده‌اند، روش‌های عمیق با وجود مزیت‌های زیاد، دارای چالش‌هایی هستند.

هزینه محاسباتی بالا: مدل‌های عمیق شامل میلیون‌ها پارامتر هستند و برای پردازش داده‌های حجیم به توان محاسباتی بالایی نیاز دارند. این مشکل باعث محدودیت در اجرای این مدل‌ها روی سخت‌افزارهای معمولی و افزایش زمان آموزش و استنتاج می‌شود. استفاده از روش‌هایی مانند کاهش ابعاد ویژگی‌ها، فشرده‌سازی مدل، و اجرای توزیع‌شده روی زیرساخت‌های ابری می‌تواند این چالش را کاهش دهد.

حساسیت به پارامترها: عملکرد مدل‌های خوشه‌بندی عمیق به شدت به انتخاب مقادیر مناسب ابرپارامترها مانند نرخ یادگیری، تعداد لایه‌ها و اندازه خوشه‌ها وابسته است. یافتن مقادیر بهینه معمولاً از طریق آزمایش‌های پرتکرار و روش‌های تنظیم ابرپارامتر مانند جستجوی شبکه‌ای یا بهینه‌سازی بیزین انجام می‌شود که زمان‌بر و پرهزینه است.

²² Attention Mechanisms

²³ Data Augmentation

²⁴ Regularization

- [2] M. Ester, H.P. Kriegel, J. Sander, et al., A density-based algorithm for discovering clusters in large spatial databases with noise, kdd 96 (34) (1996) 226–231.
- [3] F. Murtagh, P. Contreras, Algorithms for hierarchical clustering: an overview. Wiley Interdiscip. Rev. Data Min. Knowl. Discov. 2(1), 86–97 (2012).
- [4] Y. Ren et al., "Deep Clustering: A Comprehensive Survey," in IEEE Transactions on Neural Networks and Learning Systems, doi: 10.1109/TNNLS.2024.3403155.
- [5] Geoffrey E Hinton and Ruslan R Salakhutdinov. Reducing the dimensionality of data with neural networks. Science, 313(5786):504–507, 2006.
- [6] Diederik P Kingma and Max Welling. Auto encoding variational bayes. arXiv preprint arXiv:1312.6114, 2013.
- [7] Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. Generative adversarial nets. In NeurIPS, pages 2672–2680, 2014.
- [8] Zonghan Wu, Shirui Pan, Fengwen Chen, Guodong Long, Chengqi Zhang, and S Yu Philip. A comprehensive survey on graph neural networks. IEEE Trans. Neural Netw. Learn. Syst., 32(1):4–24, 2020.
- [9] Durk P Kingma, Shakir Mohamed, Danilo Jimenez Rezende, and MaxWelling. Semi-supervised learning with deep generative models. In NeurIPS, pages 3581–3589, 2014.
- [10] Alexander Strehl and Joydeep Ghosh. Cluster ensembles - a knowledge reuse framework for combining multiple partitions. JMLR, 3:583–617, 2002.
- [11] Linxiao Yang, Ngai-Man Cheung, Jiaying Li, and Jun Fang. Deep clustering by gaussian mixture variational autoencoders with graph embedding. In ICCV, pages 6440–6449, 2019.
- [12] Matthew D Hoffman and Matthew J Johnson. Elbo surgery: yet another way to carve up the variational evidence lower bound. In NeurIPS, 2016.

زمینه پژوهشی مهم است. این کار می‌تواند دقت خوشه‌بندی را در کاربردهایی مانند تحلیل تصاویر پزشکی و پردازش گفتار افزایش دهد.

توسعه مدل‌های ترکیبی^{۲۵}: ترکیب مدل‌های یادگیری عمیق با روش‌های کلاسیک خوشه‌بندی می‌تواند مزایای هر دو روش را ترکیب کرده و منجر به بهبود نتایج شود. این مدل‌ها می‌توانند از ساختارهای سلسله‌مراتبی و اطلاعات پیشین برای بهبود خوشه‌بندی بهره ببرند.

ادغام یادگیری خودنظارتی: ترکیب روش‌های یادگیری خودنظارتی با خوشه‌بندی عمیق می‌تواند منجر به استخراج ویژگی‌های غنی‌تر و بهبود نتایج خوشه‌بندی شود. بهینه‌سازی مدل‌ها برای داده‌های مقیاس بزرگ: استفاده از روش‌های یادگیری فدراتیو^{۲۶} و یادگیری توزیع‌شده^{۲۷} می‌تواند به بهبود عملکرد خوشه‌بندی در مجموعه داده‌های عظیم کمک کند.

5- نتیجه‌گیری

خوشه‌بندی عمیق با استفاده از شبکه‌های عصبی عمیق، ویژگی‌های معناداری از داده‌های بدون برچسب استخراج کرده و نسبت به روش‌های سنتی عملکرد بهتری دارد. این روش در حوزه‌هایی مانند پردازش زبان طبیعی، تحلیل داده‌های پزشکی و پردازش تصاویر کاربرد دارد. با توسعه الگوریتم‌های کارآمدتر، بهبود تفسیرپذیری و کاهش هزینه‌های محاسباتی، خوشه‌بندی عمیق می‌تواند به ابزاری قوی‌تر برای تحلیل داده‌های پیچیده تبدیل شود.

مراجع

- [1] J. MacQueen, "Some methods for classification and analysis of multivariate observations," Proc. Fifth Berkeley Symp. Math. Stat. Probab., vol. 1, no. 14, 1967, pp. 281–297.

²⁵ Hybrid Models

²⁶ Federated Learning

²⁷ Distributed Learning