

مطالعه تطبیقی الگوریتم‌های کلستریندی در زمینه‌ی دیتاکاوی تحصیلی

پوهنیار احمدضیا بهرامی^۱، پوهنوال امیرکروړ شهیدزی^۲

^{۱،۲}دپارتمنت کمپیوترساینس، پوهنځی کمپیوترساینس، پوهنتون کابل، کابل، افغانستان
ایمیل: bahrami.qarabagh@gmail.com

چکیده

دیتاکاوی تحصیلی دیتاهای خام سیستم‌های تحصیلی را به اطلاعات مفیدی تبدیل می‌کند که به‌طور بالقوه می‌تواند تأثیر بیشتری بر عمل‌کرد تحقیقاتی و تحصیلی داشته باشد. بنابراین، سؤال این است که چگونه یک پوهنتون می‌تواند از قدرت این دیتاهای تحصیلی برای استفاده در استراتژی‌یک خود استفاده کند؟ برای یافتن پاسخ، این مقاله بر مطالعه‌ی تطبیقی الگوریتم‌های کلستریندی به‌عنوان کاربرد در دیتاکاوی تحصیلی تمرکز می‌کند. روش‌های مبتنی بر پارتیشن (K-Means)، مبتنی بر چگالی (DBSCAN) و سلسله‌مراتبی (BIRCH) را مقایسه کرده است تا تعیین کند که کدام تکنیک برای انجام تحلیل‌های کلستریندی در محیط تحصیلی مناسب‌تر است. مطالعات نشان می‌دهد که الگوریتم K-Means مبتنی بر طبقه‌بندی بهتر از الگوریتم BIRCH سلسله‌مراتبی و الگوریتم DBSCAN مبتنی بر چگالی عمل می‌کند.

اصطلاحات کلیدی: دیتاکاوی تحصیلی؛ کلستریندی؛ الگوریتم؛ تکنیک؛ دیتاکاوی

Comparative Study of Clustering Algorithms in the Context of Education Data Mining

Jr. Teaching Asstt. Ahmad Zia Bahrami¹ and Associate Prof. Amir Kror Shahidzay²

^{1,2}Department of Computer Science, Faculty of Computer Science, Kabul University,
Kabul, Afghanistan

Email: bahrami.qarabagh@gmail.com

Abstract

Educational data mining turns raw data in education systems into useful information that could potentially have a greater impact on research and academic performance. So, the question is how a university can harness the power of this academic data for its strategic use. To find the answer, this paper focuses on a comparative study of clustering algorithms as an application in academic data mining. Compares partition-based (K-Means), density-based (DBSCAN), and hierarchical (BIRCH) methods to determine which technique is best suited for performing clustering analysis in an educational setting. Studies show that the classification-based K-Means algorithm performs better than the hierarchical BIRCH algorithm and the density-based DBSCAN algorithm.

Keywords: EDM; Clustering; Algorithm; Technique; Data Mining

مقدمه

در دهه‌ی گذشته، در نتیجه‌ی افزایش مؤسسات تحصیلات عالی، تعداد محصلان لیسانس و ماستری افزایش یافته است. بسیاری از پوهنتون‌ها در روش تدریس یا برگزاری امتحانات تغییراتی ایجاد کرده اند؛ اما هم‌چنان با مشکلات بیکاری و ترک تحصیل مواجه هستند. درک عوامل عمل‌کرد پایین یا افزایش نرخ ترک تحصیل، کار دشواری است که شامل عمل‌کرد گذشته و حال محصلان و سوابق رشته‌ی آن‌ها می‌شود. دیتاکاوی تحصیلی EDM یکی از آن ابزارهای قدرت‌مند برای تجزیه و تحلیل و پیش‌بینی رفتار و عمل‌کرد آینده‌ی محصلان است (۱)

اگرچه مؤسسات تحصیلات عالی / پوهنتون‌ها دیتابیس‌های معلوماتی تحصیلی خوبی دارند؛ اما در هیچ تصمیم‌گیری برای افزایش عمل‌کرد محصلان یا کاهش نرخ ترک تحصیل یا بیکاری از آن‌ها استفاده نمی‌شود. هدف EDM کشف روش‌هایی برای پیشرفت تحصیل و کارآیی محصلان با کاهش نرخ ترک تحصیل آن‌هاست. EDM از کلستربندی و طبقه‌بندی پیش‌پردازش شده برای استخراج دیتا استفاده می‌کند. کلستربندی روشی بدون نظارت برای بررسی معلومات است. این شامل گروپ‌بندی دیتاهای مشابه برای تشکیل یک کلستر یا یک گروپ است. بهترین الگوریتم‌های کلستربندی آن‌هایی در نظر گرفته می‌شوند که اقلام دیتا در همان کلستر بیشترین شباهت را داشته باشند و اقلام دیتا متعلق به کلسترهای مختلف حداقل یا اصلاً دارای شباهت نباشند (۲).

طبقه‌بندی یک روی‌کرد تحت نظارت یادگیری است که مبتنی بر استفاده از نتایج شناخته شده و پیش‌بینی نتایج آینده بر اساس محدودیت‌های داده شده است. EDM با استفاده از الگوریتم‌های طبقه‌بندی، زمینه‌های مختلف پیش‌بینی برای اثربخشی سازمانی را دارد. موفقیت الگوریتم‌های طبقه‌بندی به میزان متفاوت بودن دیتاهای ارائه شده و بسیاری از عوامل دیگر بستگی دارد.

پوهنتون‌ها باید بین خود جلسه بگذارند و دلایل رایج عمل‌کرد پایین محصلان و ترک تحصیل آن‌ها را شناسایی کنند تا بتوانند عمل‌کرد و رفتار محصلان را پیش‌بینی کنند که در نهایت به محصلان و مؤسسات کمک خواهد کرد، تا بتوانند نقاط ضعف خود را بشناسند و از قبل اقداماتی را انجام دهند. این کار به نفع همه شرکت‌کنندگان مؤسسات تحصیلات عالی / پوهنتون‌ها، مدیریت، استادان، محصلان و والدین می‌شود. استادان می‌توانند در مورد مواد درسی و لکچرهای خود برنامه‌ریزی کنند و می‌توانند به چنین محصلان توصیه کنند که عمل‌کرد بهتری داشته باشند. محصلان می‌توانند روی مشکلات خود کار کنند و برای بهبود آن از استادان مشوره بگیرند. والدین می‌توانند از

عمل کرد بهتر فرزندان خود در چنین راهنمایی‌ها مطمئن باشند. مدیریت می‌تواند امکانات بهتری را هم برای استادان و هم برای محصلان فراهم کند.

پیشینه‌ی تحقیق

تجزیه و تحلیل کلاستر بندی یکی از تکنیک‌های مورد استفاده در دیتاکاوی است و شامل تقسیم مجموعه‌یی از اشیای دیتا به زیر مجموعه‌ها است. این زیرمجموعه‌ها یا کلاسترها برای سازمان‌دهی اشیا به‌گونه‌یی استفاده می‌شوند که هر شیء درون یک کلاستر مشابه یک‌دیگر باشند، اما با اشیایی که متعلق به کلاسترهای دیگر هستند، متفاوت باشند (۳). تجزیه و تحلیل کلاستر بندی می‌تواند گروپ‌های محصلان را با الگوهای استفاده‌ی مشابه برای بهبود عمل کرد سایر انواع تحلیل در محیط‌های تحصیلی شناسایی کند (۴). بازخورد و تعامل گروپ را با استفاده از تحلیل کلاستر بندی برای ارائه اطلاعات هدف‌مند بر اساس شباهت‌های استفاده‌ی استخراج شده با کلاستر بندی و الگوکاوای متوالی به‌منظور بهبود سطح و کیفیت بازخورد بهبود می‌بخشد. حوزه‌ی تحقیقی دیتاکاوی تحصیلی (EDM) بر کاربرد تکنیک‌ها و روش‌های دیتاکاوی در محیط‌های تحصیلی متمرکز است. EDM به توسعه، تحقیق و به‌کارگیری روش‌های یادگیری ماشین، دیتاکاوی و احصائوی برای شناسایی الگوهای در مجموعه‌های بزرگ دیتاهای تحصیلی که در غیر این صورت تجزیه و تحلیل آن‌ها غیرممکن است، می‌پردازد (۵).

این بخش، انواع مختلف کلاستر بندی را برجسته می‌کند و انتخاب الگوریتم‌های مورد استفاده برای نمایش هر یک از روش‌های شناسایی شده را توجیه می‌کند.

تکنیک کلاستر بندی


کلاستر بندی یکی از تکنیک‌های پرکاربرد در دیتاکاوی و یک تکنیک یادگیری بدون نظارت است. کلاستر بندی تقسیم دیتاها به گروپ‌های دارای اشیای مشابه است. هر گروپی که کلاستر نامیده می‌شود، شامل اشیایی است که باهم متفاوت از اشیای گروپ‌های دیگر هستند. انواع مختلف الگوریتم‌های کلاستر بندی را می‌توان در ۳ گروپ، کلاستر بندی سلسله‌مراتبی، پارتیشن بندی و کلاستر بندی مبتنی بر تراکم تقسیم بندی نمود.

۱. روش‌های پارتیشن بندی: الگوریتم‌های پارتیشن بندی تلاش خواهند کرد n شیء را در k پارتیشن‌های مشخص گروپ بندی کنند ($k \leq n$) که در آن هر پارتیشن (زیر گروپ) یک کلاستر را نشان می‌دهد به طوری که اشیاء درون یک کلاستر با یک‌دیگر "شبه" و با اشیاء در کلاستر

دیگر "متفاوت" هستند. هرکلیستر را می‌توان با یک مرکز نمایش داد که می‌تواند اشیایی در مجموعه‌ی دیتا (k -Medoid) باشد که در شکل ۱ نشان داده شده است.

۲. **روش‌های سلسله‌مراتبی:** تکنیک کلیستربندی سلسله‌مراتبی یکی از تکنیک‌های پرکاربرد در کلیستربندی سلسله‌مراتبی فاصله‌ی جفت‌ها را از یک‌دیگر محاسبه و سپس کلیسترهای مشابه را به روش پایین به بالا، بدون نیاز به تأمین تعداد کلیسترها ادغام می‌کند. کلیستربندی سلسله‌مراتبی یک درخت از کلیسترها می‌سازد که به‌عنوان دندروگرام شناخته می‌شود. هر نمود کلیستر، شامل چند کلیستر فرزند است.

۳. **کلیستربندی مبتنی بر تراکم:** این روش از تراکم‌های محلی برای تعیین نحوه‌ی گروپ‌بندی اشیاء برای ایجاد کلیسترها استفاده می‌کند. این تراکم‌های محلی که به‌عنوان همسایگی‌ها نامیده می‌شوند، امکان شناسایی کلیسترهایی از اشکال دل‌خواه را فراهم می‌کنند. همان‌طور که در شکل ۱ نشان داده شده است، در مقایسه با شکل‌های بیضی و محدب روش‌های تقسیم‌بندی که صرفاً به فاصله بین اشیاء در داخل متکی هستند.



شکل ۱: خانواده الگوریتم‌های کلیستربندی (۱)

الگوریتم‌های کلیستربندی

کلیستربندی K-Means

در این الگوریتم دیتا را به K کلیستر مجزا تقسیم کنیم. این الگوریتم به دو فاز مجزا تقسیم می‌شود. فاز اول برای هر کلیستر یک نقطه را به‌عنوان نقطه‌ی ثقل کلیستر یا نقطه‌ی مرکزی کلیستر به دست می‌آوریم. در فاز بعدی به دست می‌آوریم که هر نقطه از مجموعه، به کدام مرکز کلیستر نزدیک‌تر است و آن نقطه

را به کلاستر مربوطه نسبت می دهیم، در حالت کلی برای به دست آوردن فاصله بین نقاط دیتا و مراکز کلاسترها از فاصله ی اقلیدسی استفاده می شود. زمانی که تمام نقاط در کلاسترها قرار گرفتند، مرحله ی اول به اتمام رسیده و کلاستربندی اولیه انجام شده است. سپس دوباره برای کلاسترها مراکز جدید به دست می آوریم و فاصله ی هر نقطه را نسبت به این نقاط مرکزی اندازه می گیریم تا کلاسترها آپدیت شوند و این کار تا زمانی ادامه پیدا می کند که کلاسترها همگرا شوند.

اما مشکل عمده یی این الگوریتم این است که با توجه به مقدار مراکز اولیه کلاسترهای متفاوتی تولید می شود و در نتیجه کیفیت کلاسترهای نهایی شدیداً به انتخاب مراکز اولیه کلاسترها وابسته است. این الگوریتم از لحاظ محاسباتی گران و متناسب با تعداد نقاط، تعداد کلاسترها و تعداد تکرارها نیاز به زمان دارد. مرکز برای الگوریتم K-Means به عنوان مقدار اوسط در فضای دیتا محاسبه شده از مقادیر ویژگی اشیای درون کلاستر نشان داده می شود.

درحالی که الگوریتم های تقسیم بندی دیگر مانند Partitioning Around Medoids وجود دارد که از یک شی واقعی در فضای شی به عنوان مرکز استفاده می کند و Clustering Large Applications (Ng & Han 2002) based upon Randomized Search از ویژگی های فضایی اشیاء استفاده می کند که تجزیه و تحلیل نه تنها اشیای نقطه یی بلکه اشیای مبتنی بر چندضلعی پیچیده تر را تسهیل می کند.

کلاستربندی BIRCH

الگوریتم کلاستربندی BIRCH یکی از الگوریتم های مطرح در کلاستربندی سلسله مراتبی است. این روش با کمک تکنیک کلاستربندی سلسله مراتبی و تکنیک دیگر (معمولاً k-means) برای کاربر روی دیتاهای عددی با حجم بالا طراحی شده است. این الگوریتم از ویژگی کلاستر یا به اختصار CF جهت انجام کلاستربندی استفاده می کند و همین امر سبب شده تا الگوریتم از سرعت و قابلیت مقیاس پذیری بالایی برخوردار باشد. ویژگی کلاستر، یک روش خلاصه سازی اطلاعات است که نقاط دیتا برای هر زیر کلاستر را نگهداری می نماید. الگوریتم BIRCH از درخت متوازن استفاده می شود. درخت متوازن CFها را جهت اجرای الگوریتم ذخیره می کند. هر گروپ از این درخت که دارای گره فرزند است، در خود مجموع CFهای فرزندانش نگهداری می نماید. بدین ترتیب اطلاعات خلاصه شده یی از فرزندان خود را خواهد داشت. درخت دارای دو پارامتر به نام های فاکتور کلاستربندی B واحد آستانه T است. حد اکثر تعداد فرزندان گره های غیر پایانی با فاکتور کلاستربندی B مشخص می شوند و حد آستانه T به حداکثر فاصله یی که میان دو نمونه از کلاسترهای برگ قرار دارد، اطلاق می شود.

پس از درج و یا حذف یک CF در درخت و یا در صورت افزایش مقادیر B و T از مقدار تعیین شده توسط کاربر، گره‌های درخت متوازن تقسیم و یا ادغام می‌شوند. واضح است که مقادیر B و T در اندازه‌ی درخت تولیدشده نهایی، نقش به‌سزایی ایفا می‌کند.

کلستر بندی DBSCAN

الگوریتم Density-based spatial clustering of applications with noise به اختصار DBSCAN به معنای کلستر بندی بر اساس تراکم فضایی از کاربرد با نویز، نوعی از کلستر بندی است که در سال ۱۹۹۶ توسط مارتین استر و همکاران پای به عرصه وجود نهاد. همان طوری که از نام این الگوریتم پیدا است، این الگوریتم بر مبنای الگوریتم بر تراکم نقاط دیتا استوار است؛ به این معنا که نقاط دیتا در هر کجای فضا دارای بیشترین تراکم باشد، آن‌ها را به عنوان یک کلستر در نظر می‌گیرد.

در الگوریتم DBSCAN نیز مجموعه‌یی از نقاط در برخی فضاها، نقاط با همسایگان مجاور خود به عنوان یک گروه دسته بندی می‌شوند و تنها در مناطقی که دارای کمترین تراکم اند (که از همسایگی بسیار دور هستند)، به عنوان دیتاهای خارج از محدوده آن‌ها را حساب می‌کند. برخلاف بسیاری از روش‌های کلستر بندی، DBSCAN نسبت به شکل دیتا حساس نیست و می‌تواند دیتا شکل‌های بسیار پیچیده را نیز گروه بندی کند.

استفاده از کلستر بندی در دیتا کاوی تحصیلی

این بخش یک نمای کلی از تجزیه و تحلیل کلستر بندی در زمینه‌ی تحصیلی ارائه می‌دهد. ما چندین نشریه را از سال ۲۰۱۱ تا ۲۰۱۹ بررسی کردیم و تحقیقات خویش را بر اساس هدف و الگوریتم‌های مورد استفاده سازماندهی نمودیم. هدف این است که این تحقیق بینش‌های ارزشمندی را در باره‌ی این که چطور می‌توانیم از تجزیه و تحلیل کلستر بندی در محیط تحصیلی استفاده نماییم، ارائه می‌دهد.

جدول ۱: بررسی تحلیل کلستریندی در تعلیم و تربیه از سال ۲۰۱۱ تا ۲۰۲۰

نوی سنده	هدف	الگوریتم
(6)	طبقه بندی	K-Means
(7)	ارزیابی	K-Means
(4)	ارزیابی	EM
(8)	ارزیابی	Hierarchical EM, X-Means, K-Means,
(9)	ارزیابی	Ward, K-Means
(5)	ارزیابی	K-Means
(10)	طبقه بندی	K-Means, X-Means, EM, Hierarchical
(11)	ارزیابی	K-Means
(3)	طبقه بندی	SOM, Fuzzy Clustering K-Means,
(12)	طبقه بندی	Unknown
(13)	طبقه بندی	K-Means
(14)	اکتشاف	K-Means
(15)	اکتشاف	K-Means
(16)	اکتشاف	clustering K-Means, Fuzzy

کلستریندی در تعلیم و تربیه به طور گسترده توسط تعدادی از نویسندگان بررسی شده و در جدول ۱ خلاصه شده است. در جدول ۱ اهداف مختلفی را که تجزیه و تحلیل کلستریندی برای آن‌ها به کار گرفته شده است و در صورت وجود، الگوریتمی را که برای تجزیه و تحلیل واقعی استفاده می‌شود، برجسته شده است. در این جدول، هدف تجزیه و تحلیل را به سه دسته طبقه بندی، ارزیابی و اکتشاف گروپ بندی شده است. گروپ طبقه بندی با استفاده از الگوریتم‌های کلستریندی برای فورمول بندی مدل‌هایی اشاره دارد که می‌توانند متعاقباً برای کارهای طبقه بندی مانند پیش‌بینی مورد استفاده قرار گیرند. گروپ ارزشیابی به استفاده از تکنیک‌های کلستریندی برای ایجاد گروپ‌ها به منظور دستیابی به درک بهتر از رفتارهای کاربران و محتوا در محیط تحصیلی اشاره دارد. اکتشاف از تکنیک‌های کلستریندی برای ارائه بلوک ساختمانی برای تجزیه و تحلیل بیشتر دیتاها استفاده می‌کند. ممکن است برای تجزیه و تحلیل کلستریندی بعدی یا ورودی به سایر تکنیک‌های تجزیه و تحلیل باشد.

با استفاده از این جدول، می‌توانیم تعدادی روند جالب را یادداشت کنیم. اولاً، الگوریتم K-Means یک انتخاب محبوب برای انجام تجزیه و تحلیل کلستریندی در بین نویسندگان باقی مانده است. همان‌طور که انتظار می‌رود، اکثر مطالعات از تجزیه و تحلیل کلستریندی برای ارزیابی استفاده می‌کنند، با این حال بیست درصد (۲۰٪) از کلستریندی برای ایجاد مدل‌هایی برای کاوش بیشتر استفاده می‌کنند و سی و شش درصد (۳۶٪) از آن به عنوان مبنایی برای طبقه بندی بعدی استفاده می‌کنند. درحالی‌که

برخی از نویسندگان به تنهایی از تجزیه و تحلیل کلاستر بندی استفاده می‌کنند، تعدادی از نویسندگان مانند Campagni و همکاران، (۲۰۱۵)، از تکنیک‌های کلاستر بندی در ارتباط با الگوهای متوالی یا سایر الگوهای غیر مرتبط برای استخراج اطلاعات استفاده می‌کنند.

یکی از مشاهدات جالب بررسی مقالات این است که بسیاری از نویسندگان پیشنهاد می‌کنند که برای تعمیم نتایج به دست آمده از آزمایش‌های شان، نیاز به آزمایش نتایج در سطح مقطع وسیع‌تری از دروس وجود دارد. آن‌ها هم چنین نشان دادند که تعداد صفات رابطه‌ی قوی با دقت الگوریتم‌ها دارد. برخی از عمل‌کرد الگوریتم هنگام حذف ویژگی‌ها کاهش می‌یابد.

نتیجه‌گیری

تجزیه و تحلیل کلاستر بندی به ویژه در طول ارزیابی و تجزیه و تحلیل دیتاهای اکتشافی مهم است. جایی که محققان تلاش می‌کنند روندهای اساسی را که بدون دانش قبلی در مورد دیتاهای تولید شده در مؤسسات تحصیلات عالی / پوهنتون‌ها وجود دارد، کشف کنند. با این حال، انتخاب تکنیک و الگوریتم کلاستر بندی با دانش ساختار دیتا، انواع تحلیل‌هایی که باید ترسیم شوند و اندازه‌ی مجموعه دیتای ارزیابی شده تعیین می‌شود. بررسی ما از تجزیه و تحلیل کلاستر بندی در تحصیلات در جدول ۱ نشان می‌دهد که اکثر مقالات تحقیقی از کلاستر بندی برای ارزیابی و اکتشاف استفاده کرده‌اند و در بسیاری از موارد فقط از الگوریتم K-Means استفاده شده است. هدف این مطالعه گسترش دانش در مورد عمل‌کرد الگوریتم‌های کلاستر بندی با در نظر گرفتن یک تحلیل مبتنی بر موردی از عمل‌کرد تطبیقی در بین دسته‌های تکنیک کلاستر بندی است.

برای به دست آوردن بینشی در مورد این که چگونه تجزیه و تحلیل کلاستر بندی می‌تواند در دوره‌های مختلف انجام شود، عمل‌کرد سه الگوریتم نماینده در اندازه‌های مختلف مجموعه دیتاها مورد ارزیابی قرار گرفت.

نتایج تجربی تأیید کرد که الگوریتم K-Means مبتنی بر طبقه بندی بهتر از الگوریتم BIRCH سلسله‌مراتبی و الگوریتم DBSCAN مبتنی بر تراکم عمل‌کرد. کلاسترهایی با ضرایب بالاتر نسبت به دو الگوریتم دیگر برای مجموعه دیتاهای ۲ بُعدی و ۷ بُعدی تولید می‌کند. بنابراین، روش‌های مبتنی بر طبقه بندی را می‌توان مناسب‌ترین تکنیک برای انجام تحلیل کلاستر بندی دیتاهای محیط تحصیلی دانست. عمل‌کرد خوب روش مبتنی بر طبقه بندی و عمل‌کرد نسبتاً پایین روش مبتنی بر تراکم نشان می‌دهد که دیتاهای تولید شده توسط گزارش‌های مؤسسات تحصیلات عالی، تمایل به تشکیل

گروپ‌هایی در اطراف مرکز (نقطه یا شی) دارند و تجزیه و تحلیل با استفاده از این فرض در برخی از موارد، نتایج مفیدتر برای تحلیل اکتشافی گروپ‌بندی‌ها را تولید می‌کند.

عمل‌کرد جالب الگوریتم BIRCH نیاز به بررسی این امکان، اشاره دارد که ممکن است ساختارهای سلسله‌مراتبی در دیتاهای گزارش تحصیلی وجود داشته باشد. درک این سلسله‌مراتب ممکن بینش جالبی برای درک روابط موجود بین ابعاد مختلف و تعامل کاربر در تحصیل ارائه دهد.

- (1) Martins MPG, Miguéis VL, Fonseca DSB. Data Mining Educacional: Uma Revisão da Literatura Educational Data Mining: A Literature Review (Internet]. Available from: www.educationaldatamining.org.
- (2) Liu Y, Li Z, Xiong H, Gao X, Wu J. Understanding of internal clustering validation measures. In: Proceedings - IEEE International Conference on Data Mining, ICDM. 2010. pp. 911–6.
- (3) Mamdouh Fouad M, Yu PS, Fattah Mashat A, Fouad MM, Arabia Tarek Gharib SF. Efficient Clustering Technique for University Admission Data [Internet]. Vol. 45, International Journal of Computer Applications. 2012. Available from: <https://www.researchgate.net/publication/235333407>
- (4) Bogarín A, Romero C, Cerezo R, Sánchez-Santillán M. Clustering for improving Educational process mining. In: ACM International Conference Proceeding Series. Association for Computing Machinery; 2014. pp. 11–5.
- (5) Dutt A, Ismail MA, Herawan T. A Systematic Review on Educational Data Mining. Vol. 5, IEEE Access. Institute of Electrical and Electronics Engineers Inc.; 2017. pp. 15991–6005.
- (6) Harwati, Alfiani AP, Wulandari FA. Mapping Student's Performance Based on Data Mining Approach (A Case Study). Agriculture and Agricultural Science Procedia. 2015; 3:173–7.
- (7) Campagni R, Merlini D, Sprugnoli R, Verri MC. Data mining models for student careers. Expert Systems with Applications. 2015 Aug 1; 42(13):5508–21.
- (8) Liu Y, Li Z, Xiong H, Gao X, Wu J, Wu S. Understanding and enhancement of internal clustering validation measures. IEEE Transactions on Cybernetics. 2013 Jun; 43(3): 982–94.
- (9) Ghorpade-Aher J, Metre VA. PSO based Multidimensional Data Clustering: A Survey. Vol. 87, International Journal of Computer Applications. 2014.
- (10) López MI, Luna JM, Romero C, Ventura S. Classification via clustering for predicting final marks based on student participation in forums.
- (11) El-Halees A, Tair MMA, El-Halees AM. Mining Educational Data to Improve Students' Performance: A Case Study Cite this paper Mining Educational Data to Improve Students' Performance: A Case Study. 2012; 2(2). Available from: <http://www.esjournals.org>.
- (12) DeFreitas K, Bernard M. COMPARATIVE PERFORMANCE ANALYSIS OF CLUSTERING TECHNIQUES IN EDUCATIONAL DATA MINING. IADIS International Journal on Computer Science and Information Systems. 10(2): 65–78.
- (13) Durairaj M, Vijitha C. Educational Data mining for Prediction of Student Performance Using Clustering Algorithms [Internet]. Available from: www.ijcsit.com.
- (14) Peña-Ayala A. Educational data mining: A survey and a data mining-based analysis of recent works. Vol. 41, Expert Systems with Applications. 2014. pp. 1432–62.
- (15) Romero C, Ventura S. Educational data science in massive open online courses. Vol. 7, Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery. Wiley-Blackwell; 2017.
- (16) Romero C, Ventura S. Educational data mining and learning analytics: An updated survey. Wiley Interdisciplinary Reviews: Data Mining