

M-Cluster: Uma ferramenta de Recomendação para Formação de Grupos em Ambientes Virtuais de Aprendizagem

Ilmara M. M. Ramos^{1,2}, David B. Ramos^{1,2}, Priscilla B. Nascimento¹, Geovana de Souza Amaral¹, Bruno Gadelha¹, Elaine H. T. Oliveira¹

¹Instituto de Computação – Universidade Federal do Amazonas (UFAM) – Manaus – AM – Brasil.

²Instituto Federal de Educação, Ciência e Tecnologia do Amazonas (IFAM) – Campus Parintins – Parintins – AM – Brasil.

{ilmaramonteverde, david.ramos,
priscilla.batista,bruno,elaine}@icomp.ufam.edu.br,
gsamaral05@gmail.com

***Abstract.** Groups are a basic social structure that form and change themselves for multiple purposes. Often it is necessary to organize groups of students to carry out activities. This paper presents the M-Cluster, a tool that suggests groups for performing collaborative activities in Virtual Learning Environments. It uses the K-Means algorithm, coupled with three similarity metrics, along with the attributes obtained from the Learning Path. The M-Cluster presents three solutions, descriptively or visually, to the teacher who chooses the most appropriate for each case. The results of the case study show that the tool is promising, improving the performance of up to 75% of the students.*

***Resumo.** Grupos são uma estrutura social básica que se formam e se modificam para múltiplos propósitos. Muitas vezes é necessário organizar grupos de discentes para realizar atividades. Este artigo apresenta a ferramenta M-Cluster que sugere grupos para a realização de atividades colaborativas em Ambientes Virtuais de Aprendizagem. Ela utiliza o algoritmo K-Means, associado a três métricas de similaridade, juntamente com os atributos obtidos das Trilhas de Aprendizagem. O M-Cluster apresenta três soluções, de forma descritiva ou visual, ao professor que escolhe a mais adequada para cada caso. Os resultados do estudo de caso mostram que a ferramenta é promissora, melhorando o desempenho de até 75% dos alunos.*

1. Introdução

Grupos são pequenos conjuntos de indivíduos que se reúnem em torno de uma determinada peculiaridade [Santos, Castro e Castro 2007]. Enquanto estudantes formam grupos facilmente no ambiente externo da sala de aula, formar grupos em um curso pode ser um processo não natural. Contudo, para que a aprendizagem colaborativa seja bem-sucedida, é importante formar grupos que possam ser efetivos e eficientes em realizar os objetivos da tarefa. Nesse sentido, busca-se melhorar as interações dos alunos principalmente em atividades em grupo. O trabalho em grupo é um recurso bastante

utilizado pelo docente, com o intuito de incentivar a interação dos alunos nas atividades colaborativas e contribuir para construção coletiva do conhecimento.

De acordo com Lima *et al.* [2014] os Ambientes Virtuais de Aprendizagem (AVAs) não possuem ferramentas suficientes para ajudar o docente a detectar as relações sociais entre os alunos, impedindo assim a identificação de grupos. Além disso, existe nos AVAs uma deficiência em dar suporte à criação de grupos. Nesse sentido, as Trilhas de Aprendizagem (TAs) são recursos para sugerir grupos de alunos. No contexto deste artigo, uma TA representa a trajetória percorrida pelo aluno durante a sua interação com o AVA sendo representada na forma de grafo, Ramos *et al.* [2015]. O uso de TAs é promissor porque mostra os caminhos percorridos pelos alunos nos AVAs, o que possibilita sugerir grupos baseados nessas interações dado que formar grupos na modalidade EAD é realmente uma tarefa desafiadora para o docente. No geral, nessa modalidade, os alunos só possuem 20% do contato presencial entre si e com o docente, dificultando estabelecer critérios para realizar os agrupamentos. Diante deste contexto, neste artigo é apresentada a ferramenta *Moodle Cluster* (M-Cluster) para formação de grupos em atividades colaborativas, por meio dos dados extraídos das TAs propostas por Ramos *et al.* [2016], para auxiliar o docente no processo de ensino-aprendizagem. O mecanismo dá ênfase à formação dos grupos aplicando o algoritmo *K-Means* MacQueen [1967], que é utilizado com três métricas de similaridade, que são as distâncias: Euclidiana, *Manhattan* e Cosseno, usando os atributos mais relevantes do aluno (média de acesso de vértices, quantidade, dispersão e variâncias das arestas padrão, avanço e retorno) obtidos dos dados extraídos das TAs. Este artigo está estruturado da seguinte forma: na Seção 2 serão discutidos os trabalhos relacionados. A Seção 3 apresenta a metodologia utilizada e a Seção 4 descreve a ferramenta proposta. Na Seção 5 estão os resultados do uso da ferramenta em um ambiente real. Finalmente, a Seção 6 apresenta a conclusão.

2. Trabalhos Relacionados

Os trabalhos a seguir apresentam um panorama das diferentes formas de agrupamento de alunos em AVAs. Eles fazem parte do resultado da Revisão Sistemática da Literatura, já publicado em Ramos *et al.* [2016] e mostram também que muitas técnicas diferentes podem ser aplicadas. A seguir, são descritos os trabalhos mais similares ao trabalho proposto.

O trabalho apresentado por Jagadish [2014] descreve a formação de grupos de alunos por meio da aprendizagem colaborativa utilizando a plataforma Moodle. O algoritmo KNN (*K-Nearest Neighbor*) foi utilizado para realizar a formação dos grupos. Essa pesquisa usa o chat da plataforma para realizar as interações entre os alunos, possibilitando extrair dados sobre as preferências dos usuários por meio dos *logs* de acesso do Moodle. A coleta implícita de informações é utilizada para classificar os perfis dos alunos por meio do algoritmo KNN. Ainda na fase de coleta de dados, também foi empregado o preenchimento de questionários para a obtenção de traços de personalidade e estilos de aprendizagem dos alunos. A pesquisa de Abnar, Orooji e Taghiyareh [2012] propõe um processo interativo com base em algoritmo genético e escala de Likert. O algoritmo é flexível para o número e o tipo dos atributos. Para diferentes contextos, conjuntos diferentes de atributos podem ser usados para formar grupos de aprendizagem. Na verdade, o professor tem a possibilidade de escolher um

conjunto diferente de atributos e classificá-los com base em seu impacto sobre a formação de grupos. Além disso, o modelo de estilo de aprendizagem de Felder-Silverman [Felder e Silverman 1988] e grafos são utilizados também para representação dos atributos. Essa abordagem permite que o professor adicione, selecione e classifique as características de construção do grupo, criar grupos, e avaliar a formação dos aprendizes após a realização de atividade. O estudo proposto por [Yathongchai *et al.* 2013], aborda o agrupamento de alunos na plataforma Moodle usando as técnicas de árvore de decisão, mineração de dados e índice de Hartigan considerando duas etapas principais: 1) Aplicar o algoritmo de agrupamento *K-Means* para analisar o comportamento de aprendizagem de cada aluno, com base no perfil gerado por meio dos *logs* de acesso do Moodle. Como resultado, temos quatro grupos apropriados que são criados com base no perfil dos alunos; 2) Aplicação de um classificador de árvore de decisão para gerar o modelo de classificação do aluno, baseado em seus comportamentos e desempenho por meio de suas notas. O ambiente virtual utilizado foi o Moodle. O artigo de Daradoumis *et al.* [2013] relata a formação de grupos, como uma dinâmica no processo colaborativo onde os alunos devem se conhecer em um ambiente informal, para começar a desenvolver relacionamentos, avaliar e aprender uns com os outros, antes de realizarem atividades no AVA, permitindo a eficácia do grupo posteriormente. Neste contexto, a pesquisa menciona princípios básicos do ciclo de vida do grupo. Para implementá-lo, o autor propõe um regime de quatro fases: proposta de grupo, negociação, introdução e iniciação, que consiste de processos bem definidos cujo objetivo é envolver os alunos em atividades que irão levar à criação do bom funcionamento dos grupos de alunos.

Quadro 1 - Trabalhos Relacionados

	Tipo de Coleta de Dados	Usado com Moodle	Fonte dos dados	Técnicas usadas para formar os grupos
(DARADOUMIS <i>et al.</i>, 2002)	Explícito	Não	Questionário	Raciocínio Baseado em Casos
(JAGADISH, 2014)	Explícito	Sim	Questionário	Algoritmo <i>KNN (k-Nearest Neighbor)</i>
(ABNAR; OROOJI E TAGHIYAREH, 2012)	Implícito	Sim	<i>Logs(-)</i>	Algoritmo genético
(YATHONGCHAI <i>et al.</i>, 2013)	Implícito	Sim	<i>Logs</i> (Frequência de login, tempo de download, etc..)	<i>K-Means</i> e <i>C4.5</i>
(MONTAZER; REZAEI, 2013)	Implícito	-	<i>Logs (-)</i>	<i>K-Means</i> e <i>C-Means Fuzzy</i>
Proposta de trabalho	Implícito	Sim	Dados das Trilhas de Aprendizagem	<i>K-Means</i>

A pesquisa de Montazer e Rezaei [2013] aborda a criação de um método híbrido de agrupamento que consiste na junção dos métodos *K-Means* e *Fuzzy C-means* [Bezdek 1981], este intitulado de *Hybrid Clustering Method* (HCM). Este método híbrido foi avaliado comparando com outros três métodos tradicionais: *K-Means*, *Fuzzy C-Means* e *Evolutionary Fuzzy C-means* [Le 1995]. A coleta de dados é realizada de forma implícita por meio dos *logs* de acesso da plataforma, sendo que os atributos utilizados não foram mencionados. É possível verificar, através do Quadro 1, o comparativo dos trabalhos similares relacionados ao contexto desta pesquisa. Campos com traço são dados que não puderam ser identificados nas publicações. Como visto anteriormente, os cinco trabalhos citados estão relacionados com esta proposta, sendo que as abordagens de Daradoumis *et al.* [2012] e Jagadish [2014], realizam a formação de grupos de forma explícita, já os trabalhos de Abnar, Orooji e Taghiyareh [2012], Yathongchai *et al.* [2013], Montazer e Rezaei [2013] formam os grupos de forma implícita. A maioria dessas pesquisas usam o Moodle e técnicas de mineração de dados ou raciocínio baseado em casos. As fontes de dados usadas para caracterizar os perfis dos alunos nas duas primeiras pesquisas foram os questionários e das três últimas, os *logs* de acessos extraídos da plataforma Moodle. Logo, essa pesquisa difere das apresentadas por considerar as TAs para a formação dos grupos dos aprendizes. Além disso, nos trabalhos citados, a técnica de mineração de dados mais utilizada foi do *K-Means* com uma única métrica de similaridade, alcançando um único resultado. Já nesta abordagem, é utilizado o algoritmo *K-Means* com três métricas de distâncias: Euclidiana, *Manhattan* e Cosseno, onde cada métrica apresenta um resultado, oferecendo ao docente três possibilidades de recomendação de grupos de alunos de forma automática. Mais detalhes sobre as sugestões de recomendações podem ser vistos na seção 4.

3. Metodologia

Foi realizada uma pesquisa bibliográfica por meio de uma Revisão Sistemática de Literatura (RSL) sobre recomendação de grupos para atividades colaborativas em ambientes virtuais. Tal revisão sistemática ocorreu por meio de consultas em bases de conhecimento científico, como: *Scopus* e *IEEE*. Na etapa seguinte, foram realizadas pesquisas sobre as métricas de similaridades e técnicas de mineração de dados. Tal estudo objetivou a obtenção de subsídios para extrair os dados dos grafos baseados nas trilhas de aprendizagem dos alunos e verificar a similaridade entre as amostras e, conseqüentemente, usar o *K-Means* para classifica-los. O passo posterior consistiu na identificação do cenário educacional correspondente à aprendizagem em grupo em um ambiente a distância. Nesta fase ocorreu uma pesquisa de campo, onde foram coletadas as informações de duas turmas fechadas da disciplina de Matemática Discreta do curso de Ciência e Engenharia da Computação no Moodle. As turmas são dos semestres de 2015/2 e 2016/1. Os dados foram analisados e posteriormente transformados em atributos sendo organizados para a realização dos experimentos iniciais de formação de grupos. Os atributos foram usados no ambiente Eclipse com a integração da *Application Programming Interface* (API) do *Waikato Environment for Knowledge Analysis* (WEKA) usando a linguagem de programação JAVA. O objetivo dessa análise foi de verificar como as TAs, baseadas em grafos, em conjunto com as métricas de similaridade e o *K-Means*, formariam o cenário de agrupamento dos alunos. Em seguida, foi desenvolvida uma ferramenta, o *Moodle Cluster* (*M-Cluster*), que analisa os

dados produzidos pelo passo anterior e sugere a formação dos grupos de acordo com a análise realizada. Após isso, foi realizada uma nova pesquisa de campo com uma turma real em andamento da disciplina Matemática Discreta dos cursos de Ciência da Computação do semestre de 2016/2. A ferramenta foi integrada ao Moodle em formato de *plugin*, onde foram analisados e validados os dados do passo anterior, buscando identificar a contribuição da abordagem proposta para a atividade docente. A seguir, será descrita a arquitetura do trabalho.

3.1.Arquitetura do Trabalho

A Figura 1 representa a arquitetura do *M-Cluster*. A ferramenta coleta as informações das interações dos usuários com o AVA, armazenada nos *logs* de acesso dos usuários na plataforma Moodle. Essa coleta de dados permite caracterizar os aprendizes ao compor o cenário das trilhas de aprendizagem (TA). As trilhas são representadas por estrutura de grafo, onde as arestas correspondem à navegação do usuário pelos recursos e atividades, e os vértices representam os próprios recursos/atividades. A partir dos grafos das TAs, foram extraídos os seguintes dados: identificação do aluno, média de acesso por vértice, além de quantidade, variância e dispersão de arestas de avanço, retorno e padrão, para compor os atributos a serem processados pelo algoritmo *K-Means*, utilizando as distâncias Euclidiana, Cosseno e *Manhattan*. Dessa forma, são obtidos três resultados de agrupamentos dos aprendizes, levando-se em consideração cada métrica usada. Esses resultados são exibidos ao professor com duas opções de representação: uma descritiva e uma visual por meio do gráfico de bolhas.

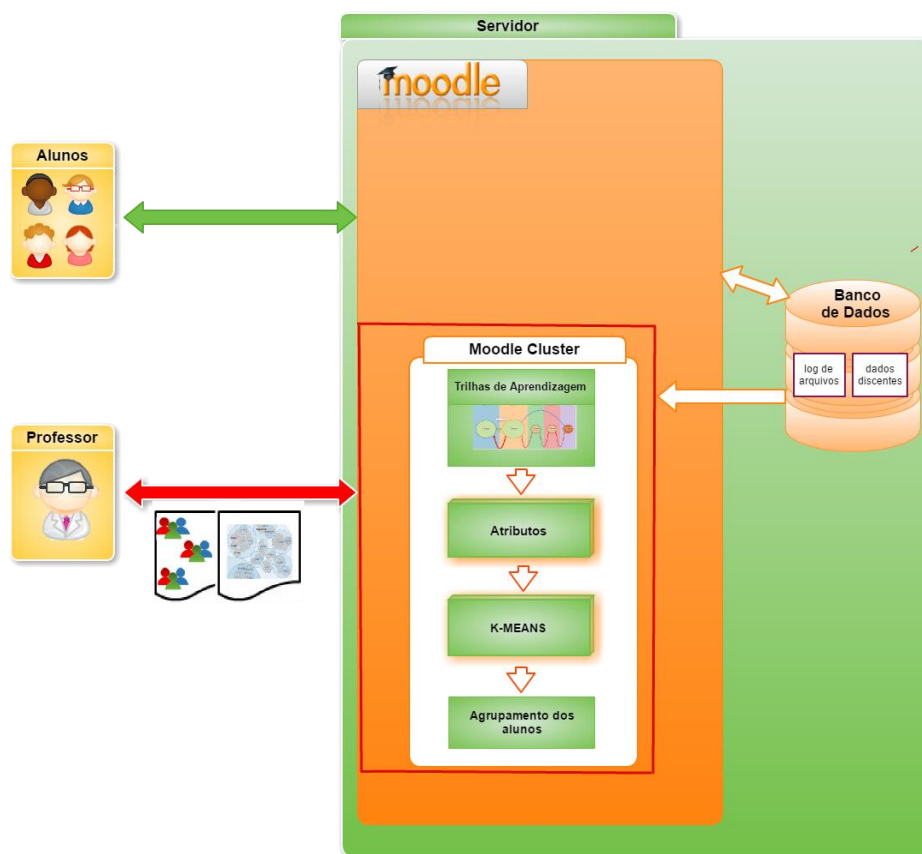


Figura 1. Arquitetura do M-Cluster

Ao final, o professor escolhe qual das representações deseja utilizar para obter as sugestões de recomendações dos grupos para realizar as atividades colaborativas de acordo com as trilhas de aprendizagem obtidas na disciplina. Os detalhes sobre a ferramenta estão descritos na seção a seguir.

4. A Ferramenta M-Cluster

A lógica da ferramenta foi dividida em três partes: a identificação das TAs, a partir dos dados do ambiente virtual onde foram coletadas todas as informações e transformadas no formato de grafo conforme descrito na seção 3.1 deste artigo; a partir disso, obteve-se uma lista de atributos relevantes para cada aluno (média de acesso de vértices, quantidade, dispersão e variância das arestas padrão, avanço e de retorno), obtidos das TAs. Estes atributos foram validados pelos professores especialistas; e apresentação das sugestões de agrupamento de forma descritiva ou visual.

O plugin *M-Cluster* constitui-se de um bloco que ao ser clicado abre a ferramenta do cluster de aprendizagem. No canto inferior esquerdo da Figura 2, é apresentado o bloco de acesso ao *M-Cluster* e ao centro está a tela principal do *M-Cluster* que está dividida em: seleção de grupos, tipo de exibição, seleção do número de clusteres, seleção dos dados, download de arquivo pdf e representação visual. Como visto na Figura 2, o professor/tutor escolhe os parâmetros necessários para que o algoritmo possa recomendar os grupos. Os parâmetros são descritos a seguir: Em seleção de grupos, deve-se selecionar um grupo (turma) que está inserido em uma determinada disciplina, que irá retornar os alunos do grupo no item Seleção de Dados. Caso não haja nenhum grupo, todos os alunos da disciplina são listados. Abaixo, encontra-se o Tipo de Exibição, onde é escolhida a forma de exibição dos clusteres, que pode ser apenas descritivo, ou em forma de gráfico de bolhas. Este último está exemplificado no item Representação Visual na Figura 2.

Em Seleção de Número de Clusteres, o professor/tutor seleciona a quantidade de número de clusteres que deseja, para que o algoritmo possa realizar a classificação de forma automática dos dados, de acordo com o parâmetro escolhido pelo docente. Em Seleção de Dados, o professor/tutor escolhe quais os alunos que ele deseja que faça parte da recomendação de grupos. Para isso, ele faz a seleção dos dados no campo usuário e, em seguida, clica no botão adicionar ao lado direito do campo. Com isso, os alunos escolhidos compõem o campo à direita Alunos para Recomendação, somente os alunos deste campo, serão analisados e classificados na ferramenta. Caso seja necessário remover um elemento deste campo, há o botão remover que retira o item que foi selecionado. Após as escolhas realizadas pelo professor/tutor dentro da ferramenta, o mesmo deve clicar no botão Sugerir Grupos na parte de Seleção de Dados. O processo de análise e classificação do algoritmo *K-Means* juntamente com as métricas de similaridade é realizado, e, em seguida, disponibilizado na tela a representação dos grupos de acordo opção escolhida, visual ou descritiva. Caso o professor/ tutor queira realizar o download em formato pdf da representação escolhida, o mesmo deve clicar no botão “download pdf”, para baixar o conteúdo contendo a descrição de todos os grupos recomendados pela ferramenta.

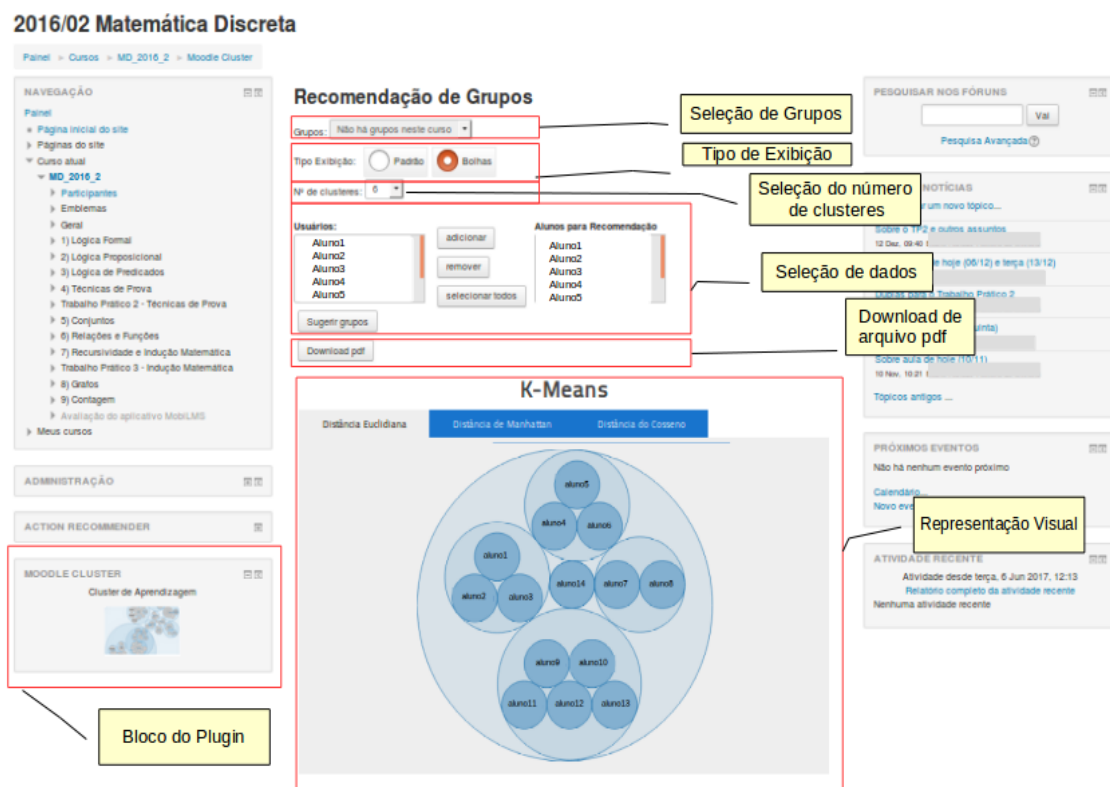


Figura 2. Parte da tela do M-Cluster

5. Validação Inicial e Resultados

Nesta seção, são descritos os testes realizados para validar o *M-Cluster* e os resultados que foram obtidos. Para validar a ferramenta, foi realizado um estudo de caso em uma turma real em andamento, da disciplina de Matemática Discreta, do ano de 2016/2, do curso de Ciência da Computação da UFAM, na modalidade semipresencial. Participaram do estudo de caso 40 alunos matriculados, um docente e um tutor. No estudo de caso, o *M-Cluster* utilizou os atributos relatados na seção 3.1 e os classificou com o *K-Means*, obtendo-se três resultados de agrupamentos homogêneos, um para cada métrica. O docente analisa e escolhe dentre as sugestões geradas pela ferramenta, qual opção será disponibilizada aos alunos. Para validar os grupos sugeridos, foram realizadas duas atividades, com o mesmo grau de dificuldade. Na primeira atividade, o docente solicitou que os alunos realizassem uma atividade em dupla, sendo que estes puderam escolher com quem gostariam de formar as mesmas e na segunda, o professor utilizou a ferramenta para obter uma sugestão de cluster, em que os alunos pudessem formar duplas. A opção escolhida foi de formar a sugestão com quatro clusters contendo grupos de 10 alunos cada. A partir desses parâmetros, a sugestão mais adequada conforme a visão do docente foi do algoritmo *K-Means* com a distância Euclidiana. Após a escolha da sugestão, o professor disponibilizou a mesma aos alunos no ColabWeb que é uma customização do Moodle utilizado pela UFAM. Ao disponibilizar os clusters aos alunos, os mesmos tiveram a orientação que só poderiam formar as duplas com os componentes que estivessem no mesmo cluster. Assim as duplas foram formadas e postadas no ColabWeb pelos alunos para o professor. Os resultados

mostraram que, de acordo com o docente especialista, a sugestão gerada pela ferramenta obteve resultados satisfatórios, onde 75% dos alunos igualaram ou melhoraram as suas notas individuais (essas adquiridas ao formar a dupla para executar as atividades) em relação às notas alcançadas na primeira atividade conforme pode ser visualizado na Figura 3. Foi constatado também, que do total de grupos formados, 30% destes formaram duplas idênticas a da primeira formação (os mesmos obtiveram bons resultados nas duas atividades). Esses resultados ainda não são conclusivos, mas já são um ponto de partida para análises futuras mais detalhadas.

Na Figura 3 pode-se visualizar as notas individuais dos alunos de Matemática Discreta. Os alunos desistentes foram excluídos do gráfico. Percebe-se que os 25% restantes dos alunos tiveram notas da atividade 2 aproximada ou superior à da atividade 1.

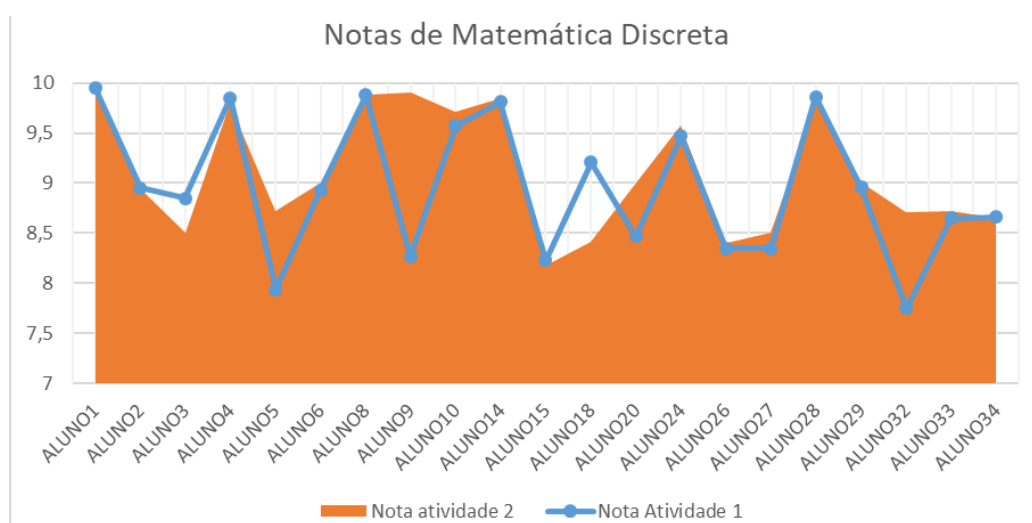


Figura 3. Notas dos alunos de Matemática Discreta

No estudo de caso a seguir, o professor solicitou cinco clusters e selecionou 14 alunos para que os mesmos fizessem em dupla uma determinada atividade. A seguir, as Figuras 4 e Figuras 5 apresentam as visualizações da forma descritiva e do gráfico de bolhas respectivamente, de uma das três soluções apresentadas pela ferramenta, de maneira que o professor escolha a mais adequada para cada caso.

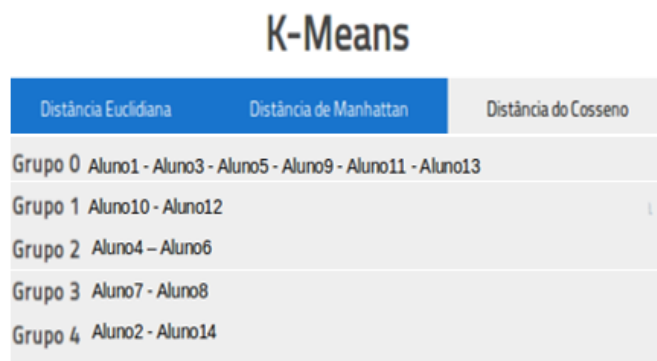


Figura 4. Visualização Descritiva do M-Cluster

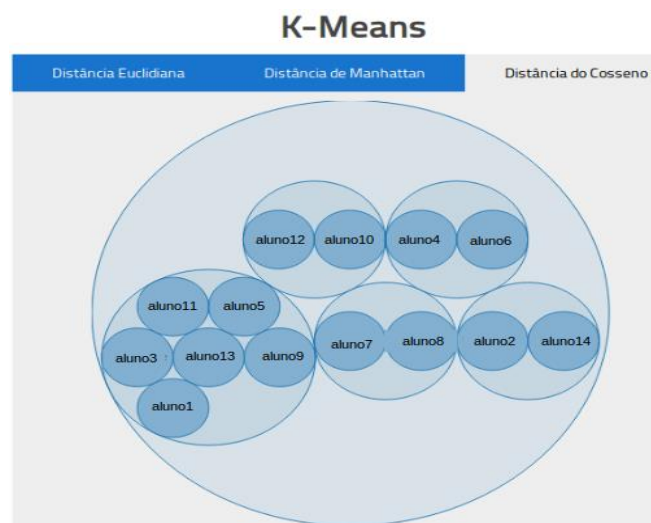


Figura 5. Visualização do Gráfico de Bolhas do M-Cluster

6. Conclusão

Este trabalho apresentou uma ferramenta que realiza a formação de grupos em atividades colaborativas, por meio dos dados extraídos dos grafos das TAs, para auxiliar o docente no processo de ensino-aprendizagem. A ferramenta mostrou-se promissora em realizar as sugestões de formação de grupos de alunos em turmas em andamento no AVA Moodle. Esta pesquisa tem como principais contribuições: o agrupamento dos alunos de acordo com as suas trilhas de aprendizagem baseadas no próprio Moodle, pois a partir daí, as TAs deram subsídios para extrair os atributos mais relevantes para serem usados no algoritmo de clusterização, permitindo gerar as sugestões dos agrupamentos; a identificação de atributos baseados nas TAs em formato de grafo, até então não observados na literatura sobre recomendação de grupos de alunos em AVAs. A terceira contribuição deste trabalho foi a implementação da métrica de similaridade da distância do cosseno para ser usado no algoritmo de *Clustering K-Means* dentro do WEKA e no *M-Cluster*, pois essa implementação não existia nos parâmetros de desenvolvimento do WEKA. O *M-Cluster* não beneficia apenas a EaD, mas qualquer modalidade de ensino que utiliza o Moodle ou outro AVA. A partir do que foi observado durante esta pesquisa, pretende-se, em trabalhos futuros, analisar a ferramenta em uma quantidade maior de turmas, com perfis diferentes, como em cursos totalmente a distância e semipresenciais. Além disso, pretende-se desenvolver novas funcionalidades, como por exemplo, criar a opção de formar tanto grupos homogêneos como heterogêneos, dando ao docente a possibilidade de agrupar indivíduos que tenham conhecimentos complementares.

7. Agradecimentos

Parte dos resultados apresentados neste artigo foi obtida através de atividades de P&D do projeto PROMOBILE patrocinado pela Samsung nos termos da lei federal brasileira nº 8.248/91. Agradecemos à FAPEAM pelo suporte financeiro concedido para a realização do projeto e ao Programa de Apoio a Jovens Doutores (PJD/UFAM), Edital PROPESP/UFAM 041/2016.

8. Referências

- Abnar, S., Orooji, F. e Taghiyareh, F. An evolutionary algorithm for forming mixed groups of learners in web based collaborative learning environments. In: Proceedings IEEE International Conference on Technology Enhanced Education, ICTEE, 2012.
- Bezdek, J. C. Pattern Recognition with Fuzzy Objective Function Algorithms. Plenum Press, New York, 1981.
- Daradoumis, T., Guitert, M., Gimenez, F., Marques, M. e Lloret, T. Supporting the composition of effective virtual groups for collaborative learning. In: International Conference on Computers in Education, v. 1, n. 1, p. 332–336, 2002.
- Felder, R. M. e Silverman, L.K. Learning and Teaching Styles in Engineering Education, *Engineering Education*, v.78, n.7, 1988, p. 674–681.
- Le, T.V. Evolutionary fuzzy clustering. In: Proc. IEEE Congr. Evol. Comput., pp. 753–758 (1995).
- Lima, D., Gadelha, B., Netto, J.F. e Bremgartner, V. MoodleGroups: Um Aplicativo para identificar as Relações Sociais entre Alunos em AVAs. In: XI Simpósio Brasileiro de Sistemas Colaborativos (SBSC 2014), p.142-148. Curitiba.
- Jagadish, D. Grouping in collaborative e-learning environment based on interaction among students. In: International Conference on Recent Trends in Information Technology, IEEE, 2014.
- MacQueen, J. Some methods for classification and analysis of multivariate observations, *Proceedings of the Fifth Berkeley Symposium On Mathematical Statistics and Probabilities*, 1, 281-296, 1967.
- Montazer, G. A. e Rezaei, M. S. A new approach in ELearners grouping using hybrid clustering method. In: International Conference on Education and e-Learning Innovations, v. 77, n. 380, p. 841–847, 2013.
- Ramos, D., Oliveira, E., Ramos, I. e Oliveira K. Trilhas de Aprendizagem em Ambientes Virtuais de Ensino-aprendizagem: Uma Revisão Sistemática da Literatura In: XXVI Simpósio Brasileiro de Informática na Educação (SBIE 2015), p.338-347.Maceió.
- Ramos, I., Ramos, D., Nascimento, P., Gadelha, B. e Oliveira, E. Formação de Grupos em Ambientes Virtuais de Aprendizagem: Uma Revisão Sistemática da Literatura. In: XXVII Simpósio Brasileiro de Informática na Educação (SBIE 2016), p.310-319. Uberlândia.
- Ramos, D., Ramos, I., Nascimento, P. e Oliveira, E. Uma Ferramenta baseada em Grafo para Identificação e Visualização de Trilhas de Aprendizagem. In: XXI Congresso Internacional de Informática na Educativa (TISE 2016), p.237-243. Chile.
- Santos, L., Castro, J. De. e Castro, T. Alteração no Modelo de Grupos do Moodle para Apoiar a Colaboração. In: XVIII Simpósio Brasileiro de Informática na Educação, p. 123–134. 2007.
- Yathongchai, C., Angskun, T., Yathongchai, W. e Angskun, J. Learner Classification Based on Learning Behavior and Performance. In: IEEE Conference on Open Systems, p. 66–70.2013