

# Aprendizado de Máquina em Análise Conversacional para Recomendar a Colaboração em Fóruns de Discussão

Antônio J. Moraes Neto<sup>1</sup>, Raimundo C. S. Vasconcelos<sup>1</sup>,  
Gabriel J. C. Lima<sup>1</sup>, Márcia A. Fernandes<sup>2</sup>, Tel Amiel<sup>3</sup>

<sup>1</sup>Instituto Federal de Brasília (IFB) — Brasília, DF — Brasil

<sup>2</sup>Universidade Federal de Uberlândia (UFU) — Uberlândia, MG — Brasil

<sup>3</sup>Universidade de Brasília (UnB) — Brasília, DF — Brasil

{antonio.neto, raimundo.vasconcelos}@ifb.edu.br,  
gabriel.lima6@estudante.ifb.edu.br, marcia@ufu.br, amiel@unb.br

**Abstract.** *The Conversational Analysis (CA) allows the identification of the collaboration level among students in discussion forums of Virtual Learning Environments (VLEs), resulting in indices that make it possible to assess collaboration and, based on this assessment, perform the recommendations to promote collaborative learning continuously. Having gathered a dataset of these indices, it is possible to use Machine Learning (ML) to cluster students and then specialize the recommendations considering their similarities. In this paper, the application of unsupervised ML in obtained indices from the CA is proposed in order to refine and validate a recommendation strategy which promotes the collaboration in discussion forums of VLEs.*

**Resumo.** *A Análise Conversacional (AC) permite identificar o nível de colaboração entre estudantes em fóruns de discussão de Ambientes Virtuais de Aprendizagem (AVAs), resultando em índices para avaliar a colaboração e a partir desses realizar recomendações visando promover continuamente a aprendizagem colaborativa. Tendo um conjunto de dados com esses índices é possível usar o aprendizado de máquina para agrupar os estudantes e assim especializar as recomendações de acordo com as suas similaridades. Neste artigo é proposta a aplicação de aprendizado de máquina não supervisionado em índices resultantes da AC, a fim de refinar e validar uma estratégia de recomendação que promova a colaboração em fóruns de discussão de AVAs.*

## 1. Introdução

Fóruns de discussão permanecem sendo amplamente adotados em Ambientes Virtuais de Aprendizagem (AVAs), tanto nos cursos presenciais quanto nos realizados a distância. Incentivar os estudantes a participarem das discussões com a perspectiva da aprendizagem colaborativa é uma questão desafiadora. Neste sentido, é relevante enviar recomendações que efetivamente ajudem estudantes e professores a promoverem a colaboração em fóruns, principalmente no contexto da Educação a Distância (EaD).

A Análise Conversacional (AC) oferece uma maneira de analisar o entendimento produzido por meio das interações, focando nos métodos pelos quais os participantes constroem significado colaborativamente, com a finalidade de relatar como o

entendimento foi alcançado em uma conversa [Koschmann 2013]. A abordagem metodológica de AC pode avaliar não apenas o conteúdo, mas ainda a estrutura, os papéis desempenhados pelos participantes e as relações estabelecidas nas suas conversas [Abraham et al. 2016], permitindo assim obter índices para avaliar a colaboração em fóruns de discussão.

A partir do conjunto de índices obtido na etapa de AC pode-se aplicar métodos de aprendizado de máquina, ou *Machine Learning* (ML), para agrupar estudantes de acordo com perfis de colaboração. Considerando que as recomendações voltadas para o conhecimento têm como fundamento os requisitos especificados, neste caso os de colaboração, e não o histórico de interação [Aggarwal 2016], é possível avaliar e refinar a estratégia de recomendação a fim de melhorar os diversos índices e então transmitir aquelas mais apropriadas para cada agrupamento de estudantes, dependendo do perfil revelado.

Com o objetivo de abordar a aplicação de ML a partir de resultados da AC a fim de promover a colaboração entre estudantes em fóruns de discussão de AVAs, este artigo está organizado da seguinte forma: a Fundamentação Teórica com a abordagem dos temas introduzidos; a descrição de como realizar o Agrupamento de Estudantes para Avaliar e Refinar Recomendações, após obter índices resultantes da AC em fóruns; os Resultados Alcançados a partir dos agrupamentos de estudantes realizados; e as Considerações Finais com reflexões tecnológicas e educacionais para promover a aprendizagem colaborativa, incluindo possibilidades de trabalhos futuros; além das Referências.

## **2. Fundamentação Teórica**

São abordadas nesta Seção as referências relacionadas à abordagem de recomendações a fim de promover a colaboração em fóruns de discussão, AC para identificar a colaboração em fóruns de discussão de AVAs e a aplicação de ML para realizar agrupamentos de estudantes no contexto das recomendações educacionais.

### **2.1. Promovendo a Aprendizagem Colaborativa em Fóruns de Discussão**

Realizar recomendações em AVAs pode contribuir para a aceleração do processo de aprendizagem, facilitar o acesso a conteúdos educativos e enriquecer esses ambientes [Liu et al. 2019]. Na perspectiva de efetuar isso em fóruns de discussão, é necessário iniciar-se pela AC destes, combinando a análise de interação com a detecção de tópicos abordados nos fóruns a fim de informar sobre a atuação de estudantes na perspectiva de identificar um conjunto de dimensões sociais e cognitivas, marcado pela interação com as pessoas apropriadas sobre o conteúdo apropriado [Gašević et al. 2019].

Em seguida, é preciso planejar as recomendações, o que pode ser feito com base na estrutura *Academically Productive Talk* (APT) [Michaels 2016], projetada para estimular a discussão em contexto educacional com ênfase na valorização da interação [Tegos et al. 2020], que propõe ferramentas a serem adotadas pelo professor a fim de estimular a discussão em sala de aula na qual os alunos expõem seus raciocínios, ouvem profunda e criticamente as contribuições dos outros e, assim, interagem de forma colaborativa [Michaels and O'Connor 2015]. É importante notar que quando os estudantes postam suas participações em fóruns e seus colegas recebem convites para

comentá-las, isso resulta em menos tópicos de discussão fragmentados, mas com maior número de participações por tópico [Oliveira et al. 2011].

Efetuar a recomendação em prol da aprendizagem colaborativa em fóruns de discussão, portanto, começa com a AC para identificar a colaboração entre os estudantes nesses debates. A partir disso, pode-se planejar e transmitir recomendações apropriadas a fim de promover o debate entre eles, sugerindo que postem questionamentos e comentem mensagens de colegas acerca dos assuntos em debate nos fóruns monitorados.

## **2.2. Análise Conversacional para Determinar a Colaboração em Fóruns**

A AC busca sistematizar as características da conversação on-line, construída pelos participantes desta por meio de ferramentas como fóruns de discussão, na qual negociam um contexto comum [Recuero 2012], concentrando-se na natureza sequencial do pensamento, que se perde na maioria das análises estatísticas, onde as postagens individuais são codificadas e depois contabilizadas, sem levar em conta a ordem de resposta sequencial [Stahl 2012]. A adoção da AC é relevante quando se precisa considerar as características das conversas on-line, cuja gramática é comparativamente informal e desestruturada em relação a outros textos [Uthus and Aha 2013].

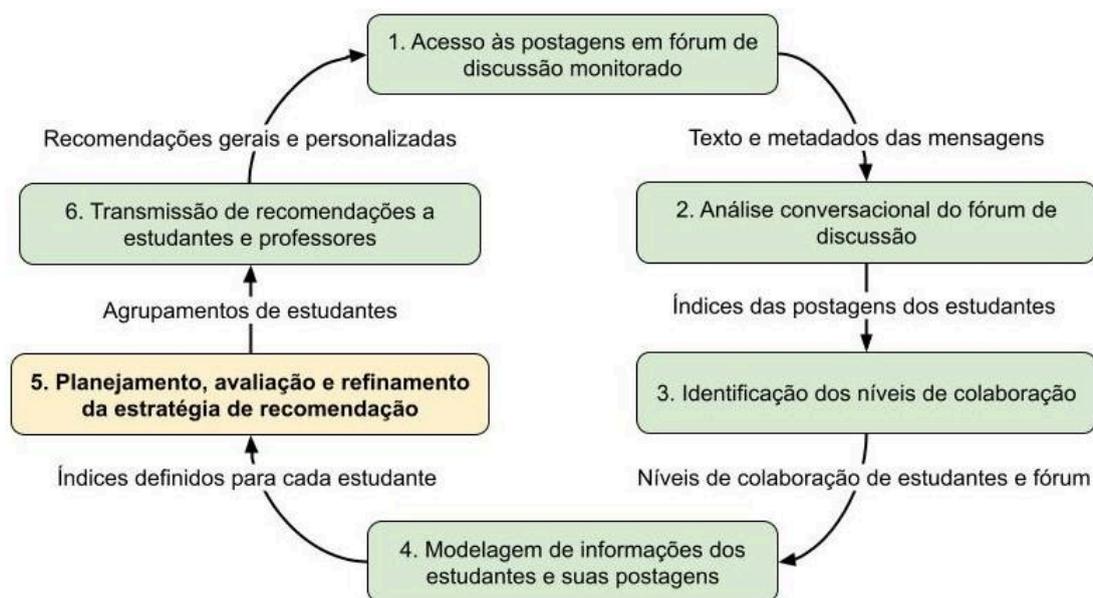
A partir da análise dos logs de conversa, além dos conteúdos, é possível adotar uma metodologia de AC para identificar e avaliar o comportamento de interação dos estudantes [Procter et al. 2018]. Para avaliar a colaboração entre eles é necessário utilizar técnicas de análise de interação que permitam uma visão desta em conformidade com o fluxo sequencial das suas postagens. À medida que os estudantes resolvem problemas juntos, eles necessariamente expressam seus pensamentos uns aos outros e esses dados ficam disponíveis para análise nos fóruns de discussão dos AVAs.

Ao analisar a dimensão cognitiva em discussões on-line, constatou-se que o evento desencadeador é normalmente uma questão inicial que desperta o debate, apresentando pontos de interrogação. Em seguida, a presença cognitiva geralmente se aprofunda em mensagens mais longas, usando uma linguagem mais complexa. Averiguou-se ainda a relevância da adoção de práticas criteriosas de pré-processamento para que os resultados dessa análise possam ser usados com maior confiabilidade [Farrow et al. 2019].

Com base em revisão sistemática de literatura publicada [Moraes Neto et al. 2020], sugere-se que para promover a aprendizagem colaborativa em fóruns de discussão de AVAs é necessária a adoção cíclica dos seguintes estágios: (1) acesso de leitura às postagens de um fórum, previamente apontado pelo professor para ser monitorado; (2) AC desse fórum, cujo resultado gera índices para as postagens; (3) identificação dos níveis de colaboração, calculados a partir dos índices resultantes da AC; (4) modelagem de informações dos estudantes e suas postagens, definindo índices para cada estudante; (5) planejamento da estratégia de recomendação, posteriormente a avaliação e refinamento desta; e (6) transmissão de recomendações apropriadas a estudantes e professores. Este artigo trata de evidenciar o quinto estágio a ser adotado, conforme está destacado na Figura 1.

No contexto deste artigo, com base em publicação anterior [Moraes Neto and

Fernandes and et al. 2022], três índices são relevantes para estabelecer o nível de colaboração dos estudantes em fóruns de discussão por meio da AC, cuja combinação indica onde e em que grau ocorreu a colaboração. Para obtê-los é necessário inicialmente realizar o pré-processamento, etapa da AC na qual são aplicadas técnicas específicas do Processamento de Linguagem Natural (PLN). Primeiro, é importante limpar os dados obtidos, como excluir *tags* HTML. Posteriormente, ocorrem técnicas como: *lematização*, mapeando formas flexionadas de palavras para uma raiz comum; *stemização*, retirando o final das palavras para encontrar sua forma base; e remoção de *stop words*, excluindo das demais etapas da AC os termos mais comuns.



**Figura 1. Estágios para promover a aprendizagem colaborativa em fóruns de discussão**

Em seguida, outras etapas da AC ocorrem a fim de definir os índices a serem calculados para cada postagem: o Processamento de Recursos trata do relacionamento entre as mensagens, definindo o ISI; a Identificação do Atributo da Mensagem é onde se caracteriza o tipo da mensagem, determinando o índice QC para definir as postagens com perguntas; a inferência dos principais termos abordados no fórum ocorre na etapa Detecção e Rastreamento de Tópicos, definindo o índice MTA. A média desses índices determina o nível de colaboração dos estudantes, ou SCL. Visando facilitar a leitura, estão apresentados na Tabela 1 esses e os demais índices utilizados neste trabalho, na qual o uso de cores busca destacar a relação entre tais índices.

**Tabela 1. Descrição resumida dos índices utilizados**

Sigla	Vocábulo	Descrição
ISI	<i>Identification of Students' Interactions</i>	Divisão do total de retornos de estudantes (WDC) pela quantidade de respostas (OD) para cada mensagem: $WDC / OD$ , para OD maior que zero
QC	<i>Questioning Characterization</i>	<i>QMark</i> é a porcentagem relacionada aos pontos de interrogação em uma postagem: $QMark / 100$
MTA	<i>Main Topic Approached</i>	Proporção do tópico com maior distribuição de palavras no fórum para cada mensagem: $\theta^{(d)}$ do maior $\phi$

Sigla	Vocábulo	Descrição
SCL	<i>Student's Collaboration Level</i>	Média dos índices anteriores, por postagem de estudante: $(ISI + QC + MTA) / 3$
PSQ	<i>Percentage of Student's Questions</i>	Porcentagem das mensagens com questionamento pelo total de postagens a cada estudante
PSR	<i>Percentage of Student's Returns</i>	Porcentagem dos retornos a postagens de colegas pelo total de mensagens por estudante
MaxSCL	<i>Maximum SCL</i>	Valor do maior SCL atingido por cada estudante em uma de suas postagens
PSM	<i>Percentage of Student's Messages</i>	Porcentagem de mensagens de cada aluno em relação ao total de postagens feitas pelos estudantes
SIL	<i>Student's Inducement Level</i>	Média de PSM, PSQ e a média do ISI das mensagens de cada estudante: $(PSM + PSQ + ISI\ average) / 3$
SPL	<i>Student's Participation Level</i>	Média de PSM, PSR e a média do ISI: $(PSM + PSR + ISI\ average) / 3$

Na Tabela 2 é apresentado um exemplo de resultados desses índices para cada postagem de um fórum de discussão, na qual NA refere-se à postagem de professor, em que não se aplica o cálculo do SCL.

**Tabela 2. Resultados dos índices por postagem**

Post ID	QC	ISI	MTA	SCL
16760	0,000	1,000	0,358	NA
16914	0,000	1,000	0,595	0,532
17450	0,039	0,000	0,775	0,272

A partir dos resultados da AC, conforme detalhado em publicação anterior [Moraes Neto and Costa and et al. 2022], podem ser definidos índices para cada estudante, como o exemplo que consta na Tabela 3, o qual postou seis mensagens, que representam 11,32% do total de postagens dos estudantes, dentre as quais uma (16,67%) continha questionamento e quatro (66,67%) foram retornos deste a mensagens de colegas. Considerando-se os resultados de suas postagens, foram calculadas ainda as médias de ISI (0,5), MTA (0,413) e SCL (0,307), além do SCL máximo que atingiu em uma destas (0,599).

**Tabela 3. Índices definidos para um estudante**

User ID	Total messages	PSM	PSQ	PSR	ISI average	MTA average	SCL average	MaxSCL
241	6	11,32%	16,67%	66,67%	0,500	0,413	0,307	0,599

Esses índices e nível de colaboração possibilitam disponibilizar diversas recomendações, cada uma voltada para a melhoria de um ou mais desses índices. Sugere-se que, em sintonia com o planejamento do professor, a repetição desse processo de AC seguido da transmissão de recomendações de forma cíclica, promove continuamente a aprendizagem colaborativa em fóruns de discussão.

### 2.3. Aprendizado de Máquina Voltado para Recomendações Educacionais

No contexto da inteligência artificial na educação é comum a aplicação de métodos de

ML para reconhecer e classificar padrões e modelar perfis de estudantes para fazer previsões [Zawacki-Richter et al. 2019]. No planejamento das recomendações a serem realizadas a partir do uso de ML, indica-se que estas podem, dentre outras proposições, incentivar os estudantes a pedirem ajuda aos colegas e comentarem as suas postagens, sugerir colegas ou professores para ajudarem com as dúvidas postadas pelos alunos, despertar interesse para a colaboração, encorajar comentários quando há novidades, estimular interações na inexistência destas, e motivar o compartilhamento de opiniões e ideias quanto aos assuntos do componente curricular em questão [Pereira et al. 2022]. É relevante destacar que os estudantes devem ter autonomia para aceitar as recomendações e se comunicarem com os colegas indicados [Ahmadian Yazdi et al. 2022].

A fim de especificar recomendações a partir da análise de interações pode-se realizar a formação de agrupamentos passando-se pelas etapas de: aplicação do K-Means; avaliação da tendência de agrupamento; identificação da quantidade de *clusters* apropriada para o contexto; e validação dos agrupamentos [Pereira 2021]. Pode-se ainda, de maneira similar, aplicar esse algoritmo em um conjunto dos dados de interação dos estudantes, disponíveis em um AVA, para recomendar a formação de grupos desses alunos em prol da colaboração, alcançando-se melhoria no rendimento estudantil das turmas para as quais as recomendações foram disponibilizadas [Monteverde et al. 2017]. A partir dos dados de interação em fóruns de discussão, usa-se também ML para definir ocorrências de colaboração de cada estudante, classificadas em três níveis – baixo, médio ou alto, a fim de realizar recomendações que motivem a aprendizagem colaborativa [Anaya et al. 2016].

As recomendações em contexto educacional podem ser classificadas como gerais e personalizadas, sendo as gerais aquelas que são transmitidas para professores e estudantes sem considerar suas especificidades, mas indicando conteúdos e atividades que devem ser destacados. Por outro lado, as recomendações personalizadas levam em consideração as características de cada aluno, aos quais são enviadas sugestões com informações pessoais como, por exemplo, as quantidades de mensagens que postou e quais os tipos (perguntas, retornos), no caso de enfatizar a colaboração.

Quando se aplica ML para agrupar estudantes de acordo com suas similaridades (preferências, notas), pode-se especializar algumas recomendações, tanto gerais quanto personalizadas, a fim de oferecê-las em conformidade com os perfis de agrupamento identificados [Vera and González 2022].

### **3. Agrupamento de Estudantes para Avaliar e Refinar Recomendações**

Nesta Seção é apresentado um procedimento de aplicação do ML em índices resultantes da AC, como aqueles descritos na Tabela 3. Na sequência, define-se como foi feito o refinamento das recomendações a fim de especializá-las de acordo com cada agrupamento obtido do ML.

#### **3.1. Determinando Agrupamentos a Partir dos Índices de Colaboração**

Considerando-se os apontamentos apresentados na Seção 2.3, foram aplicados algoritmos K-Means para gerar dois e três agrupamentos a partir dos índices e SCL. Os resultados iniciais do *KMeans* da biblioteca Python *sklearn.cluster* foram inicialmente inconsistentes, principalmente pela disparidade de valores das porcentagens de

questionamentos e retornos (PSQ e PSR). Isso ocorre quando a configuração do fórum permite que os estudantes criem seus próprios tópicos de discussão, não sendo compulsório postar retorno aos demais participantes, o que resulta em diversos valores iguais a zero. Por outro lado, quando não se pode criar esses tópicos, frequentemente ocorrem valores de PSR bem superiores aos demais índices para os estudantes que postam retornos aos colegas.

A aplicação do K-Means levou então à revisão dos índices, a partir da qual foram testados vários outros, culminando com a formação de dois, levando-se em consideração a porcentagem das mensagens do estudante em relação ao total de postagens dos colegas no fórum (PSM), constituídos da seguinte maneira:

- Nível de provocação do estudante, ou SIL, passando a considerar não apenas os questionamentos postados pelo estudante (PSQ), mas também as suas postagens (PSM) e a média dos retornos de colegas que estas provocaram (*ISI average*);
- Nível de participação do estudante, ou SPL, incluindo além dos retornos postados pelo estudante (PSR), as suas postagens (PSM) e a média dos retornos que estas obtiveram de colegas (*ISI average*).

Os índices PSQ e PSR foram portanto substituídos pelo SIL e SPL, de maneira que os valores destes fossem superiores a zero, o que permitiu obter resultados com melhor distribuição de estudantes a partir do K-Means. Para fins de comparação foram calculadas ainda as médias dos índices por agrupamento e o desvio padrão para cada índice. Ao comparar os resultados de dois e três agrupamentos a partir dos quatro índices mencionados (SIL, SPL, médias do MTA e SCL), percebeu-se que a aplicação do K-Means sem a média do SCL permitiu a interpretação de agrupamentos conceitualmente claros, considerando que os demais índices (SIL, SPL e MTA *average*) fazem parte, diretamente ou não, do seu cálculo, tornando frequentemente o SCL *average* o índice preponderante na formação dos agrupamentos. Destaca-se que essa preponderância de índice acontece para aquele com o maior desvio padrão.

Dessa forma, por meio de experimentação e interpretação qualitativa, verificou-se que a aplicação do K-Means para formar três agrupamentos a partir dos índices SIL, SPL e MTA *average* produziu os resultados considerados consistentes.

### **3.2. Refinando a Estratégia de Recomendação pelo Agrupamento de Estudantes**

A participação dos estudantes no início de um fórum de discussão pode ser diminuta, sendo necessário que ao menos cinco deles tenham feito postagens para que seja viável gerar três agrupamentos. Ainda assim, houve caso em que apenas um ajuntamento foi obtido, pois, no estágio inicial do fórum, podem ocorrer postagens muito semelhantes, resultando em índices idênticos. Portanto, caso não haja participação de ao menos cinco alunos, a análise do fórum não deve incluir a aplicação do K-Means. Além disso, essa aplicação, quando ocorrer, deve retornar ao menos dois agrupamentos.

A distribuição dos estudantes em três agrupamentos revelou grupos com desempenhos colaborativos menor, intermediário e maior, considerando-se as médias do índice preponderante por ajuntamento (SIL, SPL ou MTA *average*). Comparando-se essas médias, houve caso em que a diferença entre dois desses desempenhos foi insignificante, sendo necessário então reconsiderar os estudantes de ambos os grupos

como constantes apenas naquele com desempenho inferior. Com base em diversas comparações realizadas, considera-se que a diferença entre essas médias deve ser superior a 10% para ratificar a distribuição obtida por meio de ML em dois agrupamentos. Caso contrário, os alunos devem ser reunidos em apenas um.

A partir da obtenção de agrupamentos consistentes, a estratégia de recomendação pode ser avaliada e refinada, caso tenha ocorrido a transmissão de recomendações em análise anterior do fórum de discussão. Tal avaliação é iniciada pela identificação do tipo de envio para cada estudante, considerando que:

- Há aqueles que não consentiram o envio, ou seja, as recomendações não foram transmitidas para eles, sendo assim associados ao código de envio 0 (zero);
- Há os que consentiram o envio, mas não participaram do fórum até o momento da análise, para os quais foram enviadas apenas as recomendações gerais, recebendo assim o código de envio 1 (um);
- Os estudantes que consentiram o envio e participaram do fórum são associados ao código 2 (dois), para os quais foram enviadas recomendações gerais e personalizadas.

Calcula-se ainda as porcentagens dos tipos de envio de recomendação por agrupamento de estudantes. Dessa forma, é possível avaliar a efetividade da estratégia de recomendação realizada comparando o desempenho colaborativo de cada agrupamento com essas proporções. A efetividade dessa estratégia é revelada quando os maiores percentuais dos tipos de envio 1 e 2 ocorrem nos agrupamentos com desempenhos colaborativos intermediário e maior, respectivamente.

A partir da avaliação da estratégia de recomendação é possível rever o planejamento desta de maneira a especializar as recomendações para cada agrupamento de acordo com o desempenho colaborativo. Em conformidade com a estrutura APT, abordada na Seção 2.1, pode-se refinar as recomendações relativas ao índice preponderante de modo que:

- Para o agrupamento com menor desempenho colaborativo sejam reelaboradas as recomendações relativas a tal índice a fim de que passem a desafiar os estudantes no sentido de participarem mais, sugerindo que exponham suas opiniões, forneçam exemplos ou esclarecimentos;
- Ao ajuntamento com desempenho colaborativo intermediário as recomendações sejam voltadas para aprofundar o debate, incentivando os estudantes a acrescentarem evidências, referências, opiniões convergentes ou divergentes em resposta às postagens dos colegas;
- Não sejam enviadas as recomendações relativas ao índice preponderante para o agrupamento com maior desempenho colaborativo, caso sua média para esse índice seja superior a 10% em relação à média do grupo com desempenho intermediário. Caso não seja, devem ser disponibilizadas para esse ajuntamento as mesmas recomendações enviadas ao anterior.

#### **4. Resultados Alcançados**

A partir da avaliação e refinamento das recomendações por meio da aplicação de ML para o agrupamento consistente de estudantes, apresenta-se nesta Seção os principais

resultados obtidos.

#### 4.1. Especialização das Recomendações

No âmbito da pesquisa que origina este artigo, cinco ciclos de experimentos foram realizados, tanto em cursos ofertados presencialmente quanto a distância, com a participação de estudantes adultos, havendo, para tanto, as devidas aprovações dos Comitês de Ética em Pesquisa das diferentes instituições de ensino superior envolvidas. Todos os experimentos foram relevantes ao amadurecimento dos estágios necessários para promover a colaboração entre estudantes em fóruns de discussão. Nos dois últimos, abrangendo oito turmas formadas para realizar dois componentes curriculares de cursos superiores da EaD, houve participações mais amplas, permitindo obter agrupamentos consistentes por meio do K-Means e conseqüentemente refinar e validar as recomendações. Entretanto, em nenhuma experimentação foi avaliada a estratégia de recomendação após a aplicação de ML.

Na Tabela 4 apresenta-se um resumo dos fóruns de discussão analisados, identificados pelos seus códigos do AVA, sendo que quatro, destacados na cor laranja, não foram monitorados por haver quantitativo insuficiente de estudantes que consentiram o envio de recomendações. Entretanto, foi relevante analisar os fóruns monitorados e aqueles que não foram a fim de comparar seus resultados. Nesse sentido, destaca-se que houve expressivo aumento da quantidade de pessoas que postaram nos fóruns monitorados, ou seja, nos quais houve envio de recomendações. Houve ainda um aumento na proporção de mensagens por participante, principalmente nos dois fóruns com maiores quantidades de estudantes que consentiram (9974 e 9246).

**Tabela 4. Resumo dos fóruns de discussão analisados**

ID do fórum	9908	9919	9930	9941	9952	9963	9974	9246	Totais
Total de estudantes	32	21	26	21	16	52	56	42	266
Estudantes que consentiram	6	0	4	0	0	1	24	42	77
Percentual de estudantes que consentiram	19%	0%	15%	0%	0%	2%	43%	100%	29%
Etapas para envio de recomendações gerais	3	0	3	0	0	0	3	2	11
Quantidade de recomen. personalizadas enviadas	5	0	2	0	0	0	28	20	55
Etapas para envio de recomen. a professores	3	0	3	0	0	0	3	2	11
Mensagens postadas	22	13	31	12	13	11	30	78	210
Pessoas que postaram	22	11	22	12	13	11	26	18	135
Proporção de mensagens por participante	1,00	1,18	1,41	1,00	1,00	1,00	1,15	4,33	1,56

Houve diversas aplicações de ML nesses fóruns, em extrações iniciais e finais destes, a fim de estabelecer os índices e a forma de agrupamento mais consistente. Dessa maneira, foi possível estabelecer os parâmetros destacados na Seção 3.1. O gráfico constante na Figura 2 exemplifica a distribuição de estudantes em três

agrupamentos (0, 1 e 2), na qual o índice MTA *average* é preponderante, tendo obtido o desvio padrão (0,144) maior que os demais índices (SIL = 0,097 e SPL = 0,078). As diferenças das médias desse índice para os agrupamentos foram bem superiores a 10%: no agrupamento 0 o MTA *average* foi 0,101; 0,362 para o agrupamento 1; e no agrupamento 2 atingiu 0,498. Destaca-se que os códigos entre parênteses são os identificadores dos estudantes no AVA.

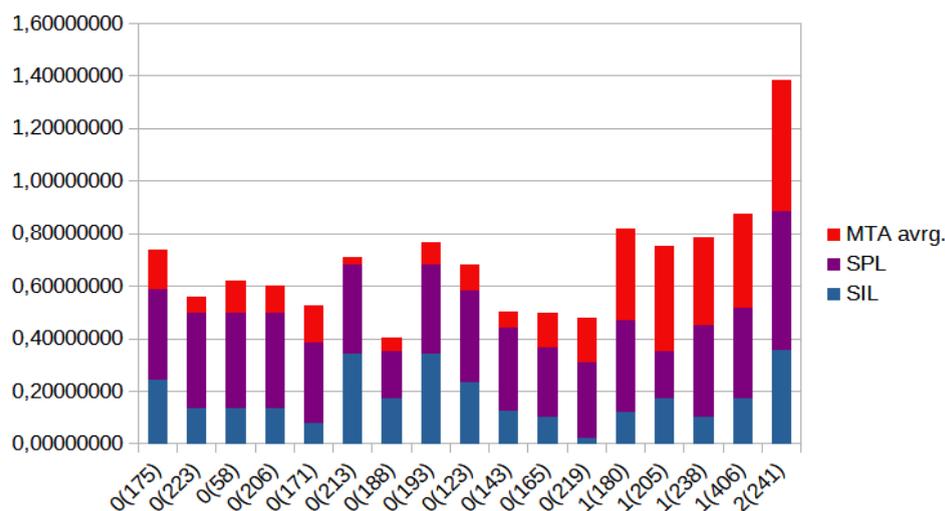


Figura 2. Três agrupamentos de estudantes no fórum 9246

Os resultados permitiram estabelecer que a recomendação referente ao índice preponderante pudesse ser especializada de acordo com o desempenho colaborativo alcançado por cada um dos três agrupamentos obtidos por K-Means. Segue um exemplo de refinamento da estratégia de recomendação para quando o índice MTA *average* for preponderante:

- Para estudantes no agrupamento com menor desempenho colaborativo: “Você pode colaborar com os/as colegas, comentando alguma postagem deles(as) com algo mais que pensa sobre estes termos que estão sendo debatidos no fórum: ['Termo1'], ['Termo2'], ['Termo3'], ['Termo4'], ['Termo5].” No caso do fórum 9246 essa recomendação seria enviada ao agrupamento 0 (zero);
- Para estudantes no agrupamento com desempenho colaborativo intermediário: “Os seguintes termos estão sendo mais debatidos neste fórum: ['Termo1'], ['Termo2'], ['Termo3'], ['Termo4'], ['Termo5]. Para aprofundar esse debate você poderia postar uma mensagem com uma referência ou evidência sobre o assunto debatido.” Para o fórum 9246 essa recomendação seria enviada ao agrupamento 1 (um);
- Não enviar esta recomendação para o agrupamento com maior desempenho colaborativo, caso sua média para o índice preponderante seja superior a 10% em relação à média do grupo com desempenho intermediário. No exemplo do fórum 9246, ao estudante 241 não seria enviada a recomendação referente ao índice MTA *average*.

Para o professor, a recomendação com a lista dos estudantes e seus respectivos *Maximum SCL* deve ser refinada de forma que estejam agrupados de acordo com o

índice preponderante, a fim de destacar os agrupamentos e as sugestões de intervenção relativas a tal índice.

#### 4.2. Validação da Estratégia de Recomendação

De maneira geral, os comparativos das médias dos índices resultantes das análises feitas no começo e ao final dos monitoramentos daqueles quatro fóruns de discussão, constantes na Tabela 4, revelaram que há uma melhora significativa das médias do SIL, SPL, MTA e SCL, destacando-se incrementos superiores a 33% e 119% dos dois últimos índices respectivamente. Ao se comparar os resultados de dois fóruns de discussão similares, tanto na finalidade quanto na quantidade de estudantes inscritos (56 e 52), sendo que um foi monitorado (9974) e outro não (9963), merecem destaques os seguintes aumentos expressivos no resultado daquele em que houve monitoramento:

- O fórum monitorado contou com a participação de 15 pessoas a mais (11 no 9963 e 26 no 9974);
- Com relação à abordagem dos principais termos em discussão, as médias finais do MTA foram 91,3% maiores no fórum monitorado (9974);
- As médias finais do SCL, ou seja, do nível de colaboração dos estudantes, foram superiores 125,7% em relação ao fórum não monitorado (9963).

Os agrupamentos obtidos por meio de K-Means viabilizaram ainda a validação da estratégia que definiu as recomendações transmitidas aos estudantes e professores, considerando-se os fóruns de discussão nos quais houve consentimento para enviar recomendações. Na Tabela 5 apresenta-se o comparativo de resultados das análises dos dois fóruns monitorados com maiores quantidades de estudantes que consentiram o envio de recomendações (9974 e 9246), incluindo-se o resultado daquele que não foi monitorado (9963), destacado em laranja, a fim de estabelecer confrontação de dados.

**Tabela 5. Comparativo de resultados dos principais fóruns analisados.**

Fórum	Descrição do resultado	SIL <i>average</i>	SPL <i>average</i>	MTA <i>average</i>	SCL <i>average</i>
9963	Médias iniciais	0,167	0,167	0,100	0,033
	Médias finais	0,030	0,030	0,104	0,035
	Comparação das médias	↓82,0%	↓82,0%	↑4,0%	↑6,1%
9974	Médias iniciais	0,048	0,048	0,108	0,036
	Médias finais	0,026	0,032	0,199	0,079
	Comparação das médias	↓45,8%	↓33,3%	↑84,3%	↑119,4%
	Envio de recomendação tipo 0	0,013	0,013	0,117	0,039
	Envio de recomendação tipo 1	0,011	0,011	0,258	0,086
	Envio de recomendação tipo 2	0,041	0,055	0,248	0,110
9246	Médias iniciais	0,111	0,139	0,107	0,091
	Médias finais	0,177	0,326	0,186	0,208
	Comparação das médias	↑59,5%	↑134,5%	↑73,8%	↑128,6%
	Envio de recomendação tipo 0	0,000	0,000	0,000	0,000
	Envio de recomendação tipo 1	0,087	0,305	0,120	0,105

Fórum	Descrição do resultado	SIL <i>average</i>	SPL <i>average</i>	MTA <i>average</i>	SCL <i>average</i>
	Envio de recomendação tipo 2	0,197	0,331	0,200	0,230

Nos dois fóruns em que as recomendações foram enviadas para a maioria dos estudantes (9246 e 9974) aqueles para os quais foram enviadas recomendações estão nos agrupamentos com maiores desempenhos colaborativos, inclusive se forem consideradas as médias desses índices pelos tipos de envio das recomendações.

Os comparativos entre os desempenhos colaborativos finais dos principais fóruns de discussão monitorados (9246 e 9974) e aquele não monitorado (9963), apontam uma diferença expressiva nas médias dos índices SIL, SPL, MTA e SCL, além da média da quantidade de palavras por postagem de estudante. Por esses índices, o desempenho colaborativo dos estudantes no fórum não monitorado foi consideravelmente inferior, com destaque para as médias finais do MTA, de 0,104, 0,199 e 0,186 nos fóruns 9963, 9974 e 9246, respectivamente. Os comparativos entre as médias iniciais e finais evidenciam expressivas diferenças das suas porcentagens nos fóruns monitorados em relação àquele que não foi.

## 5. Considerações Finais

Mediante o que foi exposto e tendo em vista promover a aprendizagem colaborativa em fóruns de discussão, a aplicação de aprendizado de máquina em índices resultantes da análise conversacional permitiu inicialmente revisar e eventualmente ajustar os resultados da AC realizada. Posteriormente, tendo obtido agrupamentos consistentes de estudantes, foi possível refinar a estratégia de recomendação estabelecida, especializando-a de acordo com o desempenho colaborativo revelado em cada ajuntamento. Por fim, após realizar alguns ciclos de recomendação a alunos e professores, pôde-se avaliar a efetividade das recomendações comparando-se, não apenas os resultados gerais dos índices da AC, mas também aqueles alcançados por agrupamento de estudantes.

Assim caracterizou-se um procedimento para refinar e validar a estratégia de recomendação, como parte dos estágios cíclicos para promover a aprendizagem colaborativa em fóruns de discussão. Acredita-se que a adoção desses ciclos pode, de maneira direta, auxiliar efetivamente tanto os estudantes na participação ativa dos debates em fóruns quanto os professores no engajamento dos alunos nessas discussões. Em perspectiva ampla é possível vislumbrar que essa adoção contribua para reorientar os planejamentos pedagógicos no sentido de tornar os fóruns em AVAs mais dinâmicos, motivadores da produção de texto e interativos, em um contexto de ensino e aprendizagem mais colaborativo.

Em trabalhos futuros é recomendado que haja experimento mais abrangente, preferencialmente em contexto da EaD, com vistas a avaliar o refinamento e validação da estratégia de recomendação propostos. É relevante ainda integrar o sistema de recomendação educacional que implemente os estágios cíclicos descritos em um AVA, a fim de promover a aprendizagem colaborativa.

## 6. Referências

- Abraham, J., Kannampallil, T., Brenner, C., et al. (2016). Characterizing the structure and content of nurse handoffs: A Sequential Conversational Analysis approach. *Journal of Biomedical Informatics*, v. 59, p. 76–88.
- Aggarwal, C. (2016). An Introduction to Recommender Systems. In: Aggarwal, C. [Ed.]. *Recommender Systems: The Textbook*. Cham: Springer International Publishing. p. 1–28.
- Ahmadian Yazdi, H., Seyyed Mahdavi Chabok, S. J. and Kheirabadi, M. (2022). Dynamic Educational Recommender System Based on Improved Recurrent Neural Networks Using Attention Technique. *Applied Artificial Intelligence*, v. 36, n. 1, p. 2005298.
- Anaya, A. R., Luque, M. and Peinado, M. (1 mar 2016). A visual recommender tool in a collaborative learning experience. *Expert Systems with Applications*, v. 45, p. 248–259.
- Farrow, E., Moore, J. and Gašević, D. (2019). Analysing discussion forum data: a replication study avoiding data contamination. In *Proceedings of the 9th International Conference on Learning Analytics & Knowledge, LAK19*. Association for Computing Machinery. <http://doi.org/10.1145/3303772.3303779>, [accessed on Nov 16].
- Gašević, D., Joksimović, S., Eagan, B. R. and Shaffer, D. W. (2019). SENS: Network analytics to combine social and cognitive perspectives of collaborative learning. *Computers in Human Behavior*, v. 92, p. 562–577.
- Koschmann, T. (2013). Conversation Analysis and Collaborative Learning. In: Hmelo-Silver, C.; Chinn, C.; Chan, C.; O'Donnell, A. [Eds.]. *The International Handbook of Collaborative Learning*. New York: Routledge Handbooks. p. 149–167.
- Liu, Q., Huang, J., Wu, L., Zhu, K. and Ba, S. (2019). CBET: design and evaluation of a domain-specific chatbot for mobile learning. *Universal Access in the Information Society*.
- Michaels, S. (2016). Accountable Talk® Sourcebook: For Classroom Conversation that Works. p. 46.
- Michaels, S. and O'Connor, C. (2015). Conceptualizing Talk Moves as Tools: Professional Development Approaches for Academically Productive Discussions. In: Resnick, L. B.; Asterhan, C. S. C.; Clarke, S. N. [Eds.]. *Socializing Intelligence Through Academic Talk and Dialogue*. American Educational Research Association. p. 347–361.
- Monteverde, I., Amaral, G., Ramos, D., et al. (2017). M-Cluster: Uma ferramenta de Recomendação para Formação de Grupos em Ambientes Virtuais de Aprendizagem. *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação - SBIE)*, v. 28, n. 1, p. 1657.
- Moraes Neto, A. J., Costa, N. T., Fernandes, M. A. and Amiel, T. (2022). Análise Conversacional para Diagnosticar e Recomendar a Colaboração em Ambientes

- Virtuais de Aprendizagem. In *Anais do Simpósio Brasileiro de Informática na Educação*. SBC. <https://sol.sbc.org.br/index.php/sbie/article/view/22494>, [accessed on Dec 3].
- Moraes Neto, A. J., Fernandes, M. A. and Amiel, T. (2020). Chatbot e Análise Conversacional para Recomendação da Aprendizagem Colaborativa na EaD. *Anais do Simpósio Brasileiro de Informática na Educação*, p. 1142–1151.
- Moraes Neto, A. J., Fernandes, M. A. and Amiel, T. (2022). Conversational Analysis to Recommend Collaborative Learning in Distance Education. <https://www.scitepress.org/Link.aspx?doi=10.5220/0011092600003182>, [accessed on Aug 12].
- Oliveira, I., Tinoca, L. and Pereira, A. (2011). Online group work patterns: How to promote a successful collaboration. *Computers & Education*, v. 57, n. 1, p. 1348–1357.
- Pereira, A. J. (2021). Especificação de sistema de recomendação a partir de análise de interações em Rede Social Educacional. Master Thesis. <https://repositorio.ufpe.br/handle/123456789/41538>, [accessed on Jun 21].
- Pereira, A. J., Gomes, A. S. and Primo, T. T. (2022). Design de Sistema de Recomendação Educacional: abordagens com Mágico de Oz. In *Anais do Simpósio Brasileiro de Informática na Educação*. SBC. <https://sol.sbc.org.br/index.php/sbie/article/view/22492>, [accessed on Jan 5].
- Procter, M., Lin, F. and Heller, B. (2018). Intelligent intervention by conversational agent through chatlog analysis. *Smart Learning Environments*, v. 5, n. 1, p. 30.
- Recuero, R. (2012). A Conversação como Apropriação na Comunicação Mediada pelo Computador. In: Buitoni, D. S.; Chiachiri, R. [Eds.]. *Comunicação, Cultura de Rede e Jornalismo*. 1ª ed. São Paulo: Almedina. p. 259–274.
- Stahl, G. (2012). A view of Computer-Supported Collaborative Learning research and its Lessons for Future-Generation Collaboration Systems. <http://gerrystahl.net/pub/fgcs.pdf>.
- Tegos, S., Demetriadis, S., Psathas, G. and Tsiatsos, T. (2020). A Configurable Agent to Advance Peers' Productive Dialogue in MOOCs. [A. Følstad, T. Araujo, S. Papadopoulos, et al., Eds.] In *Chatbot Research and Design*. Lecture Notes in Computer Science. Springer International Publishing.
- Uthus, D. C. and Aha, D. W. (2013). Multiparticipant chat analysis: A survey. *Artificial Intelligence*, v. 199–200, p. 106–121.
- Vera, A. A. and González, C. M. (2022). Educational Resource Recommender Systems Using Python and Moodle. [O. Gervasi, B. Murgante, S. Misra, A. M. A. C. Rocha, & C. Garau, Eds.] In *Computational Science and Its Applications – ICCSA 2022 Workshops*. Lecture Notes in Computer Science. Springer International Publishing.
- Zawacki-Richter, O., Marín, V. I., Bond, M. and Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*, v. 16, n. 1, p. 39.