

Um Modelo para Auxiliar a Descoberta e Classificação de Conteúdo para Ambientes Virtuais de Aprendizagem

Cleyton Aparecido Dim
Universidade Federal do Pará – UFPA
cleytondim@ufpa.br

Jefferson Magalhães de Moraes
Universidade Federal do Pará – UFPA
jeffersonmoraes@ufpa.br

Marcelle Pereira Mota
Universidade Federal do Pará – UFPA
mpmota@ufpa.br

Orlando Belo
Universidade do Minho – UMINHO
obelo@di.uminho.pt

Rafael Martins Feitosa
Universidade Federal do Pará – UFPA
rafaelfm@ufpa.br

Raimundo Viegas Junior
Universidade Federal do Pará – UFPA
rviegas@ufpa.br

ABSTRACT

The massive amount of information currently available on the Internet makes it difficult for teachers to curate quality educational content or to select material for self-regulated study by students. Aiming to facilitate these steps in the teaching and/or learning process this article presents an approach to assist the discovery of educational content from the hybrid recommendation system and later classification from the feedback evaluation with sentiment analysis techniques trained with the Re-Li corpus. This paper describes the proposed model, the implementation of a prototype and its application in non-formal training involving 13 participants.

KEY WORDS

Sistemas de Recomendação, Análise de Sentimento, AVA

1 INTRODUÇÃO

Com a produção cada vez mais massiva de informação, esforços vem sendo tomados no sentido de facilitar o processo de ensino-aprendizagem mediado pela tecnologia. Auxiliar o professor na estruturação e disponibilização do conteúdo educacional e guiar o aluno para o melhor aproveitamento do seus estudos tem sido um desafio que atravessa décadas. Neste período, diversas pesquisas produziram soluções relevantes separadamente, mas em geral não são integradas e aplicadas em média ou larga escala [1].

Uma dessas soluções são os Sistemas Tutores Inteligentes (STI), tutores cognitivos ou ambientes adaptativos de aprendizagem que traçam um perfil do estudante e atuam personalizadas para que o estudante alcance a proficiência em determinado domínio do conhecimento [2, 3].

Outra linha de pesquisa é de *Learning Analytics*, que permite aos professores extrair informações sobre dados do estudantes e seu contexto com o propósito de entender e otimizar o aprendizado no ambiente que ele ocorre [4]. Nesta linha existem algumas pesquisas em especial que são sobre *Learning Analytics* em Objetos de Aprendizagem [5, 6].

Além dessas existem outras técnicas também com o intuito de melhorar o processo de ensino e da aprendizagem, tais como análise de sentimento no apoio ao ensino híbrido [7, 8] ou sistemas de recomendação de Objetos de Aprendizagem (OAs) [9, 10] e a própria organização de Repositórios de Objetos de Aprendizagem (ROAs) [11].

Neste contexto, o presente trabalho visa contribuir com a proposta de um modelo e a implementação de um sistema adaptativo

que facilite o gerenciamento de OAs pelos professores, apresentando ao aluno conteúdo de acordo com o seu nível de conhecimento. Adicionalmente descreve-se uma forma de apresentar os comentários dos alunos sobre os OAs realizadas por análise de sentimento.

O restante do artigo está organizado da seguinte forma: Seção 2 apresenta os trabalhos relacionados; Na Seção 3 é descrito o modelo do sistema tutor proposto; a Seção 4 apresenta a metodologia de avaliação e de coleta de dados da aplicação de um treinamento com a ferramenta, nomeada Microtutor na ocasião; na Seção 5 são apresentados os Resultados e por fim a Seção 6 apresenta as considerações finais e trabalhos futuros.

2 TRABALHOS RELACIONADOS

O uso de Sistemas Tutores Inteligentes tem sido efetivo no apoio da aprendizagem dos estudantes [2], podendo aumentar em média até 1 desvio-padrão, equivalente ao aumento de um nível na nota dos estudantes [12]. Este resultado ainda não alcança o efeito de 2 desvios-padrão (2-sigma) do ensino um-para-um em contextos naturalísticos [13]. Um exemplo de sistema adaptativo é o o Adaptweb [14], com o objetivo de adaptar o conteúdo, as formas de apresentação do conteúdo e a navegação de acordo com o perfil do aluno.

Um fator que pode influenciar o aprendizado do estudante é seu estado emocional enquanto aprende [3]. Estes sistemas que levam em consideração o estado emocional são denominados de Sistemas Tutores Afetivos (STA). Contudo, algumas questões ainda necessitam de mais investigações para os STAs – tais como quais emoções são relevantes para a aprendizagem e como usar essa informação para tornar o processo de ensino e aprendizagem mais efetivos através destes sistemas – há ainda o problema do alto custo de aparelhos como Encefalograma (EEG) e Resposta Galvânica da Pele (GSR), provavelmente acarretando em escassez de mais estudos nessa área [15].

2.1 Sistemas de Recomendação

Os sistemas de recomendação realizam indicação de itens relevantes baseado nas preferências ou necessidades do usuário.

No contexto educacional, possibilitam encontrar materiais mais relevantes ao aprendizado do aluno [16].

Segundo revisões sistemática sobre o tema [17, 18], as principais técnicas encontradas em sistemas de recomendação educacional são filtragem colaborativa, filtragem baseada em conteúdo, filtragem híbrida e filtragem baseada em conhecimento.

Em [19] é proposto um sistema de recomendação personalizada de objetos de aprendizagem de acordo com os interesses do aluno e competências baseado em filtragem colaborativa. Outro trabalho [20] apresenta o RECoaComp - um recomendador de objetos de aprendizagem baseado em competências.

O DICA [21] é um sistema de recomendação de OA baseado em conteúdo que utiliza informações do Banco Internacional de Objetos Educacionais (BIOE), um repositório de objetos de aprendizagem. Faz esta recomendação de material de acordo com as semelhanças existentes entre os OAs e também disponibilizando um espaço para comentários.

O presente trabalho tem como diferencial em relação aos demais a busca além de bases estruturadas como os repositórios de objetos de aprendizado, realizando coleta de materiais educacionais disponíveis na web através de crawling e text mining aplicado ao português.

2.2 Análise de Sentimento

O *feedback* é mencionado como um elemento chave no ensino e aprendizagem [22]. A mineração de opiniões e a análise de sentimentos permite analisar as opiniões, sentimentos, avaliações, atitudes e emoções das pessoas em relação a entidades como produtos, serviços, organizações [23].

No contexto de educação, a aplicação de análise de sentimento, permitem entender a partir do *feedback* dos estudantes, por exemplo, que determinado conteúdo em uma plataforma de *e-learning* não é adequado ou precisa de melhorias [24]. Pode servir também para, a partir da opinião dos alunos sobre as aulas, facilitar a compreensão das necessidades dos alunos pelos professores, para que estes adequem suas aulas presenciais [8]

Em alguns trabalhos [24, 25] foram realizadas a análise de sentimento integrado a um sistema tutor com foco no ensino de programação, porém estes trabalhos foram voltados para textos em espanhol.

Uma das características da proposta deste artigo é a realização da análise de sentimento aplicada aos comentários dos objetos de aprendizagem registrados na plataforma, em português.

2.3 Learning Analytics

Apesar do uso de Learning Analytics aplicado em OAs poder potencializar a compreensão sobre o comportamento e a performance dos alunos, ainda há uma carência de alternativas que envolvam seu uso fora do escopo dos *Learning Management Systems* (LMS) ou ROAs, que costumam ser sobre contabilização de acesso, tempo e uso de *frameworks* para salvar resultados [5].

Alguns trabalhos propuseram extensões ao Adaptweb, como a aplicação das informações de Learning Analytics numa abordagem de gamificação [26] e numa abordagem de sistemas de recomendação em objetos de aprendizagem baseada nas escolhas do usuário estudante, tais como “o que aprender”, “como” e “com quem” [10].

Como mencionado, existem várias linhas de pesquisa voltadas para melhorar o processo de ensino-aprendizagem. O presente trabalho visa integrar soluções dessas diferentes linhas – Sistemas Inteligentes e Adaptativos, Sistemas de Recomendação, Análise de Sentimento e Learning Analytics – através de uma ferramenta que, além dos dados citados como normalmente coletados – quantidade e

tempos de acessos – também permite a coleta de avaliações objetivas e subjetivas sobre os OAs por parte do estudantes. Busca também fornecer uma base para estudos posteriores com os dados coletados.

3 MODELO PROPOSTO

Visando auxiliar estudantes e professores, o modelo proposto tem por objetivo facilitar a descoberta de conteúdo em diversas fontes de materiais educacionais e realizar uma recomendação híbrida de conteúdo adaptada às necessidades do estudante, levando em consideração também a análise de sentimentos sobre os *feedbacks* fornecidos pelos usuários do sistema (professores, monitores, estudantes). Este modelo pode ser aplicado tanto no âmbito de educação formal como em treinamentos informais.

A seções a seguir detalham melhor os componentes do modelo

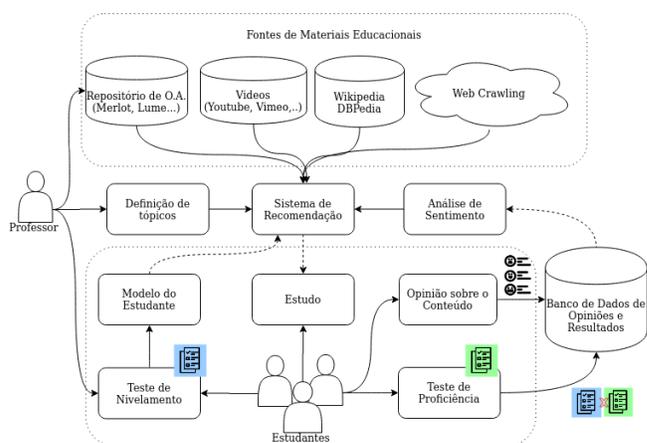


Figura 1: Modelo proposto de Sistema tutor .

3.1 Descoberta de Conteúdo

Para a descoberta de conteúdo são consideradas diversas fontes de materiais educacionais. Além dos tradicionais Repositórios de Objetos de Aprendizagem como o Merlot, são considerados também outras fontes como as plataformas de vídeos (Youtube, Vimeo), enciclopédia colaborativa (Wikipedia/DBPedia) e também conteúdo semi-estruturado na web, como portais educacionais.

Para acesso aos objetos de repositórios de objetos de aprendizagem existem alguns padrões de comunicação, tal como o SCORM, xAPI ou REST. No caso das plataformas de vídeo e enciclopédia é possível busca através do protocolo HTTP.

Para realizar o *crawling*, [27] apresenta um algoritmo para coleta de conteúdo web. A partir de um determinado conjunto de páginas sementes, analisa o conteúdo para extrair novos links, a estrutura e o texto do documento e realiza o processamento desse conteúdo.

Essas a busca de materiais educacionais é realizada nestas diversas fontes quando um novo tópico é cadastrado. Os professores também podem adicionar materiais

3.2 Modelo do Aluno

A modelagem do aluno consiste em rastrear os estados cognitivos, afetivos, motivacionais, entre outros, que são inferidos a partir da

performance do aluno no decorrer do processo de aprendizagem [28].

Uma das abordagens mais tradicionais para traçar esse perfil de conhecimento do estudante no âmbito de sistemas tutores é o *Baysean Knowledge Tracing* (BKT) [28, 29]. O BKT tem por objetivo inferir o modelo cognitivo do estudante através do monitoramento dos estados do conhecimento e a performance de acertos e de erros do estudante enquanto ele estuda.

Além do BKT existe uma série de outras abordagens, tais como Learning Factor Analysis, Learning Decomposition, Instructional Factor Analysis e mais recentemente o uso de Long Short Term Memory(LSTM) que são redes neurais de aprendizagem profunda [29].

Contudo, em meio a diversas abordagens complexas, [1] chama a atenção para o fato de que algumas ferramentas com estratégias mais simples, como o ASSISTments [30] obtiveram maior sucesso em serem utilizadas em larga escala. Uma das estratégias utilizada pelo ASSISTments para considerar que o estudante alcançou proficiência no tópico é quando este acerta três questões em sequência.

A partir dessa perspectiva de design mais simples e orientado a dados (*data-driven*) [1, 30], o modelo proposto neste artigo considera que o estudante alcançou proficiência em determinado tópico se acertou todas as questões selecionadas para o teste de nivelamento sobre este tópico. Neste caso não será necessário estudar este, sendo sugerido o estudo de outros tópicos que o estudante não tenha tanta proficiência.

3.3 Recomendação de Conteúdo

Os Sistemas de Recomendação podem ser classificados quanto a abordagem que utilizam para realizar a recomendação de itens ao usuário, tal como a Filtragem Colaborativa, baseada em conteúdo, em conhecimentos, abordagens híbridas, entre outras [31].

A filtragem colaborativa é uma das mais utilizadas e considera usuários de perfis semelhantes para a recomendação de itens. Para a filtragem baseada em conteúdo, uma forma frequentemente encontrada na literatura é através do cálculo de relevância dos documentos com base no TF-IDF, conforme Equação (1) [16, 32].

$$TF_IDF(t_k, d_j) = TF(t_k, d_j) \cdot \log \frac{N}{n_k} \quad (1)$$

O TF_IDF é usado para computar a importância geral de palavras chaves em um documento numa dada coleção. O d_j denota o documento em um espaço vetorial n-dimensional ($d_j = \{w_{1j}, w_{2j}, \dots, w_{nj}\}$), t_k denota a palavra chave no documento d_j , N denota o número de documento no corpus ou coleção e n_k denota o número de documentos na coleção em que o termo t_k ocorre pelo menos uma vez.

A abordagem baseada em conhecimento pode utilizar três tipos de conhecimento: sobre o usuário, sobre o item e sobre o casamento entre a necessidade do usuário e o item. Cada abordagem tem seus pontos fortes e fracos, sendo apontado pela literatura que abordagens híbridas conseguem melhores resultados combinando os principais aspectos de cada abordagem[33].

Dessa forma foi considerado para o presente modelo uma abordagem híbrida baseado em conhecimento e no resultado da análise de sentimento sobre as opiniões sobre os materiais educacionais.

3.4 Análise de Sentimento

As opiniões sobre o material educacional são registradas pelos usuários após o estudo. Estas opiniões são armazenadas em um banco de dados e são posteriormente utilizadas para o processamento da análise de sentimento.

Algumas das abordagens para a tarefa de análise de sentimento são a aprendizagem de máquina, baseada em léxico e abordagem híbrida [23, 24]. A abordagem utilizada no modelo proposto é a abordagem híbrida, conforme descrito na seção 4.5.

4 IMPLEMENTAÇÃO

O modelo proposto de sistema tutor inteligente afetivo possui três perfis de uso: Administrador, Professor e Aluno. O Administrador atribui perfis e a justos parâmetros. O Professor estrutura o curso/disciplina e o Aluno faz uso da estrutura para adquirir conhecimentos.

O modelo no perfil do Professor conta com o fluxo tradicional de sistema tutor, com os professores criando e adicionando conteúdo sobre o objeto de estudo, também podendo visualizar o desempenho dos alunos e adicionar outros materiais durante o curso conforme a necessidade. Já no perfil do Aluno, o fluxo inicia com a coleta de *feedback* explícito sobre o seu estado emocional e informações sobre o seu dia. Após isto, é realizado um teste de nivelamento, seguido da recomendação dos tópicos apropriados para estudo. Na sequência o aluno escolhe os tópicos de estudo e acessa os materiais de vídeo ou leitura, podendo fornecer *feedback* em áudio e texto para cada material estudado. Também é possível resolver exercícios propostos, e ao final dos seus estudos é realizada a avaliação final com o questionário cadastrado pelo Professor.

O Microtutor conta com um módulo de recomendação de estudos de acordo com o nível de conhecimento prévio do aluno, contando também com um extrator de sentimentos dos *feedbacks* textuais. A arquitetura completa do modelo é apresentada na Figura 1.



Figura 2: Tópicos de estudos sugeridos de forma personalizada ao conhecimento do aluno .

4.1 O Feedback Inicial

O primeiro contato do aluno participante é o registro de seu usuário, feito através de um formulário padrão com nome, e-mail e senha. Após o cadastro, temos o primeiro *feedback* consciente do aluno:

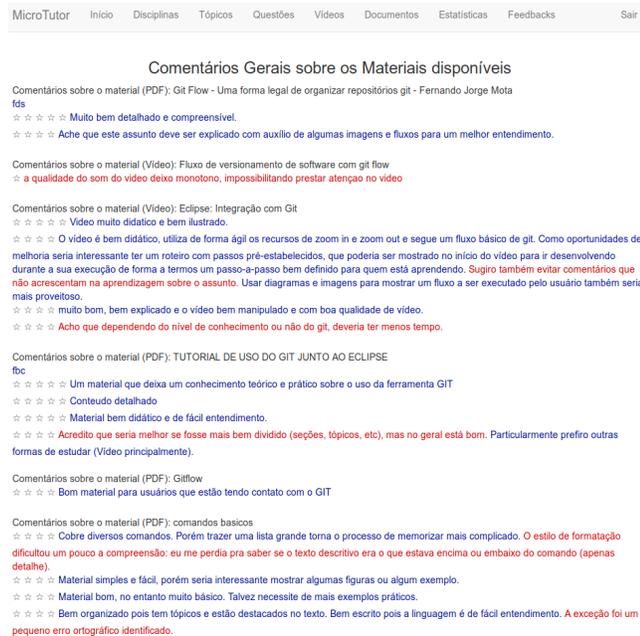


Figura 3: Resenhas sobre materiais educacionais mar cadas de acordo com polaridade de Análise de Sentimento Automática

comunicação expressa via áudio de como ele está se sentindo no momento. Esta informação pode ser importante em um futuro tutor inteligente afetivo, pois além do reconhecimento das expressões pela captura de vídeo, uma informação direta do aluno a respeito de como ele se sente e como está sendo seu dia pode ser bem aproveitada na tomada de decisão do tutor ao sugerir fluxos e materiais de estudo.

4.2 Nivelamento

Após o registro do *feedback* inicial, o participante escolhe a disciplina dos seus estudos. Em seguida há o direcionamento para uma página com questões para verificação do nível de proficiência do aluno com relação a cada tópico que será abordado na disciplina, de forma semelhante à Teoria da Resposta ao Item. Neste momento o aluno não tem conhecimento de quais são os tópicos, nem da ligação das questões com algum tópico. Respondidas as questões, é realizada a avaliação das respostas relacionadas a cada tópico da disciplina.

Caso o aluno tenha acertado as questões de nivelamento de um tópico específico, neste tópico haverá a informação de que o aluno tem conhecimentos suficientes. O mesmo aluno, tendo errado questões de um outro tópico, a informação seria a de que neste tópico o aluno poderia se beneficiar dos materiais disponíveis. Neste exemplo exibido na Figura 2, de disciplina com 4 tópicos, foram marcadas corretamente as questões referentes apenas aos dois primeiros tópico, ficando os 2 seguintes como sugestão para prosseguimento nos estudos.

A informação do nivelamento de que o aluno já domina um determinado tópico não impede o aluno de ter acesso aos materiais do mesmo, podendo ele acessá-los caso deseje aprimorar seus conhecimentos. Mas é relevante que isto lhe seja informado.

4.3 Os Tipos de Estudo à disposição

O Microtutor fornece três possibilidades de estudo ao aluno: visualização de vídeos, leitura de documentos e resolução de exercícios. Todos os materiais são cadastrados pelo professor responsável pela disciplina e cada material é vinculado a um tópico de estudo.



Figura 4: Escolha da modalidade de estudo

Os vídeos são embutidos de links externos para visualização interna, de modo que não são feitos *uploads* dos vídeos no sistema. O aluno pode visualizá-lo, expandir em tela cheia, pausar, acelerar e parar. Os documentos para leitura são arquivos em formato PDF. O aluno realiza a leitura diretamente nas páginas do sistema, podendo aumentar ou diminuir o zoom do documento. Os exercícios são questões objetivas de múltipla escolha.

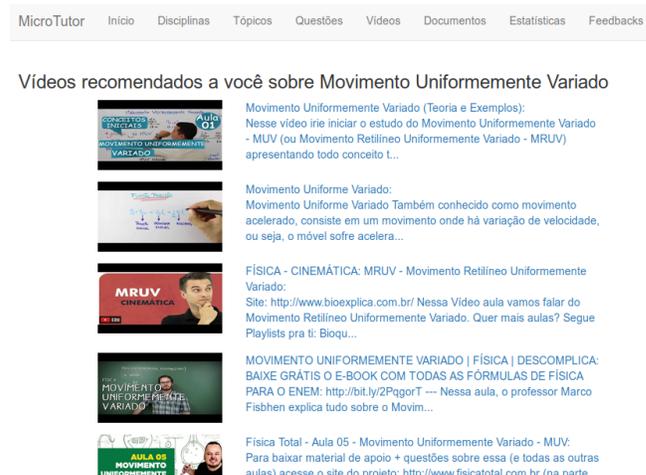


Figura 5: Exemplos de apresentação dos vídeos recomendados

4.4 Avaliação final de aproveitamento de estudos

Após o estudo dos materiais, o aluno pode fazer sua avaliação final para ser verificado o aproveitamento dos seus estudos com

as questões inicialmente propostas no nivelamento. Desta forma, é possível traçar um grau de evolução do aluno comparando-se o que ele já sabia ou não, com o que ele passou a saber após os estudos.

Como possível cenários podemos citar um aluno que não detinha bons conhecimentos prévios e após os estudos passou ou não a ter bons conhecimentos. Por outro lado, um aluno que possuía um nível de conhecimento considerado bom, e após os estudos o seu nível permaneceu o mesmo. São dados importantes para avaliação interna dos materiais em relação ao perfil daquele aluno, e podem ser utilizados em um módulo de recomendação de conteúdo para diferentes perfis.

4.5 Tecnologias utilizadas

A arquitetura do sistema proposto é baseada no modelo cliente-servidor web, utilizando o *microframework* Flask, na linguagem Python, e algumas ferramentas *client-side*, como o tempo de permanência na aba e gravação de áudio, foram em JavaScript. Um protocolo utilizado para facilitar o cadastro de objetos de aprendizagem foi o Open Graph¹, que permite a qualquer página web se tornar um objeto rico dentro de um grafo social através de tags de metadados. Dessa forma, a partir da url cadastrada pelo professor, é possível recuperar informações adicionais, tais como título, descrição, url de imagens e vídeos, que no presente trabalho são usados para a apresentação do material ao estudante.

Para o Processamento de Linguagem Natural e Análise de Sentimento foram utilizados os toolkits TextBlob² e NLTK³. Para a classificação quanto a polaridade da sentença, foi utilizado um classificador bayesiano a abordagem Bag-of-Words(BoW) e utilizando como dados de treinamento o dicionário Léxico ReLi-Lex [34].

Este dicionário foi criado a partir de um corpus composto por resenhas de livros publicadas na internet. Sua integração com o sistema tutor apresentou resultados promissores como pode ser visto na Figura 3. As sentenças classificadas como positivas aparecem em azul e as negativas em vermelho.

5 METODOLOGIA DE AVALIAÇÃO

A aplicabilidade do Microtutor como sistema tutor foi feita com a realização de um treinamento sobre GIT, um sistema de controle de versões de código em desenvolvimento de softwares⁴. Este treinamento foi realizado com cada aluno de forma individual numa sala com um notebook, com tempo de sessão de estudo sugerido de 15 minutos. Neste cenário, foram criadas questões sobre o assunto e selecionados previamente alguns vídeos e documentos como conteúdo para os participantes estudarem.

Participaram do treinamento, utilizando o sistema desenvolvido, 13 profissionais da área de Tecnologia da Informação de uma Instituição de Ensino Superior, divididos em 3 grupos, aleatoriamente. A cada grupo foi atribuído um perfil de estudo. O primeiro grupo, composto de 5 participantes, foi instruído a utilizar o Microtutor de maneira livre, da forma considerarem melhor para assimilar o conteúdo do treinamento. Ao segundo grupo, composto de 4 participantes, foi solicitado que acessassem materiais de estudo apenas

no formato de vídeo e exercícios. Para o terceiro grupo, com 4 participantes, foi solicitado que o acesso aos materiais fosse limitado aos documentos de leitura e exercícios.

Independentemente do grupo, todos os participantes eram solicitados a dar o *feedback* sobre este material. O *feedback* contava com campo de escrita livre e campo de nota variando de péssimo a muito bom numa escala *likert*. Também foi registrado pelo sistema métricas como o tempo do usuário em cada página ou material. Algumas dessas métricas irão compor os dados para Learning Analytics, como o tempo em que o estudante demora respondendo cada questão.

A verificação de aplicabilidade do Microtutor baseou-se no *feedback* dos alunos durante o uso do sistema e em entrevista com perguntas abertas, onde ressaltavam pontos positivos e negativos. Também se considera o tempo do participante no treinamento e de permanência em cada tela do sistema. Além da avaliação do Microtutor, os dados coletados serão fundamentais para o desenvolvimento do módulo de análise de sentimentos.

6 RESULTADOS

Os resultados obtidos são divididos em 3 subseções: Quantitativos, Opiniões dos Participantes, Análise de Sentimento.

6.1 Quantitativos

Os resultados quantitativos referem-se aos percentuais de acertos, tempo de treinamento e média da pontuação dada aos materiais no *feedback*, para cada participante de cada um dos 3 perfis de estudo, a saber: estudo livre, estudo de materiais de vídeo e estudo de materiais de leitura.

Resalta-se que boa parte dos participantes já possuíam conhecimentos prévios sobre o tema, uma vez que são profissionais da tecnologia da informação, onde alguns já trabalhavam com o assunto do treinamento.

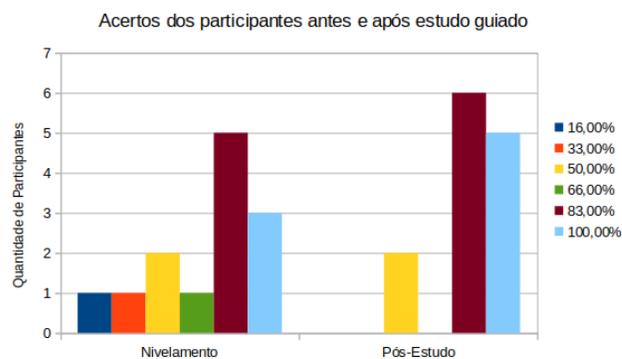


Figura 6: Tópicos de estudos sugeridos de forma personalizada ao conhecimento do aluno.

Pode-se verificar que, excluídos os participantes que obtiveram 100% no nivelamento, houve um aumento médio de 14% na pontuação dos participantes após realizar o treinamento, com alguns chegando a 33,33%. Observa-se também que o tempo médio de cada grupo ao fazer o treinamento varia, sendo o grupo de leitura de documentos o de menor tempo médio, o grupo de estudo livre com

¹<http://ogp.me/>

²<https://textblob.readthedocs.io>

³<http://www.nltk.org>

⁴<https://git-scm.com/>

tempo intermediário, e o grupo de visualização de vídeos o de maior tempo, chegando a uma média de 20 minutos.

Outro dado disponível nos resultados é a média da nota dada aos materiais por cada participante. É portanto possível verificar o grau de satisfação com os materiais.

6.2 Opiniões dos Participantes

Os participantes em geral relataram que o Microtutor é interessante e auxilia no processo de aprendizagem de temas que podem ser relevantes para os mesmos. Algumas frases registradas foram: “*Eu gostei muito desse sistema. Ele é simples mas ajuda a aprender*”, “*No começo eu não estava muito interessada mas acabou ficando interessante. Além do sistema, gostei muito do material utilizado*” e “*Pode ser um bom canal de treinamento*”. Alguns sugeriram possíveis melhorias como aprimorar a informação de acertos nos questionários que no momento é limitado a informar a quantidade de questões corretas ou incorretas, mas não informa quais foram os erros. Houve sugestões também de melhoria na etapa final, o questionário de avaliação pós estudos (aproveitamento), que estaria com poucas informações de que é a etapa de conclusão dos estudos, conforme observamos nas frases: “*Eu queria ter descoberto quais perguntas eu errei*” e “*Não entendi muito bem que tinha encerrado os estudos, não ficou muito claro*”.

6.3 Análise de Sentimento

Um exemplo da integração de análise de sentimento sobre os feedbacks dos estudantes em relação aos OAs pode ser visto na Figura 3. Podemos perceber que os feedbacks textuais, realçados pelo próprio sistema de acordo com a polaridade de sentimento classificada, facilitam a inspeção visual de críticas negativas ou construtivas mesmo dentro de um grupo de feedbacks com mesma nota objetiva positiva (4 - Bom). Apesar de resultados promissores, é possível melhorá-los através da utilização de modelos mais adaptados ao domínio, como mostram trabalhos efetuados em outros idiomas [24]

7 CONSIDERAÇÕES FINAIS

Foi desenvolvido um sistema tutor adaptativo que visa apoiar o processo de ensino e aprendizagem tanto para professores como para alunos. Os professores além de contarem com uma ferramenta para indicação de Objetos de Aprendizagem, podem ter acesso a informações sobre a evolução dos estudantes a partir dos dados de uso do sistema, como o tempo de permanência em determinado material e dos *feedbacks*. Também foi apresentada uma nova forma de disposição de comentários sobre Objetos de Aprendizagem, com a polaridade realçada automaticamente por meio de integração de módulo de Análise de Sentimento com o sistema tutor implementado.

Este sistema tutor informa quais são os tópicos mais adequados para o aluno complementar seus conhecimentos baseando-se no seu grau de proficiência prévia em determinado assunto. Dentre as formas de estudo possíveis para os alunos, possibilita-se a aprendizagem por vídeos, documentos e exercícios, podendo o aluno fornecer *feedback* sobre cada material disponibilizado. Todos esses

dados podem ser utilizados pelos professores e monitores para adicionar novos materiais ou remover materiais existentes, caso estes não estejam atingindo os objetivos desejados.

Com a disponibilização do sistema desenvolvido e um uso em maior escala por parte de estudantes e professores, será possível melhorar a relevância da recomendação de materiais educacionais. Como trabalhos futuros é possível aprimorar o modelo, estendendo por exemplo a análise de sentimentos para tratar dados multimodais (voz, expressões, etc.) ou a inclusão uso de web semântica e grafos de conhecimento para auxiliar a modelagem do domínio.

AGRADECIMENTOS

O presente trabalho foi realizado com financiamento de bolsa de estudos pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior do Brasil (CAPES), no âmbito do Programa PROCAD-AMAZÔNIA, processo N° 88881.357580/2019-01.

REFERÊNCIAS

- [1] Ryan S. Baker. Stupid Tutoring Systems, Intelligent Humans. *International Journal of Artificial Intelligence in Education*, 26(2):600–614, jun 2016. ISSN 15604306. doi: 10.1007/s40593-016-0105-0. URL <http://link.springer.com/10.1007/s40593-016-0105-0>.
- [2] Sidney D’mello and Art Graesser. AutoTutor and affective autotutor. *ACM Transactions on Interactive Intelligent Systems*, 2(4):1–39, dec 2012. ISSN 21606455. doi: 10.1145/2395123.2395128. URL <http://dl.acm.org/citation.cfm?doi=2395123.2395128>.
- [3] Ivon Arroyo, Beverly Park Woolf, Winslow Burelson, Kasia Muldner, Dovan Rai, and Minghui Tai. A Multimedia Adaptive Tutoring System for Mathematics that Addresses Cognition, Metacognition and Affect. *International Journal of Artificial Intelligence in Education*, 24(4):387–426, 2014. ISSN 1560-4306. doi: 10.1007/s40593-014-0023-y. URL <https://doi.org/10.1007/s40593-014-0023-y>.
- [4] George Siemens. Learning Analytics. *American Behavioral Scientist*, 57(10): 1380–1400, oct 2013. ISSN 0002-7642. doi: 10.1177/0002764213498851. URL <http://journals.sagepub.com/doi/10.1177/0002764213498851>.
- [5] João Guterres and Milene Silveira. Um panorama sobre Learning Analytics em Objetos de Aprendizagem. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação - SBIE)*, volume 29, page 1303, oct 2018. doi: 10.5753/cbie.sbie.2018.1303. URL <http://br-ie.org/pub/index.php/sbie/article/view/8090>.
- [6] Aline De Campos, Sílvia César Cazella, and Sílvia César Cazella. Learning Analytics em processos de personalização de aprendizagem: uma revisão sistemática de literatura. *RENOTE*, 16(1), aug 2018. doi: 10.22456/1679-1916.86028. URL <https://seer.ufrgs.br/renote/article/view/86028>.
- [7] Francesco Colace, Fabio Clarizia, Marco Lombardi, and Francesco Pascale. A Sentiment Analysis Approach for supporting Blended Learning Process. *Proceedings of the 24th International DMS Conference on Visualization and Visual Languages*, 2018:8–14, 2018. URL http://ksiresearch.org.ipage.com/seke/dms18paper/dms18paper_1.pdf.
- [8] Leonardo Preuss, Joel Dos Santos, and Gustavo Paiva Guedes. VITA - Estimando a satisfação de estudantes por meio da Análise de Sentimentos. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação - SBIE)*, page 1143, oct 2018. doi: 10.5753/cbie.sbie.2018.1143. URL <http://br-ie.org/pub/index.php/sbie/article/view/8074>.
- [9] Christopher Krauss, Agathe Merceron, Truong-Sinh An, Miggi Zwicklbauer, Stephan Steglich, and Stefan Arbanowski. Teaching Advanced Web Technologies with a Mobile Learning Companion Application. In *Proceedings of the 16th World Conference on Mobile and Contextual Learning - mLearn 2017*, pages 1–4, New York, New York, USA, 2017. ACM Press. ISBN 9781450352550. doi: 10.1145/3136907.3136937. URL <http://dl.acm.org/citation.cfm?doi=3136907.3136937>.
- [10] Alessandro Da Silveira Dias and Leandro Wives. Definition of Learner Choices from Learner-Driven Learning for Ubiquitous e-Learning Systems and its Application in the AdaptWeb Platform. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação - SBIE)*, volume 29, page 118, oct 2018. doi: 10.5753/cbie.sbie.2018.118. URL <http://br-ie.org/pub/index.php/sbie/article/view/7963>.
- [11] Jose Wallison da Silva and Cidley De Souza. Repositórios de Objetos de Aprendizagem - características, classificações, limitações e tendências. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação - SBIE)*, volume 28, page 61, oct 2017. doi: 10.5753/cbie.sbie.2017.61. URL <http://www.br-ie.org/pub/index.php/sbie/article/view/7535>.

- [12] Kurt VanLehn, Arthur C. Graesser, G. Tanner Jackson, Pamela Jordan, Andrew Olney, and Carolyn P. Rosé. When Are Tutorial Dialogues More Effective Than Reading? *Cognitive Science*, 31(1):3–62, feb 2007. ISSN 03640213. doi: 10.1080/03640210709336984. URL <http://doi.wiley.com/10.1080/03640210709336984>.
- [13] Benjamin S. Bloom. The 2 Sigma Problem: The Search for Methods of Group Instruction as Effective as One-to-One Tutoring. *Educational Researcher*, 13(6):4–16, jun 1984. ISSN 0013-189X. doi: 10.3102/0013189X013006004. URL <http://journals.sagepub.com/doi/10.3102/0013189X013006004>.
- [14] José Palazzo Moreira de Oliveira, Maria Angélica de Oliveira Camargo Brunetto, Mário Lemes Proença Júnior, Marcelo Soares Pimenta, Cora Helena Francisconi Pinto Ribeiro, José Valdeni de Lima, Veronice de Freitas, Viviane Sodré Prado Marçal, Isabela Gasparini, and Marília Abrahão Amaral. Adaptweb: um ambiente para ensino/aprendizagem adaptativo na Web. *Educar em Revista*, pages 175–197, 2003. ISSN 0104-4060. doi: 10.1590/0104-4060.305. URL http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0104-40602003000300009&lng=pt&tng=pt.
- [15] Helena Macedo Reis, Patricia Augustin Jaques, and Seiji Isotani. Sistemas Tutores Inteligentes que Detectam as Emoções dos Estudantes: um Mapeamento Sistemático. *Revista Brasileira de Informática na Educação*, 26(3):76, sep 2018. ISSN 2317-6121. doi: 10.5753/rbie.2018.26.03.76. URL <http://www.br-ie.org/pub/index.php/rbie/article/view/7184>.
- [16] John K. Tarus, Zhendong Niu, and Ghulam Mustafa. Knowledge-based recommendation: a review of ontology-based recommender systems for e-learning. *Artificial Intelligence Review*, 50(1):21–48, jun 2018. ISSN 0269-2821. doi: 10.1007/s10462-017-9539-5. URL <http://link.springer.com/10.1007/s10462-017-9539-5>.
- [17] Victor Ferreira, Germano Vasconcelos, and Rozelma França. Mapeamento Sistemático sobre Sistemas de Recomendações Educacionais. *Anais do XXVIII Simpósio Brasileiro de Informática na Educação (SBIE 2017)*, 1(Cbie):253, 2017. doi: 10.5753/cbie.sbie.2017.253.
- [18] Jéssica Laisa, Taina Medeiros, Eduardo Aranha, and Thiago Reis da Silva. Uma Revisão Sistemática da Literatura sobre Sistemas de Recomendação Educacional. *Anais do Computer on the Beach*, 0(0):751–760, 2018. URL <https://siaiap32.univali.br/seer/index.php/acotb/article/view/12893>.
- [19] Sílvio César Cazella, Eliseo Berni Reategui, Munique Machado, and Jorge Luis V. Barbosa. Recomendação de Objetos de Aprendizagem Empregando Filtragem Colaborativa e Competências. *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação - SBIE)*, 1(1), nov 2009. ISSN 2316-6533. URL <https://www.br-ie.org/pub/index.php/sbie/article/view/1158>.
- [20] Sílvio Cazella, Patricia Behar, Daisy Schneider, Ketia da Silva, and Rodrigo Freitas. Desenvolvendo um Sistema de Recomendação de Objetos de Aprendizagem baseado em Competências para a Educação: relato de experiências. *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação - SBIE)*, 23(1):26–30, 2012. ISSN 2316-6533. URL <https://www.br-ie.org/pub/index.php/sbie/article/view/1710>.
- [21] Felipe José Rocha Vieira and Maria Augusta Silveira Netto Nunes. DICA: Sistema de Recomendação de Objetos de Aprendizagem Baseado em Conteúdo. *Scientia Plena*, 8:1–10, 2012. ISSN 1808-2793. URL <http://www.scientiaplena.org.br/ojs/index.php/sp/article/view/464>.
- [22] Anna D. Rowe. Feelings About Feedback: The Role of Emotions in Assessment for Learning. In *Scaling up Assessment for Learning in Higher Education*, pages 159–172. Springer, Singapore, 2017. doi: 10.1007/978-981-10-3045-1_11. URL http://link.springer.com/10.1007/978-981-10-3045-1_11.
- [23] Bing Liu. *Sentiment Analysis and Opinion Mining*. Morgan & Claypool Publishers, 2012. ISBN 1608458849 9781608458844.
- [24] Maria Lucia Barron-Estrada, Ramon Zatarain-Cabada, Raul Oramas-Bustillos, and Francisco Gonzalez-Hernandez. Sentiment Analysis in an Affective Intelligent Tutoring System. In *Proceedings - IEEE 17th International Conference on Advanced Learning Technologies, ICALT 2017*, pages 394–397. IEEE, jul 2017. ISBN 9781538638705. doi: 10.1109/ICALT.2017.137. URL <http://ieeexplore.ieee.org/document/8001815/>.
- [25] Raul Oramas-Bustillos, Maria Lucia Barron-Estrada, Ramon Zatarain-Cabada, and Sandra Lucia Ramirez-Avila. A Corpus for Sentiment Analysis and Emotion Recognition for a Learning Environment. In *2018 IEEE 18th International Conference on Advanced Learning Technologies (ICALT)*, pages 431–435. IEEE, jul 2018. ISBN 978-1-5386-6049-2. doi: 10.1109/ICALT.2018.00109. URL <https://ieeexplore.ieee.org/document/8433556/>.
- [26] Aline Nunes Ogawa, Ana Carolina Tomé Klock, and Isabela Gasparini. Integrando Técnicas de Learning Analytics no processo de Gamificação em um Ambiente Virtual de Aprendizagem. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação - SBIE)*, volume 28, page 615, oct 2017. doi: 10.5753/cbie.sbie.2017.615. URL <http://www.br-ie.org/pub/index.php/sbie/article/view/7590>.
- [27] Ricardo Baeza-Yates and Berthier Ribeiro-Neto. *Recuperação de Informação: Conceitos e Tecnologia das Máquinas de Busca*. Bookman Editora, Porto Alegre, 2013.
- [28] Robert A. Sottolare, Arthur Graesser, Xiangen Hu, and Heather Holden. *Design recommendations for intelligent tutoring systems*, volume 1 - Learner Modeling. U.S. Army Research Laboratory, Orlando, 2013. ISBN 978098932303.
- [29] Ye Mao, Chen Lin, and Min Chi. Deep Learning vs. Bayesian Knowledge Tracing: Student Models for Interventions. *Journal of Educational Data Mining*, 10(2):28–54, 2018. URL <https://jedm.educationaldatamining.org/index.php/JEDM/article/view/318>.
- [30] Neil T. Heffernan and Cristina Lindquist Heffernan. The ASSISTments Ecosystem: Building a Platform that Brings Scientists and Teachers Together for Minimally Invasive Research on Human Learning and Teaching. *International Journal of Artificial Intelligence in Education*, 24(4):470–497, dec 2014. ISSN 1560-4292. doi: 10.1007/s40593-014-0024-x. URL <http://link.springer.com/10.1007/s40593-014-0024-x>.
- [31] H. Drachler, K. Verbert, O. C. Santos, and N. Manouselis. Panorama of recommender systems to support learning. In *Recommender Systems Handbook, Second Edition*, pages 421–451. Springer US, 2015. ISBN 9781489976376. doi: 10.1007/978-1-4899-7637-12.
- [32] Pasquale Lops, Marco de Gemmis, and Giovanni Semeraro. Content-based Recommender Systems: State of the Art and Trends. In *Recommender Systems Handbook*, pages 73–105. Springer US, Boston, MA, 2011. doi: 10.1007/978-0-387-85820-3_3. URL http://link.springer.com/10.1007/978-0-387-85820-3_3.
- [33] Aline Campos, Gabriela Santos, and Patricia A Behar. Mapeamento de soluções tecnológicas em sistemas de recomendação educacionais em âmbito brasileiro. *Informática na educação: teoria & prática*, 20(3 set/dez):78–93, 2017. ISSN 1982-1654. doi: 10.22456/1982-1654.79624.
- [34] Cláudia Freitas. Sobre a construção de um léxico da afetividade para o processamento computacional do português. *Revista Brasileira de Linguística Aplicada*, 13(4):1031–1059, nov 2013. ISSN 1984-6398. doi: 10.1590/S1984-63982013005000024. URL http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1984-63982013000400004&lng=pt&tng=pt.