

**UNIVERSIDADE FEDERAL DE ALAGOAS-UFAL
INSTITUTO DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM COMPUTACIONAL DO
CONHECIMENTO**

RANDERSON DOUGLAS RIBEIRO DOS SANTOS

**ANÁLISE DA ADERÊNCIA DE RECOMENDAÇÕES EXPLICADAS DE RECURSOS
EDUCACIONAIS PARA APOIAR O ENSINO E A APRENDIZAGEM EM UM
AMBIENTE EDUCACIONAL ONLINE.**

**MACEIÓ - AL
2019**

Randerson Douglas Ribeiro dos Santos

Análise da Aderência de Recomendações Explicadas de Recursos Educacionais para Apoiar o Ensino e a Aprendizagem em um Ambiente Educacional Online.

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Modelagem Computacional do Conhecimento do Instituto de Computação da Universidade Federal de Alagoas

Orientador: Prof. Dr. Ig Ilbert Bittencourt Santana Pinto

Coorientador: Prof. Dr. Ranilson Oscar de Araújo Paiva

Maceió - AL

2019

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico

Bibliotecário: Marcelino de Carvalho Freitas Neto – CRB-4 – 1767

S237a Santos, Randerson Douglas Ribeiro dos.
Análise da aderência de recomendações explicadas de recursos educacionais para apoiar o ensino e a aprendizagem em um ambiente educacional *online* / Randerson Douglas Ribeiro dos Santos. – 2020.
114 f. : il.

Orientador: Ig Ilbert Bittencourt Santana Pinto.
Co-orientador: Ranielson Oscar de Araújo Paiva.
Dissertação (mestrado em Modelagem Computacional do Conhecimento) – Universidade Federal de Alagoas. Instituto de Computação. Maceió, 2019.

Bibliografia: f. 104-107.
Apêndices: f. 108-114.

1. Ensino à distância. 2. Sistemas de recomendação. 3. Ambiente virtual de aprendizagem. 4. Inteligência artificial. I. Título.

CDU: 004.89

Folha de Aprovação

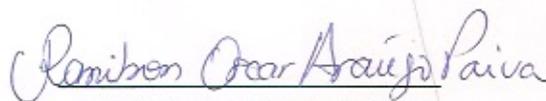
Randerson Douglas Ribeiro dos Santos

Análise da Aderência de Recomendações Explicadas de Recursos Educacionais para
Apoiar o Ensino e Aprendizagem em um Ambiente Educacional Online

Dissertação submetida ao corpo docente do
Programa de Pós-Graduação em Modelagem
Computacional de Conhecimento da
Universidade Federal de Alagoas e aprovada
em 18 de dezembro de 2019.



Prof. Dr. Ig Ibert Bittencourt Santana Pinto
Instituto de Computação - UFAL
orientador



Prof. Dr. Ranilson Oscar Araújo Paiva
Instituto de Computação - UFAL
Co-orientador

Banca Examinadora:



Prof. Dr. Diego Dermeval Medeiros da Cunha Matos
Faculdade de Medicina - UFAL
Examinador Interno



Prof. Dr. Alan Pedro da Silva
Instituto de Computação - UFAL
Examinador externo

Dedico este trabalho primeiramente a Deus que sempre esteve à frente de tudo e a minha família que sempre me apoiou.

AGRADECIMENTOS

À Deus em primeiro lugar, pela condição e oportunidade que me deu para realizar esse trabalho, pois Ele é a minha base e se não fosse pela vontade dEle, nada disso teria acontecido. A fé em Deus foi algo primordial para permanecer firme, confiante e seguindo em frente, rumo ao objetivo final.

À minha esposa e filhos que sempre acreditaram e incentivaram no sucesso do trabalho, estando ao meu lado nas horas mais difíceis e felizes da minha vida. E sendo bastante pacientes nos meus momentos de nervosismo e estresse.

Aos meus pais Benedito dos Santos e Lúcia de Fátima dos Santos Ribeiro, que foram essenciais para que essa realização dessa trabalho. Sempre me apoiando e contribuindo, dando todo o suporte necessário.

Aos meus irmão Wanderson Davisson Ribeiro dos Santos e Wyslane Fernanda Ribeiro dos Santos.

Aos meus sogros, que me ajudaram durante o processo de curso, onde a família começou a crescer e o suporte oferecido foi primordial.

Aos meus prezados e queridos orientadores Ranilson Oscar de Araújo Paiva e Ig Ibert Bittencourt Santana Pinto, que contribuíram bastante durante todo o processo de desenvolvimento deste trabalho, pela paciência e compreensão em alguns momentos, dedicação e amizade.

Não fui eu que lhe ordenei? Seja forte e corajoso! Não se apavore, nem se desanime, pois o Senhor, o seu Deus, estará com você por onde você andar.

Josué 1:9

RESUMO

Com o avanço das Tecnologias da Informação e Comunicação (TICs) e da Educação a Distância (EaD), os ambientes online de aprendizagem adquiriram uma posição de destaque como ferramentas potencializadoras do processo de aprendizagem. E pode-se ver que essas ferramentas vem ganhando uma grande popularidade pelo fato de tornar o processo de aprendizagem mais dinâmico, tornando o conteúdo adaptável para cada aluno, trazendo um ensino individualizado, dentre outros fatores. Mas, como esses ambientes disponibilizam muitos recursos para os usuários, isso pode causar uma confusão na construção do aprendizado, pois ainda que esses ambientes forneçam algumas recomendações visando auxiliar os usuários a fazerem boas escolhas, a falta de explicação pode ocasionar uma baixa aceitação, devido a falta de transparência. E isso têm sido um problema em IA, pois previsões/recomendações são feitas, mas não vem acompanhadas de explicações. Ou seja, mesmo com as recomendações, muitos usuários não conseguem progredir, pelo fato de não entenderem o que foi sugerido/recomendado e não compreenderem o motivo de tal recomendação, achando que a recomendação não se aplica ao seu perfil ou sua necessidade e simplesmente rejeitam a recomendação. Desse modo, este trabalho tem por objetivo investigar o efeito das recomendações explicadas em relação a aderência (aceitação) dos usuários em ambientes online de aprendizagem, analisando se, há ou não diferença significativa nesses ambientes (com explicação e sem explicação). Para validar a proposta, foi projetado um sistema de aprendizagem e nele foi disponibilizado um curso de estatística descritiva, onde diante das interações dos alunos, foi criado o modelo do aluno. Desse modo, retiramos um caso aleatoriamente do modelo do aluno, onde elaboramos um cenário e criamos um survey, que fornecia 4 recomendações (duas com explicações e duas sem explicações) e algumas afirmações que eram exibidas de forma gradual, para cada cenário exposto, para que os participantes pudessem responder. E para cada recomendação foi solicitado que o participante respondesse algumas afirmações que foram propostas, utilizando um escala likert. Sendo assim, foi realizada a coleta e análise dos dados, onde utilizamos uma análise fatorial, por meio de um teste pareado (Wilcoxon), para comparar os resultados de cada cenário, afim de avaliar as opiniões dos participantes. Mediante a realização do experimento, viu-se que, assim como em outros ambientes a explicação também trouxe bons resultados nas recomendações de recursos educacionais, onde houve uma maior aceitação por parte do usuário, quando ele passou a entender o motivo de tal recomendação, podendo julgar se aquilo de fato é relevante ou não.

Palavras-chave: EAD; Sistemas de Recomendação; Recomendações Explicadas; Recomendações Transparentes; Explicação;

ABSTRACT

With the advancement of Information and Communication Technologies (ICTs) and Distance Education (EaD), online learning environments have acquired a prominent position as tools that enhance the learning process. And it can be seen that these tools have been gaining a great popularity due to the fact that they make the learning process more dynamic, making the content adaptable for each student, bringing an individualized teaching, among other factors. However, as these environments provide many resources for users, this can cause confusion in the construction of learning, because although these environments provide some recommendations to help users make good choices, the lack of explanation can cause low acceptance, due to the lack of transparency. And this has been a problem in AI, as predictions / recommendations are made, but are not accompanied by explanations. That is, even with the recommendations, many users are unable to progress, due to the fact that they do not understand what was suggested / recommended and do not understand the reason for such recommendation, thinking that the recommendation does not apply to their profile or their need and simply reject the recommendation. Thus, this work aims to investigate the effect of the recommendations explained in relation to adherence (acceptance) of users in online learning environments, analyzing whether or not there is a significant difference in these environments (with explanation and without explanation). In order to validate the proposal, a learning system was designed and a descriptive statistics course was made available, where, in view of the students' interactions, the student model was created. Thus, we removed a case randomly from the student's model, where we elaborated a scenario and created a survey, which provided 4 recommendations (two with explanations and two without explanations) and some statements that were displayed gradually, for each exposed scenario, for that participants could respond to. And for each recommendation, the participant was asked to answer some statements that were proposed, using a likert scale. Therefore, data collection and analysis was performed, where we used a factor analysis, through a paired test (Wilcoxon), to compare the results of each scenario, in order to evaluate the participants' opinions. Upon carrying out the experiment, it was seen that, as in other environments, the explanation also brought good results in the recommendations of educational resources, where there was a greater acceptance by the user, when he started to understand the reason for such recommendation, judge whether that is really relevant or not.

Keywords: EAD; Systems of Recommendation; Recommendations Explained; Transparent Recommendations; Explanation;

LISTA DE FIGURAS

Figura 1 – Explain Hint Feature	37
Figura 2 – Módulo de Explicações junto da Predição.	40
Figura 3 – Módulo de Explicações antes da Predição.	40
Figura 4 – Dimensões da Taxonomia	49
Figura 5 – Modelo adaptado de (ZAINA, 2008)	59
Figura 6 – Modelo do aluno - tela 01.	60
Figura 7 – Modelo do aluno - tela 02.	61
Figura 8 – Modelo do aluno - tela 03.	61
Figura 9 – Modelo do aluno - tela 04.	62
Figura 10 – Recomendações em forma de notificações.	63
Figura 11 – Listagem das Recomendações.	64
Figura 12 – Criação da Recomendação Explicada oferecendo questões como recurso educacional.	67
Figura 13 – Criação da Recomendação Explicada oferecendo vídeos como recursos educacionais.	69
Figura 14 – Criação da Recomendação Explicada oferecendo links como recursos educacionais.	70
Figura 15 – Fluxo do processo de criação das recomendações explicadas.	72
Figura 16 – Organização do curso.	75
Figura 17 – Fluxo do Experimento.	77
Figura 18 – Gráfico das recomendações não explicadas	90
Figura 19 – Gráfico das recomendações explicadas	90

LISTA DE TABELAS

Tabela 1 – Tabela comparativa dos trabalhos relacionados	54
Tabela 2 – Tabela de interações de um usuário específico	58
Tabela 3 – Variáveis, tipos e possíveis valores	79
Tabela 4 – A tabela mostra os dados referente a primeira recomendação, que foi sem explicação. Seguem os resultados:	86
Tabela 5 – A tabela mostra os dados referente a segunda recomendação, a qual foi explicada. Seguem os resultados:	87
Tabela 6 – Nesta tabela estão as informações referente a terceira recomendação, que não tinha nenhuma explicação.	88
Tabela 7 – A tabela abaixo ilustra a quarta recomendação que vem acompanhada de explicação, onde os seguintes resultados puderam ser observados.	89
Tabela 8 – Teste de Normalidade Shapiro Wilk.	92
Tabela 9 – Análise descritiva - Afirmação 1	93
Tabela 10 – p-valor afirmação 1	93
Tabela 11 – Análise descritiva - Afirmação 2	94
Tabela 12 – p-valor afirmação 2	95
Tabela 13 – Análise descritiva - Afirmação 3	95
Tabela 14 – p-valor - afirmação 3	96
Tabela 15 – Análise descritiva - Afirmação 4	97
Tabela 16 – p-valor - afirmação 4	97
Tabela 17 – Análise descritiva - Afirmação 5	98
Tabela 18 – p-valor - afirmação 5	98
Tabela 19 – Análise descritiva - Afirmativa 6	99
Tabela 20 – p-valor - afirmação 6	99

LISTA DE ABREVIATURAS E SIGLAS

SR	Sistema de Recomendação
EAD	Educação a Distância
IA	Inteligência Artificial
SEED	Secretaria de Educação a Distância
MEC	Ministério da Educação
TIC	Tecnologias de Informação e Comunicação
STI	Sistema Tutor Inteligente
IPA	Agentes Pedagógicos Inteligentes
CAI	Instrução Assistida por Computador
M5	Algoritmo de Predição e Classificação
ML	Machine Learning
SM	Sofisticação Musical
API	Agentes Pedagógicos Inteligentes
OLM	Open Learner Model
ACSP	Applet Constraint Satisfaction Problem
TCLE	Termo de Consentimento Livre e Esclarecido

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Contexto	14
1.2	Problemática	17
1.3	Proposta de Solução	17
1.4	Objetivos gerais e específicos	19
1.5	Hipóteses	19
1.6	Metodologia	20
1.7	Estrutura do Trabalho	21
2	FUNDAMENTAÇÃO TEÓRICA	23
2.1	Educação a distância	23
2.2	Ambientes Online de Aprendizagem	24
2.3	Sistema de Recomendação	25
2.4	Explicação	27
2.5	Modelagem e Modelo do Aluno	29
2.5.1	Modelagem	29
2.5.2	Modelo do Aluno	30
3	TRABALHOS RELACIONADOS	32
3.1	Personalized explanations for hybrid recommender systems	32
3.2	Using explanations for recommender systems in learning design settings to enhance teachers' acceptance and perceived experience	33
3.3	Exploring the Need for Explainable Artificial Intelligence (XAI) in Intelligent Tutoring Systems (ITS)	36
3.4	Transparency in Fair Machine Learning: the Case of Explainable Recommender Systems	38
3.5	Learning from explanations in recommender systems	41
3.6	How should I explain? A comparison of different explanation types for recommender systems	43
3.7	Evaluating the effectiveness of explanations for recommender systems Methodological issues and empirical studies on the impact of personalization	44
3.8	A Taxonomy for Generating Explanations in Recommender Systems	47
3.9	A Survey of Explanations in Recommender Systems	49
3.10	Tabela Comparativa	53

4	PROPOSTA	56
4.1	Os Elementos Necessários para a Criação das Recomendações Explicadas .	58
4.1.1	Modelo do Aluno	59
4.1.2	Os filtros	62
4.1.3	Os recursos de aprendizagem	62
4.1.4	A recomendação dos recursos de aprendizagem	63
4.1.5	A explicação	64
4.1.5.1	Estrutura da automatização da recomendação explicada	66
4.1.6	Questões como Recurso Recomendativo	67
4.1.7	Vídeos como Recurso Recomendativo	68
4.1.8	Links como Recurso Recomendativo	70
4.2	Criação das recomendações	70
5	METODOLOGIA	73
5.1	Experimento	73
5.1.1	Tecnologias utilizadas na criação da plataforma	73
5.1.2	Panejamento do experimento	74
5.1.3	Estrutura do curso	75
5.1.4	Fluxo de interação com o curso	76
5.1.5	Survey	80
5.2	Variáveis Experimentais	82
5.3	Participantes	83
5.4	Técnica de Recomendação Utilizada	83
6	RESULTADOS E DISCUSSÕES	85
6.1	Análise dos dados	91
6.2	Teste de Normalidade por cenário e afirmação	92
6.3	AFIRMAÇÃO 1 - A recomendação oferecida a mim foi apropriada (justifica o problema descrito).	93
6.4	AFIRMAÇÃO 2 - O texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação.	94
6.5	AFIRMAÇÃO 3 - O texto da recomendação faz (motiva) com que eu siga tal recomendação.	95
6.6	AFIRMAÇÃO 4 - A recomendação está clara (Sou capaz de entende-lá e saber o que devo fazer).	96

6.7	AFIRMAÇÃO 5 - Se eu fosse o aluno 8, eu seguiria essa recomendação. . .	98
6.8	AFIRMAÇÃO 6 - Acho importante que o sistema explique porque uma recomendação foi gerada.	99
7	CONCLUSÃO	101
7.1	Limitações	102
7.2	Trabalhos futuros	103
	REFERÊNCIAS	104
	APÊNDICE A – TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO . .	108
	APÊNDICE B – QUESTIONÁRIO	110
	ANEXO A –	115

1 INTRODUÇÃO

Neste capítulo contextualizaremos sobre o tema desta pesquisa, iniciando a partir da EAD (onde se iniciou o processo de disseminação da educação utilizando-se meios tecnológicos), adentrando no assunto, ambientes online de aprendizagem, pois é o domínio que utilizaremos, posteriormente, falaremos sobre Sistemas de Recomendação (SR), bem como da Inteligência Artificial (IA) que atua como ferramenta primordial para otimizar o processo de personalização, e por fim as explicações, que no contexto desta pesquisa, é o ato de justificar o motivo da recomendação. Trataremos sobre os objetivos, problemas, hipóteses, a metodologia que foi utilizada para construção da solução, e a estrutura de organização do trabalho.

1.1 CONTEXTO

A modalidade de educação a distância (EAD) cresceu muito nos últimos anos, e um dos fatores que contribuiu para este crescimento foram as facilidades proporcionadas pelo desenvolvimento tecnológico (ALMEIDA, 2003). O surgimento de novas tecnologias computacionais de comunicação possibilitou o desenvolvimento de ambientes online de aprendizagem, cujo objetivo é propagar e facilitar o processo de ensino, com a possibilidade de personalizar esse processo, dadas as necessidades de cada aluno. No ensino a distância (mediado pelos ambientes online de aprendizagem), o estudante precisa assumir o protagonismo pelo processo de aprendizagem, onde o professor atua como coadjuvante (VIANNA, 2015).

Os ambientes online de aprendizagem são programas de computador com propósitos educacionais, que incorporam técnicas de IA, devido à possibilidade de simulação do pensamento humano para auxiliar na resolução de problemas, permitindo que seja desenvolvido um processo de método socrático, através de um ensino individualizado (FOWLER, 1991). Um ambiente online de aprendizagem clássico é composto por quatro componentes interdependentes: um modelo de aluno, uma unidade pedagógica, uma unidade cognitiva e uma unidade de comunicação (SARRAFZADEH et al., 2008). Esses quatro elementos de uma arquitetura tradicional de ambientes online de aprendizagem podem ser encontrados com nomes diferentes, mas são usados para os mesmos fins. E os exemplos desses ambientes são: STI, AVA, MOOC e etc. Especificamente, (ALKHATLAN; KALITA, 2018) referem que um ambiente online de aprendizagem consiste em quatro componentes básicos: um modelo de domínio, um modelo de aluno, um modelo de tutor e um modelo de interface com o usuário.

Em suma, pode-se dizer que, esses ambientes são softwares educacionais via internet,

destinados a apoiar as atividades de educação a distância. Estes softwares podem oferecer um conjunto de tecnologias de informação e comunicação, que permitem desenvolver as atividades no tempo, espaço e ritmo de cada participante (por meio do ensino personalizado) e possuem uma grande importância no processo de disseminação do conhecimento, principalmente pelo fato de estarem diretamente ligados aos meios tecnológicos de longo alcance (ALMEIDA, 2003). E desse modo funcionam como um meio para realização de cursos à distância, o que tem por objetivo gerar uma democratização na educação, atingindo um maior número de pessoas, dos mais diversos aspectos, sejam eles: físicos, sociais ou econômicos (ALVES, 2011) e (ALMEIDA, 2003).

Esses ambientes proporcionam alguns tipos de interações, conforme a abordagem feita por (MOORE, 1989), (ALMEIDA, 2003) e (LAGUARDIA et al., 2007), como exemplo: usuário-usuário, usuário-conteúdo e usuário-ambiente de aprendizagem. Assim como existem diversas formas de interações, os recursos educacionais oferecidos podem ser apresentados de várias formas (vídeos, textos, questões, provas, e etc.) e em grande quantidade, possuindo diversas características (assuntos, níveis de dificuldade e etc.). Dessa forma os estudantes podem interagir com qualquer conteúdo, que esteja livremente acessível/disponível pelo ambiente de ensino. Sendo assim, os estudantes devem escolher quais dos diversos conteúdos (itens) disponíveis, eles querem interagir.

Observando um ambiente online de aprendizagem, diante de suas possibilidades de interações, conteúdos, e características, vemos como um desafio para o aluno, identificar os melhores caminhos a seguir dentro da plataforma, para que possa obter êxito em seu aprendizado. Sendo assim, a IA, surge com uma proposta de oferecer ao aluno um ensino personalizado, ou seja, focando nas necessidades e habilidades de cada aluno. Pois, dentre as diversas vantagens que a IA proporciona, ela também possibilita a facilidade na mineração de dados e permite a identificação de padrões, que é de grande valia para os SRs, que são sistemas que utilizam técnicas de filtragem que carregam informações compatíveis aos interesses dos alunos, ou histórico comportamental sobre um item. Sendo capaz de prever que um item (recurso), está correlacionado com a preferência/necessidade de um aluno, baseando-se em seu modelo. Mas, geralmente as recomendações não possuem um detalhamento que forneça transparência para o usuário receptor da informação (GUNNING, 2017).

Contudo, mesmo com todos os benefícios trazidos pela geração atual de sistemas de IA, o autor (GUNNING, 2017), afirma que, sua eficácia está limitada pela incapacidade que a máquina possui, em explicar suas decisões e ações aos usuários. Pois, conforme (GEDIKLI et

al., 2014), além de ajudar o usuário a entender a saída e lógica do sistema, a prestação de tais explicações também pode melhorar a aceitação geral, qualidade percebida ou eficácia do sistema. Vale ressaltar que esse tema (explicação das decisões/recomendações geradas por sistemas de IA “denominada transparência”) tem se tornado uma preocupação mundial, discutida por representantes de todos os continentes, na UNESCO ¹.

E para que as recomendações sejam assertivas, existem dois tipos de ações que podem ser realizadas. A primeira delas é que o modelo do aluno deve estar bem ajustado, contendo o máximo de interações possíveis, onde essas interações podem ser adquiridas por uma compra de dados ou por coletas feitas pelo próprio sistema à medida que estiver sendo utilizado. E com base nas interações obter a criação do modelo do aluno, que são construídos a partir de dados do aluno geralmente coletados por um sistema de tutoria inteligente por meio da interação do aluno com o sistema de tutoria. O modelo do aluno permite que os sistemas de tutoria e instrutores entendam os pontos fortes e fracos de seus alunos. Com base nisso, a abordagem instrucional pode ser adaptada às necessidades de cada aluno ou grupo de alunos específico. O modelo do aluno pode ser definido como uma representação estruturada do conhecimento, conceitos errôneos e dificuldades de um aluno (BULL, 2004). Um modelo aberto do aluno permite que os alunos visualizem e analisem seu modelo de aluno. Ele capacita os alunos a examinar sua própria representação, incentivando comportamentos metacognitivos, como autoconsciência e autorregulação. De acordo com (KAY et al., 1997), um modelo de aluno aberto pode ajudar os alunos a entender seu progresso e processos de aprendizagem. A outra forma de melhorar uma recomendação é através da otimização do algoritmo utilizado na técnica de filtragem, e isso requer um especialista em machine learning, deep learning, etc. Tanto a primeira forma quanto a segunda, são possíveis formas de melhorias, onde no primeiro caso além de requerer um tempo considerável para aquisição dos dados, pode também requerer um bom investimento financeiro, caso seja necessário adquirir uma base pronta. Isso também é um problema visto no segundo caso, pois quando o assunto é melhoria de algoritmos utilizados em sistema de recomendação, estimasse que seja necessário um investimento considerável em mão de obra especializada. Um exemplo real disso é o caso da netflix, que é uma das maiores plataformas de streaming de vídeo do mundo, e que está oferecendo US\$ 1 milhão para quem fizer uma melhoria de 10% na performance do algoritmo de recomendação, visando uma maior aderência em relação às recomendações oferecidas para os usuários.

¹ Evento Mobile Learning Week 2019 - UNESCO

1.2 PROBLEMÁTICA

Devido à grande quantidade e diversidade de informações disponíveis nesses ambientes, torna-se difícil, dependendo da experiência pessoal do indivíduo, escolher a melhor informação para consumir ou até mesmo indicar para outros (CAZELLA et al., 2010). Essa variedade pode trazer uma dificuldade para o aluno, deixando-o confuso (pelo fato de vários recursos abordarem o mesmo assunto de inúmeras formas), sem saber qual recurso educacional ele deve escolher, diante das recomendações oferecidas. Onde o aluno pode vir a ignorar a recomendação, pelo simples fato de não compreendê-las. Dessa forma, é preciso guiar o estudante com base nas recomendações de itens (recursos educacionais), de forma explicativa, para que ele compreenda o motivo de tal recomendação, confie no conteúdo recomendado, e possa decidir segui-la ou não.

Sendo assim, conforme (SCHNABEL et al., 2018), uma boa recomendação não está relacionada somente com um algoritmo que ofereça uma boa performance e uma maior correlação com o perfil do usuário, mas que existem outros fatores como, por exemplo, a interface que oferece a recomendação. Diante desse aspecto, vale ressaltar a importância da explicabilidade da recomendação (transparência), para que o usuário possa entender o motivo de ter recebido uma determinada recomendação e, com base nessa informação, decidir se a recomendação foi, ou não, apropriada para as suas necessidades de aprendizagem. Dessa forma, o estudante pode, com mais transparência (embasado por informações fundamentadas), decidir seguir, ou não, a recomendação recebida. Pois, conforme (WELLER, 2017), a transparência é frequentemente considerada crítica para permitir a implantação efetiva de sistemas inteligentes no mundo real. Contudo, IA deve ser confiável, deve justificar (explicar) suas conclusões de maneira inteligível (transparente), o mais simples possível, e responder dinamicamente à perguntas de acompanhamento - tudo para ajudar os humanos a entenderem melhor seus dados (ABDOLLAHI; NASRAOUI, 2018) e (PUTNAM; CONATI, 2019).

1.3 PROPOSTA DE SOLUÇÃO

Diante da grande quantidade de informações presente nos ambientes online de aprendizagem, muitas recomendações são ofertadas para os usuários com finalidade de ajuda-los na tomada de decisão, mas devido às recomendações não justificarem para os usuários o motivo de estarem sendo oferecidas, os usuários podem recusar ou ignorar algo que pode ser de grande valia (CAZELLA et al., 2010)(GUNNING, 2017). Desse modo, acreditamos que a falta de explicação pode gerar incertezas e possíveis rejeições.

Conforme (PUTNAM; CONATI, 2019), acredita-se que tornar as técnicas de IA mais transparentes, pode aumentar a confiança do usuário e fornecer aos usuários, informações que possam desenvolver sua compreensão do mecanismo de aprendizado de um sistema inteligente. Sendo assim, diversas formas podem ser utilizadas para sanar o problema, tais como: otimização do algoritmo (calibragem), um banco de dados bastante robusto, com diversas interações que permitisse obter um modelo exato do usuário, onde para esse segundo caso, isso poderia ocorrer de duas formas: aguardar que a base fique robusta, com várias interações, e isso levaria um bom tempo e poderia vir a comprometer a confiabilidade do usuário no sistema; a outra forma seria comprar os dados de uma base de interações já existente. Em todos esses casos de possíveis soluções existe um alto custo financeiro, seja com pessoal ou com dados.

Diante da ausência de explicações nos sistemas de recomendação, acreditamos que muitos estudantes podem ignorar as recomendações, pelo simples fato de não saberem o motivo dela estar sendo sugerida. Um outro problema é que uma recomendação pedagógica seja vista como genérica, e, não atenda as necessidades do aluno; desse modo, a explicação seria uma alternativa para mostrar que a recomendação foi gerada com base nos dados educacionais. Há, ainda, o problema do estudante não ter a percepção clara da situação pedagógica na qual se encontra. Sendo assim, a explicação além de necessária, ela deve levar em consideração os dados educacionais dos estudantes, extraindo deles as informações necessárias para gerar recomendações personalizadas e explicadas.

Dentro desse cenário (sistemas de recomendações), aplicado a sistemas educacionais (que é o foco desta pesquisa), viu-se a necessidade de agregar explicações junto das recomendações, visando ajudar o estudante compreender o motivo de tal recomendação/sugestão, obtendo uma melhor percepção, podendo gerar uma maior aceitação. Com a utilização do fator explicação, nós poderíamos melhorar os sistemas de recomendação, dando qualidade as recomendações, oferecendo transparência para o usuário, afim de auxiliá-lo nas tomadas de decisão. Onde teríamos um custo muito baixo com relação às soluções anteriores.

Dessa forma, como as principais funções dos sistemas de recomendação são analisar os dados dos usuários e extrair informações úteis para futuras previsões (CHEN; MCLEOD, 2006), e como os SR utilizam a IA (mecanismos e dispositivos tecnológicos que possam simular o raciocínio humano), que por sua vez peca no quesito, explicabilidade. E como as boas recomendações vão além de algoritmos que oferecem previsões assertivas, de modo que outros fatores também contribuem para sua aceitação e qualidade (SCHNABEL et al., 2018). Diante disso, vimos a possibilidade de analisar a adição de explicações às recomendações que são

oferecidas aos alunos de um curso realizado em um ambiente online de aprendizagem, contendo itens, que no contexto dessa pesquisa, são os recursos educacionais ² (por exemplo: vídeos, textos, links, questões e outros) que serão sugeridos com base na necessidade do aluno, E dessa forma avaliaremos se o fator, explicação, afeta a aceitação da recomendação.

1.4 OBJETIVOS GERAIS E ESPECÍFICOS

Os principais objetivos deste trabalho são:

Oferecer recomendações personalizadas, criadas com base no modelo do aluno (criado com base nas interações dos estudantes com os recursos educacionais disponíveis no ambiente online de aprendizagem), levando em consideração o desempenho pedagógico e interação do aluno. Avaliar o efeito da explicação da recomendação de recursos/conteúdos educacionais, onde o enfoque é investigar se o fator “explicação” da recomendação causa impacto, na sua aceitação. Ou seja, **analisar o efeito (se houver) das recomendações explicadas vs as recomendações sem explicação, em relação à aderência³, no contexto da educação online.**

Desse modo, os objetivos específicos são:

- Criar recomendações automáticas e personalizadas com base no modelo do aluno.
- Analisar a aceitação das recomendações em relação aos itens (conteúdos/recursos) recomendados nos dois casos (com explicação e sem explicação).

1.5 HIPÓTESES

A presente pesquisa tem como hipótese de que as explicações possuem um efeito positivo, no tocante a aceitação de uma recomendação,

tendo em vista que o fator “explicação” fornece ao usuário a possibilidade de entender o motivo da recomendação oferecida de modo transparente, fornecendo informações para embasar a decisão de seguir ou não a recomendação feita.

Dessa forma, foram levantadas as seguintes questões de pesquisa e suas respectivas hipóteses:

QP1 - A aceitação das recomendações por parte dos usuários é maior nos casos com explicações, do que nos casos sem explicações?

² que são recursos que estão disponíveis no sistema e que visam ajudar o aluno no processo de aprendizagem

³ Ato de aceitar e seguir o que foi proposto.

- $H_{1:0}$ - Não Existem diferença significativa na aceitação das recomendações em ambientes com explicações e sem explicações.

ACEITAÇÃO (Explicação) = ACEITAÇÃO (Sem Explicação)

- $H_{1:1}$ - Existem diferença significativa na aceitação das recomendações em ambientes com explicações e sem explicações.

ACEITAÇÃO (Explicação) \neq ACEITAÇÃO (Sem Explicação)

QP2 - O ato de fazer/seguir/completar as recomendações é maior nos casos com explicações, do que nos casos sem explicações?

- $H_{1:0}$ - Não Existem diferença significativa do ato de fazer/seguir/completar as recomendações em ambientes com explicações e sem explicações.

FAZER (Explicação) = FAZER (Sem Explicação)

- $H_{1:1}$ - Existem diferença significativa ato de fazer/seguir/completar as recomendações em ambientes com explicações e sem explicações.

FAZER (Explicação) \neq FAZER (Sem Explicação)

Em resumo, acredita-se que, o fato de explicar o motivo de algum conteúdo está sendo recomendado, leva a uma maior aceitação e seguimento (aderência) da recomendação por parte dos usuários.

1.6 METODOLOGIA

Fundamentando-se em (GIL, 2007) e (FONSECA, 2016), esse estudo experimental foi conduzido pela seguinte metodologia de pesquisa:

Para avaliarmos a nossa questão de pesquisa, criamos um ambiente online de aprendizagem, capaz de recomendar conteúdo personalizado com base em um modelo criado para cada

estudante, que considera as suas interações e o desempenho pedagógico do aluno. O ambiente educacional online oferece um curso de estatística que contempla a seguinte estrutura hierárquica: curso (estatística descritiva), módulos (1,2,3,4), assuntos (introdução a estatística, medidas de tendência central, medidas de dispersão, assimetria e curtose) e tópicos (conceitos, moda, media, mediana, separatriz, desvio médio, desvio padrão, coeficiente de variação, assimetria e curtose), respectivamente. Cada um dos tópicos existentes, possuem recursos educacionais (vídeos, textos, apresentações de aulas, questões e links externos) atrelados a si, para auxiliar os alunos no processo de aprendizagem. Ao iniciar o curso, cada aluno participante será observado quanto as suas interações e desempenho na resolução de questões, e sempre que o sistema identificar uma baixa interação e/ou baixa assertividade referente as questões, serão enviadas notificações (que aparecerão no topo da tela do sistema, ficando listadas em uma página específica) para o estudante, contendo recomendações de recursos educacionais, oferecidos com base na necessidade percebida através do modelo do aluno. De forma aleatória o sistema enviará recomendações explicadas para alguns casos, e sem explicação, em outros. Dessa maneira, o aluno poderá marcar a recomendação como aceita ou recusada. Cada uma dessas recomendações ficarão disponíveis para o aluno durante um determinado período estimado no plano de estudos, onde a não marcação das opções (aceite ou recusada), será considerada como recusada, tendo em vista que o aluno a ignorou. Ao final, o aluno responderá um survey com alguns casos coletados do próprio curso, abrangendo os dois cenários (com explicação e sem explicação), onde ele poderá fornecer o feedback se a recomendação oferecida foi apropriada; se o texto da recomendação explica motivo dele está recebendo tal recomendação; se o texto da recomendação motiva para que a mesma seja seguida; e se a recomendação está clara, de modo que ele compreenda e saiba o que deve ser feito. Com base na coleta de todos esses dados, será feita uma correlação do tipo de recomendação com a aceitação dos alunos.

1.7 ESTRUTURA DO TRABALHO

O trabalho está dividido da seguinte forma: no capítulo 2 (Fundamentação Teórica) são apresentados os principais conceitos e definições sobre o tema desta pesquisa, consiste na revisão de textos, artigos, livros, periódicos, enfim, todo o material pertinente para embasar o trabalho. No capítulo 3 (Trabalhos Relacionados), são citados os principais trabalhos, com finalidade de destacar o que já foi feito de importante, assim como, os resultados obtidos sobre o problema em questão. No capítulo 4 (Proposta) é apresentada a proposta do trabalho, contendo a descrição de cada etapa da possível solução. No capítulo 5 (Metodologia) estão atividades que foram

executadas para elaboração da pesquisa. o capítulo 6 (Resultados e Discussões), contém os resultados obtidos, através da realização do experimento o relato para cada situação, bem como, as análises. o capítulo 7 (Conclusão), contém o fechamento do trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, apresentamos a fundamentação teórica que serviu de base para esta pesquisa e abordaremos os conceitos necessários para o entendimento desta dissertação. Nesse sentido, distribuímos as seções da forma como segue: na seção 2.1, será apresentado um breve panorama da educação a distância; na sequência, abordaremos ambientes online de aprendizagem na seção 2.2. Na seção 2.3 trataremos sobre sistemas de recomendação. Na seção 2.4, faremos uma abordagem sobre explicação. Na seção, 2.5 serão apresentados aspectos de modelagem e modelo do aluno.

2.1 EDUCAÇÃO A DISTÂNCIA

A Educação a Distância não surgiu do nada, ela tem uma longa história de experimentações, sucessos e fracassos. Sua origem recente, já longe das cartas de Platão e das epístolas de São Paulo, está nas experiências de educação por correspondência iniciadas no final do século XVIII e com largo desenvolvimento a partir de meados do século XIX (chegando aos dias atuais a utilizar vários meios que vão desde os impressos até simuladores online, em redes de computadores, avançando em direção da comunicação instantânea de dados de voz-imagem via satélite ou por cabos de fibra ótica, com aplicação de formas de grande interação entre o aluno e o centro produtor, quer se utilizando de inteligência artificial-IA, ou mesmo de comunicação instantânea com professores e monitores) (NUNES, 1993).

A Educação a Distância - EaD, é um recurso de incalculável importância como modo apropriado para atender a grandes contingentes de alunos de forma mais efetiva que outras modalidades e sem riscos de reduzir a qualidade dos serviços oferecidos em decorrência da ampliação da clientela atendida (NUNES, 1993).

Conforme (ALVES, 2011), EaD é uma modalidade de educação efetivada através do intenso uso de tecnologias de informação e comunicação, onde professores e alunos estão separados fisicamente no espaço e/ou no tempo, está sendo cada vez mais utilizada na Educação Básica, Educação Superior e em cursos abertos, entre outros. O autor acima traz em sua abordagem alguns dos benefícios associados à EAD, tais como: flexibilidade de tempo, economia no deslocamento até o local de estudos, vários meios de aprendizagem, interação com pessoas de diferentes culturas e experiências profissionais, além da oportunidade de estudar a partir de novas metodologias e tecnologias.

Mediante o crescimento da EAD seja no sistema formal (graduação, pós-graduação,

cursos técnicos, etc.) quanto não formal (módulos instrucionais, rádio, televisão, telefone e outros recursos) de ensino, foi criada a Secretaria de Educação a Distância (SEED), pelo Ministério da Educação (MEC), cuja finalidade seria inovar a área tecnológica nos processos de ensino e aprendizagem, promovendo a pesquisa e o desenvolvimento, voltados para a introdução de novos conceitos e práticas em escolas públicas brasileiras. Pois, conforme (DIAS; LEITE, 2010), A SEED foi criada com a missão de “atuar como agente de inovação dos processos de ensino-aprendizagem, fomentando a incorporação das Tecnologias de Informação e Comunicação (TICs) e da Educação a Distância aos métodos didático-pedagógicos das escolas públicas”.

As buscas por melhores condições de ensino em relação à EAD são um grande avanço para a educação no Brasil. Essa consolidação no meio educacional é importante para alcançar patamares de qualidade, com criatividade e inovação dos cursos a distância, garantindo que os alunos que buscam sua formação por meio desta modalidade possam ter efetividade na sua aprendizagem e formação adequada.

Neste trabalho, consideramos a EAD como uma plataforma de grande importância para a expansão da educação, pela possibilidade de aprendizagem personalizada, e dentre outros fatores que tornam o processo de aprendizagem flexível e acessível a todos. Desse modo, utilizamos o ambiente como objeto de estudo (junto a outros aspectos, que serão abordados nos próximos capítulos), por possuírem uma grande diversidade de recursos pedagógicos (vídeos, chat, fóruns, avaliações, etc.) que são elementos importantes para a presente pesquisa e por se tratar de um ambiente bastante utilizado pelas organizações educacionais.

2.2 AMBIENTES ONLINE DE APRENDIZAGEM

A aprendizagem online é um tipo de método de entrega usado na educação a distância que permite a troca síncrona e assíncrona de recursos por uma rede de comunicação (KHAN, 1998). O Ambiente de Aprendizagem Online é também o sistema que envolve o aluno e o professor em termos de aspectos técnicos e sociais (KHAN, 2000).

A maioria dos autores descreve a aprendizagem online como o acesso a experiências de aprendizagem através do uso de alguma tecnologia ((BENSON, 2002); (CARLINER, 2004)). (BENSON, 2002) identifica a aprendizagem online como uma versão mais recente do ensino à distância, o que melhora o acesso a oportunidades educacionais para os alunos, descritos como não tradicionais e desprivilegiados.

Outros autores discutem não apenas a acessibilidade da aprendizagem online, mas também sua conectividade, flexibilidade e capacidade de promover interações variadas ((ALLY,

2004); (HILTZ; TUROFF, 2005)). (HILTZ; TUROFF, 2005), em particular, não apenas evitam o relacionamento de aprendizado online com sistemas de ensino à distância e de entrega tradicional, mas também (BENSON, 2002) afirma claramente que o aprendizado online é uma versão mais nova ou melhorada do ensino à distância.

(FRANÇA et al., 2013) diz que, esses ambientes podem ser usados no desenvolvimento do processo de ensino - aprendizagem virtual ou semipresencial. Por exemplo, um professor e/ou tutor podem disponibilizar materiais, textos, vídeos e áudios, além das atividades. Os alunos acessam esses recursos, de qualquer local que tenham acesso à Internet, trocam ideias, materiais, informações, respondem às atividades, aos fóruns, entre outros. Assim, ele permite que sejam propostas atividades que promovem estas ações e possibilidades, mas exigem que nos libertemos do modelo centralizador privilegiado pela transmissão de conhecimento, evoluindo para um processo compartilhado em que o professor atua, mais do que no presencial, como um elemento do grupo, deixando à comunidade a liderança das atividades de intervenção, acompanhamento e construção do conhecimento.

2.3 SISTEMA DE RECOMENDAÇÃO

Com a finalidade de fomentar o processo de ensino-aprendizagem a ideia de sistemas de recomendação foi acoplada ao processo, com intuito de oferecer boas recomendações baseada nas necessidades do aluno, pois de modo geral os sistemas de recomendação auxiliam no aumento da capacidade e eficácia deste processo de indicação, já bastante conhecido na relação social entre seres humanos (RESNICK; VARIAN, 1997). Em um sistema típico, as pessoas fornecem recomendações como entradas e o sistema agrega e direciona para os indivíduos considerados potenciais interessados neste tipo de recomendação. Um dos grandes desafios deste tipo de sistema é realizar o casamento correto entre os que estão recomendando e aqueles que estão recebendo a recomendação, ou seja, definir e descobrir este relacionamento de interesses.

Os Sistemas de Recomendação são grandes aliados da personalização de sistemas computacionais, principalmente na web. Os Sistemas de Recomendação são capazes de identificar preferências e sugerir itens relevantes para cada usuário, de acordo com a análise de seu comportamento de navegação, consulta e/ou compra, preferências, entre outros aspectos.

Com a finalidade de encontrar sugestões relevantes para o usuário, os sistemas de recomendações atuam utilizando técnicas de filtragem para buscar os itens a serem recomendados. De acordo com (BURKE, 2002) as técnicas existentes são:

- **Filtragem Baseada em Conhecimento:** as recomendações são geradas a partir de conhecimento sobre o usuário ou sobre os produtos. Um sistema de recomendação baseado em conhecimento tem a capacidade de perceber como um determinado item se encaixa com a necessidade do usuário. Através disto ele consegue raciocinar sobre a relação entre a necessidade do usuário e uma possível recomendação.
- **Filtragem Baseada em Utilidade:** prever a utilidade de itens para um determinado usuário baseado nos itens previamente avaliados por outros usuários. É usada para medir a utilidade de uma lista ordenada por um sistema de filtragem para o usuário. Em um sistema de filtragem de informação onde o resultado de uma filtragem é retornado como uma lista de itens ordenados pela relevância, é presumível que o usuário irá investigar apenas os primeiros elementos da lista na sua busca por itens que lhe interessam (BREESE et al., 1998).
- **Filtragem Demográfica:** Usuários classificados em classes com relação a perfis em comum; Calcula-se a similaridade entre dois usuários utilizando Informações demográficas destes, como idade e profissão.
- **Filtragem Baseada em Outros Contextos:** Envolvendo aspectos psicológicos (inteligência emocional) do usuário combinados aos aspectos caracterizadores dos itens;
- **Filtragem Baseada em Conteúdo:** Utiliza informações anteriores do usuário em relação a um item para recomendar itens similares.
- **Filtragem Colaborativa:** Baseia-se no julgamento de usuários com interesses em comum. Para isso, os usuários devem avaliar os itens do sistema, e essas avaliações permitem descobrir médias para os itens; com isso, o Sistema de Recomendação pode descobrir padrões de comportamento e sugerir automaticamente os itens considerados mais interessantes pelos usuários com gostos similares.

Dentre as técnicas mencionadas, as mais utilizadas são: **Filtragem Colaborativa e Filtragem Baseada em Conteúdo.**

Os sistemas de recomendação, na maioria dos casos, apresentam algumas limitações quando utilizados em contextos educacionais. Nessas situações, é necessário considerar outras questões além das preferências do professor ou do estudante em determinado recurso, mas também o quanto o recurso irá ajudá-los a alcançar os objetivos de aprendizagem (TANG; MCCALLA, 2004).

2.4 EXPLICAÇÃO

Para Spinoza ¹ (e por definição para todos os filósofos racionalistas) 'explicar' quer dizer mostrar que uma proposição verdadeira é a consequência logicamente necessária de alguma outra; explicação essencialmente envolve exigir conexões necessárias; e "conexão necessária" nesse contexto quer dizer uma conexão estritamente lógica pela análise lógica das ideias envolvidas. Segundo Aristóteles a explicação parte do ato de justificar as conexões ideológicas.

Contudo, mediante a tantas recomendações, como identificar as que possuem maiores relevâncias? Como entender o motivo de tal recomendação no contexto educacional, com base no perfil e nas particularidades do estudante? As explicações são fatores que ajudam a tomar decisões assertivas. O conceito de explicação é frequentemente explorado em tarefas de comunicação e raciocínio humano. Consequentemente, a pesquisa dentro da inteligência artificial - em particular, no desenvolvimento de sistemas que imitam o comportamento humano - mostrou grande interesse na natureza das explicações, como, por exemplo (WELLER, 2017). Começando com a pergunta: "O que é uma explicação?", somos confrontados com um número quase ilimitado de possibilidades, onde de acordo com Hempel e Oppenheim ², a essência da explicação está em uma relação de implicação causal entre dois enunciados ou grupo de enunciados: o que explica - o explanans - e o que descreve o evento a ser explicado - o explanandum.

Enfrentando desafios tão fundamentais, pode-se perguntar: porque os sistemas de recomendação devem lidar com as explicações? A resposta está relacionada com às duas partes fornecendo e recebendo recomendações. Por exemplo, um agente de vendas pode estar interessado em promover determinados produtos, enquanto um agente de compras está preocupado em tomar a decisão de compra correta. As explicações são informações importantes que podem ser exploradas por ambos os agentes ao longo do processo de comunicação para aumentar seu desempenho, tendo em vista que ela torna o processo de tomada de decisão mais fácil, onde o usuário consegue identificar o que é relevante ou não para ele. Agentes diferentes formularão explicações com intenções diferentes - por exemplo, um agente de compras procura pechinchas e explicações que justifiquem decisões, enquanto um agente de vendas tenta melhorar os lucros fornecendo argumentos convincentes ao agente de compra. Escolhemos analisar o fenômeno das explicações de um ponto de vista pragmático. Apesar da diversidade de propostas para caracterizar o conceito de explicação, quase todas as fontes concordam que uma explicação é

¹ Stuart Hampshire, Spinoza (London: Penguin Books, 1953, primeira edição de 1951), p. 35.

² HEMPEL, G.; OPPENHEIM, P. (1948), "Studies in the logic of explanation". *Philosophy of Science*, 15(2):135-175.

uma informação trocada em um processo de comunicação.

Visando agregar ainda mais valor no processo de fornecimento de recomendações, as autoras (TINTAREV; MASTHOFF, 2011), falam sobre alguns objetivos que podem ser alcançados com a utilização das explicações em sistemas de recomendação, dessa forma as autoras relatam cada um dos objetivos. Sendo eles:

Transparência: Visam fornecer informações para que o usuário possa compreender o raciocínio usado para gerar uma recomendação específica.

Validação: Explicações podem ser geradas para permitir que um usuário verifique a validade de uma recomendação.

Confiança: Pode ser vista como um mecanismo para reduzir a complexidade da tomada de decisão em situações de incerteza

Persuasão: Explicações persuasivas para recomendações visam alterar o comportamento de compra do usuário.

Eficácia: As explicações para melhorar a eficácia normalmente ajudam o cliente a descobrir suas preferências e tomar decisões que maximizam a satisfação em relação ao produto selecionado.

Eficiência: As explicações visando aumentar a eficiência tipicamente tentam reduzir o tempo necessário para a tomada de decisões.

Satisfação: As explicações podem tentar melhorar a satisfação geral resultante do uso de um sistema de recomendação.

Relevância: Explicações podem ser fornecidas para justificar por que informações adicionais são necessárias do usuário.

Compreensibilidade: As explicações que visam a compreensão dão suporte ao usuário relacionando os conceitos conhecidos do usuário aos conceitos empregados pelo recomendador

Educação: As explicações podem ter como objetivo educar os usuários para ajudá-los a entender melhor o domínio do produto. Pois, o profundo conhecimento sobre o domínio ajuda os usuários a repensar suas preferências e avaliar os prós e contras de diferentes soluções. Onde, à medida que os clientes se tornam mais informados, eles são capazes de tomar decisões de escolha mais inteligentes. Como, por exemplo alunos que possuem dificuldades em determinados conteúdos, o sistema pode analisar as preferências baseado no perfil, preferências de recursos (com base na navegação do usuário) e oferecer recomendações que sejam atraentes (recomendando recursos no qual o usuário tem mais afinidade), e que atuem na necessidade do usuário, no tocante ao contexto o qual está sendo estudado. No contexto dos sistemas de recomendação, essas informações complementam uma recomendação com objetivos diferentes (JANNACH et al., 2010).

2.5 MODELAGEM E MODELO DO ALUNO

2.5.1 Modelagem

A modelagem é a atividade humana de construir modelos, sejam eles concretos ou abstratos (RODRIGUES; FERRACIOLI, 2006). A modelagem é um processo de construção de um modelo específico, selecionando um subconjunto de variáveis que descrevem o comportamento de um sistema, onde o nível de sofisticação estará diretamente relacionado à habilidade do modelador, ou seja, de sua experiência, conhecimento, julgamento, intuição, percepção e imaginação (SANTOS, 2002). Um modelo, por sua vez, pode ser definido como a representação de uma ideia, um objeto, um evento, um processo ou um sistema. Essa definição pode evoluir em direção ao entendimento de modelos como representações concretas, tais como, um objeto, uma maquete, um protótipo ou um sistema físico, quanto ao entendimento de modelos como representações abstratas, tais como, um pensamento, uma ideia, um evento ou um processo.

Conforme (RODRIGUES; FERRACIOLI, 2006), a modelagem aplicada ao ensino de tópicos específicos em ciência pode ser feita a partir da utilização de ambientes de modelagem computacional. Um ambiente de modelagem computacional consiste em uma ferramenta computacional onde os estudantes podem construir modelos a partir de suas próprias concepções sobre o fenômeno estudado ou explorar modelos já prontos desses fenômenos. Essas ferramentas são denominadas de ambiente de modelagem devido ao fato de haver uma proposta educacional associada à sua utilização. Os ambientes de modelagem computacional podem ser classificados de acordo com o raciocínio empregado na construção dos modelos no ambiente. Dessa forma, tem-se:

- **Modelagem Semiquantitativa**

Ambientes que enfocam o entendimento de relações causais entre os elementos do sistema e a análise do efeito nessas relações – acréscimo e decréscimo – mas não no conhecimento dos valores numéricos das relações algébricas.

- **Modelagem Qualitativos**

Nestes ambientes os modelos são criados sem a especificação de variáveis, relações algébricas ou quantidades, mas pela especificação dos seus constituintes básicos e das regras que determinam seus comportamentos. Existem dois tipos de atividades utilizando a modelagem computacional denominadas por (MELLAR; BLISS, 1994) de atividade expressiva

e a exploratória cuja diferenciação é baseada na relação de interação entre o estudante e a ferramenta de modelagem computacional.

- **Modelagem Exploratória**

O estudante é levado a explorar um modelo previamente construído por um professor ou especialista sobre um determinado fenômeno.

- **Modelagem Expressiva**

O estudante é levado a construir seus próprios modelos a partir de suas próprias concepções sobre um fenômeno ou sistema. Sendo assim, os ambientes de modelagem computacional são utilizados de acordo com a forma de raciocínio empregada na construção ou exploração dos modelos dos fenômenos do mundo que nos cerca.

2.5.2 Modelo do Aluno

Dentre os diversos modelos existentes na arquitetura de sistemas de aprendizagem, enfatizaremos o Modelo do Aluno, pois será o protagonista do processo de ensino-aprendizagem a ser explorado nesta pesquisa, dessa forma foram trazidas algumas perspectivas de visão de alguns autores com relação a este modelo.

O modelo de aluno é uma sobreposição no modelo de domínio. Ele enfatiza estados cognitivos e afetivos do aluno em relação à sua evolução à medida que o processo de aprendizagem avança. À medida que o aluno trabalha passo-a-passo no processo de solução de problemas, o sistema se engaja no processo de rastreamento de modelo (ALAWAR; NASER, 2017).

A personalização é a chave dos sistemas educacionais inteligentes atuais. Ela acontece por meio do modelo do aluno (ANDERSON, 2013). É o seguimento que constrói o perfil do aluno definindo o nível de conhecimento e o tipo de situações que costuma apresentar para solução de problemas (heurística). O modelo do aluno contém informações a respeito do aluno: como ele aprende, sobre seu estado emocional ou sobre seu conhecimento a respeito do assunto que está sendo abordado (modelo cognitivo), suas preferências (perfil de aprendizagem), seu desempenho em atividades educacionais e traços de sua personalidade, por exemplo. Não necessariamente todas estas ou apenas estas informações costumam estar presentes no modelo do aluno. Em alguns casos, esse modelo contém apenas informações sobre como um aluno está resolvendo um determinado problema em uma situação de ensino/aprendizagem. Neste caso, o modelo possui

o estado cognitivo do aluno e também representa o processo que o aluno está utilizando para buscar a solução do problema. O quanto de informação é necessário o modelo conter depende da finalidade do sistema de ensino/aprendizagem. A qualidade dessas informações vai contribuir para estabelecer a inteligência do sistema computacional. A concentração de esforços no aluno é uma das características fundamentais num STI, e o Modelo Aluno é responsável por garantir o ensino personalizado e devidamente adaptado às necessidades individuais desse aprendiz (SANTOS et al., 2018).

Há também o Open Learning Model (OLM), que é um modelo de aluno aberto, que visa: aumentar a precisão do modelo do aluno, incentivar maior confiança no modelo do aluno, promover a reflexão do aluno, pois segundo (BULL; KAY, 2009), a representação dos modelos do aluno geralmente são ocultadas do aluno, pois o principal objetivo de um modelo do aluno é fornecer informações para permitir que um ambiente de aprendizado se adapte às necessidades de aprendizado do usuário. Tais modelos abertos do aluno permitem que o aluno (e / ou outros) visualize informações sobre si mesmo. O modelo proposto na presente pesquisa não chega a ser um modelo aberto, mas permite que o aluno possa influenciar o seu próprio modelo.

Com base nas interações com o sistema, o modelo do aluno pode calcular os assuntos já dominados pelo aluno. Exemplo: Se um aluno concluiu todas as atividades relacionadas a um determinado tópico, o sistema tem uma boa pista sobre seu nível de domínio no tópico relacionando.

E dessa forma o aluno pode aferir seu conhecimento, pois a interação do aluno com o sistema também pode estabelecer o grau de domínio de um assunto específico. Exemplo: depois que o aluno terminar de responder a um questionário, o sistema poderá inferir quão bem ele entende os tópicos do questionário e o que precisa ser revisado.

Como o sistema irá identificar a necessidade do aluno, visando não somente oferecer meios que auxiliem na aprendizagem de uma melhor forma, mas também, diante das recomendações oferecidas, com base na deficiência interativa e/ou pedagógica, onde nada impede que o próprio aluno analise seu status atual de conhecimento e decida o que pode ser tratado ou revisado a seguir.

3 TRABALHOS RELACIONADOS

Nesta seção apresentaremos 10 dos artigos mais significantes/recentes sobre a explicação da recomendação/inteligência artificial. No final do capítulo, comparamos esses trabalhos com a proposta desta dissertação.

3.1 PERSONALIZED EXPLANATIONS FOR HYBRID RECOMMENDER SYSTEMS

No artigo, (KOUKI et al., 2019), trata a respeito da importância de transparência em sistemas de recomendação mediante a sua complexidade, visando evoluir na captura da riqueza da informação usada para fazer a recomendação. No entanto, as diferenças individuais também exigem atender às preferências dos usuários pelas explicações que eles consideram mais persuasivas. Afirma-se que as explicações híbridas, que combinam múltiplos estilos como baseado em usuário e baseado em itens são mais eficazes do que homólogos não híbridos. Nesta pesquisa, foi criado um sistema de recomendação híbrido que pôde incorporar uma variedade de abordagens de recomendação (por exemplo, baseado em conteúdo e filtragem colaborativa). Usando este sistema híbrido, foram geradas explicações híbridas que consistem em muitos estilos, onde cada estilo está associado a um algoritmo de recomendação. Para entender melhor como melhorar a persuasão da explicação usando múltiplos estilos de explicação, foi realizado um grande estudo personalizado do usuário em um sistema real do domínio musical. Foram manipulados experimentalmente os estilos de explicação produzidos (por exemplo, baseado em conteúdo social ou baseado em conteúdo), o número de estilos de explicação apresentados (por exemplo, três ou quatro explicações) e o formato visual das explicações (por exemplo, textual ou visual). Uma pesquisa recente (BERKOVSKY et al., 2017) indicou que pode haver uma relação entre a personalidade de uma pessoa e o tipo de explicação que é mais persuasiva, então também foi conduzida uma análise exploratória para explicações híbridas.

O SR híbrido foi utilizado para produzir recomendações em tempo real, incorporando uma variedade de fontes de informação. Além disso, foi utilizado um sistema de coleta de dados em tempo real para adquirir o histórico de um usuário, conexões sociais, tags e estatísticas de popularidade da mídia social last.fm local. Esses sinais foram usados para criar um modelo híbrido que incorpora semelhanças entre usuários e itens, usando informações advindas de FC, conteúdo, social e popularidade. Em seguida, foi implementado um sistema de tradução que gera explicações personalizadas a partir da saída do sistema híbrido.

O estudo foi dividido em duas fases. Na primeira fase, foi solicitado ao participante que

respondesse um questionário para estudo prévio (o mesmo para todos os participantes). Ao mesmo tempo, os dados de música desse participante foram rastreados e o modelo HyPER¹ foi executado para gerar recomendações com explicações. Na segunda fase do estudo, as recomendações personalizadas produzidas com explicações foram exibidas para o participante e feitas um conjunto de perguntas.

As principais contribuições do presente trabalho foram: (1) um sistema híbrido de recomendação que pode fornecer recomendações em tempo real com até sete estilos diferentes de explicações em vários formatos (como textual e visual), (2) insights sobre os estilos mais persuasivos, o número ideal de estilos de explicação, e os formatos de apresentação mais persuasivos como resultado de um estudo de usuário; e (3) insights sobre o efeito de diferentes traços de personalidade na persuasão das explicações (como resultado do mesmo estudo).

Dentro do que foi investigado concluiu-se que:

- As pessoas preferem explicações centradas em itens, mas não centradas no usuário ou sociocêntricas.
- As pessoas preferem ver no máximo três ou quatro estilos de explicação.
- Explicações textuais são ideais, com relação as visuais.

3.2 USING EXPLANATIONS FOR RECOMMENDER SYSTEMS IN LEARNING DESIGN SETTINGS TO ENHANCE TEACHERS' ACCEPTANCE AND PERCEIVED EXPERIENCE

No artigo, os autores (KARGA; SATRATZEMI, 2019), investigaram os resultados de fornecer explicações para as recomendações do Design de Aprendizagem para os professores. Para esse fim, foi projetado e implementado um mecanismo explicativo incorporado ao Sistema de Recomendação (SR), que propõe Desenhos de Aprendizagem preexistentes para os professores. No geral, este estudo fornece evidências de que explicações devem ser incorporadas aos Sistemas de Recomendadores que propõem Desenhos de Aprendizagem, como uma maneira de melhorar a experiência percebida pelo professor e promover sua adoção mais ampla pelos professores. Quanto mais os professores aceitam e adotam Sistemas de Recomendações que propõem Desenhos de Aprendizagem, mais a comunidade educacional obtém os benefícios de reutilizar os Desenhos de Aprendizagem

¹ HyPER: Sistema de Recomendação híbrido que usa a estrutura de lógica probabilística.

Para cada Desenho de Aprendizagem na lista de recomendações, o sistema de recomendação fornece explicações aos professores. O estilo de explicação adotado foi baseado em dados de conteúdo em combinação com dados de classificação, levando em consideração que várias pesquisas sugeriram que essa combinação leva a explicações mais valiosas em termos de eficácia e satisfação do usuário.

Os dados de classificação foram coletados diretamente, solicitando aos professores que classificassem os Desenhos de Aprendizagem propostos aplicando um sistema de 5 estrelas. Um pedaço de texto foi incluído como explicações sobre a classificação da comunidade para o Projeto de Aprendizagem proposto. Os dados do conteúdo foram derivados dos Desenhos de Aprendizagem na forma dos seguintes recursos, derivados de outros projetos:

- O domínio do assunto ao qual o Desenhos de aprendizagem está relacionado.
- O nível cognitivo dos alunos aos quais o Design de Aprendizagem é direcionado (por exemplo, Introdutório, Intermediário, Avançado, Não avaliado).
- O modelo de avaliação que pode ser Diagnóstico (geralmente é conduzido antes do ensino para identificar os pontos fortes e fracos dos alunos, a fim de adaptar o processo de ensino), Formativo (é geralmente conduzido durante o processo de aprendizado, a fim de adaptar as atividades futuras de acordo com resultados) ou sumativo (ocorre após a conclusão da aprendizagem para avaliar o resultado da aprendizagem).
- O modelo de entrega usado para entregar o Desenhos de aprendizagem (por exemplo, síncrono e assíncrono).
- O tempo aproximado necessário para o Projeto de Aprendizagem ser executado pelos alunos.

O instrumento de pesquisa foi um questionário on-line composto por duas partes: (a) mensurando as variáveis dependentes e b) mensurando as variáveis demográficas dos professores. As questões que medem uma variável dependente estavam altamente relacionadas e poderiam ser unificadas em uma escala, onde elas eram estáveis, uma vez que as cargas fatoriais resultantes de uma análise fatorial dos componentes principais eram altas. As escalas não excederam seis itens, em conformidade com as recomendações e as questões foram da escala *Likert*, variando de 1, o que significa discordo totalmente a 5, o que significa concordo totalmente.

A primeira parte do questionário avalia a aceitação do sistema de recomendação, para esse fim foram utilizadas 6 perguntas que foram adotadas do modelo ResQue². As perguntas foram as seguintes:

1. Os Desenhos de Aprendizagem recomendados para mim correspondiam aos meus interesses.
2. Gostei da interface do SR.
3. Eu me familiarizei com o SR muito rapidamente.
4. No geral, estou satisfeito com o SR.
5. Eu usaria o SR novamente.
6. Eu recomendaria o SR a um amigo.

Na segunda parte avalia a variável eficácia da decisão. Para atingir esse objetivo, foram utilizadas duas perguntas, sendo elas:

1. As informações fornecidas para os itens recomendados foram suficientes para eu tomar uma decisão.
2. Encontrar um Desenho de Aprendizado em que confiar para criar o meu próprio, consumia menos tempo com a ajuda do SR do que sem ele.

Na terceira parte que visa avaliar a confiança do usuário para tomada de decisão, também foram utilizadas duas perguntas, conforme a seguir:

1. O SR me deixou confiante com o Desenho de Aprendizagem criado.
2. O SR me ajudou a encontrar um Design de Aprendizado digno de confiança, para criar meu próprio.

A quarta parte consiste em avaliar a variável de entendimento do sistema percebido.

1. Entendi por que os Desenhos de Aprendizagem me foram recomendados.
2. O SR me ajudou a entender por que os itens me foram recomendados.

² ReQue: É uma estrutura de avaliação composta por quatro camadas, que verifica as atitudes dos usuários e a aceitação de um SR.

E finalmente, a última parte mede o senso de controle do usuário, e para isso utilizou-se as perguntas:

1. Eu tinha o controle de dizer ao recomendador o que eu queria.
2. Eu me senti no controle para alterar o resultado dos itens recomendados devido às minhas alterações de preferência.

O estudo foi realizado comparando duas condições: (a) explicações fornecidas: cada Desenho de Aprendizagem recomendado foi acompanhado por explicações da justificativa por trás da recomendação (grupo experimental); e (b) explicações não fornecidas: nenhuma facilidade de explicação foi oferecida (grupo controle) A expectativa é que os professores do grupo experimental tenham pontuações significativamente mais altas, por um lado, na aceitação do SR proposto e, por outro lado, nas variáveis de experiência do usuário (ou seja, eficácia da decisão, confiança na decisão, percepção do sistema e senso de controle do usuário) em comparação com o grupo controle.

O artigo conclui argumentando que fornecer explicações no contexto de um SR que propõe Desenhos de Aprendizagem pode aumentar a aceitação dos professores e melhorar sua experiência das seguintes maneiras. Ele pode: ajudar os professores no processo de tomada de decisão sobre qual Desenho de Aprendizagem selecionar dentro de um tempo limitado, tornando o SR mais compreensível para os professores e fazendo com que os professores sintam mais controle na interação com o SR.

3.3 EXPLORING THE NEED FOR EXPLAINABLE ARTIFICIAL INTELLIGENCE (XAI) IN INTELLIGENT TUTORING SYSTEMS (ITS)

(PUTNAM; CONATI, 2019) traz em seu artigo uma abordagem, visando entender quando é necessário que um Sistema Tutor Inteligente (STI) explique suas técnicas subjacentes de modelagem de usuários aos alunos, bem como, investigar se ter um STI que pode explicar seu comportamento ajuda a suprir essa necessidade (interpretabilidade), e como as explicações afetam a eficácia do STI, com foco específico em analisar como as diferenças individuais dos alunos influenciam no tocante ao efeito das explicações. Nesse sentido, foi realizado um estudo piloto inicial para explorar as atitudes dos alunos no sentido de incorporar explicações a um STI, pedindo sugestões aos participantes sobre o tipo de explicações, se houver, que gostariam de ver. Os resultados indicaram um sentimento geral positivo em relação à explicação desejada e sugeriram algumas orientações de projeto para incorporar a explicação em um STI existente.

A fim de reunir sugestões sobre o tipo de explicações que os alunos gostariam de ter na ACSP (Adaptive Constraint Satisfaction Problem - ITS)³, foi incorporado um recurso de “dica de explicação” nas intervenções da ACSP. Uma vez que o aluno tenha recebido uma dica de nível 1 ou nível 2, o aluno pode optar por ter a dica explicada (Figura 1A). Uma vez que o botão “Explain Hint” é selecionado, as ferramentas para inserir a explicação desejada ficam visíveis (Figura 1B). Aqui, os alunos selecionam as seguintes opções: porque o sistema deu essa dica, como o sistema escolheu essa dica, alguma outra explicação sobre essa dica (com um campo para entrada do usuário) ou nenhuma explicação para essa dica. Para estabelecer uma explicação foram utilizadas as cláusulas do tipo “por que” e “como”. Uma explicação por que irá fornecer uma cadeia de razões causais (isto é, fatos) sobre o sistema. Além disso, uma explicação como fornecerá informações sobre o processo de sistemas que permite ao sistema estabelecer esses fatos / causas. O trabalho definiu uma resposta de um aluno (ou seja, “Enviar resposta” na Figura 1B) para ser uma apresentação de um aluno.

Figura 1 – Explain Hint Feature

Fonte: Exploring the Need for Explainable Artificial Intelligence (XAI) in Intelligent Tutoring Systems (ITS).

³ Problema de satisfação de restrições adaptativas - É um ambiente de aprendizado exploratório que fornece ferramentas para os alunos explorarem um algoritmo que resolve problemas de satisfação de restrições em uma simulação interativa. O ACSP se adapta em tempo real para fornecer instruções personalizadas aos alunos usando intervenções na forma de mensagens (dicas de texto).

Nesse sentido foi observado que os participantes precisam de explicações e os consideram valiosas quando são curiosos e quando discordam da tomada de decisões do sistema. Contudo, as descobertas do trabalho, sugerem que incorporar explicações no ACSP é um recurso que a maioria dos estudantes deseja ver. Foi percebido que os participantes expressam querer alguma forma de explicação para 54% das dicas que foram entregues. Dessas 54% das respostas, os participantes relatam que gostariam de saber o porquê mais frequentemente durante sua interação com o sistema. Além disso, descobriu-se que explicações podem ser mais necessárias no início da interação de um aluno com o sistema e que os alunos relatam que não desejam mais explicações à medida que interagem mais com o sistema. Também observou-se que a curiosidade e discordar da tomada de decisão dos sistemas são razões comuns para a necessidade de explicações entre os alunos.

3.4 TRANSPARENCY IN FAIR MACHINE LEARNING: THE CASE OF EXPLAINABLE RECOMMENDER SYSTEMS

Em sua pesquisa (ABDOLLAHI; NASRAOUI, 2018) afirma que, os modelos de Machine Learning (ML) estão sendo cada vez mais usados em muitos setores, como: saúde, educação, justiça e investigação criminal. Portanto, é de grande importância construir um modelo que transmita o raciocínio por trás de suas previsões. Com isso, o objetivo central é utilizar a explicação como um fator que agrega valor à recomendação oferecida. Sendo assim eles decidiram utilizar sistemas de recomendação, pois eles são um modelo proeminente de ML onde há interação direta com os seres humanos. E como os modelos ML fazem previsões que afetam a tomada de decisão, onde essas decisões podem ter um impacto sobre os seres humanos, seja individualmente (para uma única pessoa) ou coletivamente (para um grupo de pessoas). Tal impacto pode ser injusto se for baseado em uma inferência que seja tendenciosa contra um certo grupo de pessoas. E para que não haja injustiça e que as previsões geradas sejam confiáveis, a explicabilidade pode desempenhar um papel importante (confiança) em ML evitando/minimizando assim a existência de modelos pretensiosos e injustos (com previsões enviesadas). Métricas de avaliação convencionais, como exatidão ou precisão, não levam em conta a equidade do modelo. Assim, para satisfazer a justiça, são necessários modelos explicáveis. Embora a construção de modelos éticos e justos seja o objetivo final, a transparência é o critério mínimo com o qual os especialistas da ML podem contribuir diretamente, e esse pode ser o primeiro passo nessa direção. Portanto, projetar sistemas inteligentes explicáveis que facilitam a transmissão do raciocínio por trás dos resultados é de grande importância na concepção de modelos justos.

O autor ainda define que, as técnicas de ML voltadas para explicação podem geralmente ser categorizadas em dois grupos principais:

1. Modelos que explicam suas previsões de maneira interpretável pelo usuário. Esses tipos de métodos geralmente apenas justificam sua saída sem fornecer uma compreensão aprofundada do algoritmo ML. Essa forma de explicação geralmente é útil quando o usuário do sistema não é especialista, como no caso de sistemas de recomendação. O módulo de geração de explicações pode estar localizado em um módulo separado relativo ao preditor.
2. Modelos que incorporam modelos interpretáveis na construção dos sistemas automatizados. Modelos white-box, como árvores de decisão onde o modelo ML é intuitivo para o usuário, podem ser categorizados neste grupo, embora, nestes modelos, o modelo seja normalmente mantido simples e em muitos casos eles podem não ser tão precisos quanto poderosas técnicas de caixa preta.

O autor traz em sua abordagem algumas afirmações quanto ao uso de explicações:

“Independentemente da precisão/recomendação, os usuários são mais propensos a confiar em um modelo se puderem compreender por que ele fez as previsões que ele fez, o que traz de forma subtendida a importância da explicação, no tocante a tornar o processo transparente.”

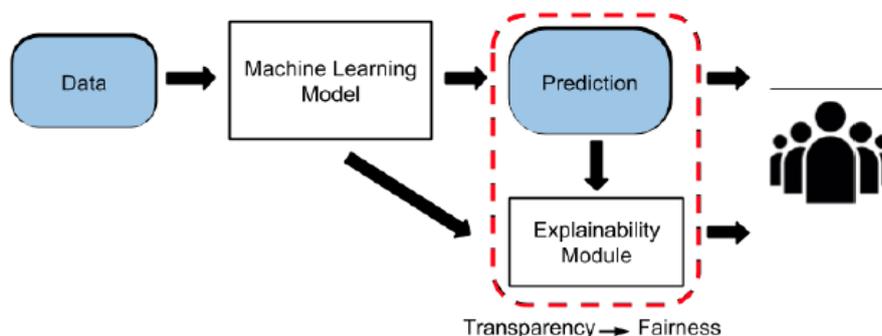
“As explicações aumentam a confiança do usuário em um sistema de recomendação, além de fornecer outros benefícios, como a capacidade de verificação, o que significa a capacidade de verificar a validade das recomendações.”

“As recomendações explicativas podem melhorar a estimativa do usuário da qualidade do item e ajudar os usuários a tomar decisões mais precisas (ou seja, satisfação do usuário).”

“A qualidade da explicação pode ser medida usando duas abordagens diferentes: a abordagem de promoção ou abordagem de satisfação. A abordagem de promoção favorece a explicação que convenceria o usuário a adotar um item, enquanto a satisfação. Essa abordagem favorece uma explicação que permitiria ao usuário avaliar a qualidade de (ou o quanto eles gostam) um item melhor.”

Nas figuras abaixo, estão ilustradas os dois tipos de modelagem utilizados no artigo para recomendar itens, utilizando a predição e a explicação como fator de transparência para o usuário.

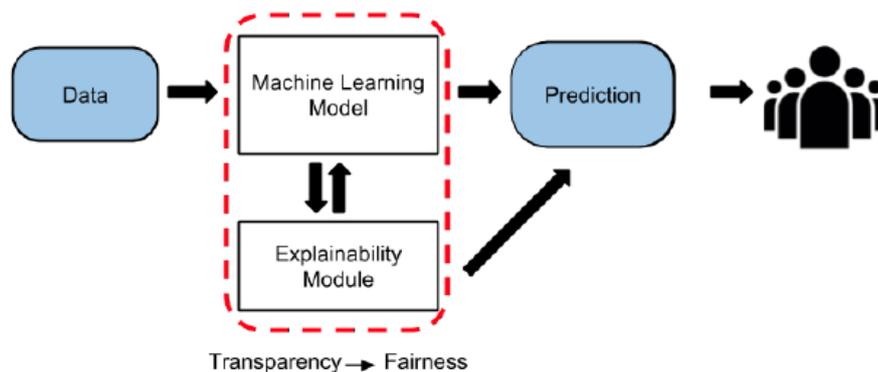
Figura 2 – Módulo de Explicações junto da Predição.



Fonte: Transparency in Fair Machine Learning: the Case of Explainable Recommender Systems

Nesta forma de modelagem (modelo de ML confiável), a explicabilidade ocorre na etapa de previsão, que resulta em mais transparência e aumenta a confiança ao apresentar resultados justificados ao usuário.

Figura 3 – Módulo de Explicações antes da Predição.



Fonte: Transparency in Fair Machine Learning: the Case of Explainable Recommender Systems

Nesta forma de modelagem (modelo de ML confiável), a explicabilidade ocorre na fase de modelagem, o que resulta em projetar modelos ML transparentes e, conseqüentemente, ter modelos mais transparentes e confiáveis.

Conclui-se que, os modelos de aprendizado de máquina dependem cada vez mais dos dados gerados em um ritmo acelerado. Em particular, mais e mais desses dados estão relacionados aos seres humanos ou gerados pela atividade humana, e isso, por sua vez, torna os dados suscetíveis a várias formas de viés humano. A tendência que pode se originar dos dados ou do design do próprio algoritmo pode resultar na construção de modelos injustos de aprendizado de

máquina. Portanto, é importante estudar e reconhecer a fonte do viés antes de projetar modelos de ML. Uma maneira de determinar se um modelo é justo é incorporando a explicabilidade que resulta em transparência. A criação de modelos de sistemas de recomendação explicativos e a explicação de recomendações podem ajudar a aprimorar a capacidade de análise dos modelos aprendidos e a detectar possíveis vieses, além de oferecer, como saída adicional, o raciocínio por trás das previsões.

3.5 LEARNING FROM EXPLANATIONS IN RECOMMENDER SYSTEMS

(CLEGER et al., 2014) apresenta uma nova técnica para melhorar as recomendações com base em uma série de explicações que devem ser fornecidas quando vários itens já conhecidos são recomendados. O objetivo da proposta é aprender um modelo de regressão a partir das informações apresentadas nessas explicações e, quando apropriado, usar esse modelo para alterar a recomendação para um item de destino. Para testar essa abordagem, foi utilizado o conjunto de dados MovieLens. Várias lições puderam ser aprendidas: primeiro, é possível aprender com um conjunto de explicações, embora isso seja altamente dependente do usuário; e, em segundo lugar, podemos usar um procedimento automático para analisar o papel dos diferentes recursos apresentados em uma explicação.

Para iniciar a abordagem sobre explicação no artigo, primeiro considerou-se um exemplo simples: suponhamos que um grupo de pessoas recomende que você assista a um filme específico, por exemplo, A (ou vá a um determinado restaurante, hotel, etc.) porque a classificação média é “boa”. Para você tomar uma decisão sobre o filme, peça que justifiquem a recomendação dada. A título de explicação, pode ser natural que cada pessoa apoie sua opinião usando os filmes que já viu anteriormente. Alguém pode dizer, portanto, que o recomendou porque é semelhante ao B de que eles desfrutavam muito. No entanto, você também pode considerar a opinião deles sobre itens diferentes (e se eles gostaram ou não) como relevantes para sua tomada de decisão. Isso ocorre porque se você estiver interessado em detectar uma recomendação errada, seria útil analisar opiniões conflitantes.

A hipótese do artigo é que existem duas razões principais pelas quais esse tipo de opinião é valioso para os usuários: a primeira é que a opinião vem de usuários com a mesma opinião (“amigos”); e a segunda é que as explicações foram contextualizadas usando o ativo plano de fundo do próprio usuário (itens já conhecidos).

Para experimentação, como a abordagem não requer interação do usuário, foi utilizada uma avaliação empírica baseada no conjunto de dados clássico MovieLens, que foi coletado pelo

Projeto de Pesquisa GroupLens da Universidade de Minnesota contendo 100.000 classificações anônimas (em uma escala de 1 a 5) de aproximadamente 1682 filmes classificados por 943 usuários do MovieLens que ingressaram no MovieLens durante o período de sete meses entre 19 de setembro de 1997 e 22 de abril de 1998. Para validar a proposta com modelos diferentes, foram utilizadas duas abordagens de filtragem colaborativa na experimentação. Descrita de acordo com os dois estágios principais da filtragem colaborativa (seleção e previsão de vizinhos):

PCCF: nesse modelo de filtragem colaborativa, os melhores vizinhos para recomendar o item alvo, são selecionados usando o Coeficiente de Correlação de Pearson entre os indivíduos que o avaliaram, desvalorizando as correlações baseadas em um pequeno número de itens avaliados em conjunto.

ELCF: baseia-se em capacidades preditivas em vez de classificar semelhanças, isto é, uma filtragem colaborativa anterior baseada em previsões. Esse algoritmo também segue uma abordagem baseada na vizinhança, selecionando como vizinhos os usuários que melhor prevêm as classificações dos usuários. A ideia é que, se um usuário é bom em prever as classificações anteriores do usuário ativo, ele também é bom em prever classificações não observadas. Mais especificamente, o Usuário X será incluído na vizinhança do Usuário A ativo se a perda esperada sobre as classificações anteriores dos usuários ativos, for alta o suficiente.

Utilizou-se como métricas para validação de recomendações, o MAE⁴ e RMSE⁵, que diferem basicamente na perda associada a cada erro. O erro de previsão foi estimado por meio de um algoritmo de regressão e, mais especificamente, o algoritmo M50. Com relação aos parâmetros do M50, foi utilizada uma estratégia sem poda que exige um número mínimo de instâncias para dividir um nó. Ao analisar a árvore do modelo resultante, foram consideradas duas restrições para acionar uma regra: 1. O número de casos na folha (suporte de regras) deve ser $P \geq 10$ e 2. A porcentagem de ganho de erro deve ser menor que um limite.

Para validar o modelo proposto, sempre que o SR calcular uma previsão para o usuário ativo, é necessário aprender uma árvore de decisão com suas experiências anteriores. Como a maioria das metodologias de avaliação de aprendizado de máquina, e como o usuário geralmente não classifica um grande número de itens, aplicou-se uma estratégia de deixar de fora.

Contudo, nesse artigo viu-se que as explicações podem ser consideradas como uma fonte valiosa de conhecimento que pode ser explorada por um sistema de recomendação. Este artigo oferece uma primeira visão sobre este tópico e, mais especificamente, essa pesquisa se concentra no uso das opiniões dos vizinhos sobre itens anteriormente avaliados pelo usuário nas

⁴ MAE - Erro Médio Absoluto

⁵ RMSE - Raiz do Erro Quadrático Médio

explicações.

A experiência mostra vantagens em termos de maior precisão no uso das explicações serem altamente dependentes do usuário: o que é bom para um usuário não é necessariamente bom para outro. Foram identificados uma série de recursos que podem ser usado para fins de previsão para melhorar as recomendações para cerca de 30% dos usuários, considerando experiências anteriores do usuário.

3.6 HOW SHOULD I EXPLAIN? A COMPARISON OF DIFFERENT EXPLANATION TYPES FOR RECOMMENDER SYSTEMS

(GEDIKLI et al., 2014) faz uma abordagem em seu artigo, através de um levantamento e observações trazidas por alguns autores, que tratam questões de como as explicações poderiam ser comunicadas ao usuário de maneira mais efetiva. No geral, o tipo e a profundidade das explicações que um sistema de recomendação pode fornecer dependem dos tipos de conhecimento e/ou algoritmos usados para gerar as listas de recomendação. Na recomendação baseada no conhecimento ou abordagens consultivas, as explicações podem ser baseadas na base de regras que codificam o domínio do conhecimento de um especialista e as preferências do usuário explicitamente adquiridas (FELFERNIG et al., 2006). Para o tipo mais proeminente de sistemas de recomendação, os recomendadores de filtragem colaborativa, (HERLOCKER et al., 2000) e (BILGIC; MOONEY, 2005) propuseram várias formas de explicar as recomendações ao usuário. (HERLOCKER et al., 2000) Também demonstraram que as explicações podem ajudar a melhorar a aceitação geral de um sistema de recomendação.

A principal questão que se buscou responder neste artigo foi: quais diferentes tipos de efeitos as recomendações explicadas têm sobre os usuários? O objetivo foi analisar a influência da eficiência, eficácia e transparência percebida na satisfação do usuário. Neste trabalho foi feita uma avaliação dos diferentes tipos de explicação, de forma abrangente e considerar os efeitos desejados e as dimensões de qualidade eficiência, eficácia, persuasão, transparência percebida e satisfação.

Foi proposto um conjunto de diretrizes para construir interfaces de explicação para sistemas de recomendação que suportam o usuário no processo de tomada de decisão. Uma explicação pode ser considerada como uma informação que é apresentada em um processo de comunicação para servir objetivos diferentes, como expor o raciocínio por trás de uma recomendação (HERLOCKER et al., 2000) ou permitir padrões de comunicação mais avançados em casos de sistemas comerciais (JANNACH et al., 2010), o que acredita-se não ser diferente no

contexto educacional.

A eficácia das explicações pode ser medida de diferentes maneiras. (VIG et al., 2009), por exemplo, realizaram um estudo no qual foram apresentados diferentes tipos de explicações para os usuários e, em seguida, perguntaram a eles como os tipos de explicações individuais os ajudavam a decidir se gostavam ou não de um item. (BILGIC; MOONEY, 2005), em contraste, determinam a eficácia medindo a proximidade entre a estimativa do usuário da qualidade, ou adequação de um item e a qualidade, ou utilidade real dos itens recomendados.

Semelhante a (TINTAREV; MASTHOFF, 2012), o trabalho realizado por (GEDIKLI et al., 2014) adotou essa segunda abordagem onde utilizou o seguinte procedimento. Primeiro, os usuários são solicitados a estimar a qualidade de um item recomendado, considerando apenas a explicação gerada pelo recomendador. Depois disso, os usuários usam ou “consomem” o item (por exemplo, assistir a um filme ou analisar o item com base em informações mais detalhadas) e classificam o item novamente com base em suas experiências reais ou no conhecimento adicional. A proximidade das duas classificações pode então ser usada como um proxy para medir a eficácia.

3.7 EVALUATING THE EFFECTIVENESS OF EXPLANATIONS FOR RECOMMENDER SYSTEMS METHODOLOGICAL ISSUES AND EMPIRICAL STUDIES ON THE IMPACT OF PERSONALIZATION

O artigo elaborado por (TINTAREV; MASTHOFF, 2012), investiga o papel das explicações, através da análise do impacto da personalização de explicações baseadas em recursos simples sobre eficácia e satisfação, onde a eficácia aproximada e real é investigada. Às vezes, é assumido erroneamente que as explicações devem sempre justificar⁶ porque os itens foram recomendados. Sendo assim, o artigo traz consigo uma série de métricas utilizadas por alguns autores para medir a eficácia, como, por exemplo:

- Eficácia percebida antes do consumo: quando permitem que os participantes julguem a eficácia das explicações classificando quanto concordaram com afirmações como “Esta explicação me ajuda a determinar o quão bem gostarei deste filme”. Outra métrica semelhante estudou a eficácia percebida das explicações para várias interfaces e algoritmos de recomendação. Onde foi perguntado aos participantes quão úteis (e compreensíveis) eles consideravam as explicações e foi pedido para classificá-las em ordem de utilidade.

⁶ Uma definição popular de explicação é "justificar".

- Eficácia percebida após o consumo: seria para os participantes avaliarem o quanto concordam com afirmações como “Esta explicação me ajudou a determinar o quanto eu gostaria desse item”.
- Taxa de sucesso em encontrar o melhor item: usaram uma métrica de qualidade de decisão do marketing que mede a fração de participantes que mudaram sua escolha para outra opção depois de visualizar todos os itens. Essa métrica considera a eficácia com que o sistema oferece suporte aos usuários para encontrar o melhor item possível (em vez de “itens suficientemente bons”, como acima). Os participantes interagiram com o sistema até encontrar o item que comprariam. Em seguida, eles visualizaram todos os itens e puderam alterar sua escolha. A efetividade foi medida pela fração de participantes que alteraram sua escolha (portanto, uma fração menor significa melhor eficácia).
- Aceitação de itens conhecidos pelo usuário: contaram o número de recomendações aceitas. Em seu domínio, isso significava o número de pessoas recomendadas que foram adicionadas a uma rede social. No entanto, se os itens recomendados (pessoas em seu domínio) já são conhecidos pelo usuário (como foi o caso em seu estudo), a fração das recomendações aceitas pode realmente medir a eficácia.
- Uso das explicações: investigaram explicações compostas baseadas em críticas que tornam os usuários mais conscientes dos itens disponíveis além do item sugerido atualmente (por exemplo, outras câmeras com mais memória, mas mais pesada).
- Semelhança entre gostar de itens antes e depois do consumo: usaram como métrica a ausência de diferença entre o gosto do item recomendado antes e depois do consumo. A métrica compara duas classificações de itens: uma após receber uma explicação e uma segunda após experimentar o item. Se a opinião sobre o item não mudou muito, a explicação foi considerada eficaz.

As métricas abordadas diferem em três dimensões:

Tempo: medição da eficácia antes ou depois do consumo.

Itens Considerados: medição da eficácia usando apenas o item recomendado superior ou todos os itens.

Tipo de medição: medindo a eficácia objetiva ou percebida. A eficácia percebida mede a percepção do usuário sobre a eficácia do sistema (por exemplo, através do auto-relato), enquanto a eficácia objetiva mede a eficácia diretamente (por exemplo, comparando a diferença entre as

avaliações antes e depois dos itens).

A métrica utilizada foi a de (BILGIC; MOONEY, 2005), que mede a eficácia objetiva após o consumo, e considera todos os itens. Pois a eficácia antes do consumo pode se sobrepor à capacidade de persuasão. Mediu-se a eficácia objetiva, pois a eficácia percebida pode se sobrepor à satisfação.

Pelos motivos expostos, a eficácia foi medida usando a métrica sugerida por (BILGIC; MOONEY, 2005):

1. (Avaliação 1) O usuário classifica o item com base na explicação.
2. O usuário tenta o item.
3. (Avaliação 2) O usuário reavalia o item.

Fase de Experimentos: Os participantes foram alocados aleatoriamente em uma das três condições no projeto. As condições diferiam no tipo de explicações fornecidas, em particular se as explicações eram personalizadas e baseadas em recursos.

Em vez de avaliar um sistema completo de recomendação, concentramos a avaliação na combinação das camadas, desejou-se saber se a decisão de personalizar as explicações (DA) e a maneira como isso foi feito (AA) levaria a um aumento de eficácia e satisfação. Era preciso garantir entrada precisa para as camadas em avaliação, para um modelo de usuário preciso. Portanto, os participantes forneceram o modelo do usuário diretamente, usando os recursos disponíveis para um recomendador comercial. Foram utilizadas as seguintes variáveis, consideradas como independentes:

3 Tipos de explicações que foram utilizadas:

Linha de base: A explicação não foi personalizada nem descreveu as características do item. Por exemplo. “Este filme é um dos 100 melhores filmes do Internet Movie Database”.

Não personalizado, baseado em recursos: A explicação descreveu os recursos do item, mas os recursos não foram adaptados para o usuário. Por exemplo. “Este filme pertence ao gênero (s): Drama. Kasi Lemmons dirigiu este filme.”

Personalizado, baseado em recursos: A explicação descreveu os recursos do item e os adaptou aos interesses do usuário. Por exemplo. “Embora este filme não pertença a nenhum dos seus gêneros preferidos, ele pertence ao (s) gênero (s): documentário (s). Este filme é estrelado por Ben Kingsley, Ralph Fiennes e Liam Neeson, seu (s) ator (es) favorito (s).”.

E abaixo, as variáveis dependentes:

A **eficácia** foi medida usando a métrica descrita anteriormente. Os participantes classificaram os itens duas vezes (por exemplo, “Quanto você acha que gostaria desta câmera?”), usando uma escala Likert de 7 pontos (de “nada” a “muito”), antes e depois de experimentá-los. A métrica considera como a avaliação do usuário dos itens é alterada. **Satisfação**. A satisfação foi medida através da classificação das explicações (“O quão bom você acha que esta explicação é?”) em uma escala Likert de 7 pontos (de muito ruim a muito boa).

Desse modo, conclui-se que, para que uma explicação seja eficaz, ela deve no mínimo obter algum tipo de classificação (de preferência uma que reflita as preferências do usuário). Uma explicação que não pode ajudar a obter qualquer classificação, por definição, leva a uma eficácia insuficiente e, além disso, provavelmente resulta em satisfação do usuário tão baixa que o sistema provavelmente perderá o usuário. Em segundo lugar, a validade da métrica usada depende do conjunto de dados subjacente.

3.8 A TAXONOMY FOR GENERATING EXPLANATIONS IN RECOMMENDER SYSTEMS

Em sistemas de recomendação, as explicações servem como um tipo adicional de informações que podem ajudar os usuários a entender melhor a saída do sistema e promover objetivos como confiança, seja na tomada de decisões ou na utilidade. (FRIEDRICH; ZANKER, 2011) definem explicações em sistemas de recomendação por duas propriedades. Primeiro, elas são informações sobre recomendações, em que uma recomendação é geralmente uma lista classificada de itens. Segundo, as explicações apoiam os objetivos definidos pelo projetista do sistema de recomendação. O autor traz em seu estudo, abordagens de autores como (TINTAREV; MASTHOFF, 2011), que por sua vez, fornecem uma enumeração dos objetivos potenciais que podem ser pretendidos pelas explicações de um sistema de recomendação. Em sistemas de recomendação, as explicações podem ser explicitamente solicitadas pelos usuários ou exibidas automaticamente pelo sistema. Além disso, características estruturais como comprimento, estilo de escrita (por exemplo, o sistema poderia usar frases lisonjeiras ou mais factuais), ou a confiança que é transmitida em explicações pode ser usada como dimensões adicionais. Em contraste com a classificação por princípios de design, as explicações podem ser categorizadas por seus efeitos ou impacto em seus usuários (TINTAREV; MASTHOFF, 2011). O impacto das explicações sobre os usuários é medido em termos da realização de diferentes objetivos que são, portanto, construções endógenas (em contraste com os princípios de design exógeno acima mencionados).

No entanto, a influência de diferentes estratégias de explicação em relação ao alcance de objetivos como a satisfação ou a confiança do usuário ainda não foi sistematicamente pesquisada. Foram abordadas três dimensões da taxonomia:

Modelo de raciocínio: O modelo de raciocínio descreve como as explicações são geradas e é o critério distintivo mais fundamental. Convencionalmente, a noção de “explicando recomendações” indica que o sistema torna o processo de raciocínio transparente para o usuário. Nos casos em que o sistema especialista requer informações do usuário, são fornecidas explicações sobre o motivo pelo qual essas informações são necessárias. Por outro lado, quando um sistema especialista gera uma solução, um usuário pode solicitar uma justificativa da solução proposta. **Paradigma de recomendação:** filtragem colaborativa e baseada em conteúdo, bem como recomendações baseadas no conhecimento constituem os três paradigmas básicos de recomendação. **Categorias de informações exploradas:** compreende as categorias de informação que podem ser exploradas para gerar explicações.

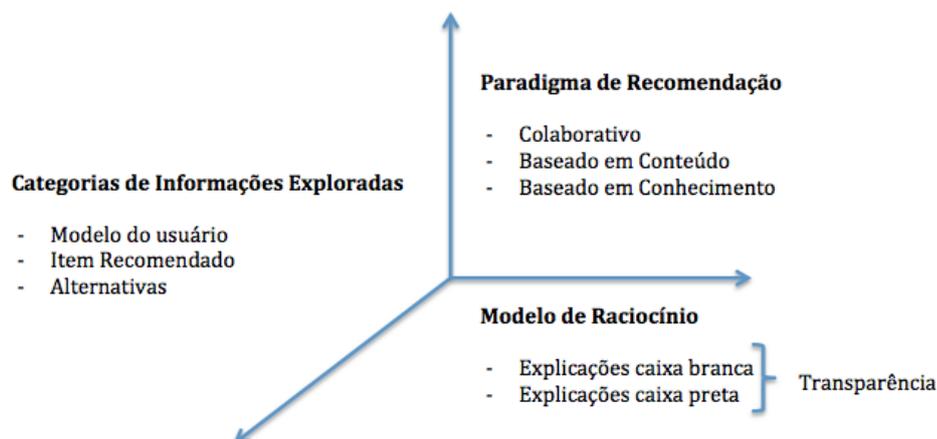
- Modelo de usuário: (O sistema pode apresentar argumentos com base nas classificações, preferências ou informações demográficas conhecidas do usuário.)
- Item recomendado: (A explicação depende do item específico recomendado? Por exemplo, a explicação faz afirmações sobre as características específicas do item recomendado?)
- Alternativas: (As explicações argumentam a favor do contrário das alternativas ao item recomendado? Sim, as explicações podem ser adaptadas a todos os três aspectos, nenhum deles, ou qualquer outra combinação).

Para resumir, as abordagens de explicação caixa-preta⁷ computam as justificativas que argumentam por que uma recomendação específica é plausível ou deveria ser de interesse, embora o modelo de raciocínio não tenha considerado essas proposições ao realmente computar a recomendação. Em contraste, as explicações de caixa branca⁸ revelam (pelo menos parcialmente) o modelo de raciocínio e seu conteúdo para o usuário na tradição de explicações do sistema especialista. A figura abaixo mostra como estão divididos os segmentos.

⁷ Que não permite que o usuário compreenda objetivo e interpretação do que foi proposto.

⁸ Que fornece ao usuário a possibilidade de entender o que foi proposto.

Figura 4 – Dimensões da Taxonomia



Fonte: Dimensões de uma Taxonomia para geração de explicações em sistemas de recomendação.

Em suma, há muitas evidências de que as explicações são uma ferramenta poderosa para influenciar o comportamento do usuário. Atualmente, a maioria das implementações de componentes de explicação em sistemas de recomendação segue uma abordagem de caixa branca. Isso é razoável para otimizar o esforço de desenvolvimento. No entanto, do ponto de vista científico, pouca pesquisa se concentra em prever quais estratégias de explicação são mais adequadas para alcançar quais objetivos de explicação. Consequentemente, o trabalho contribuiu para uma melhoria substancial na qualidade das explicações, desde que os pesquisadores desenvolvam uma melhor compreensão de como diferentes características das explicações impactam os usuários, a fim de desenvolver um modelo de explicação eficaz para domínios específicos.

3.9 A SURVEY OF EXPLANATIONS IN RECOMMENDER SYSTEMS

Este artigo fornece uma revisão abrangente das explicações nos sistemas de recomendação, oferecendo uma visão sistemática geral da questão em aberto sobre o que é uma boa explicação e pesquisar as abordagens existentes. (TINTAREV; MASTHOFF, 2007) pesquisaram de forma detalhada a respeito dos sete objetivos nos quais, uma série de sistemas de recomendação acadêmica deveriam oferecer, sendo eles:

Transparência (Tra.) Explicar como o sistema funciona

Scrutability⁹ (Scr.) Permitir que os usuários digam ao sistema que está errado

Confiança (Conf) Aumentar a confiança dos usuários no sistema

Eficácia (Ef.) Ajudar os usuários a tomar boas decisões

⁹ Examinabilidade

Persuasão (Pers.) Convencer os usuários a realizar uma ação (por exemplo: experimentar algo, comprar algo, etc.).

Eficiência (Efc.) Ajudar os usuários a tomar decisões mais rapidamente

Satisfação (sáb.) Aumentar a facilidade de uso ou prazer

Diante desses aspectos que foram levantados pelas autoras, poderemos ver a descrição sobre o funcionamento de cada um, no tocante aos objetivos que vislumbram.

- Aborda a importância da **transparência**, ressalta a relevância da explicação da recomendação (o motivo de tal sugestão), onde trouxe como exemplo um caso onde Um artigo anedótico no Wall Street Journal intitulado “Se O TiVo pensa que você é homossexual, aqui está como esclarecer as coisas” descreve a frustração dos usuários com escolhas irrelevantes feitas por um gravador de vídeos que grava programas que supostamente ele acredite que seu dono goste, contudo, ele acreditava que seu dispositivo achava que ele fosse homossexual, mediante aos tipos de recomendações feitas.
- A característica **Scrutability** ressalta a importância das explicações, onde elas podem ajudar a isolar e corrigir suposições ou etapas equivocadas. As explicações devem ser parte de um ciclo, em que o usuário entende o que está acontecendo no sistema e exerce controle sobre o tipo de recomendações feitas, corrigindo as suposições do sistema quando necessário.
- O aspecto **confiança**, às vezes pode estar ligado à transparência, pois estudos anteriores indicam que a transparência e a possibilidade de interação com os sistemas de recomendação aumentam a confiança do usuário. A confiança no sistema de recomendação também pode depender da precisão do algoritmo de recomendação. Contudo, o artigo não alega que as explicações possam compensar totalmente as más recomendações. Por outro lado, um usuário pode ser mais indulgente e mais confiante nas recomendações, se entender por que uma má recomendação foi feita e pode impedir que ela ocorra novamente (através da possibilidade de interação).
- Explicações podem aumentar a avaliação do usuário do sistema ou as recomendações dadas. Isso pode qualificar como **persuasão**, já que é uma tentativa de obter benefícios para o sistema e não para o usuário. De fato, foi demonstrado que os usuários podem ser manipulados para dar uma classificação mais próxima da previsão do sistema, seja esta previsão precisa ou não.

- A **eficácia** é, por definição, altamente dependente da precisão do algoritmo de recomendação. Uma explicação eficaz ajudaria o usuário a avaliar a qualidade dos itens sugeridos de acordo com suas próprias preferências. Isso aumentaria a probabilidade de o usuário descartar opções irrelevantes e, ao mesmo tempo, ajudá-las a reconhecer opções úteis. Explicações eficazes também poderiam servir ao propósito de introduzir um novo domínio, ou a gama de itens recomendados, a um usuário novato, ajudando-os a entender a gama completa de opções.
- As explicações podem tornar mais rápido para os usuários decidirem qual item recomendado é o melhor para eles. A **eficiência** é outro princípio de usabilidade estabelecido, ou seja, a rapidez com que uma tarefa pode ser executada. Esse critério é um dos mais comumente abordados na literatura sobre sistemas de recomendação, uma vez que a tarefa de recomendar sistemas é encontrar agulhas em pilhas de feno de informação.
- Explicações podem aumentar a **satisfação** do usuário com o sistema, embora explicações fracas provavelmente diminuam o interesse do usuário ou a aceitação de um sistema.

Os objetivos acima também podem ser descritas como critérios, que podem ser usados para avaliar quão boa é uma explicação. Sendo assim, as autoras concluíram que ao escolher e comparar técnicas de explicação, é muito importante concordar com o que a explicação está tentando alcançar. Por exemplo, embora um estudo tenha medido a satisfação do usuário com as recomendações (persuasão), isso não é o mesmo que medir a satisfação com itens reais (eficácia). Conforme mostrado neste artigo, as explicações estão intrinsecamente ligadas à maneira como as recomendações são apresentadas e ao grau de interatividade oferecido.

Diante desse aspecto as autoras mencionam maneiras de oferecer recomendações com mais detalhes e ilustramos como as explicações podem ser usadas em cada caso. O primeiro ponto abordado é o Top Item que é considerado a maneira mais simples de apresentar uma recomendação ao usuário é oferecendo o melhor item. O segundo ponto é o Top N-Itens, considerando que o sistema apresente vários itens ao mesmo tempo. Nesse caso, existem vários itens que podem ser altamente interessantes para o usuário. Se o fã de futebol também estiver interessado em notícias de tecnologia, o sistema poderá apresentar várias histórias esportivas juntamente com alguns itens de tecnologia. O terceiro ponto é Semelhante ao primeiro item (s), uma vez que um usuário mostra uma preferência por um ou mais itens, o sistema de recomendação pode oferecer itens semelhantes. O sistema de recomendação pode apresentar um único item, uma lista de itens preferenciais ou mesmo os itens mais visualizados no momento. Para cada item,

ele pode apresentar um ou mais itens semelhantes e pode mostrar explicações semelhantes aos pontos 1 e 2. No quarto ponto Classificações previstas para todos os itens, o invés de forçar seleções no usuário, um sistema pode permitir que seus usuários naveguem em todas as opções disponíveis. As recomendações são apresentadas como classificações previstas em uma escala (por exemplo, de 0 a 5) para cada item. Um usuário ainda pode encontrar itens com classificações previstas baixas e neutralizar previsões classificando os itens afetados ou modificando diretamente o modelo do usuário, ou seja, alterando a visualização do sistema de suas preferências. Isso permite que o usuário informe o sistema quando estiver errado, cumprindo os critérios de verificação. No quinto ponto, visão geral estruturada, o melhor item correspondente é exibido na parte superior. Abaixo dele, estão listadas várias categorias de alternativas. Cada categoria tem um título explicando as características dos itens, onde a ordem dos títulos depende de quão bem a categoria corresponde aos requisitos do usuário. O quinto ponto sobre a apresentação das recomendações é que, o recomendador pode ter uma personalidade afirmativa, fornecendo ao usuário, recomendações de itens que ele já deve conhecer. Isso pode inspirar a confiança de um usuário na capacidade do sistema de apresentar itens relevantes ou precisos. Ou, pelo contrário, pode ter como objetivo oferecer recomendações mais recentes e surpreendentemente positivas (aleatórias) para aumentar a satisfação do usuário.

No tocante a interação considerou-se, quando o Usuário especifica seus requisitos, onde ao permitir que um usuário especifique diretamente seus requisitos, é possível contornar o tipo de suposições defeituosas que podem ser feitas por um sistema em que os interesses de um usuário se baseiam nos itens que eles decidem ver ou em como eles interagem. Outra forma de interação citada é quando o usuário pede uma alteração, que é uma forma mais direta que permitir que os usuários solicitem explicitamente alterações nos itens recomendados. Essa abordagem ajuda os usuários a encontrar o que desejam mais rapidamente. Outra forma, seria permitir que o Usuário classifique itens, onde para alterar o tipo de recomendação que eles recebem, o usuário pode corrigir as classificações previstas ou modificar uma classificação feita anteriormente. A classificação pode ser explicitamente inserida pelo usuário ou inferida a partir dos padrões de uso. E finalizando, um princípio comum de usabilidade é que é mais fácil para os seres humanos reconhecerem itens do que retirá-los da memória. Portanto, às vezes é mais fácil para um usuário dizer o que quer ou não, quando tem opções à sua frente. Como conclusão, viu-se que, as explicações estão intrinsecamente ligadas à maneira como as recomendações são apresentadas e ao grau de interatividade oferecido. Um sistema que pode explicar ao usuário em seus próprios termos porque os itens são recomendados provavelmente aumentará a confiança do usuário, bem

como a transparência e a capacidade de análise do sistema

3.10 TABELA COMPARATIVA

Criamos com o propósito de reunir as características dos modelos apresentados nos trabalhos relacionados, bem como compará-los com o modelo proposto nesta dissertação (Tabela 1). Quanto a escala foram atribuídos os seguintes valores: SIM (para os trabalhos que possuem uma forte correlação com o contexto que estamos trabalhando), PARCIALMENTE (para os trabalhos que falam ou reforçam de maneira superficial o que estamos propondo) e NÃO (para os trabalhos que abordam explicação, mas não atuam em nenhum dos contextos da nossa pesquisa). Nesta sumarização, consideramos as seguintes características:

- 1. As recomendações são no contexto educacional?**
- 2. As explicações são propostas com base no modelo do estudante?**
- 3. Cria as explicações com base nos 7 objetivos da explicação propostos por TINTA-REV e MASTHOFF?**
- 4. Permite que o estudante influencie no modelo que dá origem às recomendações?**
- 5. Analisa a explicação como fator determinante para aceitação da recomendação?**

Tabela 1 – Tabela comparativa dos trabalhos relacionados

	<i>As recomendações são no contexto educacional?</i>	<i>As explicações são propostas com base no modelo do estudante?</i>	<i>Cria as explicações com base nos 7 objetivos da explicação propostos por TINTAREV e MASTHOFF?</i>	<i>Permite que o estudante influencie no modelo que dá origem às recomendações?</i>	<i>Analisa a explicação como fator determinante para aceitação da recomendação?</i>
Modelo Proposto	SIM	SIM	SIM	SIM	SIM
Kouki et al., 2019	NÃO	NÃO	PARCIALMENTE	NÃO	SIM
Karga, S.; Satratzemi, M. 2019	PARCIALMENTE	NÃO	SIM	NÃO	SIM
Putnam; Conati, 2019	PARCIALMENTE	PARCIALMENTE	SIM	NÃO	PARCIALMENTE
Abdollahi; Nasraoui, 2018	NÃO	NÃO	PARCIALMENTE	NÃO	SIM
Cleger et al., 2014	NÃO	NÃO	SIM	NÃO	SIM
Gedikli et al., 2014	NÃO	NÃO	PARCIALMENTE	NÃO	PARCIALMENTE
Tintarev; Masthoff, 2012	NÃO	NÃO	SIM	PARCIALMENTE	PARCIALMENTE
Friedrich; Zanker, 2011	NÃO	NÃO	SIM	NÃO	SIM
Tintarev; Masthoff, 2007	NÃO	NÃO	SIM	NÃO	SIM

Mediante aos estudos que foram levantados, pode-se ver que o ponto em comum entre todos eles são ressaltar a importância da explicação em IA, afim de tornar os modelos mais confiáveis (ABDOLLAHI; NASRAOUI, 2018), o que conseqüentemente influencia os sistemas de recomendação. Mas diferentemente dos trabalhos avaliados que visam, investigar quando é necessário que os ambientes online de aprendizagem ofereçam explicações, assim como, se um ambiente online de aprendizagem que pode explicar seu comportamento ajuda no tocante à interpretabilidade, e como as explicações afetam a eficácia de um ambiente online de aprendizagem (PUTNAM; CONATI, 2019), possibilidade de aprender com as explicações (CLEGER

et al., 2014), objetivos que podem ser alcançados através da utilização de explicações (TINTAREV; MASTHOFF, 2007), taxonomia para gerar explicações (abrangendo 3 áreas, como: modelo de raciocínio, paradigmas de recomendação, categorias de informações exploradas), elaboração de várias interfaces de explicação para sistemas de recomendação que auxiliam o usuário no processo de tomada de decisão, onde (GEDIKLI et al., 2014) e (KOUKI et al., 2019) levaram em consideração aspectos textuais e visuais para otimizar o fator explicativo, já outros estudos focam na influência das características pessoais para compreensão das recomendações explicadas. Sendo assim, dentre todas as abordagens apresentadas a que mais se aproxima da proposta desse trabalho, é a pesquisa realizada por (TINTAREV; MASTHOFF, 2012), que visou realizar uma avaliação da eficácia de explicações para sistemas de recomendação, através da realização de testes (inicial e final), onde foram utilizados alguns tipos de explicações e três dimensões como: tempo, itens considerados e tipo de medição (comparando os resultados). (KARGA; SATRATZEMI, 2019) em sua abordagem utilizou a explicação para avaliar a aceitação, eficácia, confiança e tomada de decisão, em relação a recomendações de desenhos de aprendizagem, onde obteve resultado positivo, favorecendo a utilização de explicações no contexto recomendativo, atuando como ferramenta de auxílio direto para professor e não do aluno. Já no presente trabalho, o objetivo é analisar a correlação da recomendação explicada (criada mediante a necessidade/déficit do aluno, percebido pelo sistema) com a aceitação da recomendação, analisando a interação do usuário e monitorando se a recomendação foi seguida (investigando se ele seguiu a recomendação).

4 PROPOSTA

Diante disso, a proposta desse trabalho objetiva criar recomendações explicadas personalizadas e de forma automática, com base no modelo do aluno, visando avaliar a aderência dos estudantes à recomendação, ou seja, se o aluno seguiu ou não a recomendação recebida, por causa da “explicação”. Em outras palavras, o nosso objetivo é analisar se além do fato das explicações facilitarem a compreensão das recomendações, se elas influenciam a aceitação por parte dos usuários (que no caso deste trabalho serão estudantes).

Nesse aspecto, foi desenvolvido um experimento, através da realização de um curso de estatística (que será abordado na seção 5.1 - experimento), visando testar as hipóteses e apresentar indícios a respeito da influência da explicação na aderência das recomendações de recursos educacionais.

E para isso, a abordagem de modelo do aluno que será usada neste trabalho, considera o desempenho do estudante na resolução de questões (desempenho pedagógico), bem como as suas interações (desempenho de interação) dentro do ambiente de aprendizagem online. E para ambos coeficientes o cálculo se dará de forma individual (por aluno) e para cada tópico do curso. Para modelar esses construtos, utilizaremos as seguintes fórmulas:

Cd = Coeficiente de desempenho para um determinado tópico;

Qa = Questões acertadas;

Qf = Questões feitas;

Tq = Total de questões existentes no sistema (por tópico);

$$Cd = ((Qa/Qf) * (Qf/Tq)) * 100$$

Ci = Coeficiente de interação para um determinado tópico;

If = Interações feitas;

Ti = Total de interações possíveis por tópico;

$$Ci = (If/Ti) * 100$$

Ex: levando em consideração os recursos oferecidos pelo curso e os dados de interações de um aluno em determinado tópico do curso:

Recursos oferecidos
para determinado tópico do curso:

- 4 questões
- 1 Vídeo
- 1 Texto
- 1 Link externo
- 1 Apresentação da aula.

(TOTALIZANDO: 8 ITENS)

$$Cd = ((Qa/Qf)*(Qf*Tq)) * 100$$

$$Cd = (1/3)*(3/4)*100$$

$$Cd = 37,5\%$$

Recursos utilizados pelo usuário:

- 1 Vídeo.
- 1 Texto.
- 1 Link externo.
- 1 Apresentação da aula.
- 3 Questões respondidas (errou 2 e acertou 1).

(TOTALIZANDO: 7 ITENS)

$$Ci = (If/Ti)$$

$$Ci = (7/8)*100$$

$$Ci = 87,5\%$$

Com isso, o modelo do aluno, além das interações, será composto também pelo cálculo do desempenho e da interação (coeficientes) para todos os tópicos que o aluno já teve contato. O modelo do aluno, definirá o conhecimento do sistema sobre cada aluno. O modelo do aluno será monitorado através dos coeficientes (percentuais) de desempenho e interação, sendo 60% o aproveitamento mínimo aceitável. Esse valor de 60% foi estimado sem nenhuma fundamentação teórica, foi adotado simplesmente por ser um valor que corresponde mais da metade do que foi proposto.

Quanto à interação, serão observadas as interações realizadas pelos usuários com os recursos educacionais oferecidos pelo sistema, onde o sistema de forma automática identificará a quantidade de recursos utilizadas, assim como, o nível de dificuldade das questões respondidas, acertos/erros nas questões feitas e tempo de resposta nas questões que foram respondidas. E com essas informações as recomendações (explicadas ou não) serão criadas visando a necessidade do aluno.

A Tabela 2 contém os recursos que um usuário específico interagiu, a quantidade de recursos que ele utilizou, quantidade de questões feitas, os níveis das questões respondidas, a quantidade de acertos, erros e o tempo de resolução de cada questão. Com esses dados é possível descobrir os recursos que não foram utilizados, as questões que não foram respondidas, nível de dificuldade das questões que foram acertadas e ter uma noção do conhecimento do aluno sobre o

Modelo do aluno (Interações)			
RECURSOS	AÇÕES	TOTAL DE	NÍVEL
Vídeos	Assistidos	2 de 10	-
Textos	Lidos	1 de 4	-
Links	Acessados	1 de 3	-
Questões	Feitas	5 de 21	Muito Fácil (1); Muito Fácil (2); Fácil (3); Fácil (4); Moderada (5);
Questões	Respondidas corretamente	5 de 21	certo (1); errado (2); certo (3); certo (4); errado (5)
Questões	Tempo de resposta	5 de 21	54 ms (1); 65 ms (2); 113 ms (3); 200 ms (4); 345 ms (5);

Tabela 2 – Tabela de interações de um usuário específico

assunto. Com base nessas informações, podemos criar recomendações visando as necessidades do aluno.

Além do coeficiente de interação, existe outro que consideraremos, chamado de coeficiente de desempenho, que é gerado através das notas dos alunos, onde o aproveitamento mínimo aceitável são 60%. Para os casos em que esse coeficiente for menor, o sistema também recomendará com base nas dificuldades percebidas nas respostas dos alunos de determinado assunto.

Modelo do aluno (item desempenho) -> desempenho do aluno no tópico {média}, do currículo {medidas de tendência central}, do sub-domínio estatística descritiva: 40% (abaixo dos 60% que era o esperado).

4.1 OS ELEMENTOS NECESSÁRIOS PARA A CRIAÇÃO DAS RECOMENDAÇÕES EXPLICADAS

Com base no modelo do aluno criado a partir das interações do usuário com o sistema, e desempenho de aprendizagem (referente às questões), são identificadas as necessidades de cada aluno. Diante dessas informações, inicia-se o processo de criação das recomendações. Para criação da recomendação explicada, são utilizados 5 fatores, sendo: o modelo do aluno, o filtro, os recursos de aprendizagem, a recomendação dos recursos de aprendizagem e a explicação. Dessa forma, apresentaremos abaixo o que cada um desses tópicos significa no contexto da presente pesquisa.

4.1.1 Modelo do Aluno

Consiste em dados que apontem para o conhecimento atual dos alunos, identificando as dificuldades, com base na interação e desempenho obtido no decorrer do curso (coeficientes), onde esse modelo vai sendo incrementado de acordo com a performance do aluno, conforme definição exibida na fundamentação teórica (seção 2.5.2).

O modelo do aluno utilizado foi baseado na abordagem feita por (ZAINA, 2008), que é um modelo do aluno com base nas interações do aluno. E segundo (FISCHER, 2001), ele fala que a interação do aluno com o sistema pode ocorrer de duas formas: explícita, que é alimentado quando o usuário passa as informações de forma objetiva ao sistema; e a implícita, na qual através da interação do aluno é possível obter dados a respeito de suas habilidades. Nesse caso nossa abordagem se dará de forma implícita, na qual, ao decorrer do processo de ensino, o perfil do aluno será traçado, podendo ser identificadas suas preferências, habilidades e necessidades.

Desse modo, pode-se dizer que com base nas interações do aluno, identificaremos seu conhecimento (habilidades e crenças) e as suas necessidades tanto em relação a desempenho nas resoluções de questões, quanto na interação com os demais recursos de aprendizagem (vídeos, links, textos e slides).

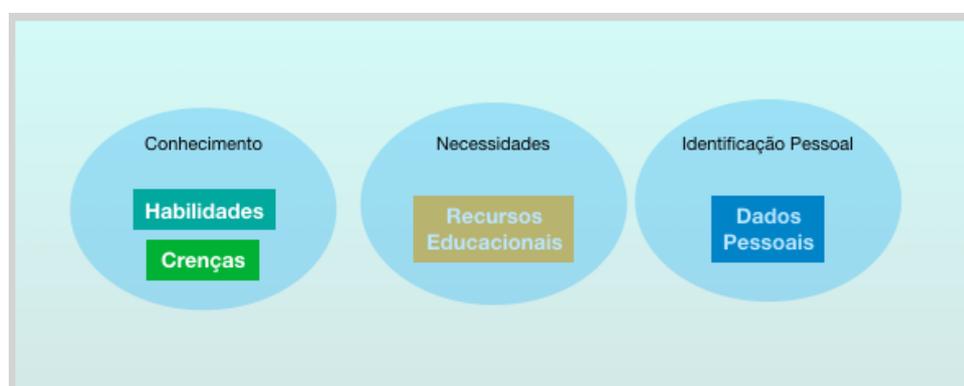


Figura 5 – Modelo adaptado de (ZAINA, 2008)

O modelo do aluno foi criado a partir de dados extraídos da tabela de registro das interações dos estudantes com o sistema (log de interações), estruturado conforme as Figuras: 06, 07, 08 e 09 (trata-se da mesma tabela dividida em 4 partes para facilitar a visualização neste texto). As Figuras 06, 07 e 08 registram as interações dos estudantes com os recursos de aprendizagem (vídeos, textos, links, apresentações e questões) disponíveis no curso estudado sobre estatística descritiva, bem como o desempenho na resolução das questões. A Figura 09

registra o desempenho (pedagógico e de interação) do estudante.

Por exemplo: a primeira linha (Figuras 6, 7, 8 e 9) mostra as interações do estudante 1 com o módulo 1 do curso de estatística descritiva básica. O assunto que o estudante interagiu foi Introdução à Estatística. O Tópico foi o de Teorias e Conceitos. Em relação aos recursos de aprendizagem associados a esse tópico, o estudante assistiu os vídeos, não leu o texto, acessou o link para um recurso externo (outro site), leu os slides da aula, respondeu todas as 4 questões, mas acertou apenas 2. Isso resultou em um desempenho pedagógico de 50% e de interação de 87,5%. Esse desempenho mostra que o estudante interagiu bem com os recursos associados ao tópico, mas não obteve um número de acertos apropriados na resolução de questões (valor de referência = 60%). Sendo assim, uma recomendação será enviada ao estudante com o objetivo de melhorar seu desempenho pedagógico neste tópico.

USUARIO	MODULO	ASSUNTO	TOPICO	VIDEOS ASSISTIDOS
1	1	Introducao a estatistica	Teorias e Conceitos	SIM
1	2	Medidas de tendencia central	Moda	NAO
1	2	Medidas de tendencia central	Mediana	NAO
1	2	Medidas de tendencia central	Media	NAO
1	2	Medidas de tendencia central	Separatiz	SIM
1	3	Medidas de dispersao	Coefficiente de variacao	NAO
1	3	Medidas de dispersao	Desvio Medio	NAO
1	3	Medidas de dispersao	Variancia e Desvio Padrao	NAO
1	4	Medidas de assimetria e curtose	Assimetria	SIM
1	4	Medidas de assimetria e curtose	Curtose	SIM
2	1	Introducao a estatistica	Teorias e Conceitos	SIM
2	2	Medidas de tendencia central	Moda	NAO
2	2	Medidas de tendencia central	Mediana	SIM
2	2	Medidas de tendencia central	Media	SIM
2	2	Medidas de tendencia central	Separatiz	SIM
2	3	Medidas de dispersao	Coefficiente de variacao	NAO
2	3	Medidas de dispersao	Desvio Medio	SIM
2	3	Medidas de dispersao	Variancia e Desvio Padrao	NAO
2	4	Medidas de assimetria e curtose	Assimetria	NAO
2	4	Medidas de assimetria e curtose	Curtose	NAO

Figura 6 – Modelo do aluno - tela 01.

VIDEOS ASSISTIDOS	TEXTOS LIDOS	LINK ACESSADO	PPT ACESSADO	TOTAL DE QUESTOES	QUESTOES CORRETAS
SIM	NAO	SIM	SIM	4	2
NAO	NAO	NAO	NAO	4	2
NAO	SIM	NAO	SIM	4	1
NAO	NAO	SIM	SIM	4	2
SIM	NAO	SIM	SIM	4	2
NAO	SIM	NAO	NAO	4	0
NAO	SIM	NAO	SIM	4	1
NAO	SIM	NAO	NAO	4	1
SIM	SIM	NAO	SIM	2	1
SIM	NAO	SIM	NAO	4	1
SIM	SIM	NAO	SIM	4	0
NAO	SIM	NAO	SIM	4	3
SIM	SIM	NAO	NAO	4	1
SIM	NAO	NAO	SIM	4	3
SIM	SIM	SIM	SIM	4	2
NAO	NAO	NAO	SIM	4	2
SIM	NAO	NAO	SIM	4	0
NAO	SIM	SIM	NAO	4	3
NAO	NAO	SIM	NAO	2	1
NAO	SIM	SIM	SIM	4	1

Figura 7 – Modelo do aluno - tela 02.

QUESTOES ERRADAS	QUESTOES NAO RESPONDIDAS	TOTAL DE INTERACOES DISPONIVEIS	TOTAL DE INTERACOES FEITAS
2	0	8	7
0	2	8	2
2	1	8	5
0	2	8	4
0	2	8	5
3	1	8	4
2	1	8	5
1	2	8	3
1	0	6	5
1	2	8	4
0	4	8	3
0	1	8	5
1	2	8	4
0	1	8	5
2	0	8	8
1	1	8	4
3	1	8	5
0	1	8	5
1	0	6	3
1	2	8	5

Figura 8 – Modelo do aluno - tela 03.

DESEMPENHO PEDAGOGICO (TOPICO)	DESEMPENHO INTERATIVO (TOPICO)	DESEMPENHO PEDAGOGICO (MODULO)	DESEMPENHO INTERATIVO (MODULO)
50	87.5	50	87.5
50	25		
25	62.5		
50	50		
50	62.5	43.75	50
0	50		
25	62.5		
25	37.5	16.67	50
50	83.33		
25	50	33.33	64.29
0	37.5	0	37.5
75	62.5		
25	50		
75	62.5		
50	100	56.25	68.75
50	50		
0	62.5		
75	62.5	41.67	58.33
50	50		
25	62.5	33.33	57.14
50	50	50	50

Figura 9 – Modelo do aluno - tela 04.

As colunas desempenho pedagógico (módulo) desempenho interativo (módulo) mostram o desempenho cumulativo do estudante em um determinado módulo, ou seja, uma média do desempenho do estudante em cada tópico que constitui um módulo específico.

4.1.2 Os filtros

Trata-se de uma consulta pré-definida (conforme as Figuras 12, 13 e 14 apresentadas abaixo) que funciona baseada nas ações que os usuários fizeram ou deixaram de fazer no sistema. Por exemplo: filtrar, para o assunto de medidas de tendência central, os vídeos que o estudante ainda não assistiu, textos que não foram acessados, questões que não foram respondidas ou que foram respondidas de forma errada, links e aulas que não foram visualizadas. O sistema irá consultar os recursos disponíveis com base nos filtros definidos.

4.1.3 Os recursos de aprendizagem

São os tipos/categorias de conteúdo que o sistema dispõe, ou seja, são recursos oferecidos pelo sistema que visam auxiliar os alunos no processo de aprendizagem. Esses recursos são inseridos previamente na plataforma, durante a criação do curso. Os recursos apresentados no sistema são: vídeos, textos, questões, apresentações de aula, links, etc.

4.1.4 A recomendação dos recursos de aprendizagem

A recomendação dos recursos se dará através de notificações (conforme as Figuras 10 e 11) que o sistema enviará para o aluno a medida que ele for interagindo com o sistema. As recomendações serão exibidas na tela do sistema (Figura 10) e o aluno poderá aceitar, ignorar ou recusar a recomendação. Todas as recomendações ficarão listadas em uma tela de acompanhamento, onde o aluno poderá dar seu feedback (aceita, ignora, recusa) durante o período em que o plano de estudos estiver ativo.

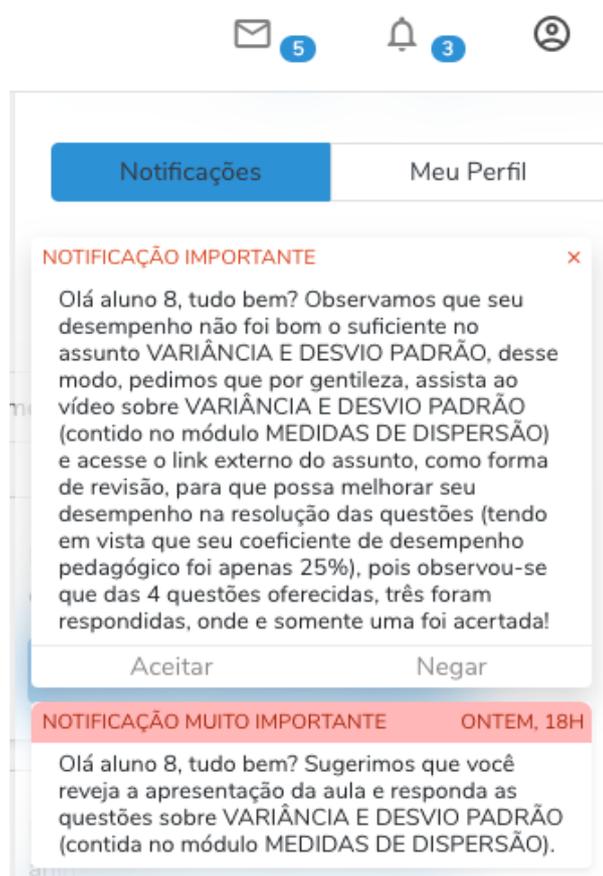


Figura 10 – Recomendações em forma de notificações.

S-Partner Início Recursos (Temporário) ▾

← Notificações Início / Notifications

Minhas notificações

Description	Grade	Time
Olá aluno 1, sugerimos que assista ao vídeo sobre mediana (do assunto medidas de tendência central - módulo 2)	Confirmação	03-12-2019
Olá aluno 1, vimos que seu desempenho não foi bom o suficiente (abaixo de 60%) e pedimos que leia o texto complementar e acesse os links externos com conteúdo explicativo sobre para que possa responder as questões 3 e 4.	Informativa	04-12-2019
Olá aluno 1, pedimos que assista o vídeo sobre desvio padrão, do assunto medidas de dispersão, módulo 3.	Importante	04-12-2019
Olá aluno 1, vimos que seu nível de interação foi bom (acima de 80%), mas o desempenho pedagógico foi baixo (abaixo de 60%), no entanto para que consiga responder as questões 2,3 que foram respondidas erradas, assista ao vídeo e veja as aulas (slides) sobre variância do assunto medidas de dispersão, módulo 3.	Muito importante	04-12-2019
Olá aluno 1, sugerimos que assista ao vídeo sobre mediana (do assunto medidas de tendência central - módulo 2)	Padrão	04-12-2019

Page 1 of 1

Figura 11 – Listagem das Recomendações.

4.1.5 A explicação

De acordo com (HEMPEL; OPPENHEIM, 1948), a essência da explicação está em uma relação de implicação causal entre dois enunciados ou grupo de enunciados: o que explica - o explanans - e o que descreve o evento a ser explicado - o explanandum.

Diante disso, nossa proposta é explicar diante de duas situações, a primeira delas é conforme a interação do aluno, ou seja, explicar que ele está recebendo aquela recomendação por causa da sua pouca interação com o sistema, o que acarretou um baixo coeficiente de interação. O segundo caso seria de acordo com o seu desempenho pedagógico, nós não explicaremos o motivo do aluno não ter entendido o assunto, ou de ter errado determinadas questões, mas sim porque o desempenho dele foi abaixo do esperado com base no coeficiente pedagógico, por isso, ele está recebendo aquela recomendação. Ressaltamos que o valor mínimo de aceitação para ambos coeficientes (interação e pedagógico) foram de 60%, cuja escolha do valor foi estabelecida por nós.

Consideramos explicação, sendo a parte do texto que justifica/explica a recomendação, tornando-a transparente para o leitor, ou seja, é o que justifica o motivo pelo qual a recomendação foi enviada ao estudante. Para a explicação, no contexto desta pesquisa, o sistema leva em consideração as interações e o desempenho de cada estudante em cada um dos assuntos do curso. Nesta pesquisa, se o desempenho do estudante, em um determinado assunto, e/ou a quantidade de interações com recursos em determinado tópico forem inferiores a 60%, o sistema irá propor recomendações para melhorar esse desempenho e/ou interação. No experimento, a aceitação dos estudantes em relação a essas recomendações quando explicadas, será comparada com a aceitação das recomendações quando não explicadas (só é descrito o que fazer).

Exemplo de explicação com base nas interações do aluno 1: “Olá aluno 1, tudo bem? Vimos que apesar de você ter interagido com quase todos os recursos disponibilizados no sistema (interação = 87,5%), o seu desempenho pedagógico foi baixo (valor referência = 60%), onde das 4 questões oferecidas, você respondeu todas, mas só acertou 2. Dessa forma recomendamos que leia o texto e assista ao vídeo sobre Teorias e Conceitos, para que possa obter êxito em todas as questões.”

Seguindo o conceito de (HEMPEL; OPPENHEIM, 1948), a nossa abordagem de recomendação explicada analisando o exemplo acima obedeceria a seguinte forma:

- **Causa:** Baixo desempenho pedagógico (assertividade de questões).
- **Explicação:** “o seu desempenho pedagógico foi baixo (valor referência = 60%), onde das 4 questões oferecidas, você respondeu todas, mas só acertou 2.”

Onde no contexto desta pesquisa, consideremos o fator explicação como um elemento que tem por finalidade fornecer transparência ao usuário. Pois, conforme (TINTAREV; MASTHOFF, 2012), a transparência é a possibilidade de expor o raciocínio e os dados por trás de uma recomendação. Uma explicação pode esclarecer como uma recomendação foi escolhida. Em sistemas especialistas, como no domínio da tomada de decisões médicas, a importância da transparência também foi reconhecida (ABRAHAM, 2005). Transparência ou heurística de “Status de Visibilidade do Sistema” também é um princípio de usabilidade estabelecido (NIELSEN; MOLICH, 1990), e sua importância também foi destacado em estudos com usuários de sistemas de recomendação (SINHA; SWEARINGEN, 2002). A compreensão da relação entre a entrada no sistema (classificações feitas por usuário) e saída (recomendações) permite que o usuário inicie uma interação previsível e eficiente com o sistema. A transparência permite que os usuários revisem significativamente a entrada para melhorar as recomendações.

4.1.5.1 Estrutura da automatização da recomendação explicada

A criação das explicações seguem a seguinte estrutura:

- Mensagem de boas vindas.
- Observações que identificam a necessidade do aluno com base no modelo do aluno (coeficientes), seja com relação a desempenho pedagógico ou a interação.
- Recursos que serão recomendados (questões não respondidas, questões erradas, vídeos não assistidos, links não acessados, textos não lidos, slides não acessados).

A estrutura terá algumas partes fixas no texto e outras que irão variar de acordo com a situação identificada no modelo do aluno.

1 - Em casos que forem detectados baixos desempenho (quanto a resolução de questões) e interação, a estrutura será a seguinte:

<boas vindas> + <nome do aluno> + percebemos que seu desempenho e interação foram baixos no tópico <nome do tópico>, contido no assunto <nome do assunto>, onde os respectivos coeficientes foram: <coeficiente desempenho> + <coeficiente interação> + e vimos que as questões <número das questões> não foram respondidas. Diante disso recomendamos que acesse <recursos não utilizados>, pois vimos que ele(s) não foram acessados durante o curso, e poderá(ão) ajuda-ló(á) a responder às questões e obter um melhor desempenho.

2 - Em casos que forem detectados baixos nível de interação a estrutura será a seguinte:

<boas vindas> + <nome do aluno> + percebemos que desempenho foi satisfatório para o tópico <nome do tópico>, contido no assunto <nome do assunto>, cujo valor de rendimento foi igual a <coeficiente desempenho>, mas vimos que você não interagiu com todos os recursos, sugerimos que interaja com os recursos <recursos não utilizados> para que possa finalizar o módulo com 100% de aproveitamento, pois seu rendimento de interação apenas <coeficiente interação>, abaixo do esperado que é 60%

3 - Em casos que houverem baixo desempenho:

<boas vindas> + <nome do aluno> + percebemos que seu desempenho foi baixo no tópico

<nome do tópico>, contido no assunto <nome do assunto>, cujo seu coeficiente de desempenho foi abaixo de 60% que é o mínimo aceitável, onde o valor obtido foi <coeficiente de desempenho>, para que tenha um melhor aproveitamento, sugerimos que acesse o(s) seguinte(s) recurso(s) do referido módulo <nome do módulo>: <recursos não utilizados>, tendo vista que esses recursos não foram utilizados e você respondeu somente as questões <questões respondidas>, vindo a acertar somente às questões <questões certas>.

Diante da situação encontrada pelo sistema, com base no exemplo do aluno 1, retirado do modelo do aluno (Figuras 6, 7, 8 e 9) que contém os dados das interações do usuário, e com base na necessidade observada, uma recomendação será enviada ao estudante visando melhorar seu desempenho pedagógico especificamente neste tópico. Nesse aspecto, as Figuras 11, 12 e 13 ilustram como as recomendações explicadas serão elaboradas. Elas serão criadas através da utilização de filtros que selecionam as ações executadas ou não pelos alunos no decorrer dos estudos feitos na plataforma, e com isso serão feitas recomendações explicadas de alguns recursos, como: apresentações de aulas, questões, textos, vídeos e links.

4.1.6 Questões como Recurso Recomendativo

FILTROS QUESTÕES			
	FILTRO	RECURSO RECOMENDADO	EXPLICAÇÃO DA RECOMENDAÇÃO
#1	Questões não respondidas	Questões	"Estamos recomendando essa questão 1,2 sobre medidas de tendência central, pois elas são inéditas para você"
#2	Questões não acertadas	Questões	"Estamos recomendando a questão 2 (sobre medidas de assimetria e curtose), pois vimos que você errou e não tentou respondê-la novamente"
#3	Dificuldade das questões	Questões	"Estamos recomendando a questão 3 (sobre medidas de tendência central), pois ela é considerada difícil e você só resolveu questões de nível fácil"

Figura 12 – Criação da Recomendação Explicada oferecendo questões como recurso educacional.

Desse modo, levando em consideração que o sistema percebeu um deficit na turma em relação a determinado assunto, ele poderá montar alguns tipos de recomendação conforme a

Figura 9, onde poderão ser realizadas as seguintes ações:

1.
 - Listar as questões que **não foram respondidas** (Filtro);
 - Sugerir-las para que sejam respondidas (Questões como recurso);
 - Explicar o motivo de tal recomendação (Explicação da Recomendação)
Ex: Estamos lhe recomendando as questões 1,2 sobre medidas de tendência central, pois elas são inéditas para você.

2.
 - Listar as questões que **não foram acertadas** (Filtro);
 - Sugerir-las para que sejam respondidas (Questões como recurso);
 - Explicar o motivo de tal recomendação. (Explicação da Recomendação)
Ex: Estamos lhe recomendando a questão 2 (sobre medidas de assimetria e curtose), pois vimos que você não acertou e não tentou respondê-la, novamente,

3.
 - Listar as questões com base nos **níveis de dificuldades** (Filtro);
 - Sugerir-las para que sejam respondidas (Questões como recurso);
 - Explicar o motivo de tal recomendação. (Explicação da Recomendação)
*Ex: *Estamos lhe recomendando a questão 3 (sobre medidas de tendência central), pois ela é considerada difícil e você só resolveu questões de nível fácil.*
** Recomendamos que faça a questão 1, porque ela é fácil e ajudará a ganhar confiança adquirir conhecimento sobre o assunto, introdução a estatística.*
** Sugerimos que faça a questão 3, pois ela é de dificuldade média, e adquira mais conhecimento, sobre Medidas de dispersão.*
** Sugerimos que faça a questão 4, pois você já possui conhecimento sobre o assunto: medidas de dispersão, e essa questão visa desafiá-lo.*

4.1.7 Vídeos como Recurso Recomendativo

Da mesma forma como feito anteriormente, o sistema poderá recomendar outros tipos de recursos, conforme como pode ser visto na Figura 10, onde são oferecidos vídeos como materiais complementares, para estimular o aprendizado e aumentar o engajamento dos alunos.

FILTROS VÍDEOS			
	FILTRO	RECURSO RECOMENDADO	EXPLICAÇÃO DA RECOMENDAÇÃO
#1	Vídeos assistidos	Vídeos	"Vimos que já assistiu a esse vídeo (curtose.mp4), mas estamos lhe recomendando para que assista novamente (a título de revisão), para que entenda melhor o conteúdo e possa responder as questões 1 e 2."
#2	Vídeos não assistidos	Vídeos	"Estamos recomendando esse vídeo (mediana.mp4), pois ele não foi assistido durante o curso e ele poderá auxiliá-lo(a) na resolução das questões sobre mediana do assunto medidas de tendência central"

Figura 13 – Criação da Recomendação Explicada oferecendo vídeos como recursos educacionais.

1.
 - Listar os vídeos que **foram assistidos** (Filtro);
 - Sugerir-los, para que sejam assistidos (vídeos como recurso);
 - Explicar o motivo de tal recomendação (Explicação da Recomendação)
Ex: Vimos que já assistiu a esse vídeo (curtose.mp4), mas estamos lhe recomendando para que assista novamente (a título de revisão), para que possa entender melhor o conteúdo sobre medidas de assimetria e curtose e possa responder às questões 1 e 2.
2.
 - Listar os vídeos que **não foram assistidos** (Filtro);
 - Sugerir-los, para que sejam assistidos (vídeos como recurso);
 - Explicar o motivo de tal recomendação (Explicação da Recomendação)
Ex: Estamos lhe recomendando esse vídeo (Mediana.mp4), pois ele não foi assistido durante o curso e ele poderá auxiliar na resolução das questões sobre mediana, do assunto, medidas de tendência central.

4.1.8 Links como Recurso Recomendativo

FILTROS LINKS			
	FILTRO	RECURSO RECOMENDADO	EXPLICAÇÃO DA RECOMENDAÇÃO
#1	Links não acessados	Links de conteúdo didático	“Estamos Recomendando esse link, pois vimos que você não o acessou, e ele pode ser útil para responder as questões 1,2 e 3 do assunto: medidas de dispersão, tópico: Desvio Padrão.”

Figura 14 – Criação da Recomendação Explicada oferecendo links como recursos educacionais.

- Listar os links que **não foram acessados** (Filtro);
 - Sugerir-los para que possam ser acessados (Links como recurso);
 - Explicar o motivo de tal recomendação. (Explicação da Recomendação)

Ex: Estamos Recomendando esse link, pois vimos que você não o acessou, e ele pode ser útil para responder as questões 1,2 e 3 do assunto: medidas de dispersão, tópico: desvio Padrão.

4.2 CRIAÇÃO DAS RECOMENDAÇÕES

O ponto de partida são as interações dos estudantes com o ambiente de aprendizagem. Essas interações são usadas para gerar o modelo do aluno. Esse modelo, para cada aluno, é analisado e com base nele, são feitas as recomendações (se necessárias). A análise feita pelo sistema se dá quando o sistema detecta baixos coeficientes de interação e/ou desempenho (que são obtidos do modelo do aluno) por parte de alguns alunos ou toda turma, em um determinado tópico, de um assunto, em uma disciplina, onde mediante uma análise, percebe-se que os alunos estavam com dificuldade na disciplina de estatística descritiva, no assunto de medidas de dispersão, estritamente no tópico de desvio padrão, e mediante isso, estavam respondendo somente questões de nível fácil. Com base nas informações obtidas, o sistema criará um plano de estudo contendo todo o fluxo do processo e os recursos educacionais (vídeos, questões,

textos, links, etc.) que serão disponibilizados. Esse plano de estudo visa resolver o problema do estudante em relação a um determinado assunto. O plano será enviado para o estudante como uma recomendação, que o estudante pode aceitar, rejeitar ou ignorar. A recomendação poderá ser acompanhada de uma explicação, ou seja, um motivo de o estudante ter recebido tal recomendação.

Utilizando-se de filtros, com base no modelo do aluno que o sistema pretende atingir e nos recursos que serão recomendados, o sistema cria como será montada a explicação da recomendação, por exemplo: listar todos os alunos que estão com notas (coeficientes) baixas e sugerir que respondam questões com nível médio de dificuldade ou assistam determinado vídeo, ou acessem algum material/link com conteúdo complementar, tudo isso seguido de uma explicação ou não, pois serão disponibilizados os dois cenários. Após definir os recursos educacionais, a presença ou ausência da explicação, o(s) aluno(s) receberá(ão) as recomendações por meio de uma notificação e com base nisso, poderá(ão) dar um feedback, informando se a recomendação foi apropriada ou não (a relevância), assim como, se a explicação foi apropriada ou não (para os casos a qual for aplicada) e se pretendem segui-la (conforme a Figura 12).

O professor também tem um papel fundamental no processo, pois atuará em casos contraditórios listados abaixo, onde seu conhecimento/vivência na pedagogia e ensino será útil para compreender melhor esses casos, por exemplo:

- O estudante informa que a recomendação está apropriada, mas não aceita realizá-la.
- O estudante aceita a recomendação, mas informa que ela não estava apropriada.
- O professor receberá a notificação, e avaliará o caso, especificamente o conteúdo (texto) da recomendação, afim de analisar a adequação.

A Figura 12 sintetiza fluxo do processo de criação da recomendação explicada, assim como a forma que ela chega até o aluno, conforme descrito anteriormente.

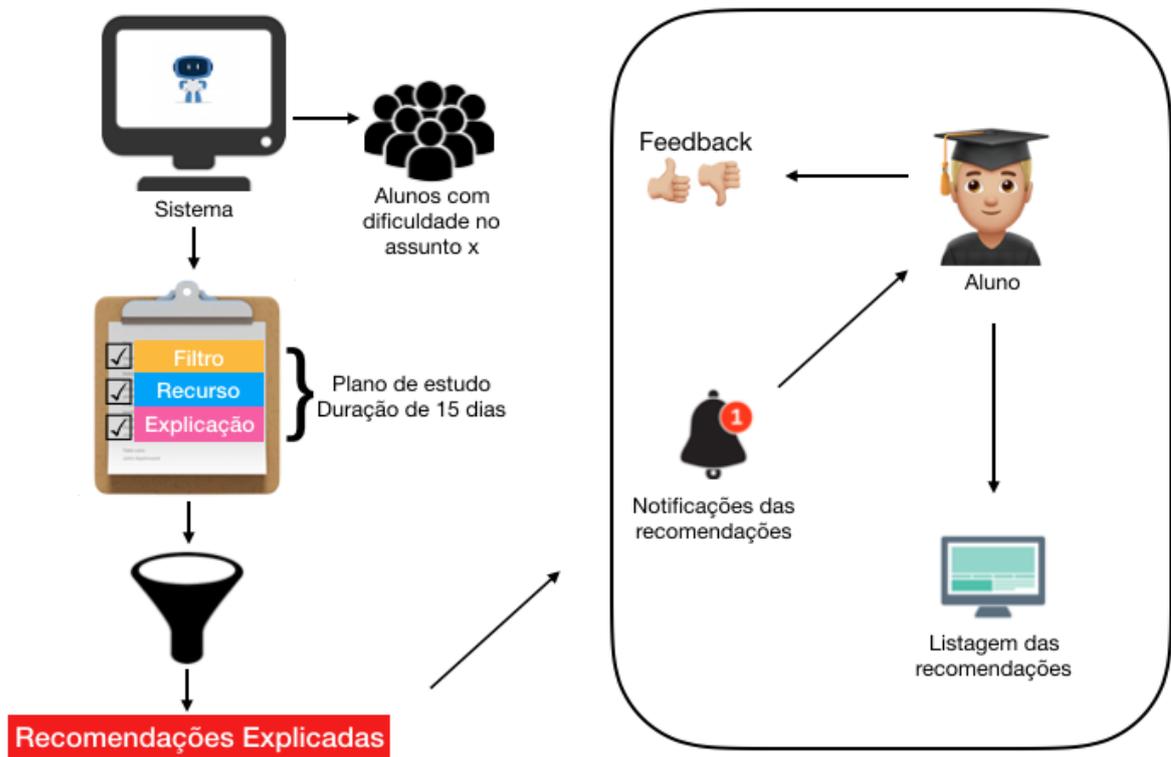


Figura 15 – Fluxo do processo de criação das recomendações explicadas.

5 METODOLOGIA

Para validar as hipóteses da pesquisa, conforme mencionado na seção 1.5: H0: não Existe diferença significativa na aceitação das recomendações em ambientes com explicações e sem explicações. HA: existe diferença significativa na aceitação das recomendações em ambientes com explicações e sem explicações. Fizemos o levantamento de informações através das técnicas de coleta (questionários, entrevistas, etc).

5.1 EXPERIMENTO

Inicialmente havíamos planejado desenvolver o sistema (conforme descrito abaixo) e termos interações reais com alunos reais, gerando dados, e a partir desses dados iríamos modelar cada um dos alunos, e enviar recomendações, onde avaliaríamos se ele aceitou ou não a recomendação e caso tenha aceitado, analisaríamos se ele seguiu/concluiu ou não a recomendação dentro do prazo estabelecido. Mas infelizmente devido à instabilidade na interface do sistema, isto não foi possível, pois poderia gerar dúvidas, se os problemas de interação dos alunos foram decorrentes da recomendação ou do funcionamento apropriado da interface. Por esse motivo decidimos criar as interações por meio de simulação, onde foram criadas 30 personas, e para cada persona atribuímos diversos tipos de interações aleatórias com os recursos do sistema. Analisamos os cenários criados e escolhemos um, que relata o caso do aluno 8 e criamos 4 recomendações com base nas interações do aluno e para cada uma das recomendações apresentamos um conjunto de afirmações, que abordam aspectos tanto da recomendação quanto do texto que as compõem (presença e ausência da explicação).

O curso a ser fornecido pelo sistema que pretendíamos utilizar, era um curso de estatística descritiva, cuja organização e fluxo podem ser vistos nas Figuras 13 (anterior) e 14 respectivamente, mas isso não foi possível utilizar a plataforma criada devido aos impedimentos que surgiram no decorrer do processo (que foram detalhados anteriormente), mas que não comprometeram a realização da pesquisa. Contudo, detalharemos o processo de criação da plataforma e curso.

5.1.1 Tecnologias utilizadas na criação da plataforma

A plataforma é voltada para a arquitetura web, onde para sua implementação foram utilizadas as seguintes tecnologias:

Backend : linguagem de programação php, framework laravel

Frontend: framework vue.js

Banco de dados: Mysql.

A escolha das tecnologias citadas se deu pelo motivo de serem de fácil utilização, por serem bastante utilizadas e de fácil manutenção. Além de possibilitar um desenvolvimento rápido, permitindo gerar um produto confiável e escalável (que possibilite uma expansão e entendimento caso necessite de replicação).

5.1.2 Panejamento do experimento

Diante do objetivo da pesquisa, que é saber se as explicações influenciam na aderência de uma recomendação, e isso está diretamente ligado ao estudo do comportamento do ser humano, quando está diante de determinada situação, vimos a possibilidade de criar um sistema de aprendizagem online, e através dele oferecer um curso de estatística descritiva. O curso teria alguns recursos disponíveis (vídeo, texto, link, slides e questões) para os alunos, e mediante as interações dos alunos, as recomendações seriam criadas, com base no modelo de cada aluno. Com o modelo criado, as recomendações seriam enviadas de forma alternada, iniciando por uma recomendação sem explicação e posteriormente uma recomendação com explicação. E com isso, poderíamos observar quais foram os posicionamentos dos participantes e tiramos uma conclusão quanto a hipótese investigada.

O sistema permite a criação de cursos com a seguinte estrutura: um curso pode ser composto por 1 ou mais módulos. Cada módulo pode conter 1 ou mais assuntos. Cada assunto pode conter 1 ou mais tópicos. Cada tópico pode conter 1 ou mais recursos de aprendizagem. O curso em questão (introdução à estatística descritiva) é composto de 4 módulos, e cada módulo contém assuntos e tópicos conforme exibido na Figura 15. Por exemplo: no curso de estatística descritiva, o segundo módulo contempla o assunto de medidas de tendência central e o tópico é mediana. Para cada tópico existem recursos educacionais associados, como: vídeos, questões, links, aulas (slides) e textos com conteúdo auxiliar, dos mais diversos graus de dificuldade. A medida que o aluno interagir com os recursos da plataforma o modelo do aluno é criado.

5.1.3 Estrutura do curso

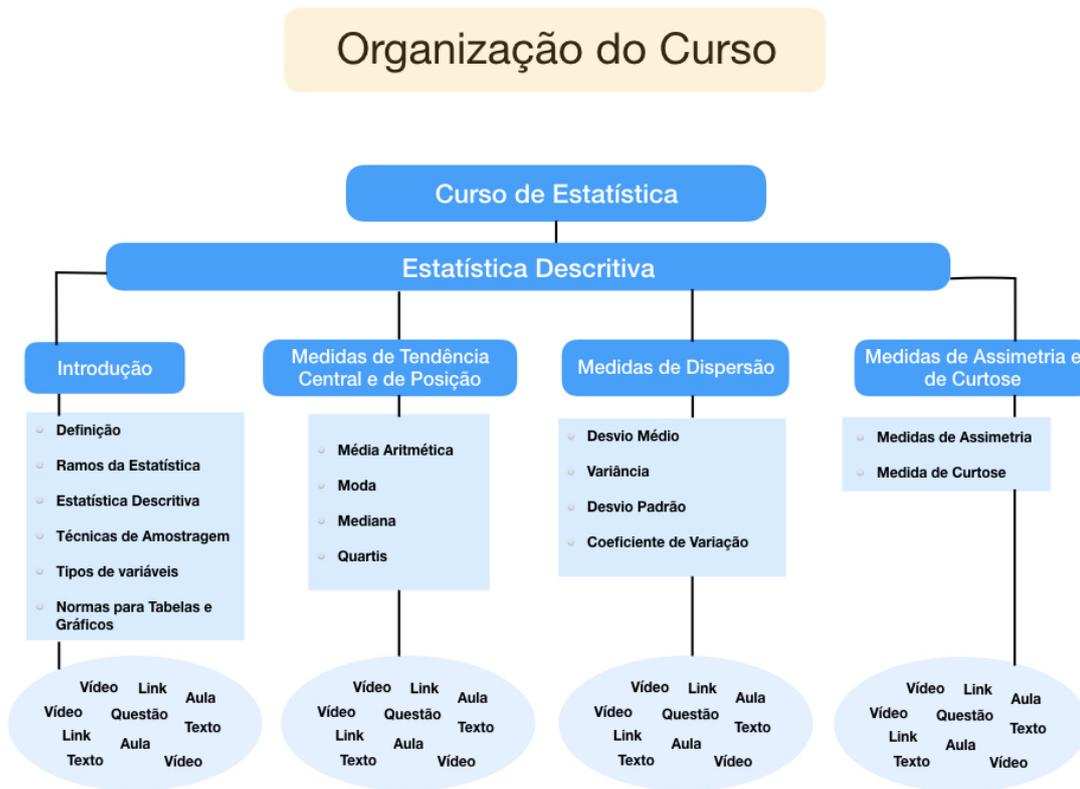


Figura 16 – Organização do curso.

5.1.4 Fluxo de interação com o curso

Conforme pode ser visto abaixo, a Figura 16 apresenta o fluxo de interação com o curso, que funciona da seguinte forma:

1. O aluno é submetido a realizar um curso de estatística descritiva.
2. O aluno iniciará o curso, que conta com 4 módulos, cada um contendo recursos como: vídeo, questões, textos links e apresentações de aulas, onde o aluno só poderá passar para o próximo módulo após finalizar o anterior.
3. O sistema monitora as interações realizadas pelo aluno e armazena os dados.
4. À medida que os dados são armazenados, o modelo do aluno vai sendo criado.
5. Para cada aluno o sistema calcula o coeficiente pedagógico e de interação, onde o mínimo aceitável é de 60% para cada um dos casos e incrementa o modelo do aluno.
6. Caso o aluno tenha algum dos seus coeficientes abaixo de 60%, o sistema consulta os dados armazenados, durante o monitoramento, para listar recursos não utilizados e questões não respondidas ou respondidas erradas. Caso seja igual ou maior que 60% nada é feito.
7. Com base nas interações e desempenho do aluno o sistema cria e recomendações personalizadas (explicadas e não explicadas) com base no modelo do aluno.
8. O sistema envia as recomendações (explicadas e/ou não) com os itens (recursos educacionais) automaticamente para os alunos.
9. O aluno recebe as recomendações em forma de notificações.
10. O aluno poderá informar se aceita ou recusa a recomendação.
11. O aluno terá um local específico com a listagem todas as recomendações feitas durante o curso.
12. caso o aluno indique que não aceita recomendação, o sistema criará um teste (do módulo-assunto-tópico em questão) para que o aluno responda e notifica o professor, para que se possa validar a recomendação que foi enviada. Caso o aluno responda corretamente, o modelo do aluno é atualizado (recomendação foi equivocada), caso contrário (recomendação correta) a recomendação é enviada novamente para o aluno.

interatividade e/ou um baixo desempenho quanto a questões, o sistema criará recomendações de forma automática.

As recomendações atuam com base nas seguintes observações:

1. Questões não respondidas.
2. Questões respondidas erradas.
3. Somente respostas a questões de nível fácil.
4. Vídeos assistidos (como forma de revisão) e não assistidos.
5. Links acessados (como forma de revisão) e não acessados.
6. Textos acessados (como forma de revisão) e não acessados.
7. Apresentações de aula acessadas (como forma de revisão) e não acessadas.

Diante dos aspectos mencionados, o sistema envia recomendações como forma de notificações conforme a Figura 9 (seção 4.1.4), sugerindo interações com recursos educacionais não utilizados e/ou já utilizados (como forma de revisão), visando um melhor desempenho. Ao receber a recomendação (notificação) o aluno poderá informar se aceita ou rejeita a recomendação. O estudante pode, ainda, ignorar a recomendação (não aceitar nem rejeitar a notificação contendo a recomendação). Neste caso, o sistema não possui nenhuma informação sobre a percepção do estudante sobre a recomendação enviada. Isso pode ser uma atitude deliberada do estudante ou o estudante não acessou o sistema depois que a recomendação foi enviada. Durante o experimento, avaliamos cenários onde recomendações foram oferecidas considerando dois cenários: recomendações com explicação e sem explicação.

Como mencionado inicialmente, infelizmente não foi possível realizar o curso com alunos reais, pois, a plataforma não ficou estável, a interface do sistema que não ficou satisfatória, e isto fez com que os planos fossem mudados, pois esses fatores poderiam resultar em uma ameaça quanto a validade da hipótese. E para ajustar a plataforma levaria um bom tempo, impedindo que terminássemos a pesquisa no prazo determinado pelo programa de mestrado.

O experimento foi reformulado, de modo que os dados utilizados foram gerados por meio de simulação de logs de interação dos usuários, criados por um algoritmo, utilizando combinações de dados que fossem possíveis de ocorrer no mundo real. Foram criados 30 personas e diversas interações para cada usuário envolvido. Todas as interações foram armazenadas em uma tabela

de log no banco de dados da aplicação, onde a tabela serviu para que pudéssemos agrupar todas as ações simuladas por usuário. Para que fosse possível analisar a performance de cada usuário a respeito da interatividade e desempenho.

Com os dados armazenados, foi feita uma triagem para listar os campos necessários para elaborar o modelo do aluno, onde os campos foram: identificador do usuário, módulo, assunto, tópico, quantidade de vídeos disponíveis, vídeos assistidos, quantidade de textos disponíveis, textos acessados, quantidade de links disponíveis, links acessados, quantidade de apresentações de aula disponíveis e acessados, total de questões disponíveis, total de questões corretas, total de questões erradas, total de questões não respondidas, total de interações disponíveis, total de interações feitas, desempenho pedagógico por tópico, desempenho auto avaliativo, desempenho interativo por tópico, desempenho pedagógico por módulo, desempenho interativo por módulo. Abaixo estão listados os dados coletados, o tipo que corresponde o dado e os possíveis valores que podem assumir:

Variável	Descrição	Tipo de dado	Fatores (possíveis valores)
idUsuario	Número único que identifica o usuário	Inteiro	de 1 a infinito
idModulo	Número único que identifica o módulo	Inteiro	de 1 a infinito
idAssunto	Número único que identifica o assunto	Inteiro	de 1 a infinito
idTopico	Número único que identifica o tópico	Inteiro	de 1 a infinito
qtdVideoDisp	Número que mostra o total de vídeos disponíveis	Inteiro	de 1 a infinito
qtdVideoAss	Número que mostra o total de vídeos assistidos	Inteiro	de 1 a infinito
qtdTextDisp	Número que mostra o total de textos disponíveis	Inteiro	de 1 a infinito
qtdTextoAcessado	Número que mostra o total de textos lidos	Inteiro	de 1 a infinito
qtdLinksDisp	Número que mostra o total de links disponíveis	Inteiro	de 1 a infinito
qtdLinksAcessado	Número que mostra o total de links acessados	Inteiro	de 1 a infinito
qtdAulasSlide	Número que mostra o total de aulas disponíveis	Inteiro	de 1 a infinito
qtdAulasSlide	Número que mostra o total de aulas acessadas	Inteiro	de 1 a infinito
qtdQuestoesDisp	Número que mostra o total de questões disponíveis	Inteiro	de 1 a infinito
qtdQuestoesAcertadas	Número que mostra o total de questões acertadas	Inteiro	de 1 a infinito
qtdQuestoesErradas	Número que mostra o total de questões erradas	Inteiro	de 1 a infinito
qtdQuestoesNaoRespondidas	Número que mostra o total de questões não respondidas	Inteiro	de 1 a infinito
totalDeInteracoesDisp	Número que mostra o total de interações disponíveis	Inteiro	de 1 a infinito
totalDeInteracoesFeitas	Número que mostra o total de interações feitas	Inteiro	de 1 a infinito
desempenhoAvaliativo	Número que mostra a opinião do usuário sobre a recomendação	Inteiro	-1; 0; 1; (vazio)
desempenhoPedagogicoTopico	Número que mostra o desempenho pedagógico por tópico	Decimal	de 1% a 100%
desempenhoPedagogicoModulo	Número que mostra o desempenho pedagógico por módulo	Decimal	de 1% a 100%
desempenhoInterativoTopico	Número que mostra o desempenho interativo por tópico	Decimal	de 1% a 100%
desempenhoInterativoModulo	Número que mostra o desempenho interativo por módulo	Decimal	de 1% a 100%

Tabela 3 – Variáveis, tipos e possíveis valores

5.1.5 Survey

A partir do modelo do aluno, utilizamos uma abordagem baseada em cenários, onde foi elaborado um survey contendo quatro cenários de recomendação (todos em relação a uma situação prevista de acordo com as interações de um usuário escolhido aleatoriamente dentre os dados (simulados) de interação de 30 usuários criados). Quanto às recomendações, foram 2 com explicação e 2 sem explicação, e para cada recomendação foram feitas as seguintes afirmações:

- **(1) A recomendação oferecida a mim foi apropriada (justifica o problema descrito).**
esta afirmação visa avaliar se os participantes perceberam a recomendação como sendo de boa qualidade e pertinente à situação descrita no cenário. A qualidade das recomendações não pode ser um fator que influencie a decisão do participante em segui-la ou não. Sendo assim, todas as recomendações foram feitas com cuidado e atenção à qualidade.
- **(2) O texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação.**
esta afirmação visa avaliar se explicação ajudou o participante a entender o motivo de ter recebido a recomendação.
- **(3) O texto da recomendação faz (motiva) com que eu siga tal recomendação.**
esta afirmação visa avaliar se o participante sentiu-se motivado em seguir a recomendação por causa da explicação.
- **(4) A recomendação está clara (Sou capaz de entendê-la e saber o que devo fazer).**
esta afirmação visa verificar se a recomendação foi clara. O objetivo é que a recomendação permita que após lê-la, o usuário saiba o que deve fazer. Isso que é diferente da explicação que justifica o motivo de a recomendação ter sido feita.
- **(5) Se eu fosse o aluno 8, eu seguiria essa recomendação.**
esta afirmação visa verificar se o participante, se colocando na posição do aluno 8 (cuja situação é descrita no cenário), seguiria a recomendação oferecida.
- **(6) Acho importante que o sistema explique porque uma recomendação foi gerada.**
esta afirmação visa verificar se o participante concorda que explicar o motivo de uma recomendação ter sido feita é algo desejável/importante.

A ordem de apresentação das recomendações para cada cenário foi: cenário 1: recomendação sem explicação; cenário 2: recomendação com explicação; cenário 3: recomendação

sem explicação e cenário 4 com explicação. O survey foi disponibilizado online para uma lista de estudantes e professores para que pudessem respondê-lo. O survey contém as seguintes informações:

- Termo de Consentimento Livre e Esclarecido - TCLE (para que o voluntário pudesse confirmar participação e aceitar os termos);
- Dados pessoais do participante
 - Nome, gênero, data de nascimento, email, grau de escolaridade, nível de conhecimento no uso de tecnologias, se já participou de cursos online, quantidade de cursos que já participou.
- Contextualização de um caso, cujo coeficiente pedagógico e/ou interativo estejam baixos, sendo escolhidos de forma aleatória do modelo do aluno;
- Breve release do cenário exposto no contexto inicial (caso real, retirado do log do sistema); Recomendação explicada/não explicada de recursos educacionais, com base no modelo do aluno;
- Cenário: *“O aluno 8 obteve um baixo percentual de desempenho pedagógico (PDP), no assunto VARIÂNCIA E DESVIO PADRÃO (tópico 3), do módulo MEDIDAS DE DISPERSÃO (módulo 3). Pois observou-se que, das 4 questões que foram oferecidas pelo sistema o aluno respondeu apenas 3 das quais acertou 1 e errou 2, obtendo um PDP = 25%, onde o desempenho aceitável pelo sistema, é de no mínimo 60%.”*
- As 4 Recomendações:
 1. **SEM EXPLICAÇÃO:** *“Olá aluno 8, tudo bem? Sugerimos que você reveja a apresentação da aula e responda as questões sobre VARIÂNCIA E DESVIO PADRÃO (contida no módulo MEDIDAS DE DISPERSÃO).”*
 2. **COM EXPLICAÇÃO:** *“Olá aluno 8, tudo bem? Observamos que seu desempenho não foi bom o suficiente no assunto, VARIÂNCIA E DESVIO PADRÃO, desse modo, pedimos que por gentileza, assista ao vídeo sobre VARIÂNCIA E DESVIO PADRÃO (contido no módulo MEDIDAS DE DISPERSÃO) e acesse o link externo do assunto, como forma de revisão, para que possa melhorar seu desempenho na resolução das questões (tendo em vista que seu coeficiente de desempenho pedagógico foi apenas*

25%), pois se observou que das 4 questões oferecidas, três foram respondidas, onde e somente uma foi acertada!”

3. **SEM EXPLICAÇÃO:** “Olá aluno 8, tudo bem? Pedimos por gentileza que leia o texto auxiliar, acesse o link externo, assista novamente ao vídeo sobre o assunto, **VARIÂNCIA E DESVIO PADRÃO** (contido no módulo **MEDIDAS DE DISPERSÃO**) e responda às questões.”
4. **COM EXPLICAÇÃO:** “Olá aluno 8, tudo bem? Observamos que seu desempenho de interação foi satisfatório (87.5%) e lhe parabenizamos por isso, pois vimos que utilizou quase todos os recursos disponibilizados pelo sistema, mas percebemos que o seu desempenho pedagógico (25%), quanto a resolução de questões não foi bom, no assunto, **VARIÂNCIA E DESVIO PADRÃO**. Sendo assim, pedimos por gentileza, que assista novamente ao vídeo sobre **VARIÂNCIA E DESVIO PADRÃO** (contido no módulo **MEDIDAS DE DISPERSÃO**) e reveja a apresentação da aula que contém exemplos bastante didáticos, que te ajudarão a resolver todas as questões.”

- Questões (comum para cada uma das 4 recomendações)

1. A recomendação oferecida foi apropriada (justifica o problema descrito).
2. O texto da recomendação explica ao aluno o motivo dele está recebendo tal recomendação.
3. O texto da recomendação faz (motiva) com que eu siga tal recomendação.
4. A recomendação está clara (Sou capaz de entendê-la e saber o que devo fazer).
5. Se eu fosse o aluno 8, eu seguiria essa recomendação.
6. É importante que o sistema explique porque uma recomendação foi gerada.

O link do questionário foi liberado no dia 22/10 e permaneceu ativo por 21 dias, sendo desativado no dia 11/11 às 29:59.

As recomendações eram apresentadas, de modo que, no primeiro cenário a primeira recomendação era não explicada, a segunda era explicada, a terceira era não explicada e a última era explicada.

5.2 VARIÁVEIS EXPERIMENTAIS

Quanto à análise, pretende-se verificar a incidência/correlação dos tipos de recomendações (com explicação e sem explicação) em relação à aceitação de tal recomendação. Dessa

forma, as variáveis foram classificadas como independentes, dependentes cada uma com seus respectivos fatores.

1. Independente

- Recomendação
 - Com explicação
 - Sem explicação

2. Dependentes

- Aceitação
 - Aceitar
 - Rejeitar
 - Ignorar (Não será medida no contexto deste experimento, mas é um possível fator)

5.3 PARTICIPANTES

Existem dois tipos de participantes, os participantes do curso e os participantes do survey.

Participantes do curso: Quanto a seleção de pessoas para participar do curso, a pretensão era: alunos de nacionalidade Brasileira, professores, estudantes de graduação do curso de ciência da computação, engenharia de software e pós-graduação. E que aceitassem participar do experimento de forma voluntária. Mas como mencionado anteriormente nesta seção, os dados utilizados foram obtidos por meio de uma simulação de logs de interação.

Participantes do survey: Quanto ao critério de seleção de participação no survey, foi: qualquer pessoa que já tivesse realizado um curso em alguma plataforma online de ensino. Eles receberam o link do survey por email do grupo institucional, que contemplavam os alunos e professores do Instituto de Computação (IC).

5.4 TÉCNICA DE RECOMENDAÇÃO UTILIZADA

Conforme (JANNACH et al., 2010), a recomendação baseada em conteúdo, em sua essência é baseada na disponibilidade de descrições de itens (criadas manualmente ou extraídas

automaticamente) e em um perfil que atribui importância a essas características. Quando comparada com as abordagens independentes de conteúdo, descritas acima, a recomendação baseada em conteúdo tem duas vantagens. Primeiro, não requer grandes grupos de usuários para alcançar uma precisão razoável das recomendações. Além disso, novos itens podem ser recomendados imediatamente quando os atributos do item estiverem disponíveis. Em alguns domínios, essas descrições de itens podem ser extraídas automaticamente (por exemplo, de documentos de texto). Dessa forma, utilizaremos a técnica de Filtragem Baseada em Conteúdo (FBC) para recomendação de itens (recursos), utilizada em sistemas de recomendação, onde ela lista itens com base na comparação entre o conteúdo/descrição de um conjunto de itens e o perfil de um dado usuário. E baseado no modelo do aluno, criado mediante suas interações no sistema, o seu desempenho será avaliado e com base nos níveis de interação, serão oferecidas recomendações de itens (recursos) que visem ajudar o aluno não somente de acordo com sua(s) preferências, mas com a(s) sua(s) necessidade(s). De modo que, serão recomendados itens (conteúdo, recursos) relacionados ao assunto que o aluno obteve um baixo percentual de desempenho pedagógico e/ou de interação.

Exemplo de situação percebida: o aluno 1 está com dificuldade no assunto de Introdução à Estatística, especificamente no tópico de Teorias e Conceitos. E foi percebido que dentre os diversos recursos oferecidos, ele interagiu com mais de 80% deles. Mas o seu desempenho quanto a resolução de questões não foi bom. Diante de situações como questões respondidas erradas ou que não foram respondidas, o sistema irá analisar os recursos que não foram utilizados ou que já foram vistos (à título de revisão) e eles serão recomendados para o aluno, afim de que possam ajudá-los na resolução das questões.

Exemplo de recomendação: olá aluno 1, vimos que seu nível de interação com os recursos do sistema foi bom, mas o seu desempenho pedagógico ficou abaixo do esperado (60%), contudo recomendamos que assista ao vídeo sobre Teorias e Conceitos, e leia o texto de conteúdo auxiliar, referente ao assunto, Introdução à estatística (Módulo 1), pois dessa forma, possivelmente você conseguirá responder às questões 3 e 4 que foram respondidas erradas.

6 RESULTADOS E DISCUSSÕES

A amostra (respondentes) utilizada para validar a pesquisa foi composta por professores, graduando e graduados dos cursos de graduação em ciências da computação, engenharia de software e pós-graduação da Universidade Federal de Alagoas - UFAL (2019), das quais foram contabilizadas 32 participações.

Analisando os dados obtidos do survey, podemos observar que em relação ao gênero dos participantes, 70% são do gênero masculino e 30% do feminino. 83% dos participantes informaram suas ocupações, onde, 72% são estudantes, 8% são professores, e 12% exercem outras atividades. 50% dos participantes estão cursando a graduação, 20% possuem a graduação completa, 16,7% possuem especialização, 10% possuem mestrado e 3,3% possuem doutorado. Quanto ao nível de conhecimento quanto ao uso de tecnologias, 60% informaram ter um conhecimento avançado, 36,7% nível moderado e 3,3% nível baixo. **Foi informado que 96,7% dos participantes já participou de algum curso online e apenas 3,7% não participou de nenhum curso online.** As tabelas abaixo ilustram os resultados obtidos das respostas fornecidas pelos participantes referente a cada cenário (a descrição dos cenários está na Seção 5.1.5, entenda-se cenários como: recomendações explicadas e não explicadas) lhes foram apresentados, onde para a resposta, foi utilizado uma escala baseada na escala likert, obedecendo as descrições: discordo completamente (DC), discordo (D), não concordo nem discordo (NCnD), concordo (C) e concordo completamente (CC).

Tabela 4 – A tabela mostra os dados referente a primeira recomendação, que foi sem explicação. Seguem os resultados:

#	Afirmações	DC	D	NCnD	C	CC
1	A recomendação oferecida a mim foi apropriada (justifica o problema descrito).	0%	16,7%	10%	60%	13,3%
2	O texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação.	23,3%	46,3%	10%	20%	0%
3	O texto da recomendação faz (motiva) com que eu siga tal recomendação.	6,7%	23,3%	36,7%	30%	3,3%
4	A recomendação está clara (sou capaz de entendê-la e saber o que devo fazer).	0%	0%	3,3%	63,3%	33,3%
5	Se eu fosse o aluno 8, eu seguiria essa recomendação.	0%	6,7%	16,7%	66,7%	10%
6	Acho importante que o sistema explique porque uma recomendação foi gerada.	0%	0%	3,3%	30%	66,7%

Diante das afirmações da tabela 4, chama-se atenção para os dados:

- Devido a recomendação 1 não oferecer nenhum tipo de explicação, percebe-se um baixo percentual (0%) de participantes, que afirmam que "concordam plenamente" que: "o texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação", e somente 20% "concordam" ou seja, o maior número de pessoas discordam dessa afirmação.
- Outro dado que chama atenção é o percentual de apenas 3,3% para pessoas que "concordam plenamente" com a afirmação "o texto da recomendação faz (motiva) com que eu siga tal recomendação", onde pode-se considerar uma aceitação de 33,3%.
- 76,7% das pessoas informaram que seguiriam tal recomendação, mas desse total apenas 10% concordam completamente com a afirmação.
- Uma ampla concordância (96,7%) de pessoas que acham importante que o sistema explique porque uma recomendação foi gerada.

Tabela 5 – A tabela mostra os dados referente a segunda recomendação, a qual foi explicada. Seguem os resultados:

#	Afirmações	DC	D	NCnD	C	CC
1	A recomendação oferecida a mim foi apropriada (justifica o problema descrito).	0%	13,3%	3,3%	53,3%	30%
2	O texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação.	0%	0%	0%	60%	40%
3	O texto da recomendação faz (motiva) com que eu siga tal recomendação.	3,3%	16,7%	10%	43,3%	26,7%
4	A recomendação está clara (sou capaz de entendê-la e saber o que devo fazer).	0%	3,3%	0%	60%	36,7%
5	Se eu fosse o aluno 8, eu seguiria essa recomendação.	0%	10%	10%	43,3%	36,7%
6	Acho importante que o sistema explique porque uma recomendação foi gerada.	0%	0%	0%	36,7%	63,3%

Com base nos resultados da recomendação 2, presentes na tabela 5, pode-se observar:

- Diante da recomendação explicada que foi oferecida, 83,3% dos participantes concordam que a recomendação oferecida foi apropriada e justifica o problema.

- 100% de concordância dos participantes, de que o texto explica o motivo da recomendação estar sendo oferecida.
- 70% Pessoas que afirmam que o texto da recomendação faz (motiva) com que a recomendação seja seguida. Nas recomendações explicadas, os participantes se sentiram mais motivados a seguir a recomendação (seguir = aceitar e concluir, ou seja, aderência) e afirmaram que seguiriam a recomendação.
- 80% afirmam que seguiriam tal recomendação.
- Diante de uma recomendação explicada, 100% dos participantes acham importante que o sistema explique porque uma recomendação foi gerada.

Tabela 6 – Nesta tabela estão as informações referente a terceira recomendação, que não tinha nenhuma explicação.

#	Afirmações	DC	D	NCnD	C	CC
1	A recomendação oferecida a mim foi apropriada (justifica o problema descrito).	6,7%	30%	13,3%	40%	10%
2	O texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação.	26,7%	46,7%	10%	16,7%	0%
3	O texto da recomendação faz (motiva) com que eu siga tal recomendação.	16,7%	23,3%	30%	23,3%	6,7%
4	A recomendação está clara (sou capaz de entendê-la e saber o que devo fazer).	3,3%	6,7%	23,3%	50%	16,7%
5	Se eu fosse o aluno 8, eu seguiria essa recomendação.	3,3%	23,3%	23,3%	43,3%	6,7%
6	Acho importante que o sistema explique porque uma recomendação foi gerada.	0%	0%	7%	26,3%	66,7%

De acordo com a tabela 6, observou-se que:

- 50% das pessoas concordam que o texto da recomendação está apropriado (justifica o problema descrito).
- Apenas 16% dos participantes acreditam que o texto da recomendação explica o motivo dela está sendo oferecida.

- 50% dos participantes afirma que seguiriam a recomendação, onde desse percentual apenas 6,7% concordaram completamente.
- 93% concordam que é importante que o sistema explique porque uma recomendação foi gerada.

Tabela 7 – A tabela abaixo ilustra a quarta recomendação que vem acompanhada de explicação, onde os seguintes resultados puderam ser observados.

#	Afirmações	DC	D	NCnD	C	CC
1	A recomendação oferecida a mim foi apropriada (justifica o problema descrito).	0%	3,3%	0%	50%	46,7%
2	O texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação.	0%	3,3%	0%	26,7%	70%
3	O texto da recomendação faz (motiva) com que eu siga tal recomendação.	6,7%	3,3%	6,7%	30%	53,3%
4	A recomendação está clara (sou capaz de entendê-la e saber o que devo fazer).	0%	0%	3,3%	30%	66,7%
5	Se eu fosse o aluno 8, eu seguiria essa recomendação.	0%	3,3%	10%	30%	56,7%
6	Acho importante que o sistema explique porque uma recomendação foi gerada.	0%	0%	0%	16,7%	83,3%

- 96,7% concordaram que o texto da recomendação está apropriado para o problema abordado.
- 96,7% concordaram que o texto da recomendação explica o motivo da recomendação está sendo oferecida.
- 83,3% concordam que o texto da recomendação faz com que a mesma seja seguida.
- 86,7% afirmam que seguiriam a recomendação.
- 100% concordam que é importante que o sistema explique porque uma recomendação foi gerada.

Visando fazer uma análise geral, foram elaborados dois gráficos (Figura 15 e 16) agrupando em recomendações explicadas e não explicadas em apenas dois cenários ou invés de quatro (somando os 2 cenários explicados, e posteriormente somando os não explicados), para que fosse possível visualizar onde estão localizadas as maiores concentrações de dados em relação a aceitação da recomendação.

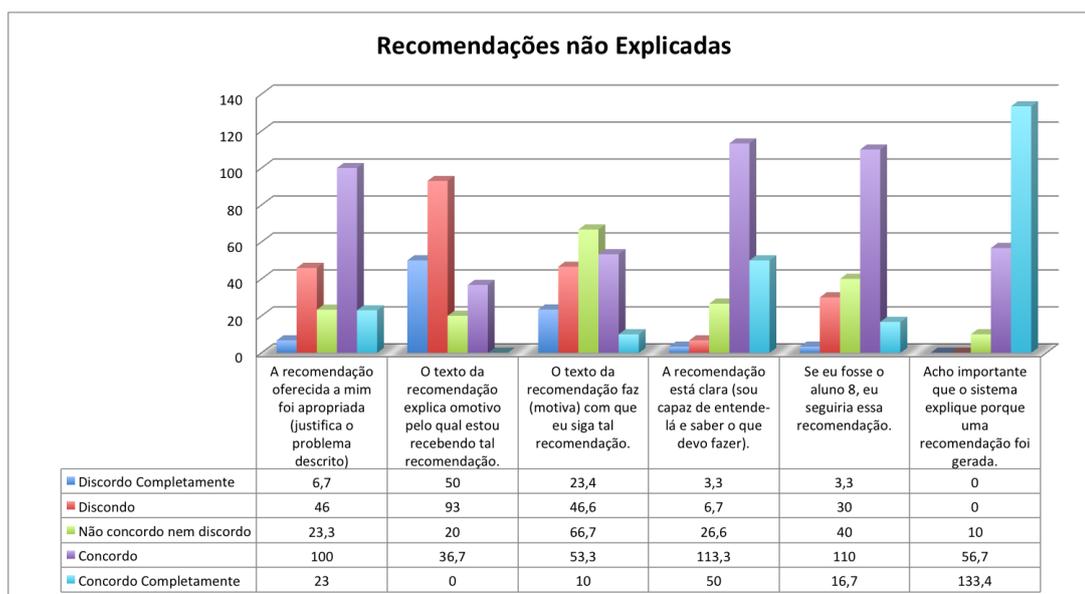


Figura 18 – Gráfico das recomendações não explicadas

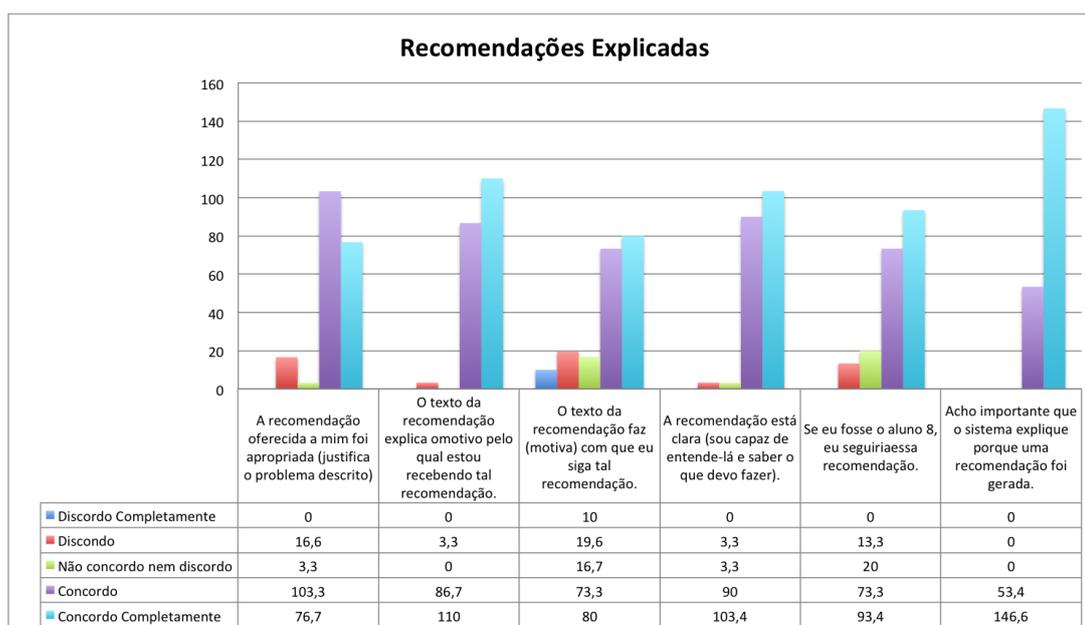


Figura 19 – Gráfico das recomendações explicadas

6.1 ANÁLISE DOS DADOS

Conforme informado acima, foram elaborados 4 (quatro) cenários, contendo recomendações com base no modelo do aluno, contextualizado abaixo.

O aluno 8, onde o mesmo obteve um baixo percentual de desempenho pedagógico (PDP), no assunto, VARIÂNCIA E DESVIO PADRÃO (tópico 3), do módulo MEDIDAS DE DISPERSÃO (módulo 3). Pois se observou que, das 4 questões que foram oferecidas pelo sistema o aluno respondeu apenas 3 das quais acertou 1 e errou 2, obtendo um PDP = 25%, onde o desempenho aceitável pelo sistema, é de no mínimo 60%.

- Dessa forma o sistema ofereceu a **primeira recomendação, não explicada (sem muitos detalhes)**, sendo ela: *"Olá aluno 8, tudo bem? Sugerimos que você reveja a apresentação da aula e responda às questões sobre VARIÂNCIA E DESVIO PADRÃO (contida no módulo MEDIDAS DE DISPERSÃO)."*
- **Segunda recomendação oferecida, contendo uma explicação.**
"Olá aluno 8, tudo bem? Observamos que seu desempenho não foi bom o suficiente no assunto VARIÂNCIA E DESVIO PADRÃO, desse modo, pedimos que por gentileza, assista ao vídeo sobre VARIÂNCIA E DESVIO PADRÃO (contido no módulo MEDIDAS DE DISPERSÃO) e acesse o link externo do assunto, como forma de revisão, para que possa melhorar seu desempenho na resolução das questões (tendo em vista que seu coeficiente de desempenho pedagógico foi apenas 25%), pois observou-se que das 4 questões oferecidas, três foram respondidas, onde e somente uma foi acertada!"
- **Terceira recomendação, oferecida sem nenhuma explicação.**
"Olá aluno 8, tudo bem? Pedimos por gentileza que leia o texto auxiliar, acesse o link externo, assista novamente ao vídeo sobre o assunto VARIÂNCIA E DESVIO PADRÃO (contido no módulo MEDIDAS DE DISPERSÃO) e responda às questões."
- **Quarta recomendação, feita de forma explicada.**
"Olá aluno 8, tudo bem? Observamos que seu desempenho de interação foi satisfatório (87.5%) e lhe parabenizamos por isso, pois vimos que utilizou quase todos os recursos disponibilizados pelo sistema, mas percebemos que o seu desempenho pedagógico (25%), quanto a resolução de questões não foi bom, no assunto, VARIÂNCIA E DESVIO PADRÃO. Sendo assim, pedimos por gentileza, que assista novamente ao vídeo sobre VARIÂNCIA E DESVIO PADRÃO (contido no módulo MEDIDAS DE DISPERSÃO) e reveja a apresenta-

ção da aula que contém exemplos bastante didáticos, que te ajudarão a resolver todas as questões.”

Dessa forma, para cada recomendação oferecida foram feitas algumas afirmações, para que pudéssemos coletar as opiniões dos usuários entrevistados no survey. Logo abaixo estão listadas as afirmações e os resultados obtidos.

6.2 TESTE DE NORMALIDADE POR CENÁRIO E AFIRMAÇÃO

Tabela 8 – Teste de Normalidade Shapiro Wilk.

Cenário	Afirmação 1	Afirmação 2	Afirmação 3	Afirmação 4	Afirmação 5	Afirmação 6
#1	W = 0.80951 p-value = 6.184e-05	W = 0.82284 p-value = 0.000113	W = 0.90581 p-value = 0.008736	W = 0.6996 p-value = 8.575e-07	W = 0.79571 p-value = 3.388e-05	W = 0.65358 p-value = 1.884e-07
#2	W = 0.76204 p-value = 8.515e-06	W = 0.62507 p-value = 7.836e-08	W = 0.84757 p-value = 0.0003676	W = 0.67437 p-value = 3.676e-07	W = 0.81722 p-value = 8.737e-05	W = 0.61488 p-value = 5.784e-08
#3	W = 0.86615 p-value = 0.0009477	W = 0.82003 p-value = 9.93e-05	W = 0.91516 p-value = 0.0154	W = 0.8547 p-value = 0.0005252	W = 0.86828 p-value = 0.00106	W = 0.66331 p-value = 2.568e-07
#4	W = 0.69727 p-value = 7.915e-07	W = 0.58953 p-value = 2.778e-08	W = 0.71585 p-value = 1.514e-06	W = 0.65358 p-value = 1.884e-07	W = 0.74357 p-value = 4.178e-06	W = 0.47763 p-value = 1.487e-09

Diante do teste de normalidade feito com o método Shapiro Wilk, observamos que todos os p-valores são inferiores a 0.05, indicando que os dados são oriundos de uma população de dados não paramétricos, ou seja, são de distribuições não normais, e por esse motivo foi necessário aplicar o método de Wilcoxon para comparar as performances de cada cenário (pares de cenários) no sentido de verificar se existem diferenças significativas entre os seus resultados nas duas situações. Estas diferenças são ordenadas em função da sua grandeza (independentemente do sinal positivo ou negativo). O ordenamento assim obtido é depois apresentado separadamente para os resultados positivos e negativos. O menor dos valores deste segundo, dá-lhe o valor de uma “estatística” designada por W. Dado que a estatística W reflete o menor total de ordens, quanto menor for o W mais significativas serão as diferenças nas ordenações entre às duas situações.

Visando os objetivos da pesquisa, que é criar recomendações personalizadas de forma automática com base no modelo do aluno, e principalmente, analisar se a explicação causa impacto na aceitação da recomendação. Foram feitas comparações entre todos os cenários, referindo-se a mesma afirmação, para que pudéssemos avaliar cada afirmação individualmente. Dessa forma, foi oferecido um survey contendo 4 cenários para que os participantes avaliassem e respondessem, classificando (escala likert) cada afirmação que era fornecida. As recomendações

foram ofertadas de forma alternada, onde a primeira recomendação foi entregue sem nenhuma explicação, a segunda foi entregue acompanhada de uma explicação, em seguida a terceira sem explicação e a última com explicação.

6.3 AFIRMAÇÃO 1 - A RECOMENDAÇÃO OFERECIDA A MIM FOI APROPRIADA (JUSTIFICA O PROBLEMA DESCRITO).

Diante dessa afirmação, os dados obtidos foram:

Com base em todos os cenários existentes, estão listadas as informações (mínimo, máximo, média, mediana e desvio padrão) referentes a **afirmação 1**.

Cenários	Recomendação	Min	Max	Mean	Median	Sd
1	Sem Explicação	2	5	3.71875	4	0.9240296
2	Com Explicação	2	5	4.03125	4	0.9327163
3	Sem Explicação	1	5	3.21875	4	1.156591
4	Com Explicação	2	5	4.34375	4	0.7873752

Tabela 9 – Análise descritiva - Afirmação 1

Visando avaliar a significância estatística utilizamos o teste de Wilcoxon, para comparar a mesma afirmação dentre os diversos cenários que foram disponibilizados.

Afirmação 1	Cenário 1	Cenário 2	Cenário 3	Cenário 4
Cenário 1	-	0,1946	0.009032	0.00767
Cenário 2	-	-	0.01538	0.1622
Cenário 3	-	-	-	0.0002763

Tabela 10 – p-valor afirmação 1

Os resultados que se referem à primeira afirmação, onde a afirmativa diz que: “A recomendação oferecida a mim, foi apropriada (justifica o problema descrito)”, mostram que não há uma diferença entre os cenários 1 e 2, o que contrária a nossa expectativa, pois como os cenários são distintos, acreditávamos que o cenário 2 por ser explicado, teria uma maior relevância, mas pode-se ver que mesmo assim a média e mediana, conforme a tabela 9, são maiores que o cenário 1 (não explicado), diante disso, acreditamos que, como os participantes iniciaram a pesquisa por uma recomendação sem explicação (cenário 1), e posteriormente uma recomendação explicada,

e assim sucessivamente (de forma alternada) até o quarto cenário (último), os participantes começaram a ficar mais exigentes, e os índices de significância foram melhorando.

Vale ressaltar que, as recomendações foram criadas para serem de boa qualidade, e talvez por isso elas foram consideradas apropriadas em ambos os casos, mesmo nos cenários com a ausência da explicação. Podemos considerar que as recomendações oferecidas foram apropriadas, mas com uma boa percepção de melhoria avaliativa a partir do cenário 3, conforme mostram as tabelas 4, 5, 6 e 7 onde inicialmente há um alto percentual (cenário 1 = 73,3% concordam que a recomendação foi apropriada, mesmo sem explicação), que vai se moldando à medida que o participante percebe o fator explicativo presente ou ausente nos cenários. Como no caso comparativo entre os cenários 1 e 3 que apesar de serem cenários iguais (não explicados), o usuário ainda não sabia o que viria pela frente ao se deparar com o cenário 1 e isso gerou impacto. Nos casos 1 e 4, 2 e 3, 3 e 4 ocorreu o que esperávamos (cenários diferentes) houve relevância. Observamos que não houve diferença significativa entre os cenários 2 e 4 (dois cenários com explicação).

6.4 **AFIRMAÇÃO 2** - O TEXTO DA RECOMENDAÇÃO EXPLICA O MOTIVO PELO QUAL ESTOU RECEBENDO TAL RECOMENDAÇÃO.

Os resultados obtidos para a segunda afirmação foram:

Diante de todos os cenários existentes, estão listadas as informações (mínimo, máximo, média, mediana e desvio padrão) referentes a **afirmação 2**.

Cenários	Recomendação	Min	Max	Mean	Median	Sd
1	Sem Explicação	1	4	2.28125	2	1.084625
2	Com Explicação	4	5	4.40625	4	0.4989909
3	Sem Explicação	1	4	2.1875	2	1.06066
4	Com Explicação	2	5	4.625	5	0.659912

Tabela 11 – Análise descritiva - Afirmação 2

Teste de Wilcoxon para avaliar o comparativo da afirmação 2 entre os cenários.

Afirmção 2	Cenário 1	Cenário 2	Cenário 3	Cenário 4
Cenário 1	-	1.945e-06	0.766	3.558e-06
Cenário 2	-	-	3.313e-06	0.06371
Cenário 3	-	-	-	2.073e-06

Tabela 12 – p-valor afirmação 2

Referente a segunda afirmação (O texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação.), vimos que ao comparar a mesma afirmação em cenários distintos (Explicado X Não explicados), gerou uma diferença estatisticamente relevante, onde o p-valor foi $p < 0,05$. Ainda observando os dados da Tabela 11, podemos ver que, tanto a média quanto a mediana são maiores nos casos em que as recomendações são explicadas. O que gera um forte indício de que a explicação realmente faz com que o usuário entenda o motivo dele está recebendo determinada recomendação, fornecendo uma relação de transparência (que coincide com a nossa expectativa). Podemos observar analisando as Tabelas 4, 5, 6 e 7 que os percentuais também foram dentro do esperado, pois os cenários 2 e 4 (explicados) obtiveram os respectivos índices 100% e 96,7% em relação aos cenários 1 e 3 (não explicados) cujos índices percentuais foram respectivamente 20% e 16,7% de concordância com a afirmativa. Observamos que no cenário 3 (não explicado) apenas 16% dos participantes acreditam que o texto da recomendação explica o motivo dela está sendo oferecida, essa dado reforça o ponto de que a explicação motiva e promove a aderência à recomendação.

6.5 AFIRMAÇÃO 3 - O TEXTO DA RECOMENDAÇÃO FAZ (MOTIVA) COM QUE EU SIGA TAL RECOMENDAÇÃO.

Diante de todos os cenários existentes, estão listadas as informações (mínimo, máximo, média, mediana e desvio padrão) referentes a **afirmação 3**.

Cenários	Recomendação	Min	Max	Mean	Median	Sd
1	Sem Explicação	1	5	2.96875	3	0.9666829
2	Com Explicação	1	5	3.6875	4	1.148281
3	Sem Explicação	1	5	2.84375	3	1.167003
4	Com Explicação	1	5	4.1875	4.5	1.119836

Tabela 13 – Análise descritiva - Afirmação 3

Teste de Wilcoxon para avaliar o comparativo da afirmação 3 entre os cenários.

Afirmação 3	Cenário 1	Cenário 2	Cenário 3	Cenário 4
Cenário 1	-	0.001575	0.5609	0.0004368
Cenário 2	-	-	0.01121	0.008123
Cenário 3	-	-	-	0.0008265

Tabela 14 – p-valor - afirmação 3

Diante da afirmação 3 que diz: “O texto da recomendação faz (motiva) com que eu siga tal recomendação.”, ao comparar os resultados de todos os cenários, vimos que a comparação em cenários diferentes, mostrou p-valor < 0.05 , ou seja, houve significância estatística, concordando com a nossa expectativa, que seria a percepção do usuário em relação ao texto, diferenciando-os. Já nos cenários iguais (que comparavam cenários: Explicado X Explicado e Não explicado X Não explicado), o resultado dos cenários não explicados foram condizentes com a nossa expectativa, ou seja, que não houvesse diferença estatística significativa (p-valor > 0.05). Mas nos cruzamentos dos cenários explicados (cenários 2 e 4), vimos que houve uma diferença significativa, onde acreditávamos que não haveria. Diante disso, acreditamos que os participantes devem ter percebido que a recomendação do cenário 4 foi melhor elaborada, continha um nível maior de explicação e detalhamento em relação à recomendação do cenário 2. Ainda assim a média e mediana dos cenários explicados 2 e 4, foram respectivamente média = 3.6875, mediana = 4 e média = 4.1875, mediana = 4.5 são maiores que os cenários 1 e 3, onde a média e mediana foram respectivamente média = 2.96875 e mediana = 3, média = 2.84375 e mediana = 3, o que mostra uma melhor aceitação dos cenários explicados, onde de toda forma os resultados para a afirmativa 3 foram satisfatórios. Observando as tabelas 4, 5, 6 e 7 o fato do participante desconhecer os cenários futuros e receber o primeiro cenário sem nenhuma explicação, fez com que o resultado do primeiro cenário (33,3%) fosse mais alto que o terceiro cenário (30%) que também era sem explicação, mas a partir do segundo cenário em diante pudemos observar uma consonância com nossa expectativa.

6.6 AFIRMAÇÃO 4 - A RECOMENDAÇÃO ESTÁ CLARA (SOU CAPAZ DE ENTENDER E SABER O QUE DEVO FAZER).

Diante de todos os cenários existentes, estão listadas as informações (mínimo, máximo, média, mediana e desvio padrão) referentes a **afirmação 4**.

Cenários	Recomendação	Min	Max	Mean	Median	Sd
1	Sem Explicação	3	5	4.3125	4	0.535061
2	Com Explicação	2	5	4.28125	4	0.6342064
3	Sem Explicação	1	5	3.75	4	0.9503819
4	Com Explicação	3	5	4.625	5	0.5535807

Tabela 15 – Análise descritiva - Afirmação 4

Teste de Wilcoxon para avaliar o comparativo da afirmação 4 entre os cenários.

Afirmação 4	Cenário 1	Cenário 2	Cenário 3	Cenário 4
Cenário 1	-	0.8353	0.001443	0.01383
Cenário 2	-	-	0.0128	0.008457
Cenário 3	-	-	-	0.0001645

Tabela 16 – p-valor - afirmação 4

A afirmação 4 que traz a seguinte afirmativa: “A recomendação está clara (Sou capaz de entendê-la e saber o que devo fazer).”, mostrou que, não houve uma diferença estatística significativa na comparação referente aos cenários 1 (não explicado) e 2 (explicado), pois acreditamos que devido o usuário receber inicialmente uma recomendação não explicada (cenário 1) ele a considerou clara, pelo fato de ainda desconhecer os cenários futuros, e que ao se deparar com a explicação (cenário 2) viu que também era boa. No comparativo entre os cenários 1 e 3 (não explicados), o resultado obtido foi significativo, o que esperávamos que não fosse, pelo fato de serem cenários com as mesmas características e com conteúdo sem muitos detalhes, mas mesmo assim, os usuários foram capazes de entender a recomendação, podendo ser devido ao mesmo fato explicado acima, onde o cenário 1 por ser o primeiro a ser apresentado obteve uma boa avaliação, mesmo com a ausência de elementos explicativos, o que foi percebido posteriormente pelos usuários, e melhor avaliado (também percebido conforme tabelas 4, 5, 6 e 7), ao ver na sequência uma recomendação explicada, outra não explicada e por fim, uma explicada. Na comparação feita entre os cenários 1 e 4; 2 e 3; 3 e 4, houve diferença estatisticamente relevante, pois o p-valor foi $p < 0.05$. O usuário preferiu as recomendações explicadas, o que foi concordante com a nossa expectativa. Já na avaliação dos cenários 2 e 4, que acreditávamos não haver diferença significativa, pela similaridade contextual, houve uma relevância, o que consideramos normal, pois os participantes devem ter percebido que a recomendação do cenário 4 tinha mais detalhes em relação ao cenário 2.

6.7 AFIRMAÇÃO 5 - SE EU FOSSE O ALUNO 8, EU SEGUIRIA ESSA RECOMENDAÇÃO.

Diante de todos os cenários existentes, estão listadas as informações (mínimo, máximo, média, mediana e desvio padrão) referentes a **afirmação 5**.

Cenários	Recomendação	Min	Max	Mean	Median	Sd
1	Sem Explicação	2	5	3.75	4	0.7184212
2	Com Explicação	2	5	4.0625	4	0.9482582
3	Sem Explicação	1	5	3.34375	4	0.9708452
4	Com Explicação	2	5	4.375	5	0.8327955

Tabela 17 – Análise descritiva - Afirmação 5

Teste de Wilcoxon para avaliar o comparativo da afirmação 5 entre os cenários.

Afirmação 5	Cenário 1	Cenário 2	Cenário 3	Cenário 4
Cenário 1	-	0.08759	0.007762	0.001627
Cenário 2	-	-	0.005874	0.0495
Cenário 3	-	-	-	0.0003657

Tabela 18 – p-valor - afirmação 5

Quanto a afirmação 5 que afirma: “Se eu fosse o aluno 8, eu seguiria essa recomendação.”, vimos que nas comparações feitas nos cenários: 1 e 4, 2 e 3, 3 e 4 foram significativamente relevantes pois o p-valor obtido foi $p < 0.05$ e isso coincidiu com a nossa expectativa, que versava haver diferença significativa na comparação entre cenários diferentes, onde os cenários com explicação obteriam um melhor desempenho em relação aos cenários sem explicação. E isso foi percebido pelos usuários. A comparação feita nos cenários 1 e 2, segue o mesmo resultado que foi observado e relatado anteriormente, pois conforme a tabela 4, podemos ver que 76,7% dos participantes informaram que seguiriam tal recomendação (que era sem nenhuma explicação), e os percentuais foram mudando com o decorrer do experimento. Comparando os cenários 1 e 3, vimos que houve uma diferença significativa, o que não era esperado por nós, pois acreditávamos que não houvesse nenhuma diferença, pois os cenários são similares. No entanto, alguns usuários seguiriam de diferente modo o cenário 3, talvez por achar a recomendação mais completa em relação a do cenário 1. O mesmo ocorreu com os cenários 2 e 4, que mesmo sendo similares, gerou uma diferença significante, o que acatamos ser em relação à desenvoltura do texto da

recomendação (como dito nos tópicos acima). Observamos que 86,7% afirma que seguiriam a recomendação.

6.8 AFIRMAÇÃO 6 - ACHO IMPORTANTE QUE O SISTEMA EXPLIQUE PORQUE UMA RECOMENDAÇÃO FOI GERADA.

Diante de todos os cenários existentes, estão listadas as informações (mínimo, máximo, média, mediana e desvio padrão) referentes a **afirmação 6**.

Cenários	Afirmações	Min	Max	Mean	Median	Sd
1	Sem Explicação	3	5	4.625	5	0.5535807
2	Com Explicação	4	5	4.625	5	0.4918694
3	Sem Explicação	3	5	4.59375	5	0.6148367
4	Com Explicação	4	5	4.8125	5	0.3965578

Tabela 19 – Análise descritiva - Afirmativa 6

Teste de Wilcoxon para avaliar o comparativo da afirmação 5 entre os cenários.

Afirmação 6	Cenário 1	Cenário 2	Cenário 3	Cenário 4
Cenário 1	-	1	0.8211	0.09534
Cenário 2	-	-	0.8241	0.04108
Cenário 3	-	-	-	0.02627

Tabela 20 – p-valor - afirmação 6

A afirmação 6: “Acho importante que o sistema explique porque uma recomendação foi gerada.”, nossa expectativa era que independente do tipo de cenário (Explicado ou Não explicado), não haveria diferença estatística significativa, onde era esperado um p-valor > 0.05. E houve uma concordância, observando os resultados obtidos, onde não houve diferença estatística significativa na maioria dos casos. Em apenas dois casos, os resultados foram significantes com p-valor < 0.05, que foram as comparações dos cenários 2 e 4; e 3 e 4, onde no primeiro caso (2,4) pelo fato de ambas as recomendações apresentarem explicações o usuário achou que já estava suficiente o bastante, mas não descartando a sua importância, quando se observa as análises anteriores (média e mediana conforme a Tabela 19). No segundo caso (3,4), acreditamos que a significância foi gerada justamente pelo fato do usuário entender melhor o cenário 4 (explicado) devido ao maior nível de detalhe em relação da recomendação do cenário 3 (não explicado), onde

nesse caso o usuário pode ter considerado que a afirmativa se referia a questão vigente e não ao contexto geral, o qual de fato era a situação avaliada. Observou-se que apesar de as medianas serem iguais em todos os casos, os cenários 1 e 2 possuem médias iguais, no terceiro cenário (não explicado) houve uma diminuição na média em relação ao primeiro também não explicado, mas no quarto caso ocorreu um aumento na média, que por sinal foi a maior dos 4 cenários, o que evidencia o fato de que o participante avaliou a afirmativa relacionada ao cenário e não ao contexto geral. Analisando os resultados de forma isolada conforme as Tabelas 4,5,6, e 7, ou seja, sem fazer comparações com outros cenários, essa afirmativa obteve uma avaliação bastante positiva, onde em cada caso, mais de 90% dos participantes concordaram que é importante que o sistema explique porque uma recomendação foi gerada.

7 CONCLUSÃO

Para tratar esse problema quanto a aceitação da recomendação, nós criamos recomendações explicadas (explicando literalmente as explicações), e para isso criamos um modelo dos alunos, com base nas interações dos alunos com os recursos educacionais do sistema como um todo (vídeos, textos, links externos, aulas e o desempenho do aluno que se baseia nas questões resolvidas, questões certas e questões disponíveis para um determinado assunto). Com base nisso, nós analisamos o desempenho e as interações do aluno e fizemos propostas de recomendação, baseando-se no que ele fez e acertou, no que ele não fez e no que ele fez e errou. Com isso, propomos uma forma automatizada baseada no modelo do aluno, de identificar os pontos que o aluno precisa de melhoria e de acordo com o que ele interagiu/não interagiu/interagiu e não foi bem-sucedido, enviar juntamente com as recomendações, explicações do motivo dele está recebendo aquela recomendação.

Para avaliarmos a nossa proposta, criamos um curso de introdução à estatística descritiva, simulamos interações de 30 alunos com os recursos deste curso (vídeos, textos, aulas, links, questões), ou seja, foi a simulação de 30 alunos utilizando o curso. Desses 30 alunos, selecionamos aleatoriamente 4 alunos, criamos um modelo desses alunos, identificamos a deficiência e fizemos recomendações para o aluno. Duas dessas recomendações não tinham explicação, elas simplesmente solicitavam que o aluno fizesse alguma coisa. E outras duas recomendações que tinham uma explicação. Sendo assim, criamos um survey, buscando saber se as recomendações que foram feitas estavam apropriadas, se o texto da recomendação explica o motivo da recomendação está sendo enviada, se o texto da recomendação faz (motiva) com que a recomendação seja seguida, se a recomendação está clara, se eu seguiria a recomendação apresentada, se é importante que os sistemas expliquem porque uma recomendação foi gerada. O survey foi respondido por 32 pessoas, dentre elas professores, graduandos e graduados. O nosso público alvo foi pessoas que já realizaram algum tipo de curso online.

Analisando o feedback dos participantes através do survey, os resultados mostraram uma diferença significativa para todas as questões. Onde pudemos ver individualmente que os cenários que não forneciam explicação, tiveram um baixo percentual quando comparados aos cenários que ofereciam explicações. O primeiro cenário apresentado no survey trazia uma recomendação não explicada e as respostas dos participantes foram boas, o que esperávamos fosse, pois, a primeira recomendação avaliava somente a recomendação, e com isso queríamos mostrar imparcialidade e que todas as recomendações tinham qualidade, independente de explicação

ou não. Ao responderem o segundo cenário (explicado), percebemos que os resultados também foram bons, e os participantes já começaram a ver que havia algo a mais na recomendação, que não estava presente no primeiro cenário, mas como todas as recomendações foram criadas para serem boas, consideramos o fato como positivo. Ao se depararem com o terceiro cenário (sem explicação) os percentuais caíram, ficando mais do que o cenário 1, pois os participantes começaram a ficar mais exigentes, pois perceberam que estava faltando algo que justificasse (explicação), as mesmo assim o índice foi favorável. E por fim na quarta e última recomendação os resultados foram satisfatórios em relação a todos os cenários. Os resultados ficaram da seguinte forma: cenário 1 (não explicado) um pouco menor do que o cenário 2 (explicado), cenário 2 melhor que cenário 3 (não explicado), cenário 3 menor que cenário 1, 2 e 4 (explicado). Quanto a teste estatístico, utilizamos wilcoxon pareado, comparando cada questão entre os diversos cenários, realizando um teste fatorial, cujos resultados foram relevantes na maioria dos casos, onde $p < 0,05$.

Diante disso, concluímos que, a recomendação explicada é melhor que a recomendação não explicada, e as pessoas veem uma ênfase muito grande na explicação da recomendação. Percebesse que a explicação de recomendação é desejada, as pessoas percebem ela como importante, e a compreensão da recomendação foi melhor quando estava acompanhada da explicação.

7.1 LIMITAÇÕES

A primeira limitação é que apesar de os dados serem simulados possíveis e plausíveis, nós não conseguimos trabalhar com alunos reais, devido à interface da plataforma desenvolvida ter apresentado instabilidade e os resultados poderiam ser confundidos com algum problema ou dificuldades de interação dos alunos com o sistema. Por este motivo preferimos simular os dados.

Uma outra limitação está em analisar o fator “seguir”, ou seja, se o aluno de fato seguiu ou não a recomendação, para assim validar a aderência por completo. Isto não foi possível, pois não utilizamos pessoas reais para a coleta de dados.

Uma ameaça quanto a validade, está relacionada ao fato dos dados simulados mostrarem uma interação não natural, e para dirimir esse problema, foram criamos 30 personas que mostram situações possíveis, o que pode-se dizer que é um tamanho de amostra baixo, mas considerado o mínimo preconizado pela estatística, mas que ainda assim é um número baixo dada a quantidade de alunos que podem existir em um ambiente online de aprendizagem (que pode ser muito

superior a esse valor). Visando diminuir a aparição de um cenário incomum. Como a avaliação foi um survey, nos colhemos opiniões, e nem sempre as ações realizadas pelas pessoas são as que foram relatadas (opinadas), pois há uma diferença entre uma pessoa manifestar sua opinião e de agir. Podendo haver uma discrepância entre a ação e a opinião.

Outra ameaça considerada, foi a sequência das recomendações que foram fixas, iniciando por uma recomendação sem explicação, seguida por uma explicada, outra não explicada e a última explicada.

O que também pode ser considerada uma ameaça é o usuário poder ter percebido o objeto a ser avaliado (explicações da recomendação), devido à segunda afirmação “O texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação.” e isso ter influenciado no resultado obtido.

O fato de estarmos trabalhando com percepção, pode ser uma ameaça, pois não se sabe se de fato ela se tornará uma realidade e isso só pode ser medido em um ambiente ecológico com pessoas reais.

7.2 TRABALHOS FUTUROS

Diante das limitações apresentadas, pretendemos realizar as seguintes atividades em trabalhos futuros.

- Aprimorar a plataforma para que possamos utilizar pessoas reais para coletar os dados.
- Pretendemos avaliar a forma do usuário afetar o próprio modelo, de modo que futuramente o mesmo seja aberto.
- Com a utilização de pessoas reais, avaliaremos a aderência por completo.

REFERÊNCIAS

- ABDOLLAHI, B.; NASRAOUI, O. Transparency in fair machine learning: the case of explainable recommender systems. In: **Human and Machine Learning**. [S.l.]: Springer, 2018. p. 21–35.
- ABRAHAM, A. Rule-based expert systems. **Handbook of measuring system design**, Wiley Online Library, 2005.
- ALAWAR, M. W.; NASER, S. S. A. Css-tutor: An intelligent tutoring system for css and html. **International Journal of Academic Research and Development**, v. 2, n. 1, p. 94–98, 2017.
- ALKHATLAN, A.; KALITA, J. Intelligent tutoring systems: A comprehensive historical survey with recent developments. **arXiv preprint arXiv:1812.09628**, 2018.
- ALLY, M. Foundations of educational theory for online learning. **Theory and practice of online learning**, v. 2, p. 15–44, 2004.
- ALMEIDA, M. E. B. de. Educação a distância na internet: abordagens e contribuições dos ambientes digitais de aprendizagem. **Educação e pesquisa**, SciELO Brasil, v. 29, n. 2, p. 327–340, 2003.
- ALVES, L. Educação a distância: conceitos e história no brasil e no mundo. **Revista Brasileira de Aprendizagem Aberta e a Distância**, v. 10, 2011.
- ANDERSON, J. R. **The architecture of cognition**. [S.l.]: Psychology Press, 2013.
- BENSON, A. D. Using online learning to meet workforce demand: A case study of stakeholder influence. **Quarterly review of distance education**, v. 3, n. 4, p. 443–52, 2002.
- BERKOVSKY, S.; TAIB, R.; CONWAY, D. How to recommend?: User trust factors in movie recommender systems. In: ACM. **Proceedings of the 22nd International Conference on Intelligent User Interfaces**. [S.l.], 2017. p. 287–300.
- BILGIC, M.; MOONEY, R. J. Explaining recommendations: Satisfaction vs. promotion. In: **Beyond Personalization Workshop, IUI**. [S.l.: s.n.], 2005. v. 5, p. 153.
- BREESE, J. S.; HECKERMAN, D.; KADIE, C. Empirical analysis of predictive algorithms for collaborative filtering. In: MORGAN KAUFMANN PUBLISHERS INC. **Proceedings of the Fourteenth conference on Uncertainty in artificial intelligence**. [S.l.], 1998. p. 43–52.
- BULL, S. Supporting learning with open learner models. **Planning**, v. 29, n. 14, p. 1, 2004.
- BULL, S.; KAY, J. Categorisation and educational benefits of open learner models. Citeseer, 2009.
- BURKE, R. Hybrid recommender systems: Survey and experiments. **User modeling and user-adapted interaction**, Springer, v. 12, n. 4, p. 331–370, 2002.
- CARLINER, S. **An overview of online learning**. [S.l.]: Human Resource Development, 2004.
- CAZELLA, S. C.; NUNES, M.; REATEGUI, E. A ciência da opinião: Estado da arte em sistemas de recomendação. **André Ponce de Leon F. de Carvalho; Tomasz Kowaltowski..(Org.). Jornada de Atualização de Informática-JAI**, p. 161–216, 2010.

- CHEN, A. Y.-A.; MCLEOD, D. Collaborative filtering for information recommendation systems. In: **Encyclopedia of E-Commerce, E-Government, and Mobile Commerce**. [S.l.]: IGI Global, 2006. p. 118–123.
- CLEGER, S.; FERNÁNDEZ-LUNA, J. M.; HUETE, J. F. Learning from explanations in recommender systems. **Information Sciences**, Elsevier, v. 287, p. 90–108, 2014.
- DIAS, R. A.; LEITE, L. S. **Educação a distância: da legislação ao pedagógico**. [S.l.]: Vozes, 2010.
- FELFERNIG, A.; FRIEDRICH, G.; JANNACH, D.; ZANKER, M. An integrated environment for the development of knowledge-based recommender applications. **International Journal of Electronic Commerce**, Taylor & Francis, v. 11, n. 2, p. 11–34, 2006.
- FISCHER, G. User modeling in human–computer interaction. **User modeling and user-adapted interaction**, Springer, v. 11, n. 1-2, p. 65–86, 2001.
- FONSECA, J. Metodologia da pesquisa científica. fortaleza: Uec, 2002. apostila. **SILVEIRA, DT; CÓRDOVA, FP A pesquisa científica. Cap**, v. 2, p. 31–42, 2016.
- FOWLER, D. G. A model for designing intelligent tutoring systems. **Journal of medical systems**, Springer, v. 15, n. 1, p. 47–63, 1991.
- FRANÇA, R. M.; SANTOS, H. F. d. A. C.; JÚNIOR, C.; GARCIA, P. T.; SANTOS, G. C. d.; PINHO, J. R. O.; REIS, R. S.; OLIVEIRA, A. E. F. d.; SILVA, E. G. d. S.; FERREIRA, E. B. et al. Conceitos da educação a distância (ead): Ambiente virtual de aprendizagem. <https://ares.unasus.gov.br/acervo/handle/ARES/1160>, 2013.
- FRIEDRICH, G.; ZANKER, M. A taxonomy for generating explanations in recommender systems. **AI Magazine**, v. 32, n. 3, p. 90–98, 2011.
- GEDIKLI, F.; JANNACH, D.; GE, M. How should i explain? a comparison of different explanation types for recommender systems. **International Journal of Human-Computer Studies**, Elsevier, v. 72, n. 4, p. 367–382, 2014.
- GIL, A. C. Como elaborar projetos de pesquisa. 4. ed. são paulo, sp: Atlas. 2007.
- GUNNING, D. Explainable artificial intelligence (xai). **Defense Advanced Research Projects Agency (DARPA), nd Web**, 2017.
- HEMPEL, C. G.; OPPENHEIM, P. Studies in the logic of explanation. **Philosophy of science**, Williams and Wilkins Co., v. 15, n. 2, p. 135–175, 1948.
- HERLOCKER, J. L.; KONSTAN, J. A.; RIEDL, J. Explaining collaborative filtering recommendations. In: ACM. **Proceedings of the 2000 ACM conference on Computer supported cooperative work**. [S.l.], 2000. p. 241–250.
- HILTZ, S. R.; TUROFF, M. Education goes digital: The evolution of online learning and the revolution in higher education. **Commun. ACM**, ACM, New York, NY, USA, v. 48, n. 10, p. 59–64, out. 2005. ISSN 0001-0782. Disponível em: <<http://doi.acm.org/10.1145/1089107.1089139>>.
- JANNACH, D.; ZANKER, M.; FELFERNIG, A.; FRIEDRICH, G. **Recommender systems: an introduction**. [S.l.]: Cambridge University Press, 2010.

- KARGA, S.; SATRATZEMI, M. Using explanations for recommender systems in learning design settings to enhance teachers' acceptance and perceived experience. **Education and Information Technologies**, Springer, p. 1–22, 2019.
- KAY, J.; HALIN, Z.; OTTOMANN, T.; RAZAK, Z. Learner know thyself: Student models to give learner control and responsibility. In: **Proceedings of International Conference on Computers in Education**. [S.l.: s.n.], 1997. p. 17–24.
- KHAN, B. H. Web-based instruction (wbi): an introduction. **Educational Media International**, Taylor & Francis, v. 35, n. 2, p. 63–71, 1998.
- KHAN, B. H. A framework for web-based learning. **Spring US**, Techtrends, v. 3, n. 7, p. 44:51, 2000.
- KOUKI, P.; SCHAFFER, J.; PUJARA, J.; O'DONOVAN, J.; GETOOR, L. Personalized explanations for hybrid recommender systems. In: **ACM. Proceedings of the 24th International Conference on Intelligent User Interfaces**. [S.l.], 2019. p. 379–390.
- LAGUARDIA, J.; PORTELA, M. C.; VASCONCELLOS, M. M. Avaliação em ambientes virtuais de aprendizagem. **Educação e pesquisa**, SciELO Brasil, v. 33, n. 3, p. 513–530, 2007.
- MELLAR, H.; BLISS, J. Introduction: modelling and education. In: . [S.l.]: Falmer Press, 1994.
- MOORE, M. G. **Three types of interaction**. [S.l.]: Taylor & Francis, 1989.
- NIELSEN, J.; MOLICH, R. Heuristic evaluation of user interfaces. In: **ACM. Proceedings of the SIGCHI conference on Human factors in computing systems**. [S.l.], 1990. p. 249–256.
- NUNES, I. B. Noções de educação a distância. **Revista educação à distância**, v. 4, n. 5, p. 7–25, 1993.
- PUTNAM, V.; CONATI, C. Exploring the need for explainable artificial intelligence (xai) in intelligent tutoring systems (its). In: **IUI Workshops**. [S.l.: s.n.], 2019.
- RESNICK, P.; VARIAN, H. R. Recommender systems. **Communications of the ACM**, ACM, v. 40, n. 3, p. 56–58, 1997.
- RODRIGUES, R.; FERRACIOLI, L. A utilização da modelagem computacional qualitativa no estudo do sistema gás-recipiente: Uma análise da construção de regras através da metodologia dos passos de construção de modelos (pcms). **EPEF**, X, 2006.
- SANTOS, K. Modelciências: Características do desenvolvimento de um portal para o projeto modelagem computacional semiquantitativa e quantitativa na educação em ciências do plano sul de pesquisa e pós-graduação do cnpq. **Anais IV Seminário sobre Representações e Modelagem no Processo de Ensino-Aprendizagem: Perspectivas da Modelagem em Educação em Ciências e Tecnologia para a Formação de Professores através do Ensino à Distância**, p. 123–147, 2002.
- SANTOS, R.; MENEZES, C. de; CURY, D. Uma arquitetura de tutor inteligente que provê suporte ao diálogo com o aluno iniciante em linguagem de programação. In: **Anais dos Workshops do Congresso Brasileiro de Informática na Educação**. [S.l.: s.n.], 2018. v. 7, n. 1, p. 768.

- SARRAFZADEH, A.; ALEXANDER, S.; DADGOSTAR, F.; FAN, C.; BIGDELI, A. “how do you know that i don’t understand?” a look at the future of intelligent tutoring systems. **Computers in Human Behavior**, Elsevier, v. 24, n. 4, p. 1342–1363, 2008.
- SCHNABEL, T.; BENNETT, P. N.; JOACHIMS, T. Improving recommender systems beyond the algorithm. **arXiv preprint arXiv:1802.07578**, 2018.
- SINHA, R.; SWEARINGEN, K. The role of transparency in recommender systems. In: ACM. **CHI’02 extended abstracts on Human factors in computing systems**. [S.l.], 2002. p. 830–831.
- TANG, T.; MCCALLA, G. Beyond learners’ interest: personalized paper recommendation based on their pedagogical features for an e-learning system. In: SPRINGER. **Pacific Rim International Conference on Artificial Intelligence**. [S.l.], 2004. p. 301–310.
- TINTAREV, N.; MASTHOFF, J. A survey of explanations in recommender systems. In: IEEE. **Data Engineering Workshop, 2007 IEEE 23rd International Conference on**. [S.l.], 2007. p. 801–810.
- TINTAREV, N.; MASTHOFF, J. Designing and evaluating explanations for recommender systems. In: **Recommender systems handbook**. [S.l.]: Springer, 2011. p. 479–510.
- TINTAREV, N.; MASTHOFF, J. Evaluating the effectiveness of explanations for recommender systems. **User Modeling and User-Adapted Interaction**, Springer, v. 22, n. 4-5, p. 399–439, 2012.
- VIANNA, J. A. Educação à distância, inclusão e mobilidade social. **InterSciencePlace**, v. 1, n. 5, 2015.
- VIG, J.; SEN, S.; RIEDL, J. Tagsplanations: explaining recommendations using tags. In: ACM. **Proceedings of the 14th international conference on Intelligent user interfaces**. [S.l.], 2009. p. 47–56.
- WELLER, A. Challenges for transparency. **arXiv preprint arXiv:1708.01870**, 2017.
- ZAINA, L. A. M. **Avaliação do perfil do aluno baseado em interações contextualizadas para adaptação de cenários de aprendizagem**. Tese (Doutorado) — Universidade de São Paulo, 2008.

APÊNDICE A – TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Você está sendo convidado (a) para participar, como voluntário, do projeto de pesquisa ANÁLISE DA ADERÊNCIA DE RECOMENDAÇÕES EXPLICADAS DE RECURSOS EDUCACIONAIS PARA APOIAR O ENSINO E A APRENDIZAGEM EM UM AMBIENTE EDUCACIONAL ONLINE, de responsabilidade do pesquisador Randerson Douglas.

Leia cuidadosamente. Após ser esclarecido (a) sobre as informações a seguir, no caso aceite fazer parte do estudo, marque a opção ao final deste documento. Em caso de recusa você não sofrerá nenhuma penalidade.

Declaro ter sido esclarecido sobre os seguintes pontos:

1. O trabalho tem por objetivos apresentar dados obtidos de um sistema tutor inteligente que ofereceu um curso online (experimento) que foi aplicado para os alunos da UFAL, onde todos os dados referentes as interações dos alunos foram armazenados, bem como os erros e acertos (quando se referiam à questões). E diante da necessidade dos alunos, o sistema oferecia algumas recomendações automáticas e personalizadas com base no modelo do aluno. Diante disso, serão apresentados alguns cenários vivenciados no curso, juntamente com as recomendações que foram oferecidas, visando colher um feedback quanto a sua visão sobre a qualidade da recomendação e a aceitação da mesma.
2. A participação do voluntário nesta pesquisa consistirá em analisar o cenário proposto. e responder aos questionamentos, onde o tempo de duração está estimado em 8 minutos.
3. O preenchimento do formulário se dará um única vez por participante.
4. A coleta de dados começará em 07/10 e terminará dia 18/10.
5. A finalidade deste trabalho é contribuir para que os sistemas que utilizam recomendações possam oferecê-las de uma forma que todos consigam entender o propósito dela ter sido sugerida, melhorando assim a qualidade e possivelmente a aceitação das recomendações por parte dos usuários.
6. O benefício esperado com a sua participação no projeto de pesquisa é que nossa metodologia comprove a eficácia da aceitação das recomendações através do objeto explicação.

7. Não haverá nenhuma despesa ou valor a receber ao participar da pesquisa e o voluntário poderá deixar de participar ou retirar seu consentimento a qualquer momento, sem precisar justificar, e não sofrerá qualquer prejuízo.
8. Os nomes dos voluntários serão mantido em sigilo, assegurando assim a privacidade, e caso deseje terá livre acesso a todas as informações e esclarecimentos adicionais sobre o estudo e suas consequências, enfim, tudo o que eu queira saber antes, durante e depois da minha participação.
9. Os dados coletados serão utilizados, única e exclusivamente, para fins desta pesquisa, e que os resultados poderão ser publicados.
10. Qualquer dúvida, pedimos a gentileza de entrar em contato com Randerson Douglas, pesquisador responsável pela pesquisa, e-mail: rdrs@ic.ufal.br

APÊNDICE B – QUESTIONÁRIO

1. INFORMAÇÕES DO PARTICIPANTE:

- a) Nome; ocupação e área de atuação; gênero; data de nascimento; email; grau de escolaridade; nível de conhecimento no uso de tecnologias/sistemas/computadores (nenhum, baixo, moderado e avançado); já participou de algum curso online (sim/não); quantos cursos online já participou (0; 0-5; 5-10; 10-15; acima de 15);

2. INSTRUÇÕES:

- a) CASO DESEJE VISUALIZAR OS DADOS UTILIZADOS NA PESQUISA, CLIQUE NO LINK ABAIXO!

TABELA DE LOG DE INTERAÇÃO DE TODOS OS ALUNOS: <https://bit.ly/2krHAwp>

CONCEITOS BÁSICOS:

Desempenho Pedagógico: cálculo do percentual, que considera as questões certas, feitas e todas.

Desempenho de interação: Percentual obtido da divisão da quantidade de recursos que o usuário utilizou dividido total de interações oferecidas pelo sistema.

Recomendação: É a oferta de recursos educacionais, que o sistema sugere ao aluno.

Percentual de Desempenho Pedagógico mínimo aceitável: 60%

Percentual de Desempenho de Interação mínimo aceitável: 60%

CONTEXTO:

O aluno 8 que fez um curso de estatística descritiva, contendo 4 (quatro) módulos, que oferecem diversos recursos (video, texto, questões e links externos) como forma de auxiliar na aprendizagem. Observou-se (através da tabela de log gerada pelo sistema) que ele não obteve um bom desempenho no assunto: VARIÂNCIA E DESVIO

PADRÃO (tópico 3), do módulo: MEDIDAS DE DISPERSÃO (módulo 3). Sendo assim, foram obtidos os seguintes índices:

- Percentual de Desempenho Pedagógico: 25%.
- Percentual de Desempenho de Interação: 87,5%.

Recursos oferecidos pelo curso:

- 4 questões
- 1 Vídeo
- 1 Texto
- 1 Link externo
- 1 Apresentação da aula (TOTALIZANDO: 8 ITENS)

Recursos utilizados pelo usuário:

- 1 Vídeo
- 1 Texto
- 1 Link externo
- 1 Apresentação da aula
- 3 Questões respondidas (errou 2 e acertou 1). (TOTALIZANDO: 7 ITENS)

Diante deste cenário, o sistema viu a necessidade de auxiliar o aluno 8 através de recomendações, para que ele possa alcançar um melhor desempenho. Sendo assim, Analise as recomendações apresentadas no passos a seguir:

3. RECOMENDAÇÕES

a) RELEMBRANDO O CENÁRIO

O aluno 8 obteve um baixo percentual de desempenho pedagógico (PDP), no assunto VARIÂNCIA E DESVIO PADRÃO (tópico 3), do módulo MEDIDAS DE DISPERSÃO (módulo 3). Pois observou-se que, das 4 questões que foram oferecidas pelo sistema o aluno respondeu apenas 3 das quais acertou 1 e errou 2, obtendo um PDP = 25%, onde o desempenho aceitável pelo sistema, é de no mínimo 60%.

RECOMENDAÇÃO 01:

"Olá aluno 8, tudo bem? Sugerimos que você reveja a apresentação da aula e responda as questões sobre VARIÂNCIA E DESVIO PADRÃO (contida no módulo MEDIDAS DE DISPERSÃO)."

QUESTÕES

- i. A recomendação oferecida a mim foi apropriada (justifica o problema descrito).
- ii. O texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação.
- iii. O texto da recomendação faz (motiva) com que eu siga tal recomendação.
- iv. A recomendação está clara (Sou capaz de entendê-la e saber o que devo fazer).
- v. Se eu fosse o aluno 8, eu seguiria essa recomendação.
- vi. Acho importante que o sistema explique porque uma recomendação foi gerada.

RECOMENDAÇÃO 02:

"Olá aluno 8, tudo bem? Observamos que seu desempenho não foi bom o suficiente no assunto VARIÂNCIA E DESVIO PADRÃO, desse modo, pedimos que por gentileza, assista ao vídeo sobre VARIÂNCIA E DESVIO PADRÃO (contido no módulo MEDIDAS DE DISPERSÃO) e acesse o link externo do assunto, como forma de revisão, para que possa melhorar seu desempenho na resolução das questões (tendo em vista que seu coeficiente de desempenho pedagógico foi apenas 25%), pois observou-se que das 4 questões oferecidas, três foram respondidas, onde e somente uma foi acertada!"

QUESTÕES

- i. A recomendação oferecida a mim foi apropriada (justifica o problema descrito).
- ii. O texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação.
- iii. O texto da recomendação faz (motiva) com que eu siga tal recomendação.
- iv. A recomendação está clara (Sou capaz de entendê-la e saber o que devo fazer).
- v. Se eu fosse o aluno 8, eu seguiria essa recomendação.
- vi. Acho importante que o sistema explique porque uma recomendação foi gerada.

RECOMENDAÇÃO 03:

"Olá aluno 8, tudo bem? Pedimos por gentileza que leia o texto auxiliar, acesse o link externo, assista novamente ao vídeo sobre o assunto VARIÂNCIA E DESVIO PADRÃO (contido no módulo MEDIDAS DE DISPERSÃO) e responda as questões."

QUESTÕES

- i. A recomendação oferecida a mim foi apropriada (justifica o problema descrito).
- ii. O texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação.
- iii. O texto da recomendação faz (motiva) com que eu siga tal recomendação.
- iv. A recomendação está clara (Sou capaz de entendê-la e saber o que devo fazer).
- v. Se eu fosse o aluno 8, eu seguiria essa recomendação.
- vi. Acho importante que o sistema explique porque uma recomendação foi gerada.

RECOMENDAÇÃO 04:

"Olá aluno 8, tudo bem? Observamos que seu desempenho de interação foi satisfatório (87.5%) e lhe parabenizamos por isso, pois vimos que utilizou quase todos os recursos disponibilizados pelo sistema, mas percebemos que o seu desempenho pedagógico (25%), quanto a resolução de questões não foi bom, no assunto VARIÂNCIA E DESVIO PADRÃO. Sendo assim, pedimos por gentileza, que assista novamente ao vídeo sobre VARIÂNCIA E DESVIO PADRÃO (contido no módulo MEDIDAS DE DISPERSÃO) e reveja a apresentação da aula que contém exemplos bastante didáticos, que te ajudarão a resolver todas as questões."

QUESTÕES

- i. A recomendação oferecida a mim foi apropriada (justifica o problema descrito).
- ii. O texto da recomendação explica o motivo pelo qual estou recebendo tal recomendação.
- iii. O texto da recomendação faz (motiva) com que eu siga tal recomendação.
- iv. A recomendação está clara (Sou capaz de entendê-la e saber o que devo fazer).
- v. Se eu fosse o aluno 8, eu seguiria essa recomendação.
- vi. Acho importante que o sistema explique porque uma recomendação foi gerada.

4. OPÇÕES DE RESPOSTA PARA CADA QUESTÃO

- a) Discordo plenamente
- b) Discordo
- c) Nem concordo nem discordo
- d) Concordo
- e) Concordo plenamente

5. OBSERVAÇÕES

Utiliza este espaço para elogios, críticas ou outras observações que deseje nos enviar.

ANEXO A -