

Universidade Federal de Campina Grande  
Centro de Engenharia Elétrica e Informática  
Coordenação de Pós-Graduação em Ciência da Computação

## Dissertação de Mestrado

Recomendação de Objetos de Aprendizagem baseada  
em Estilos de Aprendizagem e Traços de Personalidade

Janderson Jason Barbosa Aguiar

Campina Grande, Paraíba, Brasil

Agosto de 2015

Universidade Federal de Campina Grande  
Centro de Engenharia Elétrica e Informática  
Coordenação de Pós-Graduação em Ciência da Computação

## Recomendação de Objetos de Aprendizagem baseada em Estilos de Aprendizagem e Traços de Personalidade

Janderson Jason Barbosa Aguiar

Dissertação submetida à Coordenação do Curso de Pós-Graduação em Ciência da Computação da Universidade Federal de Campina Grande – Campus I como parte dos requisitos necessários para obtenção do grau de Mestre em Ciência da Computação.

Área de Concentração: Ciência da Computação  
Linha de Pesquisa: Metodologia e Técnicas da Computação

Dr. Evandro de Barros Costa  
(Orientador)

Dr.<sup>a</sup> Joseana Macêdo Fachine Régis de Araújo  
(Orientadora)

Campina Grande, Paraíba, Brasil  
Agosto de 2015

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFCG

A282r      Aguiar, Janderson Jason Barbosa.  
Recomendação de objetos de aprendizagem baseada em estilos de aprendizagem e traços de personalidade / Janderson Jason Barbosa Aguiar. – Campina Grande, 2015.  
214 f. : il. color.

Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2015.

"Orientação: Dr. Evandro de Barros Costa, Dr.<sup>a</sup> Joseana Macêdo Fechine Régis de Araújo".

Referências.

1. Sistemas de Recomendação. 2. Objetos de Aprendizagem. 3. Traços de Personalidade. 4. Estilos de Aprendizagem. I. Costa, Evandro de Barros. II. Araújo, Joseana Macêdo Fechine Régis de. III. Título.

CDU 004.65(043)

**"RECOMENDAÇÃO DE OBJETOS DE APRENDIZAGEM BASEADA EM ESTILOS DE APRENDIZAGEM E TRAÇOS DE PERSONALIDADE"**

**JANDERSON JASON BARBOSA AGUIAR**

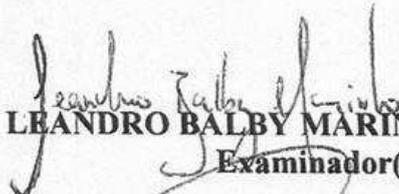
**DISSERTAÇÃO APROVADA EM 25/08/2015**



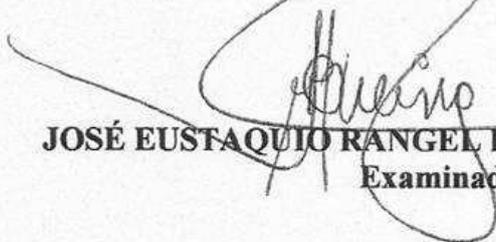
**EVANDRO DE BARROS COSTA, D.Sc, UFAL**  
**Orientador(a)**



**JOSEANA MACÊDO FECHINE RÉGIS DE ARAÚJO, D.Sc, UFCG**  
**Orientador(a)**



**LEANDRO BALBY MARINHO, Dr., UFCG**  
**Examinador(a)**



**JOSÉ EUSTAQUIO RANGEL DE QUEIROZ, D.Sc, UFCG**  
**Examinador(a)**

**FABIANO AZEVEDO DORÇA, Dr., UFU**  
**Examinador(a)**

**PATRICK HENRIQUE DA SILVA BRITO, Dr.**  
**Examinador(a)**

**CAMPINA GRANDE - PB**

*Dedico esta dissertação a meus pais,  
base de minha educação, que tanto  
torceram e se sacrificaram para eu  
chegar até aqui.*

## **Agradecimentos**

Primeiramente, agradeço a Deus, pelos dons concedidos para realização deste mestrado, iluminando-me e abençoando-me com saúde e ânimo, permitindo-me conhecer pessoas importantes durante minha caminhada.

À minha família, pelo carinho, compreensão, paciência e incentivo nos momentos difíceis; especialmente aos meus pais, pois esta conquista pertence essencialmente a eles.

Ao meu orientador Evandro Costa, agradeço a oportunidade de trabalharmos juntos, mesmo sem nos conhecermos previamente. À minha orientadora Joseana Fechine, agradeço o companheirismo e incentivo desde sua tutoria no PET (Programa de Educação Tutorial) durante minha graduação. A ambos os orientadores, agradeço pelos direcionamentos, sugestões e esforço dedicado que fizeram ser possível o desenvolvimento desta pesquisa.

Agradeço também aos demais professores e funcionários da Universidade Federal de Campina Grande (UFCG), especialmente àqueles que ministraram disciplinas que cursei durante o mestrado. Ainda no âmbito da UFCG, agradeço fortemente a todos os alunos do Curso de Ciência da Computação (graduação e pós-graduação) que participaram dos experimentos.

Nesse contexto, agradeço também à professora Priscilla Vieira — estendendo os agradecimentos aos seus alunos do Curso de Graduação em Ciência da Computação da Universidade Federal Rural de Pernambuco (UFRPE) que participaram do experimento final — e à Escola Técnica Redentorista (ETER) — especialmente à diretora adjunta, professora Maria de Fátima Cavalcanti, e aos alunos das turmas 11, 12 e 13 do Curso Técnico em Informática, que contribuíram na realização de experimentos iniciais.

Agradeço a todos os pesquisadores com quem entrei em contato e me responderam gentilmente, fornecendo-me informações importantes, em especial a Jonathas Magalhães (UFCG), Vitor Carvalho e Fabiano Dorça (Universidade Federal de Uberlândia — UFU). Agradeço também a Savyo Nóbrega e aos demais amigos e colegas — da UFCG e fora dela — que, mesmo indiretamente, muitas vezes contribuíram apoiando-me nesta jornada.

Agradeço, por fim, à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro.

*A verdadeira educação é aquela que nos possibilita sermos seres humanos, verdadeiramente humanos.*

*(Claudemir Sales)*

## Resumo

Os Objetos de Aprendizagem (OA) utilizados em cursos presenciais ou à distância são armazenados em ambientes computacionais usados no processo de ensino-aprendizagem, com tendência de crescimento da sua quantidade com o passar do tempo. Apesar dos Sistemas de Recomendação (SR) serem atualmente utilizados com sucesso para recomendar itens em vários domínios, o contexto educacional possui particularidades (por exemplo, questões pedagógicas) que tornam ainda mais desafiadora a criação desses sistemas. A Personalidade — que pode ser definida como um padrão de comportamento consistente originado internamente no indivíduo — influencia o processo de tomada de decisão. Além disso, há a preocupação com os Estilos de Aprendizagem (EA), a partir dos quais os aprendizes percebem, processam e retêm as informações. Diante do exposto, a pesquisa ora descrita visa a propor um modelo de Sistema de Recomendação Educacional (SRE) utilizando os conceitos de EA e Personalidade na construção do perfil dos discentes, para realizar uma seleção personalizada de OA a serem recomendados. Embora ainda seja desafiador criar SRE envolvendo a extração e inserção dos conceitos psicológicos comentados, nesta dissertação é apresentado e avaliado um modelo que recomenda OA, seguindo o padrão IEEE LOM, a partir da extração dos EA via inventário ILS (*Index of Learning Styles*) e da extração dos Traços de Personalidade (TP) via Five Labs, ferramenta *online* de análise semântica de postagens do Facebook. Considerando métricas utilizadas em SR, um experimento realizado com alunos de Ciência da Computação indicou que o modelo proposto proporcionou resultados melhores ou similares, em comparação a outras abordagens de recomendação pesquisadas. Portanto, a abordagem proposta se mostra promissora para a recomendação personalizada de conteúdo no âmbito educacional.

**Palavras-chave:** Sistemas de Recomendação. Objetos de Aprendizagem. Traços de Personalidade. Estilos de Aprendizagem.

## **Abstract**

Learning Objects (LO) used in on-site courses or distance learning are stored in computing environments used in the teaching-learning process, and tend to grow their numbers over time. Although Recommendation Systems (RS) are currently being used successfully to recommend items in various fields, the educational context has special features (for example, pedagogical issues) which make the creation of such systems even more challenging. The Personality — which can be defined as a consistent pattern of behavior originated internally in an individual — influences the decision-making process. In addition, there is concern with the Learning Styles (LS), through which learners perceive, process, and retain information. Based on the above considerations, this research aims to propose a model of RS for Learning (RSL) using the concepts of LS and Personality in building the profile of students, in order to make a custom selection of LO to be recommended. Although it is still challenging to create RSL involving the extraction and insertion of psychological concepts as previously mentioned, in this dissertation a model that recommends LO is presented and evaluated, following the IEEE LOM standard, based on the extraction of LS via Index of Learning Styles and of Personality Traits (PT) via Five Labs, an online tool for semantic analysis of Facebook posts. Considering metrics known in RS, an experiment with computer science students indicated that the proposed model provided similar or better results when compared to other recommendation approaches. Therefore, the proposed approach seems promising for personalized content recommendation in the education field.

**Keywords:** Recommendation Systems. Learning Objects. Personality Traits. Learning Styles.

# Lista de Abreviaturas e Siglas

<b>AUC</b>	<b>Area Under ROC Curve</b> (Área Sob a Curva ROC)
<b>AVA</b>	<b>Ambiente(s) Virtual(is) de Aprendizagem</b>
<b>BPR</b>	<b>Bayesian Personalized Ranking</b> (Ranking Personalizado Bayesiano)
<b>BPRMF</b>	<b>Bayesian Personalized Ranking Matrix Factorization</b> (Fatoração de Matriz baseada em Ranking Personalizado Bayesiano)
<b>CAPES</b>	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
<b>CBIE</b>	Congresso Brasileiro de Informática na Educação
<b>CFP</b>	Conselho Federal de Psicologia
<b>CGF</b>	Cinco Grandes Fatores
<b>CSBC</b>	Congresso da Sociedade Brasileira de Computação
<b>EA</b>	Estilo(s) de Aprendizagem
<b>ETER</b>	Escola Técnica Redentorista
<b>FBC</b>	Filtragem Baseada no Conteúdo
<b>FC</b>	Filtragem Colaborativa
<b>GR</b>	Grau de Recomendação
<b>IBCF</b>	<b>Item-Based Collaborative Filtering</b> (Filtragem Colaborativa Baseada no Item)
<b>IEEE</b>	<b>Institute of Electrical and Electronics Engineers</b> (Instituto de Engenheiros Eletricistas e Eletrônicos)
<b>ILS</b>	<b>Index of Learning Styles</b> (Índice de Estilos de Aprendizagem)
<b>IMS</b>	<b>Instructional Management System</b> (Sistema de Gestão Instrucional)
<b>ItemKNN</b>	<b>Item based K-Nearest Neighbors</b> (K Vizinhos Mais Próximos baseados no Item)
<b>JAIE</b>	Jornada de Atualização em Informática na Educação
<b>KNN</b>	<b>K-Nearest Neighbors</b> (K Vizinhos Mais Próximos)

<b>LOM</b>	<i>Learning Object Metadata</i> (Metadados de Objeto de Aprendizagem)
<b>LorSys</b>	<i>Learning Object Recommender System</i>
<b>LSBR</b>	<i>Learning Style Based Recommendation</i> (Recomendação Baseada em Estilos de Aprendizagem)
<b>MAE</b>	<i>Mean Absolute Error</i> (Erro Médio Absoluto)
<b>MAP</b>	<i>Mean Average Precision</i> (Média das Precisões Médias)
<b>MF</b>	<i>Matrix Factorization</i> (Fatoração de Matriz)
<b>MOOC</b>	<i>Massive Open Online Courses</i> (Cursos Online Abertos e Massivos)
<b>MP</b>	<b>Mais Popular</b>
<b>MRR</b>	<i>Mean Reciprocal Rank</i> (Posição Recíproca Média)
<b>NDCG</b>	<i>Normalized Discounted Cumulative Gain</i> (Ganho Cumulativo Descontado Normalizado)
<b>NEO-FFI</b>	<i>NEO Five-Factor Inventory</i> (Inventário de Cinco Fatores NEO)
<b>NEO-IPIP</b>	<i>NEO International Personality Item Pool</i> (Conjunto Internacional de Itens de Personalidade NEO)
<b>NEO-PI-R</b>	<i>Revised NEO Personality Inventory</i> (Inventário de Personalidade NEO Revisado)
<b>NMAE</b>	<i>Normalized Mean Absolute Error</i> (Erro Médio Absoluto Normalizado)
<b>OA</b>	<b>Objeto(s) de Aprendizagem</b>
<b>OBAA</b>	<b>Objetos de Aprendizagem baseados em Agentes</b>
<b>P@5</b>	<i>Precision at 5</i> (Precisão em 5)
<b>P@n</b>	<i>Precision at n</i> (Precisão em n)
<b>PBL</b>	<i>Problem Based Learning</i> (Aprendizagem Baseada em Problemas)
<b>PBR</b>	<i>Personality Based Recommendation</i> (Recomendação Baseada em Personalidade)
<b>R@5</b>	<i>Recall at 5</i> (Cobertura em 5)

<b>R@n</b>	<b>Recall at n</b> (Cobertura em n)
<b>RMSE</b>	<b>Root of Mean Square Error</b> (Raiz do Erro Quadrático Médio)
<b>ROC</b>	<b>Receiver Operating Characteristic</b> (Característica de Operação do Receptor)
<b>SAM</b>	<b>Self-Assessment Manikin</b> (Manequim de Autoavaliação)
<b>SATEPSI</b>	<b>Sistema de Avaliação de Testes Psicológicos</b>
<b>SBIE</b>	<b>Simpósio Brasileiro de Informática na Educação</b>
<b>SCORM</b>	<b>Sharable Content Object Reference Model</b> (Modelo de Referência de Objeto de Conteúdo Compartilhável)
<b>SPARP</b>	<b>Socially and Personality Aware Recommendation of Participants</b>
<b>SR</b>	<b>Sistema(s) de Recomendação</b>
<b>SRE</b>	<b>Sistema(s) de Recomendação Educacional(is)</b>
<b>TDIC</b>	<b>Tecnologia(s) Digital(is) de Informação e Comunicação</b>
<b>TEL</b>	<b>Technology Enhanced Learning</b> (Aprendizagem Apoiada por Tecnologia)
<b>TF-IDF</b>	<b>Term-Frequency – Inverse-Document-Frequency</b> (Frequência do Termo – Inverso da Frequência nos Documentos)
<b>TIPI</b>	<b>Ten-Item Personality Inventory</b> (Inventário de Personalidade de Dez Itens)
<b>TP</b>	<b>Traço(s) de Personalidade</b>
<b>UBCF</b>	<b>User-Based Collaborative Filtering</b> (Filtragem Colaborativa Baseada no Usuário)
<b>UFCG</b>	<b>Universidade Federal de Campina Grande</b>
<b>UFRPE</b>	<b>Universidade Federal Rural de Pernambuco</b>
<b>UserKNN</b>	<b>User based K-Nearest Neighbors</b> (K Vizinhos Mais Próximos baseados no Usuário)
<b>WEI</b>	<b>Workshop sobre Educação em Computação</b>
<b>WIE</b>	<b>Workshop de Informática na Escola</b>
<b>XML</b>	<b>eXtensible Markup Language</b> (Linguagem de Marcação Extensível)

# Lista de Figuras

<b>Figura 1.</b>	Categorias dos metadados do IEEE LOM. ....	29
<b>Figura 2.</b>	Representação da abordagem de FBC.....	41
<b>Figura 3.</b>	Representação da abordagem de FC baseada em vizinhos mais próximos. ....	42
<b>Figura 4.</b>	Países que pesquisam na área de SR em TEL. ....	48
<b>Figura 5.</b>	Modelo de recomendação proposto. ....	69
<b>Figura 6.</b>	Diagrama de atividades ilustrando o fluxo do modelo de recomendação proposto.....	77
<b>Figura 7.</b>	Diagrama da subatividade Aplicar FBC.....	78
<b>Figura 8.</b>	Diagrama da subatividade Aplicar LSBR.....	79
<b>Figura 9.</b>	Diagrama da subatividade Aplicar PBR.....	79
<b>Figura 10.</b>	Diagrama da subatividade Aplicar MP. ....	79
<b>Figura 11.</b>	Resultado da Administração do Questionário TIPI com os alunos da ETER. ....	84
<b>Figura 12.</b>	Resultado da Administração do Questionário ILS com os alunos da ETER. ....	85
<b>Figura 13.</b>	Resultado da Utilização da Five Labs pelos alunos da ETER. ....	86
<b>Figura 14.</b>	Intervalos de Confiança ( $\alpha=5\%$ ) relativos às métricas AUC, MAP, MRR, NDCG, P@5 e R@5, considerando o percentual para a base de treinamento igual a 55%. ....	101
<b>Figura 15.</b>	Intervalos de Confiança ( $\alpha=5\%$ ) relativos às métricas AUC, MAP, MRR, NDCG, P@5 e R@5, considerando o percentual para a base de treinamento igual a 65%. ....	102
<b>Figura 16.</b>	Intervalos de Confiança ( $\alpha=5\%$ ) relativos às métricas AUC, MAP, MRR, NDCG, P@5 e R@5, considerando o percentual para a base de treinamento igual a 75%. ....	103
<b>Figura 17.</b>	Opinião dos participantes sobre aspectos da pesquisa. ....	106
<b>Figura 18.</b>	Resultados de Extração de Personalidade — Traço: Extroversão. ....	170
<b>Figura 19.</b>	Resultados de Extração de Personalidade — Traço: Socialização. ....	171
<b>Figura 20.</b>	Resultados de Extração de Personalidade — Traço: Realização. ..	171
<b>Figura 21.</b>	Resultados de Extração de Personalidade — Traço: Neuroticismo.....	172
<b>Figura 22.</b>	Resultados de Extração de Personalidade — Traço: Abertura.....	172
<b>Figura 23.</b>	<i>Boxplots</i> para os dados relativos à métrica AUC por algoritmo. ...	181
<b>Figura 24.</b>	<i>Boxplots</i> para os dados relativos à métrica AUC por algoritmo e percentual dos dados utilizado para a base de treinamento. ....	181
<b>Figura 25.</b>	<i>Boxplots</i> para os dados relativos à métrica MAP por algoritmo. ...	182
<b>Figura 26.</b>	<i>Boxplots</i> para os dados relativos à métrica MAP por algoritmo e percentual dos dados utilizado para a base de treinamento. ....	182
<b>Figura 27.</b>	<i>Boxplots</i> para os dados relativos à métrica MRR por algoritmo....	183
<b>Figura 28.</b>	<i>Boxplots</i> para os dados relativos à métrica MRR por algoritmo e percentual dos dados utilizado para a base de treinamento. ....	183

<b>Figura 29.</b>	<i>Boxplots</i> para os dados relativos à métrica NDCG por algoritmo.	184
<b>Figura 30.</b>	<i>Boxplots</i> para os dados relativos à métrica NDCG por algoritmo e percentual dos dados utilizado para a base de treinamento. ....	184
<b>Figura 31.</b>	<i>Boxplots</i> para os dados relativos à métrica P@5 por algoritmo....	185
<b>Figura 32.</b>	<i>Boxplots</i> para os dados relativos à métrica P@5 por algoritmo e percentual dos dados utilizado para a base de treinamento. ....	185
<b>Figura 33.</b>	<i>Boxplots</i> para os dados relativos à métrica R@5 por algoritmo. ..	186
<b>Figura 34.</b>	<i>Boxplots</i> para os dados relativos à métrica R@5 por algoritmo e percentual dos dados utilizado para a base de treinamento. ....	186
<b>Figura 35.</b>	Intervalos de Confiança relativos à métrica AUC (%treinamento=55%).	199
<b>Figura 36.</b>	Intervalos de Confiança relativos à métrica MAP (%treinamento=55%).	199
<b>Figura 37.</b>	Intervalos de Confiança relativos à métrica MRR (%treinamento=55%).	200
<b>Figura 38.</b>	Intervalos de Confiança relativos à métrica NDCG (%treinamento=55%).	200
<b>Figura 39.</b>	Intervalos de Confiança relativos à métrica P@5 (%treinamento=55%).	201
<b>Figura 40.</b>	Intervalos de Confiança relativos à métrica R@5 (%treinamento=55%).	201
<b>Figura 41.</b>	Intervalos de Confiança relativos à métrica AUC (%treinamento=65%).	202
<b>Figura 42.</b>	Intervalos de Confiança relativos à métrica MAP (%treinamento=65%).	202
<b>Figura 43.</b>	Intervalos de Confiança relativos à métrica MRR (%treinamento=65%).	203
<b>Figura 44.</b>	Intervalos de Confiança relativos à métrica NDCG (%treinamento=65%).	203
<b>Figura 45.</b>	Intervalos de Confiança relativos à métrica P@5 (%treinamento=65%).	204
<b>Figura 46.</b>	Intervalos de Confiança relativos à métrica R@5 (%treinamento=65%).	204
<b>Figura 47.</b>	Intervalos de Confiança relativos à métrica AUC (%treinamento=75%).	205
<b>Figura 48.</b>	Intervalos de Confiança relativos à métrica MAP (%treinamento=75%).	205
<b>Figura 49.</b>	Intervalos de Confiança relativos à métrica MRR (%treinamento=75%).	206
<b>Figura 50.</b>	Intervalos de Confiança relativos à métrica NDCG (%treinamento=75%).	206
<b>Figura 51.</b>	Intervalos de Confiança relativos à métrica P@5 (%treinamento=75%).	207
<b>Figura 52.</b>	Intervalos de Confiança relativos à métrica R@5 (%treinamento=75%).	207

# Lista de Quadros

<b>Quadro 1.</b>	Características dos Aprendizes de acordo com seus EA. ....	32
<b>Quadro 2.</b>	Adjetivos característicos dos Cinco Grandes Fatores de Personalidade. ....	38
<b>Quadro 3.</b>	Comparação entre as pesquisas de Kerkiri, Manitsaris e Mavridis (2009) [K], Zaina <i>et al.</i> (2012) [Z], Oliveira (2013) [O], Resende <i>et al.</i> (2014) [R] e Carvalho <i>et al.</i> (2014) [C] sobre a associação entre o IEEE LOM e o modelo de EA de Felder–Silverman.....	54
<b>Quadro 4.</b>	Listagem das regras para mapeamento dos campos do IEEE LOM em EA. ....	56
<b>Quadro 5.</b>	Comparação entre estudos sobre SR no contexto educacional.....	65
<b>Quadro 6.</b>	Exemplo utilizando a formalização da Equação 4. ....	72
<b>Quadro 7.</b>	Exemplo de descritores de OA seguindo o padrão IEEE LOM. ....	73
<b>Quadro 8.</b>	Exemplo de Cálculo do Grau de Recomendação de OA. ....	76
<b>Quadro 9.</b>	Definição das hipóteses. ....	96
<b>Quadro 10.</b>	Definição dos tratamentos do experimento final. ....	97
<b>Quadro 11.</b>	<i>Rankings</i> dos algoritmos em relação à acurácia. ....	104
<b>Quadro 12.</b>	Comparação entre resultados do ILS após aproximadamente 1 ano entre as respostas dos alunos.....	112
<b>Quadro 13.</b>	Publicações. ....	129
<b>Quadro 14.</b>	Panorama internacional de SRE publicados entre 2010 e 2014..	163
<b>Quadro 15.</b>	Perfis de 61 alunos da ETER relativos a EA. ....	173
<b>Quadro 16.</b>	Aspectos de normalidade dos dados relativos à métrica AUC. ...	188
<b>Quadro 17.</b>	Aspectos de normalidade dos dados relativos à métrica MAP. ...	188
<b>Quadro 18.</b>	Aspectos de normalidade dos dados relativos à métrica MRR. ...	189
<b>Quadro 19.</b>	Aspectos de normalidade dos dados relativos à métrica NDCG. .	189
<b>Quadro 20.</b>	Aspectos de normalidade dos dados relativos à métrica P@5. ...	190
<b>Quadro 21.</b>	Aspectos de normalidade dos dados relativos à métrica R@5. ...	190
<b>Quadro 22.</b>	Testes de homoscedasticidade. ....	191
<b>Quadro 23.</b>	Resultado do teste ANOVA. ....	192
<b>Quadro 24.</b>	Resultado do teste de Kruskal-Wallis ....	193
<b>Quadro 25.</b>	P-valores obtidos na execução dos testes T e Mann-Whitney U, par a par, para os dados relativos à métrica AUC.....	194
<b>Quadro 26.</b>	P-valores obtidos na execução dos testes T e Mann-Whitney U, par a par, para os dados relativos à métrica MAP.....	194
<b>Quadro 27.</b>	P-valores obtidos na execução dos testes T e Mann-Whitney U, par a par, para os dados relativos à métrica MRR. ....	195
<b>Quadro 28.</b>	P-valores obtidos na execução dos testes T e Mann-Whitney U, par a par, para os dados relativos à métrica NDCG. ....	195
<b>Quadro 29.</b>	P-valores obtidos na execução dos testes T e Mann-Whitney U, par a par, para os dados relativos à métrica P@5. ....	196
<b>Quadro 30.</b>	P-valores obtidos na execução dos testes T e Mann-Whitney U, par a par, para os dados relativos à métrica R@5. ....	196

<b>Quadro 31.</b> Casos de diferença entre o resultado do teste T e o teste Mann-Whitney U.....	197
---	-----

# Lista de Tabelas

<b>Tabela 1.</b>	Correlação entre EA e TP via TIPI, considerando-se os dados não agrupados em níveis. ....	85
<b>Tabela 2.</b>	Correlação entre EA e TP via TIPI, considerando-se os dados agrupados em 3 níveis. ....	85
<b>Tabela 3.</b>	Correlação entre EA e TP via Five Labs, considerando os dados não agrupados em níveis. ....	86
<b>Tabela 4.</b>	Correlação entre EA e TP via Five Labs, considerando os dados agrupados em 3 níveis. ....	87
<b>Tabela 5.</b>	Variações na ordem dos OA com base nas 16 combinações extremas de perfis de EA. ....	89
<b>Tabela 6.</b>	Exemplo de variação na ordem dos OA com base em diferentes perfis de EA de estudantes reais. ....	91

# Sumário

<b>CAPÍTULO 1 – INTRODUÇÃO .....</b>	<b>19</b>
<b>1.1 Motivação .....</b>	<b>19</b>
<b>1.2 Objetivo.....</b>	<b>21</b>
<b>1.3 Relevância.....</b>	<b>22</b>
<b>1.4 Contribuição .....</b>	<b>24</b>
<b>1.5 Estrutura da Dissertação .....</b>	<b>26</b>
<b>CAPÍTULO 2 – FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>27</b>
<b>2.1 Objetos de Aprendizagem .....</b>	<b>27</b>
<b>2.2 Estilos de Aprendizagem .....</b>	<b>30</b>
<b>2.3 Personalidade.....</b>	<b>34</b>
<b>2.4 Sistemas de Recomendação .....</b>	<b>39</b>
2.4.1 Técnicas de Recomendação.....	40
2.4.1.1 Filtragem Baseada no Conteúdo .....	40
2.4.1.2 Filtragem Colaborativa .....	41
2.4.1.3 Filtragem Híbrida e Outras Técnicas de Recomendação .....	43
2.4.2 Avaliação de Sistemas de Recomendação .....	45
2.4.3 Sistemas de Recomendação Educacionais .....	47
<b>2.5 Considerações Finais do Capítulo .....</b>	<b>50</b>
<b>CAPÍTULO 3 – PESQUISAS RELACIONADAS .....</b>	<b>52</b>
<b>3.1 Pesquisas sobre associações entre os OA e as dimensões de EA ..</b>	<b>52</b>
<b>3.2 Pesquisas sobre SR baseados em TP .....</b>	<b>57</b>
<b>3.3 Pesquisas sobre SRE .....</b>	<b>58</b>
<b>3.4 Considerações Finais do Capítulo .....</b>	<b>65</b>
<b>CAPÍTULO 4 – MODELO DE RECOMENDAÇÃO DE OBJETOS DE APRENDIZAGEM.....</b>	<b>68</b>

<b>4.1 Perfis dos Discentes .....</b>	<b>69</b>
<b>4.2 Repositório de Metadados dos Objetos de Aprendizagem.....</b>	<b>72</b>
<b>4.3 Gerador de Recomendações .....</b>	<b>73</b>
<b>4.4 Considerações Finais do Capítulo .....</b>	<b>82</b>
<b>CAPÍTULO 5 – APRESENTAÇÃO E ANÁLISE DOS RESULTADOS .....</b>	<b>83</b>
<b>5.1 Investigação Empírica 1 .....</b>	<b>83</b>
5.1.1 Correlação entre ILS e TIPI.....	84
5.1.2 Correlação entre ILS e a ferramenta Five Labs.....	86
5.1.3 Análise Complementar de Correlação .....	87
<b>5.2 Investigação Empírica 2 .....</b>	<b>87</b>
5.2.1 Planejamento e Execução .....	88
5.2.2 Resultados e Comentários .....	88
<b>5.3 Investigação Empírica 3 .....</b>	<b>92</b>
5.3.1 Base de Dados.....	92
5.3.2 Variáveis e <i>Design</i> do Experimento .....	95
5.3.3 Execução do experimento.....	97
5.3.4 Resultados do Experimento.....	99
<b>5.4 Considerações Finais do Capítulo .....</b>	<b>107</b>
<b>CAPÍTULO 6 – CONSIDERAÇÕES FINAIS .....</b>	<b>109</b>
<b>6.1 Conclusões .....</b>	<b>109</b>
<b>6.2 Limitações e Sugestões para Pesquisas Futuras.....</b>	<b>111</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>115</b>
<b>APÊNDICE A – Publicações.....</b>	<b>129</b>
<b>APÊNDICE B – Panorama Internacional dos Sistemas de Recomendação Educacionais.....</b>	<b>163</b>
<b>APÊNDICE C – Traços de Personalidade de alunos da ETER via TIPI e via Five Labs .....</b>	<b>170</b>
<b>APÊNDICE D – Perfis de Estilos de Aprendizagem de Alunos da ETER</b>	<b>173</b>

<b>APÊNDICE E – Questionário sobre Características de Objetos de Aprendizagem.....</b>	<b>175</b>
<b>APÊNDICE F – Questionário para Opiniões sobre o Experimento.....</b>	<b>179</b>
<b>APÊNDICE G – Análise Estatística .....</b>	<b>180</b>
<b>APÊNDICE H – Execução do experimento final com vários modelos híbridos .....</b>	<b>198</b>
<b>ANEXO A – Instrumento de Mensuração de Estilos de Aprendizagem</b>	<b>208</b>
<b>ANEXO B – Instrumento de Mensuração de Traços de Personalidade</b>	<b>214</b>

# Capítulo 1

## Introdução

O uso crescente das Tecnologias Digitais de Informação e Comunicação (TDIC) possibilita mudanças a cada dia no processo de ensino–aprendizagem ([GONÇALVES, 2012](#); [COSTA, AGUIAR e MAGALHÃES, 2013](#)). Embora a utilização das TDIC possa ser considerada como um dos paradigmas de inovação e evolução das sociedades, é importante considerar o modo como as pessoas utilizam essas tecnologias para se desenvolverem individualmente e coletivamente ([MOZZAQUATRO et al., 2010](#)).

Aliado ao aumento na procura de cursos a distância ([INEP, 2013](#)), houve um crescimento acentuado no volume de recursos digitais educacionais disponíveis na Web aberta, ou mesmo em bibliotecas digitais privadas, como consequência da revolução causada pela Web 2.0, em que os usuários se tornaram, além de consumidores, produtores de conteúdo ([SAKLIKAR e SAHA, 2007](#)).

Isso dificulta a tarefa de acesso, de estudantes e professores, ao conteúdo que lhes interessa. Esse cenário apresenta o problema clássico da Sobrecarga de Informação, em que o excesso de informação disponível dificulta o acesso ao conteúdo considerado relevante ([ADOMAVICIUS e TUZHILIN, 2005](#); [BOBADILLA et al., 2013](#)).

### 1.1 Motivação

A perspectiva descrita no início deste capítulo demonstra o caráter desafiador para os professores na seleção e organização dos diversos recursos educacionais que vão surgindo na Web, de forma a contribuir para o aumento da aprendizagem e da motivação do corpo discente. Diante deste problema, é importante discutir como utilizar, da melhor forma, os recursos de um ambiente educacional, tendo em vista a ampliação do aprendizado, ou seja, como desenvolver ambientes educacionais mais eficazes, de forma que o estudante se

sinta motivado e aprenda mais e em menos tempo.

Apesar dos engenhos de busca na Web, e. g., *Google Search* e *Yahoo Search*, serem bastante úteis e utilizados, muito conteúdo irrelevante continua sendo retornado ([BARCELLOS et al., 2007](#)). Os Sistemas de Recomendação (SR) retornam informações mais específicas e SR personalizados permitem ao usuário encontrar conteúdo mais apropriado ao seu perfil, facilitando seu trabalho ([BOBADILLA et al., 2013](#)).

Os MOOC (*Massive Open Online Courses*) permitem extrair grandes quantidades de dados de alunos (úteis para a análise do comportamento de aprendizagem destes) e, portanto, proporcionam novas oportunidades para SR oferecerem apoio à aprendizagem personalizada ([DRACHSLER et al., 2015](#)).

Apesar dos SR serem atualmente utilizados com sucesso para recomendar itens em uma variedade de domínios, o contexto educacional, segundo [Parveen, Jaiswa e Kant \(2012\)](#), possui particularidades, o que requer uma reflexão especial. A recomendação personalizada de conteúdo no contexto educacional é ainda mais desafiadora, pois, de acordo com [Cazella, Nunes e Reategui \(2010\)](#), devem ser consideradas as necessidades individuais de cada aluno, além de interesses almejados pelo professor e competências a serem desenvolvidas pelo aluno. [Manouselis et al. \(2012\)](#) defendem que é preciso considerar o tipo de aprendizagem que se deseja — aprender um novo conceito ou reforçar um conhecimento existente, os quais podem exigir tipos diferentes de recursos de aprendizagem.

Além das preferências do professor ou do estudante sobre determinado recurso, requer-se saber, em Sistemas de Recomendação Educacionais (SRE), o quanto o recurso irá ajudá-los a alcançar os objetivos de aprendizagem ([TANG e MCCALLA, 2004](#)). Em particular, requisitos adicionais, a exemplo de cuidados com interface com o usuário, devem ser considerados no projeto e desenvolvimento de SR, no caso de ambientes educacionais *online*.

Identificar o estilo de aprender do aluno é uma das formas para obtenção de suas preferências, propiciando materiais de aprendizagem mais efetivos no processo de ensino-aprendizagem ([VALASKI, MALUCELLI e REINEHR, 2011](#)). Os aspectos psicológicos, tais como emoções e personalidade, também têm importância e influenciam o processo de tomada de decisão dos humanos ([NUNES, 2012](#)). [Jaques e Nunes \(2012\)](#) defendem que inferir estados afetivos do aluno pode auxiliar a prever aspectos como evasão e baixo desempenho.

Além disso, há pesquisadores ([HU e PU, 2011](#); [ELAHI et al., 2013](#); [WU, CHEN e HE, 2013](#); [XIA et al., 2014](#)) que defendem que a personalidade pode ser aproveitada para resolver o problema de partida a frio (*cold-start problem*) em SR baseados no usuário ([CAZELLA, NUNES e REATEGUI, 2010](#)), indicando alguns estudos relacionados com resultados satisfatórios (maior eficácia e lealdade dos usuários em relação a sistemas não baseados em personalidade). [Wu, Chen e He \(2013\)](#) destacam também que alguns sites comerciais, a exemplo do site de recomendação de filmes *What to Rent*, já empregam a personalidade para identificar o perfil de interesses do usuário — atualmente, as estatísticas desse site indicam que os usuários ficaram satisfeitos com as recomendações em mais de 80% do tempo ([WHATTORENT, 2015](#)).

A partir do exposto, percebe-se que conceitos como Estilos de Aprendizagem e Personalidade são pertinentes para se considerar ao estudar, no contexto educacional, como recomendar itens personalizados.

Quais as técnicas de recomendação que melhor se adaptam às necessidades de estudantes no processo de ensino–aprendizagem? Como inserir aspectos psicológicos dos estudantes no processo de recomendação? Questões como estas despertam o interesse — e demonstram a necessidade — de se estudar sobre como realizar boas recomendações de recursos educacionais. Esta problemática motivou a realização da pesquisa, ora descrita, com os objetivos descritos na Seção 1.2.

## **1.2 Objetivo**

Considerando-se que a Personalidade influencia o processo de tomada de decisão, aliado ao fato de que há preocupação sobre as formas (estilos) a partir dos quais os aprendizes lidam individualmente com as informações, o objetivo geral desta pesquisa consiste em contribuir com a área de SR ao propor um modelo de SRE utilizando os conceitos de Traços de Personalidade (TP) e Estilos de Aprendizagem (EA) na construção do perfil dos discentes.

O modelo visa a propiciar a realização de uma seleção personalizada de Objetos de Aprendizagem (OA) a serem recomendados, sendo também aplicadas técnicas tradicionais em SR, tais como a Filtragem Baseada no Conteúdo (FBC) e a Filtragem Colaborativa (FC).

A partir deste objetivo geral, é possível elencar os seguintes objetivos

específicos:

- I. Escolher especificidades (teorias, padrões, métodos) intrínsecas a TP, EA e recomendação de OA, apropriadas para criação de um modelo de SRE;
- II. Comparar formas de extração de TP e EA para analisar a possibilidade de inferir um conceito a partir do outro e, conseqüentemente, simplificar a construção do perfil dos discentes/usuários do SRE;
- III. Verificar se o uso de TP e/ou EA, na construção do perfil do usuário/aluno, interfere na melhoria das recomendações de OA para alunos;
- IV. Desenvolver e avaliar modelos para a geração de recomendações personalizadas para alunos baseadas em suas preferências anteriores, seus TP e/ou seus EA, e no conteúdo dos OA existentes;
- V. Indicar, dentre os modelos a serem desenvolvidos e comparados, o modelo de SRE — incluindo-se conceitos de Personalidade, EA, FBC, FC e Popularidade de itens — que melhor satisfaz os interesses dos alunos.

### **1.3 Relevância**

A partir da problemática que motiva a pesquisa, apresentada na Seção 1.1, a utilização de um SR consiste em uma solução para tornar os ambientes educacionais mais eficazes, de forma que o estudante se sinta motivado e aprenda mais e em menos tempo, uma vez que esses sistemas são capazes de identificar conteúdos adequados, de maneira automática, para cada indivíduo, baseando-se em suas características e/ou preferências ([ADOMAVICIUS e TUZHILIN, 2005](#)). A personalização é uma característica importante em sistemas para *e-learning* devido às diferentes experiências dos alunos adultos, foco principal desse tipo de modalidade de ensino (KERKIRI *et al.*, 2007 *apud* [PEREIRA e AUGUSTIN, 2014](#)).

Como forma de evidenciar em sala de aula as diferentes preferências no modo de aprender (EA), além das diferentes personalidades dos aprendizes, foram administrados questionários para a extração dessas características com 61 alunos do Curso Técnico em Informática da Escola Técnica Redentorista (ETER), da cidade de Campina Grande – PB. Os resultados, detalhados na Seção 5.1,

indicaram que há, conforme esperado, alunos com perfis bastante diferentes e, portanto, OA com características diferenciadas poderiam proporcionar melhores resultados no processo de ensino–aprendizagem.

Conforme defende [Ferro \(2010\)](#), a utilização de SR pode contribuir bastante no processo de ensino–aprendizagem, uma vez que os alunos poderão receber recomendações personalizadas de materiais didáticos (disponibilizados pelos professores no ambiente e disponibilizados na Web de maneira geral), além de contribuir para explorar mais o acervo existente, permitindo maior interação entre os materiais didáticos e os usuários.

Além da necessidade de atrativos e facilidades para os alunos encontrarem recursos digitais educacionais compatíveis com seu perfil, é notável que aspectos psicológicos, tais como TP, influenciam processos de tomada de decisão. Vale ressaltar também que, conforme defendem Nunes e Hu ([HU, 2010](#); [NUNES e HU, 2012](#)), embora estudos mostrem que a Personalidade influencia o processo de tomada de decisão e os interesses humanos, são poucas as pesquisas que se aventuraram em incorporar esse conceito em SR.

A criação de um modelo híbrido de SR para recomendação de recursos educacionais, envolvendo a extração e inserção dos conceitos psicológicos comentados, ainda é um desafio atualmente. Conforme afirmam [Santos et al. \(2014\)](#), há poucos SR em cenários educacionais que consideraram as questões afetivas para apoiar o processo de aprendizagem.

A execução da pesquisa ora descrita visou proporcionar à comunidade o benefício de um modelo para filtrar OA, contemplando preferências, necessidades e a personalidade dos alunos, a ser utilizado em ambientes de apoio a cursos presenciais, semipresenciais ou a distância. Além disso, almeja-se posteriormente que a comunidade possa utilizar esse modelo implementado em forma de um *plugin* para o AVA Moodle, disponível em código aberto para possíveis melhorias. Atualmente, o único *plugin*, disponível para o Moodle, focado no contexto de recomendação de recursos é o bloco Recommender, baseado apenas em recomendação não personalizada (atividades e cursos mais populares) ([MOODLE, 2013](#)).

Apesar da existência de outros estudos que propõem modelos voltados para *e-learning*, há poucos que consideram aspectos afetivos, como Personalidade, e, dentre esses, não foram encontrados modelos que contemplassem as estratégias adotadas.

Com base no que foi exposto, considera-se relevante o tema de pesquisa proposto neste documento, por consistir na criação de um modelo de SR de recursos educacionais para discentes utilizando uma técnica híbrida de recomendação que considera TP e EA na construção do perfil desses estudantes. Além disso, ao unir esses conceitos, acredita-se que esta pesquisa seja relevante por possibilitar o despertar do interesse de outros pesquisadores nessa linha de pesquisa.

## **1.4 Contribuição**

Destaca-se, primeiramente, como contribuição da pesquisa, o levantamento do estado da arte. A revisão bibliográfica inicial culminou na realização de um minicurso no Congresso Brasileiro de Informática na Educação (CBIE 2013), denominado "Sistemas de Recomendação de Recursos Educacionais: conceitos, técnicas e aplicações", cujo texto-base elaborado foi publicado como um capítulo nos anais da Jornada de Atualização em Informática na Educação (JAIE/CBIE 2013).

Ainda em relação ao levantamento bibliográfico realizado, foram publicados dois artigos no 25º Simpósio Brasileiro de Informática na Educação (SBIE/CBIE 2014): "Um Mapeamento Sistemático sobre Iniciativas Brasileiras em Sistemas de Recomendação Educacionais" e "Estilos Cognitivos e Estilos de Aprendizagem em Informática na Educação: um mapeamento sistemático focado no SBIE, WIE e RBIE". Além desses, foi aceito para publicação, no SBIE/CBIE 2015 — evento a ser realizado de 26 a 30 de outubro de 2015 —, o artigo denominado "Avaliação de Sistemas de Recomendação Educacionais no Brasil: uma revisão sistemática da literatura".

Destaca-se, ainda, como contribuição, os estudos iniciais relacionados à identificação de Traços de Personalidade e Estilos de Aprendizagem dos alunos. Em relação a esses estudos, foram publicados, no 23º Workshop sobre Educação em Computação (WEI 2015) — evento integrante do 35º Congresso da Sociedade Brasileira de Computação (CSBC 2015) —, os seguintes artigos: "Identificando os Traços de Personalidade de Estudantes de um Curso Técnico em Informática" e "Utilização do Índice de Estilos de Aprendizagem de Felder-Soloman em Turmas de Nível Técnico, Graduação e Pós-Graduação em Computação". Além desses, foi aceito para publicação, no Workshop de

Informática na Escola (WIE/CBIE 2015), o artigo denominado “Utilização da ferramenta Five Labs para Identificação de Traços de Personalidade dos Estudantes”.

Ainda se considerando os estudos iniciais, é possível afirmar que uma contribuição indireta foi, a partir da apresentação de ideias e resultados iniciais no WDCOPIN (Workshop de Dissertações e Teses do Programa de Pós-Graduação em Ciência da Computação da UFCG), a divulgação dessa linha de pesquisa a outros alunos do programa de pós-graduação, no qual esta pesquisa foi desenvolvida, assim como aos alunos da graduação em Ciência da Computação da UFCG que também participaram do evento e que aparentaram interesse pela pesquisa envolvendo esses conceitos e pela área de Informática na Educação.

Outra contribuição é a divulgação de uma comparação entre o inventário TIPI e uma ferramenta *online* para a extração de personalidade baseando-se no perfil do usuário no Facebook (validado com base no inventário NEO-IPIP), além da comparação entre os TP (extraídos por meio dessas 2 formas) e os EA de Felder–Silverman, cujo principal meio de extração se dá a partir do ILS. Detalhes sobre essa ferramenta e esses inventários supracitados encontram-se no Capítulo 2.

Ressalta-se também que foi realizada uma análise comparativa em relação às abordagens de associação entre os Estilos de Aprendizagem de Felder–Silverman e os metadados de Objetos de Aprendizagem que seguem o padrão IEEE LOM. Tal análise foi publicada no 4º Workshop de Desafios da Computação Aplicada à Educação (DesafIE 2015) — evento integrante do CSBC 2015.

Destaca-se também, como contribuição, a avaliação do modelo proposto por [Carvalho et al. \(2014\)](#), além da expansão desse modelo, cujos detalhes são apresentados no artigo intitulado “Recomendação de Objetos de Aprendizagem baseada na Popularidade dos Objetos e nos Estilos de Aprendizagem dos Alunos”, aceito para publicação no SBIE/CBIE 2015.

Os resumos e outros detalhes das publicações citadas nesta seção encontram-se no Apêndice A.

Vale ressaltar que, embora haja uma quantidade significativa de estudos que abordem SRE considerando EA, ainda é escasso o uso do conceito de TP. Portanto, a pesquisa em questão contribui com a área de SRE ao analisar a aplicação desses conceitos em um modelo híbrido de recomendação. Os resultados obtidos, no experimento final realizado em relação ao modelo

proposto, indiciam o impacto positivo desta pesquisa para o estado da arte atual em SRE, por disponibilizar uma forma de recomendar OA com características mais próximas às preferências dos discentes.

Além disso, os dados coletados e utilizados nesses experimentos podem ser úteis para outros pesquisadores na realização de estudos semelhantes.

## **1.5 Estrutura da Dissertação**

Além deste capítulo introdutório, este documento contempla mais cinco capítulos, estruturados da seguinte forma: no Capítulo 2, é apresentado o embasamento teórico relativo a Objetos de Aprendizagem, Estilos de Aprendizagem, Personalidade e Sistemas de Recomendação, destacando-se conceitos, teorias e técnicas necessários para melhor entendimento dos capítulos seguintes.

No Capítulo 3, é apresentada uma revisão da literatura, na qual são discutidas pesquisas desenvolvidas no âmbito de recomendação, especialmente de recursos educacionais.

No Capítulo 4, é apresentado o modelo proposto a partir do desenvolvimento da pesquisa.

No Capítulo 5, composto pela metodologia de avaliação e resultados obtidos, é discutida a realização dos experimentos, incluindo-se a descrição das estratégias de investigação.

No Capítulo 6, são apresentadas as considerações finais acerca da pesquisa, indicando-se suas limitações e possíveis estudos futuros.

# Capítulo 2

## Fundamentação Teórica

Este capítulo destina-se a apresentar os fundamentos teóricos referentes às áreas do conhecimento relacionadas ao objetivo da pesquisa. Na Seção 2.1 são vistos os conceitos sobre Objetos de Aprendizagem. A fundamentação sobre Estilos de Aprendizagem e Personalidade encontra-se, respectivamente, nas Seções 2.2 e 2.3. Os conceitos sobre Sistemas de Recomendação são contemplados na Seção 2.4. Por fim, na Seção 2.5, são apresentadas considerações sobre essa fundamentação teórica.

### 2.1 Objetos de Aprendizagem

Para minimizar o tempo e o esforço despendido ao desenvolver materiais didáticos — a serem disponibilizados em ambientes de ensino-aprendizagem via Web, cada vez mais utilizados no meio educacional —, e pensando em uma forma de reutilizar esses materiais, surgiu o conceito de Objetos de Aprendizagem (OA) ([Resende et al., 2014](#)).

O termo “Objeto de Aprendizagem” possui várias definições, sendo uma das mais utilizadas aquela concebida em um dos padrões do IEEE, no qual se afirma que um OA é uma entidade, digital ou não digital, que pode ser utilizada, reutilizada ou referenciada para o ensino, educação ou treinamento assistidos pela tecnologia, como sistemas de educação a distância e ambientes colaborativos de ensino ([IEEE, 2002](#)).

Alguns autores criticam as definições muito genéricas, a exemplo de [Wiley \(2000\)](#), que defende que os OA são entidades digitais que podem ser transmitidas pela Web e acessadas simultaneamente por um grande público, de uma maneira mais versátil em comparação à mídia tradicional (livros e outros materiais disponibilizados em mídias físicas). De maneira geral, a ideia de [Wiley \(2000\)](#) é empregada nesta dissertação.

Com o crescente interesse na tecnologia de OA, existe na Web um grande

número de repositórios de OA de propósito geral — a exemplo do ARIADNE ([ARIADNE FOUNDATION, 2015](#)), Connexions ([OPENSTAX CNX, 2015](#)), Learn-Alberta ([GOVERNMENT OF ALBERTA, 2015](#)), MERLOT ([MERLOT, 2015](#)) e RIVED ([SEED/MEC, 2015](#)) — e repositórios de OA específicos — a exemplo do CITIDEL ([DSPACE SOFTWARE, 2006](#)), voltado à Ciência da Computação, do HEAL ([HEAL, 2013](#)), voltado à Saúde, do FLORE ([BEAUDOIN et al., 2008](#)), voltado a Humanidades, e do CESTA ([CINTED, 2015](#)), do NOA/UFPB ([TAVARES et al., 2015](#)) e do iLumina ([ILUMINA, 2009](#)), voltados à Ciência, Matemática, Engenharia e Tecnologia. Os repositórios correspondem a bancos de dados que armazenam metadados, referências (URL) e, em alguns casos, armazenam os próprios OA ([MACHION, 2007](#)).

Os metadados são descritores — com diversas informações pertinentes, a exemplo de autor e data de criação — utilizados para facilitar a classificação e busca dos OA, permitindo sua utilização em diversas plataformas. Alguns exemplos de padrões de metadados são:

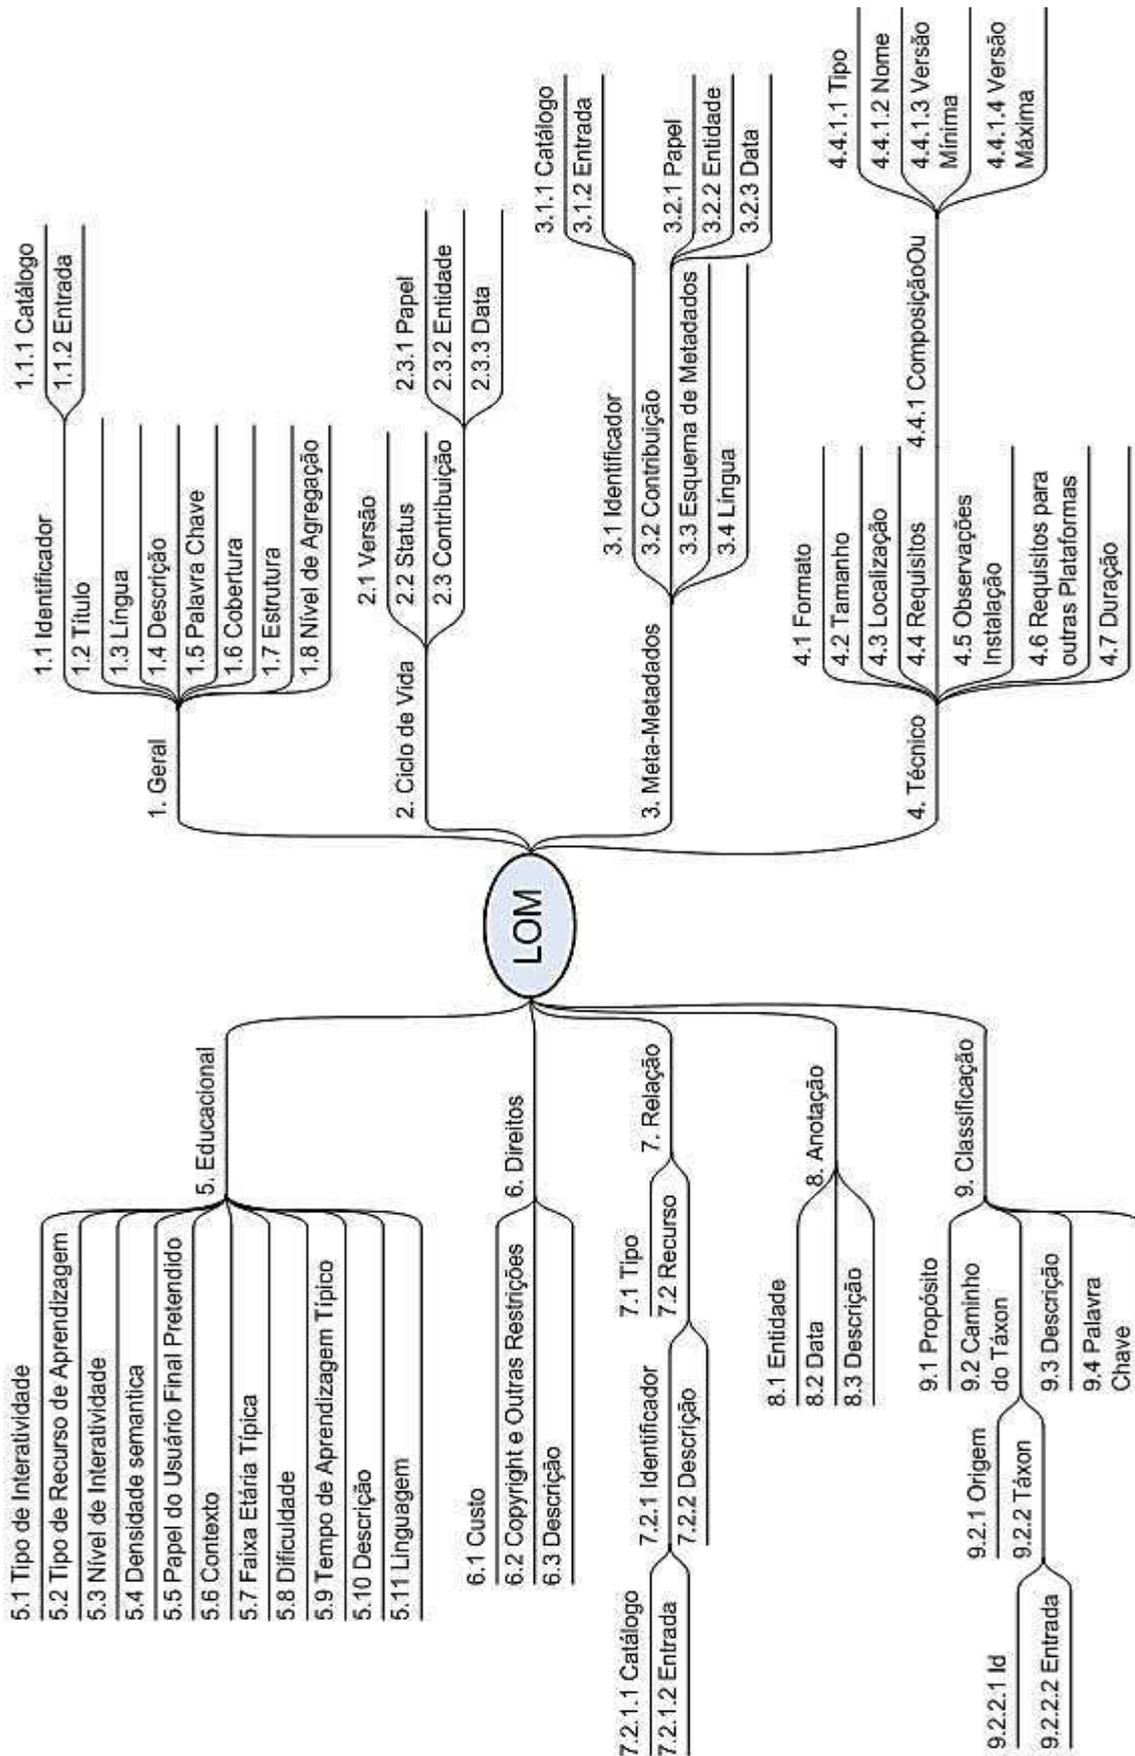
- *Dublin Core* ([DCMI, 2012](#));
- IEEE LOM (*Learning Object Metadata*) ([IEEE, 2002](#));
- IMS (*Instructional Management System*) *Learning Design* ([IMS, 2006](#));
- SCORM (*Sharable Content Object Reference Model*) ([SCORM, 2004](#));
- OBAA (Objetos de Aprendizagem baseados em Agentes) ([VICARI et al., 2010](#)).

O padrão IEEE LOM (IEEE 1484.12.1) é um padrão internacional e tem sua representação na linguagem XML (*eXtensible Markup Language*).

Os metadados do padrão IEEE LOM são agrupados nestas categorias: Geral (informações gerais do OA), Ciclo de vida (características relativas ao histórico e ao estado atual do OA), Meta-metadados (metadados utilizados para descrever os metadados do OA), Técnica (requisitos e características técnicas do OA), Educacional (características educacionais e pedagógicas do OA), Direitos (direitos de propriedade intelectual e condições de uso do OA), Relação (características que definem o relacionamento entre um OA e outros), Anotação (comentários sobre o uso do OA) e Classificação (descrições do objeto de acordo com algum sistema de classificação pré-definido) ([IEEE, 2002](#); [VAZ, 2009](#)).

Na Figura 1 são ilustradas estas categorias.

Figura 1. Categorias dos metadados do IEEE LOM.



Fonte: [MACHION, 2007, p. 17.](#)

Alguns dos principais objetivos do padrão IEEE LOM são: (i) criar uma descrição bem definida do objeto visando a facilitar sua busca, localização, uso e avaliação por softwares automatizados, professores e alunos; e (ii) compartilhar as descrições entre sistemas de busca de recursos para oferecer serviços eficientes ([VAZ, 2009](#)).

Como defendem [Vicari et al. \(2010\)](#), proponentes do padrão OBAA, o padrão IEEE LOM é amplamente aceito no meio acadêmico, sendo considerado um modelo completo, apresentando um conjunto de metadados organizado em nove categorias, permitindo a fácil inserção de novas categorias e elementos em categorias existentes. Além disso, o padrão IEEE LOM é usado para categorizar os metadados tanto no SCORM quanto no IMS *Learning Design* ([VAZ, 2009](#)). O padrão OBAA, extensão do IEEE LOM, surgiu para atender às necessidades brasileiras em termos de tecnologia, educação, acessibilidade e segmentação ([VICARI et al., 2010](#)). Em relação ao *Dublin Core*, embora sua simplicidade seja uma alternativa adequada em alguns domínios, este não define elementos específicos para a educação.

## 2.2 Estilos de Aprendizagem

O processo de aprendizagem não é vivenciado por todos os indivíduos da mesma forma, sendo desenvolvidos estilos (como resultado da bagagem hereditária, das experiências pessoais e das exigências do ambiente) que enfatizam algumas habilidades sobre as outras ([KOLB, 1984](#)).

Sobre as formas com que os aprendizes lidam particularmente/individualmente com as informações, conceitos como Estilos Cognitivos e/ou Estilos de Aprendizagem são cada vez mais presentes em pesquisas no âmbito de Informática na Educação. A literatura não tem um consenso sobre a definição desses conceitos, havendo autores que os consideram como sinônimos, outros apontam diferenças entre os termos, e outros ainda consideram EA como subcategoria dos Estilos Cognitivos ([AGUIAR, FECHINE e COSTA, 2014](#)).

[Almeida \(2010\)](#) considera que o atributo Estilos Cognitivos tem enfoque no controle e na organização dos processos cognitivos, enquanto EA tem enfoque no controle e na organização de estratégias para a aprendizagem e aquisição de informação. Em relação aos que consideram EA como subcategoria de Estilos

Cognitivos, encontram-se autores que usam o termo Estilos Cognitivos de Aprendizagem, no sentido de “a forma individual, preferida e habitual, com que o aluno organiza e representa novas informações enquanto executa uma tarefa de aprendizagem” ([RIDING e RAYNER, 2000](#)). Em Informática na Educação, os autores em geral consideram esses termos como sinônimos, sendo sugerido por [Aguiar, Fechine e Costa \(2014\)](#) o uso do termo “Estilos de Aprendizagem” ou “Estilos Cognitivos de Aprendizagem” quando o foco for a aprendizagem e aquisição de informação — o que acaba sendo uma uniformidade em pesquisas nessa área.

[Coffield et al. \(2004\)](#) realizaram uma revisão da literatura com os seguintes termos de busca: *Learning style/s; Cognitive style/s; Conative style/s; Thinking style/s; Learning preference/s, strategy/ies, orientation/s*. Foram identificados 71 modelos de EA, utilizados em áreas como educação, psicologia, sociologia, entre outras.

Dentre eles, é possível destacar o modelo de Felder–Silverman ([FELDER e SILVERMAN, 1988](#)), o mais utilizado no contexto nacional e internacional em pesquisas relativas à adaptação e personalização de materiais de aprendizagem ([AGUIAR, FECHINE e COSTA, 2014](#); [VALASKI, MALUCELLI e REINEHR, 2011](#)).

O modelo de Felder–Silverman foi usado por instrutores e alunos de engenharia e ciências, sendo posteriormente aplicado em várias outras disciplinas. Para esses autores, EA referem-se aos modos a partir dos quais os indivíduos preferem receber e processar as informações. Ao receber a informação externa (captada pelos sentidos) e a informação interna (que surge introspectivamente), essas ficam disponíveis para o indivíduo, que seleciona o material a ser processado. Ao processar, o indivíduo pode fazer uso de simples memorização ou raciocínio indutivo ou dedutivo, reflexão ou ação, introspecção ou interação com outros indivíduos. Como resultado, o conteúdo abordado no material selecionado é aprendido de uma forma ou de outra ou, então, não é aprendido ([FELDER e SILVERMAN, 1988](#)).

Diante disso, o modelo de Felder–Silverman contempla quatro dimensões de EA: (1) Processamento — Ativo/Reflexivo; (2) Percepção — Sensorial/Intuitivo; (3) Entrada — Visual/Verbal; e (4) Compreensão — Sequencial/Global.

Inicialmente, havia a dimensão Organização — Indutivo/Dedutivo —, removida em 2002 por Felder, a partir da argumentação de que o modo indutivo

proporciona melhores resultados e, uma vez que os alunos preferem o modo dedutivo, o autor não queria que sua pesquisa servisse como justificativa para os professores continuarem a usar o modo dedutivo em suas aulas ([FELDER, 2002](#)).

Baseado nas 4 dimensões, foi desenvolvido pelo próprio Richard Felder, com o auxílio de Bárbara Soloman, o Índice de Estilos de Aprendizagem (*Index of Learning Styles – ILS*), instrumento usado para determinar as preferências de aprendizagem do Modelo de Felder–Silverman ([FELDER e SOLOMAN, 1999](#)). No Quadro 1, são apresentadas características de ambas as categorias dessas quatro dimensões.

**Quadro 1. Características dos Aprendizes de acordo com seus EA.**

<b>Dimensão de EA</b>	<b>Características dos Aprendizes</b>
Processamento	<b>Ativos:</b> tendem a reter e compreender melhor a informação participando ativamente de alguma atividade, discutindo, aplicando ou explicando para outros; gostam do trabalho em grupo; são rápidos, mas podem ser precipitados.
	<b>Reflexivos:</b> preferem refletir calmamente sobre a informação; podem ser mais lentos para iniciar uma atividade; gostam do trabalho individual ou em dupla.
Percepção	<b>Sensoriais:</b> gostam de resolver problemas por meio de procedimentos bem estabelecidos e não apreciam complicações e surpresas; são pacientes com detalhes; memorizam fatos com facilidade; apreciam trabalhos de manipulação, experimentais, repetitivos (laboratório); tendem a ser práticos e cuidadosos; não gostam de disciplinas que não têm uma conexão aparente com o mundo real.
	<b>Intuitivos:</b> frequentemente preferem descobrir possibilidades e inter-relações; gostam de inovação e não apreciam a repetição; sentem-se confortáveis com abstrações e formulações matemáticas; são rápidos e criativos; não apreciam as disciplinas que envolvem muita memorização e cálculos rotineiros; apreciam a variedade.
Entrada	<b>Visuais:</b> lembram-se mais do que viram; substituem as palavras por símbolos; preferem as representações visuais — diagramas, quadros, cronogramas, gráficos, filmes e demonstrações; reconstróem imagens de diferentes modos.
	<b>Verbais:</b> tiram mais proveito das explicações escritas e faladas; gostam de ouvir e de tomar notas; materiais de apoio impressos são úteis para eles; repetem as palavras, falando ou escrevendo; fazem a leitura de suas notas em silêncio; transformam diagramas em palavras.
Compreensão	<b>Sequenciais:</b> avançam com entendimento parcial; ganham entendimento em passos lineares, com cada passo derivado do anterior; tendem a seguir caminhos lógicos e graduais na solução de um problema; têm facilidade para explicar; enfatizam a análise, os detalhes.
	<b>Globais:</b> aprendem em grandes saltos, absorvendo o material quase que aleatoriamente, sem enxergar conexões, e repentinamente compreendem tudo; precisam do contexto, do grande quadro; são hábeis para resolver rapidamente problemas complexos; têm facilidade para juntar elementos, de maneiras novas, uma vez que tenham enxergado o grande quadro, mas podem ter dificuldade para explicar como fizeram isso; o foco está na síntese, no pensamento sistêmico, holístico.

Fonte: Adaptado de [SILVA et al., 2013, p. 4](#).

O ILS abrange 44 questões objetivas (alternativa a ou b), sendo 11 para cada uma das 4 dimensões (Anexo A). As questões 1, 5, 9, 13, 17, 21, 25, 29, 33, 37 e 41 são relativas à dimensão Processamento, sendo a primeira

alternativa (letra "a") representante do valor Ativo e a segunda (letra "b") do valor Reflexivo. As questões 2, 6, 10, 14, 18, 22, 26, 30, 34, 38 e 42 referem-se à dimensão Percepção, sendo a primeira alternativa representante do valor Sensorial e a segunda alternativa representante do valor Intuitivo. As questões relativas à dimensão Entrada são a 3, 7, 11, 15, 19, 23, 27, 31, 35, 39 e 43, sendo que a primeira alternativa representa o valor Visual e a segunda o valor Verbal. As demais questões (4, 8, 12, 16, 20, 24, 28, 32, 36, 40 e 44) são relacionadas à dimensão Compreensão, sendo o valor Sequencial representado pela primeira alternativa e o valor Global pela segunda.

As respostas às questões do ILS fornecem duas pontuações, para cada uma das quatro dimensões, correspondentes aos dois estilos da dimensão. A diferença entre as duas pontuações indica, dentre os dois estilos, qual é aquele predominante/preferido pelo respondente, além de permitir conhecer a intensidade dessa preferência — que pode ser leve ou quase inexistente (pontuações 1 e 3), moderada (pontuações 5 e 7) ou forte (pontuações 9 e 11) para um ou outro estilo do par da dimensão.

Os estudos de [Zywno \(2003\)](#), [Felder e Spurlin \(2005\)](#) e [Litzinger et al. \(2007\)](#) concordam que o ILS é um instrumento confiável, válido e adequado para identificação dos EA, embora seja recomendado que continuem a ser realizadas pesquisas para avaliar a aplicação de tal instrumento.

Dentre as iniciativas de uso do modelo de Felder–Silverman que não utilizam o ILS, é possível citar as pesquisas de [Popescu, Trigano e Badica \(2007\)](#), [Graf, Kinshuk e Liu \(2008\)](#) e [Dorça et al. \(2013\)](#). Eles sugerem a utilização de métodos baseados na análise do comportamento implícito do estudante em sistemas de aprendizagem. [Graf, Kinshuk e Liu \(2008\)](#) consideram, dentre outras relações, que, se um aluno frequentemente visitou exercícios, há preferência por um estilo Ativo de aprendizagem. Nas pesquisas de [Dorça et al. \(2013\)](#) e [Popescu, Trigano e Badica \(2007\)](#), além da obtenção dos estilos, são realizadas atualizações dinamicamente, considerando o desempenho na avaliação de uma seção de aprendizagem ([DORÇA et al., 2013](#)) e regras como, por exemplo, um valor alto no número de postagens em fórum indica um estilo Ativo e Verbal ([POPESCU, TRIGANO e BADICA, 2007](#)).

## 2.3 Personalidade

Embora a compreensão da personalidade de um indivíduo seja uma das linhas de pesquisa mais antigas da Psicologia, não há um consenso para sua definição nessa área.

[Allport \(1937\)](#), pioneiro na publicação de um livro sobre personalidade, fez uma síntese e definiu a personalidade como “uma organização dinâmica, dentro do indivíduo, daqueles sistemas psicofísicos que determinam seus ajustamentos únicos ao ambiente” ([NATRIELLI FILHO, 2002](#)).

“O termo ‘organização dinâmica’ enfatiza o fato de que personalidade está constantemente se desenvolvendo e mudando, embora, ao mesmo tempo, exista uma organização ou sistema que une e relaciona os vários componentes da personalidade. O termo ‘psicofísico’ lembra que a personalidade não é nem exclusivamente mental nem exclusivamente neural.” ([NATRIELLI FILHO, 2002, p. 1](#))

Segundo [Garcia \(2006\)](#), a maioria dos teóricos desse conceito concorda em compreender a personalidade como um sistema no qual um conjunto de padrões inatos do indivíduo interage com o ambiente social — nas dimensões comportamentais, cognitivas e afetivas — para produzir ações e experiências de uma vida particular. [Garcia \(2006\)](#) também afirma que essa definição varia conforme a perspectiva utilizada, sendo estas, segundo Pervin e John (2001 *apud* [BRESSANE NETO, 2010](#)), as principais perspectivas existentes:

- Perspectiva Biológica: destaca como os fatores neuroquímicos e genéticos explanam a predisposição de indivíduos a determinados comportamentos.
- Perspectiva Cognitiva: enfatiza como as crenças, as experiências prévias, as aprendizagens anteriores, as histórias individuais, a interação com o ambiente — e a interpretação que é feita deste — moldam o comportamento e a personalidade.
- Perspectiva Humanista: destaca a experiência pessoal, os sentimentos e os valores básicos particulares dos indivíduos, sendo a personalidade considerada formada pela maneira individual com que cada sujeito observa e interpreta o mundo.
- Perspectiva Psicanalítica: explana a personalidade analisando como as forças do inconsciente, os desejos, os motivos e as necessidades físicas e biológicas influenciam os pensamentos, os sentimentos e os comportamentos.

- Perspectiva dos Traços: procura averiguar como as pessoas são diferentes (quais traços melhor as descrevem) e quanto elas diferem (o grau de variação nos traços) em relação às outras; os traços são as palavras utilizadas pelas pessoas para descrever a personalidade das outras (ou delas mesmas).

De acordo com [Bressane Neto \(2010, p. 15\)](#),

“Se um indivíduo precisar descrever outro, provavelmente não se aprofundará em questões biológicas, de interpretação do ambiente ou conflitos do inconsciente, mas provavelmente descreverá a pessoa como sendo extrovertida ou introvertida, impulsiva ou conservadora ou utilizando alguma outra característica. (...) Por ser fundamentalmente descritiva, a abordagem dos traços oferece maneiras de quantificar e classificar a personalidade em traços por meio de testes experimentais e observações”.

Nesse sentido, a perspectiva dos Traços de Personalidade (TP) tem sido a mais frequentemente aplicada à representação de personalidade, uma vez que é a mais facilmente mensurável de forma explícita em humanos por meio de computadores ([NUNES, 2009](#); [NUNES, 2012](#)).

Os pioneiros a tentar determinar o número de traços necessários para a descrição de uma pessoa foram os psicólogos norte-americanos [Allport e Obdert \(1936\)](#), da Universidade de Harvard. Utilizando o dicionário “*Webster’s New International Dictionary (second edition, 1934)*”, eles marcaram todas as palavras que podiam ser empregadas para descrever TP — foram marcadas aproximadamente 18.000 palavras e, após a retirada dos sinônimos, permaneceram pouco mais de 4.500 adjetivos. Esse estudo influenciou muitos pesquisadores a construir modelos visando a determinar o número de traços necessários para classificar a personalidade de um indivíduo ([MATTHEWS, DEARY e WHITEMAN, 2003](#); [BRESSANE NETO, 2010](#); [URSO JUNIOR, 2011](#)).

As teorias de personalidade baseadas em traços contribuíram fundamentalmente para o desenvolvimento gradual do Modelo dos Cinco Grandes Fatores, considerado um modelo universal para explicar as diferenças individuais ([MCCRAE e COSTA, 1997](#); [URSO JUNIOR, 2011](#)).

O modelo dos Cinco Grandes Fatores (CGF) da personalidade — também conhecido internacionalmente como *Five Factor Model* ou *Big Five* ([JOHN e SRIVASTAVA, 1999](#)) — é, de acordo com [Nunes \(2012\)](#), uma versão moderna da Teoria do Traço.

Os CGF, em português, podem ser definidos como: Extroversão, Socialização (ou Amabilidade), Realização (ou Conscientização, ou

Conscienciosidade), Neuroticismo (ou Instabilidade Emocional) e Abertura (ou Abertura à Mudança, ou Abertura à Experiência).

Com base nas pesquisas de [Costa e Widiger \(2002\)](#), [Costa e McCrae \(2007\)](#), [Nunes, Hutz e Nunes \(2010\)](#) e [Rabelo \(2013\)](#), é possível realizar as seguintes considerações relativas a cada um dos CGF:

- **Extroversão (*Extraversion*):** refere-se às formas como os indivíduos interagem com os outros, indicando o quanto são comunicativos, falantes, ativos, assertivos, responsivos e gregários. Índices altos tendem, portanto, a representar pessoas mais sociáveis, ativas, falantes, otimistas, alegres, bem dispostas e cordiais. Entretanto, índices baixos não representam necessariamente pessoas infelizes, não amistosas ou pessimistas, mas tendem a representar pessoas reservadas, introvertidas, sóbrias, indiferentes, independentes e quietas. O fator Extroversão contempla estas facetas: Acolhimento, Gregarismo, Assertividade, Atividade, Busca de sensações, e Emoções positivas.
- **Socialização ou Amabilidade (*Agreeableness*):** refere-se à qualidade das relações interpessoais dos indivíduos e aos tipos de interações que um indivíduo apresenta — predisposição para ser amistoso, para sensibilizar-se com a situação alheia, para colocar-se no lugar do outro, para demonstrar gentileza, complacência, compaixão. Índices altos tendem, portanto, a representar pessoas generosas, amáveis, afetuosas, prestativas e altruístas, com tendência à responsabilidade e empatia, e que acreditam que a maioria das outras pessoas agirá da mesma forma. Por outro lado, índices baixos tendem a representar pessoas petulantes, não cooperativas, facilmente irritáveis, e que podem apresentar-se de maneira manipuladora, vingativa e insensível. O fator Socialização contempla estas facetas: Confiança, Franqueza, Altruísmo, Complacência, Modéstia, Sensibilidade.
- **Realização ou Conscientização/Conscienciosidade (*Conscientiousness*):** refere-se ao grau de organização e condução de tarefas, à persistência, à motivação, ao controle e ao autocontrole, em termos de planejamento, apresentados pelos indivíduos. Índices altos tendem, portanto, a representar pessoas mais organizadas,

confiáveis, trabalhadoras, determinadas, pontuais, meticulosas, ambiciosas e persistentes. Índices baixos tendem a representar pessoas preguiçosas, descuidadas, desorganizadas, negligentes, que não têm objetivos claros, e que tendem a ter pouco comprometimento e responsabilidade diante de tarefas. O fator Realização contempla estas facetas: Competência, Ordem, Senso de dever, Esforço por realizações, Autodisciplina, Ponderação.

- **Neuroticismo (*Neuroticism*) ou Instabilidade Emocional:** refere-se à tendência cotidiana dos indivíduos a experimentar padrões emocionais vinculados a desconforto psicológico (aflição, angústia, culpa, medo, nojo, raiva, sofrimento, tristeza, vergonha, entre outros), além de referir-se à ansiedade excessiva, à pouca habilidade para conter impulsos e para lidar com o estresse, à propensão a ideias dissociadas da realidade (irracionais), e à dificuldade para tolerar a frustração causada pela não realização de desejos. Índices altos tendem, portanto, a representar pessoas predispostas a vivenciar mais profundamente o seu sofrimento emocional. Por outro lado, índices baixos tendem a representar pessoas mais tranquilas, relaxadas, constantes, menos agitadas, com habilidade maior em lidar com situações estressantes e, em síntese, com estabilidade emocional. O fator Neuroticismo contempla estas facetas: Ansiedade, Hostilidade, Depressão, Embaraço, Impulsividade, Vulnerabilidade ao estresse.
- **Abertura (*Openness*) – Abertura à Mudança ou Abertura à Experiência:** refere-se aos comportamentos exploratórios, ao reconhecimento da importância de ter novas experiências, à imaginação ativa, à sensibilidade estética, à curiosidade intelectual e à preferência pela variedade. Índices altos tendem, portanto, a representar pessoas curiosas, criativas, imaginativas, que se divertem com novas ideias, que costumam apresentar valores não convencionais, que experimentam intensamente uma gama ampla de emoções. Por outro lado, índices baixos tendem a representar pessoas convencionais, dogmáticas, rígidas nas suas crenças e atitudes, conservadoras nas suas preferências e menos responsivas emocionalmente. O fator Abertura contempla estas facetas: Fantasia, Estética, Sentimentos, Ações variadas, Ideias, Valores.

No Quadro 2, são apresentados adjetivos característicos dos CGF.

**Quadro 2. Adjetivos característicos dos Cinco Grandes Fatores de Personalidade.**

	<b>Extroversão</b>	<b>Socialização</b>	<b>Realização</b>	<b>Neuroticismo</b>	<b>Abertura</b>
<b>Polo do rótulo</b>	Ativo Aventureiro Barulhento Energético Entusiástico Exibido Sociável Tagarela	Altruísta Amigável Carinhoso Confiante Cooperativo Gentil Sensível Simpático	Confiável Consciente Eficiente Minucioso Organizado Prático Preciso Responsável	Ansioso Apreensivo Emotivo Instável Nervoso Preocupado Temeroso Tenso	Artístico Curioso Engenhoso Esperto Imaginativo Inteligente Original Sofisticado
<b>Polo oposto</b>	Acanhado Introvertido Quieto Reservado Silencioso Tímido	Antipático Brigão Bruto Crítico Frio Insensível	Desatento Descuidado Desorganizado Distraído Imprudente Irresponsável	Calmo Contido Estável Indiferente Serenos Tranquilo	Comum Simples Superficial Tolo Trivial Vulgar

Fonte: [NUNES, 2012, p. 119.](#)

[McDougall \(1932\)](#) é considerado o precursor teórico não empírico da abordagem do *Big Five*, embora esse modelo só tenha sido impulsionado quando começaram a comprovar, por meio de pesquisas empíricas, a existência de cinco traços básicos de personalidade em indivíduos de diversos países e diferentes culturas e faixas etárias ([BRESSANE NETO, 2010](#); [URSO JUNIOR, 2011](#)).

Para realizar essas pesquisas, foram criados alguns questionários visando a delinear um perfil adequado da personalidade de um indivíduo no *Big Five*, sendo o principal deles o NEO-PI-R (*Revised NEO Personality Inventory*), desenvolvido por [Costa e McCrae \(1992\)](#), com 240 questões de múltipla escolha ([BRESSANE NETO, 2010](#)). Este instrumento foi devidamente traduzido para idiomas de cinco famílias linguísticas distintas, tendo sido estatisticamente validado considerando uma diversidade cultural de amostras, o que corrobora com a ideia da universalidade da perspectiva dos TP ([MCCRAE e COSTA, 1997](#); [URSO JUNIOR, 2011](#)). O NEO-PI-R permite avaliar os 5 fatores do *Big Five* e as 6 facetas de cada um deles, sendo um inventário comercial, com direitos autorais, sem poder ser usado livremente por outros cientistas ([NUNES, 2009](#)).

Uma alternativa de custo livre ao NEO-PI-R é o NEO-IPIP (*NEO International Personality Item Pool*) com 300 itens ([JOHNSON, 2000](#)), sendo 60 para cada um dos fatores do *Big Five* (10 para cada faceta). Cada item possui uma afirmativa, a qual o respondente atribui um valor de concordância do quanto essa afirmativa o representa em uma escala tipo *Likert* de cinco pontos.

Além desses questionários, há vários outros, sendo pertinente citar o NEO-FFI (*NEO Five-Factor Inventory*), com 60 itens ([COSTA e MCCRAE, 1992](#)), versão

reduzida do NEO-PI-R, e o TIPI (*Ten-Item Personality Inventory*), com 10 itens ([GOSLING, RENTFROW e SWANN, 2003](#)), versão bastante reduzida do NEO-IPIP.

Uma interface possível ao NEO-IPIP e TIPI, com versão também em português, é apresentada por [Nunes, Moraes e Reinert \(2010\)](#), intitulada *Personality Inventory PV1.0*. [Nunes \(2012\)](#) afirma que quando a extração da personalidade não for o tópico primário de interesse na pesquisa, o uso do inventário TIPI (Anexo B deste documento) é uma boa alternativa.

Embora a técnica mais comum para extrair informações sobre a personalidade humana seja a partir dos tradicionais inventários, a melhor forma de obtenção dos TP seria a utilização de abordagens que não exigissem esforço cognitivo por parte dos usuários, como, por exemplo, padrão de digitação ([JAQUES e NUNES, 2012](#)).

Nesse contexto menos invasivo, algumas pesquisas, a exemplo de [Mairesse et al. \(2007\)](#) e [Tausczik e Pennebaker \(2009\)](#), mostram que há correlação entre o *Big Five* e características linguísticas encontradas em textos. Dentre as pesquisas mais recentes, é possível citar [Bachrach et al. \(2012\)](#), [Markovikj et al. \(2013\)](#) e [Schwartz et al. \(2013\)](#), que descrevem que TP possuem correlação com padrões de uso da rede social Facebook, podendo facilitar a detecção de personalidade com a mineração dos dados dos perfis de usuário dessa rede social.

Na pesquisa de [Schwartz et al. \(2013\)](#), por exemplo, foram analisados 700 milhões de palavras, frases e tópicos coletados de 75 mil voluntários usuários do Facebook, que também responderam ao NEO-IPIP. A acurácia foi de 91,9%. Com base nesse estudo, foi desenvolvida uma ferramenta *online* de análise semântica das postagens do Facebook, Five Labs, disponibilizada pela *startup* americana Five ([FIVE, 2015](#)).

## **2.4 Sistemas de Recomendação**

Em meio à sobrecarga de informação aliada à evolução da Web, surgiram os SR, coletando informações sobre as preferências de seus usuários para um conjunto de itens (a exemplo de filmes, músicas e materiais educacionais), objetivando auxiliar os usuários no processo de busca e acesso a informações relevantes ([RICCI et al., 2011](#), [BOBADILLA et al., 2013](#); [AGUIAR et al., 2014](#)).

Há casos em que os SR retornam todos os itens considerados relevantes e

outros casos em que são retornados apenas aqueles mais relevantes. Além disso, é possível que os SR recomendem os itens sequencialmente, sendo a ordem importante ([HERLOCKER et al., 2004](#)).

Segundo [Bobadilla et al. \(2013\)](#), o processo para gerar recomendações em SR baseia-se em definir o algoritmo de filtragem a ser utilizado, as técnicas empregadas, o modelo escolhido (com base, por exemplo, na utilização direta de dados — *memory-based* — ou em um modelo gerado usando esses dados — *model-based*), a qualidade desejada dos resultados (a exemplo de cobertura e precisão), entre outros aspectos. Nas subseções seguintes são abordados conceitos relevantes ao entendimento da pesquisa ora descrita.

## **2.4.1 Técnicas de Recomendação**

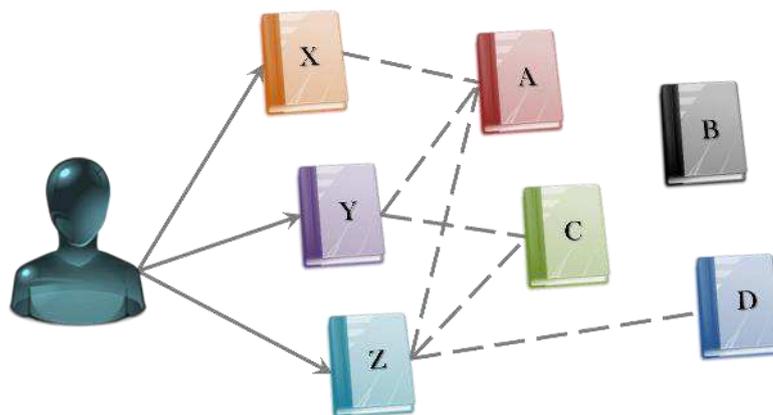
Várias técnicas têm surgido para identificar padrões de comportamento e utilizá-los na personalização do relacionamento com os usuários. Dentre essas técnicas, as mais conhecidas são a Filtragem Baseada no Conteúdo (FBC) e a Filtragem Colaborativa (FC).

### **2.4.1.1 Filtragem Baseada no Conteúdo**

O processo de recomendação que emprega Filtragem Baseada no Conteúdo (FBC) utiliza informações anteriores do usuário em relação a um item para recomendar itens similares. Esses itens são comparados com base em características definidas a eles associadas. Em um SR que utiliza FBC, serão recomendados, por exemplo, os produtos mais parecidos com aqueles avaliados anteriormente de forma positiva ([BURKE, 2002](#); [CAZELLA, NUNES e REATEGUI, 2010](#); [COSTA, AGUIAR e MAGALHÃES, 2013](#)).

Na Figura 2, é exemplificada a ideia da técnica de FBC. Considerando-se que (i) o usuário-alvo leu e avaliou bem os livros X, Y e Z; (ii) o livro A possui características que se assemelham a todos eles; (iii) o livro B não possui informações semelhantes a nenhum deles; (iv) o livro C se assemelha aos livros Y e Z; e (v) o livro D se assemelha apenas ao livro Z, pode-se inferir, portanto, que o livro A é o mais adequado a se recomendar ao usuário-alvo, enquanto o livro B é o menos adequado. Dependendo do SR, também podem ser recomendados os livros C e D, sendo, neste exemplo, C o segundo livro mais adequado a se recomendar ([COSTA, AGUIAR e MAGALHÃES, 2013](#)).

**Figura 2. Representação da abordagem de FBC.**



Fonte: Adaptado de [COSTA, AGUIAR e MAGALHÃES, 2013, p. 60.](#)

A técnica TF-IDF (*Term-Frequency - Inverse-Document-Frequency*) ([SALTON e BUCKLEY, 1988](#)) é uma das mais utilizadas para FBC quando o conteúdo é textual. Para usá-la, o perfil do usuário deve conter palavras-chave que descrevem suas preferências, assim, cada texto dos itens da base de dados é comparado com essas palavras-chave, considerando a frequência destas nos textos dos itens.

[Adomavicius e Tuzhilin \(2005\)](#), em relação à FBC, apontam a limitação na análise de conteúdo de dados pouco estruturados, além da complexidade existente na extração/análise de conteúdo não textual (multimídia, por exemplo). Outra dificuldade consiste em analisar a semântica de textos que, mesmo contendo termos semelhantes, podem ter qualidades distintas ([COSTA, AGUIAR e MAGALHÃES, 2013](#)).

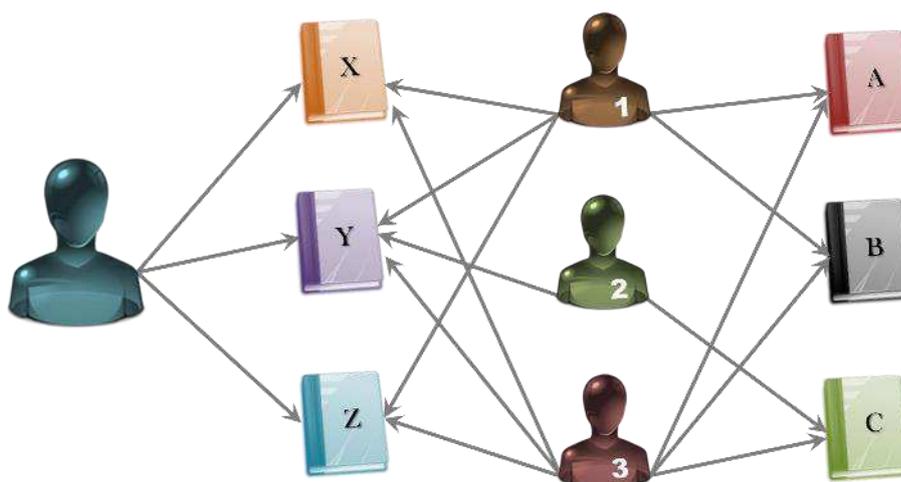
#### **2.4.1.2 Filtragem Colaborativa**

O processo de recomendação que emprega Filtragem Colaborativa (FC) baseia-se em como os seres humanos têm tomado decisões ao longo da história das civilizações, ao considerar o julgamento de usuários com interesses em comum. Na FC, com as avaliações dos itens pelos usuários do sistema, é possível descobrir médias para os itens e, assim, sugerir os itens mais bem avaliados por usuários com preferências similares, não sendo necessário compreender ou reconhecer as características dos itens ([CAZELLA, NUNES e REATEGUI, 2010](#); [BOBADILLA et al., 2013](#); [COSTA, AGUIAR e MAGALHÃES, 2013](#)).

Na Figura 3, é exemplificada a ideia da técnica de FC. Considere que (i) o usuário-alvo avaliou positivamente os livros X, Y e Z, (ii) o usuário 1, além

desses, também avaliou positivamente os livros A e B, (iii) o usuário 2 avaliou positivamente os livros Y e C, e (iv) o usuário 3 avaliou positivamente os livros X, Y e Z, além dos livros A, B e C. Os usuários 1 e 3, portanto, são os usuários com as preferências mais similares ao usuário-alvo. Dessa forma, os livros A e B são os mais adequados para serem recomendados a este usuário ([COSTA, AGUIAR e MAGALHÃES, 2013](#)).

**Figura 3. Representação da abordagem de FC baseada em vizinhos mais próximos.**



**Fonte:** Adaptado de [COSTA, AGUIAR e MAGALHÃES, 2013, p. 61](#).

A abordagem exemplificada na Figura 3 remete ao algoritmo clássico dos  $k$  vizinhos mais próximos (*K-Nearest Neighbors* — KNN), baseado em memória (*memory-based*), utilizando-se diretamente as avaliações dos usuários. O algoritmo KNN pode ser baseado em usuários (UserKNN) ou em itens (ItemKNN). Exemplificando com base no usuário, a técnica KNN consiste em (i) calcular a similaridade do usuário alvo em relação aos outros usuários; (ii) selecionar um grupo de usuários com maiores similaridades para considerar na predição; e (iii) normalizar as avaliações e computar as predições, ponderando as avaliações dos usuários mais similares ([CAZELLA, NUNES e REATEGUI, 2010](#); [COSTA, AGUIAR e MAGALHÃES, 2013](#)).

Para o cálculo da similaridade, dentre as métricas mais utilizadas, destaca-se a Medida dos Cossenos, que calcula o cosseno do ângulo formado pelos dois vetores que representam os perfis de usuário. O valor do cosseno calculado indica a similaridade entre os usuários, variando de 0 (zero) a 1 (um) — quanto mais próximo a 0, menos similares são os perfis dos usuários; quanto mais próximo a 1, mais similares ([COSTA, AGUIAR e MAGALHÃES, 2013](#)). A Equação 1

representa a Medida dos Cossenos.

$$S_{a,b} = \frac{\sum_{i=1}^m (w_{a,i} \times w_{b,i})}{\sqrt{\sum_{i=1}^m (w_{a,i})^2} \times \sqrt{\sum_{i=1}^m (w_{b,i})^2}}, \quad (1)$$

em que:

- $S_{a,b}$  representa o cálculo do cosseno entre o usuário-alvo  $a$  e um determinado usuário  $b$ ;
- $w_{a,i}$  indica a avaliação do usuário  $a$  para o item  $i$ ;
- $w_{b,i}$  indica a avaliação do usuário  $b$  para o mesmo item; e
- $m$  indica a quantidade de itens.

Uma abordagem de FC baseada em modelo (*model-based*), para redução de dimensionalidade e visando ao melhor desempenho, é conhecida como Fatoração de Matrizes (*Matrix Factorization* — MF). Uma técnica de MF é o *Ranking* Personalizado Bayesiano (*Bayesian Personalized Ranking* — BPR) ([RENDLE et al., 2009](#)).

As limitações em relação aos sistemas colaborativos referem-se especialmente à coleta de informações dos usuários, destacando-se os problemas de: (i) primeiro avaliador, uma vez que um novo item não é recomendado até que usuários o avaliem; (ii) pontuações esparsas, em casos de sistemas com pequeno número de usuários e grande número de itens; e (iii) usuário com preferências muito diferentes, dado que as recomendações para ele podem ser fracas pela escassez de usuários com preferências similares ([ADOMAVICIUS e TUZHILIN, 2005](#); [COSTA, AGUIAR e MAGALHÃES, 2013](#)).

#### **2.4.1.3 Filtragem Híbrida e Outras Técnicas de Recomendação**

Segundo [Bobadilla et al. \(2013\)](#), a evolução dos SR mostra a importância de técnicas híbridas, que combinam duas ou mais técnicas diferentes, a fim de resolver as limitações e obter as vantagens de cada uma delas. No artigo clássico de [Burke \(2002\)](#), são apresentados os seguintes métodos de hibridização.

- Ponderado (*Weighted*): As pontuações de várias técnicas de recomendação são combinados para produzir uma única recomendação.
- Alternado (*Switching*): O sistema alterna entre técnicas de recomendação, dependendo da situação atual.
- Misto (*Mixed*): Recomendações de vários recomendadores diferentes

são apresentados ao mesmo tempo.

- Combinação de característica (*Feature combination*): Características de fontes de dados de recomendações diferentes são unidas em um único algoritmo de recomendação.
- Cascata (*Cascade*): Um recomendador refina as recomendações dadas por outro, reordenando os itens recomendados.
- Melhora de característica (*Feature augmentation*): A saída de uma técnica é utilizada como uma característica de entrada para outra.
- Meta-nível (*Meta-level*): O modelo aprendido por um recomendador é usado como entrada para outro.

Além de abordar a Filtragem Híbrida e as técnicas de FBC e FC, [Burke \(2002\)](#) definiu a Filtragem Demográfica, a Filtragem Baseada em Conhecimento e a Filtragem Baseada em Utilidade.

A Filtragem Demográfica é baseada nas descrições de indivíduos — geralmente requisitadas por meio de formulários de registro — para caracterizá-los como usuários do sistema, a serem estereotipados em classes, sendo assim possível relacionar os itens aos tipos de pessoas no sistema. A Filtragem Baseada em Conhecimento é realizada ao inferir as preferências do usuário e suas necessidades por meio de conhecimento estruturado de forma funcional. A Filtragem Baseada em Utilidade é fundamentada na utilidade dos itens para um determinado usuário ([BURKE, 2002](#); [CAZELLA, NUNES e REATEGUI, 2010](#)).

[Gonzalez, De La Rosa e Montaner \(2007\)](#), ao expandir a categorização de [Burke \(2002\)](#), propuseram uma filtragem envolvendo aspectos psicológicos do usuário, tais como Inteligência Emocional e Interação Social, combinados aos aspectos caracterizadores dos itens. [Nunes \(2009\)](#), por sua vez, expandiu este modelo, apresentando a Personalidade do usuário como um fator relevante no processo de recomendação. Esse estudo foi o primeiro a usar TP para recomendar produtos, serviços ou pessoas em SR, revelando indícios de que o uso de TP efetivamente proporciona uma melhoria na recomendação ([NUNES, 2008](#); [NUNES, 2009](#)).

Conforme afirma [Cazella, Nunes e Reategui \(2010\)](#), a recomendação baseada em Personalidade é aplicada geralmente de forma híbrida, em conjunto de outra técnica, como a FC e/ou FBC. Além disso, é importante destacar que, para que seja viável esse tipo de recomendação, é preciso definir como representar a personalidade do usuário, a exemplo do uso do modelo dos Cinco

Grande Fatores (Seção 2.3). Depois de obtida a personalidade dos usuários, a recomendação, de acordo com [Quan \(2013\)](#), pode ser realizada de duas formas: (1) encontro dos vizinhos mais próximos com base na personalidade do usuário; e (2) recomendação baseada em uma matriz característica-item. O estudo de [Quan \(2013\)](#) demonstra que as abordagens tradicionais de FC baseada no Usuário (*User-Based Collaborative Filtering* — UBCF) e FC baseada no Item (*Item-Based Collaborative Filtering* — IBCF), considerando o domínio de filmes, tiveram desempenho pior que as abordagens baseadas na personalidade do usuário (*User Personality-Based Collaborative Filtering* e *Character-Item Collaborative Filtering*).

Além dessas técnicas, é importante comentar a possibilidade de recomendar itens de forma não personalizada, ou seja, os itens são recomendados da mesma forma para todos os usuários, com base em alguma regra pré-definida, a exemplo da estratégia aleatória.

Um algoritmo bastante útil e conhecido que utiliza recomendação não personalizada é o Mais Popular (*Most Popular* — MP) que, como o nome sugere, se baseia na popularidade dos itens, sendo recomendados a todos os usuários do sistema os itens mais bem avaliados pela maioria.

Embora técnicas de recomendação personalizada demonstrem ser mais eficientes em muitos contextos, a recomendação não personalizada — principalmente a estratégia de popularidade de itens — pode ser encontrada em combinação com técnicas de recomendação personalizada em muitos SR baseados em filtragem híbrida.

## **2.4.2 Avaliação de Sistemas de Recomendação**

Visando a melhorar os métodos e tecnologias em SR, os pesquisadores usam métricas de Recuperação de Informação para avaliar as predições/recomendações ([BOBADILLA et al., 2013](#)).

O artigo clássico de [Herlocker et al. \(2004\)](#) trata da avaliação em SR, sendo apresentadas categorias de métricas. A partir das métricas de acurácia de predição, é possível analisar as diferenças entre as pontuações reais e as previstas pelo SR para os itens — e. g., MAE (*Mean Absolute Error*), RMSE (*Root of Mean Square Error*) e NMAE (*Normalized Mean Absolute Error*). Por outro lado, a partir das métricas de acurácia de classificação, é possível medir quão

relevante para o usuário é o conjunto de itens recuperados/recomendados pelo SR — e. g., Precisão (*Precision*), Cobertura (*Recall*), MAP (*Mean Average Precision*), AUC (*Area Under ROC Curve*), NDCG (*Normalized Discounted Cumulative Gain*) e MRR (*Mean Reciprocal Rank*) ([BARTH, 2013](#)).

Precisão é a proporção dos itens recuperados que são relevantes em relação ao total de itens recuperados. Cobertura é a razão entre o número de itens recuperados que são relevantes e o total dos itens na coleção que são relevantes. Supondo que o conjunto de itens relevantes e o conjunto de itens recuperados são conhecidos, estas medidas podem ser representadas pelas Equações 2 e 3.

$$precisao = \frac{|relevantes \cap recuperados|}{|recuperados|} \quad (2)$$

$$cobertura = \frac{|relevantes \cap recuperados|}{|relevantes|} \quad (3)$$

As notações P@n (*Precision at n*) e R@n (*Recall at n*) são utilizadas para considerar o uso, respectivamente, da Precisão e da Cobertura para as  $n$  recomendações mais relevantes, uma vez que os usuários de SR, em geral, dão enfoque aos primeiros itens apresentados.

A métrica MAP consiste em sumarizar todos os valores P@n. Nesta abordagem, é definida uma média (denominada *Average Precision*) para todos os valores de P@n para todos os documentos relevantes. O valor de MAP é a média das *Average Precision*.

A métrica AUC consiste na área sob a curva ROC (*Receiver Operating Characteristic*), que é equivalente à probabilidade de que o sistema será capaz de escolher o item relevante, dados dois itens definidos aleatoriamente (um extraído dentre os itens relevantes e o outro extraído dentre os itens não relevantes).

As métricas NDCG e MRR são utilizadas para avaliar conjuntos de itens ordenados. A métrica NDCG considera a relevância dos itens e a sua posição na lista ordenada. A partir da métrica MRR, avalia-se se o primeiro elemento recuperado de uma lista é um elemento relevante.

Essas métricas de avaliação são geralmente empregadas para comparar as novas propostas com os modelos de recomendação existentes, sendo muitas vezes utilizados conjuntos de dados clássicos para treinar e testar esses modelos. Em alguns contextos, ainda são poucos os conjuntos de dados disponíveis, sendo apresentados no estudo de [Özgöbek, Shabib e Gulla \(2014\)](#)

alguns dos conjuntos de dados comuns para avaliar SR de propósito geral — *MovieLens*, *Netflix* e *MoviePilot* (no domínio de filmes), *Million Song* e *Last.fm* (no domínio de músicas), *Jester* (no domínio de piadas), *Book-Crossing* (no domínio de livros), *YOW* (no domínio de notícias).

O processo de validação é frequentemente realizado empregando métodos como *Holdout*, *Random Subsampling* e *K-fold Cross-validation*. Em síntese, o método *Holdout* consiste na separação aleatória dos dados em dois subconjuntos mutuamente exclusivos (um para treinar o modelo e outro para testá-lo). O método *Random Subsampling* é uma variação do método *Holdout*, sendo o processo repetido por  $k$  vezes. O *K-fold Cross-validation* consiste em dividir os dados em  $k$  subconjuntos mutuamente exclusivos do mesmo tamanho, sendo um subconjunto utilizado para teste e os subconjuntos restantes utilizados para treinamento — este processo é realizado  $k$  vezes alternando o subconjunto de teste ([HAN e KAMBER, 2006](#)).

### **2.4.3 Sistemas de Recomendação Educacionais**

Com a consolidação da Web como meio de apoio ao processo de ensino-aprendizagem, a quantidade de recursos educacionais disponíveis para estudantes e professores tende a crescer. A partir desse contexto, além de ser desafiador selecionar e organizar os diversos recursos educacionais que vão surgindo, é ainda mais desafiador quando se pretende identificar e recomendar materiais personalizados, baseando-se em necessidades individuais de cada aluno, além de interesses e competências a serem desenvolvidos ([CAZELLA, REATEGUI e BEHAR, 2010](#); [COSTA, AGUIAR e MAGALHÃES, 2013](#)).

Os Sistemas de Recomendação Educacionais (SRE) podem recomendar diversos tipos de materiais didáticos (textos, vídeos, etc.), auxiliando tanto alunos quanto professores ([AGUIAR et al., 2014](#)).

Recentemente, [Drachsler et al. \(2015\)](#) realizaram um estudo analisando a área de SR na Aprendizagem Apoiada por Tecnologia (*Recommender Systems in TEL — Technology Enhanced Learning*), ao longo de 15 anos (2000–2014), e identificando os desafios atuais. Foram investigados 82 SRE, de 35 países (indicados na Figura 4).

**Figura 4. Países que pesquisam na área de SR em TEL.**



Fonte: [DRACHSLER et al., 2015, p. 3.](#)

Os SRE, segundo [Drachsler et al. \(2015\)](#), foram classificados nestes 7 grupos: (1) SRE que seguem as abordagens de FC como em outros domínios; (2) SRE que propõem melhorias às abordagens de FC, levando em conta as particularidades do domínio TEL; (3) SRE que consideram restrições explicitamente educacionais como uma fonte de informação para o processo de recomendação; (4) SRE que exploram outras alternativas às abordagens de FC; (5) SRE que consideram a informação contextual dentro de cenários TEL para melhorar o processo de recomendação; (6) SRE que avaliam o impacto educacional das recomendações entregues; e (7) SRE que focam em recomendar cursos (em vez de recursos dentro deles).

Após a análise do estado da arte, [Drachsler et al. \(2015\)](#) perceberam que o campo está em movimento e novas abordagens de pesquisa estão surgindo. Por exemplo, inicialmente eram usados conjuntos de dados muito pequenos e internos. Entretanto, estudos mais recentes aplicam conjuntos de dados de referência maiores antes de implementar os sistemas em um cenário real. Além disso, a comunidade de pesquisa tenta fazer conjuntos de dados disponíveis para outros pesquisadores e usar adicionalmente conjuntos de dados de referência que estão disponíveis publicamente para tornar os resultados de seus estudos mais comparáveis.

Segundo [Drachsler et al. \(2015\)](#), *Encontrar bons itens é a tarefa mais*

aplicada em SRE. Mas *Recomendação de sequência de itens*, que tem como objetivo criar um caminho eficaz e eficiente de aprendizagem por meio de conteúdos digitais, é também uma tarefa importante executada. Além da recomendação de conteúdos de aprendizagem, os autores destacam a *Recomendação de outros alunos*, os chamados pares (*peers*), que seguem metas de aprendizagem semelhantes ou têm o mesmo interesse que o aluno-alvo. Além dessas tarefas, algumas das novas tarefas que aparecem nos últimos anos são *Prever desempenho de aprendizagem* e *Recomendar atividade de aprendizagem*.

Em relação à Personalização, [Drachsler et al. \(2015\)](#) afirmam que as abordagens de FC e baseadas em regras ainda são as técnicas mais utilizadas, apesar de FBC e das abordagens híbridas, que começaram a ser relatadas em 2008, serem, até hoje, cada vez mais adotadas. Além dessas, os autores expõem também que há um interesse crescente em abordagens baseadas em grafo e baseadas em conhecimento.

Vale destacar que um aspecto que difere bastante os SR de recursos educacionais, em relação a outros, é a forma de avaliá-los. Há vários conjuntos de dados com características específicas disponíveis que são usados como referência para avaliar novos modelos de recomendação — a exemplo dos conjuntos de dados Jester e MovieLens. Todavia, em se tratando de SR voltados para o processo de ensino-aprendizagem, não há muitos conjuntos de dados de referência e há pouca padronização dos procedimentos de avaliação ([MANOUSELIS et al., 2012](#)).

No contexto brasileiro, [Aguilar et al. \(2014\)](#) afirmam que aproximadamente 30% das publicações que abordam iniciativas em SRE não apresentam características detalhadas das avaliações dos modelos propostos.

[Drachsler et al. \(2015\)](#) defendem que as pesquisas sobre SRE deveriam seguir um método de avaliação padronizado, como estes quatro passos sugeridos por [Manouselis et al. \(2012\)](#): (i) uma seleção de conjuntos de dados que se adequam ao problema de recomendação e às tarefas do desenvolvimento; (ii) um estudo de comparação *offline* de diferentes algoritmos em relação aos conjuntos de dados selecionados, incluindo conjuntos de dados conhecidos para compreender o desempenho dos algoritmos de recomendação; (iii) um estudo abrangente do usuário em um ambiente experimental controlado para testar os efeitos psico-educativos em relação aos alunos, bem como testar os aspectos técnicos do SR projetado; e (iv) a implantação do SR em uma aplicação real, na

qual possa ser testado em condições operacionais realistas/normais com seus usuários legítimos.

É importante que esses quatro passos sejam publicados junto com uma descrição completa do SR, sendo declarado e acessível ao público o conjunto de dados utilizado, permitindo que outros pesquisadores repitam e ajustem qualquer parte da pesquisa para obter resultados comparáveis e novas ideias ([DRACHSLER et al., 2015](#)).

## 2.5 Considerações Finais do Capítulo

Neste capítulo, foram apresentados conceitos relevantes ao contexto da pesquisa.

Em relação à categorização dos OA, dentre os padrões existentes, é utilizado o padrão de metadados IEEE LOM.

Em relação às teorias sobre as particularidades na forma de aprendizagem dos aprendizes, é utilizado o modelo de Felder–Silverman, sendo empregado o inventário ILS de [Felder e Soloman \(1999\)](#). As justificativas para adotar esse instrumento de mensuração de EA foram: (i) acesso livre e sem custos, disponibilizado via Web em diversos idiomas; (ii) preenchimento fácil e simples, (iii) confiabilidade e validade, sendo amplamente utilizado em pesquisas anteriores, e (iv) não necessidade de implantação do modelo em um AVA para extrair os EA a partir do comportamento dos alunos no ambiente.

Em relação à personalidade, foram analisados inicialmente os testes psicológicos aprovados para uso no Sistema de Avaliação de Testes Psicológicos (SATEPSI<sup>1</sup>), uma vez que estes testes são validados, traduzidos e consideram a realidade brasileira. Entretanto, tais testes são, em geral, disponíveis apenas para psicólogos (e/ou sendo necessário comprá-los). Foi julgado mais viável para a pesquisa o uso do modelo *Big Five*. Embora o inventário TIPI seja simplificado, ele é bastante questionado e inventários maiores são dispendiosos. Com isso, decidiu-se pelo uso da ferramenta *online*, Five Labs, via Facebook, para automatizar o processo de extração.

Embora a existência de um perfil no Facebook possa ser vista como uma

---

<sup>1</sup> O SATEPSI é um sistema sob responsabilidade do Conselho Federal de Psicologia (CFP) para divulgar informações sobre os testes psicológicos à comunidade e aos psicólogos. Disponível em: <<http://satepsi.cfp.org.br/>>. Acesso em: 09 ago. 2015.

limitação, essa rede social é bastante popular, como apontado em pesquisa realizada entre 2012 e 2013 pela *Quacquarelli Symonds* (VANOZZI e BRIDGESTOCK, 2013 *apud* [PEREIRA et al., 2014](#)) — com base em 918 entrevistados de 26 países distribuídos pela África, América, Ásia e Europa, o uso do Facebook entre estudantes varia entre 78 e 96%, sendo a América Latina a região que mais o utiliza.

Vale destacar que há estudos sobre a correlação entre EA e Personalidade ([KURI, 2004](#); [SENRA, 2009](#); [ZONASH e NAQVI, 2011](#); [RAJU e VENUGOPAL, 2014](#)), indicando boas correlações entre alguns aspectos de Personalidade e algumas dimensões de EA. Uma vez que não foram encontradas pesquisas que indicassem forte correlação entre os TP do *Big Five* e as dimensões de EA de Felder–Silverman, nem foram obtidos bons resultados na investigação empírica realizada (ver Seção 5.1), ambos os conceitos (Personalidade e EA) foram considerados separadamente na construção do perfil do usuário, exposto no Capítulo 4.

Em relação a SR, apesar da variedade de aspectos dessa área a serem tratados, foram destacadas neste capítulo as técnicas consideradas na pesquisa. Sobre a avaliação, por ser utilizada a estratégia de recomendar um conjunto ordenado de OA, foram escolhidas as seguintes métricas: AUC, MAP, MRR, NDCG, P@n e R@n.

No próximo capítulo, é apresentado um levantamento bibliográfico de pesquisas relacionadas.

# Capítulo 3

## Pesquisas Relacionadas

Neste capítulo, é apresentada uma revisão do estado da arte, destacando-se as pesquisas relacionadas à pesquisa ora descrita.

Apesar de não ser o foco da pesquisa, é importante tratar inicialmente de estudos que fizeram uma associação entre as categorias dos padrões de Objetos de Aprendizagem (OA) e as teorias de Estilos de Aprendizagem (EA) — Seção 3.1 —, uma vez que isto será incorporado ao modelo proposto, descrito no Capítulo 4.

Tendo em vista que, a partir do levantamento bibliográfico realizado, não foram encontrados muitos estudos sobre SRE baseados em Personalidade, na Seção 3.2 serão abordados sistemas não necessariamente educacionais que consideram o conceito de TP para gerar recomendações.

Na Seção 3.3, por sua vez, são abordadas várias iniciativas em SRE, incluindo pesquisas que utilizam os conceitos de OA e EA.

Ao final, na Seção 3.4, é apresentado um resumo comparativo das pesquisas relacionadas, além de ser mencionada a proposta apresentada nesta dissertação (Quadro 5).

Este capítulo, assim como o Capítulo 2, relaciona-se ao objetivo específico I formulado na Seção 1.2.

### 3.1 Pesquisas sobre associações entre os OA e as dimensões de EA

Dentre as pesquisas que realizaram uma associação entre as categorias do padrão IEEE LOM e as dimensões do modelo de Felder–Silverman, é possível citar [Kerkiri, Manitsaris e Mavridis \(2009\)](#), [Yoosooka e Wuwongse \(2011\)](#), [Zaina et al. \(2012\)](#), [Oliveira \(2013\)](#) e [Resende et al. \(2014\)](#), sendo este expandido na pesquisa de [Carvalho et al. \(2014\)](#).

[Kerkiri, Manitsaris e Mavridis \(2009\)](#) apresentaram em seu estudo relações do atributo Tipo de Recurso de Aprendizagem — da categoria Educacional — a todas as dimensões de EA (incluindo-se a dimensão Organização, retirada do modelo em 2002). Além disso, ainda da categoria Educacional, foram realizadas associações dos atributos Nível de Interatividade e Densidade Semântica à dimensão Percepção.

No estudo de [Zaina et al. \(2012\)](#), é apresentada uma tabela que relaciona os atributos Tipo de Interatividade e Tipo de Recurso de Aprendizagem — da categoria Educacional — às dimensões Percepção, Entrada e Processamento.

Segundo [Oliveira \(2013\)](#), o atributo Formato — da categoria Técnica — e os atributos Tipo de Interatividade, Tipo de Recurso de Aprendizagem, Nível de Interatividade, Densidade Semântica e Dificuldade — da categoria Educacional — detalham os OA e permitem uma associação com os EA.

No estudo de [Carvalho et al. \(2014\)](#), além dos atributos considerados por [Oliveira \(2013\)](#), foram considerados os atributos Estrutura e Nível de Agregação — da categoria Geral — para associar os OA aos EA.

[Yoosooka e Wuwongse \(2011\)](#) limitaram-se a relacionar 16 perfis de aprendizes (considerando as combinações possíveis com as 2 categorias em cada uma das 4 dimensões) com apenas alguns tipos de recurso de aprendizagem (a saber: palestra, simulação, experimento, enunciado de problema, exercício e exame), ordenando entre estes aqueles que mais se adequavam a cada um dos perfis. A descoberta deste estudo foi resultado de uma busca na *ACM Digital Library* e na *IEEE Xplore Digital Library*, utilizando a *string* de busca "LOM and FELDER", considerando-se todo o texto dos artigos. Após analisar os 53 artigos retornados, desconsiderando inicialmente os que não descreviam como mapear os atributos do padrão IEEE LOM com as dimensões do modelo de Felder-Silverman, foi visto que alguns associavam poucos atributos do IEEE LOM às dimensões desse modelo, não apresentando diferenças significativas em relação aos outros estudos citados anteriormente — inclusive dois deles remetiam à abordagem de [Zaina et al. \(2012\)](#).

No Quadro 3, são apresentados os tipos de associação, realizados por [Kerkiri, Manitsaris e Mavridis \(2009\)](#), [Zaina et al. \(2012\)](#), [Oliveira \(2013\)](#), [Resende et al. \(2014\)](#) e [Carvalho et al. \(2014\)](#), entre os atributos das categorias do padrão IEEE LOM e as dimensões do modelo de EA de Felder-Silverman.

**Quadro 3. Comparação entre as pesquisas de [Kerkiri, Manitsaris e Mavridis \(2009\)](#) [K], [Zaina et al. \(2012\)](#) [Z], [Oliveira \(2013\)](#) [O], [Resende et al. \(2014\)](#) [R] e [Carvalho et al. \(2014\)](#) [C] sobre a associação entre o IEEE LOM e o modelo de EA de Felder–Silverman.**

		Dimensões do Modelo de EA de Felder–Silverman			
		Processamento	Percepção	Entrada	Compreensão
Atributos do Padrão LOM	Formato	O   R   C	O   R   C	O   R   C	O
	Tipo de Interatividade	O   R   C	Z   O   R   C		O
	Tipo de Recurso de Aprendizagem	K   Z   O   R   C	K   R   C	K   Z   O   R   C	K   C
	Nível de Interatividade	O   C	K   O		O
	Densidade Semântica		K   O		C
	Dificuldade		O   R   C		
	Estrutura				R   C
	Nível de Agregação				C

O estudo de [Zaina et al. \(2012\)](#) — representado no Quadro 3 pela letra Z — consistiu em relacionar a dimensão Percepção ao Tipo de Interatividade e as dimensões Processamento e Entrada ao atributo Tipo de Recurso de Aprendizagem. A expansão do mapeamento de [Carvalho et al. \(2014\)](#) — representado no Quadro 3 pela letra C — sobre o mapeamento de [Resende et al. \(2014\)](#) — representado no Quadro 3 pela letra R — consistiu em relacionar a dimensão Processamento ao atributo Nível de Interatividade e a dimensão Compreensão aos atributos Tipo de Recurso de Aprendizagem, Densidade Semântica e Nível de Agregação. O mapeamento de [Oliveira \(2013\)](#) — representado no Quadro 3 pela letra O — difere do mapeamento de [Carvalho et al. \(2014\)](#) essencialmente em relação às associações envolvendo as dimensões Percepção e Compreensão.

É possível notar, a partir de uma análise do Quadro 3, que os estudos de [Kerkiri, Manitsaris e Mavridis \(2009\)](#) e [Zaina et al. \(2012\)](#) abrangem menos associações que os demais, sendo destacados aqui por defenderem características diferentes dos demais. Dentre as principais diferenças, destacam-se: (i) [Zaina et al. \(2012\)](#) defende que a interatividade expositiva favorece percepção Intuitiva, e interatividade ativa favorece a percepção Sensorial, diferentemente dos outros estudos que associam esses campos; e (ii) [Kerkiri, Manitsaris e Mavridis \(2009\)](#), em contraposição a [Oliveira \(2013\)](#), defende que o Nível de Interatividade elevado favorece a percepção Sensorial.

Uma vez que nesses estudos não há detalhes sobre as associações, preferiu-se nesta pesquisa focar nas ideias de [Oliveira \(2013\)](#) e [Carvalho et al. \(2014\)](#).

[Oliveira \(2013\)](#) elaborou tabelas contendo os EA, os atributos do IEEE LOM e diferentes pesos (peso menor indicando maior proximidade do valor do atributo para o estilo; e peso maior indicando maior distância do valor do atributo para o estilo). É afirmado no estudo que os valores para os pesos podem ser facilmente alterados posteriormente tendo em vista análises efetuadas por especialistas em psicologia cognitiva e educação.

[Carvalho et al. \(2014\)](#), estendendo o mapeamento realizado por [Resende et al. \(2014\)](#), definiram regras no formato Prolog (Quadro 4) para abstrair o entendimento do mapeamento entre características do IEEE LOM e dos EA. A cada regra interpretada como verdadeira para determinado OA relativa a um EA, acrescenta-se um ponto à característica correspondente do OA. Enquanto o corpo da regra especifica os campos do IEEE LOM a serem analisados, o cabeçalho da regra especifica o EA a ser incrementado ([CARVALHO et al., 2014](#)).

No artigo intitulado "Análise Comparativa de Abordagens de Associação entre os Estilos de Aprendizagem de Felder–Silverman e os Metadados do Padrão IEEE LOM" (ver resumo/referência no Apêndice A) é detalhada uma análise comparativa realizada entre as abordagens de [Oliveira \(2013\)](#) e [Carvalho et al. \(2014\)](#).

Com base em seu entendimento a partir da fundamentação teórica, o autor desta dissertação não concorda com alguns aspectos do mapeamento de [Oliveira \(2013\)](#). Considerando, por exemplo, um OA caracterizado com Nível de Interatividade baixo, [Oliveira \(2013\)](#) relaciona tal OA ao estilo Sequencial; todavia, o autor desta dissertação não conseguiu entender com clareza a justificativa de que baixa interatividade implica em maior probabilidade da informação estar de forma encadeada e lógica. Outro aspecto, por exemplo, consiste em associar tabelas, índices e gráficos ao estilo Ativo; o autor desta dissertação entende, assim como [Carvalho et al. \(2014\)](#), que tais tipos de recurso de aprendizagem favorecem o estilo Reflexivo.

Além disto, pelo foco da pesquisa de [Carvalho et al. \(2014\)](#) ser mais próximo ao realizado nesta dissertação, decidiu-se considerar o mapeamento empregado por estes autores, exposto no Quadro 4.

**Quadro 4. Listagem das regras para mapeamento dos campos do IEEE LOM em EA.**

Ativo(X) :- TipoInteratividade(X; ativo); TipoInteratividade(X; misto).	Visual(X) :- Formato(X; imagem); Formato(X; video).
Ativo(X) :- TipoRecurso(X; exercicio); TipoRecurso(X; simulacao); TipoRecurso(X; questionario); TipoRecurso(X; enunciadoDeProblema); TipoRecurso(X; exame); TipoRecurso(X; experimento).	Visual(X) :- TipoRecurso(X; diagrama); TipoRecurso(X; grafico); TipoRecurso(X; figura); TipoRecurso(X; slide).
Ativo(X) :- NivelInteratividade(X; medio); NivelInteratividade(X; alto); NivelInteratividade(X; muitoAlto).	Verbal(X) :- Formato(X; audio); Formato(X; texto); Formato(X; video).
Reflexivo(X) :- Formato(X; audio); Formato(X; texto_html); Formato(X; video).	Verbal(X) :- TipoRecurso(X; narrativa); TipoRecurso(X; palestra); TipoRecurso(X; indice); TipoRecurso(X; slide); TipoRecurso(X; tabela); TipoRecurso(X; exame); TipoRecurso(X; experimento).
Reflexivo(X) :- TipoInteratividade(X; expositivo); TipoInteratividade(X; misto).	Sequencial(X) :- TipoRecurso(X; experimento).
Reflexivo(X) :- TipoRecurso(X; grafico); TipoRecurso(X; indice); TipoRecurso(X; slide); TipoRecurso(X; tabela).	Sequencial(X) :- DensidadeSemantica(X; media); DensidadeSemantica(X; baixa); DensidadeSemantica(X; muitoBaixa).
Reflexivo(X) :- NivelInteratividade(X; medio); NivelInteratividade(X; baixo); NivelInteratividade(X; muitoBaixo).	Sequencial(X) :- Estrutura(X; linear); Estrutura(X; hierarquico); Estrutura(X; atomico).
Sensorial(X) :- Formato(X; audio); Formato(X; imagem); Formato(X; texto); Formato(X; video).	Sequencial(X) :- NivelAgregacao(X; 1).
Sensorial(X) :- TipoInteratividade(X; expositivo).	Global(X) :- TipoRecurso(X; tabela).
Sensorial(X) :- TipoRecurso(X; diagrama); TipoRecurso(X; grafico); TipoRecurso(X; figura); TipoRecurso(X; narrativa); TipoRecurso(X; palestra); TipoRecurso(X; indice); TipoRecurso(X; slide).	Global(X) :- DensidadeSemantica(X; media); DensidadeSemantica(X; alta); DensidadeSemantica(X; muitoAlta).
Sensorial(X) :- Dificuldade(X; facil); Dificuldade(X; simples).	Global(X) :- Estrutura(X; rede); Estrutura(X; colecao).
Intuitivo(X) :- TipoRecurso(X; autoavaliacao); TipoRecurso(X; tabela).	Global(X) :- NivelAgregacao(X; 2); NivelAgregacao(X; 3); NivelAgregacao(X; 4).
Intuitivo(X) :- Dificuldade(X; dificil); Dificuldade(X; complexo).	

Fonte: Adaptado de [CARVALHO et al., 2014, p. 1192](#).

## 3.2 Pesquisas sobre SR baseados em TP

Em se tratando do conceito de Personalidade em SR, é possível destacar a pesquisa de doutorado de Nunes ([NUNES, 2008](#)), pioneira em usar TP para recomendar produtos, serviços ou pessoas.

Considerando que a personalidade do usuário não muda significativamente ao longo do tempo e, portanto, os vizinhos mais próximos do usuário podem ser calculados com antecedência, [Tkalčič et al. \(2009\)](#) propuseram uma abordagem baseada em personalidade (seguindo o modelo *Big Five*) de SR utilizando FC. A avaliação realizada por [Tkalčič et al. \(2009\)](#) indicou que o uso de medidas de similaridade usando o *Big Five* foram estatisticamente equivalentes ou melhores à abordagem tradicional (considerando *ratings*).

Em 2010, [Nunes et al. \(2010\)](#) apresentaram uma ferramenta desktop (*Group Recommender 1.0*) que possibilita a criação de equipes de trabalho eficientes coordenadas por tutores, considerando as características do tutor e a similaridade de TP de seus alunos. Para facilitar seu acesso e uso, a versão atualizada da ferramenta (*Group Recommender 2.0*) foi desenvolvida para arquitetura Web. Para utilização do sistema, é necessário que os usuários/alunos respondam ao *Personality Inventory PV1.0*, do qual se extrai o modelo de personalidade e, por meio deste, são gerados os dados necessários para a criação das equipes ([NUNES, 2012](#)).

[Trevisan, Cazella e Nunes \(2011\)](#) apresentaram um modelo que aplica TP em SR com base em contextos focado em TV Digital, demonstrando a possibilidade de seu uso no processo de ensino–aprendizagem.

Hu e Pu ([2010](#); [2011](#)) desenvolveram um SR de músicas com base nas relações entre características de personalidade humana e preferências musicais. A partir das respostas dos usuários ao questionário TIPI, o sistema é capaz de prever os tipos de música que o usuário pode gostar. Ainda no contexto musical, [Ferwerda e Schedl \(2014\)](#) apresentaram uma proposta de SR considerando informação de personalidade e estados emocionais dos usuários.

[Elahi et al. \(2013\)](#), no contexto da recomendação de lugares de interesse do usuário, usa o conceito de TP, obtendo-os por meio do questionário TIPI. Na avaliação da abordagem proposta, com um grupo de 108 participantes (em que cada um avaliou 13 itens), os autores concluem, utilizando a métrica MAE, que a personalidade do usuário tem um impacto importante na recomendação.

[Xia et al. \(2014\)](#), visando a melhorar interações, colaborações e consciência social dos participantes em uma conferência, incorporaram o conceito de TP e propuseram o algoritmo denominado SPARP (*Socially and Personality Aware Recommendation of Participants*). Com o SPARP, é possível receber recomendações de outros participantes de conferências que sejam úteis para o participante alvo.

A utilização do conceito de Personalidade em SR ainda é uma tendência emergente, não se limitando apenas ao contexto educacional ([HU e PU, 2011](#); [NUNES e HU, 2012](#); [CANTADOR e FERNÁNDEZ-TOBIÁS, 2014](#)). Não foram encontradas, a partir do levantamento bibliográfico realizado, uma quantidade significativa de pesquisas validadas e documentadas na literatura da área sobre este tema.

### **3.3 Pesquisas sobre SRE**

Dentre as primeiras iniciativas de SR voltadas para a educação, é possível citar o GroupLens, um projeto de pesquisa, desenvolvido pela Universidade de Minnesota, na década de 1990, relacionado à FC, cujo sistema auxiliava a busca de artigos, coletando a avaliação dos usuários, referente aos artigos lidos e, a partir da identificação dos usuários com avaliações similares, recomendava novos artigos ([KONSTAN et al., 1997](#)).

No Brasil, há iniciativas em SRE em várias partes do país. Partindo-se desta premissa, foi realizado um mapeamento sistemático com base nas publicações em eventos/periódicos brasileiros, voltados para a Educação e Informática e Novas Tecnologias, classificados pela CAPES com estrato pelo menos B5 na área de avaliação Ciência da Computação (ver Apêndice A — artigo intitulado “Um Mapeamento Sistemático sobre Iniciativas Brasileiras em Sistemas de Recomendação Educacionais”).

A partir desse mapeamento, foi realizada uma revisão sistemática com foco na Avaliação de SRE brasileiros (ver Apêndice A — artigo intitulado “Avaliação de Sistemas de Recomendação Educacionais no Brasil: uma revisão sistemática da literatura”). Com base nas mesmas fontes e *string* de busca, além dos critérios de inclusão e exclusão, os 26 estudos resultantes dessa revisão diferenciam-se essencialmente dos resultados do mapeamento publicado anteriormente por desconsiderar os artigos que não contemplaram uma etapa de

avaliação do modelo proposto, além de incluir os estudos publicados em 2014. Alguns detalhes relativos a cada um dos 26 estudos resultantes — usuário-alvo da recomendação, recurso educacional recomendado, técnicas de recomendação empregadas, métricas de avaliação, entre outras informações — estão disponíveis em um quadro *online* elaborado por [Aguiar e Santos \(2015\)](#).

Em relação a pesquisas em âmbito internacional, o estudo de [Drachsler et al. \(2015\)](#) consiste em uma revisão recente de pesquisas em SRE, na qual foram classificadas 82 pesquisas em 7 categorias, conforme exposto na Subseção 2.4.3 — ver Apêndice B.

Nos parágrafos a seguir, são detalhadas pesquisas citadas no Apêndice B e na revisão sistemática apresentada no artigo “Avaliação de Sistemas de Recomendação Educacionais no Brasil: uma revisão sistemática da literatura” (Apêndice A).

[Barcellos et al. \(2007\)](#) apresentaram um modelo de recomendação que dispensa a intervenção do usuário no momento de traçar seu perfil. A pesquisa objetivou realizar recomendações mais relevantes, no contexto acadêmico, a partir da integração de sistemas de busca e perfil do usuário, criado automaticamente a partir do currículo Lattes e da página pessoal do usuário, caso exista, evitando que o usuário precise, por exemplo, preencher formulários. O sistema realiza uma busca por artigos acadêmicos — com o auxílio da ferramenta Google Scholar — sobre um determinado assunto considerando o perfil do usuário. O modelo proposto funciona da seguinte forma: (i) o usuário se cadastra no sistema e, a partir do seu nome, é feita uma busca implícita na Internet para criação do seu perfil; (ii) o usuário cadastrado pode informar o assunto de interesse que deseja procurar (as pesquisas realizadas são armazenadas em seu histórico); (iii) o sistema processa implicitamente o perfil do usuário e seleciona artigos julgados adequados para o usuário, com foco nos que são referenciados em mais de uma base de dados de artigos; e (iii) o sistema apresenta esses artigos selecionados.

[Cazella, Reategui e Behar \(2010\)](#) propuseram um SR com a finalidade de filtrar os OA por meio de competências contemplando perfis de alunos de educação a distância, permitindo que se moldem e se adaptem aos diferentes contextos e situações proporcionadas por meio do ensino e da aprendizagem *online*. Em linhas gerais, o modelo proposto segue estes passos para seu funcionamento: (i) o professor planeja as aulas com base nas competências

descritas na ementa da disciplina, disponibilizando os OA a serem utilizados para desenvolver as respectivas competências; (ii) o modelo utiliza a FC para realizar os cálculos de coeficiente de similaridade e de predição; (iii) o modelo aplica as regras da competência, que filtram os conteúdos recomendados pela predição para permitir ao usuário o desenvolvimento de determinadas competências em um determinado tempo. Os autores prototiparam esse modelo e realizaram experimentos com 10 graduandos do final do curso de Engenharia da Computação. Os OA consistiram em artigos científicos relacionados com competências pretendidas na disciplina de Banco de Dados e selecionados por um professor especialista da área. Com os experimentos, os autores afirmaram que o grau de precisão alcançado pelas recomendações geradas pelo protótipo foi satisfatório (76%) ([CAZELLA, REATEGUI e BEHAR, 2010](#)).

[Ferreira e Raabe \(2010\)](#) elaboraram um modelo de SR de OA para um ambiente baseado no Moodle. Ao registrar a navegação do usuário, o ambiente possibilita a identificação da similaridade entre usuários e, além disto, os metadados que descrevem os OA permitem a identificação da similaridade entre conteúdos. O sistema desenvolvido, denominado LorSys (*Learning Object Recommender System*), gera recomendações por meio das técnicas de FC e FBC, utilizadas de forma independente. Entretanto, quando ambas as técnicas recomendam um mesmo OA, este é classificado/recomendado como “dica quente” ([FERREIRA e RAABE, 2010](#)). Em relação à FBC, cabe ao professor definir o grau de relacionamento entre os OA (“Pré-Requisito”, “Complemento”, “Similar” ou “Sem relação”). Em relação à FC, o sistema recomenda o OA mais acessado pelos outros usuários, além de recomendar o último OA acessado por usuários mais similares (os que acessaram os mesmos objetos que o usuário alvo). Definidos os OA a serem recomendados, os usuários do ambiente visualizam as indicações a partir de um bloco (recurso do Moodle). Os autores realizaram uma avaliação quantitativa e qualitativa do LorSys, disponibilizando-o a um pequeno grupo de usuários com OA na área de Ciência da Computação. Em geral, as avaliações foram positivas, indicando também uma aceitação maior das recomendações geradas por meio da FBC. Dentre as justificativas possíveis indicadas no estudo, [Ferreira e Raabe \(2010\)](#) acreditam que isso se deve ao fato dessas recomendações serem mostradas no topo do bloco.

[Nascimento Júnior et al. \(2011\)](#) propuseram e avaliaram um SR de artigos científicos, por meio de uma filtragem híbrida (FBC e FC), considerando artigos

de qualquer biblioteca digital com metadados no formato *Dublin Core* e com suporte ao protocolo OAI-PMH. O perfil do usuário é extraído com base no seu currículo Lattes, sendo possível também que o usuário o modifique, tratando eventuais informações desatualizadas do seu Lattes.

[Casali et al. \(2012\)](#) apresentaram o desenvolvimento de um SR para ajudar os usuários a encontrar OA mais adequados às suas necessidades e preferências. A partir de repositórios de aprendizagem distribuídos, os OA, descritos em metadados, são recomendados seguindo uma abordagem baseada em regras, levando-se em consideração o perfil dos usuários.

[Ferreira, Gluz e Barbosa \(2012\)](#) apresentaram o UbiReCon, um modelo de recomendação de conteúdo educacional aplicado em um ambiente de aprendizagem ubíquo, considerando-se o perfil e o contexto do aluno. Segundo os autores, o UbiReCon “agrega funcionalidades de integração a um repositório de alta escalabilidade, busca semântica aos metadados de OAs e a flexibilidade na definição das regras de recomendação” ([FERREIRA, GLUZ e BARBOSA, 2012](#)). No ano seguinte, estes autores propuseram o UbiGroup ([FERREIRA, BARBOSA e GLUZ, 2013](#)), um modelo de recomendação ubíqua de conteúdo educacional para grupos de aprendizes, considerando o perfil da turma e o contexto no qual os aprendizes estão inseridos.

[Casagrande, Kozima e Willrich \(2013\)](#) propuseram uma técnica de recomendação em repositórios digitais voltados ao ensino, a partir de perfis de usuário construídos via observação dos valores de metadados dos conteúdos acessados. Esses perfis são gerados a partir dos conteúdos acessados e das preferências específicas dos usuários, as quais são estimadas baseando-se na análise da frequência de ocorrência dos valores dos metadados observados (*Keyword, InteractivityType, LearningResourceType* e *ContextDifficulty*, conforme o padrão IEEE LOM). Uma vez criados, os perfis dos usuários são comparados, sendo agrupados os perfis similares para reduzir o tempo de processamento. Uma avaliação da técnica proposta foi realizada em um repositório digital utilizado no ensino de literatura ([CASAGRANDE, KOZIMA e WILLRICH, 2013](#)).

[Vesin et al. \(2013\)](#) apresentaram o sistema Protus, com o objetivo de orientar automaticamente atividades e recomendar links e ações relevantes para os aprendizes durante o processo de aprendizagem — mais especificamente, aprendizagem de conceitos essenciais da linguagem de programação Java. Para essa indicação, tanto de conteúdo quando de navegação, os autores usaram

técnicas de recomendação e hiperídia adaptativa, considerando a identificação dos EA dos alunos. Os autores afirmaram que a maioria dos alunos que utilizaram o sistema ficou satisfeita e que os resultados empíricos indicaram que o Protus pode apoiar os alunos para a obtenção de melhores notas e uma curva de aprendizagem ascendente.

[Ferro et al. \(2014\)](#) apresentaram um modelo de SR de materiais didáticos em AVA utilizando uma técnica de geração de recomendação híbrida, a qual combina recomendação não personalizada (a partir da popularidade dos itens), FC e FBC. Em linhas gerais, o processo de geração de recomendações realizado por [Ferro et al. \(2014\)](#) consiste nestas quatro etapas: (1) geração de uma lista de materiais didáticos, usando FC; (2) geração de uma lista ordenada (estilo *ranking*) dos materiais da lista gerada em 1, cuja ordenação é feita a partir de FBC; (3) geração de uma lista ordenada (estilo *ranking*) dos materiais da lista gerada em 1, cuja ordenação é feita a partir da procura dos materiais didáticos mais requisitados por outros usuários (recomendação não personalizada); e (4) cálculo dos Graus de Utilidade Híbrida ([FERRO et al., 2014](#)), a partir das listas geradas em 1, 2 e 3, resultando em uma lista ordenada dos materiais considerando todas as técnicas utilizadas. Os autores escolheram o Moodle como AVA para implementar um protótipo do modelo e afirmaram que o modelo de recomendação híbrido proposto foi satisfatório nos testes iniciais e no experimento envolvendo alunos reais em um curso de extensão.

Considerando a Aprendizagem Baseada em Problemas (PBL — *Problem Based Learning*), [Fróes e Santos \(2014\)](#) propuseram o E-BIACS, um sistema para a construção de ambientes virtuais para PBL. As questões relativas aos objetivos de aprendizagem são enunciadas baseando-se em problemas realísticos, que formam conjuntos de situações problemáticas no E-BIACS, sendo neste recomendados os recursos instrucionais contextualizados com o problema. O sistema construído foi avaliado por gerentes de projetos e, segundo os autores, os recursos instrucionais recomendados estavam contextualizados com as situações problemáticas, sendo considerados apropriados no processo de elucidação dos problemas.

[Karampiperis, Koukourikos, e Stoitsis \(2014\)](#) examinaram e indicaram os benefícios em introduzir técnicas de análise de sentimentos sobre comentários gerados por usuários de repositórios de recursos educacionais. Os autores utilizaram 6.720 recursos do repositório MERLOT, sendo, de cada recurso,

recuperados o título, a descrição, as palavras-chave, os comentários dos usuários e as opiniões de especialistas. O enfoque do estudo foi em abordagens lexicais para análise de sentimento, possibilitando identificar informações qualitativas e introduzi-las em um RS baseado em FC.

Considerando que a situação emocional do aluno pode influenciar o processo de aprendizagem, [Santos et al. \(2014\)](#) publicaram uma iniciativa buscando usar a Computação Afetiva para melhorar a recomendação em SRE. Para os autores, as recomendações afetivas podem ser providas por meio de movimentos faciais/corporais a estados afetivos (a exemplo de tédio, surpresa etc.) e por meio das informações fornecidas pelo aluno sobre as emoções sentidas ao resolver as tarefas propostas. Neste estudo preliminar sugere-se que TP podem ter um impacto significativo sobre a forma como as recomendações devem ser entregues e até na decisão sobre a possibilidade de entregar ou não determinada recomendação.

[Wiedemann, Barbosa e Rigo \(2014\)](#) propuseram um modelo para recomendação que explora a relação entre os OA em portais/repositórios e os interesses de pesquisa dos alunos durante as sessões de acesso a esses portais. Os OA são recomendados com base na análise de similaridade entre históricos de sessões. Durante uma sessão, o modelo recebe a sequência de OA consultados, localiza as sessões cujas sequências de OA consultados sejam similares e, finalmente, recomenda ao usuário os OA encontrados nessas sessões similares.

Em relação ao uso de SRE que utilizam o conceito de EA, na revisão de [Drachsler et al. \(2015\)](#) é possível destacar o estudo de [Kerkiri, Manitsaris e Mavridis \(2009\)](#). Na revisão sistemática sobre iniciativas brasileiras, encontram-se os estudos de [Zaina et al. \(2012\)](#) e [Carvalho et al. \(2014\)](#). Em todos eles, foi utilizado o padrão de metadados IEEE LOM para OA, sendo relacionado esse padrão com as dimensões de EA de Felder–Silverman, como previamente comentado na Seção 3.1.

[Kerkiri, Manitsaris e Mavridis \(2009\)](#) propuseram uma metodologia para aplicar algoritmos de recomendação em um sistema *e-learning*, explorando ontologias para personalizar recursos de aprendizagem. Segundo os autores, a personalização é feita por meio da manipulação de metadados relacionados à reputação, preferências e personalidade dos usuários. A partir da leitura do artigo, entende-se que a personalidade citada pelos autores relaciona-se aos seus EA — a partir do modelo de Felder–Silverman —, e não aos seus TP. Para

receberem as recomendações personalizadas, os alunos inicialmente fornecem algumas informações sobre eles (dados pessoais, preferências etc.), além de preencherem um questionário sobre EA.

Em relação aos estudos de [Zaina et al. \(2012\)](#) e [Carvalho et al. \(2014\)](#), no primeiro apresentou-se uma abordagem não dinâmica, não considerando as incertezas relacionadas à modelagem do perfil do estudante; no segundo, apesar de considerar de maneira probabilística as dimensões de EA, não foi avaliada a acurácia das recomendações.

Apesar de relevantes, as pesquisas de [Pereira et al. \(2014\)](#) e [Pereira e Augustin \(2014\)](#) não foram consideradas nas revisões sistemáticas citadas anteriormente.

[Pereira et al. \(2014\)](#) apresentaram uma proposta para gerar recomendações individualizadas de recursos educacionais a partir da relação entre os metadados do recurso educacional e o perfil educacional do usuário, construído a partir de informações extraídas da rede social Facebook. Com base nos metadados IEEE LOM considerados (*Title, Language, Keyword, Format, Context, TypicalAgeRange*), são usadas técnicas de Extração de Texto e Web Semântica para extrair estas informações: Área de interesse, Idiomas falados, Área de interesse, Preferência por mídias (Visuais/Verbais), Grau de Formação e Idade. Identificadas essas características por meio da interação na rede social, são realizadas recomendações educacionais individualizadas aderentes ao perfil e contexto do usuário.

[Pereira e Augustin \(2014\)](#) propuseram um SR para selecionar e sugerir itens denominado *Affective-Recommender*. O sistema identifica emoções a partir do *AffectButton* (BROEKENS e BRINKMAN, 2009 *apud* [PEREIRA e AUGUSTIN, 2014](#)), ferramenta para a detecção do estado afetivo do usuário a partir de *feedback* explícito, construída de forma similar ao *Self-Assessment Manikin* (SAM), um instrumento orientado a figuras (LANG, 1980 *apud* [PEREIRA e AUGUSTIN, 2014](#)). A recomendação de itens é feita utilizando uma abordagem baseada em FC, na qual a preferência de um usuário para um item é entendida como sua reação ao item (estado afetivo detectado após o contato). Vale ressaltar que o *Affective-Recommender* não foi criado especificamente para o contexto educacional. Como estudo de caso, foi empregado em um cenário de *e-learning* com três turmas de cursos de graduação utilizando o Moodle, sendo analisados os dados de acesso e aplicado um questionário para identificar as

impressões dos alunos. Os resultados indicaram que os alunos conseguiram informar seus estados afetivos, e que houve uma mudança neste estado baseado no item acessado, embora não tenham sido vislumbradas melhorias advindas das recomendações, em virtude da pequena quantidade de dados disponível para processamento e do curto tempo de aplicação ([PEREIRA e AUGUSTIN, 2014](#)).

### 3.4 Considerações Finais do Capítulo

No Quadro 5, em caráter comparativo, são apresentadas pesquisas anteriormente abordadas, além da pesquisa proposta neste documento.

**Quadro 5. Comparação entre estudos sobre SR no contexto educacional.**

<b>Pesquisa</b>	<b>Usuário-alvo da recomendação</b>	<b>Recurso educacional recomendado</b>	<b>Estratégia para recomendação</b>	<b>Uso de EA</b>	<b>Uso de TP</b>
<a href="#">Barcellos et al. (2007)</a>	Acadêmicos	Artigos científicos	FBC	Não	Não
<a href="#">Carvalho et al. (2014)</a>	Estudantes	OA em geral	Uso de regras baseadas em EA	Sim	Não
<a href="#">Casagrande, Kozima e Willrich (2013)</a>	Acadêmicos	Conteúdos de repositórios digitais	FC combinada com uma técnica de agrupamento de usuários com perfis similares	Não	Não
<a href="#">Casali et al. (2012)</a>	Estudantes	OA em geral	Baseada em regras	Sim	Não
<a href="#">Cazella, Reategui e Behar (2010)</a>	Estudantes	Artigos científicos	FC, adicionando Regras de Competências (baseadas na Ementa)	Não	Não
<a href="#">Ferreira e Raabe (2010)</a>	Estudantes	OA em geral	FBC, FC	Não	Não
<a href="#">Ferreira, Barbosa e Gluz (2013)</a>	Estudantes	OA em geral	Baseada em Contexto, Uso de Agentes	Parcialmente (sem detalhes no artigo)	Não
<a href="#">Ferreira, Gluz e Barbosa (2012)</a>	Estudantes	OA em geral	Uso de regras com Agente Recomendador de Conteúdo, Baseada em Contexto	Não	Não
<a href="#">Ferro et al. (2014)</a>	Estudantes	OA em geral	FBC, FC, Popularidade dos Itens	Não	Não
<a href="#">Fróes e Santos (2014)</a>	Estudantes	Recursos instrucionais	Baseada em ontologia	Não	Não

**Continuação do Quadro 5.**

<b>Pesquisa</b>	<b>Usuário-alvo da recomendação</b>	<b>Recurso educacional recomendado</b>	<b>Estratégia para recomendação</b>	<b>Uso de EA</b>	<b>Uso de TP</b>
<a href="#">Karampiperis, Koukourikos, e Stoitsis (2014)</a>	Estudantes	OA em repositórios	FC, com técnicas de análise de sentimentos	Não	Não, mas considera análise de sentimentos
<a href="#">Kerkiri, Manitsaris e Mavridis (2009)</a>	Estudantes	OA em geral	Uso de ontologia, baseada em EA e reputação do estudante	Sim	Não
<a href="#">Nascimento Júnior et al. (2011)</a>	Acadêmicos	Artigos científicos para bibliotecas digitais	FBC, FC	Não	Não
<a href="#">Nunes et al. (2010)</a>	Facilitadores da aprendizagem (Tutores)	Grupos de trabalho	FC	Não	Sim
<a href="#">Pereira e Augustin (2014)</a>	Estudantes	OA em geral	FC	Não	Não, mas usa emoções
<a href="#">Pereira et al. (2014)</a>	Estudantes	OA em geral	FBC, FC	Sim (apenas visual/verbal)	Não
<a href="#">Santos et al. (2014)</a>	Estudantes	Atividade de aprendizagem	Filtragem baseada em conhecimento	Não	Sim
<a href="#">Trevisan, Cazella e Nunes (2011)</a>	Público de TV Digital	Programas televisivos ( <i>T-Learning</i> )	FC, Baseada em Contexto	Não	Sim
<a href="#">Vesin et al. (2013)</a>	Estudantes	Links e ações em um AVA	FBC, Baseada em regras	Sim	Não
<a href="#">Wiedemann, Barbosa e Rigo (2014)</a>	Estudantes	OA em geral	Baseada na similaridade entre sequências de consultas realizadas em cada sessão de usuário	Não	Não
<a href="#">Xia et al. (2014)</a>	Acadêmicos (participantes de conferências)	Participantes de conferências	FC	Não	Sim
<a href="#">Zaina et al. (2012)</a>	Estudantes	OA em geral	FBC	Sim	Não
<b>PROPOSTA</b>	<b>Estudantes</b>	<b>OA em geral</b>	<b>FBC, Uso de regras baseadas em EA, FC, Popularidade dos Itens</b>	<b>Sim</b>	<b>Sim</b>

A partir da análise comparativa entre pesquisas, apresentada no Quadro 5, reforça-se o diferencial da pesquisa realizada em comparação a outras do estado da arte.

É importante ressaltar que, no Apêndice B e no quadro *online* elaborado por [Aguiar e Santos \(2015\)](#) — relativo à revisão sistemática explanada no artigo “Avaliação de Sistemas de Recomendação Educacionais no Brasil: uma revisão sistemática da literatura” (Apêndice A) —, encontram-se outros quadros comparativos elaborados durante a pesquisa.

No próximo capítulo, é apresentado o modelo proposto, considerando-se as características destacadas na última linha do Quadro 5.

## Capítulo 4

# Modelo de Recomendação de Objetos de Aprendizagem

Este capítulo relaciona-se diretamente ao objetivo específico V formulado na Seção 1.2, uma vez que é apresentado o modelo de SRE proposto. Na Seção 5.3, é explicada a metodologia do experimento adotada para se obter os resultados que corroboram com a relevância desse modelo.

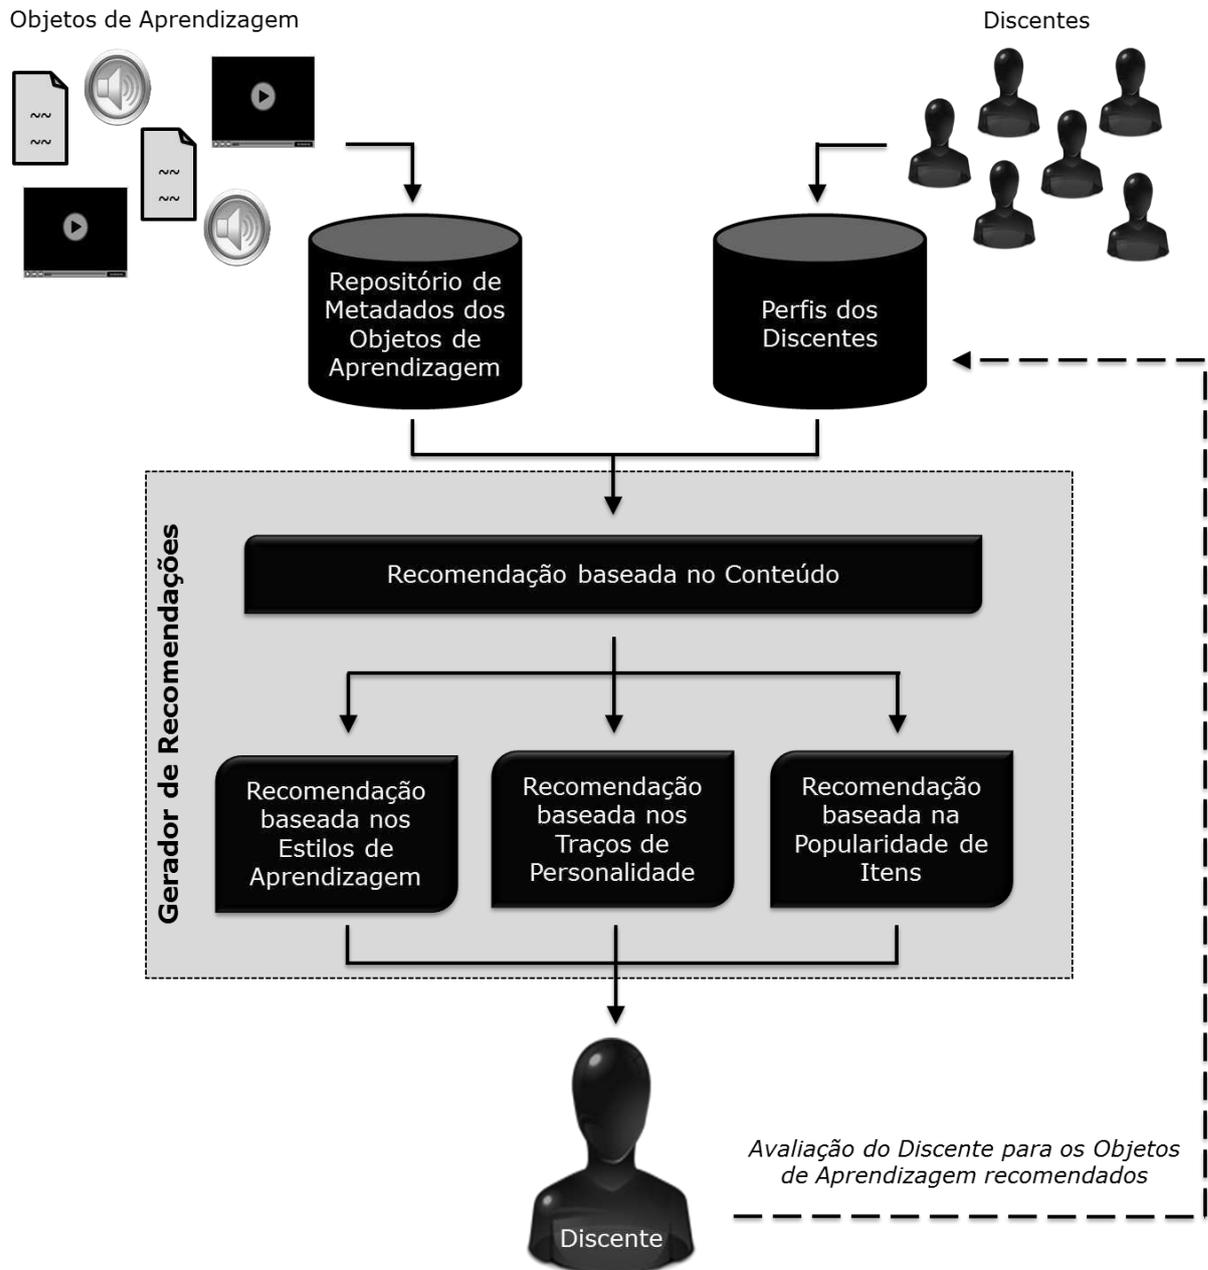
Com o intuito de melhorar a recomendação de OA para discentes, o objetivo inicial consistiu em criar um modelo de recomendação híbrido, a exemplo de [Ferro et al. \(2014\)](#), considerando os TP dos alunos.

Para isso, tentou-se inicialmente uma correlação direta entre a Personalidade dos alunos e o seus modos de aprender (EA), para extrair apenas a Personalidade (por meio do TIPI) e inferir os EA (sem ser necessário o uso do Inventário ILS). Entretanto, essa proposta (audaciosa) não se estabeleceu e, assim, foi pensado em usar diretamente o Inventário ILS.

Com a possibilidade da extração de Personalidade sem requerer grandes esforços do usuário (via ferramenta baseada no estudo de [Schwartz et al. \(2013\)](#)), optou-se por usar os dois conceitos para construir o perfil do usuário, metodologia não encontrada em outros estudos, conforme levantamento bibliográfico realizado.

Na Figura 5, é ilustrado o modelo de recomendação proposto nesta dissertação, composto essencialmente por 3 (três) elementos: Perfis dos Discentes, Repositório de Metadados dos OA e o Gerador de Recomendações, baseado no conteúdo e na popularidade dos OA, nos EA e nos TP dos discentes. Estes elementos são detalhados nas seções seguintes.

**Figura 5. Modelo de recomendação proposto.**



## 4.1 Perfis dos Discentes

Os discentes, neste modelo, consistem nos interessados em buscar OA para ajudá-los em seus estudos. Cada discente possui um perfil associado, que pode ser representado por uma quádrupla ordenada, conforme formalizada na Equação 4.

$$u = (T, D, A, P) , \quad (4)$$

em que:

- $u$  representa um usuário/aluno;

- $u \in U$ ;
- $U$  representa o conjunto de todos os usuários/alunos do sistema;
- $T$  representa o perfil do usuário relativo aos TP;
- $T = (t_1, t_2, t_3, t_4, t_5)$ ;
- $0 \leq t_1 \leq 100 \wedge t_1 \in \mathbb{N}$ , sendo  $t_1$  referente ao traço Extroversão;
- $0 \leq t_2 \leq 100 \wedge t_2 \in \mathbb{N}$ , sendo  $t_2$  referente ao traço Socialização;
- $0 \leq t_3 \leq 100 \wedge t_3 \in \mathbb{N}$ , sendo  $t_3$  referente ao traço Realização;
- $0 \leq t_4 \leq 100 \wedge t_4 \in \mathbb{N}$ , sendo  $t_4$  referente ao traço Neuroticismo;
- $0 \leq t_5 \leq 100 \wedge t_5 \in \mathbb{N}$ , sendo  $t_5$  referente ao traço Abertura;
- $D$  representa o perfil do usuário relativo aos EA;
- $D = (d_1, d_2, d_3, d_4)$ ;
- $0 \leq d_1 \leq 100 \wedge d_1 \in \mathbb{N}$ , sendo  $d_1$  referente à dimensão Processamento;
  - Quando  $d_1$  for 0, representa 0% para o Estilo Reflexivo e, consequentemente, 100% para o Estilo Ativo;
- $0 \leq d_2 \leq 100 \wedge d_2 \in \mathbb{N}$ , sendo  $d_2$  referente à dimensão Percepção;
  - Quando  $d_2$  for 0, representa 0% para o Estilo Intuitivo e, consequentemente, 100% para o Estilo Sensorial;
- $0 \leq d_3 \leq 100 \wedge d_3 \in \mathbb{N}$ , sendo  $d_3$  referente à dimensão Entrada;
  - Quando  $d_3$  for 0, representa 0% para o Estilo Verbal e, consequentemente, 100% para o Estilo Visual;
- $0 \leq d_4 \leq 100 \wedge d_4 \in \mathbb{N}$ , sendo  $d_4$  referente à dimensão Compreensão;
  - Quando  $d_4$  for 0, representa 0% para o Estilo Global e, consequentemente, 100% para o Estilo Sequencial;
- $A$  representa as avaliações (*ratings*) realizadas por determinado usuário/aluno para itens/OA do sistema;
- $A = \{(i,r) \mid i \in I \wedge r \in \mathbb{N} \wedge 1 \leq r \leq 5\}$ ;
- $I$  representa o conjunto de todos os itens/OA do sistema;
- $\forall((x,r_1),(y,r_2)), (x,r_1) \in A \wedge (y,r_2) \in A, x \neq y$ ;
- $|A| \leq |I|$ ;
- $P$  representa um conjunto de palavras-chave que indicam o interesse do usuário;
- $P = \{p \mid p \text{ é uma palavra-chave de interesse do usuário}\}$ ;
- $|P| > 0$ .

Considerando-se o modelo *Big Five* para a identificação de TP dos discentes,  $T$  representa uma quintupla ordenada, sendo seus 5 elementos representativos do valor percentual de cada um dos traços do *Big Five* para aquele discente (um valor do tipo inteiro entre 0 e 100). A identificação desses valores percentuais pode ser feita utilizando a ferramenta Five Labs, ou outro instrumento de mensuração que retorne valores referentes aos traços do *Big Five*.

Considerando-se a teoria de Felder–Silverman para a identificação das dimensões de EA dos discentes,  $D$  representa uma quádrupla ordenada, sendo seus 4 elementos representativos do valor percentual de cada uma das dimensões de EA do modelo de Felder–Silverman para aquele discente (um valor do tipo inteiro entre 0 e 100). A identificação desses valores percentuais pode ser feita utilizando o questionário ILS, ou outro meio de mensuração que retorne valores referentes às dimensões de EA do modelo de Felder–Silverman.

Além disso, o perfil de cada discente deve contemplar a avaliação (*feedback* avaliativo em uma escala de 1 a 5) para os OA, representada pelo conjunto  $A$ , sendo esta informação útil para as estratégias colaborativas (tanto na recomendação baseada em popularidade de itens, quanto na recomendação baseada em TP). O conjunto  $A$  é formado por pares ordenados, que representam o item/OA avaliado e a avaliação correspondente, não sendo possível mais de uma avaliação para o mesmo item/OA.

Ressalta-se que, uma vez que o modelo pode empregar também técnicas de FBC, além desses dados, o perfil de cada discente contempla um conjunto  $P$  de palavras-chave (características descritivas) de interesse do discente, que podem ser atualizadas automaticamente dependendo de onde o modelo seja implantado.

Se o discente se inscreve em um sistema que abrange vários cursos, por exemplo, ao se matricular em determinado curso, tal discente pode ter associadas automaticamente a seu perfil as palavras-chave específicas de tal curso. Além disso, pode ser utilizada a estratégia empregada por [Barcellos et al. \(2007\)](#), na qual o usuário cadastrado informa o assunto de interesse que deseja procurar, ficando, assim, armazenadas no conjunto  $P$  as pesquisas realizadas.

Para exemplificar, no Quadro 6 está descrito formalmente um ambiente com quatro itens/OA e três usuários/discentes.

**Quadro 6. Exemplo utilizando a formalização da Equação 4.**

$$I = \{i_1, i_2, i_3, i_4\}$$

$$U = \{u_1, u_2, u_3\}$$

$$u_1 = ( T=(20,19,80,71,13), D=(91,34,13,86), A=\{(i_2,1),(i_3,4),(i_4,3)\}, P=\{\text{"Ecologia"}\} )$$

$$u_2 = ( T=(62,77,31,44,55), D=(67,52,57,80), A=\{(i_1,1),(i_2,5),(i_4,2)\}, P=\{\text{"Ictiologia"}, \text{"Zoologia"}\} )$$

$$u_3 = ( T=(36,49,27,80,96), D=(22,21,79,27), A=\{(i_1,3),(i_2,4),(i_3,2)\}, P=\{\text{"Ecologia"}, \text{"Zoologia"}\} )$$

## 4.2 Repositório de Metadados dos Objetos de Aprendizagem

No repositório de metadados dos OA, são armazenadas as características de cada item didático encontrado no sistema a adotar o modelo de recomendação proposto.

Essas características são utilizadas para efetuar a associação com o perfil dos discentes, com base na associação apresentada no Quadro 4, além de poder identificar o conteúdo de cada OA para que possam ser filtrados na primeira fase do processo de recomendação do modelo (FBC).

Para isso, é importante que os OA tenham seus metadados, seguindo o padrão IEEE LOM, devidamente preenchidos, especialmente os campos Título, Palavra-chave e Descrição (da categoria Geral) — importantes para extrair o conteúdo dos OA e realizar a FBC —, além dos campos Formato e Estrutura (da categoria Técnico), Tipo de Interatividade, Tipo de Recurso de Aprendizagem, Nível de Interatividade, Densidade Semântica e Dificuldade (da categoria Educacional) e Nível de Agregação (da categoria Geral), considerados na associação do Quadro 4 — para realizar a recomendação com base nos EA dos discentes.

Embora não seja necessário que todos os OA contemplem informações de todos esses metadados, ressalta-se que, quanto mais informações disponíveis, mais confiável será a associação destes OA ao perfil do discente.

No Quadro 7, é exemplificado um OA descrito com base no padrão IEEE LOM, com os metadados anteriormente citados devidamente preenchidos.

**Quadro 7. Exemplo de descritores de OA seguindo o padrão IEEE LOM.**

```
<lom>
  <general>
    <title>Deep-Sea</title>
    <language>english</language>
    <description>Lecture about an international team of marine biologists
    and geologists who wanted to study the organisms that inhabit on the
    Atlantic Ocean floor</description>
    <keyword>ecology</keyword>
    <keyword>zoology</keyword>
    <structure>linear</structure>
    <aggregationLevel>1</aggregationLevel>
  </general>
  <technical>
    <format>audio</format>
    <duration></duration>
  </technical>
  <educational>
    <interactivityType>expositive</interactivityType>
    <learningResourceType>lecture</learningResourceType>
    <semanticDensity>medium</semanticDensity>
    <difficulty>medium</difficulty>
    <interactivityLevel>medium</interactivityLevel>
  </educational>
</lom>
```

### 4.3 Gerador de Recomendações

O gerador de recomendações é responsável por utilizar o perfil dos discentes e o repositório de metadados dos OA para gerar recomendações.

Conforme exposto na Figura 5, o modelo proposto utiliza uma abordagem de recomendação híbrida, combinando quatro técnicas de recomendação: recomendação baseada no conteúdo, recomendação baseada na popularidade de itens, recomendação baseada em EA e recomendação baseada em TP.

O gerador de recomendações consiste em um processo realizado em 3 (três) etapas, descritas a seguir.

1. **Recomendação baseada no Conteúdo:** Inicialmente, todos os OA disponíveis são filtrados com base no seu conteúdo, para que sejam desconsiderados OA que abordem assuntos não relacionados ao objetivo dos alunos. Ressalta-se que, dependendo de onde for implantado este modelo, em vez de aplicar técnicas como TF-IDF, esta etapa de filtragem pode ser realizada previamente pelo professor/facilitador da aprendizagem. Destaca-se que os itens dessa lista são aqueles que ainda não foram avaliados pelo usuário. O importante nesta etapa é

obter, ao seu final, um conjunto de OA que abordem conteúdo útil para a aprendizagem do discente, independente de sua popularidade e de como tal conteúdo é apresentado.

2. Considerando-se o conjunto de OA resultante da primeira etapa, a segunda etapa consiste em ordenar os OA baseando-se em sua popularidade e nos TP e EA dos discentes. Para isso, esta etapa se subdivide em três, conforme a seguir.

2.1. **Recomendação baseada nos Estilos de Aprendizagem:** Para os OA do conjunto resultante da primeira etapa, é aplicado o algoritmo de recomendação baseada em EA (sendo adotada a estratégia do estudo de [Carvalho et al. \(2014\)](#)), ordenando-os com base no perfil relativo a EA do discente alvo da recomendação. O resultado desta subetapa é, portanto, uma lista ordenada de OA relativa à execução do algoritmo de recomendação baseada em EA, denominado nesta dissertação de LSBR (*Learning Style Based Recommendation*).

2.2. **Recomendação baseada nos Traços de Personalidade:** Para os OA do conjunto resultante da primeira etapa, é aplicado o algoritmo de recomendação baseada em TP, ordenando-os com base nas preferências dos discentes com personalidade similar à do discente alvo da recomendação (estratégia similar a UserKNN em FC). O resultado desta subetapa é, portanto, uma lista ordenada de OA relativa à execução do algoritmo de recomendação colaborativa baseada em personalidade, denominado nesta dissertação de PBR (*Personality Based Recommendation*).

2.3. **Recomendação baseada na Popularidade de Itens:** Para os OA do conjunto resultante da primeira etapa, é aplicado o algoritmo de recomendação baseada em popularidade de itens, ordenando-os com base na procura dos OA pelos outros discentes. O resultado desta subetapa é, portanto, uma lista ordenada de OA relativa à execução do algoritmo de recomendação MP (*Most Popular*).

3. Considerando-se as três listas ordenadas (*rankings*) resultantes das subetapas 2.1, 2.2 e 2.3, é calculado, nesta última etapa, o Grau de Recomendação (GR) para cada OA. Em seguida, os OA são ordenados

de maneira decrescente com base nesse GR, sendo, portanto, os primeiros OA desse *ranking* recomendados ao discente alvo.

A Equação 5 representa o Grau de Recomendação dos OA.

$$GR(oa) = \frac{1}{P_{EA}(oa)} + \frac{1}{P_{TP}(oa)} + \frac{1}{P_{MP}(oa)} \quad (5)$$

em que:

- $GR(oa)$  representa o Grau de Recomendação de determinado  $oa$ ;
- $oa \in K$ ;
- $K$  representa o conjunto de itens didáticos (OA) filtrados na 1ª etapa do gerador de recomendações,  $|K| > 0$ ;
- $GR(oa) \in \mathbb{R} \wedge 0 < GR(oa) \leq 3$ ;
- $P_{EA}(oa)$  representa a posição do  $oa$  no *ranking* relativo ao algoritmo LSBR, resultante da subetapa 2.1;
- $P_{EA}(oa) \in \mathbb{N} \wedge 1 \leq P_{EA}(oa) \leq |K|$ ;
- $P_{TP}(oa)$  representa a posição do  $oa$  no *ranking* relativo ao algoritmo PBR, resultante da subetapa 2.2;
- $P_{TP}(oa) \in \mathbb{N} \wedge 1 \leq P_{TP}(oa) \leq |K|$ ;
- $P_{MP}(oa)$  representa a posição do  $oa$  no *ranking* relativo ao algoritmo MP, resultante da subetapa 2.3;
- $P_{MP}(oa) \in \mathbb{N} \wedge 1 \leq P_{MP}(oa) \leq |K|$ .

Para exemplificar esse processo de recomendação, suponha-se que, com um total de 50 OA em um repositório, após a filtragem com base no conteúdo (etapa 1), foram definidos 10 OA que abordam o conteúdo de Ecologia. Após definidos esses 10 OA, eles são ordenados em três listas diferentes, com base nos EA do discente (subetapa 2.1), com base na Personalidade dos discentes (subetapa 2.2) e com base na popularidade de itens (subetapa 2.3). Depois de ordenados nessas três listas, são calculados os GR de cada um deles.

Considerando-se um OA 'D' na posição 5 da lista resultante da subetapa 2.1 ( $P_{EA} = 5$ ), na posição 3 da lista resultante da subetapa 2.2 ( $P_{TP} = 3$ ) e na posição 6 da lista baseada em popularidade ( $P_{MP} = 6$ ), seu GR será igual a 0,7, ou seja  $(1/5)+(1/3)+(1/6)$ . Outros exemplos são apresentados no Quadro 8, pelo qual é possível verificar que, para tal discente, o OA 'H' é julgado mais útil que os demais, enquanto o OA 'F' é julgado menos útil.

**Quadro 8. Exemplo de Cálculo do Grau de Recomendação de OA.**

OA	$P_{EA}(oa)$	$P_{TP}(oa)$	$P_{MP}(oa)$	Cálculo de $GR(oa)$	$GR(oa)$	Posição no <i>Ranking</i> Final
A	4	9	3	$(1/4)+(1/9)+(1/3)$	0,694	7º
B	9	6	2	$(1/9)+(1/6)+(1/2)$	0,778	4º
C	1	8	8	$(1/1)+(1/8)+(1/8)$	1,250	3º
D	5	3	6	$(1/5)+(1/3)+(1/6)$	0,700	6º
E	7	7	7	$(1/7)+(1/7)+(1/7)$	0,429	9º
F	10	10	5	$(1/10)+(1/10)+(1/5)$	0,400	10º
G	8	5	9	$(1/8)+(1/5)+(1/9)$	0,436	8º
H	2	1	4	$(1/2)+(1/1)+(1/4)$	1,750	1º
I	3	4	1	$(1/3)+(1/4)+(1/1)$	1,583	2º
J	6	2	10	$(1/6)+(1/2)+(1/10)$	0,767	5º

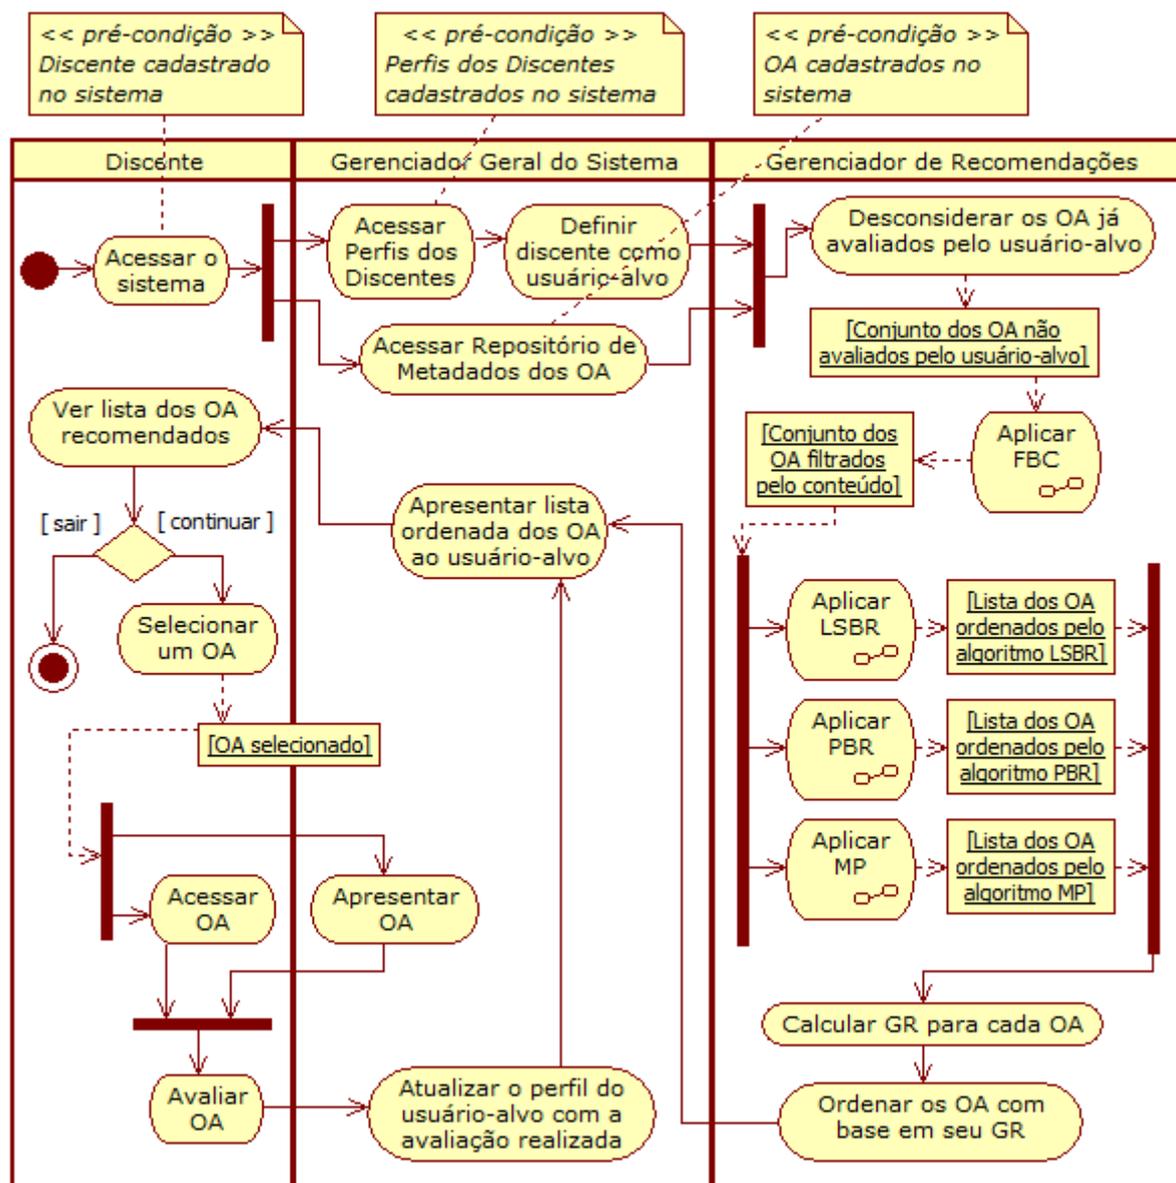
Apesar da teoria de EA ser diretamente relacionada ao processo de ensino-aprendizagem, é importante destacar que o modelo elaborado considera que não apenas essa teoria influencia na aprendizagem dos alunos. Este aspecto pode ser observado a partir dos exemplos do Quadro 8, no qual o OA 'A', em 4º lugar no *ranking* relacionado a EA, cai algumas posições e fica em 7º lugar ao considerar o modelo proposto. Outro exemplo é o OA 'C', em 1º lugar no *ranking* relacionado a EA e em 3º lugar considerando o modelo proposto. Percebe-se que esses casos ocorrem devido a considerar no modelo, além da popularidade dos itens, a teoria dos TP que, como comentado nos capítulos iniciais deste documento, também é um fator importante a considerar no processo de ensino-aprendizagem. Em relação aos exemplos dados, os OA 'A' e 'C' encontram-se, respectivamente, na posições 9 e 8 do *ranking* relacionado a TP.

Com o objetivo de detalhar o fluxo do modelo de recomendação proposto, na Figura 6 é apresentado um Diagrama de Atividades UML ([OMG, 2015](#); [GUDWIN, 2010](#)).

A pré-condição "OA cadastrados no sistema" consiste nos OA terem sido inseridos no sistema, conforme explicado na Seção 4.2, seguindo o padrão IEEE LOM (exemplificado do Quadro 7).

As pré-condições "Discente cadastrado no sistema" e "Perfis dos Discentes cadastrados no sistema" consistem nos discentes (aluno-alvo da recomendação e os demais alunos) terem seus perfis preenchidos, pelo responsável do sistema (a partir de, por exemplo, respostas dos alunos a inventários), conforme a formalização apresentada pela Equação 4 e exemplificada no Quadro 6 (Seção 4.1).

**Figura 6. Diagrama de atividades ilustrando o fluxo do modelo de recomendação proposto.**

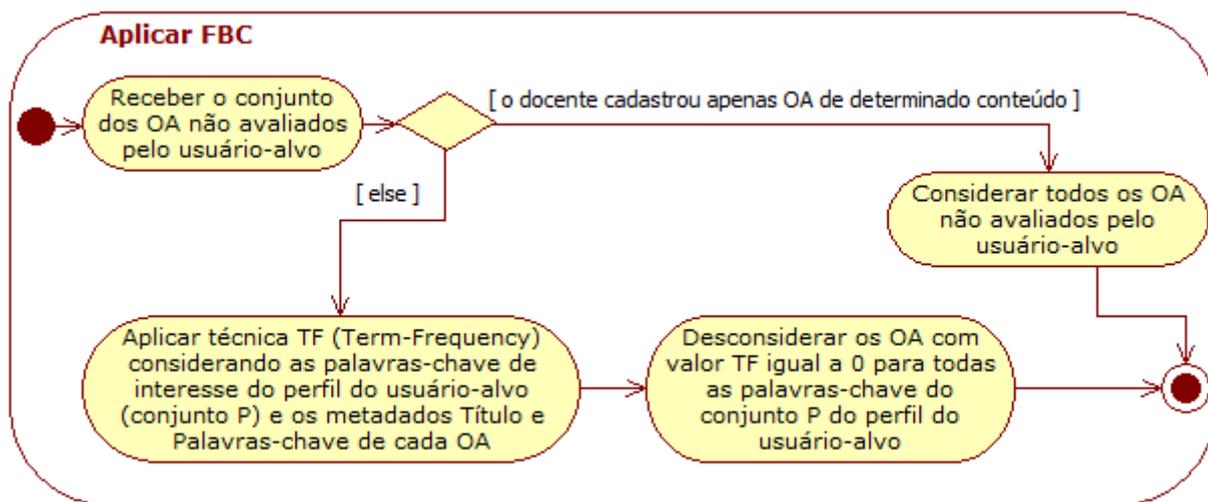


Ressalta-se que, para o modelo proposto, não foi limitada a escolha da ferramenta Five Labs e do ILS como instrumentos de mensuração dos EA e dos TP dos discentes. Esses instrumentos foram definidos para a avaliação do modelo (Seção 5.3) e, portanto, são sugeridas para uso. Todavia, reforça-se a possível utilização do modelo com outros instrumentos de mensuração, contanto que sigam o modelo *Big Five* e o modelo de Felder–Silverman.

Como é ilustrado na Figura 6, o processo de recomendação é iniciado com o acesso de um discente ao sistema. Internamente, o sistema acessa o Repositório de Metadados dos OA e os Perfis dos Discentes, definindo o discente que acessou o sistema como usuário-alvo da recomendação. Após isso, é

analisado pelo Gerenciador de Recomendações os OA já avaliados pelo usuário-alvo (disponíveis no conjunto A do perfil de discente). Com isso, o Gerenciador de Recomendações passa a tratar apenas o conjunto dos OA não avaliados pelo usuário-alvo<sup>2</sup>. A partir desse conjunto, é aplicada a filtragem por conteúdo. A subatividade “Aplicar FBC” é detalhada na Figura 7.

**Figura 7. Diagrama da subatividade Aplicar FBC.**



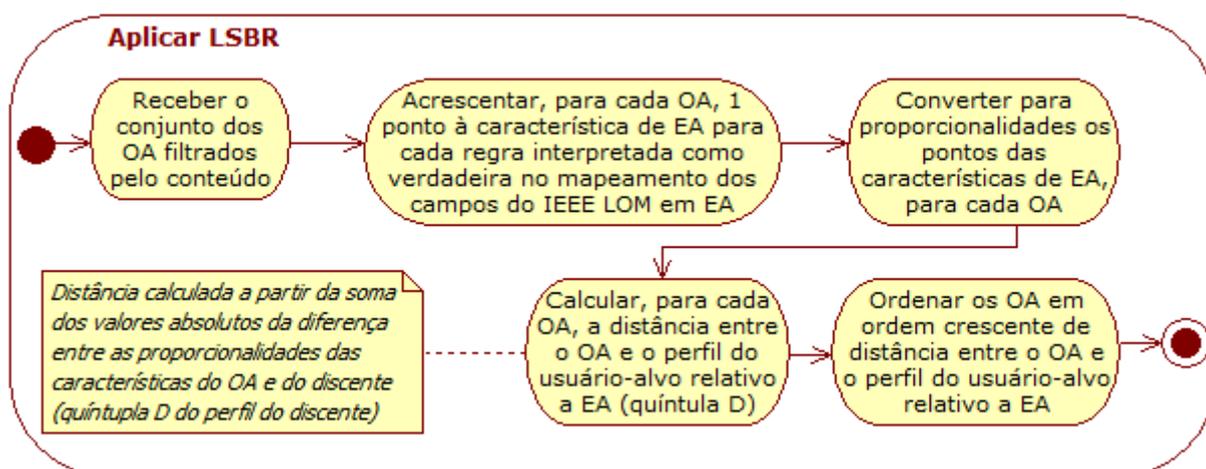
Como ilustrado na Figura 7, caso o docente cadastre apenas OA de determinado conteúdo, não é necessário realizar outra filtragem, devendo-se, portanto, considerar o conjunto anterior dos OA. Todavia, considerando-se OA cadastrados com variados assuntos, é possível aplicar alguma técnica de mineração de texto. No diagrama apresentado, considera-se a verificação da frequência dos termos (palavras-chave do conjunto P do perfil do usuário-alvo) nos metadados Título e Palavras-chave de cada OA. Uma vez que, nestes metadados, sejam contemplados os termos/palavras-chave de interesse do usuário-alvo, tal OA é considerado para a próxima etapa de recomendação.

Considerando-se o conjunto dos OA filtrados pelo conteúdo como saída da subatividade anterior, o Gerenciador de Recomendações repassa esse conjunto, paralelamente, como entrada para três algoritmos de recomendação.

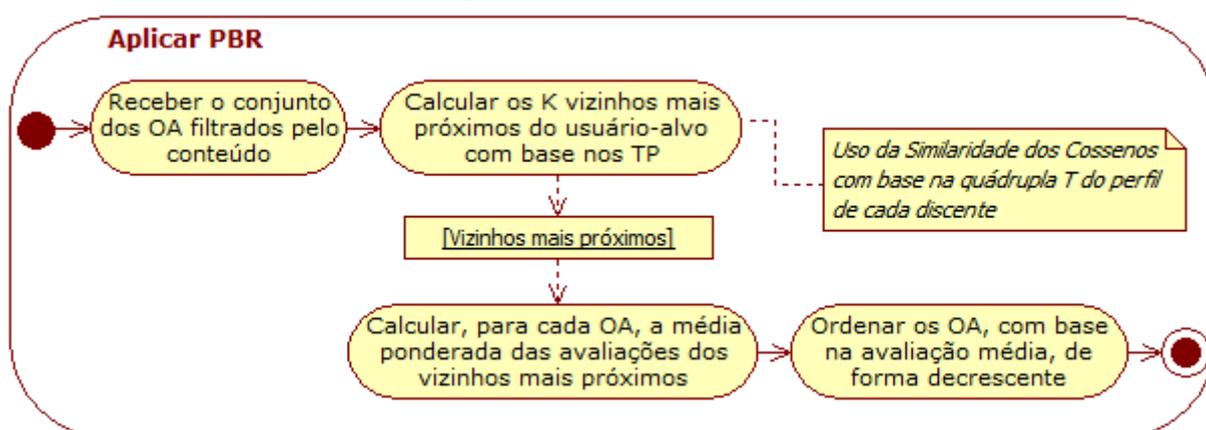
As subatividades “Aplicar LSBR”, “Aplicar PBR” e “Aplicar MP” são detalhadas, respectivamente, nas Figuras 8, 9 e 10.

<sup>2</sup> Ressalta-se que, dependendo de como seja planejada a interface do sistema com o usuário, poderiam ser considerados os OA já avaliados — além da lista de recomendação, poder-se-ia apresentar uma lista com os OA recomendados mais bem avaliados pelo usuário.

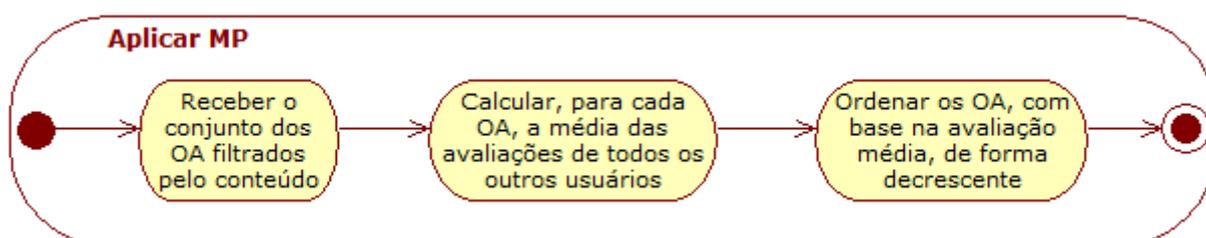
**Figura 8. Diagrama da subatividade Aplicar LSBR.**



**Figura 9. Diagrama da subatividade Aplicar PBR.**



**Figura 10. Diagrama da subatividade Aplicar MP.**



O algoritmo LSBR, como ilustrado na Figura 8, consiste na abordagem descrita por [Carvalho et al. \(2014\)](#), sendo, para cada OA, acrescentado 1 (um) ponto à característica de EA para cada regra interpretada como verdadeira no mapeamento apresentado no Quadro 4. Por exemplo: para o OA exemplificado no Quadro 7 (estrutura: linear; nível de agregação: 1; formato: áudio; tipo de interatividade: expositivo; tipo de recurso de aprendizagem: palestra; densidade semantica: médio; dificuldade: média; nível de interatividade: médio), a partir das regras do Quadro 4, são definidos 1 ponto para o estilo Ativo e 3 pontos para

o estilo Reflexivo (dimensão Processamento), 3 pontos para o estilo Sensorial e 0 ponto para o estilo Intuitivo (dimensão Percepção), 0 ponto para o estilo Visual e 2 pontos para o estilo Verbal (dimensão Entrada), 3 pontos para o estilo Sequencial e 1 ponto para o estilo Global (dimensão Compreensão).

Após isso, convertem-se os pontos para proporcionalidades. No exemplo, tem-se, portanto, 25% para o estilo Ativo e 75% para o estilo Reflexivo (dimensão Processamento), 100% para o estilo Sensorial e 0% para o estilo Intuitivo (dimensão Percepção), 0% para o estilo Visual e 100% para o estilo Verbal (dimensão Entrada), 75% para o estilo Sequencial e 25% para o estilo Global (dimensão Compreensão).

Com cada OA sendo representado por um valor percentual para os estilos de cada dimensão do modelo de Felder–Silverman, é possível calcular a distância entre os OA e o perfil do usuário-alvo relativo a EA. Ressalta-se que a quádrupla  $D$ , por questões de simplificação, apresenta apenas um valor para cada dimensão, mas este valor (como descrito na formalização apresentada na Seção 4.1) abrange ambos os estilos (por exemplo: o valor 75 representa 75% para o Estilo Reflexivo e, conseqüentemente, 25% para o Estilo Ativo).

Utilizando-se a ideia de proporcionalidades apresentada por [Carvalho et al. \(2014\)](#), a distância é calculada a partir da soma dos valores absolutos da diferença entre as proporcionalidades das características do OA e do discente. Por exemplo: para os usuários exemplificados no Quadro 6 e o OA exemplificado no Quadro 7, as distâncias entre este OA e os usuários  $u_1$ ,  $u_2$  e  $u_3$  são, respectivamente, 198 (ou seja:  $|75-91|+|0-34|+|100-13|+|25-86|$ ), 158 (ou seja:  $|75-67|+|0-52|+|100-57|+|25-80|$ ) e 97 (ou seja:  $|75-22|+|0-21|+|100-79|+|25-27|$ ); isto indica que tal OA é mais compatível com os EA do usuário  $u_3$  e menos compatível com os EA do usuário  $u_1$ . Após o cálculo das distâncias entre os OA e o perfil do usuário-alvo relativo a EA, os OA são listados em ordem crescente de distância.

O algoritmo PBR, como ilustrado na Figura 9, funciona similarmente ao algoritmo UserKNN comentado na Subseção 2.4.1.2. Todavia, os  $K$  vizinhos mais próximos do usuário-alvo são definidos com base nos TP. Não se pretende definir aqui um valor  $K$  a ser sempre utilizado, todavia, foi definido  $K=25$  (aproximadamente 50% do total de usuários) para a avaliação do modelo (detalhes na Subseção 5.3.3) e, portanto, sugere-se tal percentual para uso.

Para calcular a vizinhança no algoritmo PBR, foi utilizada a Medida dos

Cossenos com base na quintupla  $T$  do perfil de cada discente. Supondo os três usuários exemplificados no Quadro 6, a similaridade entre os usuários  $u_1$  e  $u_2$  é 0,65, enquanto a similaridade entre os usuários  $u_2$  e  $u_3$  é 0,88; neste exemplo, portanto, o usuário  $u_3$  é mais similar ao usuário  $u_2$  que o usuário  $u_1$ . Depois da definição da vizinhança, é calculada para cada OA a média ponderada (considerando-se os valores relativos à similaridade) das avaliações dos vizinhos mais próximos. Ou seja, no exemplo anterior, se os usuários  $u_1$  e  $u_3$  estivessem na vizinhança do usuário-alvo  $u_2$ , as avaliações de  $u_3$  teriam maior influência que as avaliações de  $u_1$ . Após o cálculo das avaliações médias, os OA são listados em ordem decrescente da avaliação (ou seja, são listados primeiro os OA melhor avaliados pelos usuários com personalidade similar à personalidade do usuário-alvo).

O algoritmo MP, como ilustrado na Figura 10, funciona de maneira similar ao algoritmo PBR, considerando-se a avaliação média dos outros usuários do sistema. Todavia, no algoritmo MP não se considera apenas uma parte dos usuários (vizinhos mais próximos), sendo considerados todos os usuários e sem ponderação (ou seja, uma abordagem colaborativa, mas não personalizada).

A partir das três listas dos OA ordenadas, calcula-se o GR para cada OA (com base na Equação 5) e, em seguida, ordena-se os OA com base nos GR de forma decrescente. Com isso, é apresentado pelo sistema a lista ordenada dos OA e, conseqüentemente, o discente (usuário-alvo) que acessou o sistema visualiza a lista dos OA recomendados. Uma vez que o discente decida continuar no sistema, ele pode selecionar um dos OA recomendados (a ser apresentado pelo sistema e acessado por este discente), avaliando-o após acessá-lo. Esta avaliação é armazenada no perfil do discente (conforme formalização apresentada na Seção 4.1). Após a realização da avaliação de determinado OA pelo discente, o sistema novamente apresenta a lista de OA recomendados para que o discente possa acessar outros OA, repetindo o processo de acesso/avaliação até que o discente decida sair do sistema.

É importante comentar que algumas ações do diagrama apresentado na Figura 6 podem ser realizadas uma vez, após o cadastro dos OA e dos Discentes, e reutilizadas depois, diminuindo o tempo de processamento para a geração das recomendações. Destacam-se, neste ponto, a ação de calcular a vizinhança no algoritmo PBR (os vizinhos só mudariam considerando-se inserções de discentes e/ou atualizações nos perfis dos discentes relativos a TP) e as subatividades

Aplicar FBC e Aplicar LSBR (só haveria mudanças na saída destes algoritmos considerando-se alterações no repositório de metadados dos OA e mudanças nos perfis dos discentes relativos a EA e palavras-chave de interesse).

## **4.4 Considerações Finais do Capítulo**

Objetivando-se a proposição de um modelo para a geração de recomendações personalizadas de OA (itens) para alunos (usuários), neste capítulo foi apresentado um modelo de SRE com base na popularidade e no conteúdo dos OA, além de baseado nos EA e nos TP dos discentes.

Na Figura 5, está sintetizada a ideia do modelo e, nas Seções 4.1, 4.2 e 4.3 foram comentadas as partes que o compõem. O fluxo do modelo, sintetizado na Figura 5, é detalhado nos diagramas de atividades (Figuras 6 a 10) apresentados e comentados ao final da Seção 4.3.

No próximo capítulo, são apresentadas as investigações empíricas realizadas durante a pesquisa, com destaque à avaliação do modelo proposto neste capítulo.

# Capítulo 5

## Apresentação e Análise dos Resultados

Visando-se a cumprir os objetivos específicos II a V e, conseqüentemente, o objetivo geral definidos na Seção 1.2 deste documento, foram realizadas as investigações empíricas descritas nas Seções 5.1 a 5.3.

A Seção 5.1 está relacionada ao objetivo específico II, explicando a metodologia utilizada para comparar formas de extração de TP e EA.

Na Seção 5.2, é apresentada a metodologia utilizada para confirmar a influência de EA na recomendação de OA com base em uma abordagem tratada na literatura. A estratégia adotada nesta seção corrobora com o objetivo específico III.

Na Seção 5.3, é apresentada a metodologia do experimento final, que se relaciona com os objetivos específicos III, IV e V, sendo este o experimento principal para alcançar o objetivo geral desta pesquisa.

Ao final de cada seção, são apresentados e comentados os resultados obtidos.

### 5.1 Investigação Empírica 1

Com o objetivo de simplificar a construção do perfil dos discentes/usuários do SRE, inferindo os EA a partir dos TP, foram definidos os instrumentos de mensuração e os participantes para esta investigação inicial.

Os instrumentos de mensuração foram, inicialmente, os questionários TIPI e ILS e, posteriormente, a ferramenta Five Labs. Os participantes consistiram em alunos do Curso Técnico em Informática da Escola Técnica Redentorista (ETER) de Campina Grande. De início, 61 alunos responderam aos dois questionários e, posteriormente, com a ferramenta Five Labs, foi possível extrair os TP de 49 desses 61 alunos.

Dessa forma, foi possível analisar a correlação entre esses instrumentos de mensuração, sendo apresentados os resultados obtidos nas Subseções 5.1.1 e 5.1.2. Para obter essas correlações, foi utilizado o coeficiente de correlação de Spearman ([BOSLAUGH; WATTERS, 2008](#)).

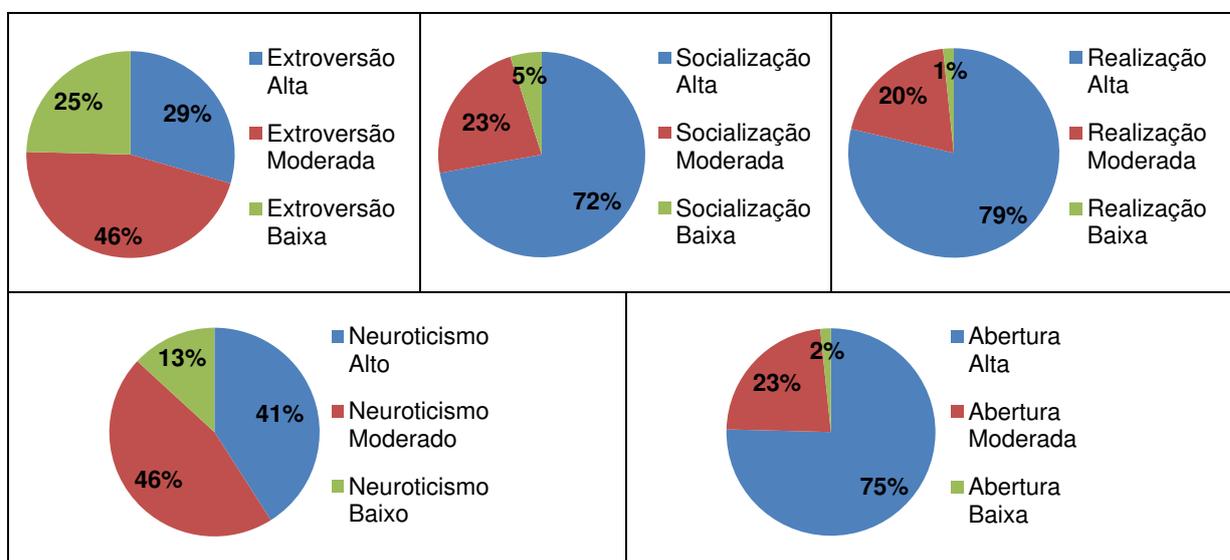
A descrição detalhada sobre a utilização do TIPI, ILS e Five Labs é apresentada em artigos citados no Apêndice A (“Identificando os Traços de Personalidade de Estudantes de um Curso Técnico em Informática”, “Utilização do Índice de Estilos de Aprendizagem de Felder–Soloman em Turmas de Nível Técnico, Graduação e Pós-Graduação em Computação” e “Utilização da ferramenta Five Labs para Identificação de Traços de Personalidade dos Estudantes”).

### 5.1.1 Correlação entre ILS e TIPI

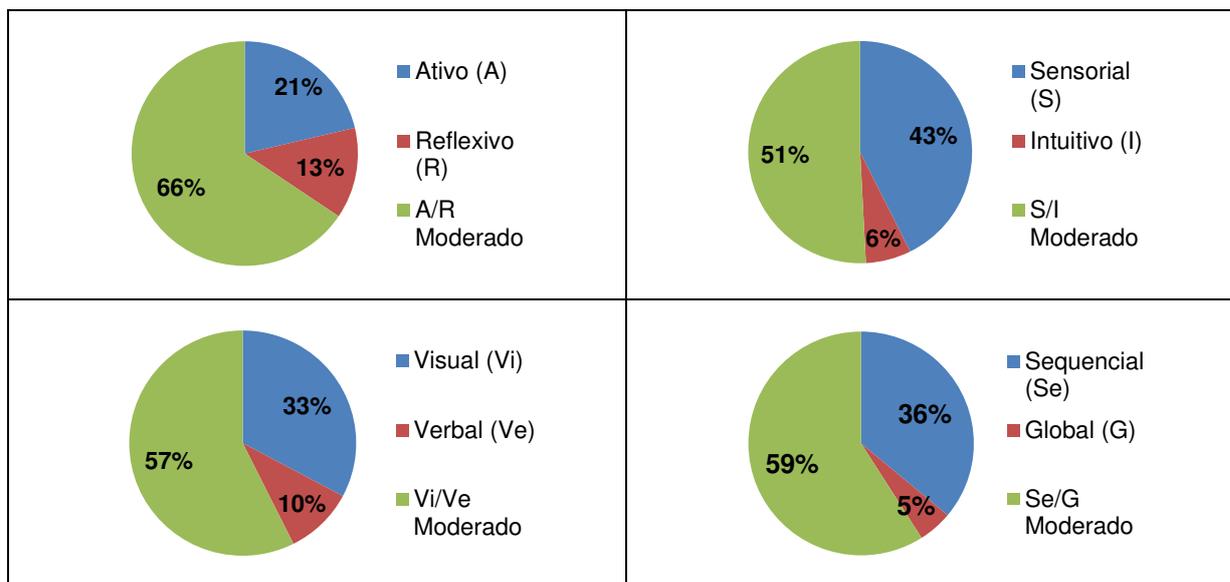
Nas Figuras 11 e 12, são apresentados os gráficos com os resultados, respectivamente, do questionário TIPI (traços: extroversão, socialização, realização, neuroticismo, abertura) e do questionário ILS (dimensões: processamento, percepção, entrada, compreensão). A fundamentação teórica sobre o assunto é apresentada no Capítulo 2 deste documento.

Percebe-se a heterogeneidade dos perfis dos alunos tanto em relação a TP (Figura 11) quanto em relação a EA (Figura 12). Os resultados por questionário apontam as ocorrências de diferentes preferências no modo de aprender (EA), além de diferentes personalidades dos alunos nas turmas.

**Figura 11. Resultado da Administração do Questionário TIPI com os alunos da ETER.**



**Figura 12. Resultado da Administração do Questionário ILS com os alunos da ETER.**



Em relação à correlação entre ILS e TIPI (Tabela 1 e Tabela 2), os valores negativos indicam, para as dimensões Processamento, Percepção, Entrada e Compreensão, correlação entre os TP e os estilos Ativo, Sensorial, Visual e Sequencial, respectivamente. Assim, os valores positivos indicam correlação entre cada traço, respectivamente para tais dimensões e os estilos Reflexivo, Intuitivo, Verbal e Global. As três correlações mais fortes em cada tabela estão destacadas em amarelo. Essas características também são válidas para as Tabelas 3 e 4 (Subseção 5.1.2).

**Tabela 1. Correlação entre EA e TP via TIPI, considerando-se os dados não agrupados em níveis.**

Dimensão EA \ Traço	Processamento (Ativo/Reflexivo)	Percepção (Sensorial/Intuitivo)	Entrada (Visual/Verbal)	Compreensão (Sequencial/Global)
Extroversão	-0,260	0,046	0,109	-0,118
Socialização	-0,230	-0,024	-0,064	-0,190
Realização	-0,062	-0,066	-0,018	-0,027
Neuroticismo	-0,211	0,066	-0,191	-0,201
Abertura	-0,207	0,123	0,062	0,016

**Tabela 2. Correlação entre EA e TP via TIPI, considerando-se os dados agrupados em 3 níveis.**

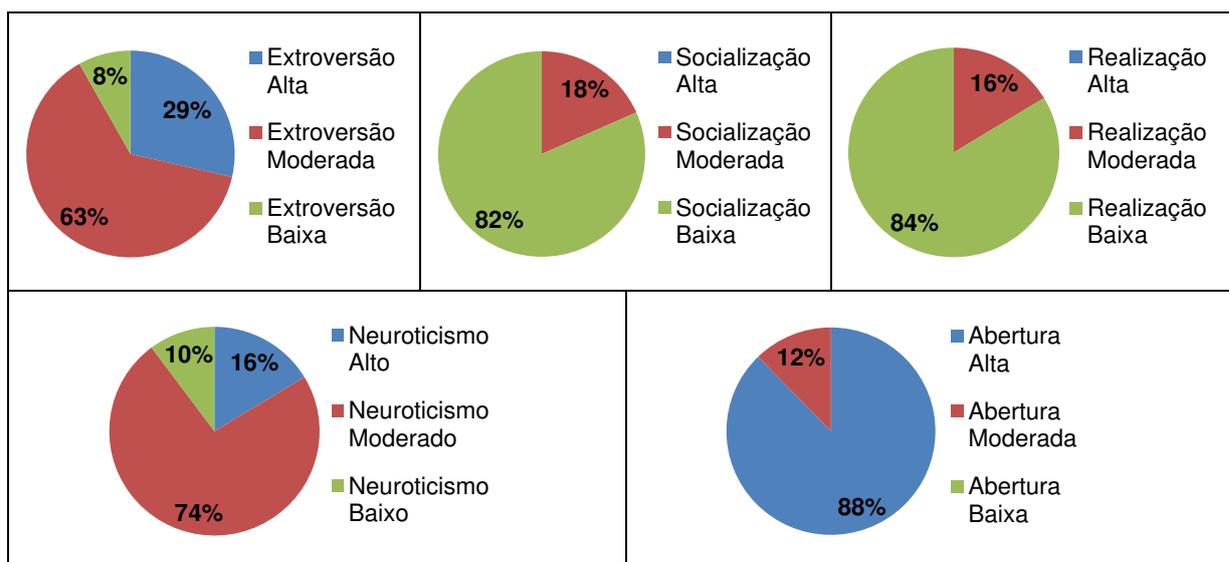
Dimensão EA \ Traço	Processamento (Ativo/Reflexivo)	Percepção (Sensorial/Intuitivo)	Entrada (Visual/Verbal)	Compreensão (Sequencial/Global)
Extroversão	-0,340	0,046	0,147	-0,156
Socialização	-0,109	-0,025	-0,030	-0,113
Realização	-0,088	-0,123	0,062	0,075
Neuroticismo	-0,192	0,104	-0,140	-0,064
Abertura	-0,166	0,187	0,273	0,041

Na Tabela 1, são apresentados os valores representativos das correlações, por cada TP e dimensão de EA, considerando-se os dados brutos, ou seja, não agrupados em níveis como nos gráficos da Figura 11 e da Figura 12. Na Tabela 2, por sua vez, são apresentados os valores considerando-se os dados agrupados em três níveis, como nesses gráficos. Com base nos valores apresentados nas Tabelas 1 e 2, não foi possível constatar correlações fortes entre os dados extraídos pelo Inventário TIPI e o Questionário ILS.

### 5.1.2 Correlação entre ILS e a ferramenta Five Labs

Na Figura 13, são apresentados os gráficos com os resultados, via ferramenta Five Labs. Percebe-se novamente a heterogeneidade dos perfis dos alunos em relação a TP.

**Figura 13. Resultado da Utilização da Five Labs pelos alunos da ETER.**



Com o uso da ferramenta Five Labs, em substituição ao TIPI, não foi possível constatar, mais uma vez, correlações fortes entre TP e EA (Tabela 3 e Tabela 4).

**Tabela 3. Correlação entre EA e TP via Five Labs, considerando os dados não agrupados em níveis.**

Dimensão EA \ Traço	Processamento (Ativo/Reflexivo)	Percepção (Sensorial/Intuitivo)	Entrada (Visual/Verbal)	Compreensão (Sequencial/Global)
Extroversão	-0,203	-0,075	0,125	-0,080
Socialização	-0,215	0,179	0,099	-0,036
Realização	0,003	-0,258	-0,007	-0,014
Neuroticismo	0,020	-0,002	-0,075	-0,095
Abertura	-0,038	0,036	-0,128	0,063

**Tabela 4. Correlação entre EA e TP via Five Labs, considerando os dados agrupados em 3 níveis.**

Dimensão EA \ Traço	Processamento (Ativo/Reflexivo)	Percepção (Sensorial/Intuitivo)	Entrada (Visual/Verbal)	Compreensão (Sequencial/Global)
<b>Extroversão</b>	-0,304	-0,323	0,369	-0,010
<b>Socialização</b>	-0,270	-0,026	0,000	0,025
<b>Realização</b>	0,014	-0,130	0,183	-0,175
<b>Neuroticismo</b>	0,147	0,076	0,082	0,103
<b>Abertura</b>	-0,086	0,118	-0,170	-0,108

Embora haja indícios, por exemplo, de que o Traço Extroversão seja correlacionado ao estilo Ativo (como defendem [Kuri \(2004\)](#) e [Senra \(2009\)](#)), em nenhum dos casos (Tabelas 1 a 4) chega-se a correlações maiores ou iguais a 40%.

Diante dos valores obtidos para as correlações, não se julgou possível desprezar o instrumento de mensuração próprio para EA e inferir as características por meio do TIPI (que é um questionário mais simplificado que o ILS), nem por meio da ferramenta Five Labs.

### 5.1.3 Análise Complementar de Correlação

Adicionalmente, foram analisados os dados relativos à personalidade obtidos via TIPI e via Five Labs. Não houve correlação forte entre esses dois meios de mensuração:

- Traço Extroversão: 0,111;
- Traço Socialização: -0,003;
- Traço Realização: 0,217;
- Traço Neuroticismo: 0,013;
- Traço Abertura: 0,151.

Considerando-se os diferentes resultados obtidos entre TIPI e Five Labs (ver Apêndice C), foi escolhida a ferramenta Five Labs como meio de mensuração para se utilizar o modelo proposto no Capítulo 4. Esta escolha justifica-se essencialmente pelo fato desta ferramenta ser baseada no estudo de [Schwartz et al. \(2013\)](#), que apresenta uma acurácia de 91,9% com o inventário NEO-IPIP (inventário mais completo que o TIPI).

## 5.2 Investigação Empírica 2

Para confirmar a influência de EA na recomendação de OA, foi utilizado o

protótipo de [Carvalho et al. \(2014\)](#), além de ter sido replicada sua estratégia experimental. Portanto, com base em perfis de estudante, tratados a seguir, foram analisadas as ordens de recomendações dos OA.

### **5.2.1 Planejamento e Execução**

Assim como no estudo de [Carvalho et al. \(2014\)](#), foram empregados OA fictícios<sup>3</sup> para a realização dos testes. Entretanto, os perfis de estudante foram tanto reais (baseando-se nos perfis coletados na Investigação Empírica 1 — Seção 5.1) quanto fictícios (sendo consideradas as porcentagens extremas para as 16 combinações possíveis de perfis de EA — por exemplo: 100% para Ativo, Sensorial, Visual e Sequencial, e, conseqüentemente, 0% para Reflexivo, Intuitivo, Verbal e Global). Vale ressaltar que todos os perfis de EA dos 61 alunos possuem diferença nessas porcentagens.

Ressalta-se, também, que os OA não foram os mesmos utilizados por [Carvalho et al. \(2014\)](#), mas aqueles que foram planejados para a Investigação Empírica final desta dissertação (ver Subseção 5.3.1 para detalhes sobre a definição desses OA).

Utilizando-se o protótipo disponibilizado, as etapas realizadas por [Carvalho et al. \(2014\)](#), e repetidas nesta pesquisa, são descritas a seguir.

1. Configurar os perfis de estudante com as probabilidades de preferências por EA.
2. Analisar os resultados obtidos para verificar:
  - i. se a similaridade entre a classificação de um OA e o perfil do estudante era mais próxima que os OA em posições inferiores da lista ordenada; e
  - ii. se havia alguma mudança ao se alterar a configuração de EA do estudante, mantendo a mesma predominância de preferências.

### **5.2.2 Resultados e Comentários**

Assim como foi verificado por [Carvalho et al. \(2014\)](#), ao se manter a preferência do estudante por determinados EA, foi percebido que variações nos valores das probabilidades dessas preferências fizeram com que alguns OA variassem

---

<sup>3</sup> OA fictícios, nesta pesquisa, referem-se à escolha de valores para os metadados do padrão IEEE LOM (a exemplo do Quadro 7), não necessariamente baseados em OA existentes em repositórios reais.

significativamente em sua ordem.

Na Tabela 5, são mostrados os OA ordenados considerando as porcentagens extremas para as 16 combinações possíveis de perfis de EA.

**Tabela 5. Variações na ordem dos OA com base nas 16 combinações extremas de perfis de EA.**

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16
1º	08	09	21	17	14	04	15	11	05	06	05	06	05	06	01	11
2º	07	23	08	20	03	23	14	10	07	09	07	11	07	09	16	12
3º	25	22	19	09	25	14	16	17	08	05	08	13	08	05	15	02
4º	14	06	07	18	15	22	21	20	24	22	19	09	06	22	11	10
5º	24	17	25	11	24	10	03	04	01	02	21	18	24	02	12	13
6º	05	20	15	13	16	02	19	18	06	23	06	12	01	23	19	18
7º	21	08	14	23	01	17	11	12	25	07	24	17	25	07	03	04
8º	19	18	24	22	21	20	25	13	03	13	01	20	09	13	21	17
9º	03	04	05	06	08	03	10	15	19	08	16	05	19	08	05	20
10º	09	07	16	10	19	09	24	23	09	04	25	22	03	18	02	01
11º	15	13	17	21	04	18	01	14	21	18	15	02	21	12	24	16
12º	23	25	20	08	07	12	17	16	14	12	11	10	22	04	10	06
13º	01	14	09	19	23	13	20	22	16	17	13	23	02	17	14	22
14º	16	24	18	04	22	11	04	02	22	20	09	07	16	20	25	15
15º	22	05	03	12	10	25	18	21	02	24	18	08	14	24	13	23
16º	06	10	11	07	05	15	12	03	15	01	12	19	23	01	07	19
17º	17	02	13	25	02	24	08	19	23	10	03	04	15	10	08	03
18º	20	21	23	15	17	16	13	09	13	25	17	21	13	25	18	09
19º	18	19	22	14	20	01	07	25	04	11	20	24	18	11	04	21
20º	04	03	06	24	09	06	23	24	18	03	22	01	12	19	17	05
21º	13	12	10	05	18	21	22	01	12	19	02	16	04	03	20	24
22º	10	11	01	16	12	08	02	06	17	21	10	25	17	21	06	14
23º	02	15	04	02	13	19	05	08	20	14	14	15	20	16	22	25
24º	12	01	12	03	11	07	09	07	10	16	23	03	10	14	23	07
25º	11	16	02	01	06	05	06	05	11	15	04	14	11	15	09	08

As combinações identificadas na Tabela 5 como C1 a C16 são representados como segue:

- C1: Ativo/Sensorial/Visual/Sequencial
- C2: Ativo/Sensorial/Visual/Global
- C3: Ativo/Intuitivo/Visual/Sequencial
- C4: Ativo/Intuitivo/Visual/Global
- C5: Ativo/Sensorial/Verbal/Sequencial
- C6: Ativo/Sensorial/Verbal/Global
- C7: Ativo/Intuitivo/Verbal/Sequencial
- C8: Ativo/Intuitivo/Verbal/Global
- C9: Reflexivo/Sensorial/Visual/Sequencial

- C10: Reflexivo/Sensorial/Visual/Global
- C11: Reflexivo/Intuitivo/Visual/Sequencial
- C12: Reflexivo/Intuitivo/Visual/Global
- C13: Reflexivo/Sensorial/Verbal/Sequencial
- C14: Reflexivo/Sensorial/Verbal/Global
- C15: Reflexivo/Intuitivo/Verbal/Sequencial
- C16: Reflexivo/Intuitivo/Verbal/Global

Como exemplo, são destacados na Tabela 5 os três primeiros OA na combinação C1 para facilitar a visualização de mudança de posição desses três OA nas outras combinações.

Na Tabela 6, são ilustradas as variações considerando perfis de estudantes reais (Apêndice D) e a ordem de recomendação dos OA, considerando os 10 primeiros do total de 25 OA.

Como exemplo, são destacados os OA 18, 19 e 21 para facilitar a visualização de mudança de posição desses três OA ao variar os estudantes. Esses três OA foram escolhidos por possuírem maior frequência no top-10 considerando todos os 61 alunos. De, no máximo, 61 possibilidades de ocorrência, o OA 19 apareceu 59 vezes, o OA 21 apareceu 58 vezes e o OA 18 apareceu 49 vezes.

Por outro lado, vale destacar estes fatos: (i) o OA 02 aparece em 1º lugar para o estudante do perfil 47 e não aparece em mais nenhum *ranking* Top-10; e (ii) o OA 04 aparece em 3º lugar para este mesmo estudante e só aparece novamente em 10º lugar para o estudante do perfil 48.

Esses resultados fornecem fortes indícios de que o estudante 47 tem um estilo peculiar em relação aos demais, e que em SR tradicionais (que não consideram EA) ele provavelmente não receberia tais recomendações.

Na pesquisa de [Carvalho et al. \(2014\)](#), os resultados mostraram-se, segundo os autores, potencialmente eficazes e promissores, ao testar todas as 16 combinações possíveis de perfis de EA, cada uma com diferentes variações em seus percentuais para o mesmo conjunto de OA. Na investigação realizada na pesquisa de mestrado ora descrita, incluindo perfis reais distintos, chega-se à mesma conclusão.

**Tabela 6. Exemplo de variação na ordem dos OA com base em diferentes perfis de EA de estudantes reais.**

	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11	P12	P13	P14	P15	P16
1º	21	17	17	25	07	17	15	19	21	21	21	21	17	24	21	21
2º	08	20	20	23	08	20	16	24	17	19	25	19	20	08	19	17
3º	19	18	18	24	05	21	21	21	20	08	17	25	21	07	17	20
4º	25	23	21	21	09	18	19	25	19	17	20	15	18	19	20	19
5º	07	21	19	22	24	13	10	07	18	20	19	24	09	25	18	18
6º	17	22	13	17	06	19	03	08	15	15	23	08	19	21	15	08
7º	20	13	23	20	22	15	14	16	25	25	24	16	23	05	25	25
8º	09	19	10	19	19	10	17	03	13	07	18	07	08	22	16	09
9º	24	25	22	08	25	16	20	15	23	18	22	17	25	03	24	15
10º	18	10	15	18	13	23	25	05	16	16	15	20	22	09	13	23
	P17	P18	P19	P20	P21	P22	P23	P24	P25	P26	P27	P28	P29	P30	P31	P32
1º	19	21	19	21	18	22	21	21	19	21	19	21	18	17	19	19
2º	21	15	21	19	13	24	17	19	21	19	24	17	13	20	07	21
3º	24	17	18	25	17	18	20	25	07	25	21	20	19	18	05	18
4º	08	20	17	08	20	23	19	17	05	24	25	19	17	23	21	13
5º	25	19	20	24	19	19	18	20	08	08	08	18	20	21	08	17
6º	16	16	16	07	21	25	15	15	16	17	18	15	07	13	24	20
7º	15	18	15	15	10	17	13	24	24	20	16	25	21	22	13	16
8º	07	13	24	17	22	20	25	18	15	15	22	13	09	19	18	24
9º	18	10	13	20	09	13	16	16	25	07	17	23	08	10	16	07
10º	17	25	25	16	23	21	23	08	13	18	20	16	22	25	25	15
	P33	P34	P35	P36	P37	P38	P39	P40	P41	P42	P43	P44	P45	P46	P47	P48
1º	13	19	24	08	21	18	19	18	07	07	21	25	25	19	02	17
2º	18	24	19	07	17	09	21	13	09	19	19	24	24	24	12	20
3º	19	07	25	24	20	19	08	19	08	24	17	21	21	18	04	23
4º	17	21	22	05	19	17	07	17	06	08	20	08	08	22	13	18
5º	20	25	07	25	18	20	18	20	05	05	18	19	19	21	10	22
6º	21	08	21	19	25	08	16	21	18	21	25	07	03	25	01	09
7º	22	18	08	21	23	22	24	22	22	25	15	03	23	17	22	13
8º	10	22	18	09	24	13	17	07	13	13	24	23	07	20	18	10
9º	24	13	23	03	08	07	20	09	19	18	16	22	22	23	03	21
10º	12	17	13	16	22	21	15	10	24	22	23	15	14	13	11	04
	P49	P50	P51	P52	P53	P54	P55	P56	P57	P58	P59	P60	P61			
1º	19	21	21	18	19	24	19	21	19	21	19	19	13			
2º	24	17	17	17	21	07	21	25	18	19	21	21	19			
3º	21	20	20	20	08	05	16	19	13	25	24	16	16			
4º	18	19	19	19	24	25	15	24	21	24	08	24	21			
5º	25	18	18	21	07	08	24	08	24	17	18	18	15			
6º	22	25	25	13	18	01	13	17	17	20	07	15	18			
7º	17	23	15	10	25	19	18	20	20	15	25	25	10			
8º	20	24	23	22	16	03	25	15	22	14	17	17	12			
9º	23	22	24	09	17	22	03	23	25	18	20	20	17			
10º	13	15	13	23	20	21	17	07	23	16	13	20				

É importante comentar que, adicionalmente, essa estratégia adotada por [Carvalho et al. \(2014\)](#) foi expandida com a estratégia de popularidade de itens, sendo comparados esse modelo expandido e o modelo original com algoritmos estado da arte em SR. Em geral, o modelo de [Carvalho et al. \(2014\)](#) e sua expansão com o MP apresentaram-se melhores que algoritmos tradicionais de FC — ver detalhes no Apêndice A (artigo intitulado “Recomendação de Objetos de Aprendizagem baseada na Popularidade dos Objetos e nos Estilos de Aprendizagem dos Alunos”).

### **5.3 Investigação Empírica 3**

No experimento abordado nesta seção, avalia-se o modelo apresentado no Capítulo 4, e, portanto, destaca-se como foco da pesquisa. As investigações empíricas anteriores serviram como alicerce para sua realização.

O objetivo desta investigação consistiu em analisar algoritmos do estado da arte em SR (expostos no Capítulo 2) e o algoritmo implementado a partir do modelo proposto no Capítulo 4, com a intenção de compará-los a respeito de sua acurácia, do ponto de vista de discentes que recebem recomendações de OA.

A questão de pesquisa pode ser descrita, portanto, desta forma: “Que algoritmo, dentre os algoritmos de recomendação a serem comparados, apresenta maior acurácia?”.

#### **5.3.1 Base de Dados**

Além de poucas bases de dados úteis para avaliar SRE, não foi encontrada uma que contivesse a preferência dos usuários sobre uma diversidade de OA, seguindo o padrão IEEE LOM (e com os metadados considerados nesta pesquisa preenchidos), além das informações dos usuários sobre seus EA (conforme o modelo de Felder–Silverman) e seus TP (conforme o modelo *Big Five*).

Devido à necessidade desses dados para execução do experimento, foi elaborado um formulário, contendo 5 etapas (Informações Iniciais; Avaliação de OA; Uso da ferramenta Five Labs; Questionário ILS; Opiniões), sendo preenchido *online* por alunos de Ciência da Computação da Universidade Federal de Campina Grande (UFCG) — 23 alunos da graduação e 19 alunos da pós-graduação — e da Universidade Federal Rural de Pernambuco (UFRPE) — 12 alunos da graduação.

Após a 1ª etapa com informações iniciais (tais como uma breve descrição

do objetivo da pesquisa), a 2ª etapa consistiu em extrair as preferências dos usuários, sendo definidas 25 variações de características de OA, para as quais os usuários realizaram avaliações em uma escala de 1 a 5 (similar à estratégia de definir 1 a 5 estrelas em sites de compra) — ver Apêndice E.

Na 3ª etapa, para extrair os TP, os participantes inseriram no formulário as porcentagens apresentadas no gráfico disponibilizado pela ferramenta Five Labs. Após isso, na 4ª etapa, os participantes responderam ao questionário ILS (Anexo A). Por fim, na 5ª etapa do formulário, foram elaboradas 5 afirmativas relativas à pesquisa (Apêndice F) para os usuários definirem seu grau de concordância, a partir de uma escala Likert de cinco pontos, além de haver um campo opcional para possíveis comentários.

Além das justificativas elencadas na Seção 2.5, ressalta-se que o uso do ILS, em vez de uma abordagem automática para extração das informações dos EA, justifica-se pelo experimento não ter sido realizado em um ambiente de aprendizagem, por meio do qual fosse possível extrair tais informações a partir do comportamento dos alunos.

Ao todo, foram obtidas 54 respostas e, portanto, a base de dados consistiu em avaliações de cada um dos 54 usuários para 25 itens (OA fictícios), sendo cada usuário caracterizado por TP (segundo o modelo *Big Five*) e EA (segundo o modelo de Felder–Silverman), além de opiniões desses usuários sobre o modelo proposto e o experimento.

Existem muitos OA disponíveis na Web, a exemplo dos encontrados nos repositórios citados na Seção 2.1. Na pesquisa não foram usados OA reais, uma vez que o foco aqui está nas características, além da dificuldade de que o uso de OA reais poderia demandar mais tempo dos colaboradores/participantes da pesquisa, dado que cada aluno teria que acessar cada um dos 25 OA (variando em vídeos, áudios, textos etc.) e, só após o contato completo com cada um, se poderia avaliá-los. Como o foco da pesquisa está voltado para as características, essa abordagem não foi adotada.

Uma vez que são 8 atributos do padrão IEEE LOM considerados no mapeamento de [Carvalho et al. \(2014\)](#), se fossem considerados todos, para o estudante diferenciá-los e julgá-los, o tempo despendido e o esforço mental seriam muito grandes. Dessa forma, foram consideradas, para a realização do experimento, estas 4 características: Formato, Tipo de Interatividade, Tipo de Recurso de Aprendizagem, e Estrutura. Além disso, no experimento, é

especificado que o assunto abordado em todos os OA seria o mesmo, alterando-se apenas a forma como é apresentada (tal fato se justifica porque o foco está voltado para os EA dos alunos).

O principal motivo de escolha dessas características foi a abrangência de cada uma delas em relação às dimensões de EA. Como é possível ver a partir do Quadro 3 e do Quadro 4, o Tipo de Recurso de Aprendizagem é relacionado com todas as 4 dimensões de EA, o Formato com 3 delas, o Tipo de Interatividade com 2 delas e os outros cinco atributos restantes com apenas 1 delas.

Enquanto a característica Dificuldade é relacionada apenas à dimensão Percepção, o Nível de Interatividade relaciona-se apenas à dimensão Processamento. Em ambos os casos, verificou-se que essas duas dimensões eram contempladas por regras associadas às características Formato, Tipo de Interatividade e Tipo de Recurso de Aprendizagem. Portanto, foram desconsideradas as características Dificuldade e Nível de Interatividade na apresentação dos OA neste experimento.

As características Nível de Agregação, Densidade Semântica e Estrutura são relacionadas apenas à dimensão Compreensão. E apenas a característica Tipo de Recurso de Aprendizagem também fazia associação com essa dimensão. Assim, decidiu-se considerar uma delas na apresentação dos OA neste experimento. Dentre as 3, foi escolhida a característica Estrutura, por ser mais fácil o aluno compreender seu significado, além desta estar presente no mapeamento de [Resende et al. \(2014\)](#).

Uma vez decidido o uso dessas 4 características (Formato, Tipo de Interatividade, Tipo de Recurso de Aprendizagem, Estrutura), foram geradas as possibilidades de OA, com base nestes níveis definidos a partir do padrão IEEE LOM e do mapeamento do Quadro 4, para a característica:

- Formato: áudio, imagem, texto, texto/html ou vídeo;
- Tipo de Interatividade: expositivo, ativo ou misto;
- Tipo de Recurso de Aprendizagem: exercício, experimento, figura, gráfico, narrativa, *slide* ou tabela; e
- Estrutura: linear ou rede.

Os outros níveis possíveis apresentados no Quadro 4 foram desconsiderados, por serem contemplados em regras, em geral, relativas aos níveis escolhidos (e. g., diagrama e figura são ambas relacionadas apenas aos estilos sensorial e visual).

Dessa forma, foram obtidas 210 combinações dos valores dos campos do padrão IEEE LOM. A partir disso, foram desconsideradas as combinações consideradas confusas (com pouco ou nenhum sentido), a exemplo de OA representados por figuras/gráficos em formato de áudio. Depois dessa etapa, restaram 62 combinações e, para cada uma destas, foram calculados, a partir do protótipo de [Carvalho et al. \(2014\)](#), os valores percentuais relativos aos EA (e. g., 33% para o estilo Ativo e 67% para o estilo Reflexivo; 50% para o estilo Sensorial e 50% para o estilo Intuitivo; 34% para o estilo Visual e 66% para o estilo Verbal; e 0% para o estilo Sequencial e 100% para o estilo Global).

Após analisar os valores percentuais relativos aos EA para cada uma dessas 62 combinações, foram desconsideradas 18 combinações que possuíam os mesmos valores. Das 44 combinações restantes, foram selecionadas 25 com os valores percentuais mais diferentes (apresentadas no Apêndice E), uma vez que se julgou não ser uma quantidade muito pequena e, ao mesmo tempo, não demasiada para os colaboradores avaliarem durante o experimento.

Vale ressaltar que, ao final dessas etapas, não restou nenhuma combinação com o tipo de recurso *slide* (definido inicialmente). E, para não ficar muito repetitivo, em alguns casos foi trocado o recurso narrativa pelo termo palestra, uma vez que contemplavam as mesmas regras.

### **5.3.2 Variáveis e *Design* do Experimento**

As variáveis independentes (fatores) e seus respectivos níveis consistiram em:

- Algoritmo: algoritmo de recomendação que tem como entrada os dados da base. Níveis para este fator: ItemKNN, UserKNN, BPRMF, MP, LSBR, PBR, PBR+LSBR, PBR+LSBR+MP.
- Percentual dos dados utilizado para a base de treinamento: porcentagem dos dados para o treinamento do algoritmo de recomendação; os dados restantes consistem na base de teste, considerando o método *Random Subsampling*, variação do método *Holdout* ([HAN e KAMBER, 2006](#)). Níveis para este fator: 55%, 65%, 75%.

Ressalta-se que, como afirmado na Subseção 5.3.1, foi definido, para o experimento, que o assunto abordado em todos os OA seria o mesmo, ou seja, considerou-se realizada uma etapa prévia de filtragem por conteúdo e, portanto,

não foram considerados algoritmos de FBC entre os níveis do fator Algoritmo. Assim, o algoritmo híbrido PBR+LSBR+MP consiste no modelo proposto nesta dissertação. Os outros algoritmos escolhidos para os níveis foram o ItemKNN, o UserKNN, o BPRMF (por serem algoritmos tradicionais de FC), o PBR, o LSBR e o MP (uma vez que compõem o algoritmo híbrido). Além desses, julgou-se pertinente considerar o algoritmo híbrido sem a parte relativa ao algoritmo MP (PBR+LSBR).

Embora, tipicamente, atribuem-se dois terços dos dados ao conjunto de treinamento ([HAN e KAMBER, 2006](#)), julgou-se interessante variar, em três níveis, o percentual dos dados utilizado para a base de treinamento. Por isso, foi definido o valor 65% (aproximadamente dois terços), e a variação de 10% para mais e para menos (55% e 75%).

As variáveis dependentes (variáveis de resposta) são métricas relacionadas à acurácia da recomendação (expostas na Subseção 2.4.2), consistindo em valores numéricos, decimais, de natureza quantitativa. São elas:

- AUC;
- MAP;
- MRR;
- NDCG;
- $P@5$  ( $P@n, n=5$ );
- $R@5$  ( $R@n, n=5$ ).

Definidas as variáveis dependentes e independentes, foram definidas, com base na questão de pesquisa, as hipóteses apresentadas no Quadro 9.

**Quadro 9. Definição das hipóteses.**

<b>Hipótese 1 (H1)</b>	H1 nula ( $H1_0$ ): O valor de AUC para os algoritmos em estudo é igual.
	H1 alternativa ( $H1_1$ ): O valor de AUC para os algoritmos em estudo é diferente.
<b>Hipótese 2 (H2)</b>	H2 nula ( $H2_0$ ): O valor de MAP para os algoritmos em estudo é igual.
	H2 alternativa ( $H2_1$ ): O valor de MAP para os algoritmos em estudo é diferente.
<b>Hipótese 3 (H3)</b>	H3 nula ( $H3_0$ ): O valor de MRR para os algoritmos em estudo é igual.
	H3 alternativa ( $H3_1$ ): O valor de MRR para os algoritmos em estudo é diferente.
<b>Hipótese 4 (H4)</b>	H4 nula ( $H4_0$ ): O valor de NDCG para os algoritmos em estudo é igual.
	H4 alternativa ( $H4_1$ ): O valor de NDCG para os algoritmos em estudo é diferente.
<b>Hipótese 5 (H5)</b>	H5 nula ( $H5_0$ ): O valor de $P@5$ para os algoritmos em estudo é igual.
	H5 alternativa ( $H5_1$ ): O valor de $P@5$ para os algoritmos em estudo é diferente.
<b>Hipótese 6 (H6)</b>	H6 nula ( $H6_0$ ): O valor de $R@5$ para os algoritmos em estudo é igual.
	H6 alternativa ( $H6_1$ ): O valor de $R@5$ para os algoritmos em estudo é diferente.

Se pelo menos uma das hipóteses nulas  $H_{1_0}$ ,  $H_{2_0}$ ,  $H_{3_0}$ ,  $H_{4_0}$ ,  $H_{5_0}$  e  $H_{6_0}$  for rejeitada, há diferença entre os algoritmos e, com base nos intervalos de confiança para a média (índice de tendência central), analisam-se as variáveis dependentes relativas à acurácia para responder à questão de pesquisa.

Este experimento é do tipo comparativo e o *design* utilizado foi o *Design Fatorial Completo*, uma vez que o custo para cada execução não é alto. Dados os fatores e níveis anteriormente detalhados, tem-se 24 tratamentos, sendo realizadas 100 repetições para cada, totalizando 2.400 ensaios. Os tratamentos são detalhados no Quadro 10.

**Quadro 10. Definição dos tratamentos do experimento final.**

<b>Tratamento</b>	<b>Algoritmo</b>	<b>Percentual dos dados utilizada para a base de treinamento</b>
1	ItemKNN	55%
2	ItemKNN	65%
3	ItemKNN	75%
4	UserKNN	55%
5	UserKNN	65%
6	UserKNN	75%
7	BPRMF	55%
8	BPRMF	65%
9	BPRMF	75%
10	MP	55%
11	MP	65%
12	MP	75%
13	LSBR	55%
14	LSBR	65%
15	LSBR	75%
16	PBR	55%
17	PBR	65%
18	PBR	75%
19	PBR+LSBR	55%
20	PBR+LSBR	65%
21	PBR+LSBR	75%
22	PBR+LSBR+MP	55%
23	PBR+LSBR+MP	65%
24	PBR+LSBR+MP	75%

### **5.3.3 Execução do experimento**

Em cada replicação do experimento, houve randomização dos conjuntos de treinamento. Outras randomizações não foram necessárias, pois os ensaios são independentes. A execução do experimento envolveu os seguintes passos:

- Coleta dos dados;
- Separação aleatória dos dados em conjuntos de treinamento e teste;
- Execução de algoritmos de recomendação para obtenção das métricas;
- Análise estatística dos resultados.

A coleta dos dados consistiu, inicialmente, no envio do formulário para os alunos (como exposto na Subseção 5.3.1) e, após os preenchimentos, os dados foram organizados para indicar, para cada usuário, suas avaliações para os OA, e os dados percentuais para os EA e os TP. Em seguida, os dados foram separados aleatoriamente, por 100 vezes, em conjuntos de treinamento e teste, considerando-se também a variação do percentual dos dados utilizado para a base de treinamento (55%, 65%, 75%).

A organização dos dados, a separação aleatória dos conjuntos, a implementação e a execução dos algoritmos PBR, LSBR e dos modelos híbridos foram realizadas utilizando a linguagem de programação Java ([ORACLE, 2015](#)), a partir da versão Kepler do ambiente Eclipse ([THE ECLIPSE FOUNDATION, 2015](#)).

Para a execução dos algoritmos BPRMF, ItemKNN e UserKNN, foi utilizada a biblioteca MyMediaLite ([GANTNER et al., 2011](#)), a qual possui diversos algoritmos de recomendação implementados, gerando saídas da aplicação dos algoritmos em determinada base de dados. A partir da biblioteca, foi possível gerar arquivos de saída contendo o identificador de cada usuário e, para cada um deles, uma lista ordenada dos identificadores dos itens, representando o *ranking* de recomendações de OA.

Para execução do algoritmo BPRMF, foram adicionados os seguintes parâmetros opcionais de recomendação: número de fatores latentes por usuário (`num_factors`) igual a 150 e número de iterações (`num_iter`) igual a 200. Tais valores foram escolhidos via experimento considerando o resultado relativo à métrica AUC, adotada no artigo de [Rendle et al. \(2009\)](#), no qual foi comparada a estratégia de BPRMF com outras estratégias de MF. Com base em valores para o número de fatores latentes (10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 150, 200, 250, 300, 350, 400, 450, 500, 1000) e valores para o número de iterações (30, 40, 50, 60, 70, 80, 90, 100, 150, 200, 250, 300, 350, 400, 450, 500, 1000) — e replicando 20 vezes para gerar intervalos de confiança —, percebeu-se que os valores *default* do MyMediaLite (`num_factors=10` e `num_iter=30`) proporcionaram baixo desempenho em relação a outras variações e que, quanto

maiores os números de fatores latentes e iterações, geralmente os resultados melhoraram até os valores escolhidos, apresentando desempenho similar com valores maiores.

Para execução do algoritmo ItemKNN, foi definido o parâmetro  $k$ , que indica a quantidade de itens a serem considerados vizinhos mais próximos. Uma vez que o total de itens foi 25,  $k=25$  indicou em geral ser o melhor parâmetro para  $k$  (dentre os valores de  $k$  analisados: 5, 10, 15, 20, 25). Entretanto, uma vez que o ideal é não tratar esse parâmetro com o valor igual ao total de itens, foi definido o valor 15, uma vez que este valor representa aproximadamente a metade do total de itens, além de ter apresentado, em geral, desempenho melhor ou similar aos valores 5, 10 e 20.

Para execução do algoritmo UserKNN, foi definido o parâmetro  $k$ , que indica a quantidade de usuários a serem considerados vizinhos mais próximos. Os valores de  $k$  mais próximos ao total de usuários (54) indicaram em geral ser os melhores para o parâmetro (foram analisados estes valores para  $k$ : 5, 10, 15, 20, 25, 30, 40, 50, 54). Entretanto, uma vez que o ideal é não tratar esse parâmetro com o valor igual ao total de usuários, foi considerada uma estratégia similar à adotada para o algoritmo ItemKNN, sendo definido o valor 25, uma vez que este valor representa aproximadamente a metade do total de usuários. Vale ressaltar que este mesmo valor de  $k$  foi definido para a quantidade de usuários/vizinhos mais próximos no algoritmo PBR.

Ressalta-se também que foi definido 3 como o limiar de execução e avaliação (valor médio das possíveis avaliações dos usuários), sendo a avaliação (cálculo das métricas AUC, MAP, MRR, NDCG, P@5 e R@5) também realizada com base na implementação da biblioteca MyMediaLite.

A análise estatística dos resultados foi realizada por meio do ambiente R ([R CORE TEAM, 2013](#)), para sumarizar os resultados obtidos, realizar testes e gerar intervalos de confiança (com nível de confiança de 95%) para a comparação entre algoritmos.

### **5.3.4 Resultados do Experimento**

Utilizando-se, inicialmente, estatística descritiva para sumarizar os dados, foi possível realizar uma breve análise e ter melhor entendimento do comportamento das variáveis.

Analisando os *boxplots* elaborados (Figuras 23 a 34 do Apêndice G), percebe-se que os algoritmos apresentam desempenho diferente, indiciando que as hipóteses  $H1_0$ ,  $H2_0$ ,  $H3_0$ ,  $H4_0$ ,  $H5_0$ , e  $H6_0$  podem ser rejeitadas. Além disso, os *boxplots* demonstram que o percentual dos dados utilizado para a base de treinamento tem grande influência quanto às métricas. Portanto, foi necessário considerar a blocagem dos dados por esse fator e realizar a análise separadamente nesses blocos.

A partir da análise estatística realizada (baseada no teste ANOVA ([JAIN, 1991](#)) e no teste de Kruskal-Wallis ([BOSLAUGH; WATTERS, 2008](#)), detalhada no Apêndice G), é possível rejeitar todas as hipóteses nulas definidas na Subseção 5.3.2, aceitando, por conseguinte, as hipóteses alternativas.

Após essa verificação das hipóteses, foram gerados intervalos de confiança para as médias, com nível de significância de 0,05, a fim de responder à questão de pesquisa (ver Figuras 14 a 16).

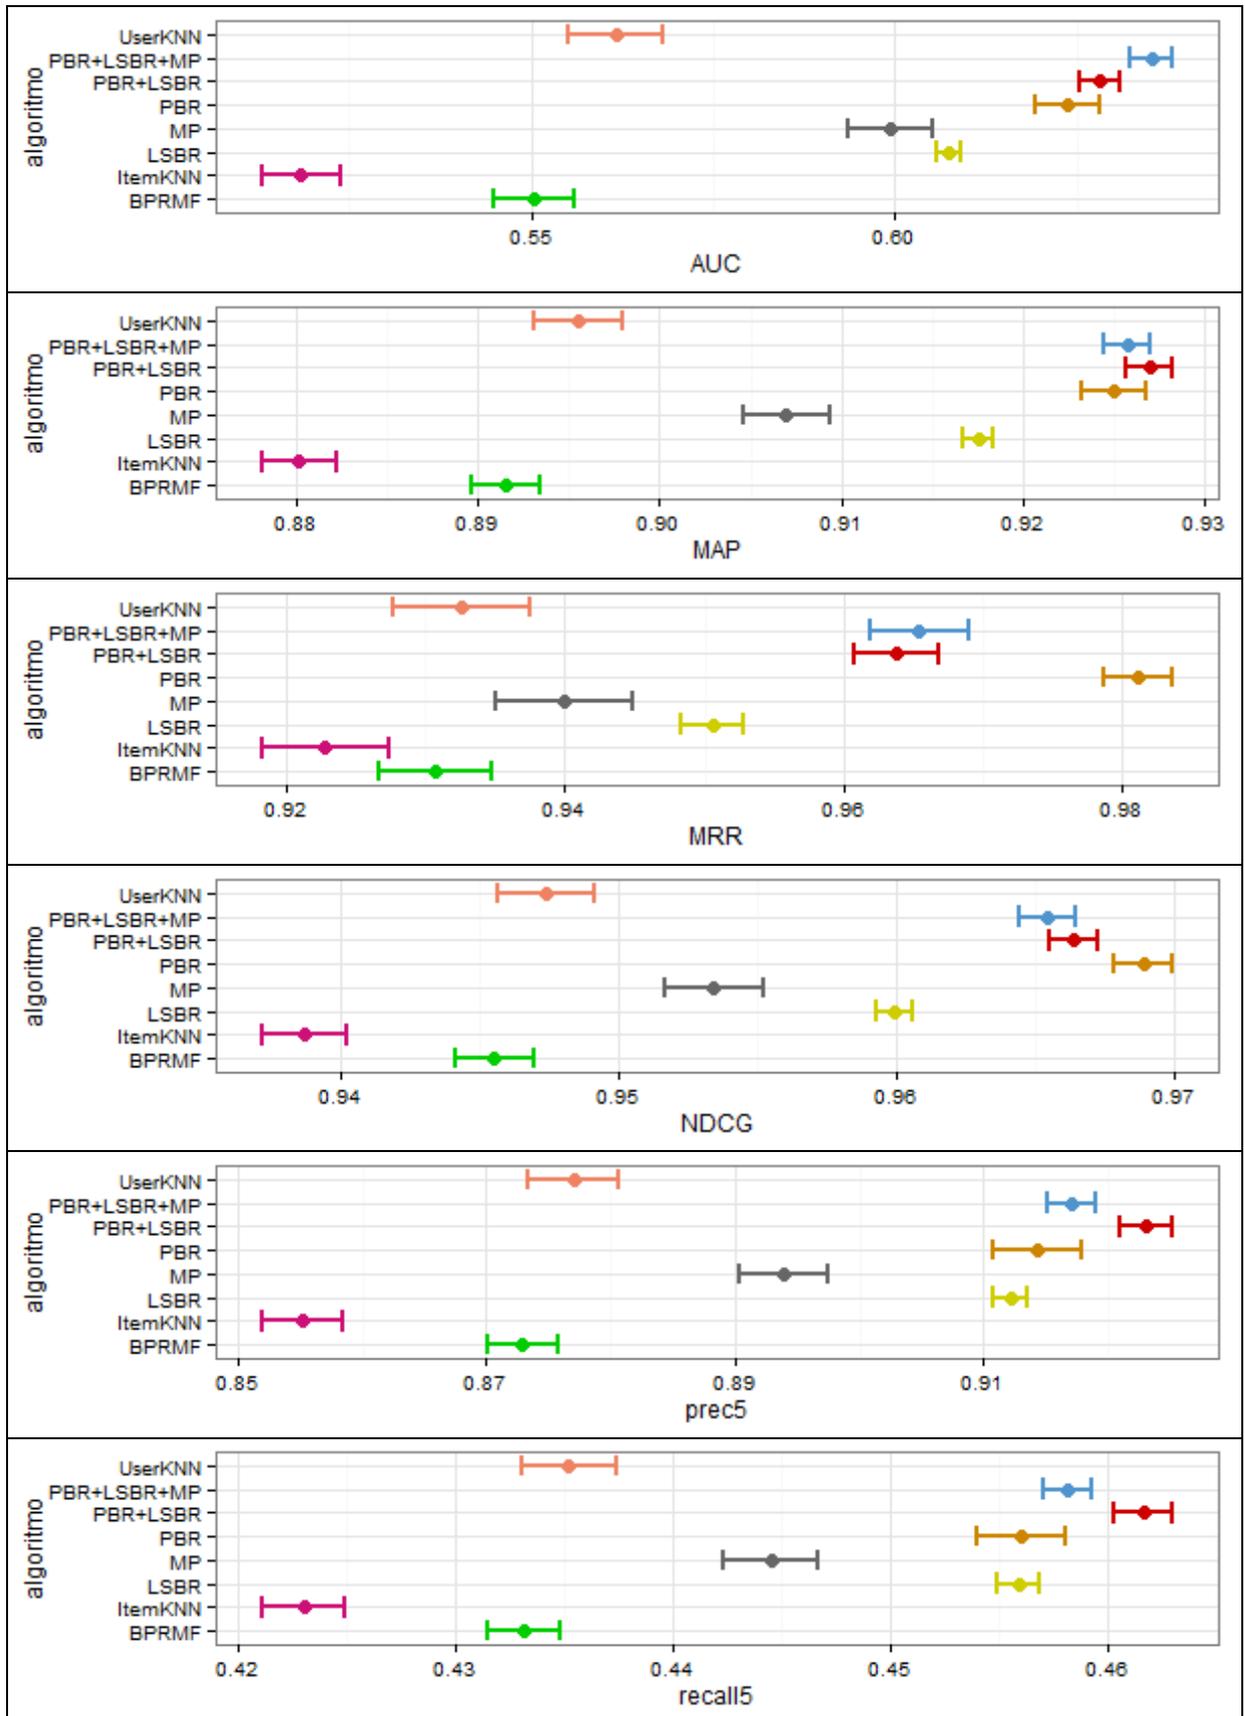
Com base nos intervalos de confiança das Figuras 14 a 16, percebe-se, em geral, um destaque positivo no desempenho do algoritmo PBR+LSBR+MP (em azul), especialmente quando comparado com algoritmos tradicionais de FC (UserKNN, ItemKNN, BPRMF).

Uma vez que alguns intervalos de confiança se sobrepuseram, foram realizados também testes T (paramétrico) e Mann-Whitney U (não paramétrico) ([BOSLAUGH; WATTERS, 2008](#)), par a par (*pairwise*), para saber se era possível realmente diferenciar os algoritmos desses intervalos sobrepostos.

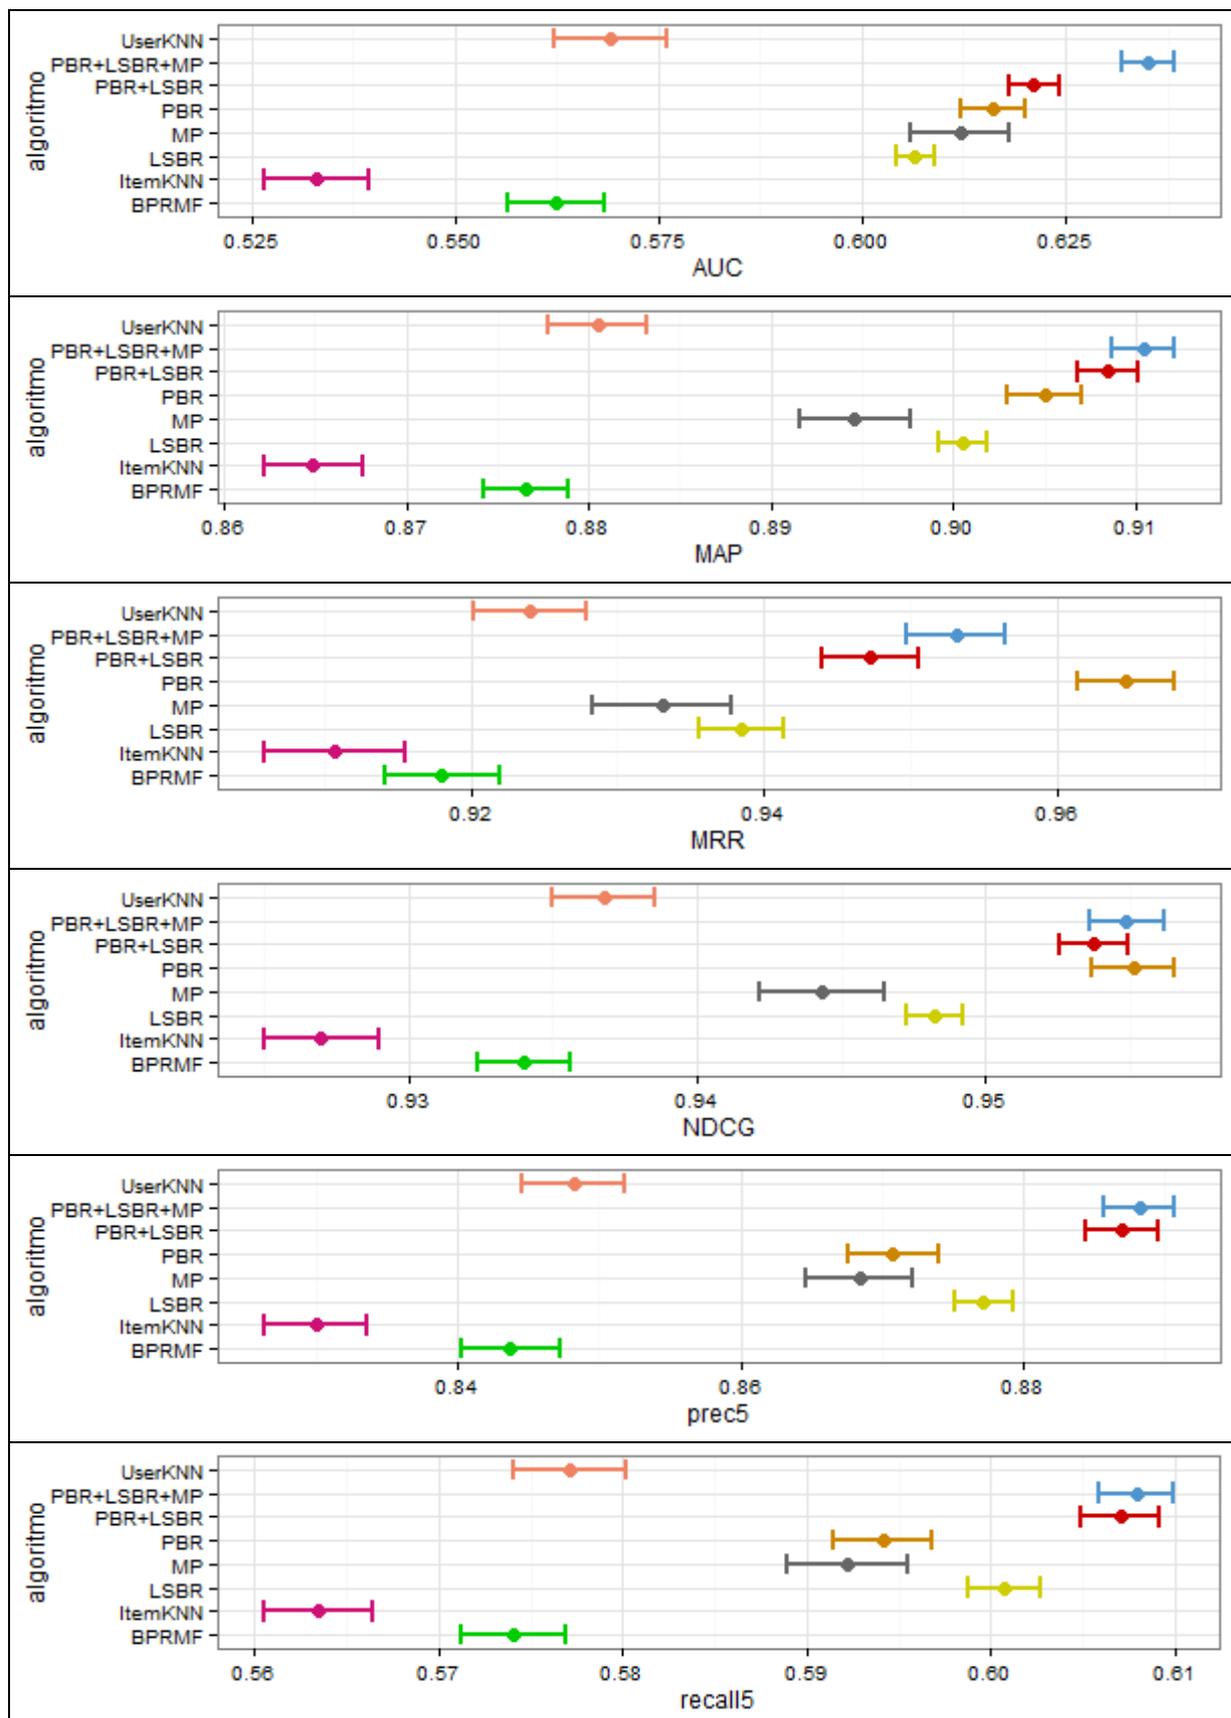
Para isso, foi preciso antes identificar a normalidade e a homoscedasticidade (homogeneidade das variâncias das amostras) dos dados, sendo analisados os valores de Kurtosis e Skewness e realizados os testes de Shapiro-Wilk e de Anderson-Darling, para testar normalidade, e realizados os testes de Levene e de Bartlett, para homoscedasticidade ([BOSLAUGH; WATTERS, 2008](#)).

No Apêndice G é detalhada a análise relativa à normalidade e à homoscedasticidade dos dados. A partir dos valores analisados, além da não homoscedasticidade, houve indícios de amostras com dados não normais. Diante disso, além do teste T par a par, foi aplicado o teste Mann-Whitney U. Os resultados desses testes também encontram-se no Apêndice G.

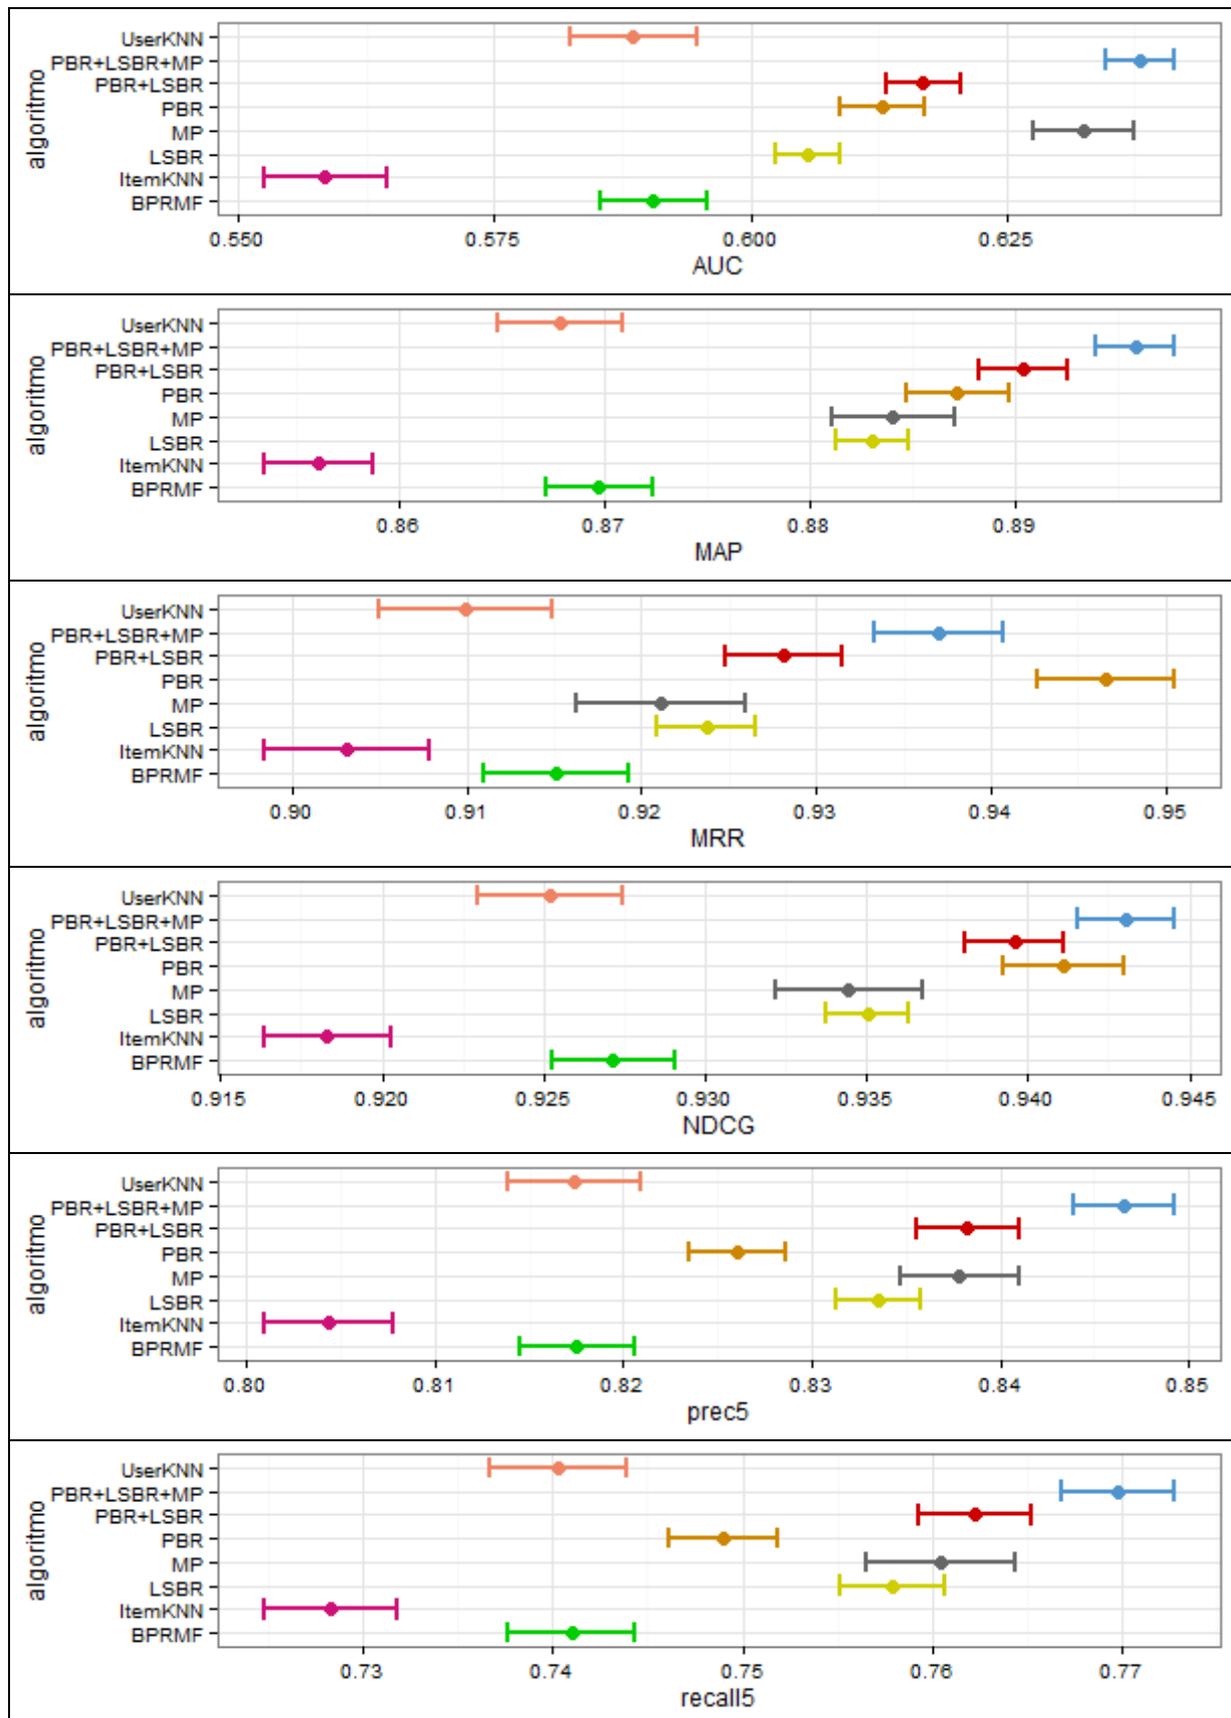
**Figura 14. Intervalos de Confiança ( $\alpha=5\%$ ) relativos às métricas AUC, MAP, MRR, NDCG, P@5 e R@5, considerando o percentual para a base de treinamento igual a 55%.**



**Figura 15. Intervalos de Confiança ( $\alpha=5\%$ ) relativos às métricas AUC, MAP, MRR, NDCG, P@5 e R@5, considerando o percentual para a base de treinamento igual a 65%.**



**Figura 16. Intervalos de Confiança ( $\alpha=5\%$ ) relativos às métricas AUC, MAP, MRR, NDCG, P@5 e R@5, considerando o percentual para a base de treinamento igual a 75%.**



A partir dos intervalos de confiança das Figuras 14 a 16, além da execução dos testes par a par (Apêndice G), foi possível definir *rankings* dos algoritmos com melhores resultados em relação à acurácia (Quadro 11).

**Quadro 11. Rankings dos algoritmos em relação à acurácia.**

		AUC			MAP		
		55%	65%	75%	55%	65%	75%
1 <sup>o</sup>	PBR+LSBR+MP	PBR+LSBR+MP	PBR+LSBR+MP	PBR+LSBR+MP MP	PBR+LSBR PBR+LSBR+MP PBR	PBR+LSBR+MP PBR+LSBR PBR	PBR+LSBR+MP
2 <sup>o</sup>	PBR+LSBR PBR	PBR+LSBR PBR MP LSBR	PBR+LSBR PBR LSBR		LSBR	LSBR	PBR+LSBR PBR MP LSBR
3 <sup>o</sup>	LSBR MP	UserKNN BPRMF	BPRMF UserKNN		MP	MP	BPRMF UserKNN
4 <sup>o</sup>	UserKNN	ItemKNN	ItemKNN		UserKNN	UserKNN	ItemKNN
5 <sup>o</sup>	BPRMF	-	-		BPRMF	BPRMF	-
6 <sup>o</sup>	ItemKNN	-	-		ItemKNN	ItemKNN	-
		MRR			NDCG		
		55%	65%	75%	55%	65%	75%
1 <sup>o</sup>	PBR	PBR	PBR	PBR	PBR	PBR PBR+LSBR+MP PBR+LSBR	PBR+LSBR+MP PBR PBR+LSBR
2 <sup>o</sup>	PBR+LSBR+MP PBR+LSBR	PBR+LSBR+MP PBR+LSBR	PBR+LSBR+MP	PBR+LSBR PBR+LSBR+MP		LSBR	LSBR MP
3 <sup>o</sup>	LSBR MP UserKNN BPRMF	LSBR MP	PBR+LSBR LSBR MP BPRMF UserKNN ItemKNN		LSBR	MP	BPRMF UserKNN
4 <sup>o</sup>	ItemKNN	UserKNN BPRMF	-		MP	UserKNN BPRMF	ItemKNN
5 <sup>o</sup>	-	ItemKNN	-		UserKNN BPRMF	ItemKNN	-
6 <sup>o</sup>	-	-	-		ItemKNN	-	-
		P@5			R@5		
		55%	65%	75%	55%	65%	75%
1 <sup>o</sup>	PBR+LSBR	PBR+LSBR+MP PBR+LSBR	PBR+LSBR+MP	PBR+LSBR	PBR+LSBR	PBR+LSBR+MP PBR+LSBR	PBR+LSBR+MP
2 <sup>o</sup>	PBR+LSBR+MP PBR LSBR	LSBR	PBR+LSBR MP LSBR	PBR+LSBR+MP PBR LSBR		LSBR	PBR+LSBR MP LSBR
3 <sup>o</sup>	MP	PBR MP	PBR		MP	PBR MP	PBR
4 <sup>o</sup>	UserKNN BPRMF	UserKNN BPRMF	BPRMF UserKNN		UserKNN BPRMF	UserKNN BPRMF	BPRMF UserKNN
5 <sup>o</sup>	ItemKNN	ItemKNN	ItemKNN		ItemKNN	ItemKNN	ItemKNN

Considerando-se as seis variáveis dependentes e os percentuais para o conjunto de treinamento, é possível perceber, em relação à métrica AUC, o bom desempenho do modelo híbrido proposto no Capítulo 4 (PBR+LSBR+MP) e do modelo híbrido sem o MP (PBR+LSBR). O mesmo acontece quando são

analisados os *rankings* relativos à métrica MAP. Em relação à métrica MRR, há destaque para o algoritmo PBR, sendo o modelo híbrido proposto destacando-se em seguida, assim como o modelo híbrido sem o MP. Quanto à métrica NDCG, também se percebe destaque para PBR e os modelos híbridos (PBR+LSBR+MP e PBR+LSBR). Sobre as métricas P@5 e R@5, é possível destacar os modelos híbridos.

Finalmente, é possível responder à questão de pesquisa definida no início desta seção. Nenhum algoritmo manteve-se sempre em destaque em relação a todos os demais. Todavia, considerando-se as primeiras posições dos *rankings*, é possível destacar o algoritmo PBR+LSBR+MP, que, dos 18 *rankings* observados no Quadro 11, se manteve 12 vezes em 1º colocado e 6 vezes em 2º (o único algoritmo ocupando sempre a 1ª ou a 2ª posição dos *rankings*). Tal fato evidencia a relevância do modelo proposto nesta dissertação.

É importante ressaltar que, nas vezes em que o desempenho do modelo proposto perdeu ou empatou com o desempenho de outros algoritmos, os algoritmos com desempenho melhor ou similares foram PBR e/ou PBR+LSBR, além de uma ocorrência em que o desempenho do modelo proposto foi similar ao do MP. Isso reforça a importância dos algoritmos que integram o modelo híbrido proposto, e, por conseguinte, reforçam a importância dos conceitos de TP e EA.

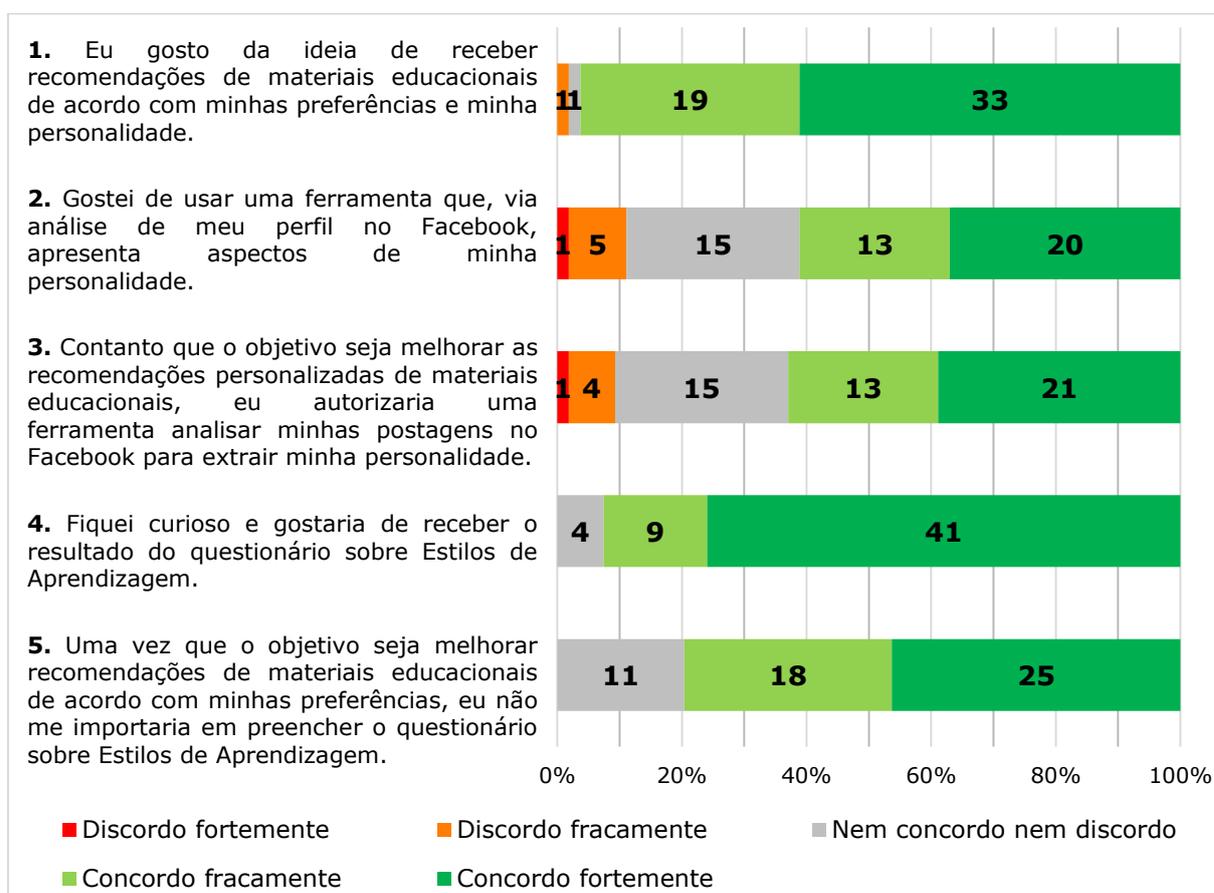
Ressalta-se que o desempenho de PBR maior que o das abordagens UserKNN e ItemKNN corrobora com os resultados obtidos por [Quan \(2013\)](#). Além disso, ressalta-se o fato de que, embora o algoritmo LSBR não fique no topo dos *rankings*, este encontra-se várias vezes na 2ª posição, tendo, em geral, desempenho melhor que os algoritmos BPRMF, UserKNN e ItemKNN.

Vale ressaltar que, adicionalmente, foram analisados outros possíveis modelos híbridos, criados utilizando uma abordagem similar à apresentada na Equação 5. Para não dificultar a visualização de dados e não aumentar o nível de comparação nesta subseção, esses outros modelos não foram apresentados nos capítulos desta dissertação. Entretanto, os gráficos gerados similarmente aos das Figuras 14 a 16 encontram-se no Apêndice H. Em resumo, nessa comparação mais ampla, o desempenho do modelo proposto nesta dissertação ainda se destaca, em geral, em relação aos outros.

Por fim, a partir das respostas ao questionário de Opiniões (Apêndice F), última etapa do formulário aplicado neste experimento, foi elaborada a Figura 17, na qual são apresentados os dados relativos às avaliações, por parte dos

respondentes, das ideias propostas nesta dissertação.

**Figura 17. Opinião dos participantes sobre aspectos da pesquisa.**



A partir do gráfico para a Afirmativa 1 da Figura 17, percebe-se que a maioria dos participantes (96%) considerou gostar da ideia de receber recomendações de materiais educacionais de acordo com suas preferências e sua personalidade.

Em relação a usar uma ferramenta que, via análise do perfil no Facebook, apresenta aspectos de personalidade (Afirmativa 2 da Figura 17), uma quantidade significativa de participantes (39%) não indicou gostar — 28% dos participantes indicaram indecisão. Ainda sobre esse aspecto, que se relaciona a questões de privacidade, 63% dos participantes concordam em autorizar uma ferramenta desse tipo, contanto que o objetivo seja melhorar as recomendações personalizadas de materiais educacionais (Afirmativa 3 da Figura 17) — 28% dos participantes também indicaram indecisão nessa questão.

Em relação ao questionário ILS, embora os participantes tivessem que responder às 44 questões, estes demonstraram, em geral, curiosidade sobre ele (Afirmativa 4 da Figura 17) — 93% dos participantes indicaram concordância,

não havendo indicações de discordância. Além disso, 80% dos participantes concordaram que não se importariam em preenchê-lo contanto que o objetivo fosse melhorar recomendações de materiais educacionais de acordo com suas preferências (Afirmativa 5 da Figura 17), não havendo indicações de discordância nesse item.

Em relação ao campo opcional para comentários, apenas 6 (seis) participantes o preencheram. Em síntese, 2 (dois) alunos comentaram que gostariam que, no ILS, não houvesse a limitação das duas alternativas apresentadas (“necessidade de mais opções de resposta e/ou poder marcar as duas alternativas”; “opção “nem um nem outro” ou “não sei””), 1 (um) aluno comentou que achou um pouco confusa a 2ª etapa (“Muitos conceitos foram apresentados de uma vez só, não sei se compreendi bem todos eles.”), 1 (um) reclamou sobre o tamanho do formulário (“coloca algo mais resumido na próxima”) e os outros 2 (dois) realizaram os seguintes comentários: “Achei bem interessante a ferramenta mostra alguns traços da minha personalidade, mesmo as vezes eu achando que sou de outro jeito. [sic]”; “Gostei de responder o questionário pois ele me fez refletir sobre mim, o que me ajudou a pensar em uma maneira mais apropriada para a minha aprendizagem. [sic]”.

A partir dos resultados apresentados por meio da Figura 17, percebe-se que os participantes da pesquisa, em geral, são favoráveis à proposta de receber recomendações de recursos educacionais de maneira personalizada, não sendo contrários a responder a um questionário para extrair os seus EA, nem contrários, em sua maioria, a permitir que uma ferramenta extraia os seus TP com base em suas postagens em uma rede social.

## **5.4 Considerações Finais do Capítulo**

As investigações empíricas comentadas neste capítulo foram realizadas visando ao objetivo geral da pesquisa. As duas primeiras investigações serviram como meio para definir características do modelo proposto (apresentado no Capítulo 4), o qual foi avaliado na terceira investigação apresentada.

Os resultados obtidos na investigação empírica final indicaram que o modelo proposto obteve, na maioria dos casos, acurácia maior em comparação a outras abordagens de recomendação.

Considerando-se as características do experimento final realizado (Seção

5.3), destaca-se a importância do modelo proposto especialmente em um cenário geralmente problemático em SR (o problema de *cold-start*).

No próximo capítulo, o último deste documento, são apresentados os comentários finais relativos à pesquisa, abordando conclusões, limitações e estudos futuros.

# Capítulo 6

## Considerações Finais

Neste capítulo, são expostas as considerações finais relacionadas ao modelo de recomendação proposto e as limitações desta pesquisa. Além disso, são apresentadas sugestões para estudos futuros.

### 6.1 Conclusões

A pesquisa em SRE está se desenvolvendo continuamente a partir de uma quantidade crescente de projetos de pesquisa, conferências, oficinas, edições especiais em revistas e livros ([DRACHSLER et al., 2015](#)). Neste documento foi apresentado um modelo de SR híbrido de OA, voltado para discentes, baseando-se em TP e EA para compor o perfil dos usuários/discentes.

Inicialmente, um experimento com alunos de um curso técnico sobre seus EA (usando o inventário ILS) e TP (usando o questionário TIPI) confirmou que os alunos possuem características diferentes em relação ao modo de aprender e à personalidade. Entretanto, não foi visualizada correlação forte entre as dimensões de EA e os TP, para que fosse possível usar apenas o menor desses questionários (o TIPI) para extrair o perfil dos discentes/usuários, como almejado inicialmente.

Em seguida, a partir do uso da ferramenta Five Labs, alguns desses alunos disponibilizaram o resultado disponível por essa ferramenta, possibilitando analisar novamente a correlação entre as dimensões de EA e os TP. Não foi novamente observada correlação forte entre esses dois conceitos, mas se decidiu usar o inventário ILS para EA e essa ferramenta automática para Personalidade, considerando assim ambos os conceitos no modelo a ser proposto.

Adicionalmente, foram analisados os dados obtidos por meio da ferramenta e do questionário TIPI e não houve também correlação forte, reforçando o que alguns pesquisadores abordam em relação ao fraco desempenho do TIPI para extrair os TP — acredita-se que a ferramenta extrai

melhor devido à forma como foi construída, baseada no estudo bem validado de [Schwartz et al. \(2013\)](#).

Definidos o uso do ILS e da ferramenta Five Labs, foi analisado o protótipo desenvolvido por [Carvalho et al. \(2014\)](#) e decidido utilizar sua estratégia para associar os EA aos metadados descritores dos OA.

A investigação empírica final realizada indicou resultados satisfatórios do modelo de SRE proposto, focando no uso de EA e TP para a criação do perfil dos alunos. Mesmo que tais aspectos psicológicos humanos sejam difíceis de extrair intencionalmente do usuário, esta pesquisa evidencia sua relevância em SRE.

Os algoritmos comparados (Seção 5.3) se comportaram de maneira diferente em relação à acurácia, sendo o modelo proposto geralmente um destaque em relação a todas as comparações realizadas (métricas AUC, MAP, MRR, NDCG, P@5 e R@5). Os algoritmos em estudo também apresentaram diferença ao variar o percentual dos dados utilizado para a base de treinamento em 55%, 65% e 75%. Todavia, essas variações não alteraram fortemente as primeiras posições dos *rankings* (Quadro 11), sendo possível continuar destacando o modelo híbrido proposto como resposta à questão de pesquisa elaborada.

Em relação às últimas colocações nos *rankings*, percebe-se a presença constante do algoritmo ItemKNN. Acredita-se que seu desempenho sempre menor diante do algoritmo UserKNN justifica-se pela quantidade de usuários (54) ser maior que a quantidade de itens (25). Portanto, adverte-se que outros experimentos, com diferentes itens e pessoas, poderiam indicar variações nesses resultados.

Todavia, o uso de várias métricas de comparação e de três distintos valores percentuais para o conjunto de treinamento foram estratégias visando a maior generalização dos resultados obtidos, ressaltando a importância da abordagem proposta (PBR+LSBR+MP) para a área de SRE.

Ao se verificar, portanto, que TP e EA, na construção do perfil do usuário/aluno, podem interferir na melhoria das recomendações em SRE, é possível dizer que a principal contribuição da dissertação ora descrita consiste em expandir o estado da arte em SRE ao propor e validar um modelo para a geração de recomendações personalizadas para alunos considerando seus TP e/ou seus EA, baseando-se em técnicas populares em SR.

Apesar da notável dificuldade de ter variados OA de determinado assunto

com características diferentes, nesta pesquisa defende-se que o ideal é trabalhar com uma variedade de atividades didáticas que considere a preferência de todos os EA. Embora a elaboração de um modelo de recomendação possa ser visto como algo técnico, a motivação para o foco educacional desta pesquisa consistiu em poder disponibilizar um modelo que possibilite que todos os estudantes sejam ensinados, pelo menos em parte, na maneira que preferem aprender, permitindo maior conforto e disposição para a aprendizagem.

“É importante reconhecer que os estudantes são diferentes, cada qual com sua própria maneira de receber e processar as informações, resolver problemas e expor ideias, ou seja, cada um tem sua própria personalidade e seu próprio Estilo de Aprendizagem”. (KURI, 2004, p. 7)

Mesmo que seja trabalhoso para o professor criar/disponibilizar OA com variadas características, é papel deste, como facilitador da aprendizagem, prover meios para, de fato, facilitar a aprendizagem dos alunos — quer seja em turmas pequenas (poucos alunos), quer seja em MOOC.

Espera-se que esta dissertação também sirva para chamar atenção ao fato de que os alunos são diferentes (com TP e EA distintos), sendo preciso que os materiais produzidos para os cursos, tanto presenciais quanto à distância, favoreçam os diferentes modos de aprender. Conforme as instituições percebam a necessidade de atualizar os materiais para englobar uma quantidade maior de EA, mais as iniciativas propostas em Informática na Educação, a exemplo deste estudo, serão mais úteis e mais bem aproveitadas.

## **6.2 Limitações e Sugestões para Pesquisas Futuras**

Além das considerações anteriores, é possível realizar as seguintes considerações em relação às limitações e sugestões para estudos futuros.

Uma vez que as investigações empíricas envolveram pessoas, uma ameaça à validade consiste na forma de participação destas, que podem não ter indicado necessariamente as opções que de fato as representassem — às vezes, por exemplo, os participantes de pesquisas não gostam de ser avaliados ou acreditam saber a(s) hipótese(s) do pesquisador, alterando seu comportamento (positivamente ou negativamente). Todavia, acredita-se que casos como esses, se existiram, foram raros e não impactaram fortemente nos resultados, uma vez que o formulário foi enviado para que os respondentes se voluntariassem em respondê-lo, não havendo obrigatoriedade nem penalizações (alguns estudantes, inclusive, iniciaram sua participação, mas decidiram não concluir os formulários).

Outro aspecto consiste na não possível generalização dos resultados além do contexto em estudo. Os estudantes de Ciência da Computação (focando no experimento final) representam apenas uma parcela de usuários/discentes que necessitam de recomendações de OA. Foram considerados, no experimento final, estudantes de pós-graduação e graduação de duas universidades federais (UFCG e UFRPE), além de serem utilizados três níveis para o percentual dos dados utilizado para a base de treinamento. Embora essas foram estratégias encontradas para não restringir muito o escopo desta pesquisa, outros estudos poderiam considerar outras bases de dados (formadas por uma quantidade maior de alunos, oriundos de variados cursos e áreas do conhecimento), viabilizando maior generalização dos resultados obtidos.

Além disso, outro aspecto a comentar consiste na não aplicação do modelo proposto em um ambiente real (com alunos de turmas em curso real e OA não fictícios). Como pesquisa futura, pretende-se realizar um estudo de caso em um curso a distância utilizando um AVA. Ressalta-se, para isso, a necessidade de implementação e disponibilização do modelo como, por exemplo, um *plugin* para o Moodle.

Em relação a EA, foi utilizado apenas o ILS como instrumento de mensuração e, portanto, o perfil discente permaneceu estático. Sobre isso, vale comentar que 3 (três) usuários se submeteram a um teste inicial e, após, aproximadamente, 1 ano, ao participarem do experimento final, responderam novamente ao ILS, e seus perfis sofreram algumas alterações (Quadro 12) — destacadas em negrito.

**Quadro 12. Comparação entre resultados do ILS após aproximadamente 1 ano entre as respostas dos alunos.**

Perfil de EA do Aluno A		Perfil de EA do Aluno B		Perfil de EA do Aluno C	
1º resultado (em 10/03/2014)	2º resultado (em 15/04/2015)	1º resultado (em 26/02/2014)	2º resultado (em 17/04/2015)	1º resultado (em 10/03/2014)	2º resultado (em 23/02/2015)
Fortemente Ativo	Fortemente Ativo	Levemente Reflexivo	Levemente Reflexivo	Moderadamente Ativo	Moderadamente Ativo
Levemente Intuitivo	Levemente Intuitivo	<b>Levemente Intuitivo</b>	<b>Levemente Sensorial</b>	Moderadamente Intuitivo	Moderadamente Intuitivo
Moderadamente Visual	Moderadamente Visual	Levemente Verbal	Levemente Verbal	Fortemente Visual	Fortemente Visual
<b>Levemente Global</b>	<b>Moderadamente Global</b>	<b>Moderadamente Global</b>	<b>Levemente Global</b>	<b>Moderadamente Global</b>	<b>Levemente Sequencial</b>

Apesar de que, para os alunos indicados no Quadro 12, tenham sido observadas poucas alterações (essencialmente para a dimensão Compreensão — estilos Global e Sequencial), após um tempo entre as respostas ao ILS, sugere-

se que as características do perfil do discente relacionada a EA — ao empregar, por exemplo, o modelo proposto nesta dissertação em um AVA — sejam atualizadas dinamicamente, como a abordagem de [Dorça et al. \(2013\)](#).

Sobre a utilização de EA em SRE, destaca-se também que a associação entre os EA e os metadados de OA não é uma tarefa trivial, além de não haver unanimidade (conforme comentado na Seção 3.1). Um exemplo da complexidade de realização dessa associação é a forma de tratar um OA no formato de vídeo. Por exemplo, um vídeo com apenas imagens e sem áudio é diferente de um vídeo apenas com áudio e legenda (o primeiro estaria relacionado ao estilo Visual, enquanto o segundo ao estilo Verbal). Além disso, um aluno pode gostar de vídeos de determinado indivíduo e não de outro, por questões didáticas dos autores dos vídeos. É interessante, portanto, que sejam fomentados estudos em parceria com estudiosos das teorias relativas a EA, como pesquisadores da área de educação e/ou psicologia.

Ainda em relação a EA, outro estudo futuro possível seria expandir o modelo proposto para empregar a estratégia de adaptação a partir do dispositivo utilizado pelo usuário (abrangendo dispositivos móveis), como defendido no estudo de [Oliveira \(2013\)](#).

Pretende-se também, como pesquisa futura, estudar a possibilidade de considerar o aspecto de Emoções no modelo, utilizando, por exemplo, a ideia empregada por [Pereira e Augustin \(2014\)](#) — por meio do *AffectButton* — ou o modelo OCC (ORTONY, CLORE e COLLINS, 1988 *apud* [JACQUES e NUNES, 2012](#)).

Como afirmado anteriormente, os aspectos psicológicos, tais como TP e Emoções, influenciam processos de tomada de decisão. Ao abordar sobre os desafios de SRE, [Drachsler et al. \(2015\)](#) afirmam que a aplicação de computação afetiva pode agregar valor às recomendações quando a informação emocional e o sentimento forem levados em conta no processo de recomendação. [Jaques et al. \(2012\)](#) afirmam que ainda não há teorias compreensíveis e validadas que identifiquem quais emoções são mais importantes para aprendizagem.

É notável, portanto, que a computação afetiva consiste em um campo promissor de pesquisa, embora desafiador devido à natureza interdisciplinar. Conforme afirma [Santos et al. \(2014\)](#), resultados sobre o impacto da Personalidade em SR precisam ser mais bem esclarecidos com experimentos adicionais voltados para desvendar a relação entre TP e o projeto de recomendações educacionais afetivos, no qual a dificuldade e a incerteza de

medição das variáveis envolvidas tem que ser consideradas.

“Uma reflexão da literatura sugere que incorporar a personalidade dos usuários em sistemas de recomendação requer uma investigação mais inovadora. Há, portanto, uma questão em aberto sobre como integrar efetivamente o fator social de personalidade em modelos diferentes de recomendação para melhorar a acurácia dos sistemas de recomendação”.  
([Xia et al. , 2014, p. 4](#), tradução livre)

Aliado a isso, considerar os EA é essencial para dar apoio aos docentes no tocante às diferenças diretamente relacionadas ao modo de aprender particular dos alunos de sua turma.

Por fim, almeja-se com esta dissertação e com seus resultados, a exemplo dos artigos publicados com base nesta pesquisa (citados na Seção 1.4 e detalhados no Apêndice A), incentivar estudos relativos a SRE considerando aspectos psicológicos.

# Referências Bibliográficas

ADOMAVICIUS, G.; TUZHILIN, A. Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. In: *IEEE Transactions On Knowledge and Data Engineering*, vol. 17, no. 6, p. 734–749, 2005. Disponível em: <<http://pages.stern.nyu.edu/~atuzhili/pdf/TKDE-Paper-as-Printed.pdf>>. Acesso em: 09 ago. 2015.

AGUIAR, J. J. B.; FECHINE, J. M.; COSTA, E. Estilos Cognitivos e Estilos de Aprendizagem em Informática na Educação: um mapeamento sistemático focado no SBIE, WIE e RBIE. In: *Anais do 25º Simpósio Brasileiro de Informática na Educação*, Dourados, p. 441–450, 2014. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/2972/2705>>. Acesso em: 09 ago. 2015.

AGUIAR, J. J. B.; SANTOS, S. I. N. Revisão Sistemática sobre Avaliação de Sistemas de Recomendação Educacionais no Brasil : Artigos Resultantes. 2015. Disponível em: <<http://goo.gl/IINp4u>>. Acesso em: 09 ago. 2015.

AGUIAR, J. J. B.; SANTOS, S. I. N.; FECHINE, J. M.; COSTA, E. Um Mapeamento Sistemático sobre Iniciativas Brasileiras em Sistemas de Recomendação Educacionais. In: *Anais do 25º Simpósio Brasileiro de Informática na Educação*, Dourados, p. 1123–1132, 2014. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/3058/2566>>. Acesso em: 09 ago. 2015.

ALLPORT, G. W. *Personality: a psychological interpretation*. New York: Holt. 1937.

ALLPORT, G. W.; ODBERT, H. S. Trait names: A psycholexical study. *Psychological Monographs*. 47: 211. 1936. Disponível em: <[http://psych.colorado.edu/~carey/courses/psyc5112/Readings/psnTraitNames\\_Allport.pdf](http://psych.colorado.edu/~carey/courses/psyc5112/Readings/psnTraitNames_Allport.pdf)>. Acesso em: 09 ago. 2015.

ALMEIDA, K. R. Descrição e análise de diferentes Estilos de Aprendizagem. *Revista Interlocução*, v. 3, n. 3, p. 38–49, 2010. Disponível em: <<http://interlocucao.loyola.g12.br/index.php/revista/article/view/73/60>>. Acesso em: 09 ago. 2015.

ARIADNE FOUNDATION. Ariadne. 2015. Disponível em: <<http://ariadne-eu.org/>>. Acesso em: 09 ago. 2015.

BACHRACH, Y.; KOSINSKI, M.; GRAEPEL, T.; KOHLI, P.; STILLWELL, D. Personality and patterns of Facebook usage. In: *Proceedings of the 3rd Annual ACM Web Science Conference (WebSci '12)*, ACM, New York, NY, USA, p. 24–32, 2012. Disponível em: <[http://research.microsoft.com/en-us/um/people/pkohli/papers/bkgks\\_acmwebsci\\_2012.pdf](http://research.microsoft.com/en-us/um/people/pkohli/papers/bkgks_acmwebsci_2012.pdf)>. Acesso em: 09 ago. 2015.

BARCELLOS, C.; MUSA, D. L.; BRANDÃO, A.; WARPECHOWSKI, M. Sistema de Recomendação Acadêmico para Apoio a Aprendizagem. *Revista Novas Tecnologias na Educação (RENOTE)*, v. 5, p. 4, 2007. Disponível em: <<http://seer.ufrgs.br/renote/article/view/14236/8152>>. Acesso em: 09 ago. 2015.

BARTH, F. J. Uma introdução ao tema Recuperação de Informações Textuais. *Revista de Informática Teórica e Aplicada (RITA)*, v. 20, p.247–272, 2013. Disponível em: <[http://seer.ufrgs.br/index.php/rita/article/view/rita\\_v20\\_n2\\_p155WesleyVol20Nr2\\_247/25454](http://seer.ufrgs.br/index.php/rita/article/view/rita_v20_n2_p155WesleyVol20Nr2_247/25454)>. Acesso em: 09 set. 2015.

BEAUDOIN, M.; GUILBAULT, C.; CAWS, C.; FRIESEN, N. FLORE — French Learning Object Repository for Education. 2008. Disponível em: <<http://flore.uvic.ca/>>. Acesso em: 09 ago. 2015.

BOBADILLA, J.; ORTEGA, F.; HERNANDO, A.; GUTIÉRREZ, A. Recommender systems survey. *Knowledge Based Systems*, v. 46, p. 109–132, 2013.

BOSLAUGH, S.; WATTERS, P. A. Statistics in a Nutshell. *O'Reilly Media*, 2008. ISBN: 978-0-596-51049-7.

BRESSANE NETO, A. F. Uma arquitetura para agentes inteligentes com personalidade e emoção. 2010. Dissertação (Mestrado em Ciência da Computação) — Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, 2010. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/45/45134/tde-28072010-121443/>>. Acesso em: 09 ago. 2015.

BURKE, R. Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, Dordrecht, v. 12, p. 4, p. 331–370, 2002. Disponível em: <<http://josquin.cs.depaul.edu/~rburke/pubs/burke-umuai02.pdf>>. Acesso em: 09 ago. 2015.

CANTADOR, I.; FERNÁNDEZ-TOBIÁS, I. On the exploitation of user personality in recommender systems. *Proceedings of the First International Workshop on Decision Making and Recommender Systems*. Ed. Mouzhi Ge, Francesco Ricci. CEUR Workshop Proceedings, v. 1278, p. 42–45, 2014. Disponível em: <<http://ceur-ws.org/Vol-1278/paper8.pdf>>. Acesso em: 09 ago. 2015.

CARVALHO, V. C.; DORÇA, F. A.; CATTELAN, R. G.; ARAÚJO, R. D. Uma Abordagem para Recomendação Automática e Dinâmica de Objetos de Aprendizagem Baseada em Estilos de Aprendizagem. *Anais do XXV Simpósio Brasileiro de Informática na Educação — SBIE 2014*, p. 1188–1197, Dourados, MS, 2014. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/3065/2573>>. Acesso em: 09 ago. 2015.

CASAGRANDE, M. F. R.; KOZIMA, G.; WILLRICH, R. Técnica de Recomendação Baseada em Metadados para Repositórios Digitais Voltados ao Ensino. In: *Anais do 24º Simpósio Brasileiro de Informática na Educação*, Campinas, p. 677–686, 2013. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/2546/2204>>. Acesso em: 09 ago. 2015.

- CASALI, A.; GERLING, V.; DECO, C.; BENDER, C. A Recommender System for Learning Objects Personalized Retrieval. In: Santos O.; Boticario, J. (Org.), *Educational Recommender Systems and Technologies: Practices and Challenges*, p. 182–210, 2012.
- CAZELLA, S. C.; NUNES, M. A. S. N.; REATEGUI, E. B. A Ciência da Opinião: Estado da arte em Sistemas de Recomendação. In: *XXX Congresso da Sociedade Brasileira de Computação — Jornada de Atualização em Informática (JAI)*, 2010. Disponível em: <<http://200.17.141.213/~gutanunes/hp/publications/JAI4.pdf>>. Acesso em: 09 ago. 2015.
- CAZELLA, S. C.; REATEGUI, E. B.; BEHAR, P. Recommendation of Learning Objects Applying Collaborative Filtering and Competencies. *IFIP Advances in Information and Communication Technology*, v. 324, p. 35–43, 2010. Disponível em: <<https://hal.inria.fr/hal-01054676/document>>. Acesso em: 09 ago. 2015.
- CINTED. CESTA — Coletânea de Entidades de Suporte ao uso de Tecnologia na Aprendizagem. 2015. Disponível em: <<http://www.cinted.ufrgs.br/CESTA/>>. Acesso em: 09 ago. 2015.
- COFFIELD, F.; MOSELEY, D.; HALL, E.; ECCLESTONE, K. *Should we be using learning styles? What research has to say to practice*. London, Learning and Skills Research Centre, Learning and Skills Development Agency, 2004. Disponível em: <[http://www.itslifejambutnotasweknowit.org.uk/files/LSRC\\_LearningStyles.pdf](http://www.itslifejambutnotasweknowit.org.uk/files/LSRC_LearningStyles.pdf)>. Acesso em: 09 ago. 2015.
- COSTA, E.; AGUIAR, J.; MAGALHÃES, J. Sistemas de Recomendação de Recursos Educacionais: conceitos, técnicas e aplicações. In: *II Congresso Brasileiro de Informática na Educação — Jornada de Atualização em Informática na Educação (JAIE)*, p. 57–78, 2013. Disponível em: <<http://www.br-ie.org/pub/index.php/pie/article/view/2589/2245>>. Acesso em: 09 ago. 2015.
- COSTA, P. T. Jr.; WIDIGER, T. A. Introduction. In: COSTA, P. T. Jr.; WIDIGER, T. A. (Org.), *Personality Disorders and the Five-Factor Model of Personality*, 2.ed., p.3-16. Washington, DC: American Psychological Association, 2002.
- COSTA, P. T. Jr.; MCCRAE, R. R. NEO PI-R: Inventário de Personalidade NEO Revisado e Inventário de Cinco Fatores NEO Revisado NEO-FFI-R [versão curta]. São Paulo: Vetor Editora Psico-Pedagógica. 2007.
- COSTA, P. T.; MCCRAE, R. R. Revised neo personality inventory (neo-pi-r) and neo five-factor inventory (neo-ffi). *Professional manual*, 1992.
- DCMI. DCMI metadata terms. *Dublin Core Metadata Initiative*. 2012. Disponível em: <<http://dublincore.org/documents/dcmi-terms/>>. Acesso em: 09 ago. 2015.
- DORÇA, F. A.; LIMA, L. V.; FERNANDES, M. A.; LOPES, C. R. Comparing strategies for modeling students learning styles through reinforcement learning in adaptive and intelligent educational systems: An experimental analysis. *Expert Systems with Applications*, v. 40, n. 6, p. 2092–2101, 2013.

DRACHSLER, H.; VERBERT, K.; SANTOS, O. C.; MANOUSELIS, N. Panorama of recommender systems to support learning. *Handbook on recommender systems*. 2015 (no prelo). Disponível em: <[https://lirias.kuleuven.be/bitstream/123456789/476545/1/TEL\\_RecSys.pdf](https://lirias.kuleuven.be/bitstream/123456789/476545/1/TEL_RecSys.pdf)>. Acesso em: 09 ago. 2015.

DSPACE SOFTWARE. CITIDEL — Computing and Information Technology Interactive Digital Educational Library. 2006. Disponível em: <<http://www.citidel.org>>. Acesso em: 09 ago. 2015.

ELAHI, M.; BRAUNHOFER, M.; RICCI, F.; TKALCIC, M. Personality-Based Active Learning for Collaborative Filtering Recommender Systems. In: Baldoni, M.; Baroglio, C.; Boella, G.; Micalizio, R. (Org.), *Advances in Artificial Intelligence (AI\*IA), Lecture Notes in Computer Science*, v. 8249, 2013, p. 360-371, Springer, Heidelberg, 2013.

FELDER, R. M. Author's Preface — June 2002. In: FELDER, R. M.; SILVERMAN, L. K. *Learning and Learning and Teaching Styles in Engineering Education*. 2002. Disponível em: <<http://www.ncsu.edu/felder-public/Papers/LS-1988.pdf>>. Acesso em: 09 ago. 2015.

FELDER, R. M.; SILVERMAN, L. K. Learning and Teaching Styles in Engineering Education. *Journal of Engineering Education*, v. 78, n. 7, p. 674–681, 1988. Disponível em: <[http://www.ncsu.edu/felder-public/Learning\\_Styles.html](http://www.ncsu.edu/felder-public/Learning_Styles.html)>. Acesso em: 09 ago. 2015.

FELDER, R. M.; SOLOMAN, B. A. Index of Learning Styles (ILS). 1999. Disponível em: <<http://www4.ncsu.edu/unity/lockers/users/f/felder/public/ILSpag.html>>. Acesso em: 09 ago. 2015.

FELDER, R.; SPURLIN, J. Applications, Reliability, and Validity of the Index of Learning Styles. *International Journal of Engineering Education*, v. 21, p. 103-112, 2005. Disponível em: <[http://www4.ncsu.edu/unity/lockers/users/f/felder/public/ILSdir/ILS\\_Validation\(IJEE\).pdf](http://www4.ncsu.edu/unity/lockers/users/f/felder/public/ILSdir/ILS_Validation(IJEE).pdf)>. Acesso em: 09 ago. 2015.

FERREIRA, L. G. A.; BARBOSA, J. L. V.; GLUZ, J. C. Um Modelo de Recomendação Ubíqua de Conteúdo para Grupos de Aprendizes. In: *Anais do 24º Simpósio Brasileiro de Informática na Educação*, Campinas, p. 697–706, 2013. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/2548/2206>>. Acesso em: 09 ago. 2015.

FERREIRA, L. G. A.; GLUZ, J. C.; BARBOSA, J. L. V. Um Modelo Multiagente para Recomendação de Conteúdo Educacional em um Ambiente Ubíquo. In: *Anais do 23º Simpósio Brasileiro de Informática na Educação*, Rio de Janeiro, 2012. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/1782/1543>>. Acesso em: 09 ago. 2015.

FERREIRA, V. F.; RAABE, A. L. A. LorSys — Um Sistema de Recomendação de Objetos de Aprendizagem SCORM. *Revista Novas Tecnologias na Educação (RENOTE)*, v. 8, p. 16, 2010. Disponível em:

<<http://seer.ufrgs.br/index.php/renote/article/view/15223/8986>>. Acesso em: 09 ago. 2015.

FERRO, M. R. C. Modelo de Sistema de Recomendação de Materiais Didáticos para Ambientes Virtuais de Aprendizagem. Dissertação de Mestrado. Universidade Federal de Alagoas — Instituto de Computação, Maceió, Alagoas, Brasil, 2010.

FERRO, M. R. C.; COSTA, F. P. D.; PERES, A. L.; MARINHO, M. F. Recomendações de Materiais Didáticos Assistida por Computador em Ambientes Virtuais de Aprendizagem. *Informática na Educação: teoria e prática*, Porto Alegre, v. 17, n. 1, p. 169–182, 2014. Disponível em: <<http://seer.ufrgs.br/index.php/InfEducTeoriaPratica/article/view/40301/29979>>. Acesso em: 09 ago. 2015.

FERWERDA, B.; SCHEDL, M. Enhancing music recommender systems with personality information and emotional states: A proposal. In: *Proceedings of the 2nd Workshop Emotions and Personality in Personalized Services (EMPIRE)*, 2014. Disponível em: <[http://ceur-ws.org/Vol-1181/empire2014\\_paper\\_04.pdf](http://ceur-ws.org/Vol-1181/empire2014_paper_04.pdf)>. Acesso em: 09 ago. 2015.

FIVE. Five Labs — See the personality behind your posts. Product of Five.com. 2015. Disponível em: <<http://labs.five.com/>>. Acesso em: 24 abr. 2015.

FRÓES, M. F.; SANTOS, E. R. E-BIACS: Um Sistema para a Construção de Ambientes Virtuais para Aprendizagem Baseada em Problemas. *Revista Novas Tecnologias na Educação (RENOTE)*, v. 12, n. 1, p. 1–10, 2014. Disponível em: <<http://www.seer.ufrgs.br/index.php/renote/article/view/49832/31190>>. Acesso em: 09 ago. 2015.

GANTNER, Z.; RENDLE, S.; FREUDENTHALER, C.; SCHMIDT-THIEME, L. MyMediaLite: A Free Recommender System Library. In: *Proceedings of the 5th ACM Conference on Recommender Systems (RecSys 2011)*, Chicago, USA, 2011. Disponível em: <[http://www.ismll.uni-hildesheim.de/pub/pdfs/Gantner\\_et\\_al2011\\_MyMediaLite.pdf](http://www.ismll.uni-hildesheim.de/pub/pdfs/Gantner_et_al2011_MyMediaLite.pdf)>. Acesso em: 09 ago. 2015.

GARCIA, L. F. Teorias psicométricas da personalidade. In Carmen Flores-Mendoza e Roberto Colom (Org.), *Introdução a Psicologia das Diferenças Individuais*, Artmed, Porto Alegre, p. 219–242, 2006.

GONÇALVES, A. R. C. O papel das TIC na escola, na aprendizagem e na educação. Dissertação de mestrado. Lisboa: ISCTE-IUL, 2012. Disponível em: <<http://hdl.handle.net/10071/5146>>. Acesso em: 09 ago. 2015.

GONZALEZ, G.; DE LA ROSA, J. L.; MONTANER, M. Embedding Emotional Context In Recommender Systems. In: *The 20th International Florida Artificial Intelligence Research Society Conference-Flairs*, Key West, Florida, 2007. Disponível em: <<http://www.aaai.org/Papers/FLAIRS/2007/Flairs07-090.pdf>>. Acesso em: 09 ago. 2015.

GOSLING, S. D.; RENTFROW, P. J.; SWANN, W. B., Jr. A very brief measure of the big-five personality domains. *Journal of Research in Personality*. Elsevier, (37):504-528, 2003. Disponível em: <<http://gosling.psy.utexas.edu/wp-content/uploads/2014/09/JRP-03-tipi.pdf>>. Acesso em: 09 ago. 2015.

GOVERNMENT OF ALBERTA. Learn-Alberta. 2015. Disponível em: <<http://learnalberta.ca>>. Acesso em: 09 ago. 2015.

GRAF, S.; KINSHUK; LIU, T-C. Identifying Learning Styles in Learning Management Systems by Using Indications from Students' Behaviour. In: *ICALT '08 — Eighth IEEE International Conference on Advanced Learning Technologies*, p. 482-486, 2008.

GUDWIN, R. R. Introdução à Linguagem UML. DCA-FEEC-UNICAMP. 2010. Disponível em: <<http://pt.scribd.com/doc/99020535/UML-Unicamp>>. Acesso em: 13 set. 2015.

HAN, J.; KAMBER, M. Data Mining: Concepts and Techniques. Elsevier, 2006. Disponível em: <[http://ccs1.hnue.edu.vn/hungtd/DM2012/DataMining\\_BOOK.pdf](http://ccs1.hnue.edu.vn/hungtd/DM2012/DataMining_BOOK.pdf)>. Acesso em: 08 set. 2015.

HEAL. HEAL — Health Education Assets Library. 2013. Disponível em: <<http://library.med.utah.edu/heal/>>. Acesso em: 09 ago. 2015.

HERLOCKER, J. L.; KONSTAN, J. A.; TERVEEN. L. G.; RIEDL, J. T. Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems*, 22 (1), p. 5-53, 2004.

HU, R. Design and user issues in personality-based recommender systems. In: *Proceedings of the fourth ACM conference on Recommender systems (RecSys '10)*. ACM, New York, NY, USA, p. 357-360, 2010. Disponível em: <<http://hci.epfl.ch/wp-content/uploads/publications/2010/doc01r-recsys10-hu.pdf>>. Acesso em: 09 ago. 2015.

HU, R.; PU, P. A Study on User Perception of Personality-Based Recommender Systems. In: DE BRA, P.; KOBASA, A; CHIN, D. (Org.), *User Modeling, Adaptation, and Personalization (UMAP)*, Springer Berlin/Heidelberg, p. 291-302, 2010. Disponível em: <[http://hci.epfl.ch/wp-content/uploads/publications/2010/HuPu\\_UMAP10.pdf](http://hci.epfl.ch/wp-content/uploads/publications/2010/HuPu_UMAP10.pdf)>. Acesso em: 09 ago. 2015.

HU, R.; PU, P. Enhancing collaborative filtering systems with personality information. In: *Proceedings of the fifth ACM conference on Recommender systems (RecSys '11)*. ACM, New York, NY, USA, p. 197-204, 2011.

IEEE. IEEE Standard for Learning Object Metadata. *IEEE Std 1484.12.1-2002*, p. i-32.

ILUMINA. iLumina — Educational Resources for Science & Mathematics. 2009. Disponível em: <<http://www.ilumina-dlib.org/>>. Acesso em: 29 jul. 2015.

IMS. Learning resource meta-data specification. *IMS Global Learning Consortium*. 2006. Disponível em: <<http://www.imsglobal.org/metadata/>>. Acesso em: 09 ago. 2015.

INEP — INSTITUTO NACIONAL DE ESTUDOS E PESQUISAS EDUCACIONAIS ANÍSIO TEIXEIRA. Censo da Educação Superior 2011 — Resumo Técnico. Brasília. 2013. Disponível em: <[http://download.inep.gov.br/download/superior/censo/2011/resumo\\_tecnico\\_censo\\_educacao\\_superior\\_2011.pdf](http://download.inep.gov.br/download/superior/censo/2011/resumo_tecnico_censo_educacao_superior_2011.pdf)>. Acesso em: 09 ago. 2015.

JAIN, R. The Art of Computer Systems Performance Analysis: Techniques for Experimental Design, Measurement, Simulation and Modeling. *Wiley Computer Publishing, John Wiley & Sons, Inc*, 1991. ISBN: 0-471-50336-3. (Errata: [http://www.cs.wustl.edu/~jain/books/ftp/errors\\_all.pdf](http://www.cs.wustl.edu/~jain/books/ftp/errors_all.pdf))

JAQUES, P. A.; NUNES, M. A. S. N. Ambientes Inteligentes de Aprendizagem que inferem, expressam e possuem emoções e personalidade. In: Seiji Isotani e Fernanda C. A. Campos. (Org.). *Jornada de Atualização em Informática na Educação — JAIE 2012*. 1 ed. Porto Alegre: SBC, v. 1, p. 32–71, 2012. Disponível em: <<http://www.br-ie.org/pub/index.php/pie/article/view/2342/2097>>. Acesso em: 09 ago. 2015.

JAQUES, P. A.; NUNES, M. A.; ISOTANI, S.; BITTENCOURT, I. Computação Afetiva aplicada à Educação: Dotando Sistemas Tutores Inteligentes de Habilidades Sociais. In: *CSBC 2012 — DesafIE, 2012*, Curitiba. Anais do CSBC, 2012.

JOHN, O. P.; SRIVASTAVA, S. The Big Five Trait taxonomy: History, measurement, and theoretical perspectives. In: Pervin, L. A.; John, O. P. (Org.), *Handbook of Personality: Theory and research*, v. 2, p. 102–138. Guilford Press, New York, 1999. Disponível em: <[http://moityca.com.br/pdfs/bigfive\\_John.pdf](http://moityca.com.br/pdfs/bigfive_John.pdf)>. Acesso em: 09 ago. 2015.

JOHNSON, J. A. Web-based personality assessment. In *71st Annual Meeting of the Eastern Psychological Association, USA, 2000*. Disponível em: <<http://www.personal.psu.edu/faculty/j/5/j5j/papers/ConferencePapers/2000EPA.pdf>>. Acesso em: 09 ago. 2015.

KARAMPIPERIS, P.; KOUKOURIKOS, A.; STOITSIS, G. Collaborative Filtering Recommendation of Educational Content in Social Environments utilizing Sentiment Analysis Techniques. In: MANOUSELIS, N.; DRACHSLER, H.; VERBERT, K.; SANTOS, O. C. (Org.), *Recommender Systems for Technology Enhanced Learning: Research Trends & Applications*, Springer New York, p. 3–23, 2014.

KERKIRI, T.; MANITSARIS, A.; MAVRIDIS, I. How e-learning systems may benefit from ontologies and recommendation methods to efficiently personalise resources. *International Journal of Knowledge and Learning (IJKL)*, v. 5, n. 3/4, p. 347–370, 2009.

KOLB, D. A. Experiential learning: experience as the source of learning and development. *Englewood Cliffs: Prentice-Hall*. 1984.

KONSTAN, J. A.; MILLER, B. N.; MALTZ, D.; HERLOCKER, J. L.; GORDON, L. R.; RIEDL, J. GroupLens: Applying Collaborative Filtering to Usenet News. *Communications of the ACM*, New York, v.40, n.3, pp. 77–87, 1997. Disponível em: <[https://www.ischool.utexas.edu/~i385q/readings/konstan\\_1997.pdf](https://www.ischool.utexas.edu/~i385q/readings/konstan_1997.pdf)>. Acesso em: 09 ago. 2015.

KURI, N. P. Tipos de personalidade e Estilos de Aprendizagem: proposições para o ensino de engenharia. 2004. Tese (Doutorado em Engenharia de Produção), Universidade Federal de São Carlos, São Carlos, 2004. Disponível em: <[http://www.bdttd.ufscar.br/htdocs/tedeSimplificado/tde\\_arquivos/1/TDE-2004-09-23T13:26:21Z-219/Publico/TeseNPK.pdf](http://www.bdttd.ufscar.br/htdocs/tedeSimplificado/tde_arquivos/1/TDE-2004-09-23T13:26:21Z-219/Publico/TeseNPK.pdf)>. Acesso em: 09 ago. 2015.

LITZINGER, T. A.; LEE, S. H.; WISE, J. C.; FELDER, R. M. A Psychometric Study of the Index of Learning Styles. *Journal of Engineering Education*, 96(4), p. 309–319, 2007. Disponível em: <[http://www4.ncsu.edu/unity/lockers/users/f/felder/public/ILSdir/ILS\\_Validation\(JEE-2007\).pdf](http://www4.ncsu.edu/unity/lockers/users/f/felder/public/ILSdir/ILS_Validation(JEE-2007).pdf)>. Acesso em: 09 ago. 2015.

MACHION, A. C. G. Uso de ontologias e mapas conceituais na descoberta e análise de Objetos de Aprendizagem: um estudo de caso em eletrostática. 2007. Tese (Doutorado em Ciência da Computação) — Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, 2007. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/45/45134/tde-06042009-122508/>>. Acesso em: 09 ago. 2015.

MAIRESSE, F.; WALKER, M. A.; MEHL, M.; MOORE, R. Using Linguistic Cues for the Automatic Recognition of Personality in Conversation and Text. *Journal of Artificial Intelligence Research*, p. 457–500, 2007. Disponível em: <<https://www.aaai.org/Papers/JAIR/Vol30/JAIR-3012.pdf>>. Acesso em: 09 ago. 2015.

MANOUSELIS, N.; DRACHSLER, H.; VERBERT, K.; DUVAL, E. Recommender Systems for Learning. Berlin, *Springer*, 90 p., 2012.

MARKOVIKJ, D.; GIEVSKA, S.; KOSINSKI, M.; STILLWELL, D. Mining Facebook Data for Predictive Personality Modeling. *Proc of Workshop on Computational Personality Recognition*, AAAI Press, Melon Park, CA, 2013. Disponível em: <[http://clic.cimec.unitn.it/fabio/wcpr13/markovikj\\_wcpr13.pdf](http://clic.cimec.unitn.it/fabio/wcpr13/markovikj_wcpr13.pdf)>. Acesso em: 09 ago. 2015.

MASTHOFF, J. The Pursuit of Satisfaction: Affective State in Group Recommender Systems. In: *Proceedings of User Modeling 2005*: 297–306. Brna, P., Ardissono, L. and Mitrovic, A. Eds. LNAI. Springer Verlag, Berlin, 2005.

MATTHEWS, G.; DEARY, I. J.; WHITEMAN, M. C. Personality Traits. *Cambridge University Press*, Cambridge. 2003.

MCCRAE, R. R.; COSTA, P. T. Jr. Personality trait structure as a human universal. *American Psychologist*, 52(5), 509–516. 1997. Disponível em: <<http://www.psychometric-assessment.com/wp-content/uploads/2013/01/Personality-Traits-as-Human-Universals-American-Psychologist-May-1997.pdf>>. Acesso em: 09 ago. 2015.

MCDUGALL, W. Of the words character and personality. *Character and Personality*, 1(1), 3–16. 1932.

MERLOT. MERLOT — Multimedia Educational Resource for Learning and Online Teaching. 2015. Disponível em: <<http://merlot.org>>. Acesso em: 09 ago. 2015.

MOODLE. *Moodle Plugins Directory: Recommender*. 2013. Disponível em: <[https://moodle.org/plugins/view.php?plugin=block\\_recommender](https://moodle.org/plugins/view.php?plugin=block_recommender)>. Acesso em: 09 ago. 2015.

MORAIS, C. T. Q.; FRANCO, S. R. K. Estudo de Caso de Alertas e Recomendações para Educação a Distância Aplicado em Turmas Heterogêneas. *Informática na Educação: teoria & prática*. Porto Alegre, v. 14, p. 129, 2011. Disponível em: <<http://seer.ufrgs.br/index.php/InfEducTeoriaPratica/article/view/22245/16844>>. Acesso em: 09 ago. 2015.

MOZZAQUATRO, P. M.; FRANCISCATO, F. T.; RIBEIRO, P. S.; MEDINA, R. D. Ambiente Virtual de Aprendizagem Móvel adaptado aos diferentes estilos cognitivos utilizando Hipermedia Adaptativa. In *XVI Workshop de Informática na Escola — WIE*, p. 1255–1264, 2010. Disponível em: <<http://www.br-ie.org/pub/index.php/wie/article/view/2048/1810>>. Acesso em: 09 ago. 2015.

NASCIMENTO JÚNIOR, H. M. N.; COSTA, E. B.; OLIVEIRA, T. T. M.; SILVA, A. P.; BITTENCOURT, I. I. Sistema de Recomendação Híbrido para Bibliotecas Digitais que Suportam o Protocolo OAI-PMH. In: *Anais do 22º Simpósio Brasileiro de Informática na Educação*, Aracaju, p. 140–149, 2011. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/1584/1349>>. Acesso em: 09 ago. 2015.

NATRIELLI FILHO, D. G. Neurobiologia da Personalidade. *Temas e Prática do Psiquiatra*, v. 32, n. 62–63, p. 1–152, 2002. Disponível em: <[http://www.psiquiatriageral.com.br/psicopatologia/Neurobiologia\\_da\\_Personalidade.htm](http://www.psiquiatriageral.com.br/psicopatologia/Neurobiologia_da_Personalidade.htm)>. Acesso em: 09 ago. 2015.

NUNES, C. H. S. S.; HUTZ, C. S.; NUNES, M. F. O. Bateria Fatorial de Personalidade. *Manual Técnico*. São Paulo: Casa do Psicólogo, 2010.

NUNES, M. A. S. N. Computação Afetiva personalizando interfaces, interações e recomendações de produtos, serviços e pessoas em Ambientes computacionais. In: Nunes, M. A. S. N.; Oliveira, A. A.; Ordonez, E. D. M. (Org.). *Projetos e Pesquisas em Ciência da Computação no DCOMP/PROCC/UFS*: São Cristóvão, p. 115–151, 2012. Disponível em: <<http://200.17.141.213/~gutanunes/hp/publications/NunesDCOMP2012.pdf>>. Acesso em: 09 ago. 2015.

NUNES, M. A. S. N. *Recommender System Based On Personality Traits*. (Tese De Doutorado). Université Montpellier 2-Lirimm- França, 2008.

NUNES, M. A. S. N. *Recommender Systems Based On Personality Traits: Could Human Psychological Aspects Influence The Computer Decision-Making Process?*. 1. ed. Berlin: Vdm Verlag Dr. Müller. v. 1. 2009.

NUNES, M. A. S. N.; BEZERRA, J. S.; REINERT, D.; MORAES, D.; PEREIRA, E.; PEREIRA, A. J. S. Computação Afetiva e sua influência na personalização de Ambientes Educacionais: Gerando equipes compatíveis para uso em AVAs na EaD. In: Glaucio José Couri Machado. (Org.). *Educação e Ciberespaço: Estudos, Propostas e Desafios*. Aracaju: Virtus Editora, v. 1, p. 308–347, 2010. Disponível em: <<http://200.17.141.213/~gutanunes/hp/publications/capitulo.pdf>>. Acesso em: 09 ago. 2015.

NUNES, M. A. S. N.; HU, R. Personality-based recommender systems: an overview. In: *Proceedings of the sixth ACM conference on Recommender systems (RecSys '12)*. ACM, New York, NY, USA, p. 5-6, 2012. Disponível em: <<http://wanlab.poly.edu/recsys12/recsys/p5.pdf>>. Acesso em: 09 ago. 2015.

NUNES, M. A. S. N.; MORAES, D.; REINERT, D. Personality Inventory — PV1.0 (Portuguese Version), 2010. Registrado no Inpi. Disponível em: <<http://personalityresearch.ufs.br/>>. Acesso em: 09 ago. 2015.

OLIVEIRA, I. C. A. AdaptMLearning: uma proposta de sistema de aprendizagem adaptativo e inteligente. 2013. Tese (Doutorado em Sistemas Eletrônicos) — Escola Politécnica, Universidade de São Paulo — USP, São Paulo, 2013. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/3/3142/tde-26122013-150826/>>. Acesso em: 09 ago. 2015.

OMG. Unified Modeling Language™ (UML®) Resource Page. 2015. Disponível em: <<http://www.uml.org/>>. Acesso em: 13 set. 2015.

OPENSTAX CNX. Sharing Knowledge and Building Communities. 2015. Disponível em: <<http://cnx.org/>>. Acesso em: 09 ago. 2015.

ORACLE. Java™. 2015. Disponível em: <<http://java.com>>. Acesso em: 09 ago. 2015.

ÖZGÖBEK, Ö.; SHABIB, N.; GULLA, J. A. Data Sets and News Recommendation. In *Proceedings of 2nd International Workshop on News Recommendation and Analytics*, 2014.

PARVEEN, R.; JAISWA, A. K.; KANT, V. E-Learning Recommendation Systems – A Survey. *International Journal of Engineering Research and Development*, v. 4, p. 10–12, 2012. Disponível em: <<http://www.ijerd.com/paper/vol4-issue12/B04121012.pdf>>. Acesso em: 09 ago. 2015.

PEREIRA, A; AUGUSTIN, I. A Learning Object Recommendation System: Affective-Recommender. In: MENDES NETO, F. M. (Org.), *Technology Platform Innovations and Forthcoming Trends in Ubiquitous Learning*, 1. ed., IGI Global, p. 254–269, 2014.

PEREIRA, C. K.; CAMPOS, F.; STRÖELE, V.; DAVID, J. M. N.; BRAGA, R. Extração de Características de Perfil e de Contexto em Redes Sociais para Recomendação de Recursos Educacionais. In: *Anais do 25º Simpósio Brasileiro de Informática na Educação*, Dourados, p. 506–515, 2014. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/2979/2712>>. Acesso em: 09 ago. 2015.

POPESCU, E.; TRIGANO, P.; BADICA, C. Adaptive Educational Hypermedia Systems: A Focus on Learning Styles. In: *EUROCON 2007 — The International Conference on "Computer as a Tool"*, p. 2473–2478, 2007.

QUAN, Z. Collaborative filtering recommendation based on user personality. In: *6th International Conference on Information Management, Innovation Management and Industrial Engineering (ICIII)*, v. 3, p. 307–310, 2013.

R CORE TEAM. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria, 2013. Disponível em: <<http://www.R-project.org>>. Acesso em: 09 ago. 2015.

RABELO, I. S. Investigação de Traços de Personalidade em atletas brasileiros: análise da adequação de uma ferramenta de avaliação psicológica. 2013. Tese (Doutorado em Pedagogia do Movimento Humano) — Escola de Educação Física e Esporte, Universidade de São Paulo, São Paulo, 2013. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/39/39133/tde-12022014-133441/>>. Acesso em: 09 ago. 2015.

RAJU, P. G.; VENUGOPAL, M. Personality & learning styles — lessons for Indian corporate trainers. *Indian Journal of Industrial Relations*, 49(4), 2014.

RENDLE, S.; FREUDENTHALER, C.; GANTNER, Z., SCHMIDT-THIEME, L. BPR: Bayesian personalized ranking from implicit feedback. In *Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence (UAI 2009)*, p. 452–461, 2009. Disponível em: <<http://arxiv.org/ftp/arxiv/papers/1205/1205.2618.pdf>>. Acesso em: 09 ago. 2015.

RESENDE, D. T.; DORÇA, F. A.; CATTELAN, R. G.; ARAÚJO, R. D. Em direção à recuperação automática de Objetos de Aprendizagem em repositórios através da associação dos Estilos de Aprendizagem de estudantes com metadados no padrão IEEE-LOM. *Anais do VI Workshop Brasileiro de Web Semântica e Educação — VI WSWEd*, Dourados, MS, 2014. Disponível em: <<http://www.br-ie.org/pub/index.php/wcbie/article/view/3265/2805>>. Acesso em: 09 ago. 2015.

RICCI, F.; ROKACH, L.; SHAPIRA, B.; KANTOR, P. B (Eds.). *Handbook on Recommender Systems*. 1.ed. Springer, 845 p., ISBN: 978-0-387-85819-7, 2011. Disponível em: <[http://www.cs.bme.hu/nagyadat/Recommender\\_systems\\_handbook.pdf](http://www.cs.bme.hu/nagyadat/Recommender_systems_handbook.pdf)>. Acesso em: 09 ago. 2015.

RIDING, R.; RAYNER, S. Cognitive styles and learning Strategies – understanding style differences in learning and behavior. London: David Fulton Publishers. 2000.

SAARI, T.; RAVAJA, N.; LAARNI, J.; TURPEINEN, M.; KALLINEN, K. Psychologically targeted persuasive advertising and product information in ecommerce. In *ICEC '04: Proceedings of the 6th international conference on Electronic commerce*, ACM Press, p. 245–254, New York, NY, USA, 2004.

SAKLIKAR, S.; SAHA, S. A Social Query Framework. In *Proceedings of the 2nd International Conference on Communication Systems Software and Middleware*, p. 1–11, 2007.

SALTON, G.; BUCKLEY, C. Term weighting approaches in automatic text retrieval. *Information Processing and Management*, vol. 5, p. 513–523, 1988.

SANTOS, O. C.; SANEIRO, M.; SALMERON-MAJADAS, S.; BOTICARIO, J. G. A methodological approach to eliciting affective educational recommendations. In: *Proceedings of the 14th IEEE International Conference on Advanced Learning Technologies (ICALT'14)*, p. 529–533, 2014.

SCHWARTZ, H. A.; EICHSTAEDT, J. C.; KERN, M. L.; DZIURZYNSKI, L.; RAMONES, S. M.; AGRAWAL, M.; SHAH, A.; KOSINSKI, M.; STILLWELL, D.; SELIGMAN, M. E. P.; UNGAR, L. H. Personality, Gender, and Age in the Language of Social Media: The Open-Vocabulary Approach. *PLoS ONE*, 8(9), e73791, 2013. Disponível em: <<http://www.ppc.sas.upenn.edu/socialmediapub.pdf>>. Acesso em: 09 ago. 2015.

SCORM. *SCORM 2004 4th edition Version 1.1*. Agosto 2004. Disponível em: <<http://www.adlnet.org/scorm>>. Acesso em: 09 ago. 2015.

SEED/MEC. RIVED — Rede Interativa Virtual de Educação. Secretaria de Educação a Distância. 2015. Disponível em: <<http://rived.mec.gov.br/>>. Acesso em: 09 ago. 2015.

SENRA, C. M. S. Os Estilos de Aprendizagem de Felder a partir de Jung. 2009. Dissertação (Mestrado em Educação Tecnológica), Centro Federal de Educação Tecnológica de Minas Gerais – CEFET-MG, Belo Horizonte, 2009. Disponível em: <<http://www2.et.cefetmg.br/permalink/a2888022-14cd-11df-b95f-00188be4f822.pdf>>. Acesso em: 17 fev. 2015.

SILVA, D. M.; LEAL, E. A.; PEREIRA, J. M.; OLIVEIRA NETO, J. D. Estilos de Aprendizagem na Educação a Distância: Uma Investigação em Cursos de Especialização. In *EnANPAD 2013*, Rio de Janeiro, 2013. Disponível em: <[http://www.anpad.org.br/admin/pdf/2013\\_EnANPAD\\_EPQ1114.pdf](http://www.anpad.org.br/admin/pdf/2013_EnANPAD_EPQ1114.pdf)>. Acesso em: 09 ago. 2015.

TANG, T. Y.; MCCALLA, G. I. Beyond learners' interest: Personalized paper recommendation based on their pedagogical features for an e-learning system. In: *PRICAI*, p. 301–310, 2004.

TAUSCZIK, Y. R.; PENNEBAKER, J. W. The Psychological Meaning of Words: LIWC and Computerized Text Analysis Methods. *Journal of Language and Social Psychology*, 29(1), p.24–54, 2009. Disponível em: <<http://homepage.psy.utexas.edu/HomePage/Faculty/Pennebaker/Reprints/Tausczik&Pennebaker2010.pdf>>. Acesso em: 09 ago. 2015.

TAVARES, R.; RODRIGUES, L.; DOS SANTOS, J. N.; ANDRADE, M. Núcleo de Construção de Objetos de Aprendizagem — NOA/UFPB. 2015. Disponível em: <<http://www.fisica.ufpb.br/~romero/objetosaprendizagem>>. Acesso em: 09 ago. 2015.

THE ECLIPSE FOUNDATION. Eclipse. 2015. Disponível em: <<http://eclipse.org>>. Acesso em: 09 ago. 2015.

TKALČIČ, M.; KUNAVER, M.; TASIČ, J.; KOŠIR, A. Personality Based User Similarity Measure for a Collaborative Recommender System. In: *5th Workshop on Emotion in Human-Computer Interaction*, Cambridge, UK, 2009. Disponível em: <[http://slavnik.fe.uni-lj.si/markot/uploads/Main/2009\\_Tkalcic\\_HCI.pdf](http://slavnik.fe.uni-lj.si/markot/uploads/Main/2009_Tkalcic_HCI.pdf)>. Acesso em: 09 ago. 2015.

TREVISAN, L. F.; CAZELLA, S. C.; NUNES, M. A. S. N. Aplicando Traços de Personalidade e Contextos em Sistemas de Recomendação para TV Digital: um facilitador do processo de ensino-aprendizagem. In: *SBIE-WIE 2011 Workshop. Towards Affective Computing in Education: how to enhance the student affective experience to foster learning?*. Aracaju, p. 1792-1799, 2011. Disponível em: <<http://200.17.141.213/~gutanunes/hp/publications/trevisan.pdf>>. Acesso em: 09 ago. 2015.

URSO JUNIOR, J. Stress e personalidade: overview e avaliação crítica de revisões sistemáticas sobre padrão comportamental tipo a e personalidade tipo d com desfechos coronarianos. 2011. Tese (Doutorado em Psicologia Social) — Instituto de Psicologia, Universidade de São Paulo, São Paulo, 2011. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/47/47134/tde-30112011-103946/>>. Acesso em: 09 ago. 2015.

VALASKI, J.; MALUCELLI, A.; REINEHR, S. Revisão dos Modelos de Estilos de Aprendizagem Aplicados à Adaptação e Personalização dos Materiais de Aprendizagem. In *XXII Simpósio Brasileiro de Informática na Educação — SBIE*, p. 844–847, 2011. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/1843/1605>>. Acesso em: 09 ago. 2015.

VAZ, M. Os Padrões Internacionais para a Construção de Material Educativo Online. *Pearson Education do Brasil*, São Paulo, 1.ed., p. 386–396, 2009.

VESIN, B.; KLASNJA-MILICEVIC, A.; IVANOVIC, M., BUDIMAC, Z. Applying Recommender Systems and Adaptive Hypermedia for e-Learning Personalization. *Computing and Informatics*, v. 32, p. 629–659, 2013.

VICARI, R. M., RIBEIRO, A., DA SILVA, J. M. C., SANTOS, E. R., PRIMO, T., BEZ, M. Brazilian proposal for agent-based learning objects metadata standard — OBAA. *Communications in Computer and Information Science*, vol.108, p. 300–311, 2010. Disponível em: <<http://www.portalobaa.org/padrao-obaa/artigos-publicados/ArtigoMSfinal.pdf>>. Acesso em: 09 ago. 2015.

WHATTORENT. What to rent?. 2015. Disponível em: <<http://www.whattorent.com/>>. Acesso em: 09 ago. 2015.

WIEDEMANN, T.; BARBOSA, J. L. V.; RIGO, S. J. Um Modelo para Recomendação de Objetos de Aprendizagem Utilizando Similaridade de Sessões. *Revista Brasileira de Informática na Educação (RBIE)*, v. 22, n. 3, p. 85–99, 2014. Disponível em: <<http://www.br-ie.org/pub/index.php/rbie/article/view/2849/2834>>. Acesso em: 09 ago. 2015.

WILEY, D. Connecting learning objects to instructional design theory: A definition, a metaphor, and a taxonomy, 2000. Disponível em: <<http://reusability.org/read/chapters/wiley.doc>>. Acesso em: 09 ago. 2015.

WU, W.; CHEN, L.; HE, L. Using personality to adjust diversity in recommender systems. In *Proceedings of the 24th ACM Conference on Hypertext and Social Media (HT '13)*. ACM, New York, NY, USA, p. 225–229, 2013. Disponível em: <<http://www.comp.hkbu.edu.hk/~lichen/download/225-Wu.pdf>>. Acesso em: 09 ago. 2015.

XIA, F.; ASABERE, N. Y.; LIU, H.; CHEN, Z.; WANG, W. Socially Aware Conference Participant Recommendation With Personality Traits. *IEEE Systems Journal*, DOI: 10.1109/JSYST.2014.2342375, 2014.

YOOSOOKA, B.; WUWONGSE, V. Linked Open Data for Learning Object Discovery: Adaptive e-Learning Systems. In *Third International Conference on Intelligent Networking and Collaborative Systems*, p. 60–67, 2011.

ZAINA, L. A.; BRESSAN, G.; CARDIERI, M. A. A.; RODRIGUES JUNIOR, J. F. E-LORS: Uma abordagem para recomendação de Objetos de Aprendizagem. *Revista Brasileira de Informatica na Educação (RBIE)*, v. 20, n. 1, p. 4–16, 2012. Disponível em: <<http://www.br-ie.org/pub/index.php/rbie/article/view/1289/1190>>. Acesso em: 09 ago. 2015.

ZONASH, R.; NAQVI, I. Personality Traits and Learning Styles among Students of Mathematics, Architecture, and Fine Arts. *Journal of Behavioral science*, v. 21, p. 92-108, 2011.

ZYWNO, M. S. A Contribution to Validation of Score Meaning for Felder-Soloman's Index of Learning Styles". In *Proceedings of the 2003 American Society for Engineering Education Annual Conference & Exposition*. Nashville, Tennessee, 2003. Disponível em: <[http://www4.ncsu.edu/unity/lockers/users/f/felder/public/ILSdir/Zywno\\_Validation\\_Study.pdf](http://www4.ncsu.edu/unity/lockers/users/f/felder/public/ILSdir/Zywno_Validation_Study.pdf)>. Acesso em: 09 ago. 2015.

# Apêndice A

## Publicações

No Quadro 13, encontram-se detalhes do capítulo e artigos publicados ao longo da realização da pesquisa de mestrado descrita neste documento.

**Quadro 13. Publicações.**

<b>Sistemas de Recomendação de Recursos Educacionais: conceitos, técnicas e aplicações</b>	
Referência	COSTA, E.; AGUIAR, J.; MAGALHÃES, J. Sistemas de Recomendação de Recursos Educacionais: conceitos, técnicas e aplicações. In: <i>Anais da II Jornada de Atualização em Informática na Educação</i> , p. 57-78, 2013. Disponível em: < <a href="http://www.br-ie.org/pub/index.php/pie/article/view/2589/2245">http://www.br-ie.org/pub/index.php/pie/article/view/2589/2245</a> >. Acesso em: 09 ago. 2015.
Resumo	Nos últimos anos tem-se observado um crescimento acentuado no volume de recursos digitais educacionais disponíveis na Web aberta ou mesmo em bibliotecas digitais privadas. Portanto, trata-se de um grande volume de recursos, tornando uma tarefa complicada para um usuário ter acesso ao que lhe interessa. Para abordar esse problema, surgiram recentemente os Sistemas de Recomendação personalizada. Entretanto, esse tipo de sistema precisa ser mais bem disseminado para os usuários de recursos educacionais, a exemplo de estudantes e professores, pois ajudarão significativamente no desempenho de suas atividades. Neste capítulo, os conceitos e as principais técnicas e algoritmos de filtragem de informação serão vistos com aplicações na recomendação de recursos digitais educacionais, demonstrando o potencial desse tipo de sistema.
Observação	Capítulo publicado nos anais da II Jornada de Atualização em Informática na Educação (JAIE 2013) — subevento do Congresso Brasileiro de Informática na Educação (CBIE 2013) — sendo base para o minicurso com a mesma denominação, ministrado no dia 25 de novembro de 2013 no CBIE, realizado na Universidade Estadual de Campinas (UNICAMP)
<b>Um Mapeamento Sistemático sobre Iniciativas Brasileiras em Sistemas de Recomendação Educacionais</b>	
Referência	AGUIAR, J. J. B.; SANTOS, S. I. N.; FECHINE, J. M.; COSTA, E. Um Mapeamento Sistemático sobre Iniciativas Brasileiras em Sistemas de Recomendação Educacionais. In: <i>Anais do 25º Simpósio Brasileiro de Informática na Educação</i> , Dourados, p. 1123-1132, 2014. Disponível em: < <a href="http://www.br-ie.org/pub/index.php/sbie/article/view/3058/2566">http://www.br-ie.org/pub/index.php/sbie/article/view/3058/2566</a> >. Acesso em: 09 ago. 2015.
Resumo	Neste artigo, é descrito um Mapeamento Sistemático relativo a Sistemas de Recomendação Educacionais (SRE), considerando as publicações nos periódicos "Informática na Educação: Teoria & Prática", "Revista Brasileira de Informática na Educação" e "Revista Novas Tecnologias na Educação" e nos anais do "Simpósio Brasileiro de Informática na Educação" e do "Workshop de Informática na Escola". Os dados obtidos indicaram a evolução histórica dessas publicações, as instituições envolvidas, as técnicas de recomendação mais utilizadas, os principais recursos recomendados, entre outros aspectos. Com este mapeamento, almeja-se que os pesquisadores e educadores possam ter acesso facilitado às iniciativas em SRE no Brasil.
Observação	Artigo publicado nos anais do XXV Simpósio Brasileiro de Informática na Educação (SBIE 2014) — subevento do III Congresso Brasileiro de Informática na Educação (CBIE 2014) — e apresentado no dia 6 de novembro de 2014 na Sessão Técnica 19 do SBIE/CBIE, realizado na Universidade Federal da Grande Dourados (UFGD).

**Continuação do Quadro 13.**

<b>Estilos Cognitivos e Estilos de Aprendizagem em Informática na Educação: um mapeamento sistemático focado no SBIE, WIE e RBIE</b>	
Referência	AGUIAR, J. J. B.; FECHINE, J. M.; COSTA, E. Estilos Cognitivos e Estilos de Aprendizagem em Informática na Educação: um mapeamento sistemático focado no SBIE, WIE e RBIE. In: <i>Anais do 25º Simpósio Brasileiro de Informática na Educação</i> , Dourados, p. 441-450, 2014. Disponível em: < <a href="http://www.br-ie.org/pub/index.php/sbie/article/view/2972/2705">http://www.br-ie.org/pub/index.php/sbie/article/view/2972/2705</a> >. Acesso em: 09 ago. 2015.
Resumo	Neste artigo, é descrito um estudo sobre as iniciativas brasileiras em relação ao uso das teorias de Estilos Cognitivos (EC) e/ou Estilos de Aprendizagem (EA) na área de Informática na Educação (IE). Foi realizado um mapeamento sistemático das publicações dos anais do SBIE e WIE, além do periódico RBIE. Com este estudo, foi possível proporcionar reflexões sobre as pesquisas brasileiras que envolvem a preocupação com os estilos dos aprendizes. Além disso, com este mapeamento, os pesquisadores podem conhecer/utilizar melhor os termos EC e EA, além de terem o acesso facilitado a dados de iniciativas de grupos brasileiros de pesquisa em IE que trabalham nessa temática.
Observação	Artigo publicado nos anais do XXV Simpósio Brasileiro de Informática na Educação (SBIE 2014) — subevento do III Congresso Brasileiro de Informática na Educação (CBIE 2014) — e apresentado no dia 4 de novembro de 2014 na Sessão Técnica 9 do SBIE/CBIE, realizado na Universidade Federal da Grande Dourados (UFGD).
<b>Identificando os Traços de Personalidade de Estudantes de um Curso Técnico em Informática</b>	
Referência	AGUIAR, J. J. B.; FECHINE, J. M.; COSTA, E. (2015). Identificando os Traços de Personalidade de Estudantes de um Curso Técnico em Informática. In: <i>Anais do XXXV Congresso da Sociedade Brasileira de Computação (CSBC) — XXIII Workshop sobre Educação em Computação (WEI)</i> , Recife, sem paginação, 2015. Disponível em: < <a href="http://goo.gl/x1oPS4">http://goo.gl/x1oPS4</a> >. Acesso em: 09 ago. 2015.
Resumo	Em geral, percebe-se que os alunos em cursos técnicos entram focados em se profissionalizar e partir rapidamente para o mercado de trabalho. Apesar de apresentarem objetivos e características bem similares, esses alunos possuem peculiaridades. O objetivo deste artigo consiste em apresentar um levantamento sobre os Traços de Personalidade de alunos de informática em nível técnico, a partir do inventário TIPI (Ten-Item Personality Inventory). Com este estudo, constatou-se a heterogeneidade das turmas em relação à personalidade dos alunos, sendo comentado como a identificação desse aspecto psicológico pode influenciar o desenvolvimento do aluno durante o processo de ensino-aprendizagem.
Observação	Artigo publicado nos anais do XXIII Workshop sobre Educação em Computação (WEI 2015) — subevento do XXXV Congresso da Sociedade Brasileira de Computação (CSBC 2015) — e apresentado no dia 23 de julho de 2015 na Sessão Técnica 1 do WEI/CSBC, realizado no Centro de Convenções de Pernambuco.

**Continuação do Quadro 13.**

<b>Utilização do Índice de Estilos de Aprendizagem de Felder–Soloman em Turmas de Nível Técnico, Graduação e Pós-Graduação em Computação</b>	
Referência	AGUIAR, J. J. B.; FECHINE, J. M.; COSTA, E. (2015). Utilização do Índice de Estilos de Aprendizagem de Felder–Soloman em Turmas de Nível Técnico, Graduação e Pós-Graduação em Computação. In: <i>Anais do XXXV Congresso da Sociedade Brasileira de Computação (CSBC) – XXIII Workshop sobre Educação em Computação (WEI)</i> , Recife, sem paginação, 2015. Disponível em: < <a href="http://goo.gl/oQy8nW">http://goo.gl/oQy8nW</a> >. Acesso em: 09 ago. 2015.
Resumo	Cada indivíduo possui preferências relativas à forma com que representa e organiza novas informações, sendo possível denominar isso de Estilos de Aprendizagem (EA). A identificação desses EA pode favorecer o processo de ensino–aprendizagem. Neste artigo, é apresentado um estudo sobre os EA dos alunos de computação de diferentes níveis de ensino (técnico, graduação e pós-graduação). A extração desses EA foi realizada a partir do Índice de Estilos de Aprendizagem de Felder–Soloman, baseado na teoria de Felder–Silverman. Este estudo possibilitou verificar o grau de heterogeneidade referente às preferências no modo de aprender dos alunos em diferentes níveis, mesmo que estes sejam de uma área específica (computação).
Observação	Artigo publicado nos anais do XXIII Workshop sobre Educação em Computação (WEI 2015) – subevento do XXXV Congresso da Sociedade Brasileira de Computação (CSBC 2015) – e apresentado no dia 23 de julho de 2015 na Sessão Técnica 3 do WEI/CSBC, realizado no Centro de Convenções de Pernambuco.
<b>Análise Comparativa de Abordagens de Associação entre os Estilos de Aprendizagem de Felder–Silverman e os Metadados do Padrão IEEE LOM</b>	
Referência	AGUIAR, J. J. B.; FECHINE, J. M.; COSTA, E. (2015). Análise Comparativa de Abordagens de Associação entre os Estilos de Aprendizagem de Felder–Silverman e os Metadados do Padrão IEEE LOM. In: <i>Anais do XXXV Congresso da Sociedade Brasileira de Computação (CSBC) – IV Workshop de Desafios da Computação Aplicada à Educação (DesafIE)</i> , Recife, sem paginação, 2015. Disponível em: < <a href="http://goo.gl/Icu1gj">http://goo.gl/Icu1gj</a> >. Acesso em: 09 ago. 2015.
Resumo	Estilos de Aprendizagem (EA) e Objetos de Aprendizagem (OA) são termos cada vez mais encontrados em pesquisas relativas à Informática na Educação. Esses conceitos podem ser associados para, por exemplo, otimizar a busca e utilização dos OA em repositórios, com base nos EA do aluno. Neste artigo, é apresentada uma análise comparativa de duas pesquisas recentes que realizaram associações entre os atributos dos OA, baseados no padrão IEEE LOM, e os EA, baseados na teoria de Felder–Silverman. O objetivo deste artigo é expor que alguns aspectos dessas associações não são triviais, havendo abordagens com diferenças significativas e que, portanto, mais estudos relativos a essas associações precisam ser realizados.
Observação	Artigo publicado nos anais do IV Workshop de Desafios da Computação Aplicada à Educação (DesafIE 2015) – subevento do XXXV Congresso da Sociedade Brasileira de Computação (CSBC 2015) – e apresentado no dia 20 de julho de 2015 na Sessão Técnica 1 do DesafIE/CSBC, realizado no Centro de Convenções de Pernambuco.

Além das publicações listadas no Quadro 13, três artigos foram aceitos para publicação no 4º Congresso Brasileiro de Informática na Educação (CBIE 2015<sup>1</sup>), a ser realizado durante os dias 26 a 30 de outubro de 2015.

- **Utilização da ferramenta Five Labs para Identificação de Traços de Personalidade dos Estudantes** — artigo submetido e aprovado para publicação na Trilha 1 (Relatos de Experiência de uso de Tecnologias Digitais de Informação e Comunicação na Educação) do 21º Workshop de Informática na Escola (WIE 2015), evento que integra o CBIE 2015.
- **Avaliação de Sistemas de Recomendação Educacionais no Brasil: uma revisão sistemática da literatura** — artigo submetido e aprovado para publicação na Trilha 4 (Inteligência em Ambientes e Sistemas Computacionais para Ensino/Aprendizagem) do 26º Simpósio Brasileiro de Informática na Educação (SBIE 2015), evento que integra o CBIE 2015.
- **Recomendação de Objetos de Aprendizagem baseada na Popularidade dos Objetos e nos Estilos de Aprendizagem dos Alunos** — artigo submetido e aprovado para publicação na Trilha 4 (Inteligência em Ambientes e Sistemas Computacionais para Ensino/Aprendizagem) do 26º Simpósio Brasileiro de Informática na Educação (SBIE 2015), evento que integra o CBIE 2015.

Nas páginas seguintes, encontram-se, no formato padrão da SBC (Sociedade Brasileira de Computação), estes artigos aceitos, mas ainda não publicados.

---

<sup>1</sup> Página Web com informações do CBIE 2015: [http://ic.ufal.br/evento/cbie\\_laclo2015/](http://ic.ufal.br/evento/cbie_laclo2015/). Acesso em: 09 ago. 2015.

# Utilização da Ferramenta Five Labs para Identificação de Traços de Personalidade dos Estudantes

Janderson J. B. Aguiar<sup>1</sup>, Joseana M. Fechine<sup>1</sup>, Evandro B. Costa<sup>2</sup>

<sup>1</sup> Universidade Federal de Campina Grande (UFCG), Campina Grande – PB – Brasil

<sup>2</sup> Universidade Federal de Alagoas (UFAL), Maceió – AL – Brasil

janderson@copin.ufcg.edu.br, joseana@dsc.ufcg.edu.br, evandro@ic.ufal.br

**Abstract.** *Increasingly there is concern in dealing with students on an individual way. Personality is a peculiar aspect of every individual that can influence the process of teaching and learning. The purpose of this paper is to present an experience report, in the school space, involving the use of Five Labs, a tool to extract the Personality Traits of students based on their posts on Facebook. With Five Labs, it was possible to identify the profile of three classes of students of computer science at technical level. It is hoped that this paper encourage the identification of this psychological aspect in schools, and encourage more research on Personality in Computers in Education.*

**Resumo.** *Cada vez mais há preocupação em tratar os alunos de maneira individualizada. A Personalidade é um aspecto peculiar de cada indivíduo que pode influenciar no processo de ensino e aprendizagem. O objetivo deste artigo consiste em apresentar um relato de experiência, no espaço escolar, envolvendo o uso da ferramenta Five Labs para, com base em postagens na rede social Facebook, extrair os Traços de Personalidade dos alunos. Com esta ferramenta, foi possível identificar com facilidade o perfil de três turmas de alunos de informática em nível técnico. Espera-se com este artigo incentivar a identificação desse aspecto psicológico nas escolas, além de incentivar mais pesquisas sobre Personalidade em Informática na Educação.*

## 1. Introdução

Segundo Litto (1996 *apud* Kuri 2004), deve-se haver uma educação individualizada, sendo inaceitável que se continue com o paradigma industrial de tratar todos os alunos iguais, como em uma linha de montagem. Apesar de ser um citação de quase 20 anos, permanece atual por ainda se perceber muitas vezes uma educação não individualizada nas escolas. Nesse sentido, é relevante utilizar, no contexto escolar, ferramentas que ajudem a tratar os alunos de maneira particularizada.

As tecnologias de informação e comunicação podem servir de mediadoras para considerar aspectos psicológicos humanos na educação. A personalidade, por exemplo, é um aspecto psicológico que influencia no processo de tomada de decisão [Nunes 2012] e, assim sendo, é importante considerá-la no processo de ensino e aprendizagem.

Apesar de a definição do conceito de personalidade não ser consensual, é possível defini-la como um padrão de comportamento consistente originado internamente no indivíduo [Burger 2000].

Neste artigo, é apresentado um relato de experiência de uso de uma ferramenta on-line (Five Labs) para identificar os traços de personalidade de alunos a partir de seus

perfis na rede social Facebook (<https://www.facebook.com/>). Com base nisso, são também realizados comentários para estimular reproduções similares dessa experiência.

O restante do artigo está estruturado da seguinte forma: na seção 2, é apresentada a teoria de personalidade baseada em traços; na seção 3, são comentados trabalhos relacionados; na seção 4, é explanado como foi organizada a experiência de uso da ferramenta Five Labs; na seção 5, são discutidos os resultados obtidos; e, na seção 6, são apresentados comentários finais baseados nessa experiência realizada.

## 2. A Teoria dos Traços de Personalidade

Por ser mais fácil mensurar por meio computacional, a Teoria dos Traços [Allport e Allport 1921] é uma das teorias mais populares para representar o conceito de personalidade em pesquisas de áreas tecnológicas.

O modelo conhecido como *Big Five* [John e Srivastava 1999] consiste na versão moderna da Teoria dos Traços. Os cinco fatores deste modelo são: Extroversão (*extraversion*), Socialização (*agreeableness*), Realização (*conscientiousness*), Neuroticismo (*neuroticism*) e Abertura (*openness*). No Quadro 1, encontram-se considerações relativas a cada um desses fatores, com base nas pesquisas de Costa e Widiger (2002), Costa e McCrae (2007), Nunes, Hutz e Nunes (2010) e Rabelo (2013).

**Quadro 1. Características dos fatores do *Big Five*.**

<p><b>Extroversão</b> refere-se às formas como os indivíduos interagem com os outros, indicando o quanto são comunicativos, falantes, ativos, assertivos, responsivos e gregários. Índices altos tendem, portanto, a representar pessoas mais sociáveis, ativas, falantes, otimistas, alegres, bem dispostas e cordiais. Entretanto, índices baixos não representam necessariamente pessoas infelizes, não amistosas ou pessimistas, mas tendem a representar pessoas reservadas, introvertidas, sóbrias, indiferentes, independentes e quietas.</p>
<p><b>Socialização</b> refere-se à qualidade das relações interpessoais dos indivíduos e aos tipos de interações que um indivíduo apresenta — predisposição para ser amistoso, para sensibilizar-se com a situação alheia, para colocar-se no lugar do outro, para demonstrar gentileza, complacência, compaixão. Índices altos tendem, portanto, a representar pessoas generosas, amáveis, afetuosas, prestativas e altruístas, com tendência à responsabilidade e empatia, e que acreditam que a maioria das outras pessoas agirá da mesma forma. Por outro lado, índices baixos tendem a representar pessoas petulantes, não cooperativas, facilmente irritáveis, e que podem apresentar-se de maneira manipuladora, vingativa e insensível.</p>
<p><b>Realização</b> refere-se ao grau de organização e condução de tarefas, persistência, motivação, controle e autocontrole em termos de planejamento apresentados pelos indivíduos. Índices altos tendem, portanto, a representar pessoas mais organizadas, confiáveis, trabalhadoras, determinadas, pontuais, meticulosas, ambiciosas e persistentes. Índices baixos tendem a representar pessoas preguiçosas, descuidadas, desorganizadas, negligentes, que não têm objetivos claros, e que tendem a ter pouco comprometimento e responsabilidade diante de tarefas.</p>
<p><b>Neuroticismo</b> refere-se à tendência cotidiana dos indivíduos a experimentar padrões emocionais vinculados a desconforto psicológico (aflição, angústia, culpa, medo, nojo, raiva, sofrimento, tristeza, vergonha, entre outros), além de referir-se à ansiedade excessiva, à pouca habilidade para conter impulsos e para lidar com o estresse, à propensão a ideias dissociadas da realidade (irracionais), e à dificuldade para tolerar a frustração causada pela não realização de desejos. Índices altos tendem, portanto, a representar pessoas predispostas a vivenciar mais profundamente o seu sofrimento emocional. Por outro lado, índices baixos tendem a representar pessoas mais tranquilas, relaxadas, constantes, menos agitadas, com habilidade maior em lidar com situações estressantes e, em síntese, com estabilidade emocional.</p>
<p><b>Abertura</b> refere-se aos comportamentos exploratórios, ao reconhecimento da importância de ter novas experiências, à imaginação ativa, à sensibilidade estética, à curiosidade intelectual e à preferência pela variedade. Índices altos tendem, portanto, a representar pessoas curiosas, criativas, imaginativas, que se divertem com novas ideias, que costumam apresentar valores não convencionais, que experienciam intensamente uma gama ampla de emoções. Por outro lado, índices baixos tendem a representar pessoas convencionais, dogmáticas, rígidas nas suas crenças e atitudes, conservadoras nas suas preferências e menos responsivas emocionalmente.</p>

Foram criados vários inventários para realizar pesquisas com base no *Big Five*, sendo alguns dos mais utilizados o NEO-PI-R (*Revised NEO Personality Inventory*), com 240 questões de múltipla escolha [Costa e McCrae 1992], e o NEO-IPIP (*NEO International Personality Item Pool*) com 300 itens [Johnson 2000].

Apesar do uso comum de inventários, há estudos considerando abordagens que não exigem muito esforço cognitivo por parte dos usuários para detectar seus traços de personalidade. Mairesse *et al.* (2007) e Tausczik e Pennebaker (2009), mostram que há correlação entre o *Big Five* e características linguísticas encontradas em textos. Bachrach *et al.* (2012), Markovikj *et al.* (2013) e Schwartz *et al.* (2013) apresentaram estudos indicando que Traços de Personalidade possuem correlação com padrões de uso da rede social Facebook, podendo facilitar a detecção de personalidade com a mineração dos dados dos perfis de usuário dessa rede social.

Na pesquisa de Schwartz *et al.* (2013), por exemplo, foram analisados 700 milhões de palavras, frases e tópicos coletados de 75 mil voluntários usuários do Facebook, que também responderam ao NEO-IPIP. A acurácia foi de 91,9%. Com base nesse estudo, foi desenvolvida uma ferramenta para análise semântica das postagens do Facebook, Five Labs, disponibilizada pela *startup* americana Five [Five 2015].

### 3. Pesquisas Relacionadas

Muitos trabalhos analisando a personalidade de indivíduos podem ser encontrados na literatura, em diversas domínios, tais como Capretz e Ahmed (2010) e Cruz *et al.* (2011) — cujo enfoque consistiu em considerar o conceito de personalidade em tarefas relativas à Engenharia de Software —, e Rabelo (2013) — que investigou os traços de personalidade em atletas brasileiros.

No contexto educacional, há pesquisas como a de Paixão, Fortaleza e Conte (2012, 2013), que realizaram estudos sobre a personalidade no ensino de computação, discutindo implicações dos perfis psicológicos a partir de uma análise inicial com 46 alunos de Ciência da Computação e Sistemas de Informação, e posteriormente com 80 alunos, relacionando também o perfil psicológico com a evasão.

Nessa mesma linha, Farias, Dobrões e Da Silva (2013) realizaram uma análise para adaptar atividades da área de computação considerando os perfis psicológicos dos alunos, para ajudar na aprendizagem e no desempenho acadêmico. Para o ensino de engenharia, Kuri (2004) estudou a personalidade dos alunos de graduação em Engenharia Civil, Mecânica Elétrica e Produção.

Apesar dos trabalhos citados nesta seção — além de alguns comentados na seção 2 — estarem relacionados ao trabalho descrito neste artigo, eles diferenciam-se deste por não utilizarem uma ferramenta que, com base nos perfis na rede social Facebook, extraiam sua personalidade objetivando propiciar melhorias no âmbito educacional. Além disso, não foram encontrados trabalhos com foco na Teoria dos Traços para detectar, sem uso de inventários, os traços de personalidade de alunos de cursos técnicos em informática — e isto consiste na experiência relatada neste artigo.

É interessante mencionar que, ao usar os termos de busca *personalid\** e *personalit\** (visando explorar todos os trabalhos em português, inglês ou espanhol que citassem algo sobre personalidade) nos engenhos de busca dos anais do SBIE (Simpósio Brasileiro de Informática na Educação), WIE (Workshop de Informática na Escola), e

do periódico RBIE (Revista Brasileira de Informática na Educação) — que são os veículos brasileiros melhor avaliados pela CAPES na área de Informática na Educação —, nenhum dos poucos trabalhos retornados (apenas 8) apresentaram o foco descrito no parágrafo anterior. Além disso, é importante destacar a não ocorrência de pesquisas resultantes na busca dos anais do WIE. Isso indicia a escassez de estudos utilizando o conceito de Personalidade em Informática na Educação.

#### 4. Metodologia

Com base na Teoria dos Traços, explanada na seção 2, foi identificada a personalidade de alunos de 3 (três) turmas do Curso Técnico em Informática da Escola Técnica Redentorista (Campina Grande – PB). Uma vez que essas turmas tinham tamanho variado, a quantidade de resultados variou por turma, sendo 25 para uma das turmas (denominada neste artigo por Turma A), 7 para outra turma (denominada neste artigo por Turma B), e 17 para uma terceira turma (denominada neste artigo por Turma C). Ao todo, portanto, foram 49 alunos com os traços de personalidade extraídos via Five Labs.

A ferramenta Five Labs analisa a linguagem que os usuários do Facebook utilizam nesta rede social. O modelo é baseado no estudo de Schwartz *et al.* (2013), examinando o conteúdo linguístico das postagens no Facebook, usando palavras-chave para realizar estimativas precisas sobre a personalidade dos indivíduos [Five 2015].

Os resultados de cada aluno foram obtidos para análise por meio de um formulário criado via Google Drive (<https://drive.google.com/>), cujo hiperlink foi enviado para o e-mail dos alunos. Em tal formulário, havia informações gerais, em português, sobre a ferramenta (uma vez que ela está disponível em inglês), além de cinco campos para cada aluno preencher a porcentagem apresentada na ferramenta relativa a cada um dos traços do *Big Five*.

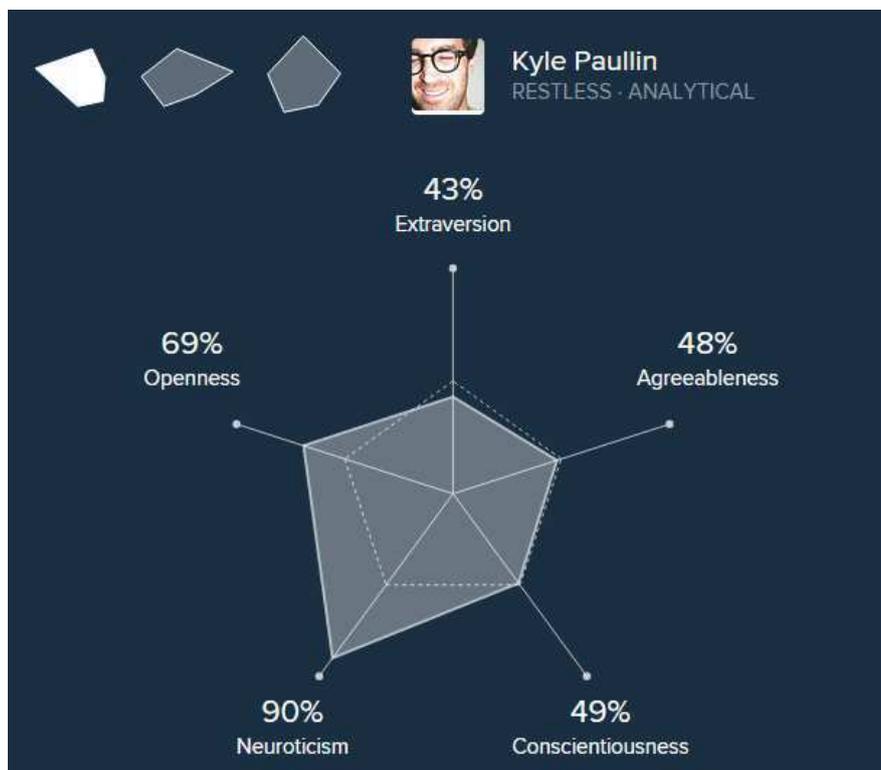


Figura 1. Ilustração da ferramenta Five Labs. Fonte: Extraído de [Five 2015].

Considerando os valores percentuais providos pela Five Labs (como ilustrado na Figura 1), foi definido que: (i) para 0 a 35%, o indivíduo possui um nível baixo para aquele traço; (ii) de 65 a 100%, o indivíduo possui um nível alto para aquele traço; e (iii) entre 35 a 65%, considerou-se que tal traço é encontrado moderadamente no indivíduo. Por exemplo, para um aluno cujo resultado disponibilizado foi 15%, 30%, 80%, 45% e 55%, respectivamente para os traços Extroversão, Socialização, Realização, Neuroticismo e Abertura, é possível afirmar que ele se apresenta como um indivíduo com Extroversão e Socialização baixas, Neuroticismo alto, e Realização e Abertura moderadas.

## **5. Análise de Resultados**

A partir da metodologia apresentada na seção 4, foram elaborados os gráficos do Quadro 2 para ilustrar os resultados obtidos.

Com base no Quadro 2, na linha relativa ao Traço Extroversão, percebe-se que a maioria apresenta um nível moderado de Extroversão, mas a quantidade de alunos com Extroversão alta é significativa. É interessante verificar também que, na Turma C, diferentemente das demais, há uma porcentagem de alunos, com nível baixo de Extroversão, que deve ser levada em consideração. Ou seja, na Turma A e na Turma B, poderiam ser adotadas estratégias mais voltadas a indivíduos extrovertidos, enquanto que, na Turma C, se deve ter mais cuidado por conter uma parcela considerável de alunos com tendência introvertida de comportamento.

Com base na linha do Quadro 2 relativa ao Traço Socialização, nota-se que, em todas as turmas, a maioria foi considerada com Socialização baixa, não havendo casos de Socialização Alta. A partir dessa análise, o docente poderia considerar a turma de forma mais homogênea, mas é importante destacar que há alguns com o nível moderado, especialmente na Turma C, devendo-se ter cuidado ao propor apenas atividades que privilegiariam o perfil de Socialização baixa.

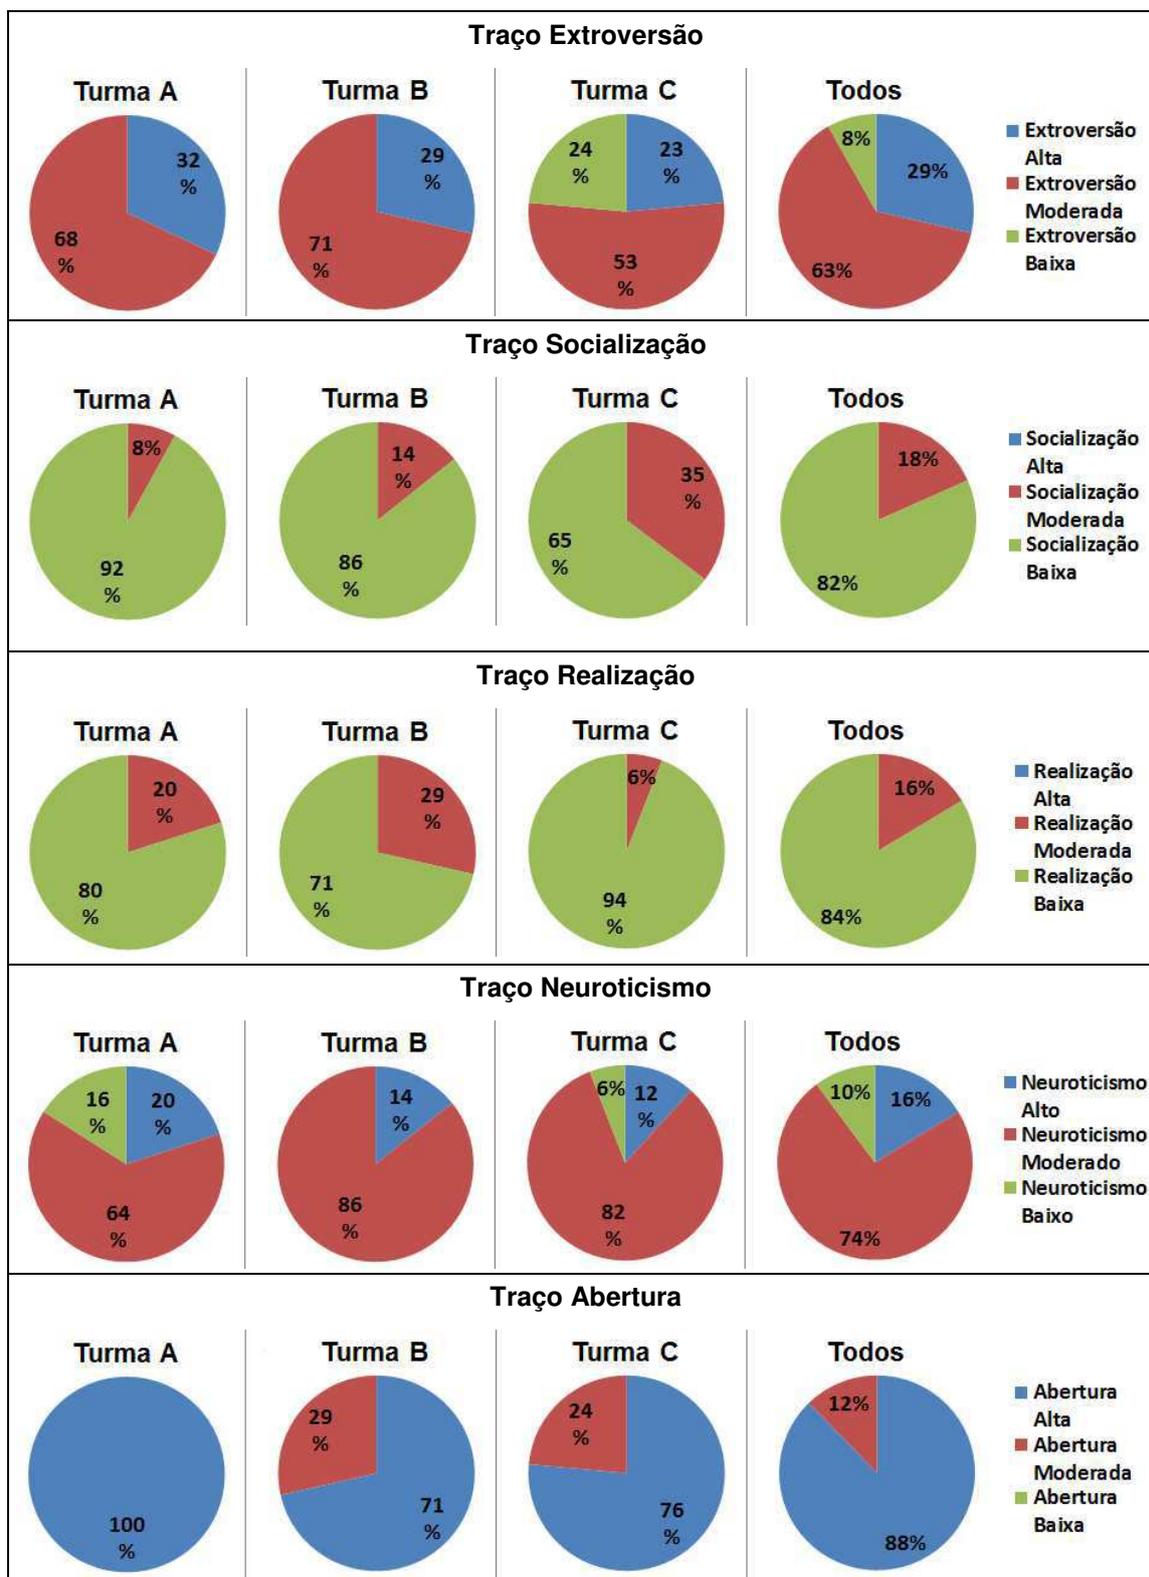
Similarmente ao traço Socialização, pelos gráficos do Quadro 2 relativos ao Traço Realização, é indicado que a maioria dos alunos apresentam um nível baixo, não havendo casos de nível alto de Realização.

Considerando a linha do Quadro 2 relativa ao Traço Neuroticismo, percebe-se que a maioria dos alunos apresenta um nível moderado de Neuroticismo. Entretanto, ao analisar por turma, visivelmente percebe-se que é interessante os docentes terem um cuidado com alguns alunos, uma vez que em cada turma há ocorrências de alunos com Neuroticismo alto, ou seja, alta instabilidade emocional.

Com base na linha do Quadro 2 relativa ao Traço Abertura, é ilustrado que os alunos apresentaram em geral um perfil com Abertura alta, ou pelo menos moderada. Especialmente na Turma A, acredita-se que o docente poderia mudar suas estratégias metodológicas durante o curso, e a turma estaria aberta a essas mudanças. Entretanto, na Turma B e na Turma C, inovações metodológicas por parte do professor provavelmente não seriam tão bem aceitas por alunos com Abertura moderada, até possivelmente prejudicando o aprendizado.

É importante reforçar o fato de que se deve verificar os traços de personalidade tanto por turma quanto individualmente, para que o professor busque estratégias mais satisfatórias e personalizadas ao propor atividades aos alunos.

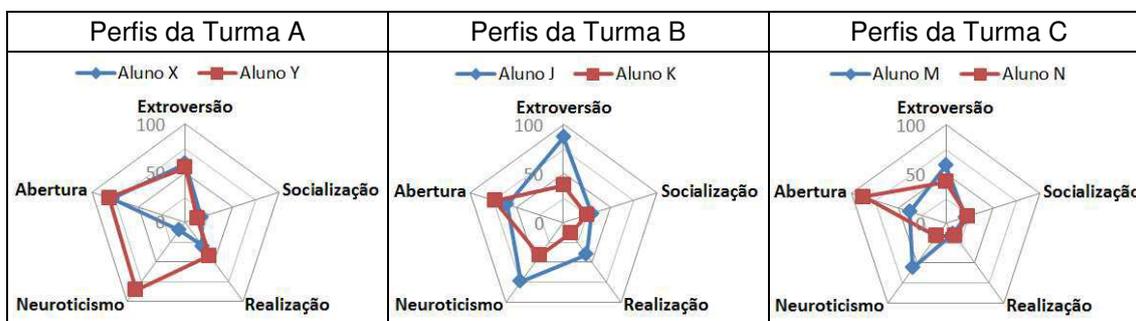
Quadro 2. Resultados da utilização do Five Labs em três turmas de alunos.



Além dos gráficos do Quadro 2, foi analisado por turma o nível de similaridade entre as personalidades dos alunos, para identificar os perfis mais diferentes, considerando os cinco traços de personalidade. Para isso, os cinco valores percentuais formaram um vetor de usuário e, uma vez que cada usuário estava sendo representado

por um vetor, foi utilizada a medida de Similaridade dos Cossenos para comparar esses vetores. No Quadro 3 são apresentados gráficos do tipo radar que ilustram os perfis de alunos mais diferentes, por turma, considerando tal medida de similaridade.

**Quadro 3. Comparação, por turma, de perfis distintos de personalidade de alunos.**



Com base nos gráficos do Quadro 3, é possível observar que os alunos do curso técnico em informática de uma mesma turma, que participaram desta experiência, podem apresentar algumas características bem diferentes, a exemplo do traço Neuroticismo no gráfico que ilustra os perfis da Turma A, do traço Extroversão no gráfico que ilustra os perfis da Turma B, e do traço Abertura no gráfico que ilustra os perfis da Turma C.

Apesar das diferenças, percebeu-se nesta experiência que, em muitos casos, os alunos são similares, como sugerem alguns traços nos gráficos do Quadro 3, além dos gráficos do Quadro 2. A partir do Quadro 4, é possível observar que há perfis de alunos do curso técnico em informática com personalidade quase 100% similares. A menor similaridade observada, considerando todos os alunos, foi de aproximadamente 76%, sendo de 78% a menor similaridade observada por turma.

**Quadro 4. Similaridades entre alunos de um Curso Técnico em Informática.**

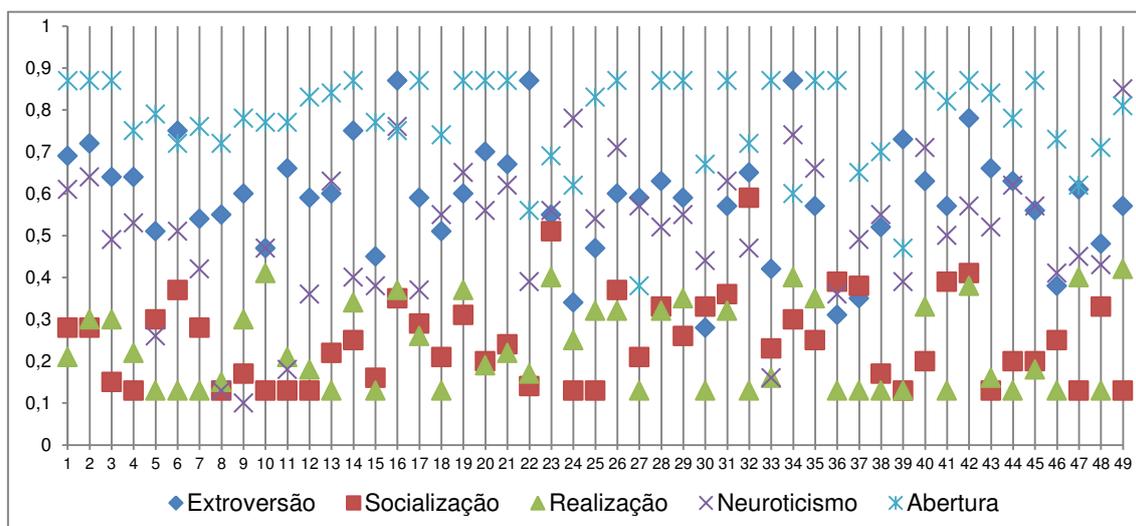
	Turma A	Turma B	Turma C	Todos
<b>Maior Similaridade</b>	0,99965	0,99388	0,99798	0,99982
<b>Menor Similaridade</b>	0,83489	0,90109	0,77717	0,75566
<b>Similaridade Média</b>	0,96633	0,96288	0,93473	0,95452

Com a realização desta experiência, foi possível perceber que, apesar de haver bastante similaridade no perfil dos alunos em um curso técnico em informática, relativo à sua personalidade, é possível encontrar alunos com características peculiares e que, se forem utilizadas estratégias sempre considerando a homogeneidade da turma, estes alunos tendem a ser prejudicados.

A análise individual dos traços de personalidade e, por conseguinte, uma visão geral de todos os traços encontrados nas turmas, podem ajudar a prever que alguns aspectos metodológicos a serem adotados podem ser mais úteis em relação aos outros.

Indivíduos, por exemplo, caracterizados com pouca Extroversão e Socialização, podem obter resultados satisfatórios em trabalhos individuais e/ou provas escritas; por outro lado, podem obter resultados insatisfatórios em apresentações de seminários e/ou trabalhos em equipes. Embora haja casos em que a maioria da turma apresente perfis similares, é papel dos docentes propiciar um aprendizado adequado a todos os alunos, mesmo que seja mais trabalhoso realizar adaptações para os mais diferenciados.

As três turmas do curso técnico em informática, de modo geral, apresentaram-se similares, mas é importante reforçar que analisar as características individuais dos alunos é muitas vezes interessante e necessário, principalmente visualizando os valores percentuais sem agrupá-los em intervalos. Com base nisso, o gráfico da Figura 2, com os cinco traços combinados por indivíduo, ilustra que os alunos apresentam-se diferentes. No eixo horizontal, têm-se a variação para os 49 estudantes. No eixo vertical, os valores indicam a porcentagem (de 0% a 100%) para cada traço, representado por símbolos/cores diferentes. Apesar de nesta experiência os percentuais não variarem com maior intensidade (por exemplo, os valores para Socialização e Realização são em geral baixos), são visíveis as variações em todo o eixo horizontal, indiciando e reforçando que cada aluno tem suas particularidades.



**Figura 2. Ilustração dos dados percentuais para cada fator do *Big Five* relativos a cada um dos 49 estudantes participantes desta pesquisa.**

## 6. Considerações Finais

A realização da experiência relatada neste artigo propiciou a visualização de perfis de alunos de três turmas em relação à personalidade, baseando-se na ferramenta Five Labs. A interação humana se faz necessária em diversas atividades. A personalidade de cada indivíduo influencia na interação com outros indivíduos e, portanto, pode impactar na realização de atividades no contexto escolar.

Uma vez que a personalidade influencia os relacionamentos aluno–professor e aluno–aluno, há consequentemente influência em aspectos educacionais como desempenho e evasão. Além disso, alguns pesquisadores, a exemplo de Kuri (2004), Zonash e Naqvi (2011) e Raju e Venugopal (2014), mostram resultados a respeito de correlações entre personalidade e teorias sobre os estilos de aprendizagem preferidos por cada aluno.

É importante que os docentes (e até mesmo instâncias mais abrangentes, como coordenadores de curso e direção escolar) reflitam a possibilidade de extrair os traços de personalidade dos alunos de suas turmas, no início das disciplinas, o que pode ser algo sistematicamente planejado e compartilhado com todos os docentes.

Ao identificarem determinados traços de personalidade a partir do uso de ferramentas (como o Five Labs e/ou outros meios, uma vez que há alunos que não usam

redes sociais), os professores poderiam indicar às coordenações ou outros responsáveis da escola a necessidade de atenção a determinados alunos, não objetivando discriminação, mas o cuidado, sugerindo em alguns casos aos pais/responsáveis o acompanhamento de alunos por psicólogos.

Além disso, as escolas que têm a presença de psicólogos em seu quadro de funcionários poderiam atribuir a estes a responsabilidade pelo diagnóstico e acompanhamento mais apropriado, verificando melhor os resultados prévios (obtidos pelos docentes por instrumentos de mensuração como o Five Labs), e analisando o impacto no aprendizado, no convívio social, e mesmo na formação cidadã, o que também é função da escola.

Além de pertinentes no contexto de como o aluno se relaciona com seus colegas e professores em sala de aula, os conceitos sobre os traços de personalidade podem ser empregados, por exemplo, na personalização de ambientes virtuais de ensino e aprendizagem, indispensáveis para cursos a distância e também empregados como apoio em cursos presenciais.

Por fim, mesmo os que desconheciam a Teoria do *Big Five* antes da leitura deste artigo, acredita-se que, neste ponto, com base nas características relativas a cada um dos traços comentadas na seção 2, é possível compreender a importância de detectar tais características dos alunos no espaço escolar, facilitando o convívio aluno–aluno e aluno–professor.

Almeja-se com este artigo motivar mais pesquisas sobre o uso de informações relativas à personalidade dos alunos no contexto educacional, realizando a detecção por meio da mineração de dados de perfis de usuários em redes sociais (como apresentado neste artigo) ou outros meios, como a aplicação dos tradicionais inventários de personalidade, que também podem ser aplicados com apoio das tecnologias de informação e comunicação.

## **Agradecimentos**

À Escola Técnica Redentorista de Campina Grande – PB, especialmente aos alunos que participaram desta pesquisa.

## **Referências**

- Allport, F. H.; Allport, G. W. (1921). Personality Traits: Their Classification And Measurement. *Journal Of Abnormal And Social Psychology*, 16, p. 6–40.
- Bachrach, Y.; Kosinski, M.; Graepel, T.; Kohli, P.; Stillwell, D. (2012). Personality and patterns of Facebook usage. In: *Proceedings of the 3rd Annual ACM Web Science Conference (WebSci '12)*, ACM, New York, NY, USA, p. 24–32.
- Burger, J. M. (2000). Personality. *Wadsworth*, fifth edition.
- Capretz, L. F.; Ahmed, F. (2010). Why Do We Need Personality Diversity in Software Engineering?. *ACM SIGSOFT Software Engineering Notes*, v. 35, n. 2, p. 1–11.
- Costa, P. T. Jr. ; Widiger, T. A. (2002). Introduction. In: Costa, P. T. Jr. ; Widiger, T. A (Org.), *Personality Disorders and the Five-Factor Model of Personality*, 2.ed., p.3-16. Washington, DC: American Psychological Association.
- Costa, P. T. Jr.; McCrae, R. R. (2007). NEO PI-R: Inventário de Personalidade NEO Revisado e Inventário de Cinco Fatores NEO Revisado NEO-FFI-R [versão curta]. São Paulo: Vetor Editora Psico-Pedagógica.

- Costa, P. T.; McCrae, R. R. (1992). Revised neo personality inventory (neo-pi-r) and neo five-factor inventory (neo-ffi). *Professional manual*.
- Cruz, S.; Da Silva, F.; Monteiro, C.; Santos, P.; Rossilei, I. (2011). Personality in Software Engineering: preliminar findings from a systematic literature review. In: *Proceedings of 15th Annual Conference on Evaluation & Assessment in Software Engineering (EASE 2011)*, p. 1–10.
- Farias, A. B.; Dobrões, J. A. L.; Da Silva, R. Y. F. (2013). Strategies for Teaching Based on Academic Personality Types. In: *XVIII Conferência Internacional sobre Informática na Educação (TISE)*, Porto Alegre-RS, p. 633–636.
- Five. (2015). Five Labs — See the personality behind your posts. *Product of Five.com*. Disponível em: <<http://labs.five.com/>>. Acesso em: 24 abr. 2015.
- John, O. P.; Srivastava, S. (1999). The Big Five Trait taxonomy: History, measurement, and theoretical perspectives. In: Pervin, L. A.; John, O. P. (Org.), *Handbook of Personality: Theory and research*, v. 2, p. 102–138. Guilford Press, New York.
- Johnson, J. A. (2000). Web-based personality assessment. In *71st Annual Meeting of the Eastern Psychological Association*, USA.
- Kuri, N. P. (2004). Tipos de personalidade e estilos de aprendizagem: proposições para o ensino de engenharia. 2004. Tese (Doutorado em Engenharia de Produção), Universidade Federal de São Carlos, São Carlos.
- Mairesse, F.; Walker, M. A.; Mehl, M.; Moore, R. (2007). Using Linguistic Cues for the Automatic Recognition of Personality in Conversation and Text. *Journal of Artificial Intelligence Research*, p. 457–500.
- Markovikj, D.; Gievska, S.; Kosinski, M.; Stillwell, D. (2013). Mining Facebook Data for Predictive Personality Modeling. *Proc of Workshop on Computational Personality Recognition*, AAAI Press, Melon Park, CA.
- Nunes, C. H. S. S.; Hutz, C. S.; Nunes, M. F. O. (2010). Bateria Fatorial de Personalidade. *Manual Técnico*. São Paulo: Casa do Psicólogo.
- Nunes, M. A. S. N. (2012). Computação Afetiva personalizando interfaces, interações e recomendações de produtos, serviços e pessoas em Ambientes computacionais. In: Nunes, M. A. S. N.; Oliveira, A. A.; Ordonez, E. D. M. (Org.). *Projetos e Pesquisas em Ciência da Computação no DCOMP/PROCC/UFS*: São Cristóvão, p. 115–151.
- Paixão, C. C.; Fortaleza, L. L.; Conte, T. (2012). Um Estudo Preliminar sobre as Implicações de Tipos de Personalidade no Ensino de Computação. In: *Anais do XXXII Congresso da Sociedade Brasileira de Computação (CSBC) — XX Workshop sobre Educação em Informática (WEI)*, Curitiba-PR.
- Paixão, C. C.; Fortaleza, L. L.; Conte, T. (2013). Desafios no Ensino de Computação: um estudo da relação entre perfil psicológico de alunos e evasão. In: *Anais do XXXIII Congresso da Sociedade Brasileira de Computação (CSBC) — XXI Workshop sobre Educação em Informática (WEI)*, Maceió-AL, p. 720–729.
- Rabelo, I. S. (2013). Investigação de traços de personalidade em atletas brasileiros: análise da adequação de uma ferramenta de avaliação psicológica. 2013. Tese (Doutorado em Pedagogia do Movimento Humano) — Escola de Educação Física e Esporte, Universidade de São Paulo, São Paulo.
- Raju, P. G.; Venugopal, M. (2014). Personality & learning styles — lessons for Indian corporate trainers. *Indian Journal of Industrial Relations*, 49(4).
- Schwartz, H. A.; Eichstaedt, J. C.; Kern, M. L.; Dziurzynski, L.; Ramones, S. M.; Agrawal, M.; Shah, A.; Kosinski, M.; Stillwell, D.; Seligman, M. E. P.; Ungar, L. H. (2013). Personality, Gender, and Age in the Language of Social Media: The Open-Vocabulary Approach. *PLoS ONE*, 8(9), e73791.
- Tausczik, Y. R.; Pennebaker, J. W. (2009). The Psychological Meaning of Words: LIWC and Computerized Text Analysis Methods. *Journal of Language and Social Psychology*, 29(1), p.24–54.
- Zonash, R.; Naqvi, I. (2011). Personality Traits and Learning Styles among Students of Mathematics, Architecture, and Fine Arts. *Journal of Behavioral science*, v. 21, p. 92–108.

# Avaliação de Sistemas de Recomendação Educacionais no Brasil: uma revisão sistemática da literatura

Janderson J. B. Aguiar<sup>1</sup>, Savyo I. N. Santos<sup>1</sup>, Joseana M. Fechine<sup>1</sup>, Evandro B. Costa<sup>2</sup>

<sup>1</sup> Universidade Federal de Campina Grande (UFCG), Campina Grande – PB – Brasil

<sup>2</sup> Universidade Federal de Alagoas (UFAL), Maceió – AL – Brasil

{janderson,savyo}@copin.ufcg.edu.br, joseana@dsc.ufcg.edu.br, evandro@ic.ufal.br

**Abstract.** *In this paper, the authors describe a Systematic Review about Recommender Systems in Education (RSE) focused on the evaluation form used, considering the primary studies published in five Brazilian scientific publication vehicles highest rated by Qualis/CAPES. Besides the evaluation form, the data indicated the historical evolution of these publications, the institutions involved, the metrics most used, and others. With this review, the authors aims that educators and researchers may have easier access to Brazilian initiatives that propose and evaluate in RSE.*

**Resumo.** *Neste artigo, é descrita uma Revisão Sistemática de Sistemas de Recomendação Educacionais (SRE) com foco na forma de avaliação empregada, considerando os estudos primários divulgados nos cinco veículos brasileiros de publicação científica melhor classificados pelo Qualis/CAPES. Além da forma de avaliação, os dados obtidos indicaram a evolução histórica dessas publicações, as instituições envolvidas, as métricas mais utilizadas, entre outros aspectos. Com esta revisão, espera-se que os educadores e pesquisadores possam ter acesso facilitado às iniciativas que propõem e avaliam SRE no Brasil.*

## 1. Introdução

Os Sistemas de Recomendação (SR) surgiram com o objetivo de auxiliar os usuários a acessarem informações relevantes em meio ao crescente número de informações disponíveis [Bobadilla *et al.* 2013]. No âmbito educacional, é possível ter SR específicos para filtrar recursos contemplando os perfis individuais dos alunos, professores e/ou outros agentes envolvidos na educação, sendo possível a utilização do termo Sistemas de Recomendação Educacionais (SRE) para os SR voltados, de maneira geral, ao processo de ensino e aprendizagem.

Para avaliar SR, em essência, deve-se verificar a satisfação do usuário, pois o interesse está em perceber o grau de aceitação das recomendações — o número de vezes que os usuários aceitam ou rejeitam itens recomendados [Dos Reis 2012]. Adomavicius e Tuzhilin (2005) afirmam que a acurácia dos SR pode ser medida de forma estatística ou por suporte à decisão. Enquanto as métricas estatísticas comparam as avaliações estimadas com as avaliações reais dos usuários, as métricas de suporte à decisão determinam quão bem um SR pode prever itens que seriam bem classificados pelo usuário [Medeiros 2013].

Dentre as métricas estatísticas mais utilizadas, é possível citar o RMSE (*Root Mean Square Error* — Raiz do Erro Médio Quadrático) e o MAE (*Mean Absolute Error* — Erro Médio Absoluto). Dentre as métricas de suporte à decisão, destaca-se o uso da

Medida F (*F-Measure*), Precisão (*Precision*) e Cobertura (*Recall*). O detalhamento destas e de outras métricas pode ser encontrado no trabalho de Herlocker *et al.* (2004).

Como defendem Costa, Aguiar e Magalhães (2013), um aspecto que difere bastante os SRE, em relação a outros SR, é a forma de avaliá-los, faltando conjuntos de dados de referência e havendo pouca padronização dos procedimentos de avaliação. Além disso, em se tratando de SRE, há várias dimensões de avaliação possíveis, como a consideração de questões pedagógicas [Manouselis *et al.* 2012].

No Brasil, o número de iniciativas em SRE tem crescido nos últimos anos [Aguiar *et al.* 2014]. Além desse crescimento, percebe-se, a partir do que foi exposto anteriormente, que é desafiador e importante avaliar os SRE propostos. Sentiu-se, com isso, a necessidade de organizar uma Revisão Sistemática (RS) da literatura com o objetivo de identificar e analisar o modo como estão sendo avaliados os SRE publicados no Brasil.

O restante do artigo está estruturado da seguinte forma: na Seção 2, são comentados estudos relacionados; na Seção 3, é descrito o método empregado nesta RS; na Seção 4, são mostrados e analisados os resultados; e, na Seção 5, são apresentadas as considerações finais.

## **2. Estudos Relacionados**

Em relação a estudos relacionados, Chughtai, Selama e Ghani (2013) publicaram uma RS no âmbito de SRE — considerando estas máquinas de busca: IEEE, ELSEVIER, SCIRUS, IDOSI, AJET, ICVL e SPRINGER — a fim de discutir as abordagens de filtragem da informação utilizadas nos SRE, além dos seus benefícios, limitações e problemas. Este trabalho não dá enfoque na avaliação dos modelos propostos, e, pelas máquinas de busca consideradas, não abrange muitas iniciativas brasileiras.

Com enfoque em veículos brasileiros de publicação científica, há algumas RS realizadas — a exemplo de [Pietruchinski *et al.* 2011], [Aureliano e Tedesco 2012] e [De Araújo, De Brito e Da Silva 2013], que revisaram, no contexto de eventos em Informática na Educação (IE), pesquisas sobre, respectivamente, jogos educativos, ensino-aprendizagem de programação e softwares para educação inclusiva.

Recentemente, foram realizados dois estudos secundários relativos à recomendação no contexto educacional [Aguiar *et al.* 2014; Pontes *et al.* 2014]. Aguiar *et al.* (2014) mapearam iniciativas nacionais em SRE, indicando sua evolução histórica, as instituições envolvidas, as técnicas de recomendação mais utilizadas, os principais recursos recomendados, entre outros aspectos. Pontes *et al.* (2014) revisaram as publicações sobre as filtragens de recomendação de objetos de aprendizagem.

Nenhum desses estudos, entretanto, comentou aspectos relacionados às estratégias de avaliação adotadas pelos SRE propostos nesses artigos, o que consiste no foco da RS descrita neste artigo.

## **3. Método**

De acordo com Kitchenham (2004), a Revisão Sistemática é um método utilizado para a realização de revisões bibliográficas de forma organizada, com etapas bem definidas, proporcionando maior fundamentação e credibilidade científica. Nesse método, a definição dos objetivos gerais e secundários, além das questões de pesquisa, é

extremamente importante para o estabelecimento do enfoque de interesse do estudo, uma vez que os objetivos norteiam a RS e as respostas às questões ajudam a obter conclusões e análises específicas em relação ao problema considerado. Além desses pontos, é necessário determinar, no início da pesquisa, critérios de inclusão e exclusão para selecionar os artigos. O conjunto das questões e dos critérios é denominado protocolo de pesquisa [Kitchenham 2004].

Segundo Barros *et al.* (2008), uma RS tem as seguintes etapas: (1) coleta das publicações potencialmente relevantes sobre a questão analisada, sendo usualmente realizada uma busca em serviços de indexação de publicações em uma determinada área; (2) seleção dentre as publicações coletadas daquelas que satisfazem a um critério de elegibilidade especificado por meio da leitura dos resumos e dos artigos, podendo ser executada em diferentes subetapas, cada vez mais seletivas, e também podendo ser as leituras realizadas por duas ou mais pessoas independentemente, como maneira de se chegar a um consenso na análise; (3) síntese das variações entre os artigos selecionados na etapa anterior, resumindo os resultados desses artigos geralmente em tabelas; (4) opcionalmente, agregação dos resultados individuais de cada publicação em um resultado único, podendo envolver técnicas estatísticas complexas e, por isso, esta fase nem sempre é executada.

A RS descrita neste artigo foi realizada com base no Mapeamento Sistemático (MS) executado por Aguiar *et al.* (2014). Petticrew e Roberts (2006) afirmam que um MS — também definido como uma pesquisa da literatura — pode identificar quais tipos de estudos podem ser abordados por uma RS. Enquanto o MS possibilita uma visão mais ampla dos estudos primários — com questões de pesquisa mais abrangentes e que podem ser de natureza exploratória e descritiva —, a RS possui questões de pesquisas mais definidas, focadas em um ponto específico da área de estudo [Kitchenham e Charters 2007]. Nesse sentido, o MS realizado por Aguiar *et al.* (2014) despertou a necessidade desta RS com enfoque na avaliação de SRE.

### 3.1. Objetivos Gerais e Específicos

A partir do questionamento central do MS de Aguiar *et al.* (2014), cujo interesse era saber como os SR estão sendo construídos/utilizados, no Brasil, para apoiar o processo de ensino e aprendizagem, os autores perceberam a necessidade de saber como esses SRE estão sendo avaliados. Considerando o método de RS, foram inicialmente definidos os objetivos gerais e específicos (listados no Quadro 1) para nortear a revisão e servir de base para a construção das questões de pesquisa.

**Quadro 1. Objetivos gerais e específicos da RS**

Objetivos Gerais	Objetivos Específicos
Analisar a evolução histórica das publicações contemplando avaliação dos SRE nos eventos e periódicos brasileiros sobre IE.	Identificar as instituições de ensino que mais publicaram estudos primários, com detalhes relativos à avaliação dos SRE propostos, nos veículos brasileiros sobre IE.
Averiguar de que forma é feita a avaliação dos estudos primários sobre SRE nos eventos e periódicos brasileiros sobre IE.	Pesquisar os trabalhos científicos sobre SRE e identificar suas considerações sobre a avaliação do SRE proposto.
	Analisar características da avaliação do SRE proposto, como, por exemplo, as métricas mais utilizadas.

### 3.2. Questões de Pesquisa

Com base nos objetivos apresentados no Quadro 1, foram definidas as seguintes questões de pesquisa para esta RS:

1. Como se deu a evolução histórica das publicações que propõem e avaliam SRE nos eventos e periódicos brasileiros sobre IE?
2. Quais são as instituições que mais publicaram estudos primários que propõem e avaliam SRE nos veículos brasileiros de publicação científica sobre IE?
3. De que forma se deu a avaliação dos SRE propostos nessas pesquisas?
4. Qual(is) a(s) métrica(s) mais utilizada(s) nas avaliações dos SRE no Brasil?

### 3.3. Fontes de Busca

Considerando as questões de pesquisa definidas na subseção 3.2, e seguindo aspectos do protocolo definido por Aguiar *et al.* (2014), as fontes de busca utilizadas foram os eventos e periódicos do Brasil voltados para a educação e informática/novas tecnologias, com estrato pelo menos B5 na área de avaliação “Ciência da Computação” da classificação Qualis da CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior). São eles: Informática na Educação: Teoria & Prática (InfEducTeoriaPratica), Revista Brasileira de Informática na Educação (RBIE), Revista Novas Tecnologias na Educação (RENOTE), Simpósio Brasileiro de Informática na Educação (SBIE) e Workshop de Informática na Escola (WIE).

### 3.4. String de Busca

A *string* de busca definida no protocolo do MS de Aguiar *et al.* (2014), e utilizada nesta RS, foi *recom\**, por ser um radical presente nas 4 línguas que os veículos de busca utilizados contemplam e, além disso, por ser um termo abrangente, evitando perda de possíveis resultados importantes caso se fizesse uma busca mais restrita.

### 3.5. Critérios de Seleção

Os Critérios de Inclusão para a seleção dos artigos desta RS foram:

- A *string* de busca deve estar presente em qualquer parte dos artigos;
- Os artigos devem ser escritos em inglês, português, espanhol ou francês (idiomas aceitos em pelo menos uma das fontes de busca consideradas);
- A versão completa dos artigos deve estar disponível on-line (considerando esse aspecto, o período de tempo dos artigos publicados variou em relação à fonte de busca — InfEducTeoriaPratica: 1991 a 2014; RBIE: 1997 a 2014; RENOTE: 2003 a 2014; SBIE: 2001 a 2014; WIE: 2003 e 2005 a 2014);
- Os artigos devem tratar sobre recomendação de recursos educacionais, sendo esta funcionalidade o enfoque, ou pelo menos parte em destaque, dos artigos publicados;
- Os artigos devem descrever como a funcionalidade de recomendação do SRE abordado foi avaliada.

Nesse sentido, os Critérios de Exclusão consistiram naturalmente no complemento ou negação dos Critérios de Inclusão. Mas, além disso, foram excluídos artigos que se enquadravam em pelo menos um destes casos:

- Artigos publicados posteriormente em outro veículo considerado na RS;

- Iniciativas estrangeiras;
- Documentos retornados na busca que não são estudos primários publicados no evento/periódico;
- *Short papers* (até 5 páginas) ou *Full Papers* com explicação superficial do processo de avaliação (ou seja, com falta de detalhes para responder às questões de pesquisas desta revisão).

#### 4. Análise dos Resultados

Utilizando a string mencionada na subseção 3.4 para buscar estudos primários nas 5 fontes definidas na subseção 3.3, foram retornados inicialmente 361 artigos. Após a triagem inicial (estratégia de exclusão a partir do título, resumo e leitura do artigo usando a técnica scanning), foram selecionados 51 artigos para uma leitura detalhada.

Após a análise minuciosa dos artigos pelos autores, aplicando os critérios de inclusão e exclusão definidos na subseção 3.5, foram selecionados 26 artigos que tratavam de SRE no Brasil, contemplando detalhes de avaliação em sua publicação.

No Quadro 2, são apresentados, por fonte de busca, os resultados por etapa de seleção dos artigos.

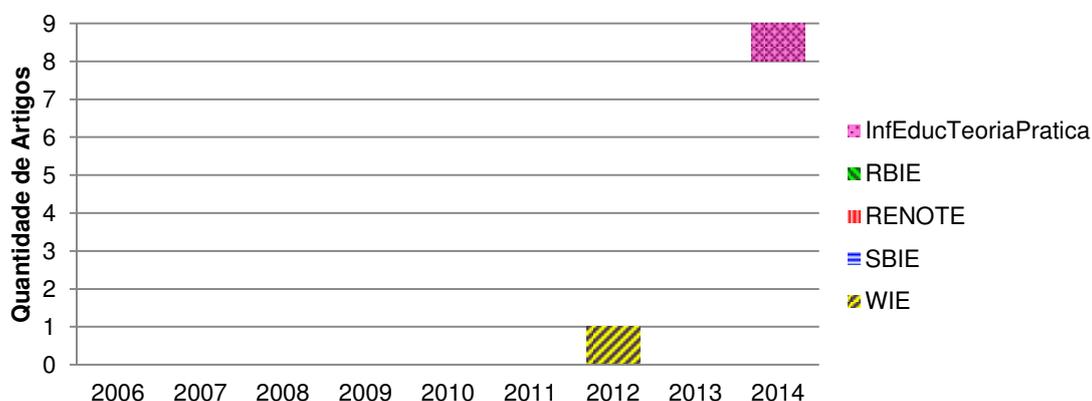
**Quadro 2. Quantidade de artigos resultantes por etapa e fonte de busca**

Fontes de busca	Etapa 1: Retorno Inicial	Etapa 2: Triagem Inicial	Etapa 3: Resultado Final
InfEducTeoriaPratica	55	3	1
RBIE	14	6	5
RENOTE	226	13	6
SBIE	59	28	13
WIE	7	1	1
<b>TOTAL</b>	<b>361</b>	<b>51</b>	<b>26</b>

Os 26 artigos considerados nesta RS encontram-se listados no Quadro 3. As respostas às questões de pesquisa encontram-se nas seguintes subseções.

##### 4.1. Evolução histórica das publicações

A evolução histórica das publicações que propõem e avaliam SRE em veículos brasileiros de publicação sobre IE é mostrada na Figura 1.



**Figura 1. Evolução das Pesquisas por Ano e Fonte de Busca**

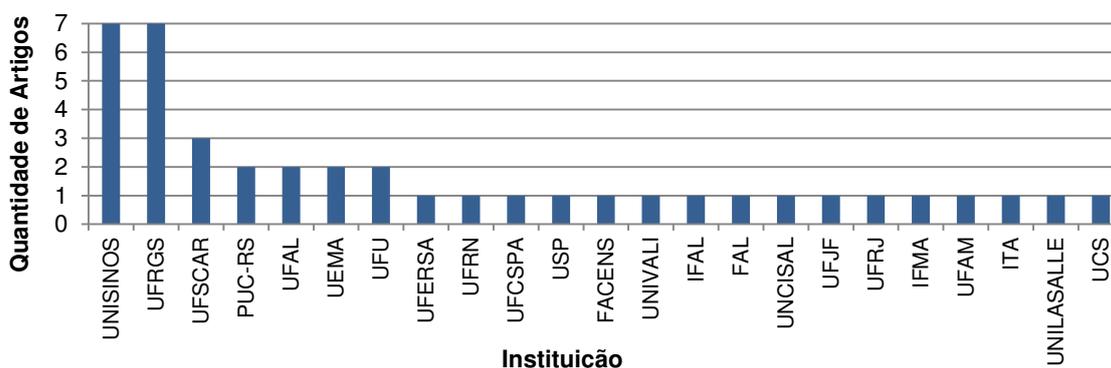
**Quadro 3. Resultado final da RS**

Título do Artigo	Hiperlink
Conhecendo o usuário através de enriquecimento semântico para apoio à aprendizagem informal em saúde	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/2956/2691">http://www.br- ie.org/pub/index.php/sbie/article/view/2956/2691</a>
Desenvolvendo um Sistema de Recomendação de Objetos de Aprendizagem baseado em Competências para a Educação: relato de experiências	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/1710">http://www.br- ie.org/pub/index.php/sbie/article/view/1710</a>
E-BIACS: Um Sistema para a Construção de Ambientes Virtuais para Aprendizagem Baseada em Problemas	<a href="http://www.seer.ufrgs.br/index.php/renote/article/view/49832/31190">http://www.seer.ufrgs.br/index.php/renote/article/view/ 49832/31190</a>
e-LORS: Uma Abordagem para Recomendação de Objetos de Aprendizagem	<a href="http://www.br-ie.org/pub/index.php/rbie/article/view/1289">http://www.br- ie.org/pub/index.php/rbie/article/view/1289</a>
LORSys – Um Sistema de Recomendação de Objetos de Aprendizagem SCORM	<a href="http://seer.ufrgs.br/index.php/renote/article/view/15223">http://seer.ufrgs.br/index.php/renote/article/view/15223</a>
O Uso de Técnicas de Recomendação em um Sistema para Apoio à Aprendizagem Colaborativa	<a href="http://www.br-ie.org/pub/index.php/rbie/article/view/46">http://www.br-ie.org/pub/index.php/rbie/article/view/46</a>
Podes me ajudar? Apoiando a formação de pares em sistemas de ajuda em pares através de técnicas de recomendação	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/2565">http://www.br- ie.org/pub/index.php/sbie/article/view/2565</a>
Predição do Desempenho do Aluno usando Sistemas de Recomendação e Acoplamento de Classificadores	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/2544">http://www.br- ie.org/pub/index.php/sbie/article/view/2544</a>
Recomendação assistida por computador de materiais didáticos em ambientes virtuais de aprendizagem	<a href="http://seer.ufrgs.br/index.php/InfEducTeoriaPratica/article/view/40301/29979">http://seer.ufrgs.br/index.php/InfEducTeoriaPratica/arti cle/view/40301/29979</a>
Recomendação Colaborativa de Conteúdos Educacionais para Dispositivos Portáteis	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/3031/2542">http://www.br- ie.org/pub/index.php/sbie/article/view/3031/2542</a>
Recomendação de Jogos na Aprendizagem da Matemática baseado na Análise Diagnóstica e Teoria de Resposta ao Item	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/3032/2543">http://www.br- ie.org/pub/index.php/sbie/article/view/3032/2543</a>
Recomendação de Objetos de Aprendizagem Empregando Filtragem Colaborativa e Competências	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/1158">http://www.br- ie.org/pub/index.php/sbie/article/view/1158</a>
Recomendando Objetos de Aprendizagem a partir das hashtags postadas no Moodle	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/2486">http://www.br- ie.org/pub/index.php/sbie/article/view/2486</a>
Relato de uma Experiência de Auxílio Personalizado a Alunos em Ambiente Virtual de Aprendizagem Utilizando Agentes	<a href="http://www.br-ie.org/pub/index.php/wie/article/view/2122">http://www.br- ie.org/pub/index.php/wie/article/view/2122</a>
Sistema de Recomendação Acadêmico para Apoio a Aprendizagem	<a href="http://seer.ufrgs.br/index.php/renote/article/view/14236">http://seer.ufrgs.br/index.php/renote/article/view/14236</a>
Sistema de Recomendação de Links para o fomento de discussões em fóruns de um Ambiente Virtual de Aprendizagem	<a href="http://www.seer.ufrgs.br/index.php/renote/article/view/53547/33050">http://www.seer.ufrgs.br/index.php/renote/article/view/ 53547/33050</a>
Sistema de Recomendação Híbrido para Bibliotecas Digitais que Suportam o Protocolo OAI-PMH	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/1584">http://www.br- ie.org/pub/index.php/sbie/article/view/1584</a>
Técnica de Recomendação Baseada em Metadados para Repositórios Digitais Voltados ao Ensino	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/2546">http://www.br- ie.org/pub/index.php/sbie/article/view/2546</a>
Um Agente Animado para Ambientes de Aprendizagem Colaborativos	<a href="http://www.br-ie.org/pub/index.php/rbie/article/view/27">http://www.br-ie.org/pub/index.php/rbie/article/view/27</a>
Um Modelo de Recomendação Ubíqua de Conteúdo para Grupos de Aprendizes	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/2548">http://www.br- ie.org/pub/index.php/sbie/article/view/2548</a>
Um Modelo Multiagente para Recomendação de Conteúdo Educacional em um Ambiente Ubíquo	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/1782">http://www.br- ie.org/pub/index.php/sbie/article/view/1782</a>
Um Modelo para Recomendação de Artigos Acadêmicos Baseado em Filtragem Colaborativa Aplicado à Ambientes Móveis	<a href="http://seer.ufrgs.br/index.php/renote/article/view/14458">http://seer.ufrgs.br/index.php/renote/article/view/14458</a>
Um Modelo para Recomendação de Objetos de Aprendizagem Utilizando Similaridade de Sessões	<a href="http://www.br-ie.org/pub/index.php/rbie/article/view/2849/2834">http://www.br- ie.org/pub/index.php/rbie/article/view/2849/2834</a>
Um Serviço para Recomendação de Artigos Científicos Baseado em Filtragem de Conteúdo Aplicado a Dispositivos Móveis	<a href="http://seer.ufrgs.br/index.php/renote/article/view/18057">http://seer.ufrgs.br/index.php/renote/article/view/18057</a>
Uma Abordagem Automática para Personalização do Processo de Ensino Baseada em Estilos de Aprendizagem em Sistemas Adaptativos e Inteligentes para Educação a Distância	<a href="http://www.br-ie.org/pub/index.php/rbie/article/view/2374/2724">http://www.br- ie.org/pub/index.php/rbie/article/view/2374/2724</a>
Uma Abordagem para Recomendação Automática e Dinâmica de Objetos de Aprendizagem Baseada em Estilos de Aprendizagem	<a href="http://www.br-ie.org/pub/index.php/sbie/article/view/3065/2573">http://www.br- ie.org/pub/index.php/sbie/article/view/3065/2573</a>

É visto, a partir da Figura 1, que a maior parte das publicações, sobretudo nos três últimos anos, ocorreram no SBIE, considerado o evento mais importante na área de IE no Brasil. Além disso, percebe-se, com o passar dos anos, um crescimento no número de publicações sobre SRE, em eventos e periódicos brasileiros sobre IE, e que destacam a fase de avaliação do SRE proposto.

#### 4.2. Instituições que mais publicaram artigos

As instituições que publicaram trabalhos científicos com propostas e avaliações de SRE, nos veículos brasileiros de publicação sobre IE consideradas nesta revisão, são apresentadas na Figura 2.



**Figura 2. Quantidade de Publicações por Instituição**

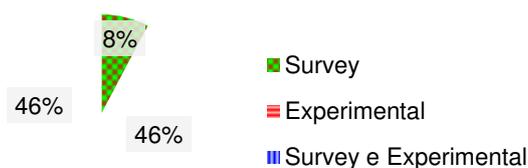
Como indicado no gráfico, as instituições que se destacaram foram a UNISINOS e a UFRGS. É importante mencionar que 38% das publicações adviram de parcerias entre instituições distintas e geralmente do mesmo estado — IFAL, UFAL, UNCISAL e FAL; IFMA e UEMA; UFRSA e UFRN; UFRGS e PUC-RS; UFRGS e UCS; UNISINOS e UFRGS; UNISINOS e UFRGS; UNISINOS, UFCSPA e UFRGS; USP, UFSCAR e FACENS. Além dessas, houve uma parceria entre UNILASALLE, UFRGS (ambas do Rio Grande do Sul) e ITA (estado de São Paulo).

Observou-se, portanto, que a região do país que abrange mais publicações nessa linha de pesquisa, preocupando-se com a avaliação dos SRE, é a região Sul, seguida das regiões Sudeste, Nordeste e Norte.

#### 4.3. Tipo de avaliação realizada

Em relação ao modo como foi realizada a avaliação dos SRE abordados nos estudos selecionados nesta RS, percebeu-se que é feito uso de estratégias empíricas e, portanto, os artigos foram categorizados em: (i) Experimento — controlados ou observacionais (estudos de caso); e/ou (ii) *Survey* — utilização de entrevistas/questionários dependendo da memória e opinião dos participantes. A distribuição dos artigos nessas categorias é apresentada na Figura 3.

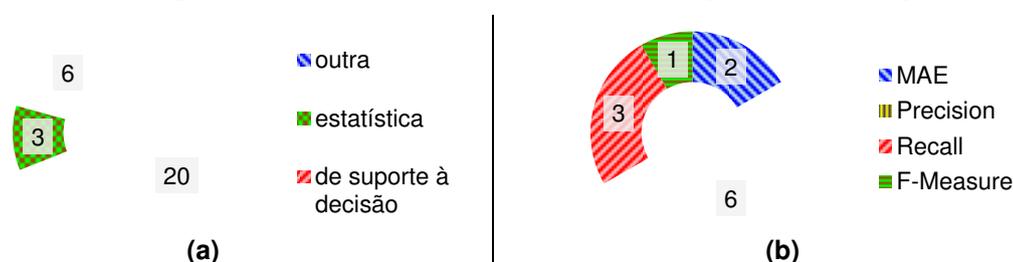
Além de experimentos controlados, foi percebida a realização de muitos estudos de caso (também denominados experimentos observacionais) e, especialmente em relação a estes, o uso frequente de questionários para avaliar o SRE proposto. Apesar de considerarem essa estratégia de avaliação, há artigos que não descrevem bem o conteúdo desses questionários, dificultando a clareza dos aspectos avaliados e identificação de métricas empregadas, o que impactou negativamente na objetividade da resposta para a quarta questão de pesquisa (subseção 3.2).



**Figura 3. Distribuição das pesquisas em relação ao modo de avaliação**

#### 4.4. Métricas mais utilizadas nas avaliações

Em se tratando das métricas utilizadas nas avaliações das iniciativas brasileiras em SRE no Brasil, com base no exposto na seção 1, os artigos foram categorizados inicialmente pelo tipo de métrica: (i) Estatística; (ii) De suporte à decisão, e (iii) Outra — esta categoria foi pensada como estratégia para especialmente os casos de artigos que utilizaram *survey* como estratégia empírica, devido à dificuldade mencionada na subseção 4.3. Na figura 4a é mostrada a distribuição dos artigos nessas categorias.



**Figura 4. Distribuição das pesquisas com relação a: (a) tipo de métricas; (b) métricas populares estatísticas e/ou de suporte à decisão**

Apesar do gráfico da Figura 4a totalizar 29 artigos, em vez de 26, é importante comentar que dois artigos utilizaram concomitantemente métricas estatísticas e de suporte à decisão, além de outro artigo utilizar métricas de suporte à decisão e outra.

A partir disso, foi gerado um gráfico (Figura 4b) para analisar o uso das métricas estatísticas e/ou de suporte à decisão mais amplamente utilizadas na avaliação de SR (conforme comentado na seção 1). Verificou-se portanto que, dentre elas, a métrica Precisão (*Precision*) foi a mais utilizada.

Analisando a Figura 4, constata-se, como defendido por alguns autores [Costa, Aguiar e Magalhães 2013] [Manouselis *et al.* 2012], a falta de padronização no modo de avaliar SRE, especialmente devido a aspectos importantes no âmbito educacional, como a avaliação da interface, destacada em alguns trabalhos.

Devido à limitação do tamanho deste artigo, não foi possível explicar uma análise mais metódica dos resultados, como, por exemplo, uma discussão relativa à qualidade dos artigos retornados. Em contrapartida, neste hiperlink <http://goo.gl/IINp4u> encontram-se detalhes relativos a cada um dos 26 trabalhos — o usuário-alvo da recomendação, o recurso educacional recomendado, as técnicas de recomendação empregadas, as métricas de avaliação, entre outras informações.

## 5. Considerações Finais

A RS descrita neste artigo permitiu elencar e analisar as iniciativas em SRE, sob o aspecto da avaliação empregada, considerando as publicações dos eventos e periódicos brasileiros mais importantes na área de IE e Novas Tecnologias.

Com esta revisão, foi constatado que os estudos utilizaram, em sua maioria, uma estratégia empírica experimental, mas que combinaram muitas vezes com a estratégia de *survey*. Os autores acreditam que, mesmo havendo aspectos mais subjetivos e específicos no âmbito educacional, geralmente captados via opinião dos usuários em *surveys*, é importante que as informações via questionários (ou meios afins) sejam sempre disponibilizadas com clareza nas publicações. Além disso, os autores deste artigo defendem que, por se tratar de um SR, é sempre interessante empregar também métricas conhecidas de suporte à decisão e/ou estatísticas.

Drachsler *et al.* (2015) defendem que as pesquisas sobre SRE deveriam seguir um método de avaliação padronizado, como estes quatro passos sugeridos por Manouselis *et al.* (2012): (i) uma seleção de conjuntos de dados que se adequam ao problema de recomendação e às tarefas do desenvolvimento; (ii) um estudo de comparação off-line de diferentes algoritmos em relação aos conjuntos de dados selecionados, incluindo conjuntos de dados conhecidos para fornecer *insights* sobre o desempenho dos algoritmos de recomendação; (iii) um estudo abrangente do usuário em um ambiente experimental controlado para testar os efeitos psico-educativos em relação aos alunos, bem como testar os aspectos técnicos do SR projetado; e (iv) a implantação do SR em uma aplicação real, na qual possa ser testado em condições operacionais realistas/normais com seus usuários legítimos. Além disso, Drachsler *et al.* (2015) comentam que é importante que esses quatro passos sejam publicados junto com uma descrição completa do SR, sendo declarado e acessível ao público o conjunto de dados utilizado, permitindo que outros pesquisadores repitam e ajustem qualquer parte da pesquisa para obter resultados comparáveis e novos *insights*.

De maneira geral, conclui-se que os estudos primários retornados nesta RS podem servir como referência para a criação de novos SRE, possibilitando aos pesquisadores e educadores — por meio dos resultados e do acesso facilitado aos artigos — conhecer as iniciativas que propõem e avaliam sistemas com estratégias de recomendação de recursos educacionais no Brasil.

Ressalta-se que, por considerar apenas as fontes de busca definidas na subseção 3.3, esta RS possui uma limitação em relação à abrangência de trabalhos primários considerados, uma vez que podem haver iniciativas brasileiras importantes que avaliaram SRE em outras fontes de busca. Todavia, decidiu-se manter aspectos do protocolo de pesquisa empregado anteriormente [Aguiar *et al.* 2014], focando na questão de avaliação, dado que assim seria (e foi) possível vislumbrar as avaliações em SRE de trabalhos publicados nos eventos e periódicos brasileiros mais importantes em IE.

Em relação a esse aspecto, vale destacar que, para as edições de 2015 do SBIE e do WIE, foi adotada pela Organização Geral e pelo Comitê Científico a estratégia de publicar artigos completos de apenas estudos primários que apresentem explicitamente metodologia e análise de resultados. Com isso, acredita-se que os pesquisadores que pretendem publicar seus modelos de SRE nesses eventos, bastante importantes na área de IE, irão se preocupar mais fortemente em realizar e explicar nos artigos uma avaliação detalhada de suas pesquisas.

Sobre trabalhos futuros, os autores estão utilizando os resultados desta RS como parte do embasamento teórico para planejar a avaliação de alguns modelos de SRE a serem posteriormente publicados.

## Referências Bibliográficas

- Adomavicius, G. e Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *Knowledge and Data Engineering, IEEE Transactions on*, v. 17, n. 6, p. 734–749.
- Aguiar, J. J. B., Santos, S. I. N., Fechine, J. M. e Costa, E. B. (2014). Um Mapeamento Sistemático sobre Iniciativas Brasileiras em Sistemas de Recomendação Educacionais. In: *XXV Simpósio Brasileiro de Informática na Educação (SBIE)*, p. 1123–1132.
- Aureliano, V. C. O. e Tedesco, P. C. A. R. (2012). Ensino-aprendizagem de Programação para Iniciantes: uma Revisão Sistemática da Literatura focada no SBIE e WIE. In: *Anais do 23º Simpósio Brasileiro de Informática na Educação (SBIE)*, Rio de Janeiro.
- Barros, A. C., Wainer, J., Claudio, K., Ferreira, L. R. R. e Dwyer, T. (2008). Uso de Computadores no Ensino Fundamental e Médio e Seus Resultados Empíricos: Uma Revisão Sistemática da Literatura. In: *Revista Brasileira de Informática na Educação (RBIE)*, v. 16, n. 1, p. 57–68.
- Bobadilla, J., Ortega, F., Hernando, A. e Gutiérrez, A. (2013). Recommender systems survey. In: *Knowledge Based Systems*, v. 46, p. 109–132.
- Chughtai, W. M., Selama, A. B. e Ghani, I. (2013) Short Systematic Review on E-Learning Recommender Systems. In: *Journal of Theoretical and Applied Information Technology*, v. 57, n. 2.
- Costa, E., Aguiar, J. e Magalhães, J. (2013). Sistemas de Recomendação de Recursos Educacionais: conceitos, técnicas e aplicações. In: *II Congresso Brasileiro de Informática na Educação — Jornada de Atualização em Informática na Educação (JAIE)*, p. 57–78.
- De Araújo, A. L. S. O., De Brito, R. R. e Da Silva, A. P. (2013). Softwares para Educação Inclusiva: Uma Revisão Sistemática no Contexto de SBIE e WIE. *Anais do 24º Simpósio Brasileiro de Informática na Educação (SBIE)*, Campinas, São Paulo.
- Dos Reis, L. F. M. (2012). Sistema de Recomendação Baseado em Conhecimento. 110 f. Dissertação (Mestrado em Engenharia Informática) — Faculdade de Ciências e Tecnologia, Universidade de Coimbra, Coimbra.
- Drachsler, H., Verbert, K., Santos, O. C. e Manouselis, N. (2015). Panorama of recommender systems to support learning. *Handbook on recommender systems*. (no prelo). Disponível em: <[https://lirias.kuleuven.be/bitstream/123456789/476545/1/TEL\\_RecSys.pdf](https://lirias.kuleuven.be/bitstream/123456789/476545/1/TEL_RecSys.pdf)>. Acesso em 29/05/2015.
- Herlocker, J. L., Konstan, J. A., Riedl, J. T. e Terveen, L. G. (2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems* 22(1), p. 5–53.
- Kitchenham, B. (2004). Procedures for performing systematic reviews. Relatório Técnico, Keele University and NICTA.
- Kitchenham, B. e Charters, S. (2007). Guidelines for performing Systematic Literature Reviews in Software Engineering. Keele University and Durham University Joint Report.
- Manouselis, N., Drachsler, H., Verbert, K. e Duval, E. (2012). *Recommender Systems for Learning*. Berlin, Springer, 90 p.
- Medeiros, I. R. G. (2013). Estudo sobre Sistemas de Recomendação Colaborativos. 30 f. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) — Centro de Informática, Universidade Federal de Pernambuco, Recife.
- Petticrew, M. e Roberts, H. (2006) *Systematic reviews in the social sciences: A practical guide*. Malden, MA: Blackwell Publishing.
- Pietruchinski, M. H., Neto, J.C., Malucelli, A. e Reinehr, S. (2011). Os jogos educativos no contexto do SBIE: uma revisão sistemática de Literatura. In: *XXII Simpósio Brasileiro de Informática na Educação (SBIE)*, p. 476–485.
- Pontes, W. L., França, R. M., Costa, A. P. M. e Behar, P. (2014). Filtragens de Recomendação de Objetos de Aprendizagem: uma revisão sistemática do CBIE. In: *XXV Simpósio Brasileiro de Informática na Educação (SBIE)*, p. 549–558.

# Recomendação de Objetos de Aprendizagem baseada na Popularidade dos Objetos e nos Estilos de Aprendizagem dos Alunos

Janderson J. B. Aguiar<sup>1</sup>, Joseana M. Fechine<sup>1</sup>, Evandro B. Costa<sup>2</sup>

<sup>1</sup> Universidade Federal de Campina Grande (UFCG), Campina Grande – PB – Brasil

<sup>2</sup> Universidade Federal de Alagoas (UFAL), Maceió – AL – Brasil

janderson@copin.ufcg.edu.br, joseana@dsc.ufcg.edu.br, evandro@ic.ufal.br

**Abstract.** *Students have different Learning Styles (LS), and therefore the characteristics of the materials used for study can impact on their learning. With the increasing number of Learning Objects (LO) in various repositories, it is important to study possibilities for improving the access of the vast amount of LO to students. Thus, it is interesting the use of Recommender Systems for LO, based on LS students. In addition, the popularity of these LO in educational environment can be used as a strategy to improve the recommendations. The objective of this paper is to present a hybrid recommendation model for LO, based on popularity of items and LS. The experiment conducted with 55 students, considering their LS and their ratings for 25 LO variations, indicated the utility of the proposed hybrid model (which proved to be better than other traditional recommendation approaches).*

**Resumo.** *Os alunos possuem diferentes Estilos de Aprendizagem (EA), e, portanto, as características dos materiais educacionais podem impactar no seu modo de aprender. Com o número crescente de Objetos de Aprendizagem (OA) em vários repositórios, é importante estudar como melhorar o acesso a esses OA. Portanto, é interessante o uso de Sistemas de Recomendação de OA, com base nos EA dos alunos. Além disso, a popularidade desses OA no ambiente educacional pode ser usado como uma estratégia para melhorar as recomendações. O objetivo deste artigo é apresentar um modelo híbrido de recomendação de OA, com base em sua popularidade e nos EA dos alunos. O experimento realizado com 55 estudantes, considerando seus EA e suas avaliações para 25 variações de OA, indicou a utilidade do modelo proposto, que se mostrou melhor que outras abordagens tradicionais de recomendação.*

## 1. Introdução

Para minimizar o tempo e o esforço despendido ao desenvolver materiais didáticos, e pensando em uma forma de reutilizar esses materiais, surgiu o conceito de Objetos de Aprendizagem (OA) [Resende *et al.* 2014]. Com a consolidação da Web como meio de apoio ao processo de ensino e aprendizagem, há uma tendência crescente na quantidade de OA disponíveis para estudantes e professores, em vários repositórios existentes, a exemplo do ARIADNE (<http://ariadne-eu.org/>), Connexions (<http://cnx.org/>), Learn-Alberta (<http://learnalberta.ca>), MERLOT (<http://merlot.org>) e RIVED (<http://rived.mec.gov.br/>).

Em meio à sobrecarga de informação, surgiram os Sistemas de Recomendação (SR), coletando informações sobre as preferências de seus usuários para um conjunto de

itens (a exemplo de filmes, músicas e materiais educacionais), e visando ao auxílio aos usuários no processo de busca e acesso a informações relevantes [Ricci *et al.* 2011; Bobadilla *et al.*, 2013; Aguiar *et al.*, 2014]. Dentre as técnicas utilizadas em SR, uma das mais conhecidas é a Filtragem Colaborativa (FC). Na FC, com as avaliações dos itens pelos usuários do sistema, é possível sugerir os itens melhor avaliados por usuários com preferências similares, não sendo necessário compreender ou reconhecer as características dos itens [Cazella, Nunes e Reategui 2010; Bobadilla *et al.* 2013; Costa, Aguiar e Magalhães 2013].

As limitações em relação à FC referem-se especialmente à coleta de informações dos usuários, destacando-se os problemas de: (i) primeiro avaliador, uma vez que um novo item não é recomendado até que usuários o avaliem; (ii) pontuações esparsas, em casos de sistemas com pequeno número de usuários e grande número de itens; (iii) usuário com gostos muito diferentes, dado que as recomendações para ele podem ser fracas pela escassez de usuários com gostos similares [Adomavicius e Tuzhilin 2005; Costa, Aguiar e Magalhães 2013].

Além dessas limitações em SR de contexto geral, é ainda mais desafiador quando se pretende recomendar recursos educacionais personalizados baseando-se em necessidades individuais de cada aluno, um vez que, segundo Kolb (1984), o processo de aprendizagem não é vivenciado por todos os indivíduos da mesma forma, sendo desenvolvidos — como resultado da bagagem hereditária, das experiências pessoais e das exigências do ambiente — Estilos de Aprendizagem (EA), que enfatizam algumas habilidades sobre as outras.

Segundo Bobadilla *et al.* (2013), a evolução dos SR mostra a importância de técnicas híbridas, que combinam duas ou mais técnicas de recomendação diferentes, a fim de resolver as limitações e obter as vantagens de cada uma delas.

Embora técnicas de recomendação personalizada demonstrem ser mais eficientes em muitos contextos, a recomendação não personalizada pode ser encontrada em combinação com técnicas de recomendação personalizada em muitos SR. Um algoritmo bastante útil e conhecido que utiliza recomendação não personalizada é o Mais Popular (*Most Popular* — MP) que, como o nome sugere, se baseia na popularidade dos itens, sendo recomendados a todos os usuários do sistema os itens julgados mais interessantes pela maioria.

Considerando todo o contexto discutido até então, percebe-se a importância de criar modelos de recomendação de OA baseada nos EA dos estudantes para melhorar a aprendizagem destes. Os resultados obtidos por meio de um experimento, realizado com alunos de graduação e pós-graduação em Ciência da Computação, indicam a utilidade de um modelo híbrido baseado em popularidade dos OA e as características desses, seguindo o padrão IEEE LOM (*Learning Object Metadata*) [IEEE 2002], associadas à teoria de EA de Felder–Silverman [Felder e Silverman 1988].

## **2. Trabalhos Relacionados**

Dentre as primeiras iniciativas de SR voltadas para a educação, é possível citar o GroupLens, um projeto de pesquisa, desenvolvido pela Universidade de Minnesota, relacionado à FC, cujo sistema auxiliava a busca de artigos, coletando a avaliação dos usuários, referente aos artigos lidos e, a partir da identificação dos usuários com avaliações similares, recomendava novos artigos [Konstan *et al.* 1997].

Recentemente, Drachsler *et al.* (2015) realizaram uma pesquisa analisando a área de SR na Aprendizagem Apoiada por Tecnologia (*Recommender Systems in TEL — Technology Enhanced Learning*), ao longo de 15 anos (2000–2014). Foram investigados 82 trabalhos, de 35 países diferentes. Dentre eles, é possível citar o de Kerkiri, Manitsaris e Mavridis (2009) e o de Casali *et al.* (2012), trabalhos que demonstraram preocupação com as preferências dos aprendizes.

Kerkiri, Manitsaris e Mavridis (2009) propuseram uma metodologia para aplicar algoritmos de recomendação em um sistema *e-learning*, explorando ontologias para personalizar recursos de aprendizagem. Segundo os autores, a personalização é realizada por meio da manipulação de metadados relacionados à reputação e aos EA dos usuários, a partir do modelo de Felder–Silverman. Para receberem as recomendações personalizadas, os alunos inicialmente fornecem algumas informações sobre eles (dados pessoais, preferências etc.), além de preencherem um questionário sobre EA.

Casali *et al.* (2012) apresentam o desenvolvimento de um SR para ajudar os usuários a encontrar OA mais adequados às suas necessidades e preferências. A partir de repositórios de aprendizagem distribuídos, os OA, descritos em metadados, são recomendados seguindo uma abordagem baseada em regras, levando em consideração o perfil dos usuários.

No contexto brasileiro, Aguiar *et al.* (2014) realizaram um mapeamento sobre iniciativas em Sistemas de Recomendação Educacionais (SRE). Dentre os trabalhos retornados nesse mapeamento, é possível destacar o de Zaina *et al.* (2012), que utiliza o padrão de metadados IEEE LOM para OA, sendo relacionado esse padrão com as dimensões de EA de Felder–Silverman. Outro trabalho que utiliza esses conceitos é o de Carvalho *et al.* (2014).

Enquanto Zaina *et al.* (2012) apresentaram uma abordagem não dinâmica, desconsiderando as incertezas relacionadas à modelagem do perfil do estudante, Carvalho *et al.* (2014) consideraram de maneira probabilística as dimensões de EA. Embora o processo de avaliação do trabalho de Carvalho *et al.* (2014) indique sua possível utilidade à personalização em SRE, não é avaliada a acurácia das recomendações.

Apesar dos trabalhos comentados anteriormente serem relacionados ao trabalho proposto neste artigo, este trabalho diferencia-se por expandir o modelo de Carvalho *et al.* (2014) com o aspecto de popularidade, criando um modelo híbrido. Além disso, este trabalho avaliou a acurácia do modelo híbrido proposto comparando-o com o modelo de Carvalho *et al.* (2014) e outros algoritmos tradicionais de recomendação.

### **3. Conceitos sobre Objetos e Estilos de Aprendizagem**

Dentre as definições de OA existentes, Wiley (2000) defende que eles são entidades digitais que podem ser transmitidas pela Web e acessadas simultaneamente por um grande público, de uma maneira mais versátil em comparação à mídia tradicional (livros e outros materiais disponibilizados em mídias físicas). Um dos padrões de OA mais populares é o padrão IEEE LOM (IEEE 1484.12.1), que, como afirmam Vicari *et al.* (2010), é amplamente aceito no meio acadêmico, apresentando um conjunto de metadados organizado em nove categorias. São elas: Geral (informações gerais do OA), Ciclo de vida (características relativas ao histórico e ao estado atual do OA), Meta-metadados (metadados utilizados para descrever os metadados do OA), Técnica

(requisitos e características técnicas do OA), Educacional (características educacionais e pedagógicas do OA), Direitos (direitos de propriedade intelectual e condições de uso do OA), Relação (características que definem o relacionamento entre um OA e outros), Anotação (comentários sobre o uso do OA) e Classificação (descrição do objeto de acordo com algum sistema de classificação pré-definido) [IEEE 2002; Vaz 2009].

Dentre os modelos de EA, é possível destacar o modelo de Felder–Silverman, o mais utilizado no contexto brasileiro e internacional em pesquisas relativas à adaptação e personalização de materiais de aprendizagem [Aguiar, Fachine e Costa 2014; Valaski, Malucelli e Reinehr 2011]. Tal modelo contempla 4 (quatro) dimensões de EA: (1) Processamento (estilos Ativo e Reflexivo); (2) Percepção (estilos Sensorial e Intuitivo); (3) Entrada (estilos Visual e Verbal); e (4) Compreensão (estilos Sequencial e Global) [Felder e Silverman 1988; Felder 2002]. Baseado nas 4 dimensões, foi desenvolvido o Índice de Estilos de Aprendizagem (*Index of Learning Styles* — ILS) [Felder e Soloman 1999], instrumento de mensuração com 44 questões.

Em geral, os alunos Ativos aprendem por meio da experimentação ativa, e compreendem as informações mais eficientemente discutindo e aplicando os conceitos; por outro lado, os Reflexivos necessitam de um tempo sozinhos para pensar/refletir sobre as informações obtidas. Os alunos Sensoriais preferem lidar com situações concretas, dados e experimentos; por outro lado, os Intuitivos são inovadores, gostam de lidar com abstrações, conceitos e teorias. Os indivíduos com estilo Visual aprendem mais facilmente por meio de demonstrações, diagramas, figuras, filmes, fluxogramas; por outro lado, aqueles com estilo Verbal compreendem melhor as informações transmitidas por meio de palavras. Os alunos Sequenciais aprendem melhor quando o conceito é expresso de maneira contínua de dificuldade e complexidade; por outro lado, os alunos Globais são multidisciplinares, aprendendo em grandes saltos e lidando com os conteúdos de forma aleatória [Felder e Silverman, 1988; Dias, Gasparini e Karczinski, 2009].

#### 4. Modelo de Recomendação

Na Figura 1, é ilustrado o modelo de recomendação proposto nesta pesquisa. Em síntese, a partir do “Perfil do Discente” e do “Perfil do Objeto de Aprendizagem”, são calculados os melhores OA para tal aluno e, por conseguinte, tais itens são recomendados para o aluno.

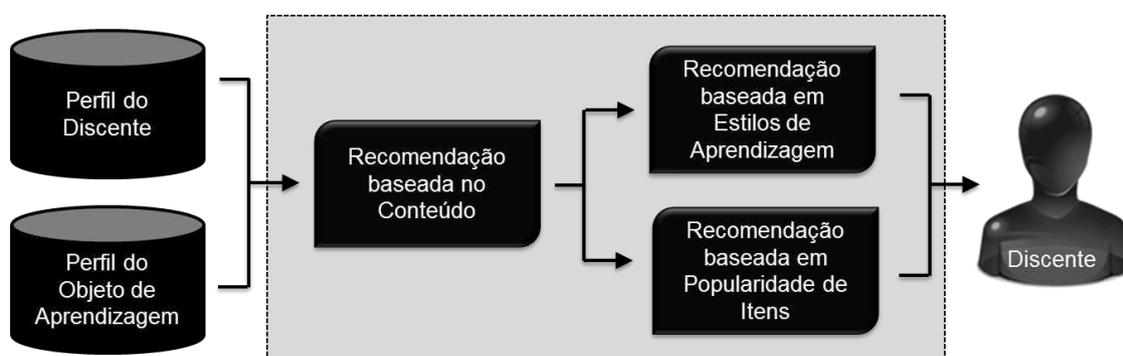


Figura 1. Modelo de recomendação de OA baseada na popularidade dos objetos e nos EA dos alunos.

O “Perfil do Discente” consiste basicamente nos EA de cada aluno, baseado no modelo de Felder–Silverman. O “Perfil do Objeto de Aprendizagem” consiste nos OA, criados com base no padrão IEEE LOM, com seus metadados devidamente preenchidos — especialmente os que se referem ao Conteúdo e à associação, realizada por Carvalho *et al.* (2014), entre os metadados dos OA do padrão IEEE LOM e as quatro dimensões de EA do modelo de Felder–Silverman.

O processo de recomendação proposto consiste inicialmente em filtrar os OA com base no seu conteúdo (para, por exemplo, alunos procurando conteúdo sobre Compiladores não receberem recomendação de OA sobre Banco de Dados etc.) e, após isso, ordenar esses OA com base nos EA do aluno, além da popularidade desses itens.

Essa ordenação é realizada com base no que foi denominado Grau de Recomendação (*GR*) do OA, calculado segundo a Equação 1, sendo  $P_{MP}$  a posição do OA no *ranking* relativo ao algoritmo MP, e sendo  $P_{EA}$  a posição do OA no *ranking* relativo ao algoritmo baseado em EA, proposto por Carvalho *et al.* (2014), chamado neste artigo de LSBR (*Learning Style based recommendation*).

$$GR(oa) = \frac{1}{P_{EA}(oa)} + \frac{1}{P_{MP}(oa)} \quad (1)$$

Suponha, por exemplo, que, com um total de 50 OA em um repositório, após a filtragem com base no conteúdo, são definidos 10 OA que abordam o conteúdo de Compiladores. Após definidos esses 10 OA, são calculados os GR de cada um deles. Para isso, tais OA são ordenados, para cada usuário-alvo, em duas listas diferentes, uma com base na execução do algoritmo LSBR (lista baseada em EA) e outra com base na execução do algoritmo MP (lista baseada em popularidade).

Considerando um OA ‘X’ na posição 2 da lista baseada em EA ( $P_{EA} = 2$ ) e na posição 4 da lista baseada em popularidade ( $P_{MP} = 4$ ), seu GR será igual a 0.75, ou seja  $(1/2)+(1/4)$ . Considerando um OA ‘Y’ na posição 1 da lista baseada em EA ( $P_{EA} = 1$ ) e na posição 5 da lista baseada em popularidade ( $P_{MP} = 5$ ), seu GR será igual a 1.2, ou seja  $(1/1)+(1/5)$ . Neste caso, o ‘Y’ é julgado mais útil que o ‘X’ para o usuário-alvo.

## 5. Avaliação do Modelo Proposto

O artigo clássico de Herlocker *et al.* (2004) aborda a avaliação em SR. Para medir quão relevante para o usuário é um conjunto de itens recuperados/recomendados pelo SR, há métricas de acurácia de classificação, tais como: Precisão (Precision),  $P@n$  (*Precision at n*), Cobertura (Recall),  $R@n$  (*Recall at n*), MAP (*Mean Average Precision*), ROC (*Receiver Operating Characteristic*), AUC (*Area Under ROC Curve*), NDCG (*Normalized Discounted Cumulative Gain*) e MRR (*Mean Reciprocal Rank*).

Para este trabalho, foram considerados que 25 OA apresentavam o mesmo conteúdo (ou seja, já seriam OA filtrados na primeira fase do modelo proposto), mas com características diferentes (valores diferentes nos metadados referente a Formato, Tipo de Recurso de Aprendizagem, Tipo de Interatividade e Estrutura). Com base nessas características, 55 estudantes de Ciência da Computação de duas universidades federais brasileiras (35 alunos de graduação e 20 alunos de pós-graduação) classificaram esses 25 OA de 1 a 5 estrelas, além de responderem o inventário ILS. As justificativas para adotar tal inventário como instrumento de mensuração de EA foram: (i) acesso livre e sem custos, disponibilizado via Web em diversos idiomas; (ii)

preenchimento fácil e simples, e (iii) confiabilidade e validade, sendo amplamente utilizado em pesquisas anteriores.

Com isso, foram comparados o algoritmo LSBR com o algoritmo híbrido proposto neste artigo (LSBR+MP), além do algoritmo MP e estes algoritmos tradicionais em SR: UserKNN e ItemKNN (FC baseada em  $k$  usuários/itens, considerados vizinhos mais próximos), e BPRMF (Fatoração de Matrizes usando BPR — *Bayesian Personal Ranking*).

Sobre a avaliação, por ser utilizada a estratégia de recomendar um conjunto ordenado de OA, foram escolhidas as seguintes métricas: AUC, MAP, MRR, NDCG, P@5 e R@5. Foi empregada a técnica de validação cruzada (*k-fold cross validation*) [Bengio e Grandvalet 2004 *apud* Bobadilla *et al.* 2013], sendo separados aleatoriamente, por cem vezes ( $k=100$ ), os dados em dois conjuntos: um para treinar o modelo, e outro para testá-lo.

Para execução desses algoritmos tradicionais, foi utilizado o MyMediaLite [Gantner *et al.* 2011], versão 3.10, considerando o limiar de avaliação de 3 estrelas como um item útil. O MyMediaLite também foi utilizado para calcular as métricas anteriormente citadas.

No experimento realizado, além do fator Algoritmo (com os níveis ItemKNN, UserKNN, BPRMF, MP, LSBR e LSBR+MP), foi considerado o fator Porcentagem utilizada para o conjunto de treino (com os níveis 65% e 75%). Este experimento, do tipo comparativo, utilizou o Design Fatorial Completo, com 12 tratamentos (6 algoritmos  $\times$  2 níveis de porcentagem), sendo realizadas 100 repetições para cada, totalizando 1200 ensaios.

## 6. Resultados e Discussão

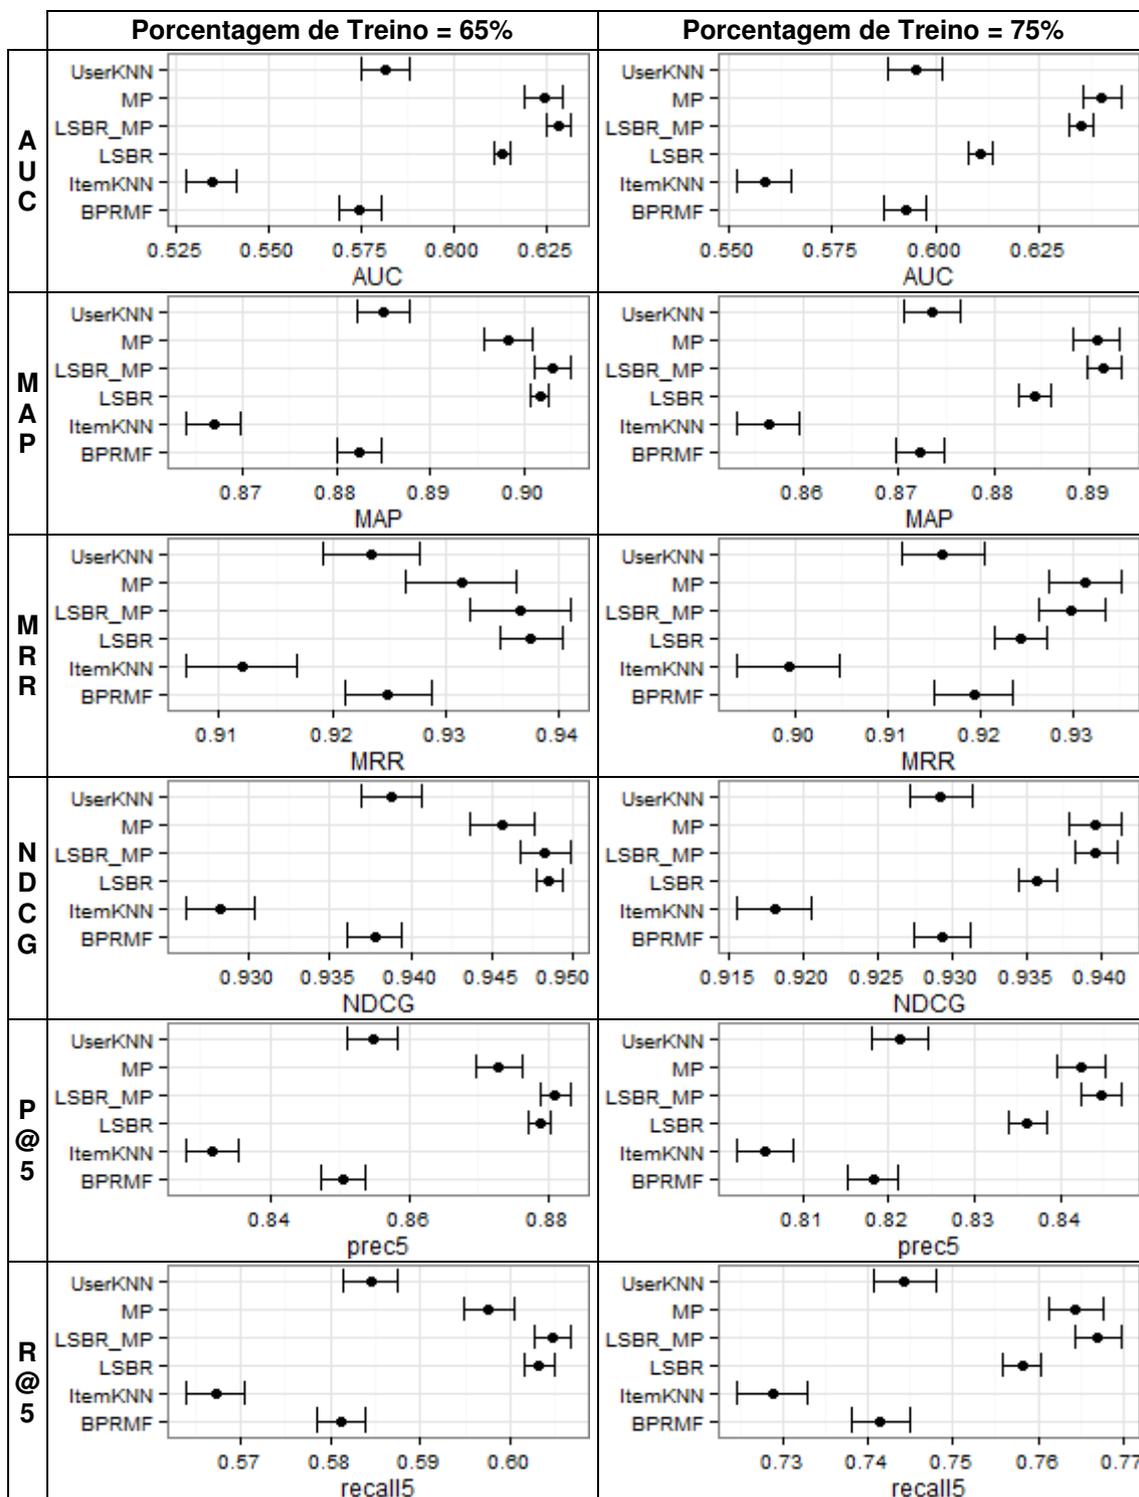
Após a execução do experimento, planejado conforme indicado na seção 5, foram gerados intervalos de confiança para as médias obtidas pelos algoritmos para cada métrica, com nível de significância de 5% (Quadro 1), a fim de verificar o desempenho do modelo proposto em relação aos outros algoritmos.

A partir do Quadro 1, percebe-se que, em geral, ao comparar os intervalos de confiança a partir das seis métricas, e da variação da porcentagem de treino, a abordagem híbrida proposta neste artigo (LSBR+MP) apresentou os melhores resultados. Nas vezes em que não se destacou dos outros algoritmos de recomendação, o intervalo de confiança manteve-se sobreposto a um dos outros algoritmos comparados.

Além do modelo proposto ser interessante por não enfrentar as limitações das abordagens de FC comentadas na seção 1, tal modelo apresentou-se, em todos os gráficos, melhor que os algoritmos tradicionais baseados em vizinhos mais próximos (UserKNN e ItemKNN), além do baseado em fatoração de matrizes (BPRMF).

Em relação à abordagem LSBR, este experimento reforça a importância do modelo proposto por Carvalho *et al.* (2014), uma vez que, em tal trabalho, apesar de ser apresentada uma simulação computacional com resultados promissores, não havia sido realizada uma avaliação comparativa como neste artigo. O modelo LSBR, em todos os gráficos, também se apresentou melhor que os algoritmos UserKNN, ItemKNN e BPRMF (apesar de uma leve sobreposição de intervalos no gráfico relativo à métrica MRR considerando a porcentagem de treino de 75%).

Quadro 1. Intervalos de confiança para comparação das abordagens de recomendação com base nas métricas AUC, MAP, MRR, NDCG, P@5 e R@5, e na porcentagem de treino utilizada (65% e 75%).



Neste experimento, ressalta-se a importância da abordagem não personalizada (MP — Mais Popular), que em alguns casos apresentou intervalos de confiança com valores até maiores que a abordagem LSBR, além de intervalos de confiança próximos ou mesmo sobrepostos aos do modelo proposto.

O uso de várias métricas de comparação e de dois distintos valores percentuais para o conjunto de treino foram estratégias visando maior generalização dos resultados obtidos. Entretanto, é importante advertir que outros experimentos, com diferentes itens e pessoas, poderiam indicar variações nesses resultados. Como é visível a partir do Quadro 1, o algoritmo ItemKNN teve desempenho sempre menor diante do algoritmo UserKNN, o que pode ser provavelmente justificado pela quantidade de usuários (55) ser maior que a quantidade de itens (25).

Todavia, dados os resultados apresentados relativos à acurácia das recomendações, ressalta-se a importância da abordagem proposta (LSBR+MP) para a área de SRE.

## 7. Considerações Finais

Há docentes e pesquisadores preocupados com a forma com que os aprendizes lidam particularmente com as informações, sendo o conceito de EA levado em consideração em muitas pesquisas atualmente, objetivando não tratar igualmente os estudantes em relação ao modo como adquirem e produzem conhecimento. Como exposto no mapeamento realizado por Aguiar, Fachine e Costa (2014), nos últimos anos houve um aumento de pesquisas em Informática na Educação considerando o conceito de EA.

Apesar de, no experimento apresentado neste artigo, ser utilizado o ILS como instrumento de mensuração de EA, é interessante comentar que há iniciativas considerando o modelo de Felder–Silverman que não o utilizam, sendo possível citar as pesquisas de Popescu, Trigano e Badica (2007) e Silva e Dorça (2014), que sugerem a utilização de métodos baseados na análise do comportamento implícito do estudante em sistemas de aprendizagem. Em ambas as pesquisas, além da obtenção dos EA, são realizadas dinamicamente atualizações no perfil do aluno, considerando o desempenho na avaliação de uma seção de aprendizagem [Silva e Dorça 2014] e regras como, por exemplo, um valor alto no número de postagens em fórum indica um estilo Ativo e Verbal [Popescu, Trigano e Badica 2007].

Dado o modelo exposto na Figura 1, essa ideia de atualização dinâmica pode ser facilmente incorporada na abordagem desta pesquisa, atualizando o “Perfil do Discente” com base no sistema de aprendizagem utilizado.

Neste ponto, vale ressaltar que, embora tenha se utilizado a teoria de EA de Felder–Silverman e o padrão IEEE LOM para os OA, o modelo proposto pode ser adaptado para usar outras teorias de EA (como a de [Kolb 1984]) e outros padrões de metadados (como o OBAA [Vicari *et al.* 2010]). Destaca-se apenas a necessidade de uma associação consistente entre a teoria de EA e o padrão de OA utilizados, para que os OA recomendados correspondam aos EA dos alunos. Nesse aspecto, muitas pesquisas ainda podem ser realizadas para melhorar/abranger as associações entre dimensões de EA e os metadados dos padrões dos OA [Aguiar, Fachine e Costa 2015].

Uma vez que é válido e necessário considerar as particularidades dos estudantes, os autores deste artigo defendem a necessidade, em ambientes educacionais, de recomendações personalizadas baseadas em EA como estratégia de melhorar o acesso a recursos educacionais por parte dos alunos e, por conseguinte, propiciar melhorias na aprendizagem destes. Além disso, o aspecto de popularidade de itens se torna importante por permitir que, mesmo que um aprendiz tenha uma preferência muito

particular, seja possível receber recomendações de alguns OA que foram julgados úteis pela maioria dos colegas.

Além desses aspectos para personalização de SR, estão sendo atualmente estudados meios de incorporar a teoria de Traços de Personalidade nesse modelo híbrido, visando melhorar ainda mais a acurácia das recomendações.

## Agradecimentos

Os autores agradecem aos pesquisadores contatados, pelos dados e informações disponibilizados, essenciais para o desenvolvimento desta pesquisa.

## Referências

- Adomavicius, G.; Tuzhilin, A. (2005). Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. In: *IEEE Transactions On Knowledge and Data Engineering*, vol. 17, n. 6, p. 734–749.
- Aguiar, J. J. B.; Fachine, J. M.; Costa, E. (2014). Estilos Cognitivos e Estilos de Aprendizagem em Informática na Educação: um mapeamento sistemático focado no SBIE, WIE e RBIE. In: *Anais do XXV Simpósio Brasileiro de Informática na Educação (SBIE)*, Dourados, p. 441–450.
- Aguiar, J. J. B.; Fachine, J. M.; Costa, E. (2015). Análise Comparativa de Abordagens de Associação entre os Estilos de Aprendizagem de Felder-Silverman e os Metadados do Padrão IEEE LOM. In: *XXXV Congresso da Sociedade Brasileira de Computação — IV Workshop de Desafios da Computação Aplicada à Educação (DesafIE)*, Recife. Sem paginação.
- Aguiar, J. J. B.; Santos, S. I. N.; Fachine, J. M.; Costa, E. (2014). Um Mapeamento Sistemático sobre Iniciativas Brasileiras em Sistemas de Recomendação Educacionais. In: *Anais do XXV Simpósio Brasileiro de Informática na Educação*, Dourados, p. 1123–1132.
- Bobadilla, J.; Ortega, F.; Hernando, A.; Gutiérrez, A. (2013). Recommender systems survey. *Knowledge Based Systems*, v. 46, p. 109–132.
- Carvalho, V. C.; Dorça, F. A.; Cattelan, R. G.; Araújo, R. D. (2014). Uma Abordagem para Recomendação Automática e Dinâmica de Objetos de Aprendizagem Baseada em Estilos de Aprendizagem. In: *Anais do XXV Simpósio Brasileiro de Informática na Educação — SBIE 2014*, Dourados, MS, p. 1188–1197.
- Casali, A.; Gerling, V.; Deco, C.; Bender, C. (2012). A Recommender System for Learning Objects Personalized Retrieval. In: Santos O.; Boticario, J. (Org.), *Educational Recommender Systems and Technologies: Practices and Challenges*, p. 182–210.
- Cazella, S. C.; Nunes, M. A. S. N.; Reategui, E. B. (2010). A Ciência da Opinião: Estado da arte em Sistemas de Recomendação. In: *XXX Congresso da Sociedade Brasileira de Computação — Jornada de Atualização em Informática (JAI)*.
- Costa, E.; Aguiar, J.; Magalhães, J. (2013). Sistemas de Recomendação de Recursos Educacionais: conceitos, técnicas e aplicações. In *II Congresso Brasileiro de Informática na Educação — Jornada de Atualização em Informática na Educação (JAIE)*, p. 57–78.
- Dias, C. C. L.; Gasparini, I.; Kemczinsk, A. (2009). Identificação dos estilos cognitivos de aprendizagem através da interação em um Ambiente EAD. In: *XXIX Congresso da Sociedade Brasileira de Computação — XVII Workshop sobre Educação em Informática (WEI)*, p. 489–498.
- Drachsler, H.; Verbert, K.; Santos, O. C.; Manouselis, N. (2015). Panorama of recommender systems to support learning. *Handbook on recommender systems*. (no prelo). Disponível em: <[https://lirias.kuleuven.be/bitstream/123456789/476545/1/TEL\\_RecSys.pdf](https://lirias.kuleuven.be/bitstream/123456789/476545/1/TEL_RecSys.pdf)>. Acesso em: 28 mai. 2015.

- Felder, R. M. (2002). Author's Preface — June 2002. In: *FELDER, R. M.; SILVERMAN, L. K. Learning and Learning and Teaching Styles in Engineering Education*. Disponível em: <<http://www.ncsu.edu/felder-public/Papers/LS-1988.pdf>>. Acesso em: 31 jan. 2015.
- Felder, R. M.; Silverman, L. K. (1988). Learning and Teaching Styles in Engineering Education. *Journal of Engineering Education*, v. 78, n. 7, p. 674–681.
- Felder, R. M.; Soloman, B. A. (1999). Index of Learning Styles (ILS). Disponível em: <<http://www4.ncsu.edu/unity/lockers/users/f/felder/public/ILSpage.html>>. Acesso: 15 out. 2014.
- Gantner, Z.; Rendle, S.; Freudenthaler, C.; Schmidt-Thieme, L. (2011). MyMediaLite: A Free Recommender System Library. In: *Proceedings of the 5th ACM Conference on Recommender Systems (RecSys 2011)*. Chicago, USA.
- Herlocker, J. L.; Konstan, J. A.; Terveen, L. G.; Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems*, 22 (1), p. 5–53.
- IEEE. (2002). IEEE Standard for Learning Object Metadata. *IEEE Std 1484.12.1-2002*, p. i–32.
- Kerkiri, T.; Manitsaris, A.; Mavridis, I. (2009). How e-learning systems may benefit from ontologies and recommendation methods to efficiently personalise resources. *International Journal of Knowledge and Learning (IJKL)*, v. 5, n. 3/4, p. 347–370.
- Kolb, D. A. (1984). Experiential learning: experience as the source of learning and development. *Englewood Cliffs: Prentice-Hall*.
- Konstan, J. A.; Miller, B. N.; Maltz, D.; Herlocker, J. L.; Gordon, L. R.; Riedl, J. (1997). GroupLens: Applying Collaborative Filtering to Usenet News. *Communications of the ACM*, New York, v.40, n.3, p. 77–87.
- Popescu, E.; Trigano, P.; Badica, C. (2007). Adaptive Educational Hypermedia Systems: A Focus on Learning Styles. In: *EUROCON 2007 — The International Conference on “Computer as a Tool”*, p. 2473–2478.
- Resende, D. T.; Dorça, F. A.; Cattelan, R. G.; Araújo, R. D. (2014). Em direção à recuperação automática de objetos de aprendizagem em repositórios através da associação dos estilos de aprendizagem de estudantes com metadados no padrão IEEE-LOM. In: *Anais do VI Workshop Brasileiro de Web Semântica e Educação (WSWed)*, Dourados, MS.
- Ricci, F.; Rokach, L.; Shapira, B.; Kantor, P. B. (Eds.). (2011). *Handbook on Recommender Systems*. 1.ed. Springer, 845 p., ISBN: 978-0-387-85819-7.
- Silva, D. H.; Dorça, F. A. (2014). Uma Abordagem Automática para Personalização do Processo de Ensino Baseada em Estilos de Aprendizagem em Sistemas Adaptativos e Inteligentes para Educação a Distância. *Revista Brasileira de Informatica na Educação (RBIE)*, v. 22, n. 2, p.1–15.
- Valaski, J.; Malucelli, A.; Reinehr, S. (2011). Revisão dos Modelos de Estilos de Aprendizagem Aplicados à Adaptação e Personalização dos Materiais de Aprendizagem. In: *Anais do XXII Simpósio Brasileiro de Informática na Educação (SBIE)*, p. 844–847.
- Vaz, M. (2009). Os Padrões Internacionais para a Construção de Material Educativo On-line. *Pearson Education do Brasil*, São Paulo, 1.ed., p. 386–396.
- Vicari, R. M.; Ribeiro, A.; Da Silva, J. M. C.; Santos, E. R.; Primo, T.; Bez, M. (2010). Brazilian proposal for agent-based learning objects metadata standard — OBAA. *Communications in Computer and Information Science*, v. 108, p. 300–311.
- Wiley, D. (2000). *Connecting learning objects to instructional design theory: A definition, a metaphor, and a taxonomy*, The Agency for Instructional Technology, Bloomington, Indiana, USA, p. 3–23.
- Zaina, L. A.; Bressan, G.; Cardieri, M. A. A.; Rodrigues Junior, J. F. (2012). E-LORS: Uma abordagem para recomendação de objetos de aprendizagem. *Revista Brasileira de Informatica na Educação (RBIE)*, v. 20, n. 1, p. 4–16.

# Apêndice B

## Panorama Internacional dos Sistemas de Recomendação Educacionais

Com base na panorama realizado por Drachsler *et al.* (2015)<sup>1</sup>, foi elaborado o Quadro 14 para facilitar a listagem e comparação de iniciativas em SRE publicados nos último 5 anos (2010-2014). Os campos preenchidos com "N.D." representam "Não Definido", para os casos em que os autores não definiram um valor, justificando que as informações fornecidas nos artigos foram às vezes incompletas.

**Quadro 14. Panorama internacional de SRE publicados entre 2010 e 2014.**

Referência do Artigo Publicado	Tarefa de Recomendação	Técnica de Recomendação	Tipo de Algoritmo
Abel, F., Bittencourt, I.I., de Barros Costa, E., Henze, N., Krause, D., Vassileva, J.: Recommendations in Online Discussion Forums for E-Learning Systems. TLT 3(2), 165-176 (2010).	Encontrar bons itens	Baseada em regras	N.D.
Aher, S.B., Lobo, L.: Combination of machine learning algorithms for recommendation of courses in E-Learning System based on historical data. Knowl.-Based Syst. 51: 1-14 (2013)	Encontrar bons itens (cursos)	FBC; Baseada em regras	Baseado em modelo
Beham, G., Kump, B., Ley, T., Lindstaedt, S.: Recommending knowledgeable people in a work-integrated learning system. Procedia Computer Science, 1(2), 2783-2792 (2010)	Encontrar bons itens; Encontrar pares	FBC	N.D.
Bielikova, M., Simko, M., Barla, M., Tvarozek, J., Labaj, M., Mro, R., Srba, I., & Sevcech, J.: ALEF: from Application to Platform for Adaptive Collaborative Learning. Special issue on Recommender Systems for Technology Enhanced Learning: Research Trends & Applications, Springer Berlin (2014)	Encontrar bons itens; Recomendar sequência de itens	FBC; Baseada em regras	Baseado em modelo

<sup>1</sup> DRACHSLER, H.; VERBERT, K.; SANTOS, O. C.; MANOUSELIS, N. Panorama of recommender systems to support learning. *Handbook on recommender systems*. 2015 (no prelo). Disponível em: <[https://lirias.kuleuven.be/bitstream/123456789/476545/1/TEL\\_RecSys.pdf](https://lirias.kuleuven.be/bitstream/123456789/476545/1/TEL_RecSys.pdf)>. Acesso em: 09 ago. 2015.

**Continuação do Quadro 14.**

<b>Referência do Artigo Publicado</b>	<b>Tarefa de Recomendação</b>	<b>Técnica de Recomendação</b>	<b>Tipo de Algoritmo</b>
Bodea, C., Dascalu, M., Lipai, A.: Clustering of the Web Search Results in Educational Recommender Systems. In: Santos O, Boticario J (eds) Educational Recommender Systems and Technologies: Practices and Challenges, pp. 154-181 (2012)	Encontrar bons itens	Baseada em regras	Baseado em modelo
Broisin, J., Brut, M., Butoianu, V., Sedes, F., Vidal, P.: A personalised recommendation framework based on CAM and document annotations. <i>Procedia Computer Science</i> , 1(2), 2839-2848 (2010)	Encontrar bons itens	FBC	Baseado em modelo
Brusilovsky, P., Cassel, L.N., Delcambre, L.M.L., Fox, E.A., Furuta, R., Garcia, D.D., Shipman III, F.M., Yudelson, M.: Social navigation for educational digital libraries, <i>Procedia Computer Science</i> , 1(2), 2889-2897 (2010)	Encontrar bons itens; Recomendar sequência de itens	Filtragem híbrida	Baseado em memória e em modelo
Carchiolo, V., Longheu, A., Malgeri, M.: Reliable peers and useful resources: Searching for the best personalised learning path in a trust- and recommendation-aware environment, <i>Information Sciences</i> , Volume 180, Issue 10, pp. 1893-1907 (2010), ISSN 0020-0255, <a href="http://dx.doi.org/10.1016/j.ins.2009.12.023">http://dx.doi.org/10.1016/j.ins.2009.12.023</a> .	Recomendar sequência de itens	Baseada em grafo	Baseado em modelo
Casali, A., Gerling, V., Deco, C., Bender, C.: A Recommender System for Learning Objects Personalized Retrieval. In: Santos O, Boticario J (eds) Educational Recommender Systems and Technologies: Practices and Challenges, pp. 182-210. (2012) doi:10.4018/978-1-61350-489-5.ch008	Encontrar bons itens	Baseada em regras	Baseado em modelo
Cazella, S.C., Reategui, E.B., Behar, P.A.: Recommendation of Learning Objects Applying Collaborative Filtering and Competencies. <i>Key Competencies in the Knowledge Society</i> pp. 35-43 (2010)	Encontrar bons itens	N.D.	N.D.
Cechinel, C., da Silva Camargo, S., Sánchez-Alonso, S., Sicilia, MA. Towards automated evaluation of learning resources inside repositories. <i>Special issue on Recommender Systems for Technology Enhanced Learning: Research Trends &amp; Applications</i> , Springer Berlin (2014). <sup>2</sup>	Encontrar bons itens	FBC	Baseado em modelo

<sup>2</sup> Na publicação do estudo de Drachsler *et al.* (2015), não há esta referência (havendo apenas o indicador RS41). Entretanto, a partir do contato via e-mail com os autores, foi repassada esta informação: "In order to answer your question, I'd say that RS41 is RS41-2014 and corresponds to a missing reference: *Cechinel, C., da Silva Camargo, S., Sánchez-Alonso, S., Sicilia, MA. (2014). Towards automated evaluation of learning resources inside repositories. Special issue on Recommender Systems for Technology Enhanced Learning: Research Trends & Applications, Springer Berlin*. Thanks for sharing this with us. We'll see if we can make some correction or list it somewhere." (SANTOS, Olga. **Re: Questions about your chapter** [mensagem pessoal]. Mensagem recebida por <janderson@copin.ufcg.edu.br> em 9 de março de 2015.).

**Continuação do Quadro 14.**

<b>Referência do Artigo Publicado</b>	<b>Tarefa de Recomendação</b>	<b>Técnica de Recomendação</b>	<b>Tipo de Algoritmo</b>
Diaz, A., Motz, R., Rohrer, E., Tansini, L.: An Ontology Network for Educational Recommender Systems. In: Santos, O., Boticario, J. (eds) Educational Recommender Systems and Technologies: Practices and Challenges, pp. 67-93. doi:10.4018/978-1-61350-489-5.ch004 (2012)	Encontrar bons itens	Baseada em regras	Baseado em modelo
El Helou, S., Salzmann, C., Gillet, D.: The 3A personalised, contextual and relation-based recommender system. Journal of Universal Computer Science, 16(16), 2179-2195 (2010)	Encontrar bons itens; Encontrar pares	FC	Baseado em memória
Farzan, R., Brusilovsky, P.: Encouraging user participation in a course recommender system: An impact on user behavior. Computers in Human Behavior, 27(1), pp. 276-284 (2011)	Encontrar bons itens (cursos)	Filtragem híbrida	Baseado em memória e em modelo
Fazeli, S., Loni, B., Drachsler, D., & Sloep, P. B. (2014). Which Recommender System Can Best Fit Social Learning Platforms?. In Proceedings of the Ninth European Conference on Technology Enhanced Learning, Open Learning and Teaching in Educational Communities (EC-TEL2014), Graz, Austria.	Encontrar bons itens; Encontrar pares	FC; Baseada em grafo	N.D.
Fernandez, A., Anjorin, M., Dackiewicz, I., and Rensing, C.: Recommendations from Heterogeneous Sources in a Technology Enhanced Learning Ecosystem. Special issue on Recommender Systems for Technology Enhanced Learning: Research Trends & Applications, Springer Berlin (2014)	N.D.	FC; Baseada em grafo	Baseado em memória e em modelo
Fraj, F., Al-Dmour, A., Al-Hashemi, R., Musa, A.: An evolving recommender-based framework for virtual learning communities. IJWBC 8(3): 322-332 (2012)	Encontrar bons itens	FC	Baseado em memória
Ghauth, K. I., & Abdullah, N. A.: The Effect of Incorporating Good Learners' Ratings in e-Learning Content-based Recommender System. Educational Technology & Society, 14 (2), 248257 (2011)	Encontrar bons itens	Filtragem híbrida	Baseado em modelo
Holanda, O., Ferreira, R., Costa, E., Bittencourt, I.I., Melo, J., Peixoto, M., Tiengo, W.: Educational resources recommendation system based on agents and semantic web for helping students in a virtual learning environment. IJWBC 8(3), pp. 333-353 (2012)	Encontrar bons itens	Recuperação bruta	N.D.
Hsieh, T.-C., Lee, M.-C., Su, C.-Y.: Designing and implementing a personalized remedial learning system for enhancing the programming learning. Educational Technology & Society 16(4): 32-46 (2013)	Recomendar sequência de itens	Baseada em regras	Baseado em modelo

**Continuação do Quadro 14.**

<b>Referência do Artigo Publicado</b>	<b>Tarefa de Recomendação</b>	<b>Técnica de Recomendação</b>	<b>Tipo de Algoritmo</b>
Hsu, C.-K., Hwang, G.-J., Chang, C.-K.: A personalized recommendation-based mobile learning approach to improving the reading performance of EFL students, <i>Computers &amp; Education</i> , Volume 63, April 2013, pp. 327-336, ISSN 0360-1315, <a href="http://dx.doi.org/10.1016/j.compedu.2012.12.004">http://dx.doi.org/10.1016/j.compedu.2012.12.004</a> (2013)	Encontrar bons itens	Baseada em regras	Baseado em modelo
Kaklauskas, A., Zavadskas, E.K., Seniut, M., Stankevicius, V., Raistenskis, J., Simkevicius, C., Stankevicius, T., Matuliuskaite, A., Bartkiene, L., Zemeckyte, L., Paliskiene, R., Cerkauskienė, R., Gribniak, V. Recommender System to Analyze Students Academic Performance. <i>Expert Systems with Applications</i> , 40(15), 6150-6165 (2013)	Encontrar bons itens	Baseada em regras	N.D.
Karampiperis, P., Koukourikos, A., Stoitsis, G.: Collaborative Filtering Recommendation of Educational Content in Social Environments utilizing Sentiment Analysis Techniques. Special issue on Recommender Systems for Technology Enhanced Learning: Research Trends & Applications, Springer Berlin (2014)	Encontrar bons itens	FC	Baseado em memória e em modelo
Leino, J.: Case study: recommending course reading materials in a small virtual learning community. <i>IJWBC</i> 8(3): 285-301 (2012)	N.D.	N.D.	N.D.
Li, M., Ogata, H., Hou, B, Uosaki, N., Mouri, K. Context-aware and Personalization Method in Ubiquitous Learning Log System. <i>Educational Technology &amp; Society</i> , 16 (3), 362373 (2013)	Encontrar bons itens	Baseada em regras	N.D.
Luo, F., Dong, J., Cao, A.: Song. A context-aware personalized resource recommendation for pervasive learning. <i>Cluster Computing</i> , June 2010, Volume 13, Issue 2, pp 213-239 (2010)	Encontrar bons itens	Filtragem híbrida	Baseado em memória e em modelo
Marino, O., Paquette, G.: A competency-driven advisor system for multi-actor learning environments. <i>Procedia Computer Science</i> , 1(2):2871-2876, doi:10.1016/j.procs.2010.08.013 (2010)	Encontrar bons itens	Baseada em regras	N.D.
Michlik, P., Bielikova, M.: Exercises recommending for limited time learning. <i>Procedia Computer Science</i> , (1)2:2821-2828. doi:10.1016/j.procs.2010.08.007 (2010)	Encontrar bons itens	Baseada em regras	Baseado em modelo
Moedritscher, F.: Towards a recommender strategy for personal learning environments. <i>Procedia Computer Science</i> , (1)2:2775-2782. doi:10.1016/j.procs.2010.08.002 (2010)	Encontrar bons itens	FC	Baseado em memória
Nowakowski, S., Ognjanovic, I., Grandbastien, M., Jovanovic, J., Sendelj, R.: Two Recommending Strategies to enhance Online Presence in Personal Learning Environments. Special issue on Recommender Systems for Technology Enhanced Learning: Research Trends & Applications, Springer Berlin (2014)	Encontrar bons itens; Encontrar pares; Recomendar sequência de itens	Filtragem híbrida	Baseado em memória e em modelo

**Continuação do Quadro 14.**

<b>Referência do Artigo Publicado</b>	<b>Tarefa de Recomendação</b>	<b>Técnica de Recomendação</b>	<b>Tipo de Algoritmo</b>
Nussbaumer, A., Berthold, M., Dahrendorf, D., Schmitz, H.C., Kravcik, M., Albert, D.: A Mashup Recommender for Creating Personal Learning Environments. <i>Advances in Web-Based Learning – ICWL 2012. Lecture Notes in Computer Science Volume 7558</i> , pp. 79-88. doi: 10.1007/978-3-642-33642-3_9 (2012)	Encontrar bons itens	N.D.	N.D.
Okoye, I., Maull, K., Foster, J., Sumner, T.: Educational Recommendation in an Informal Intentional Learning System. In: Santos O, Boticario J (eds), <i>Educational Recommender Systems and Technologies: Practices and Challenges</i> , pp. 1-23. doi:10.4018/978-1-61350-489-5.ch001 (2012)	Encontrar bons itens	Filtragem híbrida	Baseado em modelo
Salehi, M.: Application of implicit and explicit attribute based collaborative filtering and BIDE for learning resource recommendation, <i>Data &amp; Knowledge Engineering, Volume 87, September 2013</i> , pp. 130-145, ISSN 0169-023X, <a href="http://dx.doi.org/10.1016/j.datak.2013.07.001">http://dx.doi.org/10.1016/j.datak.2013.07.001</a> (2013)	Encontrar bons itens	FC	Baseado em memória e em modelo
Santos, O. C., Saneiro, M., Boticario, J., Rodriguez-Sanchez, C. Towards Interactive Context-Aware Affective Educational Recommendations in Computer Assisted Language Learning. <i>New Review of Hypermedia and Multimedia</i> (accepted)	Recomendar atividade de aprendizagem	Baseada em regras	N.D.
Santos, O.C., Boticario, J.G., Perez-Marin, D.: Extending Web-based Educational Systems with Personalised Support through User Centred Designed Recommendations along the e-Learning Life Cycle. In <i>Science of Computer Programming</i> (2013)	Recomendar atividade de aprendizagem	Filtragem baseada em conhecimento	N.D.
Santos, O.C., Boticario, J.G.: User Centred Design and Educational Data Mining support during the Recommendations Elicitation Process in Social Online Learning Environments. In <i>Expert Systems</i> , in press. DOI: 10.1111/exsy.12041 (2013)	Recomendar atividade de aprendizagem	Filtragem baseada em conhecimento	N.D.
Santos, O.C., Saneiro, M., Salmeron-Majadas, S., Boticario, J.G.: A methodological approach to eliciting affective educational recommendations. In <i>Proceedings of the 14th IEEE International Conference on Advanced Learning Technologies (ICALT14)</i> , 529-533 (2014) doi: 10.1109/ICALT.2014.234	Recomendar atividade de aprendizagem	Filtragem baseada em conhecimento	N.D.
Schoefegger, K., Seitlinger, P., Ley, T.: Towards a user model for personalised recommendations in work-integrated learning: A report on an experimental study with a collaborative tagging system. <i>Procedia Computer Science</i> , 1(2):2829-2838, doi:10.1016/j.procs.2010.08.008 (2010)	Encontrar bons itens; Encontrar pares	FBC	Baseado em modelo

**Continuação do Quadro 14.**

<b>Referência do Artigo Publicado</b>	<b>Tarefa de Recomendação</b>	<b>Técnica de Recomendação</b>	<b>Tipo de Algoritmo</b>
Shelton, B.E., Duffin, J., Wang, Y., Ball, J.: Linking open course wares and open education resources: creating an effective search and recommendation system. <i>Procedia Computer Science</i> , 1(2), pp. 2865-2870 doi:10.1016/j.procs.2010.08.012 (2010)	Encontrar bons itens	FBC	Baseado em modelo
Sicilia, M.A., Garcia-Barriocanal, E., Sanchez-Alonso, S., Cechinel, C.: Exploring user-based recommender results in large learning object repositories: the case of MERLOT. <i>Procedia Computer Science</i> , 1(2), pp. 2859-2864. doi:10.1016/j.procs.2010.08.011 (2010)	Encontrar bons itens	FC	N.D.
Sielis, G.A., Mettouris, C., Tzanavari, A., Papadopoulou, G.A.: Context-Aware Recommendations using Topic Maps Technology for the Enhancement of the Creativity Process. In: Santos O, Boticario J (eds) <i>Educational Recommender Systems and Technologies: Practices and Challenges</i> , pp. 43-66. doi:10.4018/978-1-61350-489-5.ch003 (2012)	Encontrar bons itens; Encontrar pares	Baseada em regras	Baseado em modelo
Tang, TY., Winoto, P., and McCalla, G.: Further Thoughts on Context-Aware Paper Recommendations for Education. Special issue on Recommender Systems for Technology Enhanced Learning: Research Trends & Applications, Springer Berlin (2014)	Encontrar bons itens; Recomendar sequência de itens	Filtragem híbrida	Baseado em memória e em modelo
Thai-Nghe, N., Drumond, L., Horvith, T., Krohn-Grimberghe, A., Nanopoulos, A., Schmidt-Thieme, L.: Factorization Techniques for Predicting Student Performance. In Santos O, Boticario J (eds) <i>Educational Recommender Systems and Technologies: Practices and Challenges</i> , pp. 129-153. doi:10.4018/978-1-61350-489-5.ch006 (2012)	Prever desempenho de aprendizagem	N.D.	Baseado em modelo
Underwood, J.S.: Metis: A Content Map-Based Recommender System for Digital Learning Activities. In: Santos O, Boticario J (eds), <i>Educational Recommender Systems and Technologies: Practices and Challenges</i> , pp. 24-42. doi:10.4018/978-1-61350-489-5.ch002 (2012)	Recomendar sequência de itens	Baseada em regras	Baseado em modelo
Vesin, B., Milicevic, A.K., Ivanovic, M., Budimac, Z.: Applying Recommender Systems and Adaptive Hypermedia for e-Learning Personalization. <i>Computing and Informatics</i> 32(3), pp. 629-659 (2013)	Encontrar bons itens	FBC; Baseada em regras	Baseado em modelo
Wan, X., Okamoto, T.: Utilizing learning process to improve recommender system for group learning support. <i>Neural Computing and Applications</i> 20(5): 611-621 (2011)	Encontrar bons itens; Encontrar pares	FC	Baseado em memória
Wang, F.-H.: On extracting recommendation knowledge for personalized web-based learning based on ant colony optimization with segmented-goal and meta-control strategies. <i>Expert Syst. Appl.</i> 39(7), pp. 6446-6453 (2012)	Recomendar sequência de itens	Baseada em grafo	N.D.

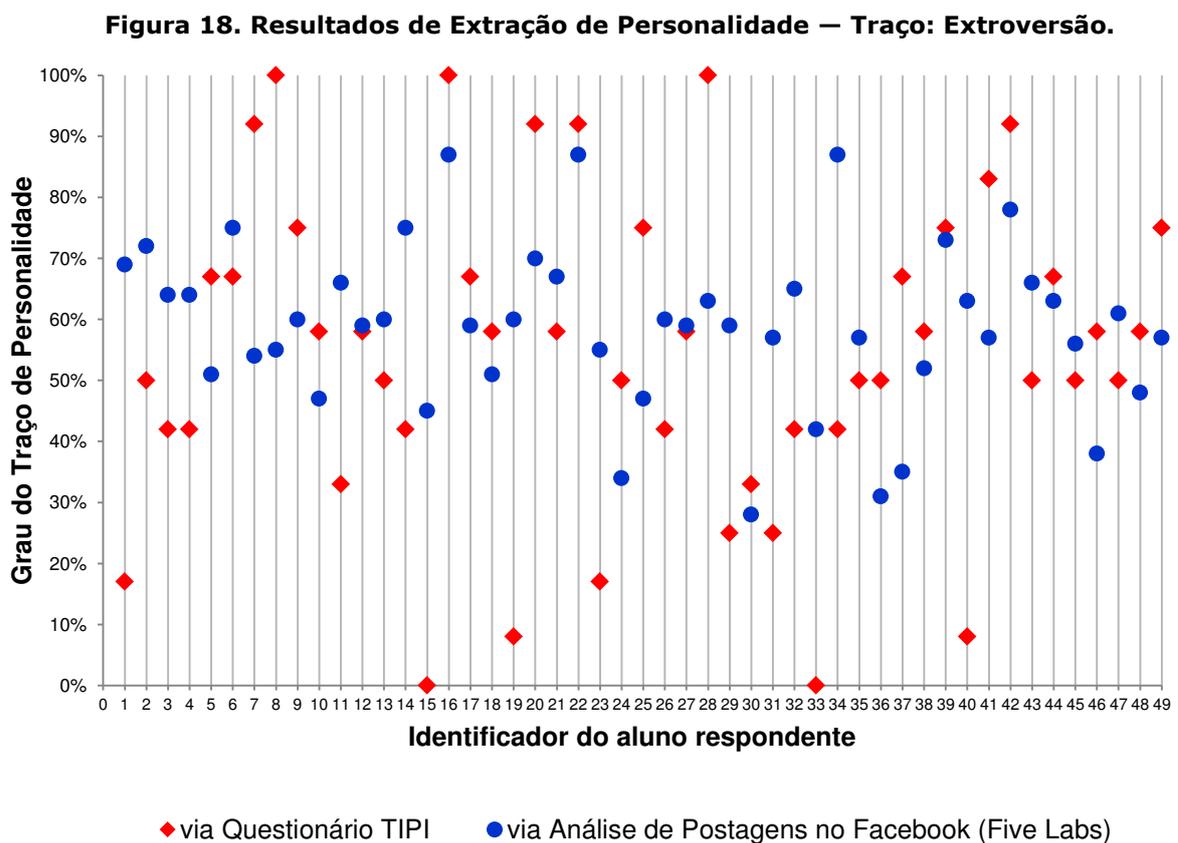
**Continuação do Quadro 14.**

<b>Referência do Artigo Publicado</b>	<b>Tarefa de Recomendação</b>	<b>Técnica de Recomendação</b>	<b>Tipo de Algoritmo</b>
Wang, S.L., Wu, C.Y. Application of context-aware and personalized recommendation to implement an adaptive ubiquitous learning system. <i>Expert Systems with Applications</i> , 38(9), 10831-10838 (2011)	Encontrar bons itens	FC	N.D.
Wang, Y., Sumiya, K.: Semantic ranking of lecture slides based on conceptual relationship and presentational structure. <i>Procedia Computer Science</i> , 1(2), pp. 2801-2810. doi:10.1016/j.procs.2010.08.005 (2010)	Encontrar bons itens	N.D.	N.D.
Yu, Z., Zhou, X., Shu, L.: Towards a semantic infrastructure for context-aware e-learning. <i>Multimedia Tools Appl.</i> 47(1): 71-86 (2010)	Encontrar bons itens	FBC	Baseado em modelo
Zaldivar, V.A., Burgos, D., Pardo, A.: Meta-Rule Based Recommender Systems for Educational Applications. In: Santos O, Boticario J (eds) <i>Educational Recommender Systems and Technologies: Practices and Challenges</i> , pp. 211-231. doi:10.4018/978-1-61350-489-5.ch009 (2012)	Encontrar bons itens	Baseada em regras; Seleccionada manualmente	Baseado em modelo
Zapata, A., Menndez, V.H., Prieto, M.E., Romero, C.: A framework for recommendation in learning object repositories: An example of application in civil engineering. <i>Advances in Engineering Software</i> 56: 1-14 (2013)	Encontrar bons itens	Filtragem híbrida	Baseado em memória e em modelo
Zhou, M., Xu, Y.: Challenges to Use Recommender Systems to Enhance Meta-Cognitive Functioning in Online Learners. In: Santos, O., Boticario, J. (eds) <i>Educational Recommender Systems and Technologies: Practices and Challenges</i> , pp. 282-301. doi:10.4018/978-1-61350-489-5.ch012 (2012)	Encontrar bons itens; Recomendar sequência de itens	Baseada em regras	Baseado em memória e em modelo

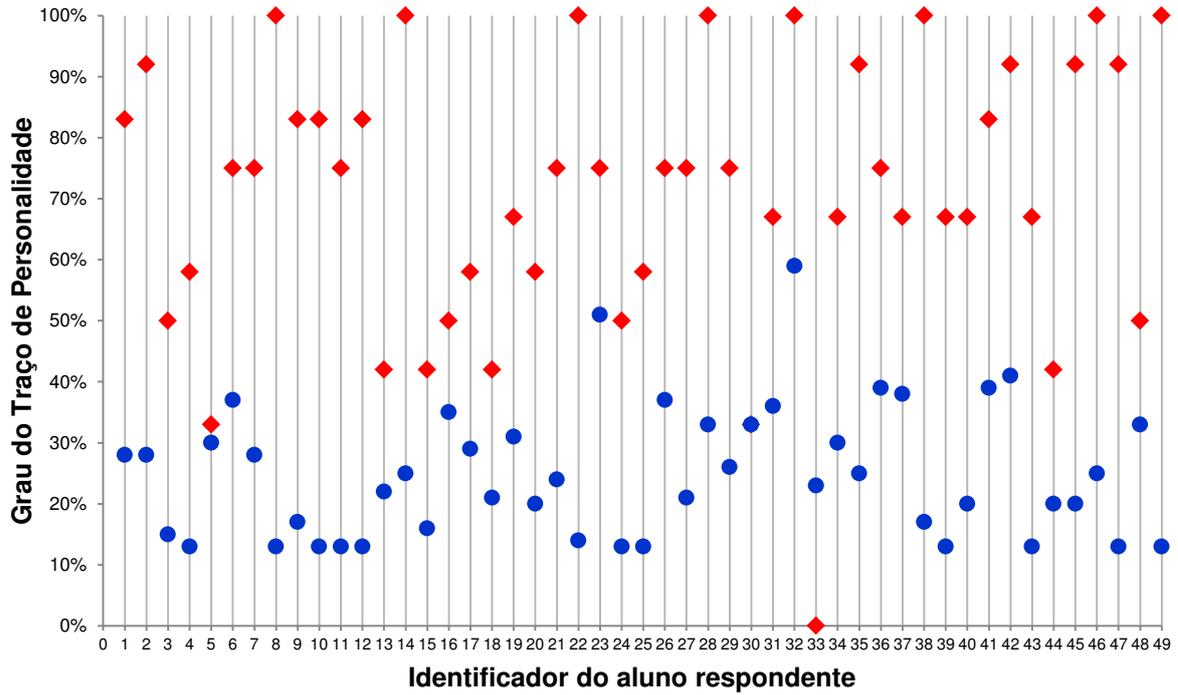
# Apêndice C

## Traços de Personalidade de alunos da ETER via TIPI e via Five Labs

Nas Figuras 18 a 22, são apresentados os resultados relativos aos Traços de Personalidade, obtidos via TIPI (em vermelho) e via Five Labs (em azul), para cada aluno respondente da Investigação Empírica 1 (Seção 5.1).

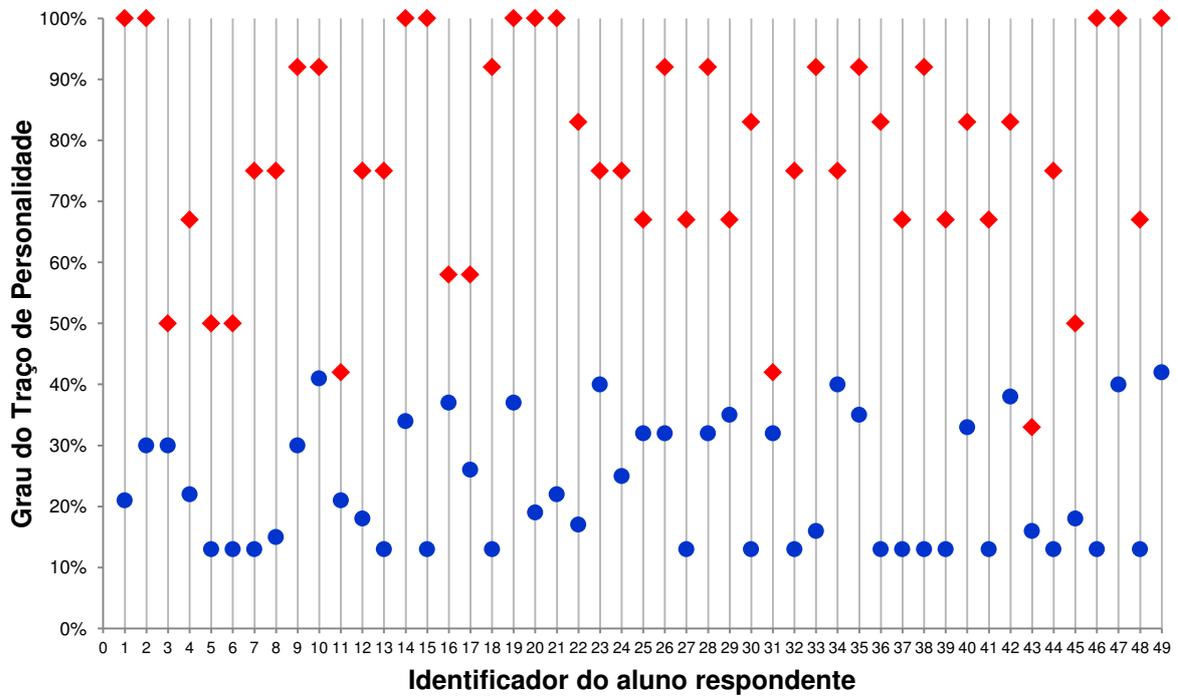


**Figura 19. Resultados de Extração de Personalidade – Traço: Socialização.**



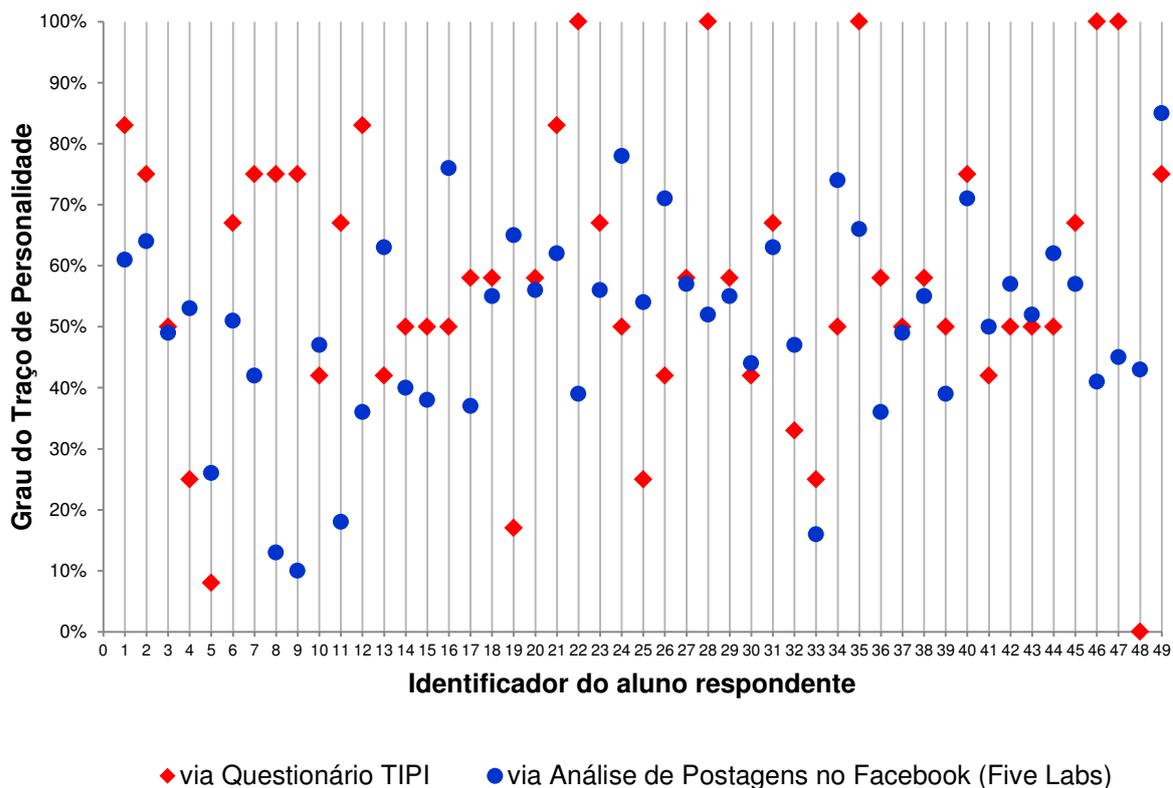
◆ via Questionário TIPI     ● via Análise de Postagens no Facebook (Five Labs)

**Figura 20. Resultados de Extração de Personalidade – Traço: Realização.**

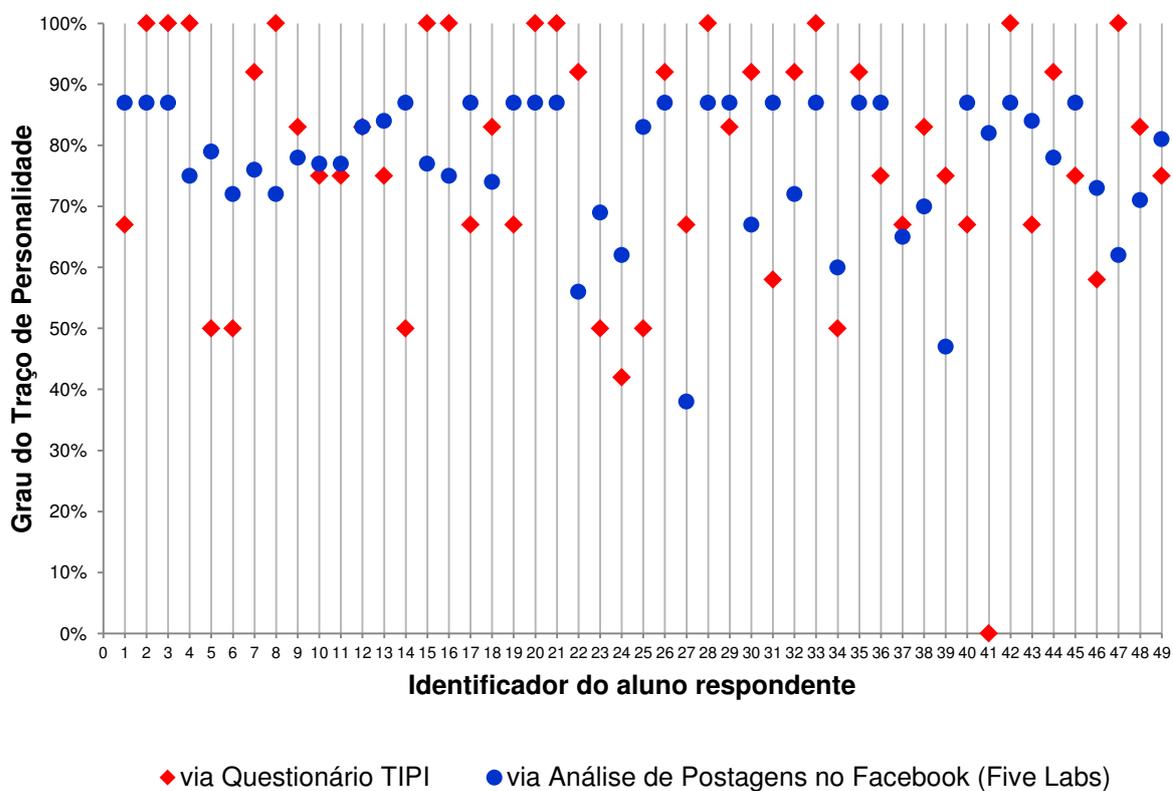


◆ via Questionário TIPI     ● via Análise de Postagens no Facebook (Five Labs)

**Figura 21. Resultados de Extração de Personalidade — Traço: Neuroticismo.**



**Figura 22. Resultados de Extração de Personalidade — Traço: Abertura.**



# Apêndice D

## Perfis de Estilos de Aprendizagem de alunos da ETER

Quadro 15. Perfis de 61 alunos da ETER relativos a EA.

ID	Dimensão Processamento		Dimensão Percepção		Dimensão Entrada		Dimensão Compreensão	
	Ativo	Reflexivo	Sensorial	Intuitivo	Visual	Verbal	Sequencial	Global
01	73%	27%	91%	9%	64%	36%	64%	36%
02	73%	27%	45%	55%	64%	36%	36%	64%
03	64%	36%	64%	36%	36%	64%	36%	64%
04	64%	36%	64%	36%	82%	18%	55%	45%
05	27%	73%	82%	18%	82%	18%	55%	45%
06	64%	36%	36%	64%	45%	55%	45%	55%
07	73%	27%	9%	91%	36%	64%	73%	27%
08	36%	64%	55%	45%	73%	27%	91%	9%
09	73%	27%	64%	36%	36%	64%	55%	45%
10	73%	27%	91%	9%	45%	55%	73%	27%
11	64%	36%	55%	45%	73%	27%	55%	45%
12	73%	27%	73%	27%	55%	45%	91%	9%
13	64%	36%	82%	18%	64%	36%	45%	55%
14	45%	55%	73%	27%	82%	18%	73%	27%
15	73%	27%	55%	45%	27%	73%	64%	36%
16	64%	36%	82%	18%	55%	45%	55%	45%
17	55%	45%	73%	27%	55%	45%	82%	18%
18	82%	18%	27%	73%	55%	45%	55%	45%
19	55%	45%	45%	55%	36%	64%	64%	36%
20	73%	27%	82%	18%	64%	36%	82%	18%
21	36%	64%	73%	27%	45%	55%	36%	64%
22	45%	55%	55%	45%	82%	18%	45%	55%
23	82%	18%	45%	55%	27%	73%	55%	45%
24	64%	36%	64%	36%	55%	45%	73%	27%
25	18%	82%	82%	18%	18%	82%	91%	9%
26	64%	36%	73%	27%	64%	36%	73%	27%
27	55%	45%	55%	45%	73%	27%	73%	27%
28	64%	36%	55%	45%	27%	73%	55%	45%
29	36%	64%	82%	18%	55%	45%	45%	55%
30	91%	9%	55%	45%	55%	45%	27%	73%

Continuação do Quadro 15.

ID	Dimensão Processamento		Dimensão Percepção		Dimensão Entrada		Dimensão Compreensão	
	Ativo	Reflexivo	Sensorial	Intuitivo	Visual	Verbal	Sequencial	Global
31	18%	82%	82%	18%	55%	45%	73%	27%
32	36%	64%	64%	36%	27%	73%	64%	36%
33	27%	73%	55%	45%	55%	45%	45%	55%
34	36%	64%	64%	36%	73%	27%	64%	36%
35	36%	64%	55%	45%	82%	18%	64%	36%
36	55%	45%	100%	0%	82%	18%	91%	9%
37	64%	36%	73%	27%	64%	36%	55%	45%
38	45%	55%	82%	18%	64%	36%	45%	55%
39	55%	45%	91%	9%	36%	64%	73%	27%
40	36%	64%	73%	27%	55%	45%	45%	55%
41	36%	64%	100%	0%	73%	27%	45%	55%
42	27%	73%	73%	27%	73%	27%	64%	36%
43	64%	36%	55%	45%	55%	45%	64%	36%
44	64%	36%	64%	36%	91%	9%	82%	18%
45	64%	36%	55%	45%	100%	0%	82%	18%
46	45%	55%	55%	45%	73%	27%	55%	45%
47	18%	82%	9%	91%	82%	18%	27%	73%
48	64%	36%	73%	27%	73%	27%	18%	82%
49	55%	45%	55%	45%	73%	27%	55%	45%
50	64%	36%	64%	36%	64%	36%	55%	45%
51	64%	36%	73%	27%	55%	45%	55%	45%
52	55%	45%	73%	27%	36%	64%	45%	55%
53	55%	45%	82%	18%	55%	45%	73%	27%
54	18%	82%	64%	36%	100%	0%	82%	18%
55	45%	55%	36%	64%	36%	64%	82%	18%
56	73%	27%	64%	36%	73%	27%	73%	27%
57	36%	64%	55%	45%	64%	36%	55%	45%
58	91%	9%	55%	45%	64%	36%	73%	27%
59	45%	55%	73%	27%	64%	36%	64%	36%
60	45%	55%	55%	45%	18%	82%	82%	18%
61	27%	73%	27%	73%	45%	55%	64%	36%

# Apêndice E

## Questionário sobre Características de Objetos de Aprendizagem

A partir das seguintes informações sobre Objetos de Aprendizagem (OA), classifique os OA descritos com base em suas características. Considere que todos os OA contemplam o mesmo assunto, mudando apenas a forma como é abordado.

### **INFORMAÇÕES IMPORTANTES:**

Um OA pode ser definido como um recurso a ser utilizado no processo de ensino–aprendizagem, possuindo diversas características. Essas características podem diferir em relação a Formato, Estrutura, Tipo de Recurso de Aprendizagem, Tipo de Interatividade, dentre outros aspectos.

- Exemplos de Formato são: áudio, imagem, texto, vídeo, página Web.
- Exemplos de Tipo de Recurso da Aprendizagem são: exercício, experimento, figura, gráfico, narrativa, palestra, tabela.
- Em relação à Estrutura, um OA em geral pode ser Linear (segue etapas contínuas) ou Rede (aborda uma visão geral).
- Sobre o Tipo de Interatividade, pode-se classificar os OA como Expositivo (o trabalho do aprendiz consiste principalmente em absorver o conteúdo exposto a ele), Ativo (o conteúdo induz diretamente ação produtiva por parte do aprendiz) ou Misto (mesclagem dessas duas características).

Com base nessas informações, classifique de 1 a 5 estrelas os OA que teriam as características a seguir. A classificação (nota) deve ser de acordo com sua preferência pela combinação de características apresentada. Alguns OA são semelhantes, mas apresentam pelo menos uma característica diferente. Em caso de dúvida, volte para as informações anteriores para lembrar a diferença e, caso a característica que diferencie os OA não tenha muita importância para você, sugere-se que atribua a mesma classificação.

1) Tipo de recurso: PALESTRA; Formato: ÁUDIO; Estrutura: LINEAR; Tipo de interatividade: EXPOSITIVO.



2) Tipo de recurso: PALESTRA; Formato: ÁUDIO; Estrutura: REDE; Tipo de interatividade: EXPOSITIVO.



3) Tipo de recurso: NARRATIVA; Formato: TEXTO; Estrutura: LINEAR; Tipo de interatividade: MISTO.



4) Tipo de recurso: NARRATIVA; Formato: TEXTO; Estrutura: REDE; Tipo de interatividade: MISTO.



5) Tipo de recurso: GRÁFICO; Formato: IMAGEM; Estrutura: LINEAR; Tipo de interatividade: EXPOSITIVO.



6) Tipo de recurso: GRÁFICO; Formato: IMAGEM; Estrutura: REDE; Tipo de interatividade: EXPOSITIVO.



7) Tipo de recurso: GRÁFICO; Formato: IMAGEM; Estrutura: LINEAR; Tipo de interatividade: MISTO.



8) Tipo de recurso: FIGURA; Formato: IMAGEM; Estrutura: LINEAR; Tipo de interatividade: MISTO.



9) Tipo de recurso: FIGURA; Formato: IMAGEM; Estrutura: REDE; Tipo de interatividade: MISTO.



10) Tipo de recurso: TABELA; Formato: TEXTO; Estrutura: REDE; Tipo de interatividade: MISTO.



11) Tipo de recurso: TABELA; Formato: PÁGINA WEB; Estrutura: REDE; Tipo de interatividade: MISTO.



12) Tipo de recurso: TABELA; Formato: PÁGINA WEB; Estrutura: REDE; Tipo de interatividade: EXPOSITIVO.



13) Tipo de recurso: TABELA; Formato: VÍDEO; Estrutura: REDE; Tipo de interatividade: MISTO.



14) Tipo de recurso: EXPERIMENTO; Formato: TEXTO; Estrutura: LINEAR; Tipo de interatividade: ATIVO.



15) Tipo de recurso: EXPERIMENTO; Formato: PÁGINA WEB; Estrutura: LINEAR; Tipo de interatividade: ATIVO.



16) Tipo de recurso: EXPERIMENTO; Formato: PÁGINA WEB; Estrutura: LINEAR; Tipo de interatividade: MISTO.



17) Tipo de recurso: EXERCÍCIO; Formato: TEXTO; Estrutura: REDE; Tipo de interatividade: ATIVO.



18) Tipo de recurso: EXERCÍCIO; Formato: PÁGINA WEB; Estrutura: REDE; Tipo de interatividade: MISTO.



19) Tipo de recurso: EXERCÍCIO; Formato: PÁGINA WEB; Estrutura: LINEAR; Tipo de interatividade: MISTO.



20) Tipo de recurso: EXERCÍCIO; Formato: PÁGINA WEB; Estrutura: REDE; Tipo de interatividade: ATIVO.



21) Tipo de recurso: EXERCÍCIO; Formato: PÁGINA WEB; Estrutura: LINEAR; Tipo de interatividade: ATIVO.



22) Tipo de recurso: EXERCÍCIO; Formato: VÍDEO; Estrutura: REDE; Tipo de interatividade: MISTO.



23) Tipo de recurso: EXERCÍCIO; Formato: VÍDEO; Estrutura: REDE; Tipo de interatividade: ATIVO.



24) Tipo de recurso: EXERCÍCIO; Formato: VÍDEO; Estrutura: LINEAR; Tipo de interatividade: MISTO.



25) Tipo de recurso: EXERCÍCIO; Formato: VÍDEO; Estrutura: LINEAR; Tipo de interatividade: ATIVO.



# Apêndice F

## Questionário para Opiniões sobre o Experimento

Para as seguintes afirmativas, marque em cada escala o grau que melhor representa sua opinião.

1. Eu gosto da ideia de receber recomendações de materiais educacionais de acordo com minhas preferências e minha personalidade.

Discordo Fortemente    1   2   3   4   5    Concordo Fortemente  
           

2. Gostei de usar uma ferramenta que, via análise de meu perfil no Facebook, apresenta aspectos de minha personalidade.

Discordo Fortemente    1   2   3   4   5    Concordo Fortemente  
           

3. Contanto que o objetivo seja melhorar as recomendações personalizadas de materiais educacionais, eu autorizaria uma ferramenta analisar minhas postagens no Facebook para extrair minha personalidade.

Discordo Fortemente    1   2   3   4   5    Concordo Fortemente  
           

4. Fiquei curioso e gostaria de receber o resultado do questionário sobre Estilos de Aprendizagem.

Discordo Fortemente    1   2   3   4   5    Concordo Fortemente  
           

5. Uma vez que o objetivo seja melhorar recomendações de materiais educacionais de acordo com minhas preferências, eu não me importaria em preencher o questionário sobre Estilos de Aprendizagem.

Discordo Fortemente    1   2   3   4   5    Concordo Fortemente

# Apêndice G

## Análise Estatística

Neste apêndice, são apresentados detalhes da análise estatística relativa à Investigação Empírica 3 (Seção 5.3), que consiste no experimento principal da pesquisa descrita neste documento.

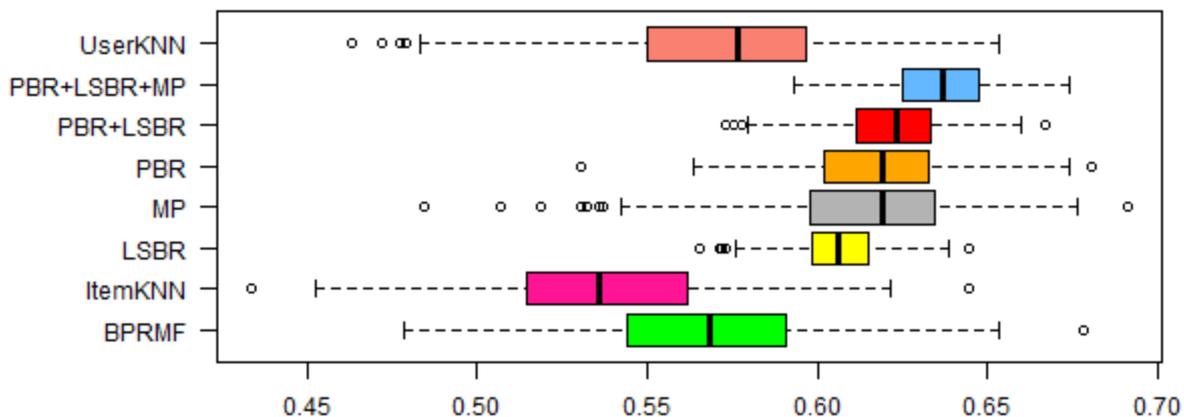
Inicialmente são expostos os *boxplots* para os dados relativos às métricas AUC, MAP, MRR, NDCG, P@5 e R@5, por algoritmo (ItemKNN, UserKNN, BPRMF, MP, LSBR, PBR, PBR+LSBR e PBR+LSBR+MP). Em seguida, são apresentadas as análises referentes à normalidade e à homoscedasticidade dos dados. Por fim, são expostos os resultados dos testes estatísticos realizados (ANOVA, Kruskal-Wallis, T e Mann-Whitney U).

### **Boxplots**

Os *boxplots* apresentados nas Figuras 23 a 34 ilustram a análise descritiva dos dados obtidos para cada uma das variáveis dependentes citadas na Subseção 5.3.2. Para facilitar as comparações visualmente, cada algoritmo está associado a uma cor, variando-se o tom quando os algoritmos são comparados por nível do percentual dos dados utilizado para a base de treinamento.

Analisando os *boxplots*, percebe-se que os algoritmos apresentam desempenho diferente, indiciando que as hipóteses  $H1_0$ ,  $H2_0$ ,  $H3_0$ ,  $H4_0$ ,  $H5_0$  e  $H6_0$  podem ser rejeitadas. Além disso, os *boxplots* das Figuras 24, 26, 28, 30, 32 e 34 demonstram que o percentual dos dados utilizado para a base de treinamento tem grande influência quanto às métricas (sendo a variação mais claramente visível em relação à métrica R@5 — Figura 34). Portanto, foi necessário considerar a blocagem dos dados por esse fator e realizar a análise separadamente nesses blocos.

**Figura 23. Boxplots para os dados relativos à métrica AUC por algoritmo.**



**Figura 24. Boxplots para os dados relativos à métrica AUC por algoritmo e percentual dos dados utilizado para a base de treinamento.**

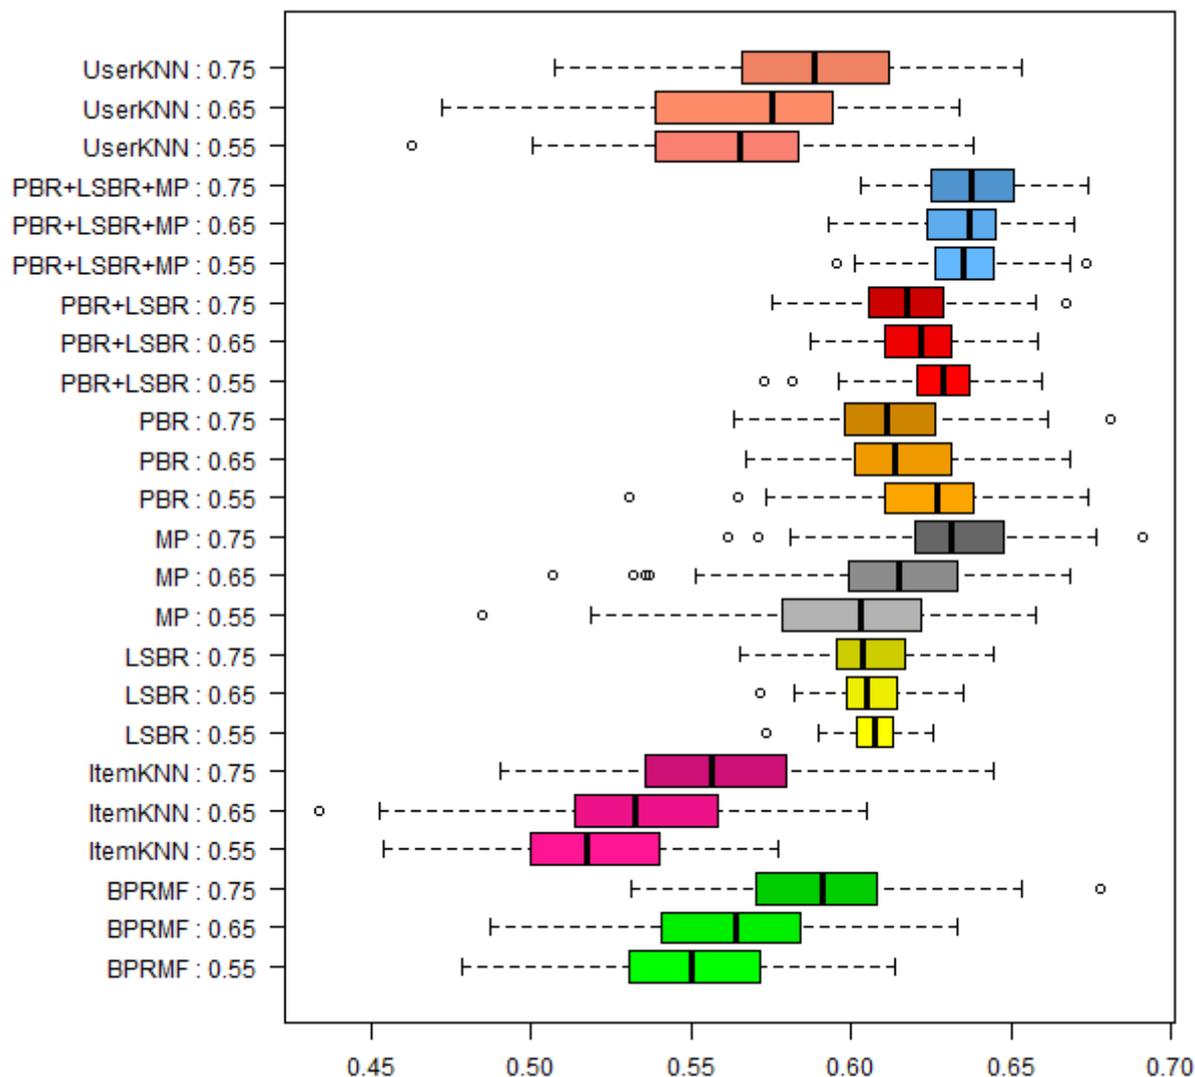


Figura 25. *Boxplots* para os dados relativos à métrica MAP por algoritmo.

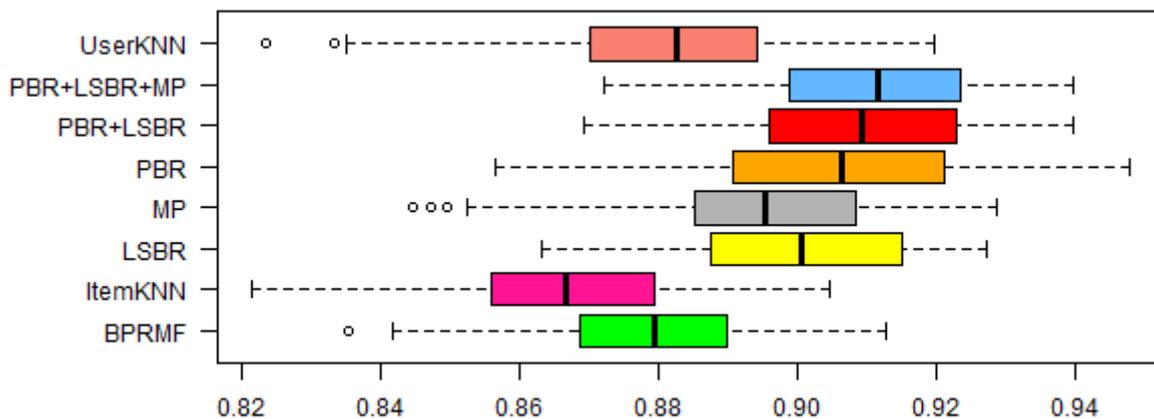
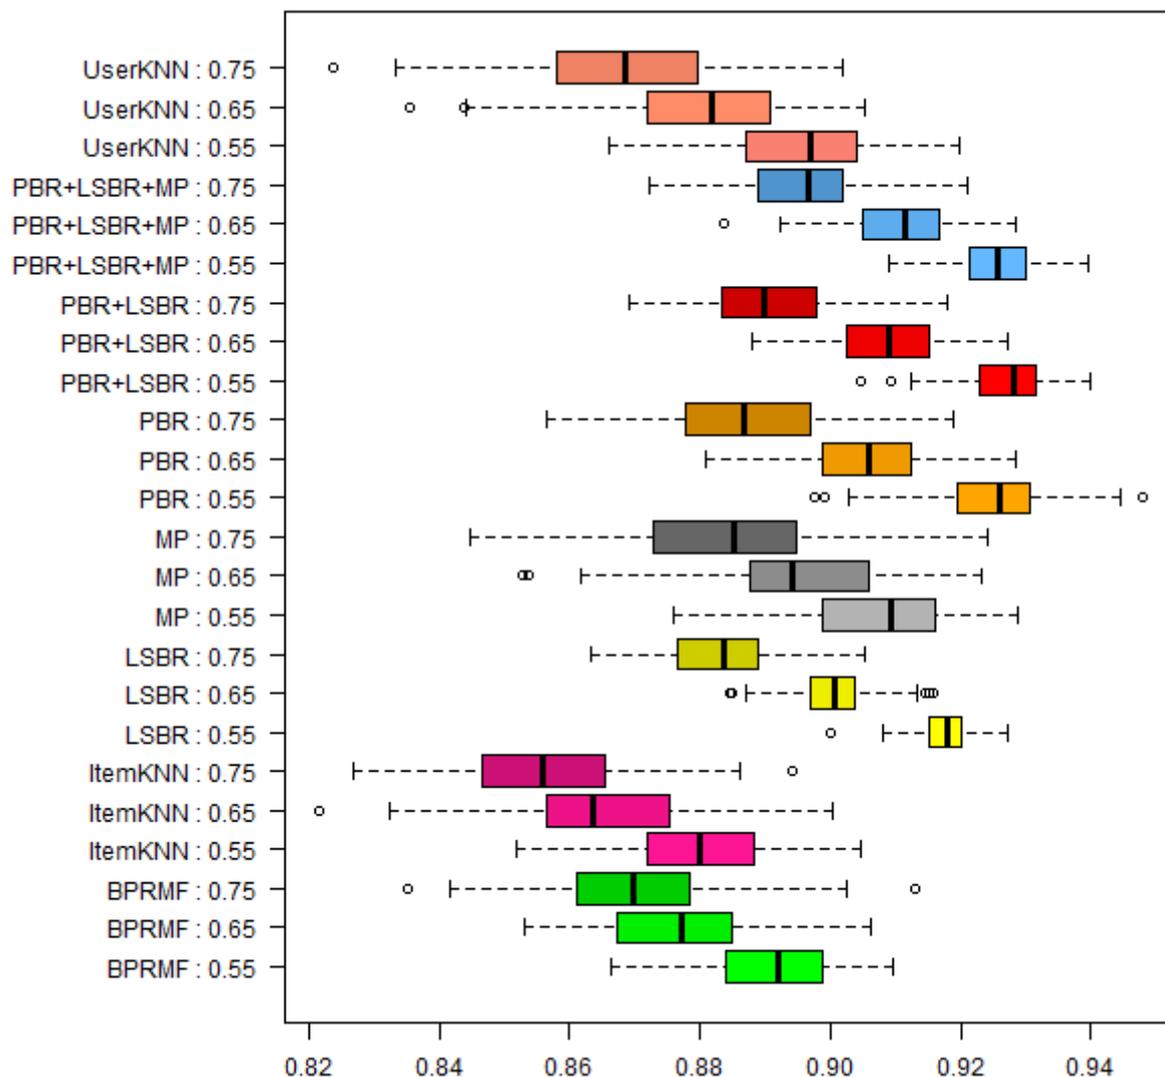
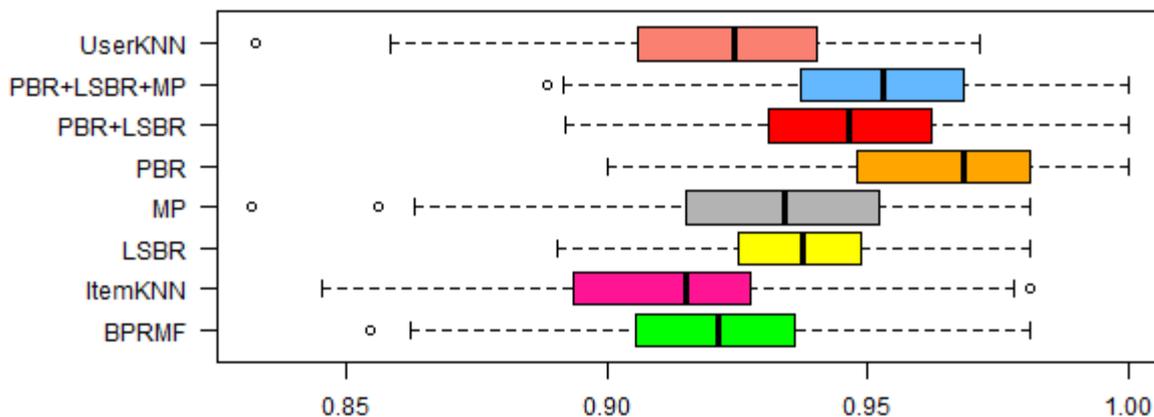


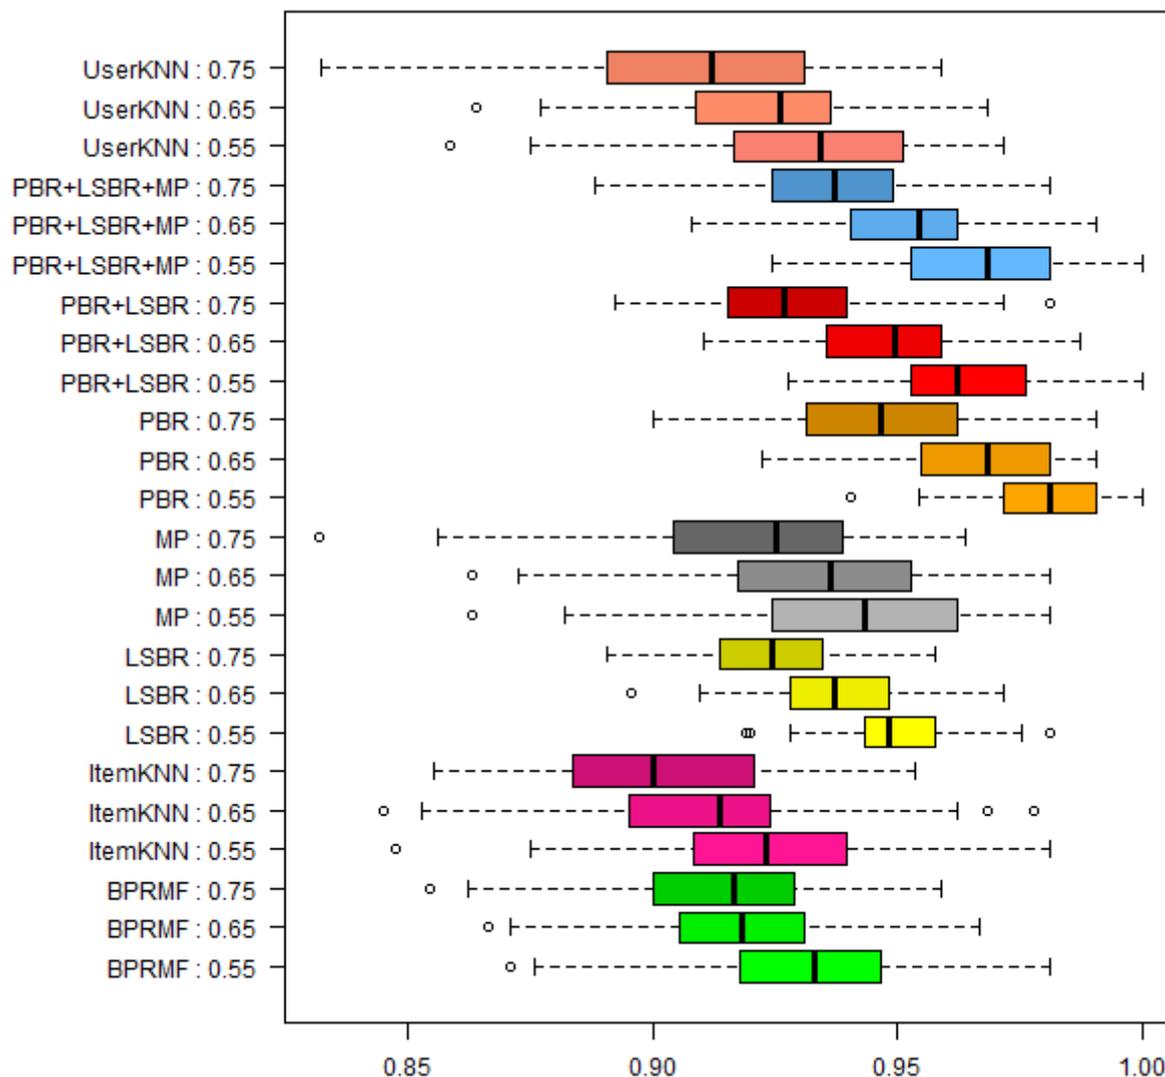
Figura 26. *Boxplots* para os dados relativos à métrica MAP por algoritmo e percentual dos dados utilizado para a base de treinamento.



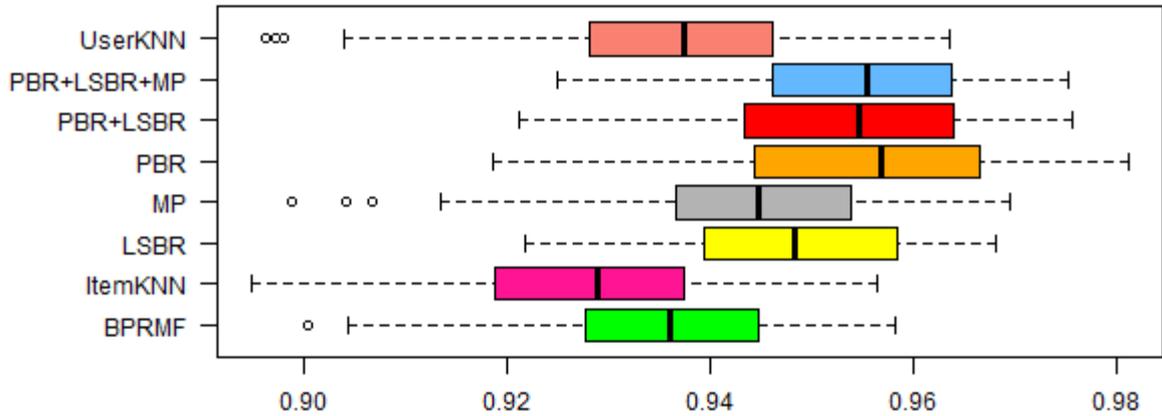
**Figura 27. Boxplots para os dados relativos à métrica MRR por algoritmo.**



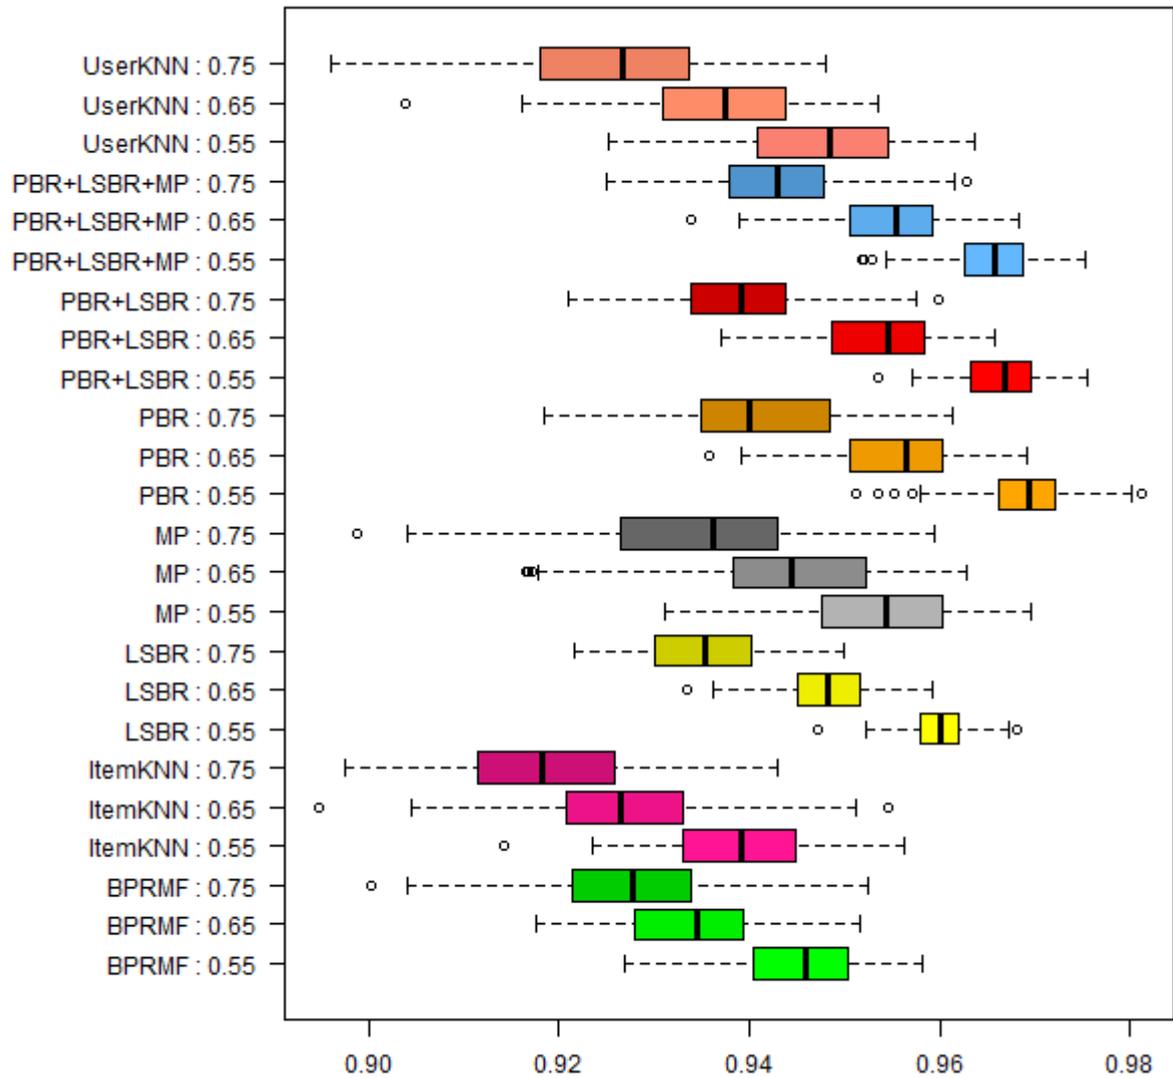
**Figura 28. Boxplots para os dados relativos à métrica MRR por algoritmo e percentual dos dados utilizado para a base de treinamento.**



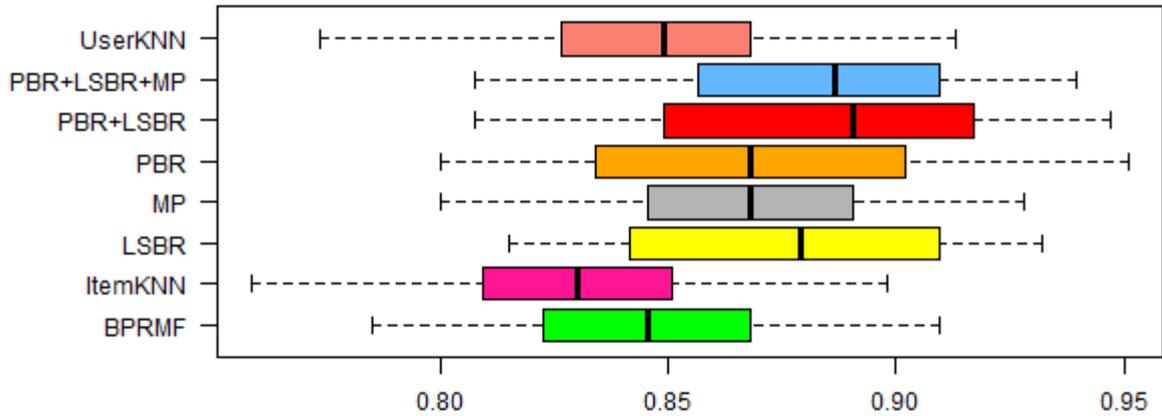
**Figura 29. Boxplots para os dados relativos à métrica NDCG por algoritmo.**



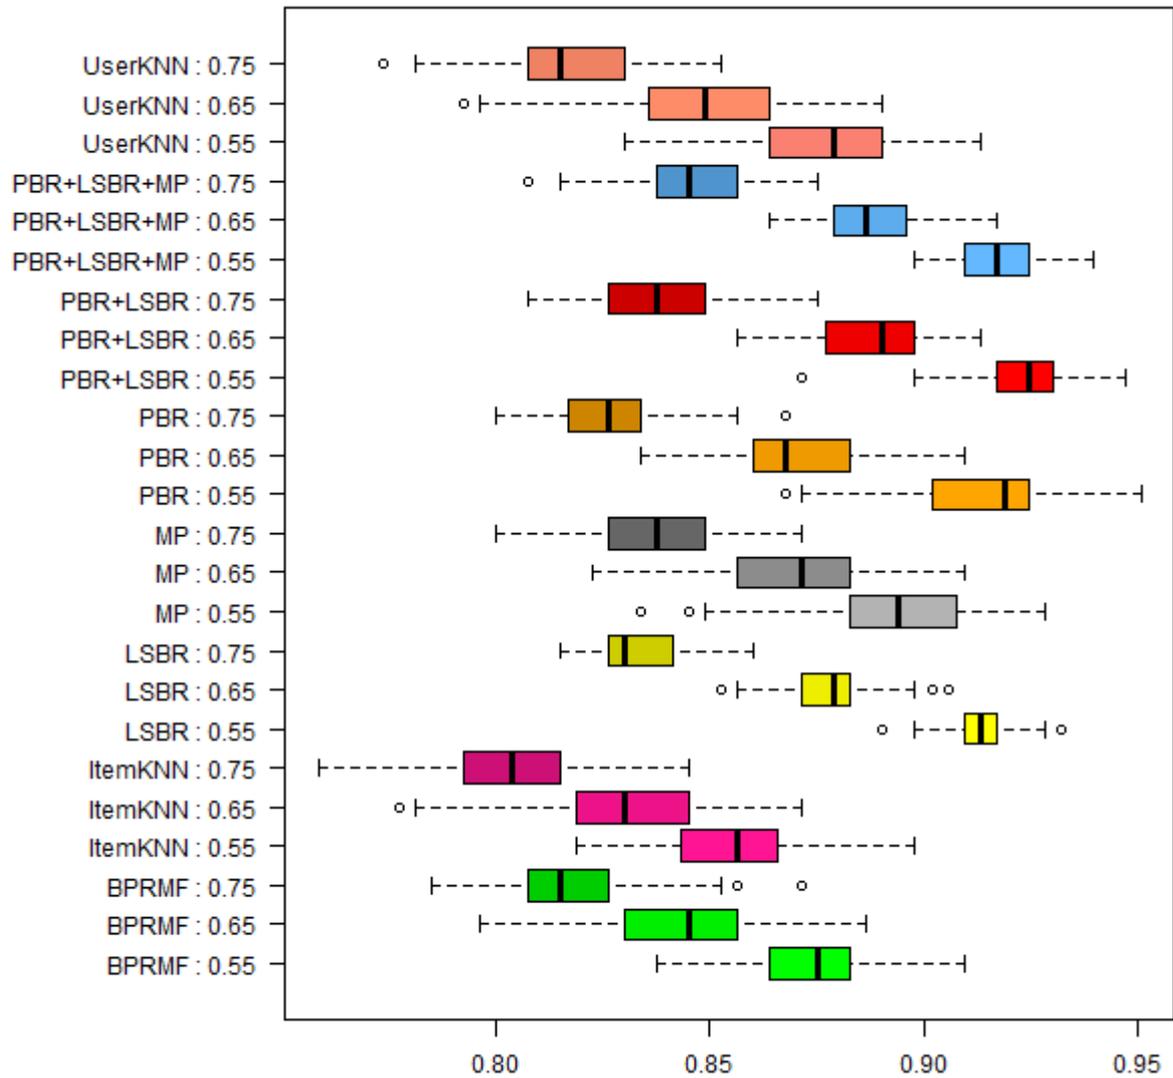
**Figura 30. Boxplots para os dados relativos à métrica NDCG por algoritmo e percentual dos dados utilizado para a base de treinamento.**



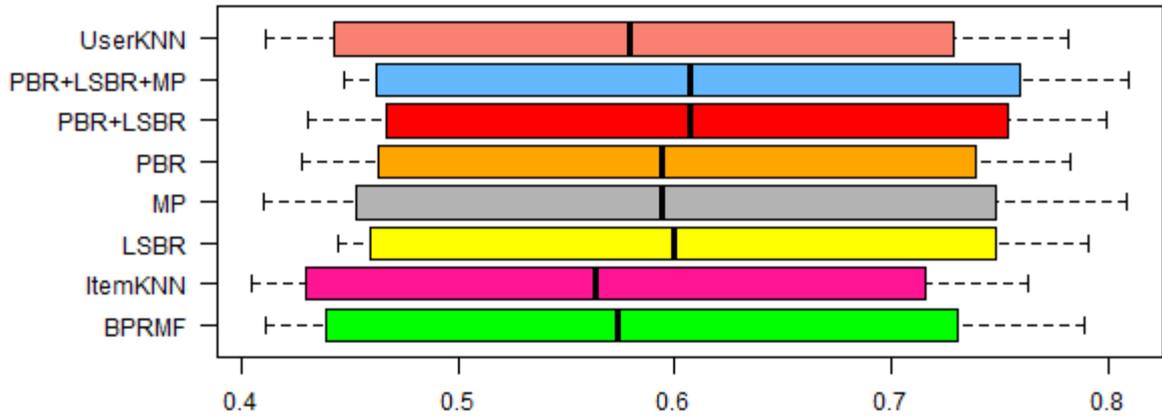
**Figura 31. Boxplots para os dados relativos à métrica P@5 por algoritmo.**



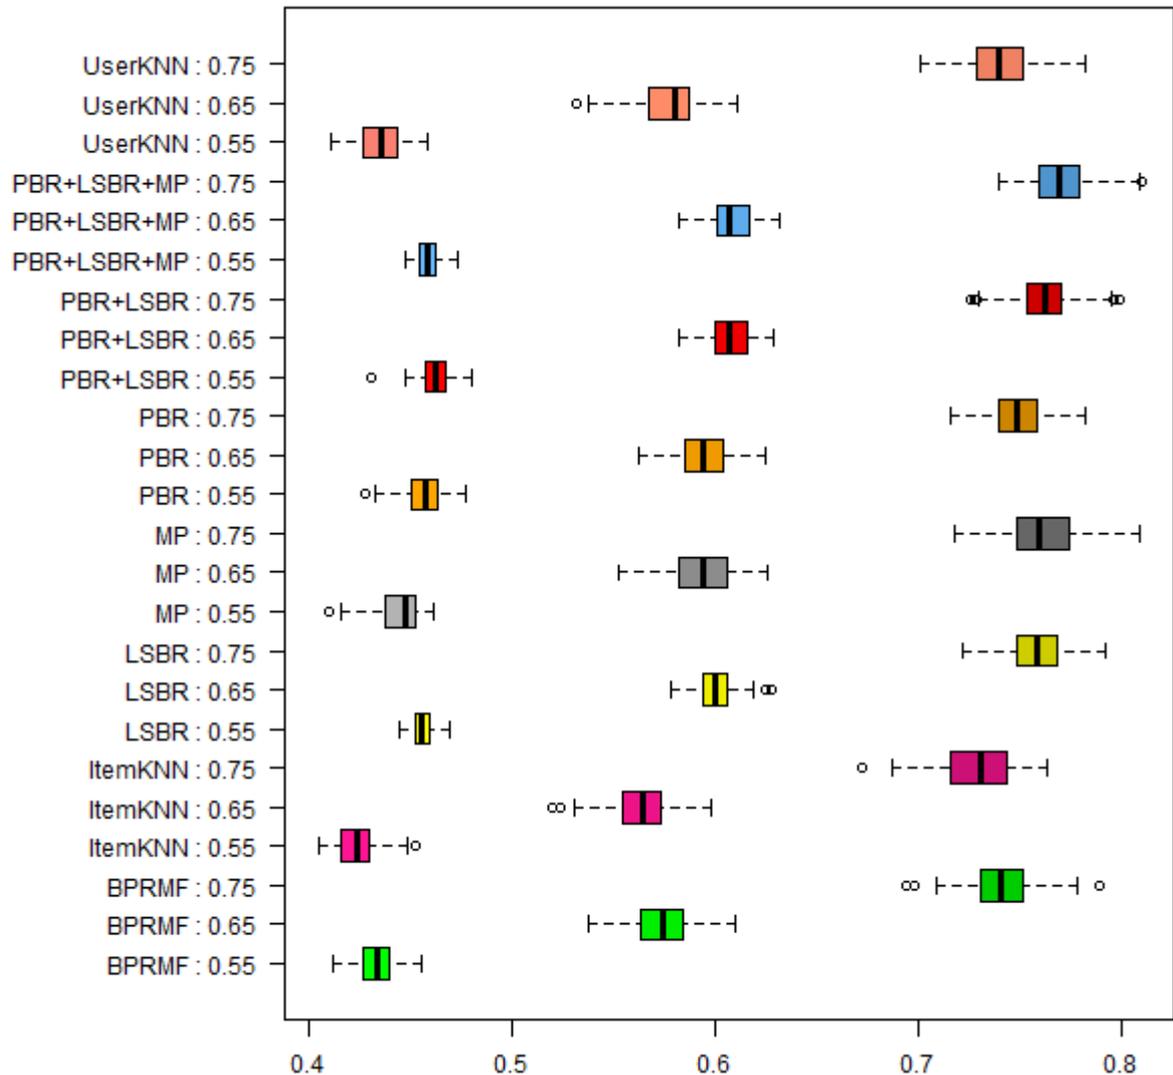
**Figura 32. Boxplots para os dados relativos à métrica P@5 por algoritmo e percentual dos dados utilizado para a base de treinamento.**



**Figura 33. Boxplots para os dados relativos à métrica R@5 por algoritmo.**



**Figura 34. Boxplots para os dados relativos à métrica R@5 por algoritmo e percentual dos dados utilizado para a base de treinamento.**



## Análise da Normalidade dos Dados

Para confirmar se há diferenças, com significância estatística, entre os algoritmos, foi verificada a normalidade dos dados para decidir pela realização de um teste estatístico paramétrico ou não paramétrico.

Para avaliar a normalidade pelos valores de Kurtosis e Skewness, foi comparado o valor de Zskewness e de Zkurtosis com um valor crítico de uma distribuição Z, sob um nível de significância de 0,05 (ou seja,  $\mp 1,960$ ). Com base nos valores do Quadro 16 ao Quadro 21, é possível notar que todos os valores de Zkurtosis (relacionados ao achatamento semelhante à distribuição normal) são maiores que 1,960. Por outro lado, em relação à Zskewness (simetria característica da distribuição normal), alguns valores não estão no intervalo  $[-1,960; 1,960]$  — destacados em amarelo do Quadro 16 ao Quadro 21. Assim, é possível dizer que a maioria das amostras são simétricas, mas isso não garante normalidade.

Os testes de Shapiro-Wilk e Anderson-Darling consideram as seguintes hipóteses:

- Hipótese Nula ( $H_0$ ): Os dados vêm de uma população que tem distribuição normal.
- Hipótese Alternativa ( $H_1$ ): Os dados não vêm de uma população que tem distribuição normal.

O teste de Shapiro-Wilk calcula uma estatística W e o p-valor é a probabilidade de obter o valor computado para estatística sendo  $H_0$  verdadeira. O teste de Anderson-Darling computa a estatística A e o p-valor é a probabilidade dessa estatística ter o valor computado caso  $H_0$  seja verdade. Percebe-se, a partir do Quadro 16 ao Quadro 21, que a maioria dos p-valores foram maiores que 0,05. Para esses casos, não se rejeita  $H_0$  e é possível dizer, com 95% de confiança, que os dados vêm de uma população que tem distribuição normal. Todavia, houve casos em que se rejeitou  $H_0$ , sendo possível dizer, com 95% de confiança, que os dados não seguem uma distribuição normal. Tais casos são destacados em amarelo dos Quadro 16 ao Quadro 21.

**Quadro 16. Aspectos de normalidade dos dados relativos à métrica AUC.**

%Treinamento	Algoritmo	Zkurtosis	Zskewness	Shapiro–Wilk		Anderson–Darling	
				P-valor	W	P-valor	A
55%	BPRMF	5,03318	-0,13430	0,72240	0,99072	0,73446	0,25116
	ItemKNN	4,88597	-0,38098	0,45231	0,98722	0,70787	0,25906
	LSBR	8,88379	-2,22476	0,04874	0,97444	0,75997	0,24340
	MP	8,65381	-3,34096	0,00211	0,95602	0,01703	0,93564
	PBR	10,82584	-3,69033	0,00137	0,95325	0,00692	1,09334
	PBR+LSBR	10,04690	-3,69256	0,00162	0,95434	0,02788	0,84952
	PBR+LSBR+MP	6,06358	-0,50434	0,97310	0,99492	0,89312	0,19245
	UserKNN	5,79062	-1,07416	0,36218	0,98580	0,20407	0,50011
65%	BPRMF	5,02000	-0,72215	0,38793	0,98623	0,11196	0,60667
	ItemKNN	6,14840	-1,03335	0,77129	0,99134	0,88529	0,19778
	LSBR	5,84074	0,35513	0,70978	0,99056	0,57191	0,30149
	MP	8,16197	-3,35099	0,00189	0,95531	0,00358	1,20889
	PBR	5,59129	1,60795	0,12310	0,97957	0,07167	0,68453
	PBR+LSBR	5,57854	0,45184	0,80024	0,99172	0,89078	0,19398
	PBR+LSBR+MP	5,39512	-0,40074	0,44419	0,98710	0,58674	0,29626
	UserKNN	6,22788	-2,41993	0,00337	0,95891	0,00154	1,35645
75%	BPRMF	6,46048	0,93552	0,66089	0,98995	0,89642	0,19035
	ItemKNN	5,47387	0,80946	0,89479	0,99311	0,95757	0,15302
	LSBR	5,54418	0,27303	0,82396	0,99204	0,44938	0,35692
	MP	6,42869	-1,13217	0,38638	0,98620	0,27098	0,44985
	PBR	6,64783	1,40510	0,56567	0,98876	0,71603	0,25665
	PBR+LSBR	5,91267	-0,16524	0,86187	0,99259	0,93707	0,16646
	PBR+LSBR+MP	4,85770	0,26424	0,28526	0,98436	0,66247	0,27247
	UserKNN	5,41870	-0,79692	0,66063	0,98995	0,67740	0,26805

**Quadro 17. Aspectos de normalidade dos dados relativos à métrica MAP.**

%Treinamento	Algoritmo	Zkurtosis	Zskewness	Shapiro–Wilk		Anderson–Darling	
				P-valor	W	P-valor	A
55%	BPRMF	4,76222	-0,87803	0,20725	0,98250	0,27713	0,44582
	ItemKNN	5,07397	-0,27867	0,69681	0,99040	0,53189	0,31797
	LSBR	10,14976	-2,63178	0,02213	0,97001	0,28143	0,44306
	MP	4,91458	-1,96220	0,00859	0,96454	0,00622	1,11190
	PBR	7,83400	-2,07567	0,05689	0,97529	0,05775	0,72224
	PBR+LSBR	7,21692	-2,61662	0,02859	0,97145	0,05514	0,73032
	PBR+LSBR+MP	5,99884	-0,79959	0,62021	0,98945	0,64610	0,27737
	UserKNN	5,11131	-1,34243	0,11325	0,97911	0,15114	0,55199
65%	BPRMF	4,88588	0,22619	0,19204	0,98207	0,24659	0,46671
	ItemKNN	6,52799	-0,38773	0,78445	0,99151	0,56210	0,30514
	LSBR	6,07357	0,18673	0,28474	0,98435	0,10875	0,61175
	MP	6,34536	-2,56502	0,00467	0,96090	0,00655	1,10290
	PBR	5,14605	-1,05710	0,21268	0,98265	0,12449	0,58485
	PBR+LSBR	5,23840	-0,88551	0,57269	0,98885	0,64428	0,27792
	PBR+LSBR+MP	5,71634	-1,13159	0,49715	0,98785	0,60849	0,28905
	UserKNN	7,58846	-2,99458	0,00784	0,96401	0,05607	0,72741
75%	BPRMF	7,14881	0,86971	0,82093	0,99200	0,86842	0,20538
	ItemKNN	5,49756	0,45804	0,92172	0,99360	0,92615	0,17290
	LSBR	5,19601	-0,03220	0,87775	0,99283	0,91541	0,17909
	MP	5,90046	-1,05167	0,66479	0,99000	0,55959	0,30610
	PBR	5,19357	0,36896	0,81659	0,99194	0,70854	0,25886
	PBR+LSBR	4,90075	-0,04226	0,38436	0,98617	0,71966	0,25557
	PBR+LSBR+MP	5,78229	0,58916	0,91654	0,99350	0,90708	0,18392
	UserKNN	5,72031	-1,40546	0,55828	0,98866	0,58313	0,29750

**Quadro 18. Aspectos de normalidade dos dados relativos à métrica MRR.**

%Treinamento	Algoritmo	Zkurtosis	Zskewness	Shapiro–Wilk		Anderson–Darling	
				P-valor	W	P-valor	A
55%	BPRMF	6,17313	-1,35040	0,45587	0,98727	0,25810	0,45857
	ItemKNN	6,68354	-1,24372	0,68162	0,99021	0,66263	0,27242
	LSBR	6,72694	-0,18273	0,30365	0,98473	0,07454	0,67769
	MP	6,05004	-2,86217	0,00088	0,95036	0,00048	1,56225
	PBR	7,63556	-2,23854	0,00006	0,93153	0,00013	1,79215
	PBR+LSBR	4,79822	-0,53385	0,05408	0,97501	0,02551	0,86499
	PBR+LSBR+MP	4,92502	-0,99056	0,04375	0,97383	0,05140	0,74260
	UserKNN	5,76195	-2,31072	0,01085	0,96591	0,04116	0,78141
65%	BPRMF	5,98849	0,17770	0,75382	0,99111	0,50747	0,33231
	ItemKNN	6,73686	0,23500	0,38654	0,98621	0,13291	0,57382
	LSBR	5,75686	0,61841	0,12623	0,97971	0,03285	0,82083
	MP	5,88348	-2,17099	0,03801	0,97305	0,01964	0,91071
	PBR	5,00636	-2,32802	0,00029	0,94285	0,00009	1,85812
	PBR+LSBR	5,06603	-0,38166	0,52147	0,98818	0,36840	0,39396
	PBR+LSBR+MP	5,93134	-1,07998	0,32506	0,98514	0,16866	0,53320
	UserKNN	6,33621	-1,51070	0,34800	0,98556	0,27454	0,44751
75%	BPRMF	5,74965	-1,44887	0,32640	0,98517	0,21103	0,49423
	ItemKNN	4,80848	1,14657	0,05636	0,97524	0,12536	0,58368
	LSBR	4,77427	-0,00926	0,55765	0,98865	0,38275	0,38689
	MP	7,92078	-3,15825	0,00657	0,96295	0,03912	0,79031
	PBR	4,97114	0,52231	0,42265	0,98677	0,43996	0,36090
	PBR+LSBR	6,23608	1,51513	0,47625	0,98756	0,75752	0,24416
	PBR+LSBR+MP	5,95212	-0,00357	0,84569	0,99235	0,82973	0,22035
	UserKNN	5,52414	-1,15856	0,21100	0,98261	0,19952	0,50405

**Quadro 19. Aspectos de normalidade dos dados relativos à métrica NDCG.**

%Treinamento	Algoritmo	Zkurtosis	Zskewness	Shapiro–Wilk		Anderson–Darling	
				P-valor	W	P-valor	A
55%	BPRMF	5,36484	-1,56802	0,04568	0,97407	0,04057	0,78393
	ItemKNN	5,91941	-0,69754	0,85887	0,99254	0,95167	0,15716
	LSBR	9,45843	-2,41495	0,02176	0,96991	0,04850	0,75274
	MP	5,27922	-2,37288	0,00247	0,95699	0,00203	1,30830
	PBR	7,97403	-2,48397	0,03737	0,97296	0,05730	0,72363
	PBR+LSBR	5,54175	-1,41682	0,09195	0,97795	0,02568	0,86387
	PBR+LSBR+MP	6,13466	-1,79277	0,09424	0,97809	0,19109	0,51158
	UserKNN	5,06009	-1,56368	0,05230	0,97483	0,05279	0,73794
65%	BPRMF	4,62315	-0,11568	0,24716	0,98352	0,34280	0,40721
	ItemKNN	7,05409	-0,17599	0,86179	0,99258	0,65719	0,27404
	LSBR	6,28348	-0,42135	0,85973	0,99255	0,94153	0,16372
	MP	6,40158	-2,62004	0,00263	0,95740	0,01330	0,97890
	PBR	5,51956	-2,15774	0,01499	0,96778	0,01026	1,02429
	PBR+LSBR	5,15718	-1,07130	0,21143	0,98262	0,10868	0,61187
	PBR+LSBR+MP	6,32921	-1,62999	0,29278	0,98451	0,33732	0,41016
	UserKNN	7,63740	-2,76887	0,02335	0,97031	0,15375	0,54908
75%	BPRMF	6,36694	-0,31105	0,94572	0,99412	0,89543	0,19098
	ItemKNN	5,04763	0,42535	0,71085	0,99057	0,81126	0,22683
	LSBR	4,57022	-0,09147	0,24918	0,98357	0,36189	0,39725
	MP	6,60506	-2,05637	0,14704	0,98056	0,12646	0,58220
	PBR	5,12803	-0,00088	0,35089	0,98561	0,37323	0,39155
	PBR+LSBR	5,53037	0,55302	0,79825	0,99169	0,56470	0,30415
	PBR+LSBR+MP	5,91837	0,31384	0,95573	0,99438	0,97490	0,13833
	UserKNN	5,43233	-1,45986	0,18710	0,98192	0,27906	0,44458

**Quadro 20. Aspectos de normalidade dos dados relativos à métrica P@5.**

%Treinamento	Algoritmo	Zkurtosis	Zskewness	Shapiro-Wilk		Anderson-Darling	
				P-valor	W	P-valor	A
55%	BPRMF	5,67720	-0,08932	0,63017	0,98957	0,26956	0,45080
	ItemKNN	5,54163	1,09230	0,28965	0,98445	0,24025	0,47134
	LSBR	6,76535	-0,32983	0,03533	0,97264	0,00169	1,33998
	MP	7,06607	-2,88299	0,00449	0,96068	0,01100	1,01217
	PBR	5,48119	-1,85598	0,02385	0,97043	0,00700	1,09115
	PBR+LSBR	13,57934	-4,51731	0,00008	0,93403	0,00374	1,20090
	PBR+LSBR+MP	5,12521	1,63154	0,00280	0,95778	0,00165	1,34399
	UserKNN	4,93819	-1,31027	0,06700	0,97620	0,03294	0,82035
65%	BPRMF	5,09075	-0,31012	0,44821	0,98716	0,17816	0,52373
	ItemKNN	6,38210	-0,38207	0,35750	0,98572	0,17809	0,52380
	LSBR	6,76612	0,47950	0,06738	0,97623	0,02559	0,86449
	MP	5,04505	-1,34358	0,04748	0,97429	0,02956	0,83929
	PBR	5,17607	0,85140	0,13569	0,98011	0,04541	0,76423
	PBR+LSBR	4,77156	-1,59608	0,00586	0,96227	0,00136	1,37823
	PBR+LSBR+MP	4,81651	0,43440	0,09100	0,97790	0,13523	0,57089
	UserKNN	6,74599	-2,20044	0,04470	0,97395	0,02759	0,85134
75%	BPRMF	7,59825	2,29184	0,04195	0,97360	0,07205	0,68361
	ItemKNN	5,22961	-0,27465	0,56462	0,98874	0,35757	0,39946
	LSBR	4,51978	1,12014	0,00339	0,95895	0,00280	1,25203
	MP	5,13809	-0,46229	0,25108	0,98361	0,11416	0,60327
	PBR	6,45051	1,40072	0,17096	0,98141	0,22749	0,48100
	PBR+LSBR	5,89860	1,12601	0,11662	0,97927	0,10222	0,62256
	PBR+LSBR+MP	5,71851	-1,00524	0,25512	0,98370	0,15997	0,54228
	UserKNN	4,96788	-0,39283	0,17988	0,98170	0,14033	0,56462

**Quadro 21. Aspectos de normalidade dos dados relativos à métrica R@5.**

%Treinamento	Algoritmo	Zkurtosis	Zskewness	Shapiro-Wilk		Anderson-Darling	
				P-valor	W	P-valor	A
55%	BPRMF	5,17467	-0,49301	0,56804	0,98879	0,27119	0,44972
	ItemKNN	5,91135	1,12530	0,29594	0,98458	0,67263	0,26945
	LSBR	5,58121	0,70328	0,54367	0,98847	0,49517	0,33857
	MP	6,51900	-3,29682	0,00031	0,94324	0,00045	1,57056
	PBR	5,65392	-1,16958	0,57184	0,98884	0,67951	0,26742
	PBR+LSBR	12,07581	-3,23754	0,00325	0,95870	0,35616	0,40019
	PBR+LSBR+MP	5,78384	1,73100	0,16861	0,98133	0,39152	0,38269
	UserKNN	4,84108	-0,50208	0,28532	0,98436	0,42508	0,36735
65%	BPRMF	5,41493	0,20378	0,98170	0,99528	0,97842	0,13455
	ItemKNN	6,81988	-1,13039	0,46579	0,98741	0,52172	0,32321
	LSBR	6,38890	1,75416	0,18528	0,98187	0,13824	0,56717
	MP	5,07623	-1,93649	0,01101	0,96600	0,00858	1,05561
	PBR	5,51246	-0,08721	0,69329	0,99035	0,78638	0,23508
	PBR+LSBR	4,59373	-0,09979	0,35949	0,98576	0,53575	0,31614
	PBR+LSBR+MP	5,32329	-0,00906	0,49468	0,98782	0,17097	0,53085
	UserKNN	6,76523	-2,03117	0,11722	0,97930	0,10272	0,62171
75%	BPRMF	6,78778	0,06980	0,97958	0,99518	0,92592	0,17304
	ItemKNN	5,76211	-1,92177	0,07642	0,97693	0,09573	0,63402
	LSBR	5,20207	-0,10073	0,93430	0,99386	0,83555	0,21824
	MP	5,28452	0,15074	0,67264	0,99010	0,83177	0,21962
	PBR	5,34997	0,34676	0,76681	0,99128	0,90311	0,18627
	PBR+LSBR	6,66383	-0,39528	0,26951	0,98402	0,15458	0,54815
	PBR+LSBR+MP	5,95952	1,26643	0,43134	0,98691	0,77164	0,23977
	UserKNN	5,07282	0,17561	0,47995	0,98761	0,66954	0,27037

## Análise da Homoscedasticidade dos Dados

Sobre a homogeneidade das variâncias das amostras, foram realizados o teste de Levene e o teste de Bartlett, considerando as seguintes hipóteses:

- Hipótese Nula ( $H_0$ ): As variâncias de todos os níveis são iguais.
- Hipótese Alternativa ( $H_1$ ): Pelo menos uma das variâncias é diferente.

A partir dos valores obtidos em ambos os testes (Quadro 22), ao comparar o p-valor com o nível de significância de 0,05, foi possível dizer que todas as amostras apresentaram evidências em relação à não igualdade de variâncias (a hipótese  $H_0$  foi rejeitada fortemente, pois os p-valores foram bem menores que 0,05).

**Quadro 22. Testes de homoscedasticidade.**

%Treinamento	Algoritmo	Bartlett		Levene	
		P-valor	Estatística	P-valor	Estatística
55%	AUC	2,84E-47	235,846	5,15E-32	25,902
	MAP	4,45E-30	154,569	1,66E-25	20,580
	MRR	2,39E-21	112,816	2,28E-17	14,142
	NDCG	8,53E-30	153,226	1,04E-25	20,744
	P@5	4,11E-27	140,439	1,08E-22	18,329
	R@5	9,77E-22	114,685	1,62E-17	14,258
65%	AUC	3,70E-38	192,872	8,26E-26	20,824
	MAP	5,70E-20	106,174	4,58E-14	11,583
	MRR	3,98E-08	47,752	7,76E-06	5,221
	NDCG	2,03E-17	93,818	2,11E-11	9,533
	P@5	3,54E-11	63,149	2,41E-09	7,949
	R@5	2,22E-09	54,128	2,44E-07	6,398
75%	AUC	1,51E-16	89,580	1,26E-13	11,246
	MAP	9,63E-09	50,896	3,19E-07	6,307
	MRR	2,79E-08	48,539	1,98E-07	6,468
	NDCG	3,82E-09	52,933	1,56E-07	6,549
	P@5	3,27E-05	32,510	0,000119	4,276
	R@5	0,001413	23,467	0,001217	3,446

Sabe-se que o teste de Levene é menos sensível que o teste de Bartlett a desvios da normalidade. Uma vez que, ao analisar a normalidade dos dados, foi possível dizer que alguns dados não são normais, o teste de Levene acaba se sobressaindo (Bartlett se sobressai quando a hipótese de normalidade não é violada). Todavia, para os dados deste experimento, ambos os testes chegaram às mesmas conclusões.

## Testes ANOVA e Kruskal-Wallis

Para utilizar o teste ANOVA, é necessária uma análise residual, sendo verificada, para cada uma das variáveis dependentes, a normalidade dos resíduos, a independência dos erros dos resíduos e a variação constante dos resíduos. Apesar do teste ANOVA ser resistente a afastamentos da distribuição normal, em alguns casos as premissas pareceram ser violadas com os dados das variáveis dependentes. Portanto, um teste não paramétrico equivalente ao teste ANOVA foi também realizado.

Considerando-se o teste ANOVA, no Quadro 23 é apresentada, para cada fator, o resultado de um teste F com nível de significância igual a 0,05. As hipóteses desse teste consistem em:

- $H_0$ : Não existe diferença entre os efeitos das alternativas do fator na variável dependente.
- $H_1$ : Existe diferença entre os efeitos das alternativas do fator na variável dependente.

**Quadro 23. Resultado do teste ANOVA.**

	Fator "Algoritmo"		Fator "Percentual dos dados utilizado para a base de treinamento"	
	<i>F</i>	<i>F-Table</i>	<i>F</i>	<i>F-Table</i>
AUC	572,74	2,01343	79,28	2,99951
MAP	602,38		1375,75	
MRR	228,19		316,99	
NDCG	457,59		1545,31	
P@5	485,77		3888,89	
R@5	348,25		103008,27	

Quando a estatística  $F$  é maior que o valor de  $F-Table$ , a hipótese  $H_0$  é rejeitada, sendo possível dizer que existe diferença entre os efeitos das alternativas do fator para determinada variável dependente. É possível ver que os valores de  $F$  são bem maiores que os valores de  $F-Table$  para todas as variáveis dependentes. Portanto, é possível afirmar que existe diferença entre os efeitos das alternativas do algoritmo em relação à acurácia (AUC, MAP, MRR, NDCG, P@5, R@5). Dessa forma, é possível rejeitar todas as hipóteses nulas definidas na Subseção 5.3.2 (Quadro 9), aceitando, por conseguinte, as hipóteses alternativas.

Uma vez que as premissas do teste ANOVA, para usar o teste  $F$ , não foram totalmente satisfeitas para todas as variáveis dependentes, o resultado desse teste foi confrontado com o resultado de um teste não paramétrico.

É importante dizer que, apesar de ser preferível usar testes paramétricos, pois têm maior poder estatístico (robustez), só se deve usar realmente quando as amostras obedecem ao que o teste espera delas. Embora o teste ANOVA geralmente funcione bem mesmo quando as premissas não são plenamente satisfeitas, partindo do princípio que usar o teste errado pode fazer com que se acredite em um resultado errado, julgou-se adequado realizar também um teste não paramétrico.

O teste de Kruskal-Wallis é uma alternativa ao teste ANOVA, e considera as seguintes hipóteses.

- $H_0$ : Todos os grupos têm a mesma distribuição — todas as populações têm a mesma mediana.
- $H_1$ : Existem grupos que são maiores que outros — as medianas não são iguais.

Os resultados desse teste para os dados encontram-se no Quadro 24 e indicam que, para todas as variáveis dependentes, se deve rejeitar a hipótese nula ( $p\text{-value} < 2.2e-16$ ) e, portanto, chega-se às mesmas conclusões do teste ANOVA.

**Quadro 24. Resultado do teste de Kruskal-Wallis**

	<b>Execução do Teste (<i>Kruskal-Wallis rank sum test</i>)</b>
AUC	Kruskal-Wallis chi-squared = 1401.277, df = 7, p-value < 2.2e-16
MAP	Kruskal-Wallis chi-squared = 1064.038, df = 7, p-value < 2.2e-16
MRR	Kruskal-Wallis chi-squared = 807.7364, df = 7, p-value < 2.2e-16
NDCG	Kruskal-Wallis chi-squared = 863.7610, df = 7, p-value < 2.2e-16
P@5	Kruskal-Wallis chi-squared = 557.6834, df = 7, p-value < 2.2e-16
R@5	Kruskal-Wallis chi-squared = 137.4708, df = 7, p-value < 2.2e-16

## Testes T e Mann-Whitney U

Dos Quadros 25 a 30 são apresentados os p-valores resultantes dos testes par a par T (paramétrico) e Mann-Whitney U (não paramétrico). Quando o p-valor obtido para determinado par de algoritmos é menor ou igual ao nível de significância de 0,05, é possível rejeitar a hipótese nula de que, em média, os algoritmos são iguais em relação à determinada métrica, sendo, então, observadas as médias das amostras para decidir qual deles se sobressai. Caso contrário ( $p\text{-valor} > 0,05$ ), não é possível rejeitar a hipótese nula e não se considera diferença entre o par — casos destacados em amarelo do Quadro 25 ao Quadro 30.

**Quadro 25. P-valores obtidos na execução dos testes T e Mann-Whitney U, par a par, para os dados relativos à métrica AUC.**

Par de Algoritmos	Teste T			Teste Mann-Whitney U		
	55%	65%	75%	55%	65%	75%
BPRMF e ItemKNN	4,46E-19	2,21E-14	6,53E-19	4,07E-11	2,65E-08	5,71E-11
BPRMF e LSBR	3,18E-53	5,39E-30	5,71E-05	1,46E-30	5,19E-24	4,58E-05
BPRMF e MP	5,00E-41	4,79E-37	4,33E-31	6,71E-20	1,46E-19	3,31E-19
BPRMF e PBR	1,29E-80	1,76E-42	8,07E-10	5,22E-30	4,33E-26	2,49E-08
BPRMF e PBR+LSBR	1,64E-88	1,35E-49	3,22E-13	3,05E-32	5,57E-29	1,03E-11
BPRMF e PBR+LSBR+MP	3,73E-101	5,05E-71	1,06E-38	1,07E-32	2,10E-31	4,05E-25
BPRMF e UserKNN	3,50E-03	<b>2,64E-01</b>	<b>5,72E-01</b>	2,20E-02	<b>1,73E-01</b>	<b>8,27E-01</b>
ItemKNN e LSBR	2,35E-108	2,05E-72	3,60E-38	7,17E-33	2,23E-31	2,27E-22
ItemKNN e MP	4,05E-94	2,34E-81	8,94E-82	1,07E-29	2,02E-27	1,04E-28
ItemKNN e PBR	8,03E-138	5,96E-88	4,86E-49	2,23E-32	1,30E-31	4,53E-24
ItemKNN e PBR+LSBR	6,82E-146	3,05E-96	2,49E-55	7,17E-33	1,91E-32	2,84E-26
ItemKNN e PBR+LSBR+MP	1,61E-158	9,31E-120	1,81E-91	7,17E-33	9,12E-33	3,29E-31
ItemKNN e UserKNN	5,41E-33	5,72E-21	7,08E-17	2,90E-15	9,17E-11	6,51E-09
LSBR e MP	<b>5,73E-02</b>	<b>3,82E-01</b>	1,02E-13	<b>3,52E-01</b>	1,58E-02	1,62E-14
LSBR e PBR	1,01E-05	<b>5,15E-02</b>	<b>1,28E-01</b>	2,39E-11	5,39E-03	4,85E-02
LSBR e PBR+LSBR	8,25E-09	5,24E-04	4,69E-03	4,01E-22	7,30E-10	4,82E-05
LSBR e PBR+LSBR+MP	5,69E-15	1,26E-13	2,61E-19	7,20E-26	2,19E-22	7,97E-23
LSBR e UserKNN	3,33E-36	2,92E-22	5,04E-06	3,50E-23	8,31E-17	9,16E-05
MP e PBR	1,35E-11	<b>3,82E-01</b>	8,88E-08	5,46E-09	<b>8,59E-01</b>	4,75E-08
MP e PBR+LSBR	8,99E-16	<b>6,54E-02</b>	3,12E-05	1,84E-13	<b>1,73E-01</b>	4,41E-06
MP e PBR+LSBR+MP	1,41E-23	3,71E-09	<b>3,15E-01</b>	1,69E-18	1,26E-08	<b>3,46E-01</b>
MP e UserKNN	1,11E-25	1,26E-28	1,13E-33	7,32E-13	2,42E-15	1,11E-17
PBR e PBR+LSBR	<b>1,83E-01</b>	<b>3,82E-01</b>	<b>4,82E-01</b>	<b>3,52E-01</b>	<b>8,51E-02</b>	<b>3,46E-01</b>
PBR e PBR+LSBR+MP	3,17E-03	1,88E-06	3,97E-12	3,41E-04	9,41E-10	3,91E-14
PBR e UserKNN	2,27E-61	1,35E-33	2,07E-11	5,79E-26	2,08E-20	1,40E-07
PBR+LSBR e PBR+LSBR+MP	<b>7,24E-02</b>	8,63E-04	6,92E-09	4,56E-03	1,40E-07	1,03E-11
PBR+LSBR e UserKNN	6,57E-69	3,47E-40	5,11E-15	2,90E-29	9,47E-25	1,99E-10
PBR+LSBR+MP e UserKNN	3,99E-81	1,45E-60	1,73E-41	8,31E-31	2,04E-29	2,76E-23

**Quadro 26. P-valores obtidos na execução dos testes T e Mann-Whitney U, par a par, para os dados relativos à métrica MAP.**

Par de Algoritmos	Teste T			Teste Mann-Whitney U		
	55%	65%	75%	55%	65%	75%
BPRMF e ItemKNN	1,28E-16	1,58E-11	1,19E-12	2,15E-11	9,36E-08	1,48E-09
BPRMF e LSBR	9,13E-71	1,70E-42	4,42E-12	1,16E-32	1,39E-28	1,65E-12
BPRMF e MP	9,39E-29	1,46E-25	1,04E-13	2,80E-15	1,53E-14	8,76E-10
BPRMF e PBR	1,74E-104	4,85E-57	8,15E-20	5,77E-32	2,88E-28	7,97E-15
BPRMF e PBR+LSBR	7,12E-114	5,27E-69	6,09E-27	8,30E-33	3,00E-31	4,62E-20
BPRMF e PBR+LSBR+MP	4,60E-108	6,90E-76	4,36E-41	7,17E-33	1,52E-31	4,72E-26
BPRMF e UserKNN	9,23E-03	4,66E-02	<b>5,65E-01</b>	3,58E-02	2,98E-02	<b>7,45E-01</b>
ItemKNN e LSBR	3,43E-123	2,46E-82	1,36E-43	7,17E-33	7,67E-32	6,98E-27
ItemKNN e MP	2,33E-74	2,79E-61	2,44E-46	2,41E-26	2,87E-23	2,90E-22
ItemKNN e PBR	1,42E-157	6,22E-99	1,18E-55	8,30E-33	8,94E-32	5,10E-27
ItemKNN e PBR+LSBR	9,31E-167	6,32E-112	1,64E-65	7,17E-33	1,47E-32	7,46E-30
ItemKNN e PBR+LSBR+MP	4,33E-161	3,53E-119	3,21E-83	7,17E-33	1,51E-32	9,30E-32
ItemKNN e UserKNN	1,20E-28	1,24E-19	1,24E-09	1,45E-14	3,37E-12	7,85E-07
LSBR e MP	1,50E-14	1,67E-03	<b>5,91E-01</b>	4,74E-11	1,82E-02	<b>7,45E-01</b>
LSBR e PBR	1,02E-07	2,34E-02	<b>1,12E-01</b>	4,67E-12	6,17E-04	<b>1,07E-01</b>
LSBR e PBR+LSBR	9,16E-12	8,21E-06	4,36E-04	4,27E-20	3,14E-10	1,83E-05
LSBR e PBR+LSBR+MP	3,88E-09	1,44E-08	3,40E-11	9,74E-18	3,56E-13	1,65E-14
LSBR e UserKNN	1,21E-53	6,86E-31	1,77E-15	3,34E-29	4,60E-24	8,14E-12
MP e PBR	9,21E-38	2,18E-09	<b>3,10E-01</b>	4,85E-21	6,66E-06	<b>6,75E-01</b>
MP e PBR+LSBR	1,98E-45	6,97E-16	3,19E-03	4,13E-26	3,84E-11	1,77E-02
MP e PBR+LSBR+MP	1,25E-40	4,28E-20	1,07E-09	4,85E-25	1,61E-13	1,20E-07
MP e UserKNN	1,09E-16	2,63E-16	2,46E-17	7,82E-09	7,14E-10	3,51E-10
PBR e PBR+LSBR	<b>3,69E-01</b>	<b>6,62E-02</b>	<b>3,10E-01</b>	<b>2,42E-01</b>	4,22E-02	<b>2,50E-01</b>
PBR e PBR+LSBR+MP	<b>6,81E-01</b>	4,66E-03	1,65E-05	<b>6,98E-01</b>	1,62E-03	8,15E-06
PBR e UserKNN	4,51E-86	3,42E-44	4,73E-24	7,21E-30	1,16E-24	1,65E-14
PBR+LSBR e PBR+LSBR+MP	<b>6,81E-01</b>	<b>2,35E-01</b>	1,47E-02	<b>2,42E-01</b>	<b>1,16E-01</b>	4,27E-03
PBR+LSBR e UserKNN	2,58E-95	1,80E-55	1,07E-31	4,03E-32	9,16E-30	1,11E-19
PBR+LSBR+MP e UserKNN	1,39E-89	5,42E-62	1,61E-46	4,03E-32	3,42E-30	4,67E-26

**Quadro 27. P-valores obtidos na execução dos testes T e Mann-Whitney U, par a par, para os dados relativos à métrica MRR.**

Par de Algoritmos	Teste T			Teste Mann-Whitney U		
	55%	65%	75%	55%	65%	75%
BPRMF e ItemKNN	1,86E-02	3,02E-02	6,46E-04	6,00E-02	6,19E-02	1,69E-03
BPRMF e LSBR	3,12E-11	6,10E-12	2,66E-02	3,19E-12	3,71E-12	2,96E-02
BPRMF e MP	4,62E-03	9,21E-07	1,80E-01	9,04E-03	1,96E-05	1,57E-01
BPRMF e PBR	3,46E-60	2,03E-53	3,07E-23	7,72E-31	1,69E-27	4,04E-17
BPRMF e PBR+LSBR	9,76E-29	3,57E-23	1,61E-04	4,11E-21	7,04E-18	4,55E-04
BPRMF e PBR+LSBR+MP	2,67E-31	2,35E-32	8,51E-12	1,14E-20	1,11E-21	2,38E-10
BPRMF e UserKNN	9,95E-01	9,49E-02	2,45E-01	7,15E-01	6,19E-02	3,93E-01
ItemKNN e LSBR	6,63E-21	3,43E-21	1,52E-10	8,66E-17	1,66E-16	2,66E-09
ItemKNN e MP	1,25E-08	3,23E-14	3,61E-08	3,99E-06	1,42E-08	2,41E-06
ItemKNN e PBR	1,91E-76	2,30E-68	1,12E-41	1,99E-31	5,01E-28	3,51E-22
ItemKNN e PBR+LSBR	3,78E-42	6,37E-35	3,86E-15	1,08E-24	1,46E-20	1,59E-11
ItemKNN e PBR+LSBR+MP	4,75E-45	2,04E-45	1,29E-26	2,61E-24	2,02E-23	7,14E-17
ItemKNN e UserKNN	2,77E-03	1,31E-05	1,09E-01	1,59E-02	1,14E-04	2,02E-01
LSBR e MP	1,06E-03	9,49E-02	3,71E-01	6,00E-02	3,28E-01	8,18E-01
LSBR e PBR	5,88E-25	4,20E-19	8,76E-13	7,42E-28	2,03E-18	2,78E-13
LSBR e PBR+LSBR	1,97E-05	7,49E-03	2,80E-01	1,39E-08	7,97E-04	3,93E-01
LSBR e PBR+LSBR+MP	1,20E-06	1,56E-06	1,17E-04	4,96E-09	1,42E-08	4,31E-06
LSBR e UserKNN	2,48E-09	2,23E-06	5,56E-05	6,38E-07	2,56E-06	7,20E-04
MP e PBR	1,69E-42	6,98E-27	1,05E-15	1,15E-27	3,44E-17	9,49E-11
MP e PBR+LSBR	9,28E-16	3,14E-06	1,08E-01	7,21E-11	3,51E-04	3,93E-01
MP e PBR+LSBR+MP	9,05E-18	1,27E-11	1,61E-06	1,54E-11	2,22E-08	1,05E-04
MP e UserKNN	2,49E-02	6,67E-03	1,89E-03	9,65E-02	7,39E-03	1,05E-02
PBR e PBR+LSBR	8,76E-09	5,75E-09	1,46E-08	1,67E-12	6,77E-10	8,02E-09
PBR e PBR+LSBR+MP	2,12E-07	2,14E-04	1,17E-02	4,09E-09	3,04E-05	1,23E-02
PBR e UserKNN	1,90E-56	3,51E-42	1,06E-30	3,79E-30	1,88E-25	2,48E-18
PBR+LSBR e PBR+LSBR+MP	9,95E-01	9,49E-02	2,29E-02	7,15E-01	6,19E-02	5,88E-03
PBR+LSBR e UserKNN	7,56E-26	3,19E-15	2,46E-08	1,12E-16	2,76E-13	4,88E-06
PBR+LSBR+MP e UserKNN	2,62E-28	4,44E-23	1,54E-17	7,42E-17	2,19E-18	6,97E-12

**Quadro 28. P-valores obtidos na execução dos testes T e Mann-Whitney U, par a par, para os dados relativos à métrica NDCG.**

Par de Algoritmos	Teste T			Teste Mann-Whitney U		
	55%	65%	75%	55%	65%	75%
BPRMF e ItemKNN	1,35E-11	1,72E-08	8,49E-10	4,12E-08	2,45E-06	1,12E-07
BPRMF e LSBR	1,58E-44	8,86E-31	5,79E-08	1,95E-30	6,83E-25	1,80E-08
BPRMF e MP	3,62E-15	3,43E-17	6,24E-07	2,05E-09	3,23E-11	1,74E-05
BPRMF e PBR	2,48E-98	3,51E-61	7,39E-23	2,48E-32	5,42E-29	2,09E-16
BPRMF e PBR+LSBR	1,91E-82	1,38E-54	1,81E-18	1,35E-32	8,10E-30	1,29E-15
BPRMF e PBR+LSBR+MP	1,38E-76	4,01E-60	5,55E-29	7,98E-32	4,76E-30	1,16E-21
BPRMF e UserKNN	1,07E-01	6,82E-02	5,76E-01	1,36E-01	5,41E-02	8,24E-01
ItemKNN e LSBR	9,19E-85	9,04E-62	9,26E-32	1,75E-32	5,42E-29	1,07E-22
ItemKNN e MP	2,22E-46	9,08E-44	8,44E-30	1,09E-19	1,41E-18	8,39E-17
ItemKNN e PBR	3,71E-142	8,44E-97	1,04E-54	9,06E-33	6,53E-31	5,84E-27
ItemKNN e PBR+LSBR	5,33E-126	1,38E-89	1,32E-48	7,62E-33	2,99E-31	5,29E-27
ItemKNN e PBR+LSBR+MP	6,29E-120	1,19E-95	8,45E-63	1,18E-32	2,32E-31	1,19E-29
ItemKNN e UserKNN	6,41E-18	1,46E-15	2,78E-06	8,33E-10	3,22E-10	9,34E-05
LSBR e MP	1,39E-10	3,92E-03	6,62E-01	5,28E-07	5,41E-02	9,20E-01
LSBR e PBR	4,47E-19	2,91E-08	4,81E-05	1,41E-23	6,02E-11	2,20E-05
LSBR e PBR+LSBR	1,47E-10	1,34E-05	4,02E-03	1,68E-18	4,51E-09	4,82E-04
LSBR e PBR+LSBR+MP	4,74E-08	7,74E-08	3,49E-08	1,89E-14	1,28E-11	6,70E-11
LSBR e UserKNN	4,87E-35	9,43E-21	6,78E-12	1,41E-23	1,61E-18	2,32E-09
MP e PBR	2,43E-50	1,44E-18	6,55E-06	1,40E-26	1,64E-11	8,75E-04
MP e PBR+LSBR	6,07E-37	1,70E-14	8,86E-04	3,23E-23	4,10E-10	1,38E-02
MP e PBR+LSBR+MP	2,55E-32	6,81E-18	2,62E-09	2,06E-20	5,19E-12	4,18E-07
MP e UserKNN	1,68E-09	1,02E-09	1,28E-10	1,87E-05	8,06E-07	1,16E-06
PBR e PBR+LSBR	2,44E-02	6,90E-01	5,76E-01	4,92E-04	2,67E-01	8,24E-01
PBR e PBR+LSBR+MP	1,13E-03	8,47E-01	5,76E-01	1,87E-05	5,88E-01	4,59E-01
PBR e UserKNN	1,10E-86	3,05E-48	5,55E-29	2,99E-31	3,84E-26	4,65E-17
PBR+LSBR e PBR+LSBR+MP	3,20E-01	6,90E-01	4,69E-02	1,87E-01	3,49E-01	1,38E-02
PBR+LSBR e UserKNN	3,95E-71	3,97E-42	3,85E-24	5,81E-31	9,35E-27	4,02E-16
PBR+LSBR+MP e UserKNN	1,93E-65	2,96E-47	1,18E-35	2,70E-29	1,65E-27	4,15E-22

**Quadro 29. P-valores obtidos na execução dos testes T e Mann-Whitney U, par a par, para os dados relativos à métrica P@5.**

Par de Algoritmos	Teste T			Teste Mann-Whitney U		
	55%	65%	75%	55%	65%	75%
BPRMF e ItemKNN	1,25E-15	2,88E-08	1,28E-08	1,16E-11	5,92E-06	6,03E-06
BPRMF e LSBR	1,63E-63	3,84E-41	2,40E-12	2,81E-32	7,71E-27	1,76E-12
BPRMF e MP	3,71E-21	9,02E-24	3,22E-19	4,51E-14	8,84E-14	9,91E-14
BPRMF e PBR	2,56E-69	4,32E-28	4,80E-04	1,11E-27	7,83E-18	1,69E-04
BPRMF e PBR+LSBR	4,69E-94	9,44E-64	6,93E-20	3,68E-32	6,20E-30	7,72E-16
BPRMF e PBR+LSBR+MP	6,23E-77	1,06E-66	9,64E-37	1,57E-32	9,61E-31	1,07E-22
BPRMF e UserKNN	1,57E-01	1,64E-01	1,00E+00	1,30E-01	1,64E-01	1,00E+00
ItemKNN e LSBR	9,84E-114	1,20E-73	3,89E-37	5,90E-33	2,87E-31	4,79E-23
ItemKNN e MP	3,17E-62	2,65E-52	2,72E-47	1,21E-24	3,39E-23	3,41E-23
ItemKNN e PBR	5,48E-120	7,66E-58	1,06E-21	1,47E-31	7,71E-27	4,45E-15
ItemKNN e PBR+LSBR	1,70E-145	6,14E-99	2,68E-48	8,96E-33	4,06E-32	4,02E-25
ItemKNN e PBR+LSBR+MP	5,36E-128	4,29E-102	7,48E-70	5,90E-33	2,01E-32	2,40E-29
ItemKNN e UserKNN	1,10E-22	1,08E-13	1,82E-08	1,09E-12	1,35E-09	1,81E-05
LSBR e MP	2,18E-16	7,30E-04	1,31E-01	3,26E-14	7,39E-03	7,91E-02
LSBR e PBR	3,80E-01	2,17E-02	2,39E-03	1,30E-01	4,39E-03	3,46E-04
LSBR e PBR+LSBR	1,65E-06	1,50E-04	1,08E-01	6,42E-14	4,22E-07	6,02E-02
LSBR e PBR+LSBR+MP	7,87E-02	1,59E-05	1,87E-08	4,23E-03	3,33E-08	1,01E-09
LSBR e UserKNN	7,30E-53	6,18E-32	1,55E-12	2,81E-30	3,60E-24	2,34E-09
MP e PBR	4,36E-20	6,09E-01	4,45E-07	1,91E-11	1,00E+00	1,16E-06
MP e PBR+LSBR	2,83E-38	3,45E-14	1,00E+00	6,90E-25	8,94E-11	1,00E+00
MP e PBR+LSBR+MP	3,14E-25	6,53E-16	4,26E-04	1,46E-18	1,09E-11	8,53E-04
MP e UserKNN	2,35E-14	1,67E-16	1,85E-19	1,44E-08	2,84E-10	4,94E-12
PBR e PBR+LSBR	1,87E-04	4,03E-11	1,65E-07	1,48E-03	9,27E-11	5,94E-08
PBR e PBR+LSBR+MP	3,80E-01	1,19E-12	1,67E-19	6,24E-01	7,42E-12	2,86E-17
PBR e UserKNN	1,95E-58	3,02E-20	4,26E-04	7,26E-24	2,17E-13	2,65E-03
PBR+LSBR e PBR+LSBR+MP	2,06E-02	6,09E-01	6,36E-04	5,15E-05	1,00E+00	2,15E-04
PBR+LSBR e UserKNN	1,96E-82	3,66E-53	3,91E-20	1,47E-31	1,81E-28	3,04E-13
PBR+LSBR+MP e UserKNN	9,81E-66	5,57E-56	4,58E-37	3,33E-31	1,47E-29	5,12E-21

**Quadro 30. P-valores obtidos na execução dos testes T e Mann-Whitney U, par a par, para os dados relativos à métrica R@5.**

Par de Algoritmos	Teste T			Teste Mann-Whitney U		
	55%	65%	75%	55%	65%	75%
BPRMF e ItemKNN	2,88E-14	3,81E-07	1,37E-06	1,07E-10	2,65E-05	8,26E-05
BPRMF e LSBR	3,06E-60	3,80E-38	2,78E-11	6,11E-32	2,76E-25	1,08E-10
BPRMF e MP	1,19E-17	6,66E-19	1,25E-14	5,44E-12	1,68E-11	6,48E-10
BPRMF e PBR	9,01E-61	6,92E-23	4,18E-03	5,24E-27	9,51E-16	3,55E-03
BPRMF e PBR+LSBR	1,37E-86	4,11E-55	3,33E-17	6,78E-32	7,61E-29	1,37E-14
BPRMF e PBR+LSBR+MP	3,73E-70	1,38E-57	3,69E-30	2,46E-32	2,56E-29	3,92E-21
BPRMF e UserKNN	3,17E-01	3,22E-01	8,85E-01	4,61E-01	2,04E-01	9,60E-01
ItemKNN e LSBR	1,12E-107	1,64E-67	1,44E-31	1,75E-32	5,98E-31	1,29E-21
ItemKNN e MP	9,65E-55	2,12E-43	1,32E-36	3,69E-23	3,28E-20	1,76E-19
ItemKNN e PBR	2,73E-108	1,04E-48	2,05E-16	3,47E-31	3,20E-25	1,16E-12
ItemKNN e PBR+LSBR	1,78E-135	8,11E-87	2,37E-40	1,75E-32	6,67E-32	5,59E-25
ItemKNN e PBR+LSBR+MP	2,19E-118	1,58E-89	3,59E-57	1,19E-32	3,34E-32	2,38E-29
ItemKNN e UserKNN	5,24E-20	2,33E-11	5,84E-06	1,06E-11	1,96E-08	6,29E-04
LSBR e MP	1,19E-17	6,72E-05	8,46E-01	2,08E-14	3,50E-03	9,60E-01
LSBR e PBR	9,18E-01	3,27E-03	1,49E-03	5,85E-01	1,94E-03	3,96E-04
LSBR e PBR+LSBR	4,23E-05	4,15E-03	2,61E-01	8,70E-10	1,82E-04	1,51E-01
LSBR e PBR+LSBR+MP	3,17E-01	1,15E-03	6,12E-06	3,70E-02	8,30E-06	3,37E-06
LSBR e UserKNN	3,17E-51	1,35E-30	3,87E-12	5,84E-28	2,13E-22	4,12E-10
MP e PBR	5,81E-18	6,03E-01	1,62E-05	1,27E-10	1,00E+00	2,27E-04
MP e PBR+LSBR	7,76E-37	3,44E-13	8,85E-01	1,11E-24	3,09E-09	9,60E-01
MP e PBR+LSBR+MP	2,55E-24	1,33E-14	7,05E-04	5,39E-19	3,08E-10	3,71E-03
MP e UserKNN	3,05E-12	2,11E-13	1,35E-15	1,13E-07	1,39E-08	9,08E-10
PBR e PBR+LSBR	5,81E-05	3,25E-10	4,13E-07	1,54E-04	1,15E-09	3,81E-08
PBR e PBR+LSBR+MP	3,17E-01	1,91E-11	1,67E-16	4,61E-01	4,93E-11	4,47E-15
PBR e UserKNN	9,50E-52	7,92E-17	1,64E-03	6,64E-23	6,45E-12	3,49E-03
PBR+LSBR e PBR+LSBR+MP	2,63E-02	6,50E-01	7,10E-03	1,46E-04	1,00E+00	5,05E-03
PBR+LSBR e UserKNN	9,61E-77	1,41E-46	3,02E-18	1,09E-30	5,74E-27	1,77E-13
PBR+LSBR+MP e UserKNN	9,72E-61	6,45E-49	1,83E-31	1,30E-29	6,88E-28	4,26E-20

Os casos em que o resultado do teste T foi diferente de teste Mann-Whitney U, em relação a aceitar/rejeitar a hipótese de que os algoritmos são iguais, estão apresentados no Quadro 31. Nesses casos, foi analisado se ambas as amostras comparadas foram consideradas normais (Quadro 16 ao Quadro 21) para considerar a execução do teste T. Caso contrário, foi considerada a execução do teste Mann-Whitney U.

**Quadro 31. Casos de diferença entre o resultado do teste T e o teste Mann-Whitney U.**

<b>Par de Algoritmos</b>	<b>Métrica</b>	<b>%Treinamento</b>	<b>Observação</b>
LSBR e MP	AUC	65%	Amostra MP não normal
LSBR e PBR	AUC	65% e 75%	Amostras normais
PBR+LSBR e PBR+LSBR+MP	AUC	55%	Amostra PBR+LSBR não normal
PBR e PBR+LSBR	MAP	65%	Amostras normais
BPRMF e ItemKNN	MRR	55% e 65%	Amostras normais
LSBR e MP	MRR	55%	Amostra MP não normal
MP e UserKNN	MRR	55%	Amostras não normais
LSBR e MP	NDCG	65%	Amostra MP não normal
LSBR e PBR+LSBR+MP	P@5	55%	Amostras não normais
LSBR e PBR+LSBR+MP	R@5	55%	Amostras normais

# Apêndice H

## Execução do experimento final com vários modelos híbridos

Com base nas métricas (AUC, MAP, MRR, NDCG, P@5 e R@5) e nos valores para o percentual dos dados utilizado para a base de treinamento (55%, 65% e 75%) do experimento descrito na Seção 5.3, são apresentados, nas Figuras 35 a 52, os gráficos relativos aos intervalos de confiança, com nível de significância ( $\alpha$ ) de 0,05, para comparação dos algoritmos UserKNN, ItemKNN, BPRMF, MP, LSBR e PBR, além dos variados híbridos formados por estes, seguindo a mesma lógica apresentada na Equação 5 do Capítulo 4:

- MP+UserKNN
- MP+ItemKNN
- MP+BPRMF
- LSBR+UserKNN
- LSBR+ItemKNN
- LSBR+BPRMF
- LSBR+MP
- PBR+UserKNN
- PBR+ItemKNN
- PBR+BPRMF
- PBR+MP
- PBR+LSBR
- PBR+MP+UserKNN
- PBR+MP+ItemKNN
- PBR+MP+BPRMF
- LSBR+MP+UserKNN
- LSBR+MP+ItemKNN
- LSBR+MP+BPRMF
- PBR+LSBR+UserKNN
- PBR+LSBR+ItemKNN
- PBR+LSBR+BPRMF
- **PBR+LSBR+MP**
- PBR+LSBR+MP+UserKNN
- PBR+LSBR+MP+ItemKNN
- PBR+LSBR+MP+BPRMF

Nestes gráficos, são destacados, em azul escuro, os intervalos de confiança para o algoritmo baseado no modelo híbrido proposto no Capítulo 4 (PBR+LSBR+MP). Em azul claro, são destacados os intervalos de confiança do modelo similar ao proposto, mas sem o aspecto de popularidade de itens (PBR+LSBR).

Figura 35. Intervalos de Confiança relativos à métrica AUC (%treinamento=55%).

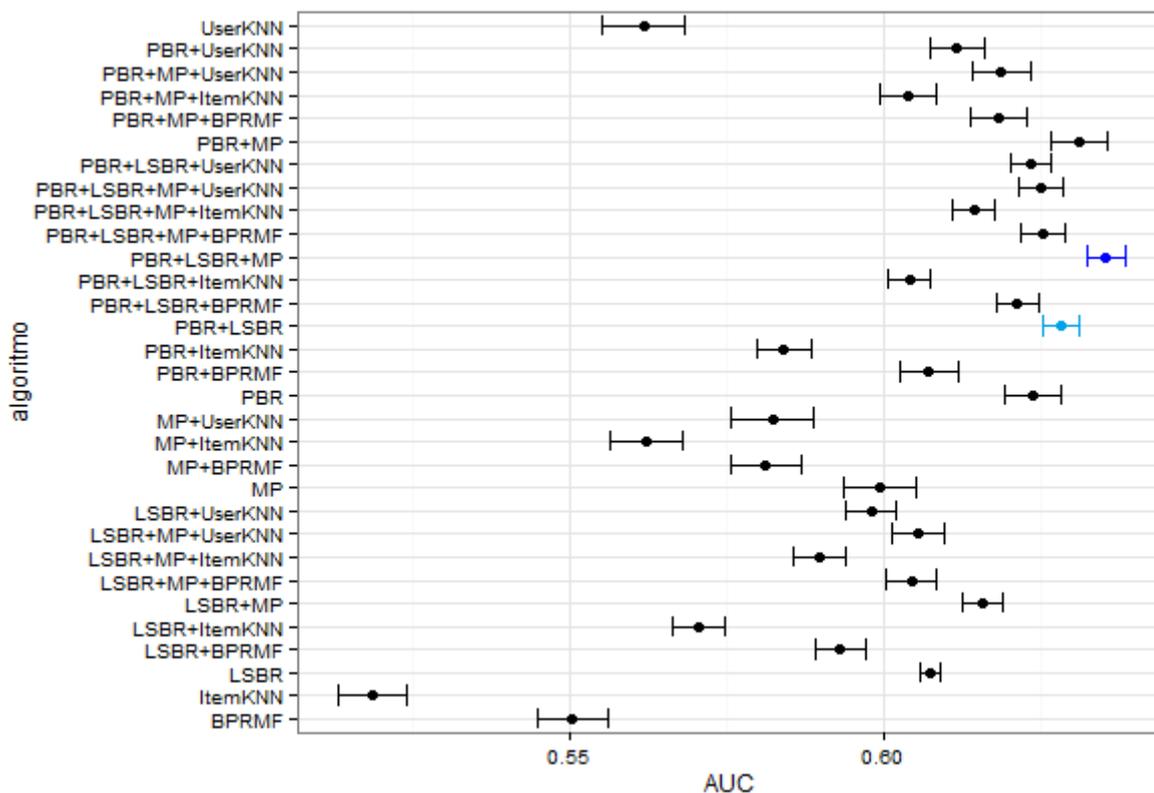
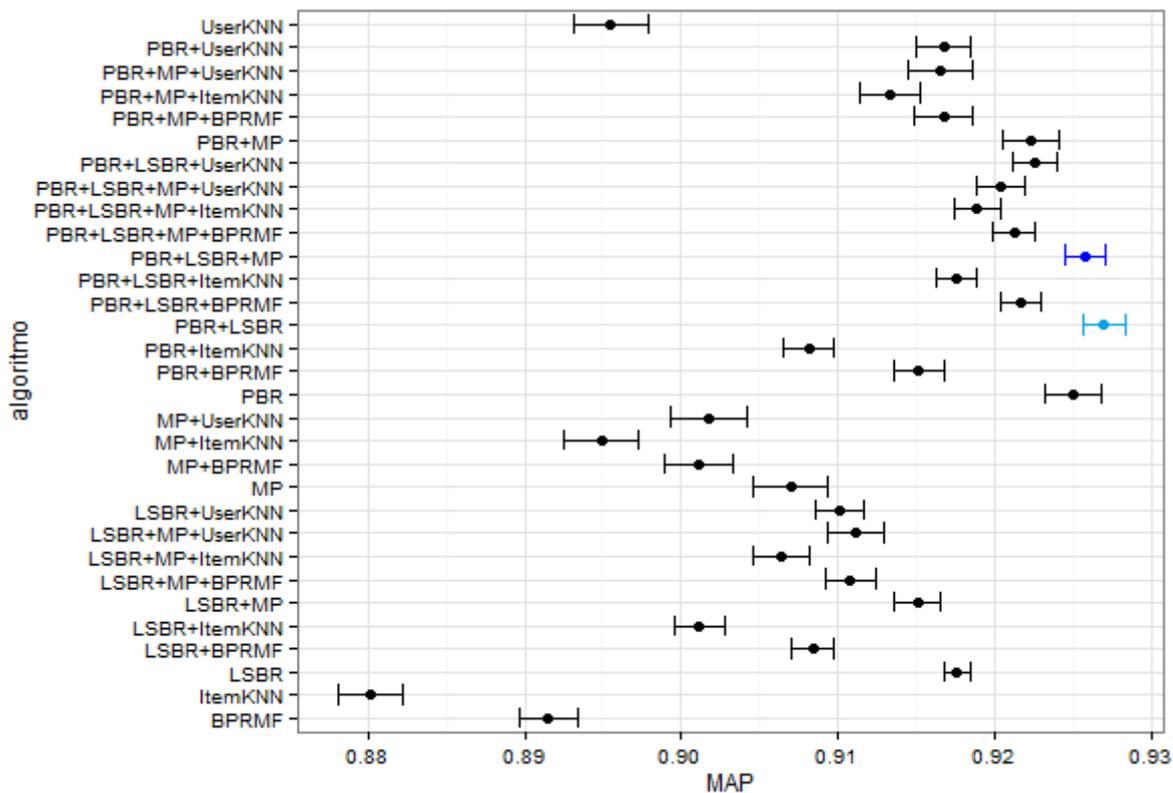
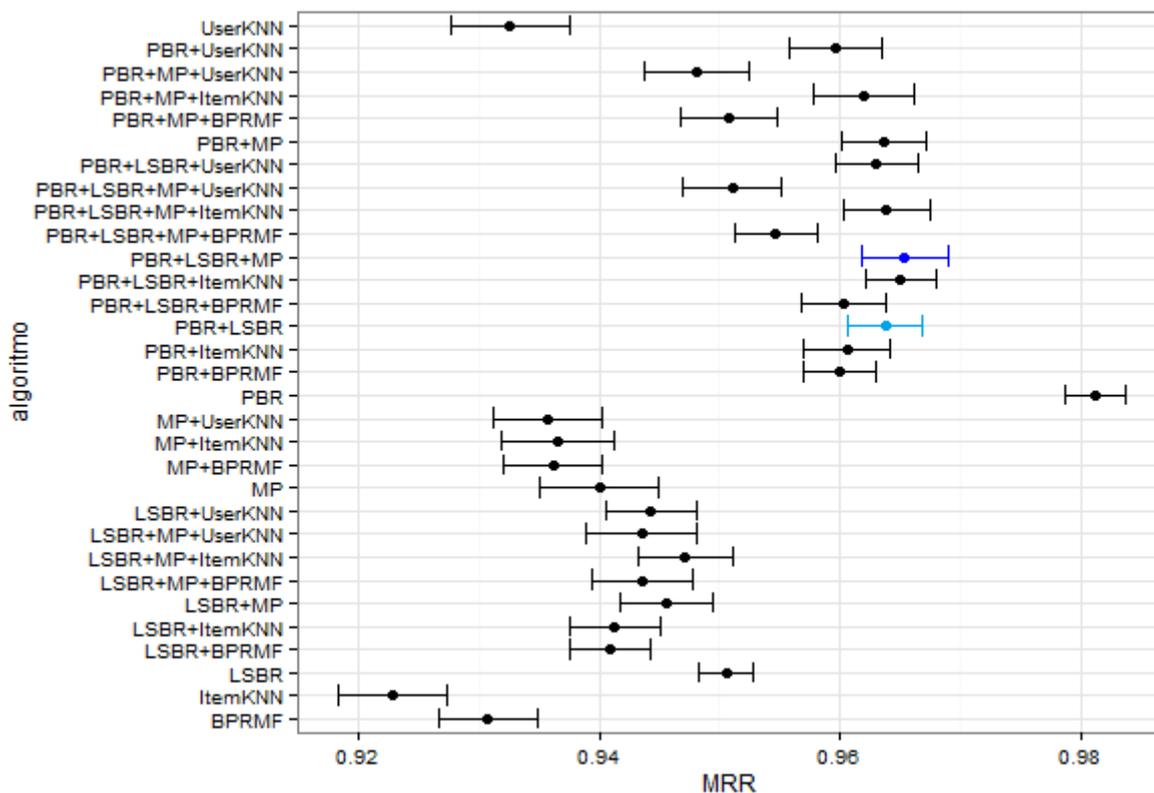


Figura 36. Intervalos de Confiança relativos à métrica MAP (%treinamento=55%).



**Figura 37. Intervalos de Confiança relativos à métrica MRR (%treinamento=55%).**



**Figura 38. Intervalos de Confiança relativos à métrica NDCG (%treinamento=55%).**

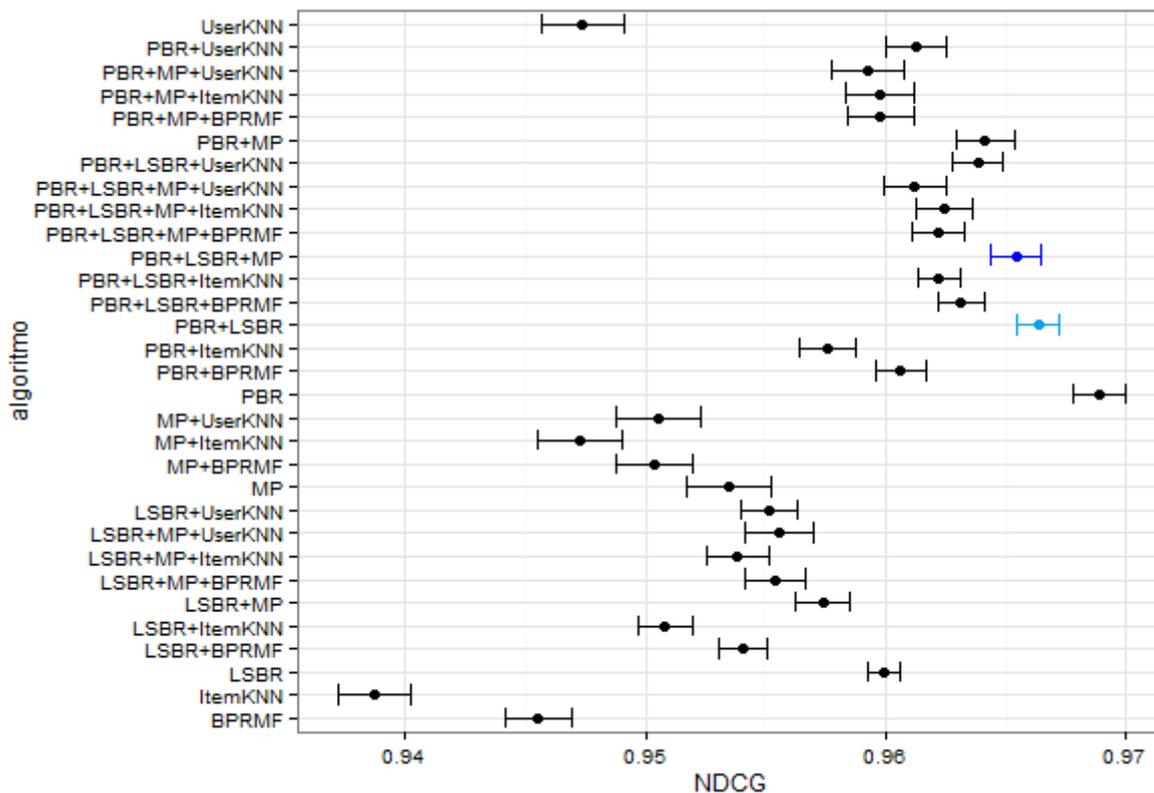


Figura 39. Intervalos de Confiança relativos à métrica P@5 (%treinamento=55%).

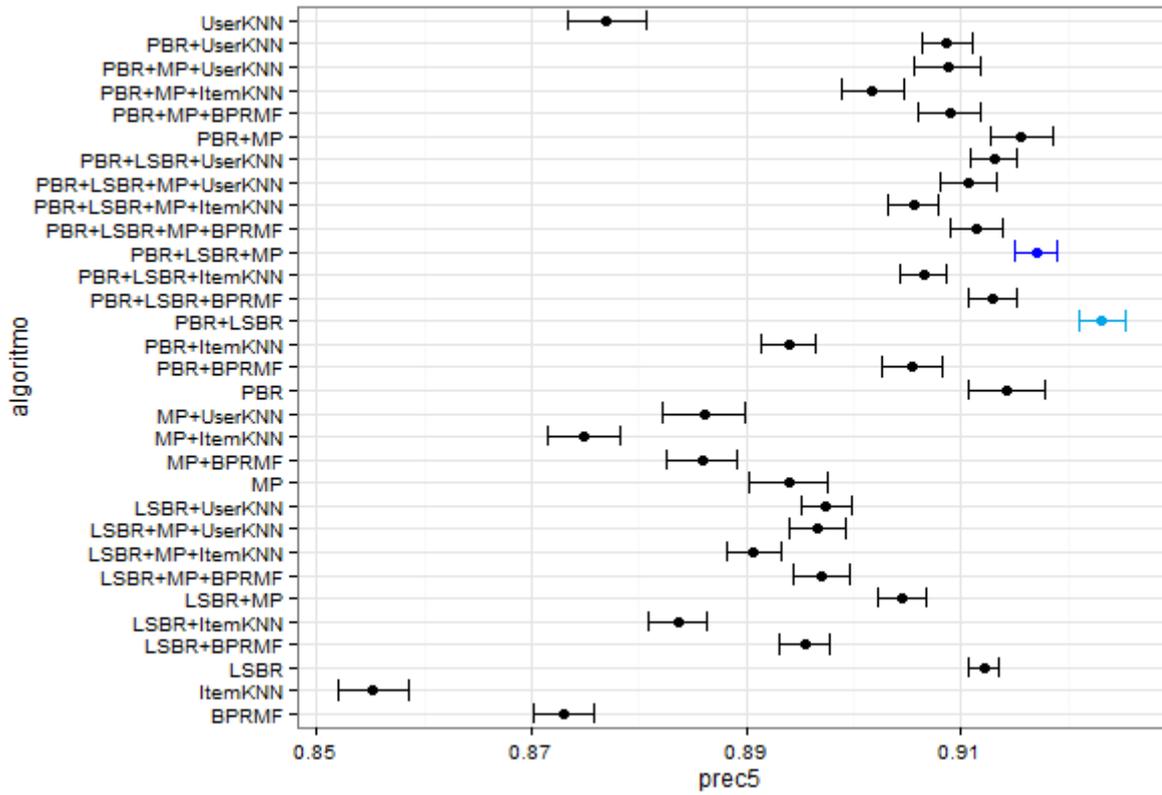


Figura 40. Intervalos de Confiança relativos à métrica R@5 (%treinamento=55%).

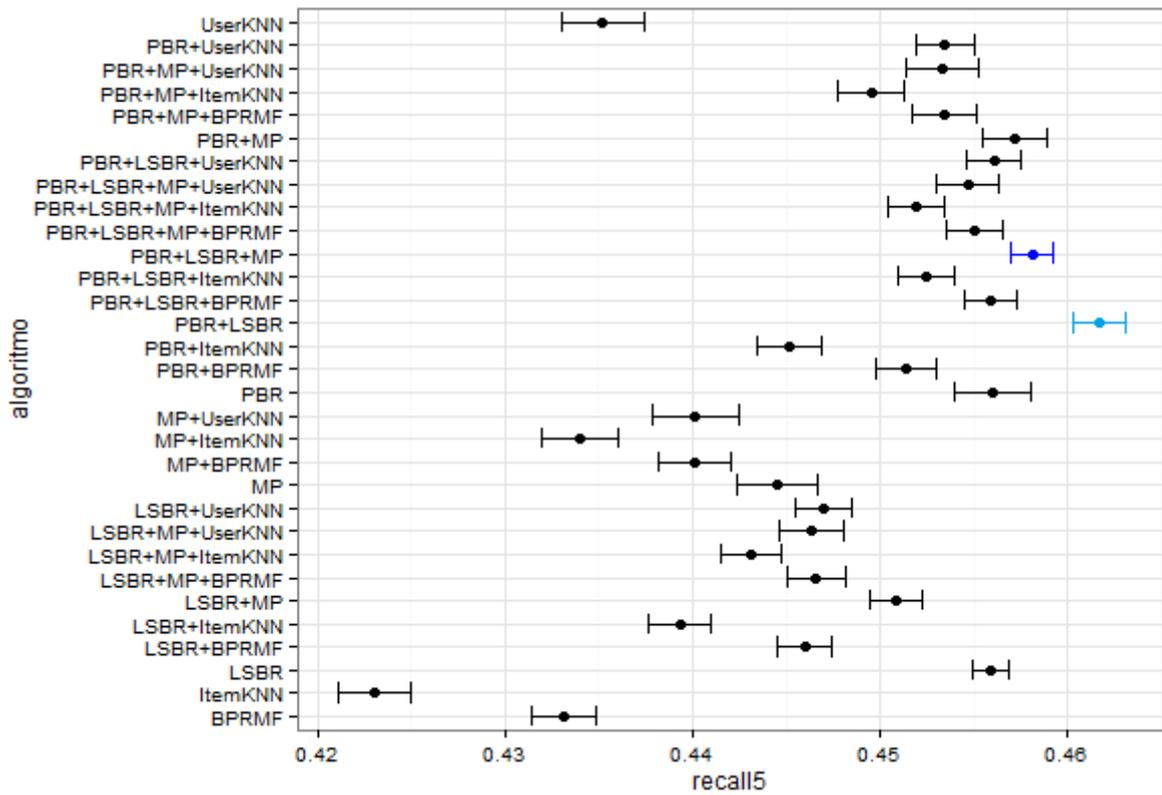


Figura 41. Intervalos de Confiança relativos à métrica AUC (%treinamento=65%).

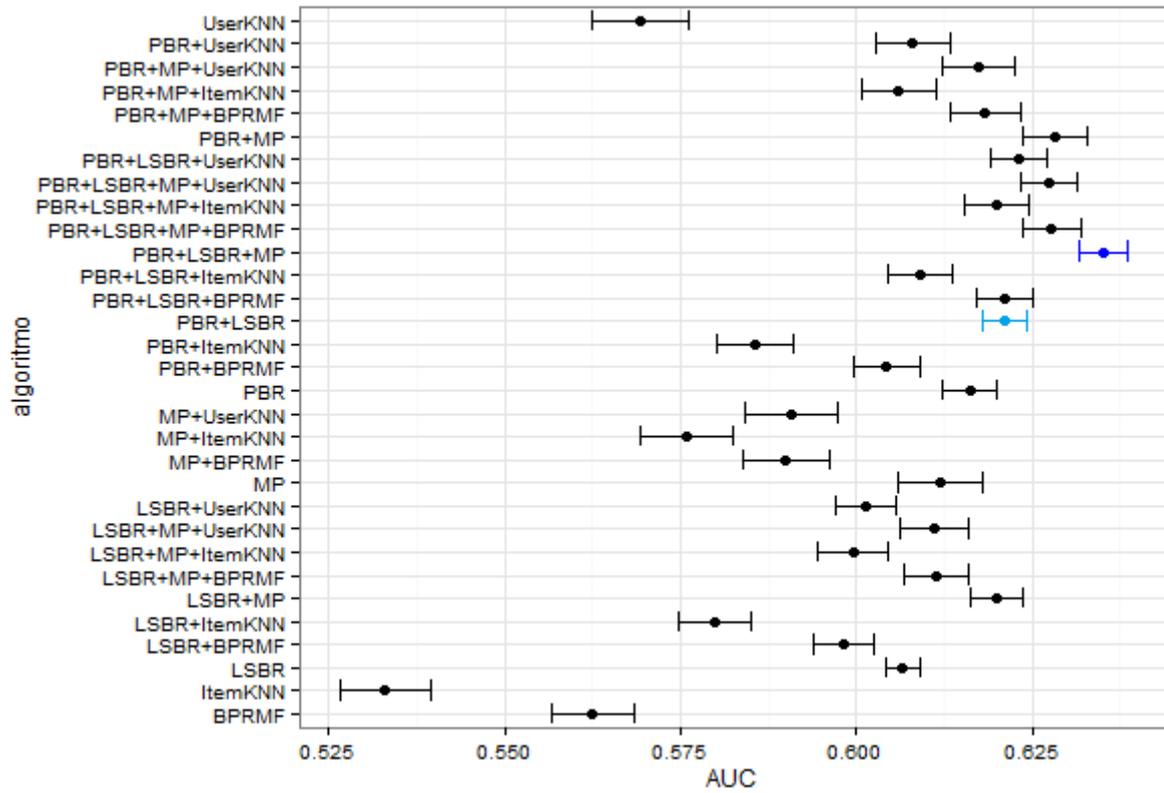
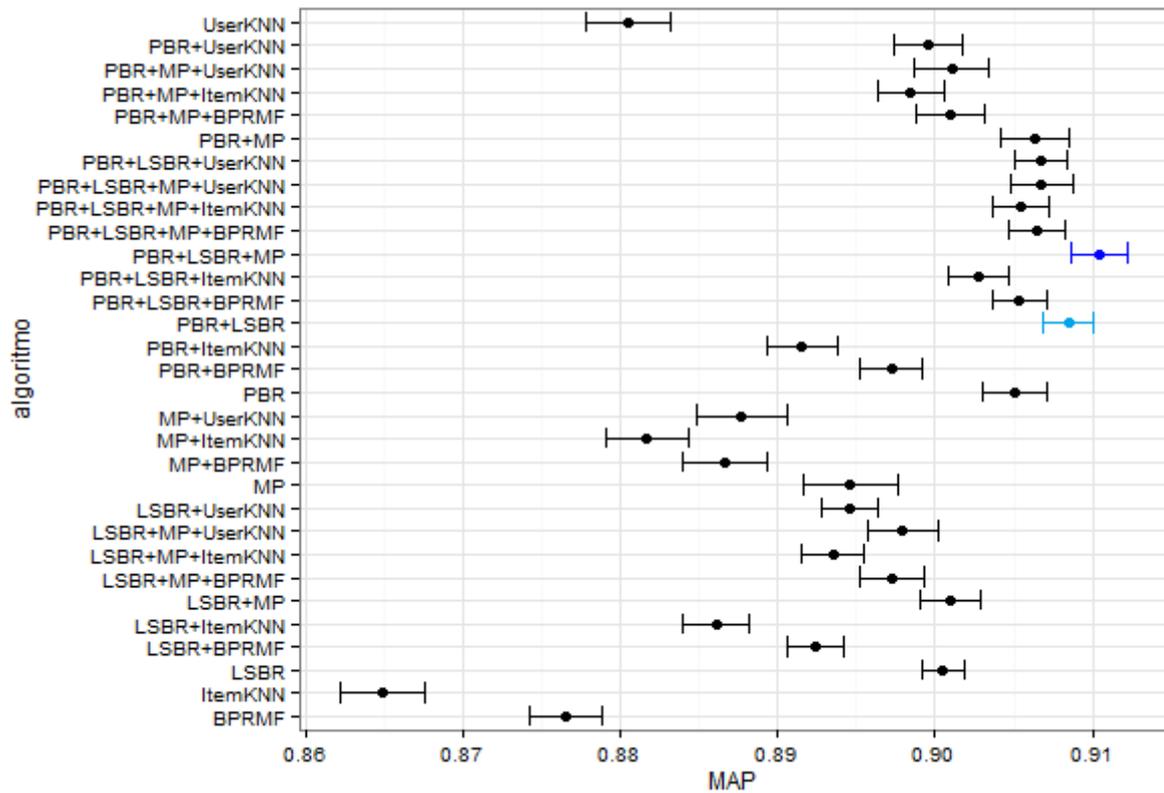
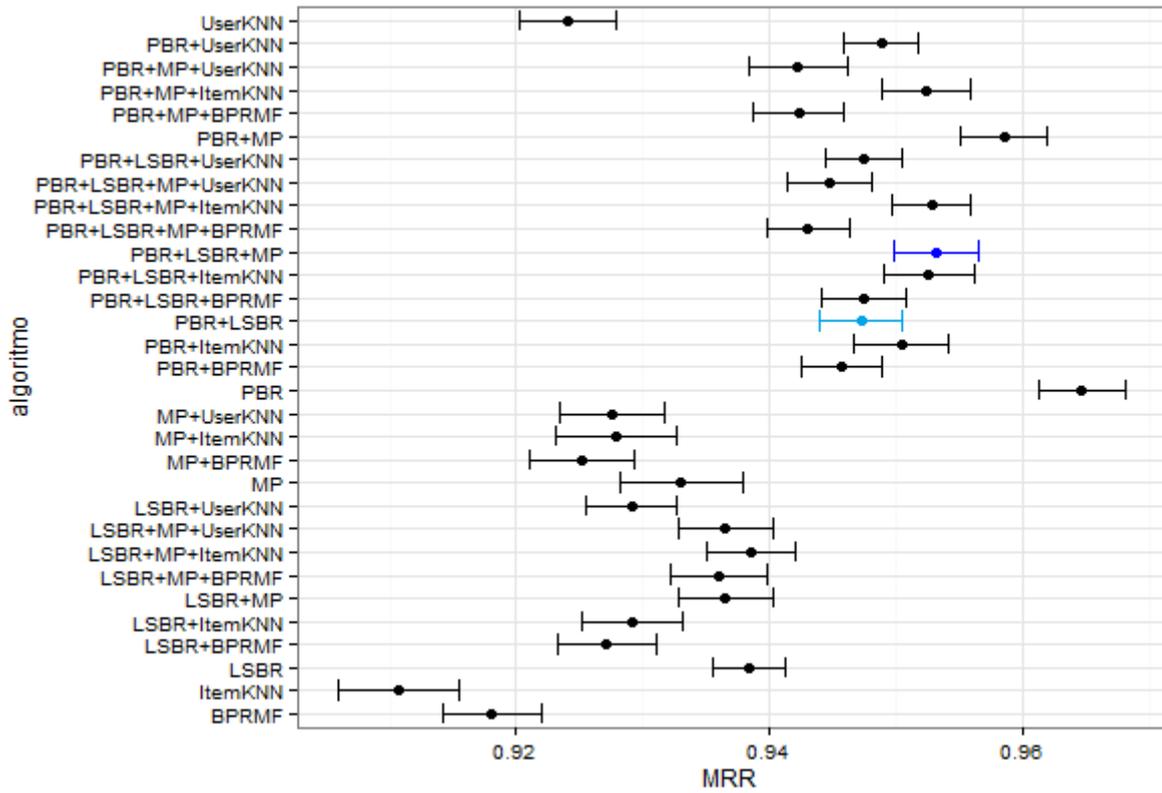


Figura 42. Intervalos de Confiança relativos à métrica MAP (%treinamento=65%).



**Figura 43. Intervalos de Confiança relativos à métrica MRR (%treinamento=65%).**



**Figura 44. Intervalos de Confiança relativos à métrica NDCG (%treinamento=65%).**

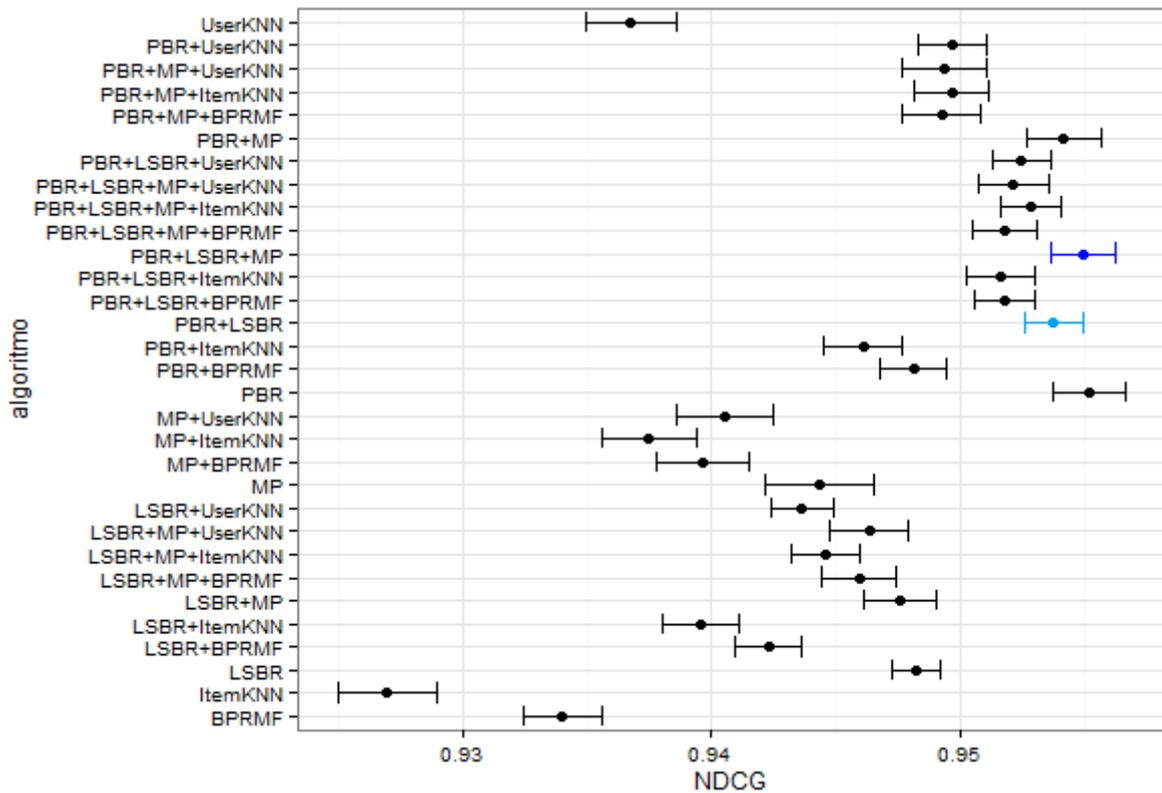


Figura 45. Intervalos de Confiança relativos à métrica P@5 (%treinamento=65%).

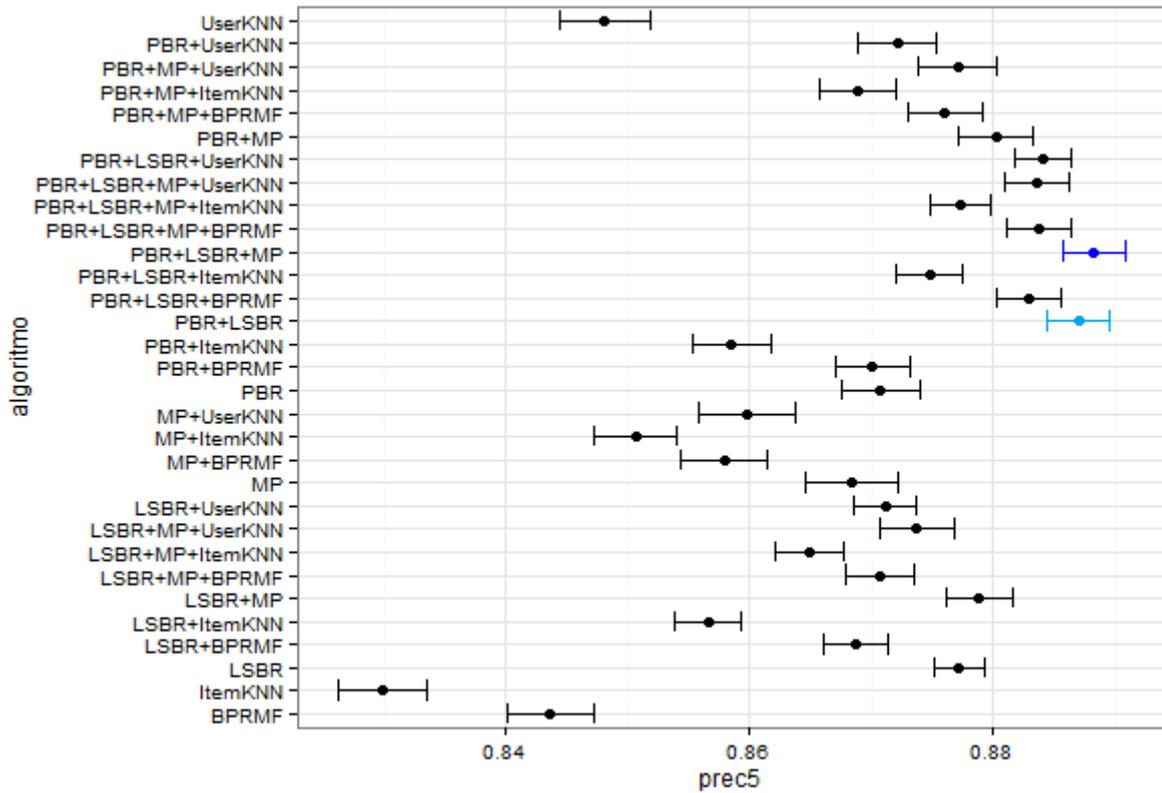


Figura 46. Intervalos de Confiança relativos à métrica R@5 (%treinamento=65%).

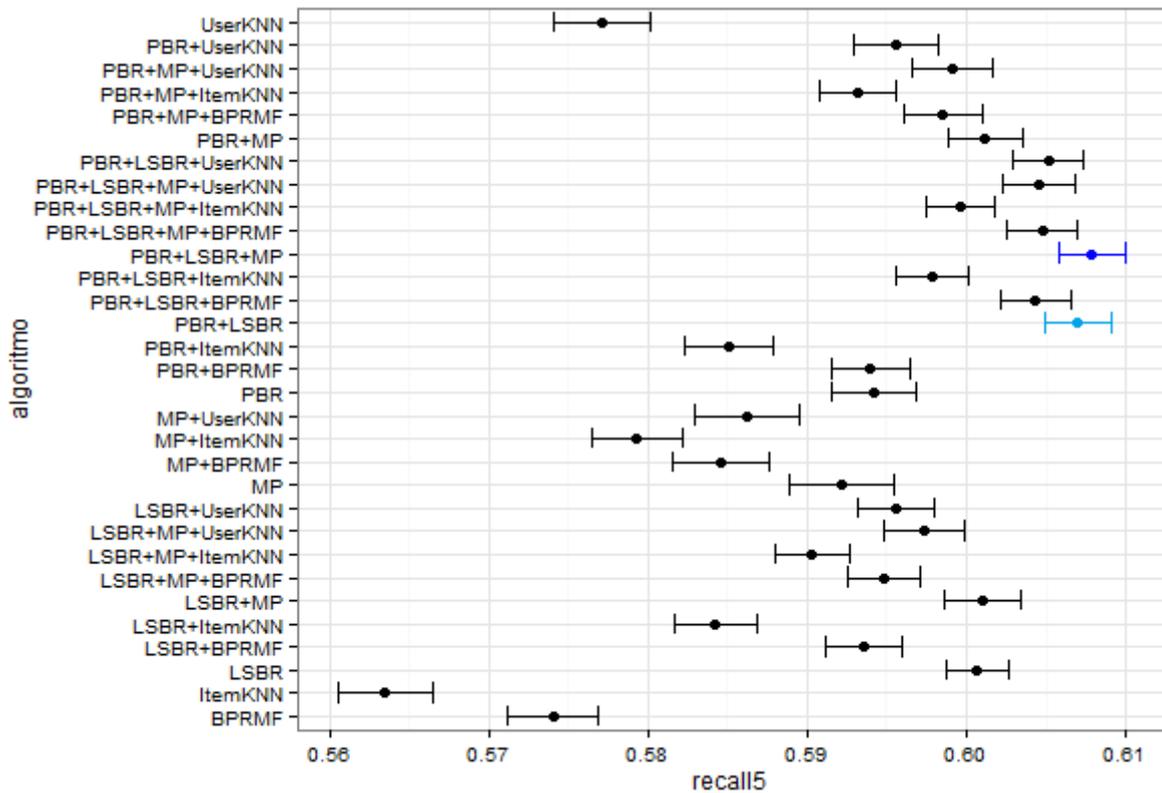


Figura 47. Intervalos de Confiança relativos à métrica AUC (%treinamento=75%).

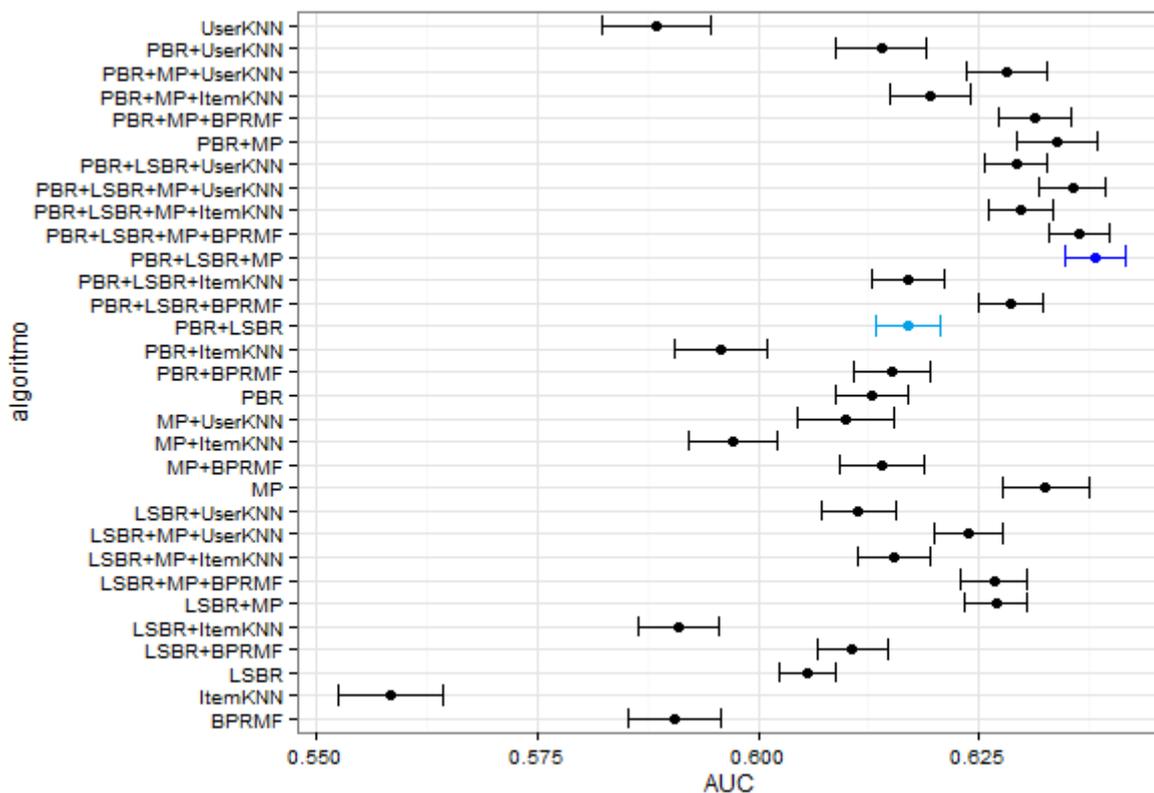


Figura 48. Intervalos de Confiança relativos à métrica MAP (%treinamento=75%).

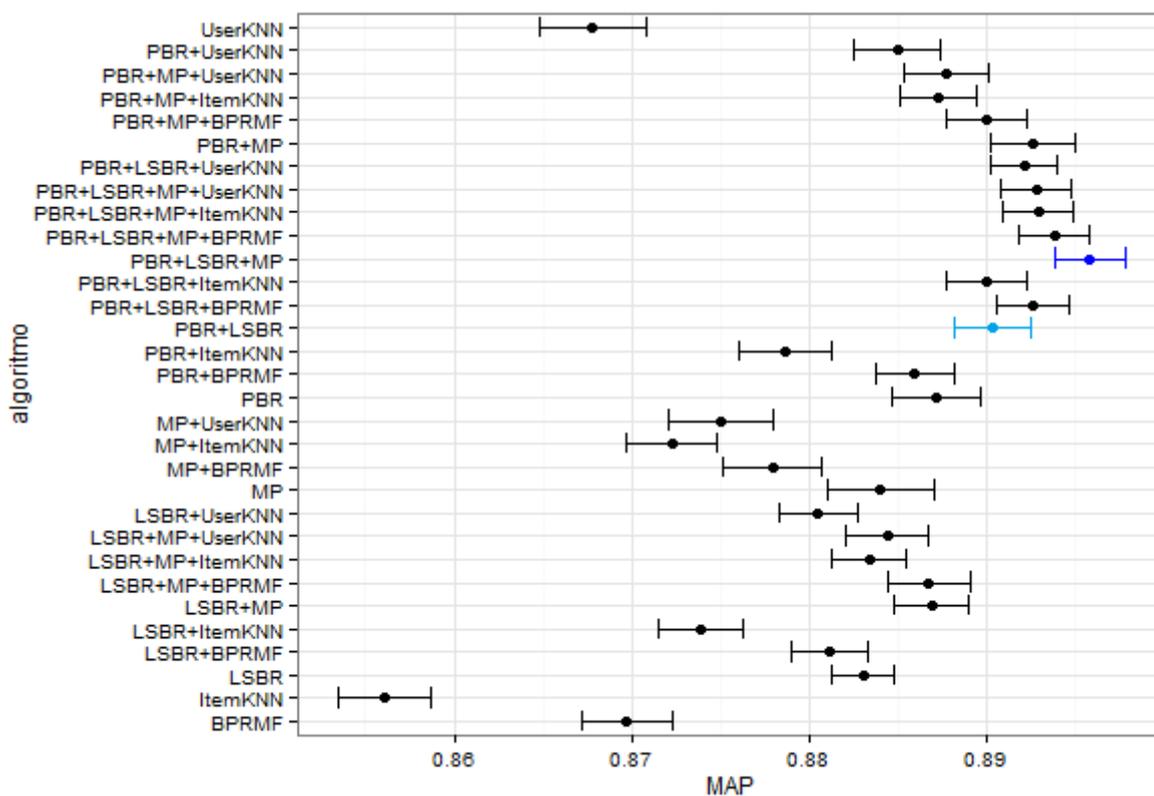


Figura 49. Intervalos de Confiança relativos à métrica MRR (%treinamento=75%).

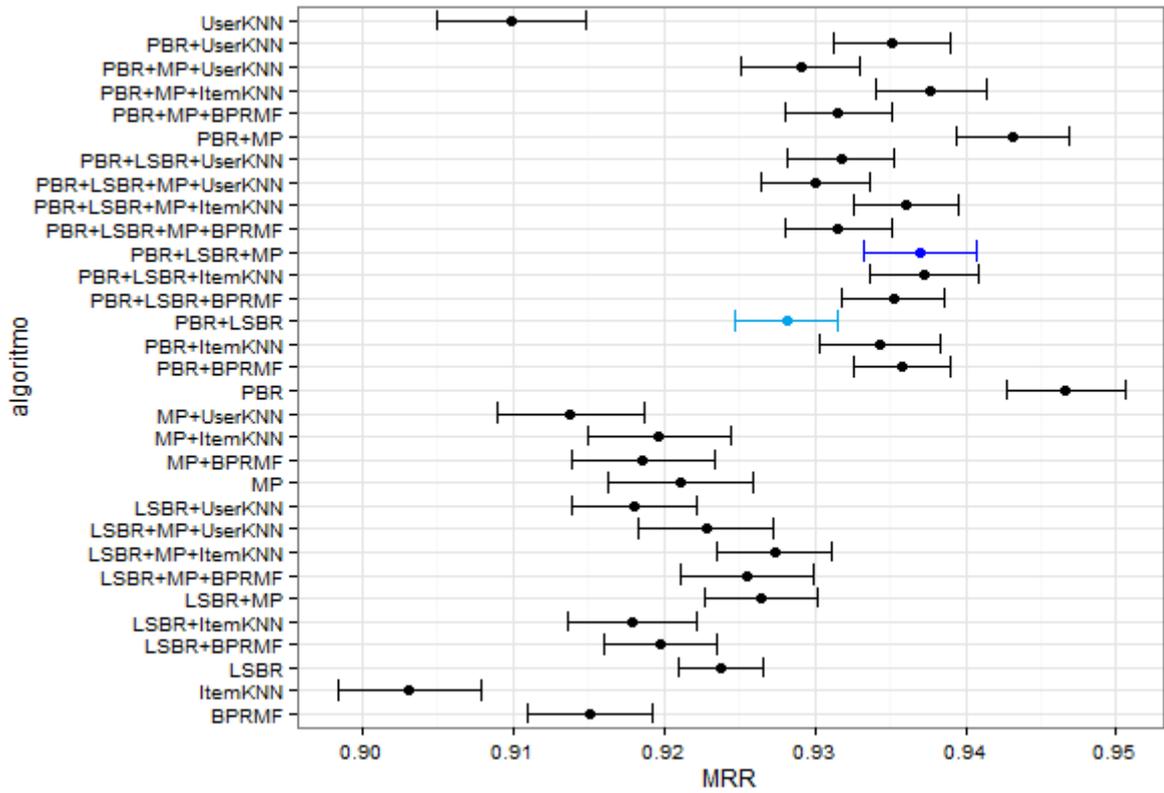


Figura 50. Intervalos de Confiança relativos à métrica NDCG (%treinamento=75%).

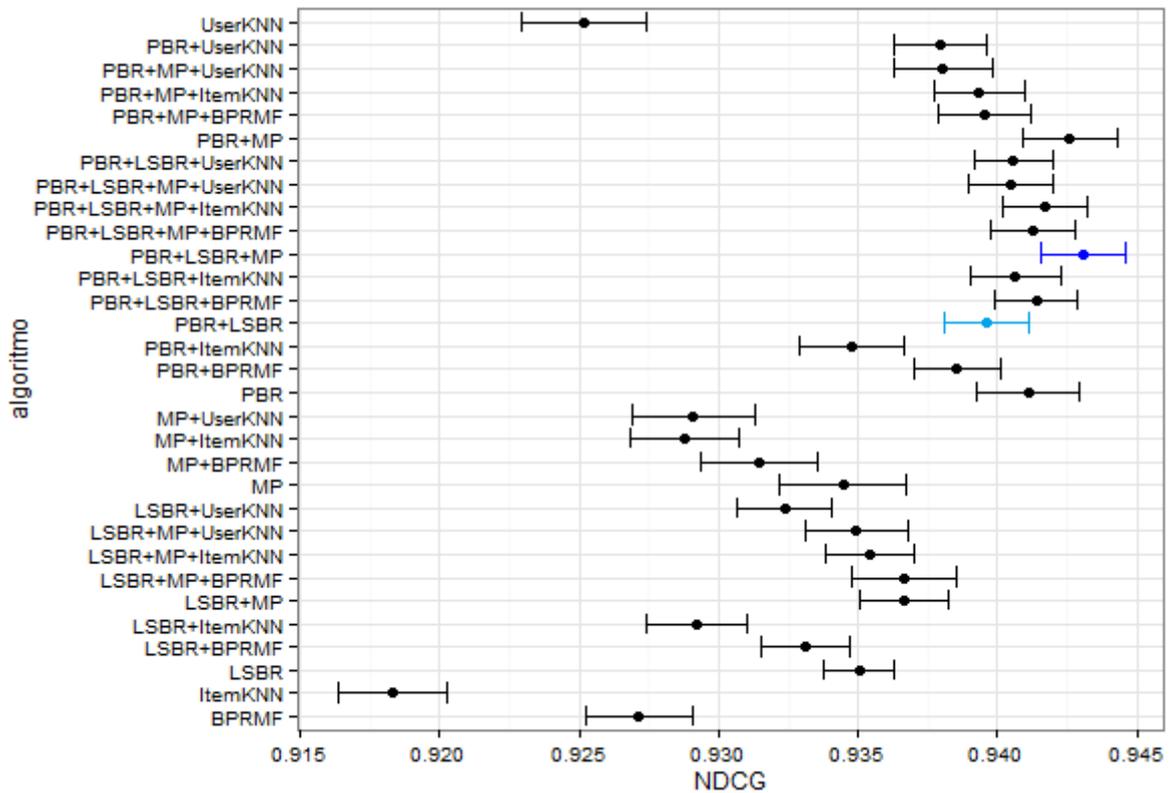


Figura 51. Intervalos de Confiança relativos à métrica P@5 (%treinamento=75%).

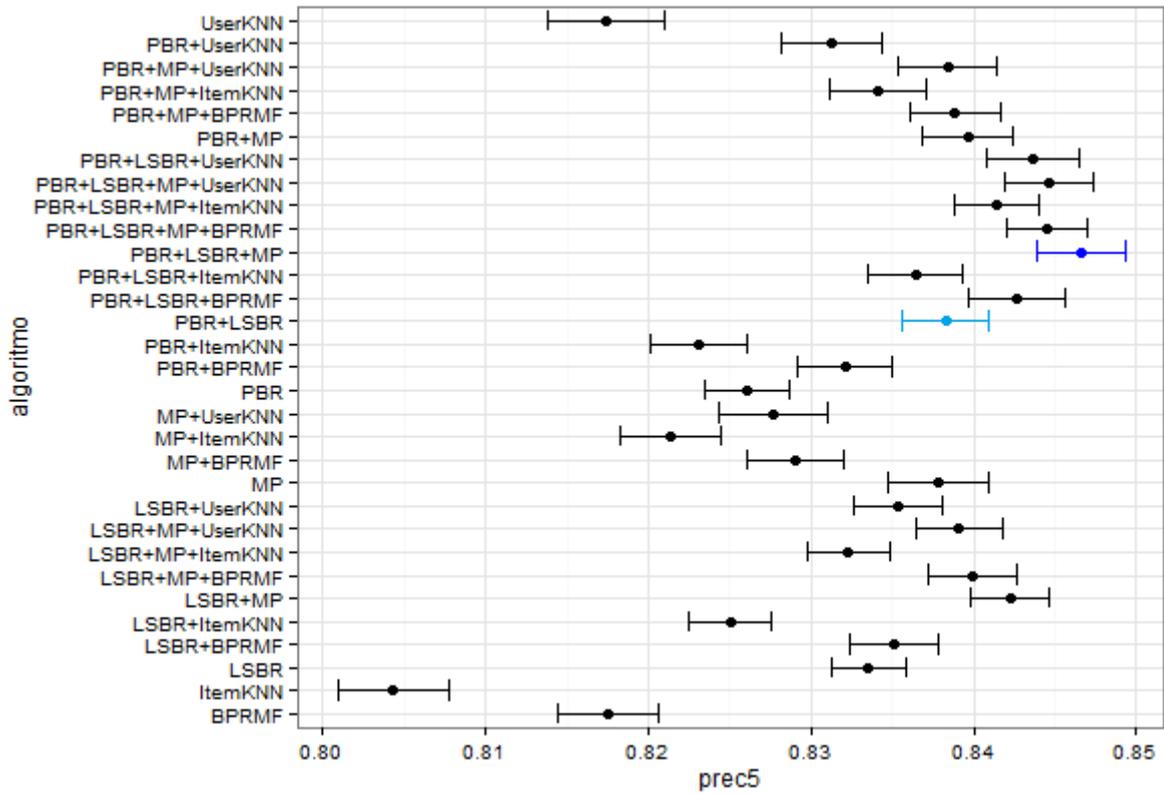
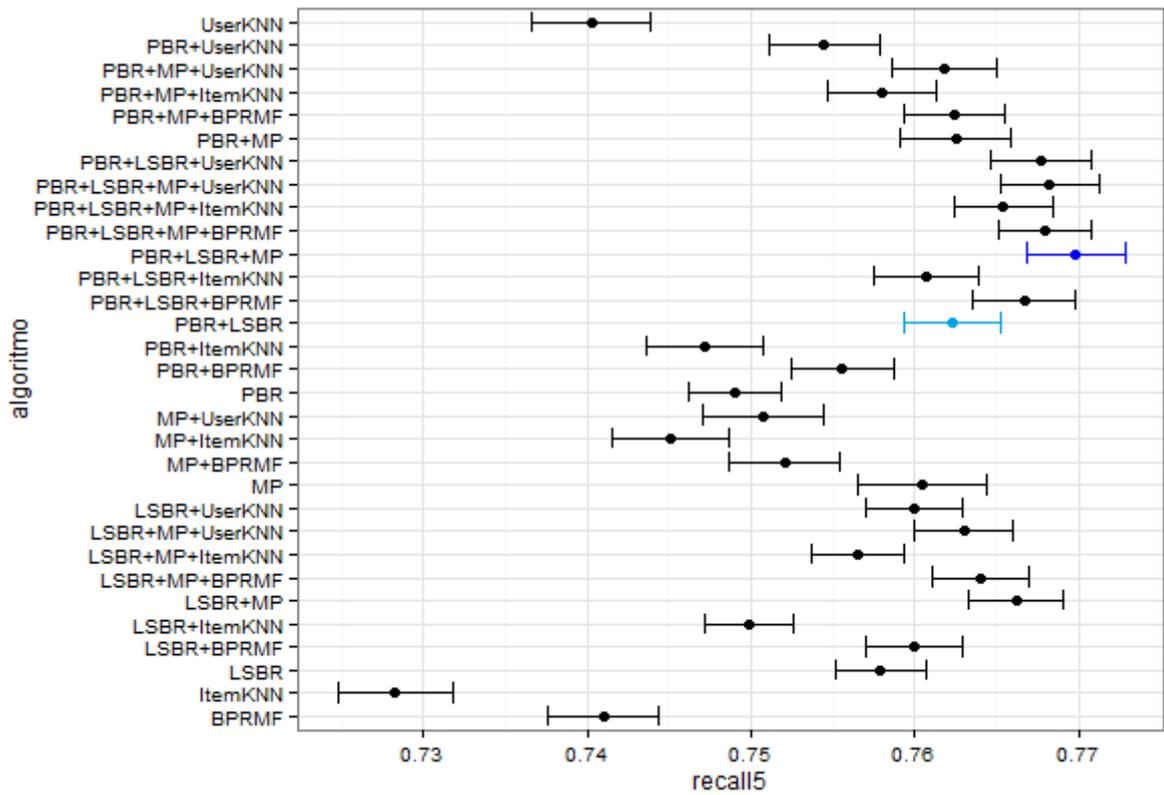


Figura 52. Intervalos de Confiança relativos à métrica R@5 (%treinamento=75%).



# Anexo A

## Instrumento de Mensuração de Estilos de Aprendizagem

Questionário traduzido por Marcius F. Giorgetti e Nidia Pavan Kuri, a partir do Índice de Estilos de Aprendizagem (*Index of Learning Styles — ILS*) desenvolvido por Richard M. Felder e Barbara A. Soloman para determinar preferências de aprendizagem em quatro dimensões do Modelo de Felder–Silverman.

### Instruções para preenchimento

Para cada uma das perguntas numeradas a seguir, selecione "a" ou "b" para indicar sua resposta. Se ambas as alternativas se aplicam a você, escolha a que se aplica com maior frequência.

### Questionário

1. Eu compreendo melhor alguma coisa depois de
  - (a) experimentar.
  - (b) refletir sobre ela.
2. Eu me considero
  - (a) realista.
  - (b) inovador(a).
3. Quando eu penso sobre o que fiz ontem, é mais provável que aflorem
  - (a) figuras.
  - (b) palavras.

4. Eu tendo a
- (a) compreender os detalhes de um assunto, mas a estrutura geral pode ficar imprecisa.
  - (b) compreender a estrutura geral de um assunto, mas os detalhes podem ficar imprecisos.
5. Quando estou aprendendo algum assunto novo, me ajuda
- (a) falar sobre ele.
  - (b) refletir sobre ele.
6. Se eu fosse um professor, eu preferiria ensinar uma disciplina
- (a) que trate com fatos e situações reais.
  - (b) que trate com idéias e teorias.
7. Eu prefiro obter novas informações através de
- (a) figuras, diagramas, gráficos ou mapas.
  - (b) instruções escritas ou informações verbais.
8. Quando eu compreendo
- (a) todas as partes, consigo entender o todo.
  - (b) o todo, consigo ver como as partes se encaixam.
9. Em um grupo de estudo, trabalhando um material difícil, eu provavelmente
- (a) tomo a iniciativa e contribuo com idéias.
  - (b) assumo uma posição discreta e escuto.
10. Acho mais fácil
- (a) aprender fatos.
  - (b) aprender conceitos.
11. Em um livro com uma porção de figuras e desenhos, eu provavelmente
- (a) observo as figuras e desenhos cuidadosamente.
  - (b) atento para o texto escrito.
12. Quando resolvo problemas de matemática, eu
- (a) usualmente trabalho de maneira a resolver uma etapa de cada vez.
  - (b) frequentemente antevejo as soluções, mas tenho que me esforçar muito para conceber as etapas para chegar a elas.

13. Nas disciplinas que cursei eu
- (a) em geral fiz amizade com muitos dos colegas.
  - (b) raramente fiz amizade com muitos dos colegas.
14. Em literatura de não-ficção, eu prefiro
- (a) algo que me ensine fatos novos ou me indique como fazer alguma coisa.
  - (b) algo que me apresente novas idéias para pensar.
15. Eu gosto de professores
- (a) que colocam uma porção de diagramas no quadro.
  - (b) que gastam bastante tempo explicando.
16. Quando estou analisando uma estória ou novela eu
- (a) penso nos incidentes e tento colocá-los juntos para identificar os temas.
  - (b) tenho consciência dos temas quando termino a leitura e então tenho que voltar atrás para encontrar os incidentes que os confirmem.
17. Quando inicio a resolução de um problema para casa, normalmente eu
- (a) começo a trabalhar imediatamente na solução.
  - (b) primeiro tento compreender completamente o problema.
18. Prefiro a idéia do
- (a) certo.
  - (b) teórico.
19. Relembro melhor
- (a) o que vejo.
  - (b) o que ouço.
20. É mais importante para mim que o professor
- (a) apresente a matéria em etapas sequenciais claras.
  - (b) apresente um quadro geral e relacione a matéria com outros assuntos.
21. Eu prefiro estudar
- (a) em grupo.
  - (b) sozinho(a).

22. Eu costumo ser considerado(a)
- (a) cuidadoso(a) com os detalhes do meu trabalho.
  - (b) criativo(a) na maneira de realizar meu trabalho.
23. Quando busco orientação para chegar a um lugar desconhecido, eu prefiro
- (a) um mapa.
  - (b) instruções por escrito.
24. Eu aprendo
- (a) num ritmo bastante regular. Se estudar pesado, eu "chego lá".
  - (b) em saltos. Fico totalmente confuso(a) por algum tempo e, então, repentinamente eu tenho um "estalo".
25. Eu prefiro primeiro
- (a) experimentar as coisas.
  - (b) pensar sobre como é que eu vou fazer.
26. Quando estou lendo como lazer, eu prefiro escritores que
- (a) explicitem claramente o que querem dizer.
  - (b) dizem as coisas de maneira criativa, interessante.
27. Quando vejo um diagrama ou esquema em uma aula, relembro mais facilmente
- (a) a figura.
  - (b) o que o(a) professor(a) disse a respeito dela.
28. Quando considero um conjunto de informações, provavelmente eu
- (a) presto mais atenção nos detalhes e não percebo o quadro geral.
  - (b) procuro compreender o quadro geral antes de atentar para os detalhes.
29. Relembro mais facilmente
- (a) algo que fiz.
  - (b) algo sobre o que pensei bastante.
30. Quando tenho uma tarefa para executar, eu prefiro
- (a) dominar uma maneira para a execução da tarefa.
  - (b) encontrar novas maneiras para a execução da tarefa.

31. Quando alguém está me mostrando dados, eu prefiro  
(a) diagramas e gráficos.  
(b) texto resumizando os resultados.
32. Quando escrevo um texto, eu prefiro trabalhar (pensar a respeito ou escrever)  
(a) a parte inicial do texto e avançar ordenadamente.  
(b) diferentes partes do texto e ordená-las depois.
33. Quando tenho que trabalhar em um projeto em grupo, eu prefiro que se faça primeiro  
(a) um debate (brainstorming) em grupo, onde todos contribuem com idéias.  
(b) um brainstorming individual, seguido de reunião do grupo para comparar idéias.
34. Considero um elogio chamar alguém de  
(a) sensível.  
(b) imaginativo.
35. Das pessoas que conheço em uma festa, provavelmente eu me recordo melhor  
(a) de sua aparência.  
(b) do que elas disseram de si mesmas.
36. Quando estou aprendendo um assunto novo, eu prefiro  
(a) concentrar-me no assunto, aprendendo o máximo possível.  
(b) tentar estabelecer conexões entre o assunto e outros com ele relacionados.
37. Mais provavelmente sou considerado(a)  
(a) expansivo(a).  
(b) reservado(a).
38. Prefiro disciplinas que enfatizam  
(a) material concreto (fatos, dados).  
(b) material abstrato (conceitos, teorias).
39. Para entretenimento, eu prefiro  
(a) assistir televisão.  
(b) ler um livro.

40. Alguns professores iniciam suas preleções com um resumo do que irão cobrir. Tais resumos são

- (a) de alguma utilidade para mim.
- (b) muito úteis para mim.

41. A idéia de fazer o trabalho de casa em grupo, com a mesma nota para todos do grupo,

- (a) me agrada.
- (b) não me agrada.

42. Quando estou fazendo cálculos longos,

- (a) tendo a repetir todos os passos e conferir meu trabalho cuidadosamente.
- (b) acho cansativo conferir o meu trabalho e tenho que me esforçar para fazê-lo.

43. Tendo a descrever os lugares onde estive

- (a) com facilidade e com bom detalhamento.
- (b) com dificuldade e sem detalhamento.

44. Quando estou resolvendo problemas em grupo, mais provavelmente eu

- (a) penso nas etapas do processo de solução.
- (b) penso nas possíveis consequências, ou sobre as aplicações da solução para uma ampla faixa de áreas.

# Anexo B

## Instrumento de Mensuração de Traços de Personalidade

Inventário traduzido por Carlos Eduardo Pimentel a partir do inventário TIPI — *Ten Item Personality Inventory*, desenvolvido por Samuel D. Gosling, Peter J. Rentfrow e William B. Swann Jr. para extrair os Traços de Personalidade com base no modelo *Big Five*.

### Instruções para preenchimento

Escreva um número ao lado de cada afirmação indicando em que medida você concorda ou discorda.

### Inventário

1	2	3	4	5	6	7
Discordo fortemente	Discordo moderadamente	Discordo um pouco	Nem concordo nem discordo	Concordo um pouco	Concordo moderadamente	Concordo fortemente

Eu me vejo como alguém...

- 1) Extrovertido, entusiasta.
- 2) Crítico, briguento.
- 3) Confiável, auto-disciplinado.
- 4) Ansioso, que se chateia facilmente.
- 5) Aberto a novas experiências, complexo.
- 6) Reservado, quieto.
- 7) Simpático, acolhedor.
- 8) Desorganizado, descuidado.
- 9) Calmo, emocionalmente estável.
- 10) Convencional, sem criatividade.