

UNIVERSIDADE FEDERAL DE GOIÁS
INSTITUTO DE INFORMÁTICA

FERNANDO RIBEIRO TRINDADE

Predição de Desempenho no Moodle usando Princípios da Andragogia

Goiânia
2020



UNIVERSIDADE FEDERAL DE GOIÁS
INSTITUTO DE INFORMÁTICA

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do material bibliográfico

Dissertação Tese

2. Nome completo do autor

Fernando Ribeiro Trindade

3. Título do trabalho

Predição de Desempenho no Moodle usando Princípios da Andragogia

4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento SIM NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

a) consulta ao(à) autor(a) e ao(à) orientador(a);

b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação.

O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Deller James Ferreira, Professor do Magistério Superior**, em 25/05/2020, às 09:59, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do

[Decreto nº 8.539, de 8 de outubro de 2015.](#)



Documento assinado eletronicamente por **FERNANDO RIBEIRO TRINDADE, Discendente**, em 25/05/2020, às 10:03, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do

[Decreto nº 8.539, de 8 de outubro de 2015.](#)



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1346005** e o código CRC **1B17AB12**.

FERNANDO RIBEIRO TRINDADE

Predição de Desempenho no Moodle usando Princípios da Andragogia

Dissertação apresentada ao Programa de Pós-Graduação do Instituto de Informática da Universidade Federal de Goiás, como requisito parcial para obtenção do título de Mestre em Computação.

Área de concentração: Informática e Educação.

Orientador: Prof. Ana Paula Laboissière Ambrósio

Co-Orientador: Prof. Deller James Ferreira

Goiânia
2020

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Ribeiro Trindade, Fernando

Predição de Desempenho no Moodle usando Princípios da Andragogia [manuscrito] / Fernando Ribeiro Trindade. - 2020. CXLVI, 146 f.

Orientador: Prof. Ana Paula Laboissière Ambrósio; co-orientador Deller James Ferreira.

Dissertação (Mestrado) - Universidade Federal de Goiás, Instituto de Informática (INF), Programa de Pós-Graduação em Ciência da Computação, Goiânia, 2020.

Bibliografia. Apêndice.

Inclui gráfico, tabelas, algoritmos, lista de figuras, lista de tabelas.

1. Predição Desempenho. 2. Tutoria. 3. EaD. 4. Andragogia. 5. Framework. I. Laboissière Ambrósio, Ana Paula, orient. II. Título.

CDU 004



UNIVERSIDADE FEDERAL DE GOIÁS

INSTITUTO DE INFORMÁTICA

ATA DE DEFESA DE DISSERTAÇÃO

Ata nº **11/2020** da sessão de Defesa de Dissertação de **Fernando Ribeiro Trindade**, que confere o título de Mestre em Ciência da Computação, na área de concentração em Ciência da Computação.

Aos quinze dias do mês de maio de dois mil e vinte, a partir das catorze horas, via sistema de webconferência da RNP, realizou-se a sessão pública de Defesa de Dissertação intitulada “**Predição de Desempenho no Moodle usando Princípios da Andragogia**”. Os trabalhos foram instalados pela Coorientadora, Professora Doutora Deller James Ferreira (INF/UFG), com a participação dos demais membros da Banca Examinadora: Professor Doutor Sean Wolfgang Matsui Siqueira (DIA/UNIRIO), membro titular externo, e Professor Doutor Cássio Leonardo Rodrigues (INF/UFG), membro titular interno. A sessão foi presidida pela coorientadora devido à inestimável perda da Profa. Ana Paula Laboissière Ambrósio, orientadora do discente, falecida em 10 de março de 2020. A realização da banca ocorreu por meio de videoconferência, em atendimento à recomendação de suspensão das atividades presenciais na UFG emitida pelo Comitê UFG para o Gerenciamento da Crise COVID-19, bem como à recomendação de isolamento social da Organização Mundial de Saúde e do Ministério da Saúde para enfrentamento da emergência de saúde pública decorrente do novo coronavírus. Durante a arguição os membros da banca não fizeram sugestão de alteração do título do trabalho. A Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Dissertação, tendo sido o candidato **aprovado** pelos seus membros. Proclamados os resultados pela Professora Doutora Deller James Ferreira, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, aos quinze dias do mês de maio de dois mil e vinte.

TÍTULO SUGERIDO PELA BANCA



Documento assinado eletronicamente por **Sean Wolfgang Matsui Siqueira, Usuário Externo**, em 15/05/2020, às 15:46, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Cássio Leonardo Rodrigues, Professor do Magistério Superior**, em 15/05/2020, às 15:54, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Deller James Ferreira, Professor do Magistério Superior**, em 15/05/2020, às 15:56, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **FERNANDO RIBEIRO TRINDADE, Discente**, em 15/05/2020, às 16:07, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).

A autenticidade deste documento pode ser conferida no site

https://sei.ufg.br/sei/controlador.php?acao=documento_imprimir_web&acao_origem=arvore_visualizar&id_documento=1381332&infra_sistema=1... 1/2



https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1282478** e o código CRC **3E793B35**.

Referência: Processo nº 23070.016294/2020-15

SEI nº 1282478

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador(a).

Fernando Ribeiro Trindade

Graduou-se em Ciências da Computação na UFG - Universidade Federal de Goiás. Durante a Graduação foi estagiário no laboratório de informática da faculdade de Ciências Sociais da UFG. Pós graduou-se em Gerenciamento de Projetos pela UCAM – Universidade Cândido Mendes. Durante o mestrado foi bolsista pela Fundação de Amparo à Pesquisa do Estado de Goiás. Atualmente é servidor do Tribunal de Justiça de Goiás, ocupando o cargo de analista de sistemas.

Dedico este trabalho à minha mãe, Maria de Fátima. E a minha esposa, Sabrina. E ao meu filho, João Pedro. E em memória da Prof. Dra. Ana Paula Laboissière Ambrósio, que me guiou com maestria durante os momentos mais difíceis do desenvolvimento desta dissertação e soube me tranquilizar, com palavras sábias, durante os momentos de angústias.

Agradecimentos

Agradeço imensamente a minha orientadora, Professora Dr^a. Ana Paula Laboisière Ambrósio, que deste o primeiro contato que tivemos se prontificou a me ajudar. Após me aceitar como orientando a professora me concedeu a oportunidade de aprender com suas experiências e me conduziu pelo caminho da sabedoria durante as fases mais difíceis do desenvolvimento deste trabalho.

Deixo também meu agradecimento especial a minha coorientadora, Professora Dr^a Deller James Ferreira, que me amparou nos momentos em que a minha orientadora não pode estar ao meu lado. Através de sua vasta experiência em escrita de artigos e dissertações colaborou com a finalização e revisão desta dissertação.

Ao colega, Igor Moreira, deixo meu agradecimento e reconhecimento pelo esforço dispendido para me auxiliar a compreender o seu trabalho. Por meio de suas explicações pude dar sequência ao seu trabalho e implementar novas funcionalidade, de forma a alcançar os objetivos propostos neste trabalho.

Aos diretores de informática do Tribunal de Justiça de Goiás, Luiz Mauro de Pádua Silveira e Anderson Yagi, que contribuíram imensamente consentido a liberação para acesso aos dados da EJUG. Agradeço também ao diretor de Infraestrutura, Giuliano Silva Oliveira, por ter liberado, prontamente, os dados para a condução desta pesquisa.

A gestora da escola judicial de Goiás, Claudivina Batista, um agradecimento especial por ter dispensado toda atenção e interesse na pesquisa. Aos meus coordenadores, Keila Sousa e Valdemar Ribeiro, que em vários momentos contribuíram com a condução deste trabalho ao concederem horário de trabalho flexível, para que as atividades do mestrado fossem cumpridas.

Agradeço aos funcionários do Instituto de Informática, que sempre se prontificaram em atender as solicitações administrativas do programa de mestrado.

Agradeço ao apoio recebido pela Fundação de Amparo à Pesquisa do Estado de Goiás, que financiou este trabalho e a publicação de artigos em congressos internacionais.

A melhor maneira de prever o futuro é inventá-lo.

Alan Kay,
Xerox Conference. Xerox Corporation - Palo Alto, 1971.

Resumo

Trindade Ribeiro, Fernando. **Predição de Desempenho no Moodle usando Princípios da Andragogia**. Goiânia, 2020. 146p. Dissertação de Mestrado. Instituto de Informática, Universidade Federal de Goiás.

De acordo com a literatura atual, as habilidades de docência dos tutores são fundamentais para se garantir a excelência no ensino e, conseqüentemente, o interesse dos alunos nos cursos. Em ambientes de ensino online alunos e tutores interagem entre si por meio dos diversos recursos de comunicação disponibilizados pelos ambientes virtuais de aprendizagem (AVA). Com isso, uma grande quantidade de dados educacionais é coletada pelos AVA's, viabilizando a realização de análises desses dados. Contudo, na literatura acadêmica poucos trabalhos foram conduzidos com o intuito de coletar dados comportamentais dos tutores e utilizar esses dados para realizar a predição de desempenho escolar dos alunos. Portanto, nesta dissertação foi elaborado um *framework* de características de tutoria correlacionadas ao bom desempenho escolar dos alunos. O *framework* foi utilizado para guiar a coleta de dados dos tutores, que foram utilizados para realizar a predição de desempenho dos alunos. As características de tutoria incluídas no *framework* foram extraídas de pesquisas anteriores, que investigaram cada atributo de tutoria, e de atributos de tutoria desejados pela Andragogia. A predição de desempenho dos alunos foi realizada a partir do desenvolvimento de uma extensão da ferramenta Moodle Predicta, que realiza a classificação dos alunos quanto à possível reprovação ou aprovação. A predição de desempenho dos alunos é feita a partir dos dados comportamentais dos alunos e tutores. A implementação da predição foi antecedida de uma análise de performance dos algoritmos classificadores, e o classificador implementado foi o *RandomForest*, que obteve melhor desempenho segundo a métrica AUC. Os dados educacionais do Moodle da escola judicial de Goiás (EJUG) foram utilizados em um estudo de caso. Duas análises exploratórias de dados foram conduzidas para se conhecer os cursos e investigar as características de tutoria do *framework* nos tutores da EJUG. Os dados dos tutores da EJUG, foram incluídos no modelo de classificação, utilizado na predição de desempenho dos alunos, mostrando que as ações dos tutores podem impactar nas conquistas escolares dos alunos.

Palavras-chave

EaD, Predição de desempenho, Tutoria, Andragogia, Moodle

Abstract

Trindade Ribeiro, Fernando. **Performance Prediction in Moodle using Andragogy Principles**. Goiânia, 2020. 146p. MSc. Dissertation. Instituto de Informática, Universidade Federal de Goiás.

According to current literature, the teaching skills of tutors are essential to ensure excellence in teaching and, consequently, the interest of students in courses. In online teaching environments, students and tutors interact with each other through the various communication resources provided by virtual learning environments (VLE). With this, a large amount of educational data is collected by AVAS's, making it possible to carry out analyzes of these data. However, in the academic literature, few studies have been conducted in order to collect behavioral data from tutors and use this data to make the prediction of students' school performance. Therefore, in this dissertation a framework of tutoring characteristics was elaborated correlated to the good school performance of students, and this framework was used to guide the data collection of tutors, which were used to make the prediction of student performance. The tutoring characteristics included in the framework were extracted from previous research, which investigated each tutoring attribute, and from tutoring attributes desired by Andragogy. The prediction of students' performance was carried out from the development of an extension of the Moodle Predicta tool, which performs classification of students as to possible failure or approval. The prediction of student performance is made from the behavioral data of students and tutors. The implementation of the prediction was preceded by a performance analysis of the classifying algorithms, and the implemented classifier was RandomForest, which achieved better performance according to the AUC metric. Educational data from Moodle from the Goiás Judicial School (EJUG) was used in a case study. Two exploratory data analyzes were conducted to learn about the courses and investigate the tutoring characteristics of the framework in EJUG tutors. The data from EJUG tutors were included in the classification model, used to predict student performance, showing that the actions of tutors can impact students' academic achievements.

Keywords

Online courses, Prediction Performance, Tutoring, Andragogy, Moodle

Sumário

Lista de Figuras	16
Lista de Tabelas	18
1 Introdução	20
1.1 Motivação	22
1.2 Problematização	23
1.3 Objetivos	24
1.3.1 Objetivo Geral	24
1.3.2 Objetivos Específicos	24
1.4 Justificativa	26
1.5 Estrutura da Dissertação	27
2 Conceitos Preliminares	29
2.1 Ambientes Virtuais de Aprendizagem	29
2.1.1 Público Alvo	30
Evasão em Ambientes Virtuais de Aprendizagem	30
2.1.2 O Moodle	31
2.1.3 Surveys e Feedback no Moodle	32
2.2 Mineração De Dados	33
2.2.1 Métodos de Mineração de Dados	34
Associações	34
Classificação	35
Árvores de Decisão	35
Agrupamento (<i>Clustering</i>)	35
2.2.2 Métricas de Desempenho para Classificadores	35
Acurácia	36
Precisão (<i>Precision</i>)	36
Recall	36
F-Measure	37
Matthews Correlation Coefficient (MCC)	37
Área Sob a Curva (AUC)	37
Precision Recall Curve (PRC)	38
2.2.3 Mineração de Dados Educacionais	38
2.2.4 Ferramentas de Mineração de Dados	39
WEKA	39
Linguagem e Ambiente: R	41
Arquivos ARFF	43

2.3	Andragogia - A Ciência de Ensinar Adultos	45
2.3.1	Andragogia vs. Pedagogia	46
2.3.2	Andragogia e o EaD	46
2.4	O Moodle Predicta	47
3	Metodologia de Pesquisa	49
3.1	Elaboração do <i>Framework</i> de Características dos Tutores	49
3.2	Escolha das Técnicas de Mineração de Dados Empregadas	50
3.3	Definição do Caso de Uso	51
3.4	Análise Exploratória dos Cursos e Tutores da EJUG	51
3.5	Desenvolvimento da Extensão do MP	51
3.6	Análise de Desempenho dos Classificadores	52
3.7	Avaliação da Ferramenta	52
4	Desenvolvimento do Estudo	53
4.1	Características dos Professores que Impactam o Desempenho dos Alunos: Uma Revisão Sistemática da Literatura	53
4.1.1	Questões de Pesquisa	53
4.1.2	Metodologia de Pesquisa	54
4.1.3	Definição da Expressão Geral de Busca	54
4.1.4	Escolha das bases de artigos	54
4.1.5	Critérios de Inclusão e Exclusão	55
4.1.6	Análise e Identificação das Características	57
4.1.7	Considerações Finais	61
4.2	O Framework de Características dos Tutores	61
4.2.1	Características dos Docentes: segundo a Literatura Acadêmica	62
4.2.2	Características dos Docentes: segundo a Andragogia	63
4.2.3	O Framework de Características de Tutoria	63
4.3	O Conjunto de Dados da EJUG	64
4.3.1	O Tribunal de Justiça de Goiás	65
4.3.2	A Escola Judicial de Goiás	65
4.3.3	Banco de Dados da EJUG	66
4.3.4	O Modelo de Dados do Moodle da EJUG	68
	Matrículas e Perfis de Usuário	69
	Fóruns	70
	Chats	70
	Questionários	71
	Tarefas	72
	Notas	73
	Logstore	74
4.4	Análise Exploratória: Os Cursos do TJGO	74
4.4.1	Métodos e Ferramentas	75
4.4.2	Os Cursos do TJGO	76
4.4.3	Conclusões	84
4.5	Análise Exploratória: Os Tutores da EJUG	84
4.5.1	Métodos e Ferramentas	85
4.5.2	Os Tutores da EJUG	86
4.5.3	Conclusões	95

4.6	A Extensão do Moodle Predicta	96
4.6.1	Configuração do MP	97
4.7	O Módulo de Visualização	98
4.7.1	Visualização de dados do Tutor	98
4.8	O Módulo de Predição	101
4.8.1	Metodologia de Predição	102
4.8.2	O Subconjunto de Dados Usados para Predição	103
4.8.3	Balanceamento dos Dados	105
4.8.4	Atributos dos Alunos Utilizados para Predição	107
4.8.5	Atributos dos Tutores Utilizados para Predição	108
4.8.6	Estratégias para Classificação do Tutor	109
	Clusterização	110
	Algoritmo das Médias	111
4.8.7	Seleção dos Algoritmos Classificadores	113
4.8.8	Análise de Desempenho dos Classificadores	115
	Análise Sem Inclusão das Ações dos Tutores	115
	Análise com a Inclusão das Ações dos Tutores	116
4.8.9	O Classificador <i>RandomForest</i>	117
4.8.10	Implementação da Predição	119
	Predição de Desempenho dos Alunos	119
	Predição dos Tutores	122
4.9	Avaliação da Extensão do Moodle Predicta	123
4.9.1	Perfil dos Avaliadores	124
4.9.2	A Avaliação	124
4.9.3	Recomendações dos Avaliadores	129
5	Considerações Finais	130
5.1	Limitações e Ameaças a Validade do Trabalho	132
5.2	Sugestões para Trabalhos Futuros	132
5.3	Artigos Aceitos e Publicados	133
	Referências Bibliográficas	135
A	Análise Completa de Desempenho dos Classificadores	140
A.1	Análise Sem Inclusão das Ações dos Tutores	141
A.2	Análise com a Inclusão das Ações dos Tutores	142
A	Questionário Avaliativo da Ferramenta Extensão do Moodle Predicta	145

Lista de Figuras

2.1	Processo de Descoberta de Conhecimento (FAYYAD, 1996).	34
2.2	Exemplo de AUC.	37
2.3	Tela inicial do WEKA (versão 3.8).	40
2.4	WEKA Explorer	40
2.5	WEKA Experimenter.	41
2.6	Tela inicial do RStudio (R versão 3.5; Rstudio versão 1.1).	42
2.7	RStudio: Comandos, <i>Datasets</i> e <i>Plots</i> .	42
2.8	RStudio: Script R.	43
2.9	Arquivo ARFF: seção de atributos.	44
2.10	Arquivo ARFF: seção de dados.	45
2.11	Arquitetura: Moodle Predicta (FELIX, 2017).	48
4.1	Artigos x Repositórios.	55
4.2	Artigos Aceitos.	56
4.3	Artigos Excluídos.	57
4.4	Categorias de cursos presentes na base de dados MySQL.	67
4.5	Categorias de cursos presentes na base de dados PostgreSQL.	67
4.6	Relacionamentos da tabela Curso.	68
4.7	Relacionamentos para Realização de Matrícula e Atribuição de Perfil.	69
4.8	Relacionamentos necessários para funcionamento do Fórum.	70
4.9	Relacionamentos entre tabelas de Chat.	71
4.10	Relacionamentos dos Questionários.	71
4.11	Relacionamentos que envolvem Tarefas.	72
4.12	Relacionamentos do Gradebook do Moodle.	73
4.13	Relacionamentos do sistema de log.	74
4.14	Análise Multivariada dos Cursos.	78
4.15	Quantidade de Questionários de Feedback por Tipo de Curso.	79
4.16	Notas Médias COLLES x Grupos de Questões.	80
4.17	Notas Médias ATTLS x Grupos de Questões.	81
4.18	Notas Médias x Ano.	81
4.19	Feedback dos Tutores em Tarefas e Quizzes.	82
4.20	Distribuição de Arquivos.	83
4.21	Evasão por Curso.	83
4.22	Gráfico que relaciona o sexo com a titulação do tutor.	86
4.23	Relação entre Motivação e Comunicação e a Taxa de aprovação.	89
4.24	Estímulo do pensamento e autorreflexão correlacionado com a taxa de aprovação.	90

4.25	Análise multivariada das atividades realizada pelos docentes correlacionadas com a taxa de aprovação.	91
4.26	Proporção dos tipos de arquivos utilizados por tutores.	92
4.27	Relação entre Total de Feedback e Taxa de Conclusão.	93
4.28	Auto-diretividade de acordo com tempo disponível para realização das atividades.	94
4.29	Avaliação dos atributos andragógicos: experiência, motivação e avaliações.	95
4.30	Configuração MP.	98
4.31	Relatórios de atividade no Fórum.	99
4.32	Relatórios de <i>Quizzes</i> .	99
4.33	Participações em <i>Chats</i> .	99
4.34	Tempo Dedicado ao Curso.	100
4.35	Survey: Avaliação do Tutor.	100
4.36	Questionário de Feedback.	101
4.37	Sistemática de Construção dos Conjuntos de Treinamento.	103
4.38	Proporção de Classes no Conjunto de Dados.	106
4.39	Árvore de Decisão Induzida no Conjunto de Dados da EJUG.	114
4.40	Cálculo da Importância dos Atributos: <i>RandomForest</i> .	118
4.41	Visão interna do módulo de predição.	120
4.42	Visão interna da extensão do MP.	121
4.43	Visualização da Predição no Contexto do Curso.	121
4.44	Visualização da Predição no Contexto do Aluno.	122
4.45	Predição de comportamento dos tutores.	122
4.46	Visualização da Classificação do Tutor.	123
4.47	Perfil dos usuários que avaliaram a ferramenta.	124
4.48	Avaliação da facilidade de manuseio da ferramenta.	125
4.49	Importância dos relatórios implementados.	125
4.50	Facilidade de compreensão dos gráficos.	126
4.51	Confiabilidade da predição de desempenho.	126
4.52	Importância da avaliação comportamental dos tutores.	127
4.53	O layout da ferramenta.	127
4.54	Avaliação das funcionalidades implementadas.	128
4.55	Utilização prática da ferramenta.	128
4.56	Recomendação da ferramenta.	129

Lista de Tabelas

2.1	Matriz de Confusão: para problema com 2 classes.	35
4.1	Critérios de Inclusão e Exclusão.	56
4.2	Características de Tutores e o Impacto nos Alunos.	59
4.3	Atributos de Docência: Literatura Acadêmica.	62
4.4	Framework de Características dos Docentes.	64
4.5	Descrição dos Scripts SQL fornecidos pelo TJGO.	66
4.6	Descrição dos atributos dos cursos da EJUG.	75
4.7	Cursos Comumente Ofertados pela EJUG.	76
4.8	Correlação: Total de Tutor e Taxa de Aprovação.	77
4.9	Descrição dos atributos dos cursos da EJUG.	85
4.10	Principais titulações dos professores da EJUG.	87
4.11	Correlação entre a quantidade de cursos ministrados e Taxa de Conclusão.	88
4.12	Subconjunto de Cursos.	104
4.13	Atributos dos Alunos.	108
4.14	Correlação dos atributos do Framework de Característica do Tutor com os Dados extraídos para predição.	109
4.15	Clusterização dos dados dos Tutores.	111
4.16	Parâmetros dos Algoritmos Classificadores.	115
4.17	Análise da métrica Acurácia para o conjunto de predição da EJUG.	116
4.18	Análise da métrica AUC para o conjunto de predição da EJUG.	116
4.19	Análise da métrica AUC para o conjunto de predição com dados dos tutores.	117
4.20	Taxa de Importância do atributo com base na diminuição do grau de impureza.	119
A.1	Parâmetros passado aos Classificadores.	140
A.2	Análise da métrica Acurácia para o conjunto de predição da EJUG.	141
A.3	Análise da métrica True Positive Rate (TP) para o conjunto de predição da EJUG.	141
A.4	Análise da métrica False Positive Rate (FP) para o conjunto de predição da EJUG.	141
A.5	Análise da métrica Precision para o conjunto de predição da EJUG.	141
A.6	Análise da métrica Recall para o conjunto de predição da EJUG.	141
A.7	Análise da métrica F-Measure para o conjunto de predição da EJUG.	142
A.8	Análise da métrica MCC para o conjunto de predição da EJUG.	142
A.9	Análise da métrica AUC para o conjunto de predição da EJUG.	142
A.10	Análise da métrica PRC para o conjunto de predição da EJUG.	142
A.11	Análise da métrica Acurácia para o conjunto de predição com dados dos tutores.	142

A.12	Análise da métrica True Positive Rate (TP) para o conjunto de predição com dados dos tutores.	143
A.13	Análise da métrica False Positive Rate (FP) para o conjunto de predição com dados dos tutores.	143
A.14	Análise da métrica Precision para o conjunto de predição com dados dos tutores.	143
A.15	Análise da métrica Recall para o conjunto de predição com dados dos tutores.	143
A.16	Análise da métrica F-Measure para o conjunto de predição com dados dos tutores.	143
A.17	Análise da métrica MCC para o conjunto de predição com dados dos tutores.	144
A.18	Análise da métrica AUC para o conjunto de predição com dados dos tutores.	144
A.19	Análise da métrica PRC para o conjunto de predição com dados dos tutores.	144

Introdução

O ensino a distância (EaD) permite a realização de cursos sem a necessidade de alunos e professores estarem geograficamente próximos e ainda possibilita uma maior flexibilidade dos horários de estudos. No Brasil a modalidade de ensino EaD é regulamentada pelo decreto nº 2.494, de 10 de fevereiro 1998, do Ministério da Educação. Com a regulamentação e com a maior disponibilização de internet banda larga, a modalidade de ensino a distância vem ganhando espaço no Brasil, como mostra os resultados dos censos 2015 e 2016 realizado pela Associação Brasileira de Educação a Distância, ABED, que consultou 1.145 instituições EaD em 2015 e 1303 unidades de ensino em 2016, revelando um aumento de 14%, de um ano para outro, no número de instituições fornecedoras e realizadoras de cursos à distância ([CENSO ABED, 2016](#)).

No contexto atual da nossa sociedade, a educação a distância surge como uma ferramenta de democratização de oportunidades educacionais e possibilita a emancipação do indivíduo no contexto social ([MARTINS, 2016](#)). A flexibilidade do espaço e do tempo é a característica de maior relevância social na seara da educação a distância, uma vez que permite que pessoas estudem em qualquer lugar, seja durante uma viagem de avião ou enquanto aguarda um ônibus, e a qualquer hora do dia, seja durante o intervalo para o almoço ou durante uma madrugada de insônia. A popularização da internet tornou o EaD interativo e mais dinâmico, alunos e tutores podem se comunicar, em tempo real, de qualquer lugar e a qualquer momento, utilizando-se dos mais variados recursos da rede mundial de computadores a exemplo: fóruns, e-mails, videoconferências e bate-papo online.

A modalidade de ensino EaD exige mudanças de hábitos tanto dos docentes quanto dos discentes. São vários os motivos que podem dificultar ou diminuir a taxa de aprendizagem em plataformas EAD, dentre essas se destacam: evasão de alunos, tutores sem capacitação adequada, administração inadequada do tempo e falta de interação tutor e alunos ([EAD, 2019](#)).

Do ponto de vista pedagógico, várias pesquisas já foram conduzidas com o objetivo de comprovar que o ambiente de sala de aula é mais importante que o ambiente de escola no tocante à influência no desempenho dos alunos ([MUIJS, 2014](#)). O professor

assume um papel crucial no processo de aprendizagem dos alunos. Sem a orientação e a eficácia do professor dentro, e fora, da sala de aula a aprendizagem não pode ser alcançada (KYRIAKIDES; CHRISTOFOROU, 2013). Portanto, entender o comportamento, as atitudes e as características do professor são fundamentais para se assegurar que a construção do conhecimento, com base na teoria de que as trocas de informações, entre alunos e professores, promovem reflexões que permitem a interiorização do conhecimento.

Maximizar o desempenho dos alunos e a qualidade do ensino é um desafio para os gestores da educação. Várias tentativas de associações sistemáticas entre as atitudes dos formadores de políticas educacionais e os resultados dos alunos foram realizadas, entretanto, poucos resultados positivos foram encontrados (KUKLA-ACEVEDO, 2009). Logo, a atenção dos pesquisadores passou a ser em nível da sala de aula, buscando correlações entre os professores e as conquistas acadêmicas de seus alunos.

Nesse cenário, a Andragogia pode ser uma aliada para buscar novas abordagens no ensino a distância. A andragogia é dita como a ciência de ensinar adultos. Assim como a pedagogia tem como foco a aprendizagem de crianças à andragogia tem como objeto de estudo os fatores que permeiam o ensino de jovens/adultos, que são os principais alvos do EaD. Segundo Knowles (1950), considerado pai da andragogia, professores que lecionam para adultos devem ser capazes de garantir 4 características básicas para seus alunos sendo elas: Auto-diretividade, Experiência do aluno, Motivação do aluno e Aplicabilidade das atividades. A Auto-diretividade que alunos adultos necessitam está diretamente associada a capacidade do professor de gerenciar seu tempo, como orientador, e proporcionar aos alunos a capacidade de decidir quando, como e o que estudar (KYRIAKIDES; CHRISTOFOROU, 2013). O estilo de ensino do professor deve se adequar aos alunos, de forma a explorar a experiência prévia dos alunos. A motivação dos alunos está diretamente ligada a motivação do professor assim como na credibilidade, auto-eficácia, que o professor tem sobre seus discentes. O modelo de atividades do docente deve privilegiar atividades cuja aplicabilidade seja bem definida e que preferencialmente reflitam nas atividades profissionais dos alunos.

Do ponto de vista tecnológico, ambientes Virtuais de Aprendizagem (AVA) tornaram-se ferramentas pedagógicas comuns em ambientes EaD. O Moodle é um AVA distribuído como software livre e utilizado em instituições de ensino como a: Universidade Federal de Goiás, Instituto Federal de Goiás, Universidade Estadual de Goiás e Escola judicial de Goiás. Os sistemas de ensino a distância, como o Moodle, alimentam banco de dados educacionais, com dados sobre alunos, cursos, professores, fóruns, atividades, entre outros. A partir dos dados armazenados em bases de dados educacionais e com auxílio de recursos tecnológicos apropriados é possível revelar informações valiosas acerca do ambiente de ensino em análise.

A Mineração de Dados Educacionais, EDM, é um recurso tecnológico que

auxilia na conversão de dados brutos, coletados de sistemas educacionais, em informações úteis que podem ser usadas para responder perguntas de pesquisas no campo da educação a distância (HEINER, 2007). A mineração de dados é apenas um dos passos do processo de descoberta de conhecimento em banco de dados (do inglês: *Knowledge Discovery in Databases* - KDD).

Levando-se em conta os aspectos pedagógicos supracitados, esta pesquisa criou um conjunto de características de tutores, que no contexto deste trabalho será chamado de *framework* de características de tutores. O *framework* é composto pelas características dos docentes comumente investigadas, quanto ao impacto nos alunos, na literatura e pelos atributos desejáveis pela andragogia. A coleção de características dos docentes presentes no *framework* foi utilizada como referência na coleta de dados dos professores para a aplicação das técnicas de EDM, predição de desempenho dos alunos e também para classificação dos tutores quanto a prática, ou não, dos atributos presentes no *framework*. Considerando-se os aspectos tecnológicos da EaD, no que concerne a sua capacidade de geração de uma enorme quantidade de dados educacionais que pode ser explorada, neste trabalho foi realizada a extensão do *software* Moodle Predicta (MP), desenvolvido por (FELIX, 2017) para realizar predição de desempenho de alunos a partir de dados dos alunos. Na extensão do MP foi implementada a predição de desempenho dos alunos a partir de dados dos alunos e dos tutores. A extensão do MP realiza a predição de desempenho dos alunos classificando-os como aprovados, ou reprovados, e permite o acompanhamento do comportamento dos tutores quanto a prática dos atributos de tutoria presentes no *framework*. O MP estendido também utiliza técnicas de visualização de informação para exibir gráficos, relatórios e resultados estatísticos das atividades realizadas por alunos e tutores.

1.1 Motivação

O processo de ensino e a interação aluno-professor vêm passando por mudanças com os adventos da tecnologia da informação. O conhecimento, antes, estático passou a ser dinâmico e sistêmico. As características individualistas e independentes da modalidade de ensino EaD exige que o professor atue de forma proativa diante dos alunos. O professor assume um papel crucial durante, todo, o processo de aprendizagem, uma vez que sem o acompanhamento pedagógico adequado o processo de educação não é pleno (KYRIAKIDES; CHRISTOFOROU, 2013). O tutor deve organizar o fluxo de conhecimento de forma a permitir o estudo independente, assim como observar o comportamento individual dos alunos dentro e fora do ambiente de ensino. Portanto, o professor de cursos online (EaD) deve ser um mediador no processo de aprendizado, pois suas atitudes podem influenciar diretamente no desempenho escolar dos alunos.

As habilidades dos professores são fatores determinantes nas conquistas escolares dos alunos, mesmo que considerando histórico escolar e familiar dos estudantes. Os fatores que determinam a qualidade do professor, geralmente envolvem aspectos como: tamanho da turma, certificações, tipos de qualificação, títulos obtidos e experiência profissional (GUERRIERO, 2017). A influência de cada aspecto, ligado aos professores, nos resultados dos alunos também foi objeto de investigação de algumas pesquisas. Segundo Hattie (2003), professores especialistas diferem de professores experientes particularmente no nível de profundidade e desafios apresentados aos alunos, alunos de professores especialistas exibem uma maior compreensão dos conceitos e adquirem maior capacidade de abstração. Akiba e Liang (2016), verificaram que as certificações dos professores obtidas em congressos e conferências tiveram impacto positivo no desempenho dos alunos no programa de avaliação do estado de Missouri. Chu e Loyalka (2015) analisaram o desempenho dos alunos associando-os às credenciais dos professores, e não encontraram correlação entre os títulos e prêmios dos professores e a performance dos alunos.

As ações do tutor, no ambiente de ensino online Moodle, têm impacto na predição de desempenho acadêmico dos alunos? Responder esta pergunta foi o principal fator que motivou a condução deste trabalho.

1.2 Problematização

A crescente oferta de cursos online tem levantado alguns questionamentos acerca da qualidade do ensino em cursos EaD. O aumento na oferta de cursos à distância revela a necessidade de as instituições de ensino que ofertam cursos EaD estarem preparadas para: aprender, avaliar e formar seus alunos.

Para melhorar os resultados dos alunos, em cursos online, os docentes devem estar habituados ao ambiente de ensino à distância. Canales e Maldonado (2018) constataram que a experiência profissional dos professores teve forte influência nas notas dos alunos. O domínio de ferramentas tecnológicas pode ser visto como um desafio para alguns professores de cursos EaD, portanto, os docentes devem estar capacitados para desenvolver suas atividades em Ambientes Virtuais de Aprendizagem (AVA) (COMI; ARGENTIN, 2017). O estilo de ensino do professor em ambientes de ensino online também é encarado como um obstáculo, Naimie e Siraj (2012) identificaram que avaliações modernas e inovadoras tiveram impactos positivos nas notas dos alunos. É fundamental que o professor ofereça meios de comunicação com os alunos, fornecendo e recebendo *feedbacks* (NGANG; YIE, 2015).

O tutor é o regente do curso, suas atitudes vão refletir nas atitudes de seus alunos, portanto, avaliar o comportamento dos docentes é primordial para garantir a excelência

do ensino. Desta forma, fica evidente a necessidade de se estudar e criar ferramentas para auxiliar gestores e educadores a mitigar problemas no ambiente escolar.

1.3 Objetivos

Esta pesquisa possui um objetivo geral que será alcançado a partir da execução de vários objetivos específicos. A seguir é apresentada a proposta geral desta pesquisa e as atividades intermediárias que serão executadas para se atingir o objetivo geral.

1.3.1 Objetivo Geral

Encontrar evidências de que as ações comportamentais dos tutores podem influenciar no desempenho de seus alunos, a partir da análise de dados comportamentais extraídos de ambientes virtuais de aprendizagem. Um *framework* de características dos tutores será elaborado para apoiar e justificar a seleção dos dados dos tutores que podem impactar no desempenho dos alunos. O *framework* será utilizado para auxiliar na promoção do sucesso acadêmico dos alunos em cursos online, a partir da predição de seu desempenho incluindo preditores relacionados aos tutores. Será desenvolvido um software que aplicará técnicas de EDM e visualização de dados para acompanhar o desempenho dos alunos e tutores, visando diminuir a taxa de reprovação e evasão, além de classificar o comportamento dos tutores quanto às diretrizes da andragogia.

1.3.2 Objetivos Específicos

Para atingir o objetivo geral as seguintes atividades específicas serão executadas:

- Elaborar uma Revisão sistemática da literatura:
 - Identificar as principais características dos docentes que impactam no desempenho dos alunos.
 - Objetivo realizado na seção 4.1.
- Elaborar *framework* de atributos desejados em tutoria:
 - Elencar as principais características de tutoria que podem impactar positivamente no comportamento escolar dos alunos, em consonância com a revisão da literatura e a andragogia.
 - Tarefa realizada na seção 4.2.
- Definir base de dado para caso de uso:
 - Escolher uma base de dados educacionais para servir como caso de uso prático.

- A escolha da base de dados foi justificada na seção 4.3.
- Desenvolver análise exploratória sobre os cursos:
 - Analisar dados relacionados aos cursos da EJUG a fim de se conhecer os cursos ofertados no TJGO.
 - A análise foi conduzida na seção 4.4.
- Desenvolver análise exploratória sobre os tutores:
 - Conduzir uma análise exploratória a partir de dados comportamentais dos tutores objetivando fazer um perfilamento dos tutores e identificar característica do *framework* de atributos de tutoria.
 - Análise realizada na seção 4.5.
- Definir extensão da ferramenta Moodle Predicta:
 - Instalar e adequar ao banco de dados da EJUG.
 - A proposta de extensão do Moodle Predicta foi é apresentada na seção 4.6).
- Ampliar funcionalidades na Extensão do Moodle Predicta:
 - Adição de relatórios, referente aos tutores, no módulo de visualização.
 - Os relatórios adicionados são apresentados seção 4.7.
- Definir as estratégias para classificação dos tutores:
 - Apresentar técnicas que permitam classificar tutores quanto as boas práticas de tutoria do *framework*.
 - Os métodos propostos são apresentados na seção 4.8.6.
- Análise de desempenho dos classificadores:
 - Comparação de desempenho entre os modelos de classificação selecionados para possível implementação na extensão do Moodle Predicta.
 - A análise de desempenho é feita nas seções 4.8.8 e 4.8.8).
- Implementar predição de desempenho dos alunos:
 - Implementação da predição de aprovação ou reprovação dos alunos a partir de dados dos alunos e da classificação dos tutores quanto às boas práticas de tutoria presentes no *framework*.
 - A implementação é apresentada na seção 4.8.10.
- Avaliar a extensão da ferramenta Moodle Predicta:
 - Apresentar a ferramenta desenvolvida a usuários do Moodle e aplicação de questionário acerca do *software* desenvolvido.
 - Os resultados da avaliação são apresentados na seção 4.9.

1.4 Justificativa

A investigação do comportamento dos tutores em relação ao desempenho dos alunos já foi objeto de estudo de inúmeras pesquisas acadêmicas. A revisão sistemática da literatura apresentada na seção 4.1, apresenta os vários aspectos dos tutores analisados quanto ao impacto no desenvolvimento dos alunos e faz a correlação das características encontradas na literatura com as características desejadas pela andragogia. Nenhum dos trabalhos encontrados, na revisão, correlacionou as características dos tutores com as diretrizes da andragogia, portanto, este é o primeiro ponto de contribuição deste trabalho para avanços nos estudos comportamentais dos tutores e a aprendizagem de alunos adultos.

O desenvolvimento de *frameworks* de características de tutoria também já foi alvo de algumas pesquisas anteriores. Powell, Rabbitt e Kennedy (2014) membros da iNACOL e The Learning Accelerator (TLA) motivados pelo interesse de entender as funções dos tutores na modalidade de cursos semipresenciais reuniu um comitê de gestores e especialista em cursos mistos para responder as seguinte questão: “Quais são as principais características dos professores em ambientes bem-sucedidos de aprendizado misto?” O produto do trabalho deste comitê foi um *framework* de competências recomendadas para professores de cursos semipresenciais da iNACOL. Adeosun, Oladipo e Oni (2013) elaboraram um *framework* de características cognitivas, afetivas e profissionais que são desejáveis em um professor eficaz. O conjunto de atributos foi selecionado com base em questionários aplicados a alunos, estagiários, professores e formadores de professores do sistema de educação da Nigéria. Walker (2018) por quinze anos coletou informações, de alunos universitários, sobre atitudes e comportamentos dos professores que eles consideravam mais eficientes e que contribuíram efetivamente em suas carreiras profissionais. A partir das informações coletadas Walker (2018) formulou um *framework* com doze características dos tutores que afetavam positivamente o desempenho escolar dos alunos.

Em todos os trabalhos avaliados acerca do desenvolvimento de *framework* de características dos tutores que impactam positivamente nos alunos, nenhum utilizou o conjunto de atributos para implementar algum tipo de ferramenta tecnológica, para prever comportamentos ou acompanhar o comportamento dos tutores ao longo dos cursos.

As principais ferramentas encontradas no mercado foram desenvolvidas para auxiliar professores e gestores a acompanhar o desempenho e prever resultados dos alunos. Chiang e Brinton (2020) desenvolveram a ferramenta *Zoomi* que utiliza técnicas de inteligência artificial para: aumentar as taxas de conclusão dos cursos, melhorar a eficácia dos cursos e aumentar a participação dos alunos. O *Zoomi* é uma ferramenta de gestão educacional que visa entender as necessidades individuais dos alunos e conseqüentemente melhorar os resultados nos negócios da instituição de ensino. A ferramenta *Blackboard*

Predict desenvolvida por Chasen e Pittinsky (2020) tem por objetivo fornecer as instituições de ensino meios de identificar alunos em risco, adaptar recursos aos alunos e aumentar a graduação de alunos. O *X-Ray Learning Analytics* é uma ferramenta de código aberto criada em 2005 por Miller, Bennet e Stokking (2020) para apoiar centros de ensino e empresas a compreender e diagnosticar as necessidades dos alunos e professores, a ferramenta também oferece a predição de riscos de abandono dos alunos e a geração de relatórios detalhados sobre o comportamento dos alunos.

Todas as ferramentas analisadas têm como foco os alunos e disponibilizam serviços para apoiar tutores e gestores educacionais. Tal fato reforça a contribuição deste trabalho para o avanço do estado da arte, no que diz respeito à criação de um *framework* de características de tutores, incluindo atributos da andragogia, e sua utilização para o desenvolvimento de uma ferramenta que realiza predição de desempenho dos alunos, a partir de dados dos alunos e dos docentes, além de oferecer um acompanhamento semanal dos tutores quanto à aplicação das práticas da andragogia.

1.5 Estrutura da Dissertação

O restante desse documento está dividido em 5 capítulos. O capítulo 3 apresenta, basicamente, a metodologia utilizada para se alcançar os objetivos desejados, em outras palavras, descreve como cada atividade será desenvolvida para se atingir os objetivos propostos nesta dissertação.

No capítulo 2 é feita a fundamentação teórica de todas as técnicas e conceitos utilizados, neste capítulo apresentamos os conceitos preliminares dos Ambientes Virtuais de Aprendizagem, da Mineração de Dados, da andragogia e sua contextualização com o EaD, e finalmente apresentamos a ferramenta Moodle Predicta que será incrementada com novas funcionalidades que envolvem as ações comportamentais dos tutores.

O desenvolvimento detalhado do estudo é apresentado no capítulo 4, neste capítulo apresentamos a revisão da literatura feita para reunir as principais características dos tutores investigadas no meio acadêmico, em seguida é descrito o processo de construção do *framework* de características dos docentes. Na seção conjunto de dados é apresentado o Tribunal de Justiça e a Escola Judicial de Goiás, instituições responsáveis por ceder o conjunto de dados utilizados como caso de uso neste trabalho. A partir dos dados disponibilizados pela Escola Judicial uma análise exploratória dos cursos e dos tutores é feita utilizando-se de recursos estatísticos e visuais. Nas seções subsequentes do capítulo de desenvolvimento apresentamos a proposta de extensão da ferramenta Moodle Predicta. O módulo de visualização do *software* é apresentado com as alterações propostas, que envolveu o desenvolvimento, a partir de dados dos tutores, de relatórios estatísticos e implementação de métodos de visualização da informação. O módulo de predição foi al-

terado de forma a incluir dados comportamentais dos tutores, juntamente com dados dos alunos, na predição de desempenho dos estudantes, nesta seção também é descrito todas as análises feitas para a seleção do melhor algoritmo de classificação, assim como as técnicas utilizadas para classificar os tutores em relação as práticas recomendadas pela andragogia. E finalmente encerramos o capítulo 4 apresentando a avaliação da extensão do Moodle Predicta.

O capítulo 5 apresenta as considerações finais sobre o estudo, exibindo seus pontos fortes e suas deficiências, além propor recomendações para trabalhos futuros.

Conceitos Preliminares

Este capítulo se destina a apresentar os principais fundamentos teóricos e técnicos requeridos para a compreensão e avaliação do estudo desenvolvido e apresentado no capítulo 4.

2.1 Ambientes Virtuais de Aprendizagem

Por definição os AVA's são constituídos por um conjunto de ferramentas com propósitos educativos, em sua maioria recursos tecnológicos, que utilizam a internet para disponibilizar seus serviços e conteúdos e conseqüentemente facilitar a interação entre os usuários do AVA. Para [Milligan \(1999\)](#) um AVA deve ser descrito como um *software* baseado na arquitetura cliente-servidor para gerir um ambiente educacional e para garantir a qualidade dos serviços oferecido um AVA deve ser estruturado da seguinte forma:

- Controle de Acesso: os usuários devem ser identificados.
- Administração: registros das atividades dos docentes e alunos.
- Controle de Tempo: controle de disponibilização de materiais.
- Avaliação: avaliação dos alunos e auto avaliação.
- Comunicação: deve possibilitar comunicação um-para-um, um-para-muitos, muitos-para-muitos e muitos-para-um.
- Área do usuário: espaço privativo.
- Gerenciador de Conteúdo: sistemas de buscas.
- Suporte: utilização do sistema.
- Manutenção: atualizações e reparos de erros.

Atualmente existem vários AVA's disponíveis para serem utilizados nos mais diversos contextos. A principal distinção entre os AVA's atuais diz respeito ao tipo de licença necessária para sua utilização. Os AVA's livres e de código aberto são os mais utilizados por órgãos governamentais e pequenas empresas, pois permitem adaptações e tem licenças livres de utilização, dentre estes se destacam: Moodle, Sakai, Canvas e Google

Classroom. Já os AVA's de códigos fechados são utilizados por grandes instituições de ensino privadas e destacam-se pelo suporte especializado, dentre esses temos: Blackboard, Desire2Learn e eCollege.

2.1.1 Público Alvo

Os AVA's devem ser projetados para atender todos os envolvidos no processo de ensino e também nas nuances que envolvem cada perfil de usuário. Os componentes fundamentais para execução do processo de ensino são:

- **Aluno:** é o principal ator no processo de ensino, sendo ele o receptor e fornecedor de conteúdo.
- **Professor:** atua como impulsionador no processo de aprendizagem fornecendo conteúdo e auxiliando na superação dos desafios.
- **Material Didático:** suprimento fundamental para o processo de ensino, sendo a fonte de conhecimento primária tanto dos alunos como do professor.

Com base no público alvo os AVA's disponibiliza perfis de usuários baseando-se no papel de cada usuário dentro do sistema. No Moodle os perfis de usuários pré-definidos são ([MOODLE, 2020b](#)):

- **Manager:** gerencia os cursos podendo altera-los, geralmente não participam dos cursos.
- **Course Creator:** responsáveis pela elaboração de novos cursos.
- **Teacher:** responsáveis pela condução do curso.
- **Student:** usuários matriculados regularmente nos cursos.
- **Guest:** usuários sem vínculos diretos com o curso.

Evasão em Ambientes Virtuais de Aprendizagem

A modalidade de ensino a distância aliada aos avanços dos AVA's vêm rompendo com barreiras, antes, enfrentadas pelos primórdios do EaD. Com isso cursos ofertados *online* tem se aproximado cada vez dos cursos tradicionais, no que diz respeito a qualidade do ensino. Contudo, alunos de cursos EaD devem adquirir habilidades inerentes as condições de ensino EaD, tais como auto-diretividade e autorreflexão.

Através das diversas ferramentas disponibilizadas pelo AVA's os professores podem interagir com os alunos, bem como disponibilizar conteúdos didáticos e avaliações. Com a flexibilização do local e hora de estudo os alunos devem estar comprometidos com o curso, de forma a usufruir de todas as atividades e recursos disponibilizados pelos professores, em outras palavras os alunos devem ser capazes de manter a auto-diretividade, para que o processo de ensino não seja prejudicado. Tanto o professor como os alunos

devem estimular a autorreflexão sobre o conteúdo dos materiais de forma a manter seus interesses e motivações no curso. A falta dessas duas características no ambiente de ensino pode levar ao aumento da evasão dos alunos, que podem não se sentirem comprometidos e atraídos pelo curso ofertado.

Cursos EaD estatisticamente são conhecidos pelos altos índices de evasão dos alunos. Segundo o [Censo ABED \(2016\)](#) a taxa de evasão médias nos cursos EaD ofertados no Brasil entre 2015 e 2016 foi de aproximadamente 30%. A fim de se identificar os principais motivos de evasão em cursos EaD muitas pesquisas tem sido conduzidas no meio acadêmico. Para a Associação Brasileira de Ensino a Distância (ABED) os fatores que geralmente motivam a desistência dos alunos são: custos dos cursos, falta de tempo para estudo e a não adaptação do aluno a metodologia EaD.

A utilização recursos tecnológicos também têm apoiado os gestores educacionais a detectarem possíveis desistências e desvios de comportamento. Tecnologias como a dos tutores inteligentes que utilizam recursos da Inteligência Artificial com propósitos educacionais, por exemplo, monitorar as atividades dos alunos e alertar aos professores para que façam um acompanhamento mais dedicado junto aos alunos que apresentam dificuldades.

Técnicas de análise de dados, e visualização de dados, também vêm sendo utilizadas para combater a evasão em AVA's. A partir dos dados registrados pelo AVA é possível aplicar técnicas de análises de dados para revelar informações, não transparentes, a partir das ações dos alunos e professores dentro ambiente de aprendizagem. Logo, para além de suas funções básicas os AVA's podem contribuir de maneira significativa na diminuição das taxas de desistência dos alunos.

2.1.2 O Moodle

O *Modular Oriented-Object Dynamic Learning Environment* (Moodle) é uma plataforma de ensino criada para atender as demandas de alunos, educadores e gestores educacionais. O projeto Moodle tem mais de 20 anos, com início em 1999 sendo a primeira versão liberada em 2002. As bases pedagógicas do Moodle estão alicerçadas pelo construtivismo social, que define que a interação aluno-conteúdo é responsável pelo conhecimento adquirido pelo aluno ([MOODLE, 2020a](#)).

O Moodle é distribuído de forma gratuita, sem licença, e com código aberto. Qualquer pessoa pode adaptar ou estender o Moodle para fins comerciais, ou não, e se beneficiar de possíveis lucros. Devido ao alcance global que o *software* atingiu, ele oferece suporte a diversas línguas, inclusive o português do Brasil. Devido a estas características esse AVA é amplamente utilizado por pesquisadores e principalmente por instituições de ensino públicas e privadas ([MOODLE, 2020a](#)).

O Moodle oferece suporte para cursos presenciais, mistos e totalmente online. As principais estruturas desejadas em um AVA, conforme mostrando na seção 2.1, estão presentes no Moodle. O Moodle disponibiliza mais de 20 tipos de atividades: fóruns, salas de bate-papo, *wikis*, glossários, *quizzes*, tarefas, formulários etc. Além destas, o Moodle permite a instalação de novas funcionalidades por meios de *plugins* e extensões.

A plataforma Moodle é basicamente uma *suite* de aplicações *Web*, portanto, seus serviços são baseados na arquitetura cliente-servidor. O cliente é representado pelos diversos perfis de usuários existentes no AVA, seção 2.1. O servidor é basicamente representado pelo repositório de dados e pelo servidor de aplicação, responsável por atender as solicitações dos usuários. O Moodle é codificado utilizando a linguagem de programação web PHP e possui versões com suporte a diferentes tecnologias de banco de dados de licença aberta, sendo as versões mais utilizadas as que contêm integração com o MySQL e PostgreSQL.

2.1.3 Surveys e Feedback no Moodle

O módulo *survey* do Moodle disponibiliza questionários com perguntas pré-definidas para cada tipo de *survey*. O *survey* COLLES, Constructivist On-Line Learning Environment Survey, fornece 24 questões agrupadas em 6 grupos que abordam questões-chaves sobre a qualidade do ambiente de aprendizado online.

Questionário COLLES:

1. **Relevância:** Qual a relevância da aprendizagem online para as práticas profissionais dos alunos?
2. **Reflexão:** O aprendizado online estimula o pensamento reflexivo crítico dos alunos?
3. **Interatividade:** Até que ponto os alunos se envolvem online em um rico diálogo educativo?
4. **Suporte do Tutor:** Até que ponto os tutores permitem que os alunos participem do aprendizado online?
5. **Suporte dos Colegas:** O apoio sensível e encorajador é fornecido online por colegas?
6. **Interpretação:** Os alunos e tutores entendem bem as comunicações online uns dos outros?

O *survey* ATTLS, Attitudes to Thinking and Learning Survey, contém 20 perguntas agrupadas em 3 grupos de questões, o objetivo de questionário é avaliar as atitudes em relação ao pensamento crítico e o ensino (MOODLE, 2017). Em ambos os questionários cada questão pode ser avaliada com uma nota entre 1 e 5.

Questionário ATTLS:

1. Atitudes em relação ao pensamento e à aprendizagem.
2. Aprendizado conectado.
3. Aprendizado separado.

Ao contrário do módulo *survey* que possui questões pré-definidas o módulo *feedback* é uma solução para professores que desejam criar questionários personalizados para receber opiniões dos alunos.

Tanto os *survey* como os formulários de *feedback* são muito importantes no contexto do ensino EaD, dado que as barreiras geográficas entre alunos e professor diminuem a qualidade da comunicação entre os atores do ensino a distância. Logo, essas ferramentas são importantes meios de coleta de dados e de informações para se garantir a qualidade do ensino.

2.2 Mineração De Dados

O fim do século XX foi marcado pelos adventos da tecnologia da informação (TI). A informatização, em ritmo global, foi responsável pela terceira revolução industrial, ou revolução informacional. As empresas e organizações, públicas e privadas, começaram a coletar dados das suas transações. Entretanto, grande parte desses dados não está sendo utilizadas, tendo em vista que a manipulação de grandes volumes de dados tem se mostrado uma tarefa desafiadora (FAYYAD, 1996). Portanto, surge a necessidade de se utilizar ferramentas e técnicas específicas para manipular e extrair informações úteis em grandes conjuntos de dados brutos. O processo de descoberta de conhecimento em banco de dados, *knowledge discovery in databases* (KDD), é uma área da TI que se dedica ao desenvolvimento de técnicas de análise de dados para obtenção de informações coerentes. Segundo Fayyad (1996) o KDD é um processo composto, basicamente, pelas seguintes etapas:

- Seleção dos dados;
- Pré-processamento dos dados;
- Transformação dos dados;
- Mineração dos dados;
- Interpretação e Avaliação dos dados.

O processo de KDD inicia-se com a seleção do conjunto de dados que se deseja manipular. O pré-processamento consiste em eliminar dados redundantes, unir dados de fontes distintas, remover dados inconsistentes e selecionar dados relevantes. A transformação dos dados é feita com objetivo de padronizar medidas e dimensões. Com os dados pré-processados e transformados a etapa de mineração de dados pode efetivamente ser iniciada. A MD combina métodos, já estabelecidos, de análise de dados

com algoritmos modernos de processamento de grandes quantidades de dados (VIPIN; MICHAEL; PANG-NING, 2005). Executada a tarefa de MD, os resultados obtidos precisam ser interpretados e avaliados sob a ótica do domínio a que os dados pertencem.

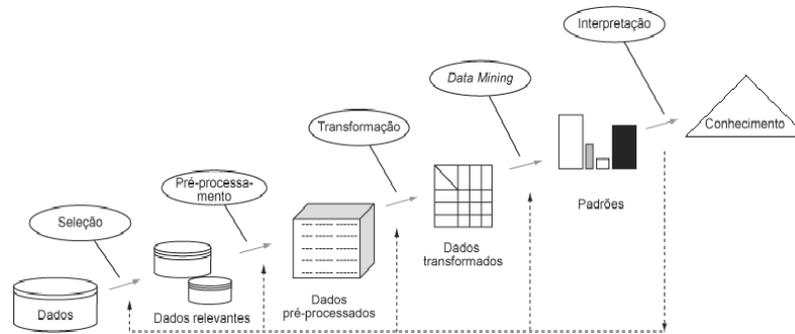


Figura 2.1: *Processo de Descoberta de Conhecimento (FAYYAD, 1996).*

A figura 2.1 resume o processo de KDD e mostra que todo o processo é cíclico, permitindo que se volte a qualquer uma das etapas, a fim de se melhorar os resultados obtidos.

Segundo Vipin, Michael e Pang-Ning (2005), a MD tem duas tarefas gerais, sendo: tarefas de predição e tarefas de descrição. As tarefas de predição são aquelas em que a partir de um conjunto de atributos deve-se ser capaz de prever o valor de um determinado atributo. Tarefas de descrição se concentram na identificação de padrões e tendências, geralmente requerem técnicas para explicar os resultados.

Existem diversas ferramentas utilizadas para facilitar a execução de cada etapa do KDD. No âmbito desta pesquisa utilizou-se a linguagem R para o pré-processamento e transformação dos dados, a ferramenta WEKA foi utilizada para aplicação das técnicas de MD e para avaliação dos resultados. Neste capítulo será apresentada cada uma das ferramentas utilizadas no contexto desta pesquisa.

2.2.1 Métodos de Mineração de Dados

Os métodos de MD são especificações dos passos a serem seguidos para se obter descobertas de conhecimentos úteis. Os métodos são classificados de acordo com as tarefas de MD, predição ou descrição, que realizam. Nesta seção serão apresentados os principais métodos utilizados nas análises feitas neste trabalho.

Associações

É um método muito utilizado em MD e realiza a tarefa de descrição. Este método faz correlações entres objetos buscando encontrar padrões do tipo: *Se compra*

pão Também compra leite. Associações deste tipo também recebem o nome de Regra de Associação.

Classificação

Realiza a tarefa de predição e descrição, os métodos de classificação criam um modelo de classificação a partir de um conjunto de dados em que já se conhece a classe dos registros. E esse modelo de classificação é então utilizado para prever a classe de registros sem classificação. Resumidamente, ao analisar os atributos do registro submetido ao método, ele deve ser capaz de prever a qual classe ele pertence.

Árvores de Decisão

É uma variação do método de classificação que cria uma estrutura de árvore em que cada nó, não folha, apresenta uma condição sobre um determinado atributo. Os nós folhas representam as possíveis classes que um registro pode assumir.

Agrupamento (*Clustering*)

Realiza a tarefa de descrição. Esse método tem como objetivo identificar e agrupar registros similares. Diferentemente da classificação, esse método exige que os registros sejam previamente categorizados, pois a identificação de similaridade é feita com base nas diferenças entre os atributos do registro submetido a este método.

2.2.2 Métricas de Desempenho para Classificadores

O principal método de MD que será utilizado nesta pesquisa será a classificação (seção 2.2.1). Neste trabalho, a tarefa de predição será realizada aplicando-se métodos de classificação para classificar alunos (aprovados e reprovados) e professores (andragógico e nao-andragógico). Portanto, nesta seção apresentaremos as principais métricas de avaliação de desempenho de modelos de classificadores utilizadas nesse trabalho a fim de definir qual melhor classificador a se utilizar no conjunto de dados da EJUG.

		Classe Predita	
		CLASSE A	CLASSE B
Classe Verdadeira	CLASSE A	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	CLASSE B	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Tabela 2.1: Matriz de Confusão: para problema com 2 classes.

A principal forma de aferir o desempenho de um modelo de classificação é a partir da quantidade de registros classificados corretamente e incorretamente pelo

modelo (VIPIN; MICHAEL; PANG-NING, 2005). A partir das classificações corretas e incorretas é possível construir uma tabela que em MD é conhecida como matriz de confusão (MF). A tabela 2.1 é uma MF para um problema que envolve duas classes. A quantidade de classificações verdadeiramente corretas (*True Positive* - TP) e a quantidade de classificações verdadeiramente negativas (*True Negative*) somadas representam o total de classificação corretas. O total de classificações falsas classificadas como positivos (FP), somados ao total de classificações corretas classificadas como falsas (FN), representam o total de classificações incorretas do modelo de classificação. Portanto, para comparar dois modelos de classificação é suficiente compararmos suas respectivas matrizes de confusão. Apesar de ser possível comparar modelos de classificação avaliando suas matrizes de confusão, algumas métricas alternativas foram propostas para simplificar os resultados da MF de cada modelo e serão apresentadas a seguir.

Acurácia

Esta métrica revela no número de predições corretas em relação ao total de predições feitas, logo a acurácia é sumarizada por:

$$\text{Acurácia} = \frac{TP+TN}{TP+TN+FN+FP}$$

A acurácia considera que a distribuição de classes é uniforme, logo essa métrica não é importante quando estamos trabalhando com dados com classes desbalanceadas.

Precisão (*Precision*)

É representado pela proporção de registros classificados corretamente como positivos, TP, e total de classificações positivas, TP+FP.

$$\text{Precision} = \frac{TP}{TP+FP}$$

Logo, uma alta taxa de precisão indica um baixo número de falsos positivos, FP.

Recall

Esta métrica calcula a taxa de classificações corretamente positivas, TP, sobre o total de classificações positivas (TP+FN).

$$\text{Recall} = \frac{TP}{TP+FN}$$

Um alto valor de *Recall* indica um baixo número de erros na classificação dos positivos, TP.

F-Measure

Representa a média harmônica entre *Recall* e *Precision*.

$$F\text{-Measure} = \frac{\text{Recall}}{\text{Precision}}$$

Um bom valor para esta métrica garante que o *Recall* e *Precisão* estão com um valor alto.

Matthews Correlation Coefficient (MCC)

É um coeficiente de correlação que assume valores entre -1 e +1. -1 significa nenhuma classificação correta, 0 indica modelo com classificações aleatórias e +1 corresponde ao modelo ideal. Resumidamente quanto mais próximo de 1 melhor é o modelo.

Área Sob a Curva (AUC)

Calcula o valor da área formada abaixo da curva (*Area Under Curve (AUC)*) plotada em um gráfico que relaciona os TP's, eixo y, e FP's, eixo x. A figura 2.2 mostra duas curvas, correspondente a dois modelos de classificação distintos. Os pontos críticos do gráfico são:

- $TP = 0, FP = 0$: todas as classificações são negativas.
- $TP = 1, FP = 1$: todas as classificações são positivas.
- $TP = 1, FP = 0$: Modelo de classificação ideal.

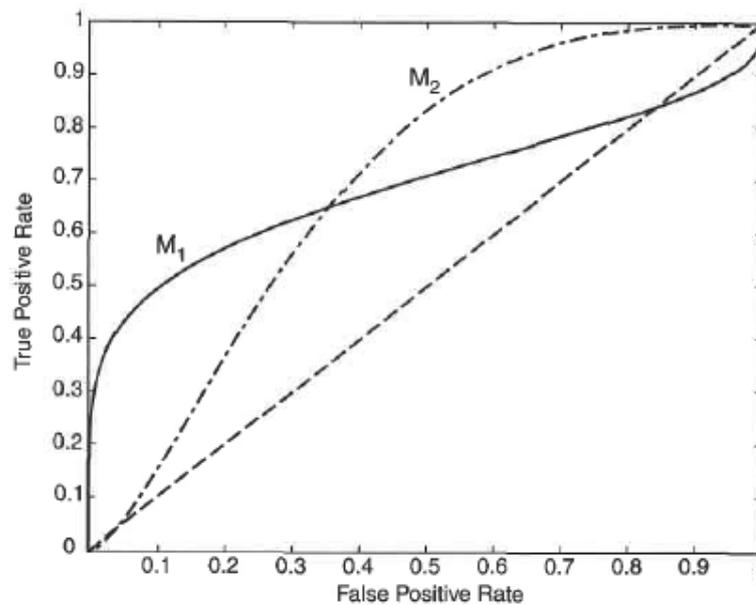


Figura 2.2: Exemplo de AUC.

Um bom modelo deve estar localizado o mais próximo possível do canto esquerdo superior do gráfico. Um modelo que faz classificações aleatórias possui as marcações próximas a diagonal principal. Em outras palavras, quanto maior a área abaixo da curva melhor é o modelo, o modelo ideal tem área 1 o modelo aleatório tem área 0.5.

Precision Recall Curve (PRC)

É um gráfico utilizado como complemento a AUC. No eixo y temos os valores do *Precision* e no eixo x os valores do *Recall*. Um bom modelo deve estar localizado o mais próximo possível do canto direito-superior. Um modelo de classificação ruim tem marcações próximas ao canto esquerdo inferior.

2.2.3 Mineração de Dados Educacionais

A mineração de dados assim como todo processo de KDD independe do domínio do qual os dados proveem, portanto, a mineração de dados pode ser aplicada em dados oriundos de qualquer área do conhecimento. Quando aplicada à educação, a metodologia de mineração de dados é chamada de mineração de dados educacionais (*Education Data Mining* - EDM). O principal objetivo da EDM é o desenvolvimento de métodos de MD para explorar dados de ambientes educacionais.

Os métodos utilizados na EDM geralmente são adaptações dos já utilizados na MD tradicional. Tais adaptações se fazem necessárias, pois dados educacionais devem ser analisados a partir de, pelo menos, três contextos distintos: aluno, professor e classe. Existe uma independência entre os dados coletados em ambientes de ensino. Há uma hierarquia entres os contextos, sendo que o nível de classe deve ser analisado do ponto de vista dos gestores educacionais, o contexto do professor deve ser interpretado do ponto de vista dos gestores e dos próprios docentes, já o contexto de alunos deve ser analisado do ponto de vista de cada um dos outros contextos. Ferramentas de MD consolidadas como, por exemplo, WEKA não oferecem suporte para a validação cruzada entre os contextos dos ambientes educacionais (BAKER; ISOTANI, 2011).

No contexto dos alunos a EDM tem sido aplicada com o objetivo de se realizar predição de desempenho, detecção de desvio de comportamento, estimular os alunos, adequação de conteúdo ao aluno, dentre outros. No nível do professor a aplicação tem sido na identificação de perfil dos alunos, adequação das práticas pedagógicas aos alunos, identificação de fatores ligados aos professores que podem melhorar o aprendizado dos alunos etc. Já no contexto de classe a EDM pode e tem sido aplicada para analisar a estrutura de cursos, melhorar a estrutura curricular dos cursos, reduzir a evasão dos alunos, acompanhar e avaliar a metodologia de ensino dos docentes.

Portanto, apesar de ser uma área de pesquisa recente a EDM tem mostrado ser bastante útil e com o mesmo potencial da MD, visto que com as devidas adaptações é possível reutilizar as técnicas de MD amplamente difundidas e utilizadas nas mais diversas áreas.

2.2.4 Ferramentas de Mineração de Dados

A manipulação de grandes volumes de dados é uma tarefa que exige ferramentas específicas e capacitação para manipulá-las. Existe uma vasta gama de ferramentas disponíveis no mercado, que oferecem apoio na execução das etapas do KDD.

Nesta seção apresentamos as duas principais ferramentas utilizadas neste trabalho: WEKA e o ambiente de análise estatística R. Ambos os *softwares* são distribuídos com licença livre, possuem compatibilidade entre si, utilizam a mesma extensão de arquivos para entrada de dados (ARFF), e são amplamente utilizadas em tarefas de mineração de dados.

WEKA

O *Waikato Environment for Knowledge Analysis - WEKA*¹ é uma ferramenta resultante de um projeto fundado pelo governo da Nova Zelândia com o objetivo de reunir as principais ferramentas de aprendizado de máquina e suas aplicações em áreas-chave. O projeto teve início em 1992 coordenado por Ian Witten na Universidade de Waikato. Já em 1993 ocorreu desenvolvimento da interface e da infraestrutura do WEKA. Somente em 1996 a ferramenta foi disponibilizada ao público com licença livre, permitindo sua utilização sem custos. As primeiras versões do WEKA foram desenvolvidas em linguagem C, fato que limitava a utilização a plataformas com suporte a compiladores dessa linguagem. Para driblar esse problema em 1999 foi distribuída uma versão nova do WEKA totalmente em linguagem JAVA o que possibilitou a utilização da ferramenta como biblioteca de funções para qualquer aplicativo desenvolvido em JAVA (WEKA, 2020).

¹Pode ser adquirido em: <https://waikato.github.io/weka-wiki/downloading_weka/>. Acessado em: 06/02/2020.



Figura 2.3: Tela inicial do WEKA (versão 3.8).

O WEKA reúne uma coleção de implementações dos algoritmos de mineração de dados mais difundidos no meio acadêmico. A ferramenta oferece suporte para preparação dos dados, avaliação estatística e visualização da informação. A figura 2.3 exibe a tela inicial do WEKA e apresenta as opções de utilização da ferramenta, listadas a seguir:

- *Explorer*: utilizada para análise exploratória dos dados;
- *Experimenter*: ambiente de experimentos comprando-se algoritmos;
- *KnowledgeFlow*: interface permite ao usuário definir o próprio fluxo de dados;
- *Workbench*: apresenta todas as interfaces em uma única;
- *SimpleCLI*: é uma interface que permite a utilização da ferramenta por linhas de comandos.

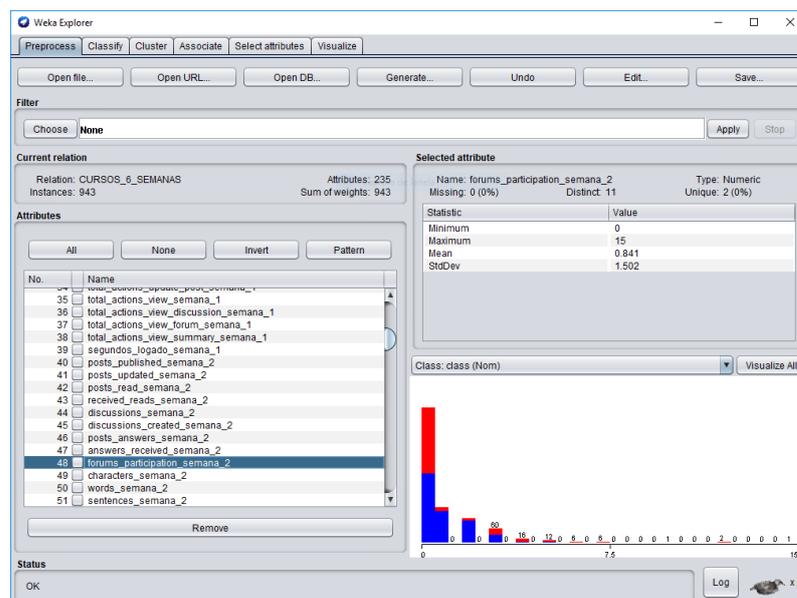


Figura 2.4: WEKA Explorer

Um dos recursos do WEKA mais utilizados neste trabalho foi a interface *Explorer* pois concentra grande parte dos métodos de MD. A figura 2.4 mostra o *layout* do *Explorer*, na primeira aba é possível realizar o pré-processamento dos dados e nas seguintes o usuário pode executar os métodos de MD e visualizar a distribuição dos dados graficamente.

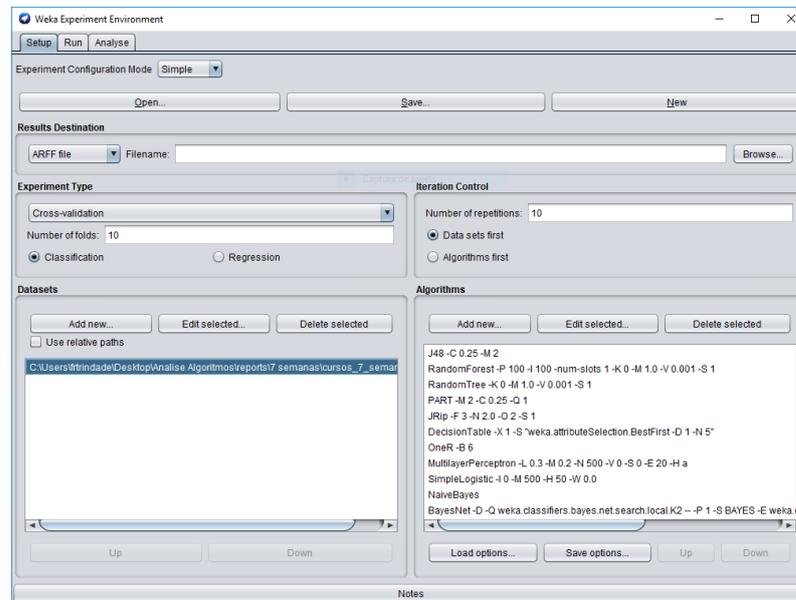


Figura 2.5: WEKA *Experimenter*.

O WEKA *Experimenter* é uma ferramenta muito utilizada para realização de testes de performance de algoritmos. No contexto deste trabalho essa funcionalidade foi utilizada para se comparar o desempenho de cada algoritmo selecionado para o teste. Na figura 2.5 a primeira aba é destinada a configuração do experimento, sendo possível selecionar os dados a serem analisados e os algoritmos a serem comparados. Na aba *Run* pode-se iniciar o processo de execução do experimento. Em seguida os resultados são apresentados na aba *Analyse*, na qual é possível analisar os resultados a partir das diversas métricas de desempenho apresentadas neste capítulo.

Linguagem e Ambiente: R

R² é simultaneamente uma linguagem de programação e também um ambiente para análise estatística de dados. O projeto R teve início em 1992 na Universidade de Auckland na Nova Zelândia, coordenado por Ross Ihaka e Robert Gentleman, a primeira versão disponibilizada aos público ocorreu no ano 2000 com licença para utilização *free* (R, 2018).

²Pode ser adquirido em: <<https://cran.r-project.org/bin/windows/base/>>. Acessado em: 06/02/2020.

A linguagem R é muito utilizada por estatísticos e analistas de dados devido a sua ampla variedade de ferramentas disponibilizadas. As principais técnicas são: modelagem linear, e não linear, testes estatísticos, classificação, *clustering* e ferramentas para visualização da informação (R, 2018).

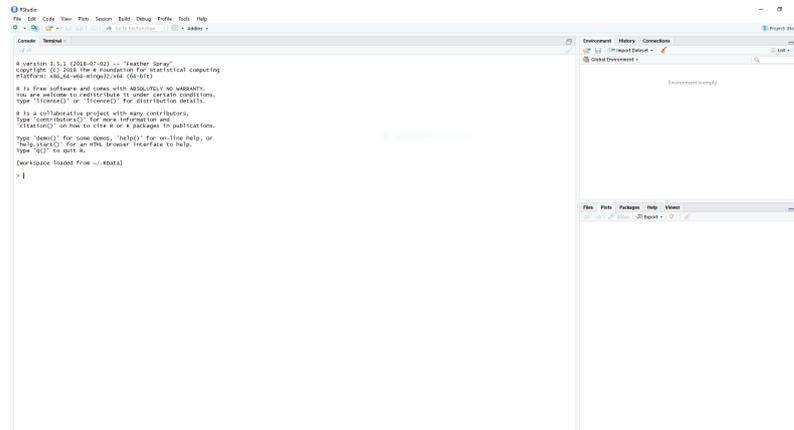


Figura 2.6: Tela inicial do RStudio (R versão 3.5; Rstudio versão 1.1).

RStudio³ é um ambiente de desenvolvimento, de licença gratuita, para a linguagem R e foi desenvolvida para apoiar a análise de dados e facilitar a reprodução das análises. Neste trabalho esta ferramenta foi utilizada para nos valer dos benefícios da linguagem R e facilitar as análises a partir da interface gráfica intuitiva do RStudio. Na figura 2.6 temos a tela inicial do RStudio, que é dividida em três ambientes. O *Console* permite a entrada de comandos R, o *Environment* armazena funções, dataset e variáveis utilizadas nas análises e o ambiente de *Plots* é a região destinada a plotagem de gráficos.

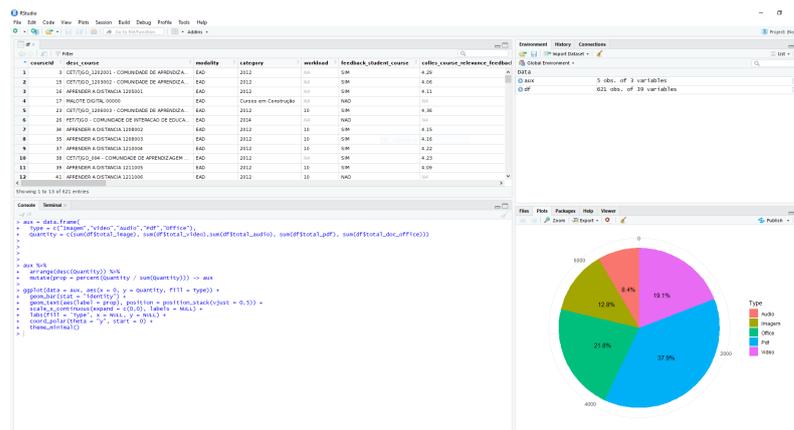


Figura 2.7: RStudio: Comandos, Datasets e Plots.

Na figura 2.7 é exibida uma utilização prática do RStudio nas análises feitas neste trabalho. É apresentado o *dataset* (df) utilizado na análise, os comandos para criar um conjunto

³Pode ser adquirido em: <<https://rstudio.com/products/rstudio/download/>>. Acessado em: 06/02/2020.


```

@RELATION content_for_prediction

@ATTRIBUTE posts_published_semana_1 NUMERIC
@ATTRIBUTE posts_updated_semana_1 NUMERIC
@ATTRIBUTE posts_read_semana_1 NUMERIC
@ATTRIBUTE received_reads_semana_1 NUMERIC
@ATTRIBUTE discussions_semana_1 NUMERIC
@ATTRIBUTE discussions_created_semana_1 NUMERIC
@ATTRIBUTE posts_answers_semana_1 NUMERIC
@ATTRIBUTE answers_received_semana_1 NUMERIC
@ATTRIBUTE forums_participation_semana_1 NUMERIC
@ATTRIBUTE characters_semana_1 NUMERIC
@ATTRIBUTE words_semana_1 NUMERIC
@ATTRIBUTE sentences_semana_1 NUMERIC
@ATTRIBUTE total_quizzes_submitted_semana_1 NUMERIC
@ATTRIBUTE total_quizzes_attempts_semana_1 NUMERIC
@ATTRIBUTE total_questions_attempted_semana_1 NUMERIC
@ATTRIBUTE correct_answers_semana_1 NUMERIC
@ATTRIBUTE wrong_answers_semana_1 NUMERIC
@ATTRIBUTE minutes_spent_quizzes_semana_1 NUMERIC
@ATTRIBUTE chats_enjoyed_semana_1 NUMERIC
@ATTRIBUTE messages_sent_semana_1 NUMERIC
@ATTRIBUTE interaction_logs_semana_1 NUMERIC
@ATTRIBUTE words_sent_semana_1 NUMERIC
@ATTRIBUTE characters_sent_semana_1 NUMERIC
@ATTRIBUTE total_assigns_semana_1 NUMERIC
@ATTRIBUTE total_submissions_semana_1 NUMERIC
@ATTRIBUTE total_out_of_date_semana_1 NUMERIC
@ATTRIBUTE total_drafts_semana_1 NUMERIC
@ATTRIBUTE total_actions_add_discussion_semana_1 NUMERIC
@ATTRIBUTE total_actions_add_post_semana_1 NUMERIC
@ATTRIBUTE total_actions_attempt_semana_1 NUMERIC
@ATTRIBUTE total_actions_close_attempt_semana_1 NUMERIC
@ATTRIBUTE total_actions_continue_attempt_semana_1 NUMERIC
@ATTRIBUTE total_actions_review_semana_1 NUMERIC
@ATTRIBUTE total_actions_update_post_semana_1 NUMERIC
@ATTRIBUTE total_actions_view_semana_1 NUMERIC
@ATTRIBUTE total_actions_view_discussion_semana_1 NUMERIC
@ATTRIBUTE total_actions_view_forum_semana_1 NUMERIC
@ATTRIBUTE total_actions_view_summary_semana_1 NUMERIC
@ATTRIBUTE segundos_logado_semana_1 NUMERIC
@ATTRIBUTE tutor_andragogico_semana_1 {sim,nao}
@ATTRIBUTE class {Aprovado, Reprovado}

```

Figura 2.9: Arquivo ARFF: seção de atributos.

A figura 2.9 exibe alguns dos atributos presentes no arquivos ARFF utilizados na predição de desempenho dos alunos, no contexto desta pesquisa. Cada atributo é tipificado com um tipo de dados, no contexto desta pesquisa os tipos de dados utilizados foram numérico, categórico e de classe. O atributo categórico “tutor_andragogico_semana_” sintetiza a classificação do tutor como andragógico em cada semana do curso e pode assumir o valor “sim” ou “não”. O atributo de classe “class” representa a classificação do aluno como “Aprovado” ou “Reprovado”.

- **Aplicabilidade das Atividades:** A andragogia é fundamentada pela máxima: "Aprender Fazendo". Atividades que envolvam a aplicabilidade do conteúdo aprendido no contexto real das atividades profissionais dos alunos geram maior empatia e expectativas nos alunos.
- **Motivação:** O processo de ensino de alunos adultos deve partir do interesse mútuo de professor e aluno. Portanto, a crença do professor na capacidade intelectual de seus alunos é fundamental para manter o interesse dos estudantes.

2.3.1 Andragogia vs. Pedagogia

No início do século VII a igreja católica inicia na Europa as práticas de ensino de crianças, com a finalidade de propagar a fé cristã e prepara-las para os serviços da igreja. É nesse contexto que surge o termo "Pedagogia", cuja etimologia é grega: *paido* (criança) e *gogos* (educar). Literalmente a pedagogia pode ser considerada como inversa a andragogia, visto que a pedagogia é a ciência de ensinar crianças (CARVALHO; PEDROTE; MOTTA, 2010). Durante a infância a dependência e a proteção dos adultos são fundamentais para o desenvolvimento humano. Esta fase da vida é marcada pelo início do aprendizado escolar, período em que os professores têm controle absoluto sobre os alunos. Na adolescência surgem os questionamentos e a autoridade dos professores é desafiada. Na fase adulta os alunos carregam uma bagagem de experiências positivas e negativas, há expectativas acerca do que não sabe e do quão importante é para sua vida profissional. Nota-se, então, que a evolução humana exige que novas abordagens de ensino sejam aplicadas de forma a garantir a aprendizagem dos alunos nas diferentes fases de suas vidas.

Alunos adultos não devem ser tratados como adolescentes imaturos. Os professores devem compreender as necessidades dos alunos que requerem mais liberdade no processo de aprendizagem, contextualização das atividades, aplicabilidade do conteúdo e motivação quanto à significância do que se está aprendendo. Em outras palavras, os professores devem utilizar as práticas andragógicas ao lecionarem para alunos adultos.

2.3.2 Andragogia e o EaD

O crescente avanço tecnológico faz com que seja quase impossível acompanhar as inovações tecnológicas, estima-se que a cada três anos os conhecimentos que envolvam tecnologias devem ser atualizados, isso revela a dissonância que há entre o que um aluno aprende na universidade, tempo médio de graduação de quatro anos, e o que ele encontrará no mercado de trabalho (WAISMAN, 2015). É nesse contexto que o ensino a distância, EaD, tem evidenciado suas vantagens. Dentre as principais motivações que levam pessoas e organizações, de todas as áreas, a procurarem cursos à distância estão:

economia, barreiras geográficas, flexibilidade de horário, padronização e diretividade do conteúdo.

A necessidade da formação continuada ao longo da carreira profissional faz com que a educação de jovens e adultos seja primordial, para que as pessoas possam acompanhar o desenvolvimento tecnológico. O decreto nº 2.494/MEC define em seu artigo 1º a modalidade EaD:

"Educação a distância é uma forma de ensino que possibilita a autoaprendizagem, com a mediação de recursos didáticos sistematicamente organizados, apresentados em diferentes suportes de informação, utilizados isoladamente ou combinados, e veiculados pelos diversos meios de comunicação."

"Parágrafo único. Os cursos ministrados sob a forma de educação a distância serão organizados em regime especial, com flexibilidade de requisitos para admissão, horário e duração, sem prejuízo, quando for o caso, dos objetivos e das diretrizes curriculares fixadas nacionalmente."

Por definição o EaD utiliza uma metodologia de ensino que valoriza a independência do aluno, tais características são convenientes para adultos que, teoricamente, não necessitam de um supervisionamento constante. Portanto, considerando-se a maturidade do indivíduo podemos encontrar pontos de correlação entre o EaD e a andragogia (OLIVEIRA; BATISTA, 2017).

De acordo com os princípios de Knowles (1980) a andragogia é alicerçada na auto-diretividade, na aplicação prática, na troca de conhecimento entre professor aluno e na motivação dos alunos quanto a importância do que está se aprendendo para o seu futuro. Pode-se notar que todos os princípios de Knowles são abordados pela legislação do ensino a distância no Brasil.

2.4 O Moodle Predicta

O desenvolvimento de ferramentas para apoiar o trabalho de gestão de AVA's, podem maximizar o desempenho dos alunos e diminuir a taxa evasão dos alunos. Portanto, o Moodle predicta (MP) foi desenvolvido para auxiliar gestores e docentes no monitoramento do comportamento dos alunos no AVA Moodle. A ferramenta MP foi elaborada como parte prática da dissertação de mestrado de Felix (2017) e intitulada:

“Mineração de Dados para Predição de Resultados e Visualização de Informação em Ambiente Virtual de Aprendizagem”

O MP se conecta diretamente com a base de dados do Moodle, o que possibilita acesso a todas as entidades do conjunto de dados. Ao se conectar ao banco de dados

um subconjunto de tabelas é selecionado, em seguida os dados tratados e transformados para que possam ser manipulados pela ferramenta de mineração WEKA que é utilizada como biblioteca no MP. A partir do pré-processamento o Moodle Predicta gera alguns relatórios estatísticos e permite a predição do risco de reprovação ou desistência dos alunos, baseando-se no algoritmo probabilístico de mineração de dados por classificação de Naive Bayes.

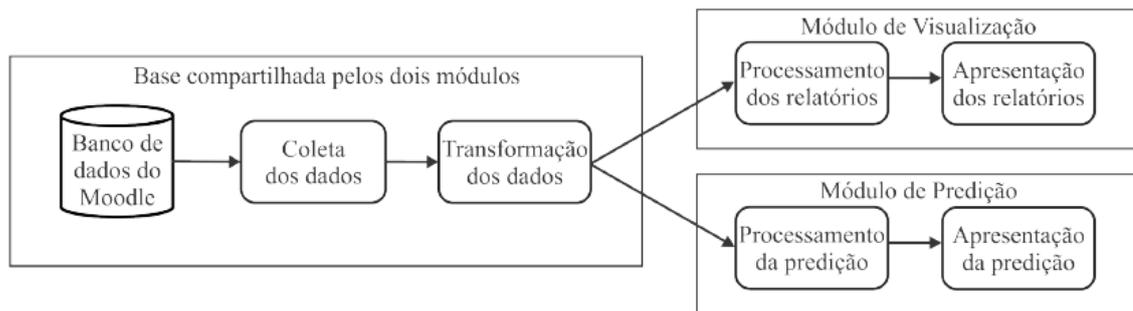


Figura 2.11: Arquitetura: Moodle Predicta (FELIX, 2017).

A figura 2.11 exibe os três módulos que compõem a ferramenta MP. O módulo base compartilhada é responsável pelas atividades comuns aos módulos de visualização e predição, em geral o base compartilhada realiza as atividades de pré-processamento dos dados.

Metodologia de Pesquisa

A metodologia de pesquisa que foi utilizada para se atingir os objetivos apresentados na seção 1.3 trata-se de uma integração de diferentes métodos qualitativos e quantitativos. Os métodos e materiais utilizados estão detalhados nas seções seguintes. Os passos metodológicos seguidos na pesquisa foram: elaboração do *framework* de características dos tutores, escolha das técnicas de mineração de dados empregadas, definição do caso de uso, análise exploratória dos cursos e tutores da EJUG, desenvolvimento da extensão do Moodle Predicta, análise de desempenho dos classificadores e avaliação da ferramenta.

3.1 Elaboração do *Framework* de Características dos Tutores

A primeira etapa da metodologia proposta compreende a realização de uma revisão da literatura sobre as principais características dos docentes que impactam positivamente na performance escolar dos alunos. A revisão foi guiada pelo seguinte protocolo:

- Definição da *String* Geral de Busca
- Escolha das Bases de Artigos
- Critérios de Inclusão e Exclusão
- Questões de Pesquisa

Inicialmente foram selecionados quais os termos, e seus sinônimos, que melhor refletiam o interesse da pesquisa, para se estabelecer a *String* geral de busca. Na etapa seguinte escolheu-se em quais bases de dados os artigos seriam coletados. A terceira fase do protocolo foi definir os critérios de inclusão e exclusão dos artigos na revisão. Após a leitura dos artigos as características dos professores foram agrupadas com os respectivos impactos que causaram no desempenho dos alunos.

O *framework* foi definido a partir do correlaciona mento das características encontradas na literatura com as características desejadas pela andragogia (seção 2.3). A

correlação das características se justifica pelo fato do ensino à distância ter como público alvo alunos adultos.

3.2 Escolha das Técnicas de Mineração de Dados Empregadas

Segundo [Fayyad \(1996\)](#) o método de classificação é umas das principais técnicas de descoberta de conhecimento utilizadas no "mundo real", tendo sido aplicadas em problemas de: detecção de fraudes, mercado de investimentos, ações de marketing e categorização de registros. No contexto deste trabalho também foi utilizado o método de classificação para categorizar os alunos em riscos e o comportamento andragógico dos tutores. Em relação aos alunos a tarefa de classificação realizada foi a categorização dos alunos quanto sua possível aprovação ou reprovação. Como parte da expansão da ferramenta Moodle Predicta a classificação foi utilizada para categorizar o comportamento dos professores como Andragógicos ou Não Andragógico.

Os métodos de agrupamento são excelentes ferramentas para realização da análise exploratória dos dados e identificação de padrões ([FACELI; CARVALHO; SOUTO, 2005](#)). Os algoritmos de agrupamento exploram os dados de forma a agrupá-los de acordo com suas similaridades. Portanto, a técnica de agrupamento (*Clustering*) também foi utilizada, seção 4.8.6, como uma abordagem na tentativa de se criar dois grupos de tutores, sendo um grupo dos tutores praticantes da andragogia e o outro grupo composto por não praticantes da andragogia. Esta abordagem se revelou não satisfatória em agrupar os tutores e portanto não foi implementada na extensão do MP.

De acordo com [Traina e Júnior \(2001\)](#) seres humanos são mais hábeis em interpretar dados em formato gráfico do que em formatos numéricos ou textuais. Em geral as técnicas de visualização da informação representam os resultados de análises estatísticas em forma de gráfico de barras, setores, dispersão etc. Logo, algumas das técnicas de visualização da informação também foram amplamente empregadas na extensão do MP. Relatórios estatísticos e gráficos foram elaborados para permitir aos tutores e gestores acompanhar as atividades dos docentes em: fóruns, salas de bate papo, *quizzes*, tarefas, relatórios de *feedbacks* e *surveys* de avaliação dos alunos.

As ferramentas WEKA e R (seção 2.2.4) foram utilizadas para facilitar as análises de dados. A funcionalidade WEKA *Experimenter* foi bastante utilizada para se realizar a análise de desempenho dos algoritmos classificadores e a função WEKA *Explorer* foi utilizada para facilitar a visualização dos dados que estavam sendo manipulados e simular a execução dos algoritmos classificadores e de agrupamento.

3.3 Definição do Caso de Uso

Os dados selecionados para utilização neste trabalho foram coletados na Escola Judicial de Goiás (EJUG) que é um órgão auxiliar do poder judiciário e vinculado ao Tribunal de Justiça de Goiás (TJGO). A EJUG mantém uma implementação do Moodle ativa para prover o aperfeiçoamento profissional de magistrados e servidores do TJGO (EJUG, 2017).

Os dados analisados foram coletados entre os anos de 2015 e 2019. Os dados extraídos para a composição dos conjuntos de dados foram obtidos de diferentes versões do Moodle o que implicou na extração de dados das bases de dados MySQL e PostgreSQL.

Os atores do caso de uso são os: gestores, tutores e cursos. Os dados coletados para análise são os que expressam as interações dos tutores e gestores dentro dos cursos ofertados pela EJUG.

3.4 Análise Exploratória dos Cursos e Tutores da EJUG

Duas análises exploratórias dos dados foram conduzidas a fim de obter um perfil das principais características dos cursos e dos tutores da EJUG.

A análise exploratória sobre os cursos disponibilizados pela EJUG foi executada com a intenção de se identificar quais tipos de cursos são ofertados, qual o perfil dos alunos que se interessam por esses curso e principalmente descrever como é a interação aluno-professor nos cursos ofertados pela EJUG.

Em seguida foi realizado o perfilamento dos tutores da EJUG. A definição do perfil dos tutores foi realizada correlacionando-se as características definidas no *framework* (seção 4.2) com os ações dos tutores no ambiente de ensino da EJUG.

3.5 Desenvolvimento da Extensão do MP

Foi realizada uma ampliação do trabalho realizado por Felix (2017). A ferramenta Moodle Predicta foi desenvolvida com o objetivo de coletar dados dos alunos no Moodle e a partir destes dados fazer a predição de aprovação ou reprovação dos alunos.

Portanto, para ampliar as funções oferecidas pelo MP, os dados rastreáveis das ações dos docentes, dentro do Moodle, foram incluídos junto aos dados comportamentais dos alunos para aperfeiçoar a predição de desempenho dos alunos, além de permitir a comprovação de que o comportamento dos professores podem influenciar nas conquistas dos alunos. A extensão do MP abarcou também a inclusão de relatórios estatísticos e gráficos para se acompanhar as atividades dos docentes no curso. A classificação dos

tutores quanto a aplicação dos conceitos da andragogia, também foi resultado da extensão do MP.

3.6 Análise de Desempenho dos Classificadores

A análise de desempenho dos algoritmos de classificação envolveu a execução dos classificadores listados em 4.8.7. As métricas de desempenho utilizadas para se definir qual a melhor performance foram as definidas na seção 2.2.2.

A primeira rodada de análises foi executada sem as informações referentes aos professores, com o objetivo de verificar se há diferenças consideráveis entre as bases de dados e no desempenho dos algoritmos classificadores, utilizados nesta pesquisa e na utilizada por Felix (2017).

A segunda etapa de análises foi realizada com a inclusão dos dados referentes às ações comportamentais dos docentes, com o objetivo de identificar qual classificador obteve melhor desempenho e também verificar se os dados dos professores foram utilizados na construção do modelo de classificação dos alunos.

3.7 Avaliação da Ferramenta

A avaliação da ferramenta extensão do MP foi conduzida para validar a importância, eficiência e eficácia das funcionalidades implementadas. A avaliação foi conduzida por um especialista da área, tutores, alunos e por um grupo de gestores da EJUG. O processo de avaliação foi conduzido com a disponibilização da ferramenta para utilização dos avaliadores. Os avaliadores foram recomendados a descrever livremente suas impressões e expectativas quanto às funções disponíveis na extensão do MP. Os relatos dos avaliadores foram apresentados na seção 4.9.

Desenvolvimento do Estudo

Este capítulo apresenta o desenvolvimento de todos os passos metodológicos definidos no capítulo 3 para se atingir os objetivos (seção 1.3) de pesquisa deste trabalho.

Resumidamente o desenvolvimento do estudo se inicia com a apresentação da revisão da literatura e a criação do *framework* de características dos professores. Em seguida é apresentado o conjunto de dados utilizado nas análises e é feito o levantamento do perfil dos cursos e dos tutores da EJUG. Nas seções seguintes são apresentadas as propostas de extensão da ferramenta MP, as análises de desempenho dos classificadores, a implementação do algoritmo classificador e finalmente é feita a avaliação da extensão do MP.

4.1 Características dos Professores que Impactam o Desempenho dos Alunos: Uma Revisão Sistemática da Literatura

Esta revisão da literatura foi conduzida com o objetivo de coletar evidências que possam validar ou anular a hipótese de que as atitudes dos professores influenciam no desempenho dos alunos. Especificamente foi definido um protocolo que norteou a execução da revisão sistemática da literatura a fim de elucidar quais são as características mais observadas nos professores que geram algum impacto no desempenho dos estudantes.

4.1.1 Questões de Pesquisa

As questões de pesquisas auxiliam na análise dos artigos de forma a facilitar a seleção das pesquisas que serão incluídas ou excluídas da revisão. As questões abaixo foram definidas para facilitar a extração das informações que realmente são relevantes para esta revisão da literatura.

1. De quais fontes dos dados foram extraídos?

2. Quais métodos de análises de dados foram empregados?
3. Quais as características dos professores influenciam no desempenho dos alunos?
4. Quais foram os impactos de cada característica no desempenho dos alunos?

4.1.2 Metodologia de Pesquisa

Para realizar esta pesquisa de revisão da literatura foi definido o seguinte protocolo:

- Definição da *String* Geral de Busca.
- Escolha das Bases de Artigos.
- Critérios de Inclusão e Exclusão.
- Análise e Identificação das Características.

Inicialmente foram selecionados quais os termos, e seus sinônimos, que melhor refletiam os interesses de pesquisa, estabelecendo a *String* Geral de Busca. Na etapa seguinte foi feita a seleção dos repositórios de artigos dos quais os artigos foram coletados. Na terceira fase do protocolo foram definidos os critérios de inclusão e exclusão dos artigos na revisão. A próxima fase consistiu na leitura dos artigos e da identificação das principais características dos docentes analisadas em cada pesquisa.

Para auxiliar no gerenciamento dos artigos selecionados, foi utilizado a ferramenta StArt, *State of Art through Systematic Review* (LAPES, 2011).

4.1.3 Definição da Expressão Geral de Busca

A expressão geral de busca foi elaborada com termos chaves e seus possíveis sinônimos, que representam as características relevantes para esta revisão. A principal função desta expressão é maximizar a qualidade dos resultados obtidos e permitir a replicabilidade das consultas. A partir da manipulação, inclusão e exclusão de termos, da expressão geral de busca é possível fazer ajustes finos para aprimorar a precisão na seleção dos artigos em relação aos termos chaves da expressão geral de busca.

A expressão geral de busca utilizada nessa revisão sistemática foi:

(teacher OR tutor OR teaching) AND practice AND (effect OR impact) AND student AND (outcome OR achievement)

4.1.4 Escolha das bases de artigos

As bases de artigos científicos selecionadas foram aquelas consideradas mais úteis para área da computação aplicada à educação. A listagem abaixo apresenta as bases de artigos selecionadas e as respectivas *strings* de busca utilizadas.

- ACM (dl.acm.org) : "query": acmdlTitle:(teacher effect impact student achievement outcome) AND keywords.author.keyword:(achievement outcome) "filter": "publicationYear": "gte":2010
- SCIENCE DIRECT (www.sciencedirect.com): ("teacher"OR "tutor"OR "teaching") AND ("practice") AND ("effect"OR "impact") AND "student"AND ("outcome"OR "achievement") keyword, title, abs: teaching teacher impact student achievement
- WEB OF SCIENCE (www.webofknowledge.com): TÍTULO: (teach* effect* student out*) OR TÍTULO: (teach* impact* student* achieve*) OR TÍTULO: (teach* improve* student* grade*)
- SCOPUS (www.scopus.com): ("teacher"OR "tutor") AND ("practice") ("impact"OR "effect") AND ("student") AND ("achievement"OR "outcome"OR "performance"OR "grade") keyword: teacher OR impact OR student OR achievement OR outcome

A figura 4.1 mostra o total de artigos retornados em cada repositório de artigos científicos.

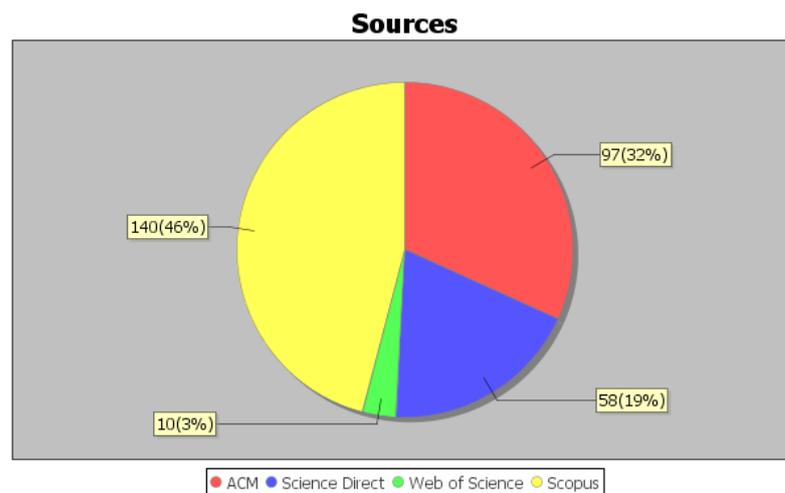


Figura 4.1: Artigos x Repositórios.

4.1.5 Critérios de Inclusão e Exclusão

A tabela 4.1 apresenta os critérios de inclusão e exclusão definidos, a fim de filtrar os artigos de acordo com os objetivos propostos por esta revisão sistemática.

Inclusão	Exclusão
Artigo trata de característica do professor que influenciam o aluno	Artigo não trata de atitudes dos professores que influenciam os alunos
É realizada avaliação do professor	Fora do intervalo de publicação aceito 2010 - 2018
Artigo trata características de tutores em cursos online	Artigo em língua divergente de inglês e português
	Artigo não disponível para leitura na íntegra
	Contexto divergente do objetivo do artigo

Tabela 4.1: *Critérios de Inclusão e Exclusão.*

A definição dos critérios de inclusão embasou-se no foco dos artigos quanto aos objetivos desta revisão da literatura. A tabela 4.1 revela que os aceitos artigos exploraram características dos professores e/ou fizeram avaliação dos professores de forma a elucidar os impactos das atitudes dos docentes diante dos alunos. Os artigos selecionados investigaram professores que lecionam nas modalidades de ensino: presencial, mista e a distância.

Foram rejeitados artigos que não tiveram como objetivo principal investigar atitudes dos professores e a relação com os estudantes. Pesquisas que focaram em características étnicas, raciais e socioeconômicas de professores e alunos, não foram aceitas, pois focaram em contextos muito específicos e que não são passíveis de generalização. Foram excluídos artigos que não foram escritos ou disponibilizados no idioma português ou inglês, porém vale ressaltar que apenas artigos na língua inglesa foram qualificados para inclusão nesta pesquisa. Dada a grande quantidade de artigos retornados, e com a intenção de identificar os trabalhos mais recentes para delinear o estado atual da arte, limitou-se pesquisa a trabalhos publicados a partir do ano de 2010.

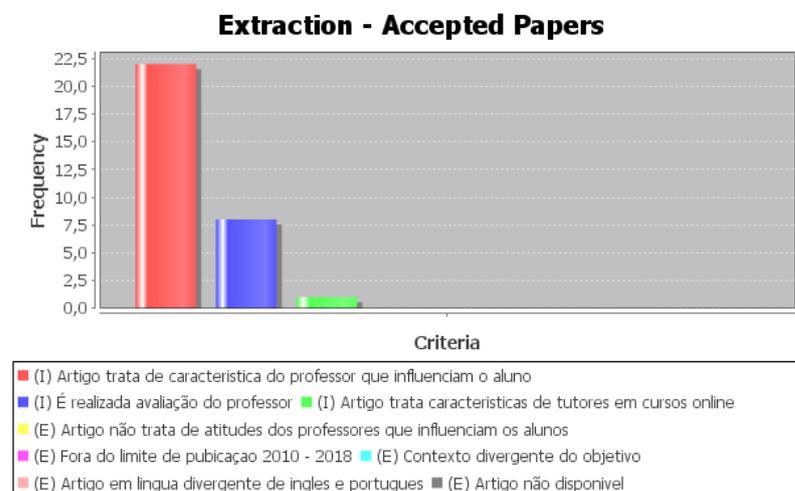


Figura 4.2: *Artigos Aceitos.*

A figura 4.2 exibe a proporção de artigos aceitos por cada critério de inclusão definido na tabela 4.1. A análise da figura 4.2 revela que a maioria dos artigos aceitos analisaram atitudes e comportamentos dos professores que impactaram nos seus alunos. Artigos que investigaram a relação entre a avaliação do professor e as conquistas dos alunos também tiveram representatividade significativa.

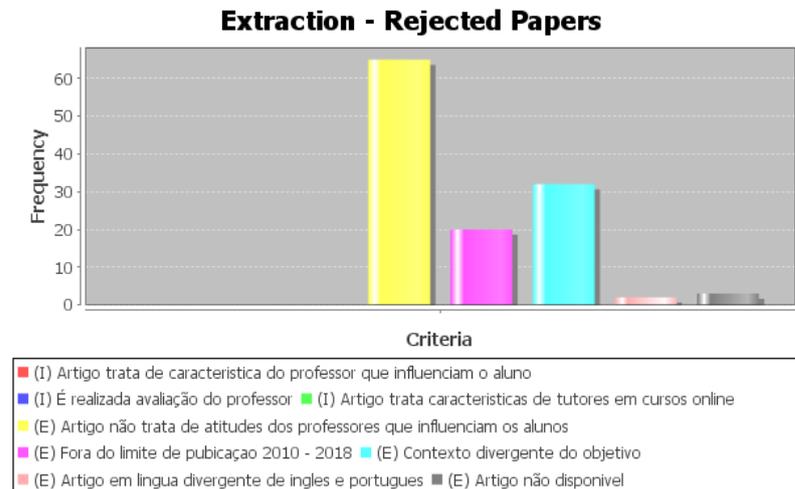


Figura 4.3: Artigos Excluídos.

O gráfico apresentado na figura 4.3 mostra que a maioria dos artigos rejeitados não analisou o perfil dos professores com a intenção de identificar as características dos professores que afetavam as conquistas escolares dos alunos. Outro fator que limitou a inclusão de artigos nesta revisão foi o período de publicação dos artigos. Um número considerável de artigos também foi excluído desta pesquisa por tratar de características étnicas, socioeconômicas e raciais que fogem ao escopo de interesse desta revisão da literatura.

4.1.6 Análise e Identificação das Características

A análise e leitura dos artigos selecionados foram conduzidas de forma a responder as questões de pesquisas (seção 4.1.1). Inicialmente foram coletados 305 artigos, que foram obtidos a partir de simples consultas aos repositórios de artigos com suas respectivas expressões de buscas. Em seguida foi feita uma pré-seleção dos artigos focando nos títulos e resumos dos artigos. As pesquisas que não apresentaram objetivos condizentes com a meta desta pesquisa foram excluídas. A pré-análise resultou em 136 artigos aceitos para a etapa de verificação dos critérios de inclusão e exclusão (tabela 4.1). Para a etapa final de leitura completa dos artigos foram selecionados 26 artigos.

As fontes de dados mais utilizadas pelos artigos selecionados foram:

- Questionários.

- Base de dados educacionais.
- Avaliações e *Quizzes*.
- Observações.

O principal meio de coleta de dados foi através da aplicação de questionários padronizados como: *Teacher Opportunity to Learn* (TOTL), *Teacher Self Efficacy* (TSE) e *Questionnaire on Teacher Interaction* (QTI), além de questionários personalizados pelos pesquisadores. Todas as pesquisas utilizaram o índice alfa de *cronbach* para confirmar a confiabilidade dos questionários aplicados aos professores e alunos. Outras fontes utilizadas foram as bases de dados educacionais de ministérios da educação, escolas e universidades. Notas de *quizzes* e exames como: *Programme for International Student Assessment* (PISA), *Teaching and Learning International Survey* (TALIS) e *Education Quality Measurement System* (SIMCE), foram utilizadas para se verificar o desempenho de alunos e em alguns casos dos professores (TALIS).

Os métodos de análises de dados mais empregados na literatura em análise foram:

- Estatística descritiva.
- Correlação de Pearson.
- Teste qui-quadrado.
- Regressão linear.
- Análises: OLS, ANOVA, Fatorial.

As técnicas de estatística descritiva foram amplamente utilizadas, por exemplo, medidas de tendências centrais como: médias, medianas, variâncias (ANOVA) e desvios padrões. A correlação de Pearson foi o recurso mais utilizado para medir o grau de associação entre os atributos dos docentes e o desempenho dos alunos. Testes qui-quadrado foram utilizados, em algumas pesquisas, para se verificar o nível de dependências entre as variáveis dos professores e os índices ligados às conquistas dos alunos. Algumas pesquisas utilizaram a regressão linear para definir funções de estimativas de desempenho dos alunos dado os atributos do educador. Alguns artigos também utilizaram regressão de mínimos quadrados, OLS, e análises multivariadas por meios de modelos fatoriais. As ferramentas de análises mais recorrentes nos estudos foram o SPSS e o MLwiN.

Característica	Impacto Positivo	Impacto Negativo	Sem Impacto
Experiência	(CANALES; MALDONADO, 2018) (CLOTFELTER; LADD, 2010) (SANTIN; SICILIA, 2018) (ÇAKIR; BICHELMeyer, 2016)		(SHUKLA; NIRBAN; DOSAYA, 2018) (STES; MAEYER, 2012) (AZIGWE; KYRIAKIDES, 2016)
Formação	(SHUKLA; NIRBAN; DOSAYA, 2018)		(ÇAKIR; BICHELMeyer, 2016) (CHU; LOYALKA, 2015) (CANALES; MALDONADO, 2018) (SANTIN; SICILIA, 2018) (CLOTFELTER; LADD, 2010)
Motivação	(YOU; DANG, 2016) (LEE; LONGHURST, 2017)		(ÇAKIR; BICHELMeyer, 2016)
Comunicação	(NGANG; YIE, 2015)	(ZAKHAROV; CARNOY, 2014)	
Liderança	(NGANG; YIE, 2015) (PASSINI; MOLINARI, 2015) (SANTIN; SICILIA, 2018)		(NAIMIE; SIRAJ, 2012)
Estilo de Ensino	(NGANG; YIE, 2015) (CORDERO; GIL-IZQUIERDO, 2018) (NAIMIE; SIRAJ, 2012) (CHOI; YANG, 2011) (KYRIAKIDES; CHRISTOFOROU, 2013)	(CORDERO; GIL-IZQUIERDO, 2018) (COMI; ARGENTIN, 2017)	
Gerência do Tempo	(AZIGWE; KYRIAKIDES, 2016) (KYRIAKIDES; CHRISTOFOROU, 2013)		
Avaliações	(NAIMIE; SIRAJ, 2012) (ZAKHAROV; CARNOY, 2014)		
Habilidades em T.I	(COMI; ARGENTIN, 2017)		(LEE; LONGHURST, 2017)
Capacitação	(GOLOB, 2012)		(AKIBA; LIANG, 2016) (ZHANG; LAI, 2013) (STES; MAEYER, 2012)
Auto-eficácia	(MOJAVEZI; TAMIZ, 2012) (FRIEDRICH; FLUNGER, 2015)		
Comportamento Não Verbal	(PASSINI; MOLINARI, 2015) (CHAUDHRY; ARIF, 2012) (ABDELLAH, 2015) (KYRIAKIDES; CHRISTOFOROU, 2013)		

Tabela 4.2: Características de Tutores e o Impacto nos Alunos.

As principais características dos professores identificadas durante a leitura dos artigos estão listadas na tabela 4.2. Cada linha na tabela 4.2 lista uma característica, os artigos que avaliaram tal atributo, e qual o impacto que a característica do tutor causou nos alunos. O tipo de impacto, no contexto desta revisão, é considerado: positivo quando os alunos tiveram melhor desempenho escolar, negativo quando as características observadas influenciaram em piora no rendimento escolar, e neutro nas ocasiões em que os estudos não identificaram nenhuma interferência da característica avaliada no desempenho acadêmico dos alunos.

Nas pesquisas analisadas a *Experiência* foi analisada utilizando duas métricas: tempo de docência e antiguidade na instituição de ensino. A *Formação* foi avaliada em vários níveis, dentre os principais: graduação, especialização e mestrado. A *Motivação* foi trabalhada como a capacidade do professor de gerar auto-eficácia nos alunos e estimular os estudantes a se engajarem no processo de aprendizagem. A interação entre aluno e professor, dentro e fora do ambiente escolar, foi caracterizada como *Comunicação*. A capacidade do professor de orientar os alunos foi abordada como uma característica de *Liderança*. O *Gerenciamento do Tempo* foi analisado como a capacidade do docente de aproveitar o tempo disponível para interação com os alunos. As pesquisas que direcio-

naram seus objetivos para analisar a forma como os instrutores transmitiram o conhecimento, classificaram essa característica como *Estilo de Ensino* e foi observada quanto a: participação ativa dos alunos – aprendizado ativo, participação ativa do orientador – aprendizado orientado, e em relação aos recursos utilizados. A quantidade de exercícios disponibilizados, testes práticos (simulados) e o estilo de avaliação dos professores foram analisados como atributos de *Avaliações*. As *Habilidades em Tecnologia da Informação* foram mensuradas levando-se em consideração a capacidade de preparação de materiais, uso de softwares na sala de aula e o uso de recursos como: fóruns, sites e e-mail. O envolvimento dos educadores em cursos de aperfeiçoamento profissional, especializações, participações em congressos e produção científica foram caracterizados como atributos de *Capacitação*. As expectativas dos professores frente ao desenvolvimento e desempenho de seus alunos foi objeto de estudo, de algumas pesquisas, e esse comportamento foi definido como *Auto-Eficácia* dos professores. O *Comportamento Não Verbal* dos educadores foi observado quanto a: cordialidade, compreensão, segurança, humor, rigor, estrutura e aplicabilidades das atividades e a capacidade do professor de criar e manter o ambiente de sala de aula.

Em relação aos impactos gerados nos alunos houve divergências quanto ao impacto da *Experiência* dos professores e as conquistas escolares, contudo, os resultados encontrados mostram que não houve efeito negativo para estes atributos em relação ao desempenho dos alunos. A *Formação* acadêmica dos professores não impactou a performance dos estudantes, sendo então considerada neutra. A *Motivação* transmitida pelo professor mostrou-se eficaz, em todos os estudos analisados, nas realizações escolares dos alunos. A forma de *Comunicação* entre aluno e professor pode afetar negativamente o desempenho dos alunos, foi percebido que a utilização contínua de mídias sociais como meio de interação ocasionou queda na produtividade dos alunos (ZAKHAROV; CARNOY, 2014). Educadores que assumem uma postura de *Liderança* no nível de sala de aula conseguem frequentemente melhorar a qualidade do ensino e o desempenho dos seus alunos (NGANG; YIE, 2015). O *Estilo de ensino* adotado pelos docentes mostrou-se como um forte influenciador dos resultados obtidos pelos discentes, de acordo com os artigos, que observaram esta característica, em abordagens de ensino em que os alunos atuam ativamente no contexto da sala de aula foi prejudicial para os alunos (CORDERO; GIL-IZQUIERDO, 2018), abordagens em que os professores utilizaram recursos visuais mostraram-se eficazes em melhorar o processo de ensino (CHOI; YANG, 2011). A forma como a *Gerência do tempo* disponível para o ensino foi conduzida, pelos educadores, evidenciou-se fortemente correlacionada com o progresso escolar dos alunos, em todas análises. O modo como as *Avaliações* dos alunos foram realizadas influenciou diretamente os alunos, Zakharov e Carnoy (2014) relatam que a quantidade de exercícios resolvidos pelos alunos impactou positivamente as notas no exame nacional (USE) da

Rússia. O uso da tecnologia da informação no ambiente da sala de aula está diretamente ligado as crenças pedagógicas dos professores, segundo Lee e Longhurst (2017) alguns professores podem não se sentirem familiarizado ou não acreditar na eficácia dos recursos de T.I aplicados à educação, a aquisição de *Habilidades em Tecnologia da Informação* mostrou-se eficaz no desempenho dos alunos (COMI; ARGENTIN, 2017). A participação dos professores em programas de *Capacitação* não gerou efeitos significativos na aprendizagem dos alunos (STES; MAEYER, 2012). A confiança dos professores, *Auto-Eficácia*, em seus alunos está positivamente ligada às conquistas acadêmicas dos estudantes. Em todas as pesquisas analisadas o *Comportamento Não Verbal* dos professores impactaram positivamente no desempenho dos alunos.

4.1.7 Considerações Finais

Esta revisão sistemática da literatura teve como objetivo geral elucidar atributos ligados aos professores que impactam, direta ou indiretamente, no desempenho e conquistas escolares dos alunos. A partir dos trabalhos selecionados foram extraídos os métodos de análises e de coleta de dados mais recorrentes nos artigos em estudo. As técnicas de estatística descritiva e a aplicação questionários foram as mais utilizadas para análise estatística e coleta de dados, respectivamente.

A leitura dos artigos viabilizou a identificação das características, dos educadores, e dos efeitos desses atributos nos alunos. As características dos docentes que se mostraram positivamente relacionadas com o desempenho escolar dos alunos foram: Motivação, Liderança, Estilo de Ensino, Gerência do Tempo e o Comportamento não verbal. Os atributos relacionados a: Experiência, Formação e Capacitação não tiveram correlações significativas com o desempenho escolar dos estudantes.

O principal desafio encontrado neste estudo foi o grande volume de pesquisas e a seleção dos artigos mais relevantes. Pesquisas valiosas podem não ter sido incluídas nesta revisão, entretanto, atualizações futuras desta pesquisa poderão complementar e atualizar este estudo acerca do estado da arte, na seara da avaliação comportamental dos docentes e o reflexo no desempenho dos alunos.

A partir desta revisão da literatura ficou evidenciado que alguns comportamentos podem interferir nas conquistas escolares dos alunos e assim pode-se assumir que a hipótese de que as atitudes dos professores influenciam o desempenho dos alunos é válida.

4.2 O Framework de Características dos Tutores

Conceitualmente um *framework* é um conjunto de premissas que são utilizadas para descrever um domínio. O conceito de *framework* é genérico, portanto, sofre variações

a depender do contexto em que é utilizado. Na área de Tecnologia da Informação, onde este conceito tem sido amplamente utilizado, o termo *framework* é utilizado para descrever um conjunto de técnicas utilizadas para resolver problemas específicos processo de desenvolvimento de *software*.

No contexto desta pesquisa o conceito de *framework* será utilizado para descrever o conjunto de características dos professores que podem interferir no desempenho escolar dos seus alunos. Cada característica sintetiza um comportamento observado nos tutores dentro do ambiente escolar.

O *framework* de atributos dos docentes que impactam no desempenho dos alunos foi construído a partir das características observadas em trabalhos da literatura acadêmica, levantados na revisão da literatura (seção 4.1), e posteriormente correlacionados e embasados pelas características desejadas pela andragogia (seção 2.3), que tem foco em ambientes de ensino voltados para adultos. A andragogia foi utilizada como referencial teórico educacional para unificar e explicar as características encontradas na literatura.

4.2.1 Características dos Docentes: segundo a Literatura Acadêmica

Para a construção do *framework* de atributos dos docentes selecionamos um subconjunto das características encontradas na revisão da literatura (tabela 4.2), pois para atingir o objetivo de realizar a predição de desempenho dos alunos a partir dos dados extraídos do Moodle é preciso que as características dos docentes sejam rastreáveis dentro da base de dados do AVA. Portanto, o conjunto de atributos incluídos no *framework* foram aqueles em que se conseguiu fazer uma correlação com os dados coletados pelo Moodle.

Característica	Descrição
Avaliações	Representa o modelo de avaliação aplicado pelos tutores.
Capacitação	Diz respeito ao aperfeiçoamento profissional.
Comunicação	Representa o nível de interação entre aluno e professor.
Estilo de Ensino	Refere-se a metodologia de ensino aplicada.
Experiência	Traduz a experiência em docência.
Formação	Revela a formação acadêmica: Graduação e Pós Graduações
Gerenciamento do Tempo	Diz respeito ao tempo dedicado aos alunos.
Liderança	Capacidade de orientar os alunos.
Motivação	Capacidade do professor em estimular os alunos.

Tabela 4.3: Atributos de Docência: Literatura Acadêmica.

A tabela 4.3 apresenta o subconjunto de atributos, passíveis de serem rastreados no modelo de dados do Moodle, que foram selecionados para compor o *framework*. Cada

atributo selecionado foi avaliado, quanto ao impacto gerado nos alunos, por pelo menos uma pesquisa e seu impacto nos alunos foi apresentado na tabela 4.2.

4.2.2 Características dos Docentes: segundo a Andragogia

A andragogia tem como foco o ensino para alunos adultos. As diretrizes da andragogia foram incluídas no *framework* baseando-se nas seguintes proposições:

- Cursos EaD tem foco em alunos jovens e adultos;
- Os preceitos da andragogia estão presentes no decreto nº 2.494/MEC que institui o EaD no Brasil (seção 2.3)
- Os dados analisados foram coletados de cursos ofertados à alunos adultos.

As características andragógicas desejadas no ensino para adultos estão listadas na seção 2.3. Os atributos definidos pela andragogia tem um caráter global podendo se correlacionar com um ou mais dos atributos selecionados para formar o *framework* de características de tutoria (tabela 4.3).

A correlação dos atributos da andragogia com os atributos encontrados na literatura embasou-se na perspectiva em que cada característica da literatura foi abordado nos artigos e no nível de afinidade com a definição de cada atributo andragógico, segundo Knowles (1950).

A *Auto-diretividade* que alunos adultos necessitam está diretamente associada a gerência do tempo, ao modelo de avaliações do tutores e na capacidade de motivar os alunos a participarem das atividades.

A capacidade do tutor em abordar as *experiências prévias* dos alunos, conforme recomendado pela andragogia, está relacionado ao modelo de Avaliações, ao Estilo de ensino do tutor, nas habilidades de Comunicação e Experiência profissional dos tutores.

A capacidade do tutor em *motivar* os alunos está ligada as seguintes características dos docentes: Motivação, Comunicação, Liderança e Estilo de Ensino.

O modelo de *avaliações* do docente deve privilegiar atividades cuja aplicabilidade sejam bem definidas e que preferencialmente reflitam nas atividades profissionais dos alunos. As habilidades dos tutores em elaborar atividades que incorporem os interesses dos alunos estão ligadas as seguintes características: Avaliações, Estilo de Ensino, Experiência e Comunicação.

4.2.3 O Framework de Características de Tutoria

A tabela 4.4 correlaciona as características dos tutores segundo a andragogia com as características mais comumente investigadas na literatura acadêmica. A primeira coluna lista os atributos de docência desejados pela andragogia. Na coluna seguinte são

listados os atributos dos docentes que impactam na performance dos alunos, segundo a literatura acadêmica.

Característica Andragógicas	Características da Literatura
Avaliações	Avaliações; Estilo de ensino; Experiência; Comunicação.
Auto-diretividade	Gerenciamento do Tempo; Avaliações; Motivação.
Experiência Prévia	Avaliações; Estilo de Ensino; Comunicação; Experiência.
Motivação	Motivação; Comunicação; Estilo de Ensino; Liderança.

Tabela 4.4: *Framework de Características dos Docentes.*

Portanto, a tabela 4.4 será o *framework* de características de tutoria que será utilizado no contexto de pesquisa, as principais abordagens que envolveram a utilização do *framework* de tutoria serão as análises exploratórias dos tutores da EJUG e na classificação comportamental dos tutores e dos alunos. A correlação entre os dados extraídos da base de dados da EJUG e as características dos tutores presentes no *framework* é apresentada nas seções 4.5 e 4.8.5.

4.3 O Conjunto de Dados da EJUG

No Tribunal de Justiça de Goiás (TJGO), o ensino à distância tem sido utilizado para prover capacitação contínua aos magistrados e servidores do judiciário. A modalidade EaD tem sido amplamente utilizada no âmbito do TJGO, tendo em vista que o poder judiciário está presente em mais da metade dos municípios do estado de Goiás, pois com essa modalidade de ensino é possível disponibilizar cursos de capacitação para todos os seus servidores. Entretanto também são ofertados cursos presenciais e semipresenciais.

O TJGO oferece cursos de capacitação profissional aos seus agentes por meio da Escola Judicial de Goiás (EJUG). A EJUG utiliza o ambiente virtual de aprendizagem

Moodle para gerenciar seus cursos. Portanto, a partir da concessão de acesso aos dados pelo diretor da EJUG, selecionamos os dados coletados pelo Moodle da EJUG para a execução deste trabalho. O caráter corporativo dos cursos ofertados no TJGO nos motivou a trabalhar com o conjunto de dados da EJUG, pois possibilitou a comparação de desempenho, de algoritmos classificadores, em diferentes conjuntos de dados (seções 4.8.7 e 4.8.8).

4.3.1 O Tribunal de Justiça de Goiás

O Tribunal de Justiça de Goiás (TJGO) é uma entidade pública que representa o poder judiciário no estado de Goiás. Como um órgão do estado o TJGO tem corpo funcional de 10.024 serventuários e magistrados que atendem às demandas de aproximadamente 6.730.848 jurisdicionados. O TJGO está distribuído em 127 dos 246 municípios do estado de Goiás, sendo 327 o número total de unidades judiciárias (CNJ, 2018).

A política de política de capacitação continuada do TJGO oferece, desde 2006, cursos de capacitação profissional e benefícios pecuniários aos servidores que participam dos cursos de capacitação. O artigo 24 da lei 17.663, que dispõe sobre a estrutura das carreiras do poder judiciário, institui a gratificação de incentivo funcional, a cada 120 horas de treinamento os servidores recebem aumento de 2% em seus salários, observando o limite 10% e a renovação das ações a cada cinco anos.

4.3.2 A Escola Judicial de Goiás

O artigo. 39, da Constituição da República de 1988, dispõe que os entes da administração pública devem prover escolas para propiciar a formação contínua de seus agentes. Seguindo as determinações da carta magna o Conselho Nacional de Justiça (CNJ), instituição reguladora do poder judiciário, regulamentou a criação das escolas judiciais para prover formação profissional de magistrados e servidores. Portanto, em consonância com as diretrizes do CNJ foi criada, em 2015, a Escola Judicial de Goiás (EJUG) no âmbito do TJGO.

A missão da escola judicial é promover o aprimoramento técnico e humano dos magistrados e servidores do TJGO. Em termos gerais, a EJUG é responsável por: transmitir os valores preconizados pela instituição a todos os funcionários, capacitar e atualizar magistrados e servidores, profissionalizar a área administrativa e auxiliar o poder judiciário na implementação das novas e melhores práticas de gestão (TJGO, 2017).

Os cursos oferecidos pela EJUG se concentram na capacitação de gestores do judiciário, treinamento na área jurídica, aprimoramento administrativo, capacitação no processo digital judicial e educação socioambiental. Os cursos oferecidos pela escola judicial são criados por uma equipe multidisciplinar composta por pedagogos, administra-

dores e psicólogos, há também cursos obtidos por parcerias com outras entidades públicas e privados.

Dentre o corpo funcional do TJGO, 246 funcionários atuam como tutores dos treinamentos ofertados pela instituição e 6037 funcionários já participaram de alguma ação de capacitação da escola judicial, o que resultou na emissão de 14.003 certificados de conclusão de curso.

A EJUG seleciona seus professores por meio de processos seletivos publicados em editais internos ao TJGO. São habilitados para seleção servidores ocupantes de cargos efetivos ou em comissão, e além do vínculo empregatício os candidatos à tutoria devem ter experiência e formação nos cursos ofertados, os proponentes devem comprovar os requisitos apresentando *curriculum vitae* e diplomas acadêmicos. Os candidatos são avaliados por uma banca examinadora definida pela EJUG, composta por três servidores. Os tutores selecionados recebem retribuição financeira por hora-aula, 50 minutos, e a remuneração varia de acordo com a titularidade do tutor, sendo consideradas as seguintes divisões de títulos: graduação, mestrado e doutorado (TJGO, 2016).

4.3.3 Banco de Dados da EJUG

Com a devida autorização, por parte da Diretoria de Informática do TJGO e do Diretor da EJUG, para acesso aos bancos de dados da EJUG, a equipe do departamento de infraestrutura forneceu os *scripts* (*dump* em inglês) necessários para recriação do banco de dados do Moodle utilizado pela EJUG.

Os dados, contidos nos *scripts*, estão estruturados em formato SQL (*Structured Query Language*). No período em que esta pesquisa foi realizada a EJUG estava migrando da versão 3.2 para a versão 3.4 do Moodle, que utilizam diferentes *softwares* de sistema gerenciador de banco de dados (SGBD), sendo que cada versão utiliza, respectivamente, MySQL e PostgreSQL. Portanto, dois arquivos de *scprits* dos bancos de dados da EJUG foram disponibilizados, cada *script* contém a estrutura completa do modelo de dados utilizado pelo Moodle e representa uma instalação do Moodle em diferentes versões.

Arquivo	Tamanho	Banco de Dados
backup_moodle_mysql	4.48GB	Moodle v3.2 (MySQL)
backup_moodle_postgresql	349MB	Moodle v3.6 (PostgreSQL)

Tabela 4.5: Descrição dos Scripts SQL fornecidos pelo TJGO.

A tabela 4.5 revela, a partir do tamanho do arquivo de *scripts*, que os conjuntos de dados contêm uma enorme quantidade de dados, que ressalta a importância da aplicação das técnicas de EDM para extração de informações úteis.

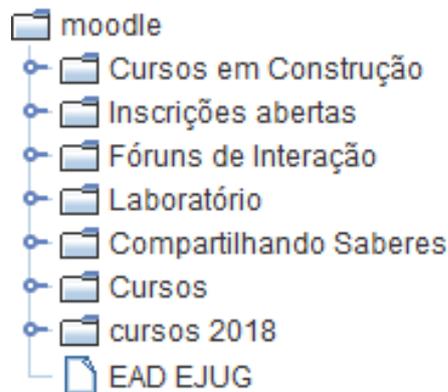


Figura 4.4: *Categorias de cursos presentes na base de dados MySQL.*

Os dados presentes na base de dados do Moodle, versão 3.2 e com SGBD MySQL, foram coletados entre julho de 2009 e junho de 2018. Portanto, as informações nesse conjunto de dados expressam as características dos cursos, alunos e tutores antes e depois da criação da EJUG. O arquivo “backup_moodle_mysql” (tabela 4.5) contém mais de 4 *Gigabyte* de dados, agrupados em 387 tabelas, com mais de 12.519 usuários inseridos e 622 cursos criados. A figura 4.4 exibe a estrutura de categorias em que os cursos estão distribuídos.

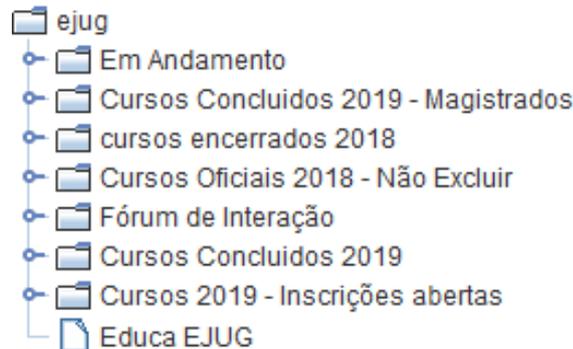


Figura 4.5: *Categorias de cursos presentes na base de dados PostgreSQL.*

O banco "backup_moodle_postgresql"(tabela 4.5), versão 3.6 e com SGBD PostgreSQL, contém dados que foram coletados entre 2015 e 2019, logo, os dados presentes nessa base de dados diz respeito ao período pós EJUG. O esquema de dados contém 349 Megabytes de informações, distribuídas em 408 tabelas, com 14.610 usuários cadastrados e 116 cursos. Os cursos são agrupados por categorias, a figura 4.5 exibe as categorias de cursos existentes no esquema.

4.3.4 O Modelo de Dados do Moodle da EJUG

O modelo de dados do Moodle contém algumas centenas de tabelas, a quantidade de tabelas pode variar de acordo a versão do Moodle, agrupadas de acordo com seus relacionamentos. As tabelas do modelo de dados podem ser nomeadas com um prefixo, por padrão “mdl_”, a utilização de prefixos permite que mais de uma instalação do Moodle utilize o mesmo banco de dados, sendo as tabelas de cada instalação diferenciadas pelo prefixo.

A tabela curso armazena todas as informações referentes a um curso cadastrado, e se relaciona direta ou indiretamente com todas as demais tabelas do Moodle, portanto, exerce uma posição de centralidade entre os relacionamentos. A figura 4.6 apresenta os principais relacionamentos da tabela curso na versão 3.6 do Moodle.

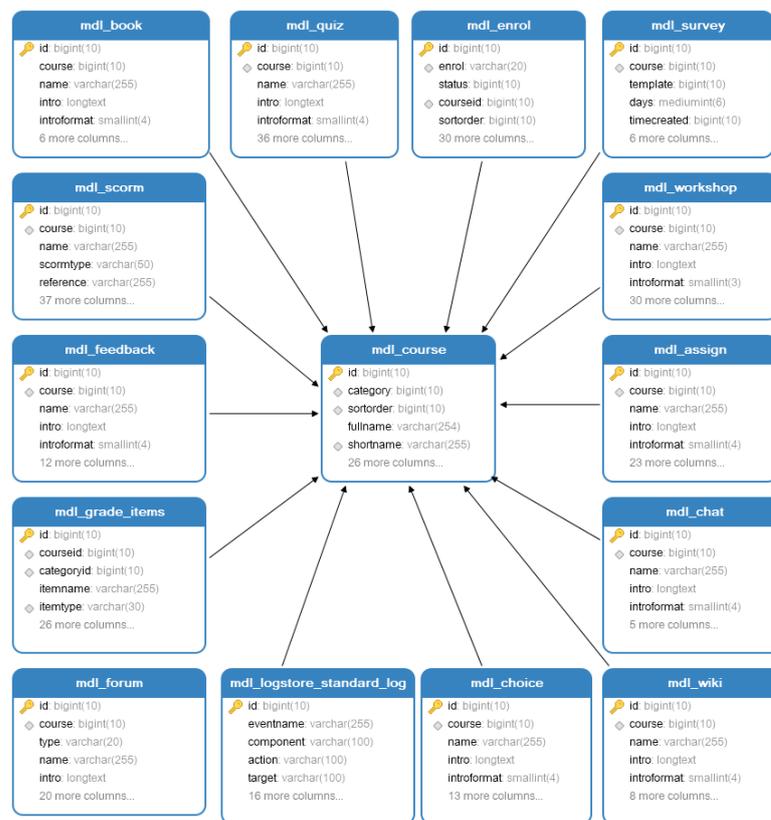


Figura 4.6: Relacionamentos da tabela Curso.

Os relacionamentos entre as tabelas abstraem a dinâmica de funcionamento do ambiente virtual de aprendizagem, os relacionamentos da tabela curso, por exemplo, sintetizam como os cursos são agrupados em categorias, módulos, atividades pedagógicas, conclusões dos cursos, notas das atividades etc.

Para alcançar os objetivos propostos (seção 1.3) várias tabelas e seus respectivos relacionamentos foram utilizados. A seguir serão apresentados os principais relaciona-

mentos utilizados para elaboração dos relatórios do módulo de visualização (seção 4.7) e para execução da predição (seção 4.8.10).

Matrículas e Perfis de Usuário

A matrícula e inscrição dos alunos em um curso envolve a criação de usuários e atribuição de perfil aos usuários. O perfil de usuário determina os privilégios de acessos às funções disponibilizadas no Moodle. Na versão 3.6 do Moodle há alguns perfis de usuários pré-definidos: *Manager*, *Course Creator*, *Tutor*, *Moderator*, *Student* e *Quest*. A figura 4.7 mostra os relacionamentos necessários para realização de matrícula e atribuição de um perfil de usuário.

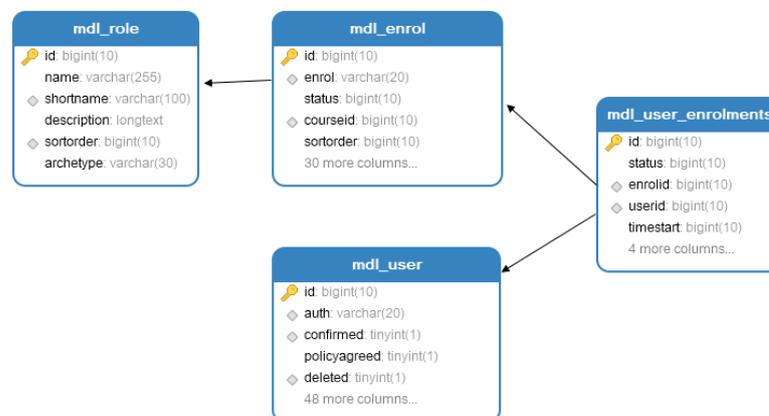


Figura 4.7: *Relacionamentos para Realização de Matrícula e Atribuição de Perfil.*

A matrícula de um aluno em um determinado segue os seguintes passos:

- O gestor de cursos define como os alunos devem se inscrever nos cursos, essa informação fica registrada na tabela *enrol*;
- Os alunos interessados caso não tenha usuário cadastrado no AVA deveram criar um usuário, inserção de dados na tabela *user*;
- O perfil de usuário poderá ser atribuído automaticamente ou designado pelo gestor dos cursos;
- Ao entrar com o usuário cadastrado no ambiente virtual o aluno poderá inscrever nos cursos que desejar, conforme definido no passo 1. A ligação entre o usuário e o curso, que representa a matrícula propriamente dita, fica armazenada na tabela *user_enrolments* que referencia a tabela *role* para definir qual perfil o usuário exercerá no curso matriculado.

Fóruns

A interação entre alunos e professor em ambientes de ensino EaD é fundamental para simular o ambiente de sala de aula tradicional (PICCIANO, 2002). Portanto, os fóruns de notícias, e atividades, são amplamente utilizados em AVAs, pois permite que a comunicação ocorra de várias formas e em diversos sentidos, seja aluno para aluno, aluno para professor ou professor para alunos. A figura 4.8 define os relacionamentos necessários para o funcionamento da dinâmica dos fóruns no Moodle.

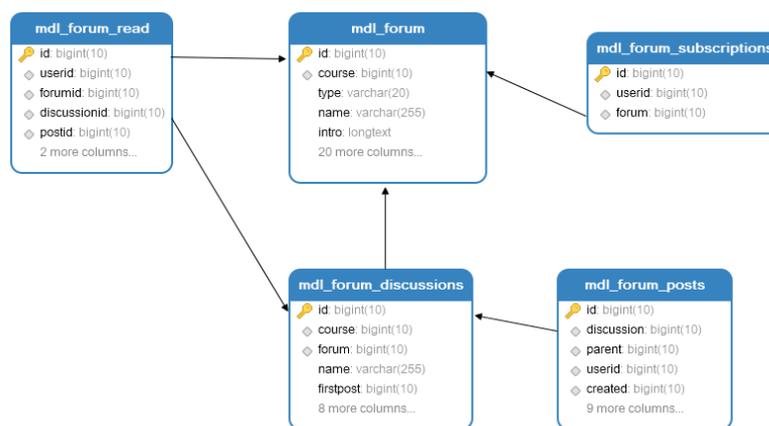


Figura 4.8: Relacionamentos necessários para funcionamento do Fórum.

A interação por meio dos fóruns se dá da seguinte forma:

- Usuários com perfis de gestor, criador de curso e tutor inicialmente criam o módulo fórum dentro do curso, os dados do fórum ficam armazenados na tabela **forum**;
- Com a disponibilização do fórum os usuários cadastrados no curso podem então iniciar tópicos de discussões que ficam salvos na tabela **forum_discussions**;
- A comunicação ocorre efetivamente com as postagens dos usuários, realizadas dentro dos tópicos de discussões. Todas as postagens ficam registradas na tabela **forum_post**.

Chats

Salas de bate papo (*chats*) são muito utilizados para interação entre pessoas conectadas pela internet. O Moodle também se apropriou deste recurso tecnológico para fornecer mais uma alternativa para comunicação entre os usuários da plataforma. A utilização do módulo de *chat* é facultada aos administradores e ao tutor do curso, uma vez que está função é desabilitada por padrão. A interação via *chat* envolve basicamente duas tabelas e o relacionamento entre elas é expresso na figura 4.9.

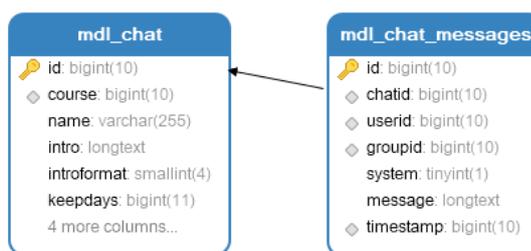


Figura 4.9: Relacionamentos entre tabelas de Chat.

As salas de bate papos são representadas pela tabela *chat* que armazena todos os detalhes e descrições das salas cadastradas. As mensagens trocadas entre os usuários são registradas na tabela *chat_messages*.

Questionários

Os questionários avaliativos são utilizados como atividades para verificar o nível de aprendizagem dos alunos. Em plataformas de ensino EaD os questionários são comumente chamados de *quizzes*. No modelo de dados do Moodle os relacionamentos que envolvem questionários utilizam as tabelas presentes na figura 4.10, sendo que um questionário é composto por questões, que pode ser agrupadas em categorias, cada questão pode ser feita uma ou mais vezes, caso o usuário não acerte a questão, e as questões podem ser de múltipla escolha, verdadeira ou falso ou discursiva. Cada questão deve estar relacionada a pelo menos um *quiz*.

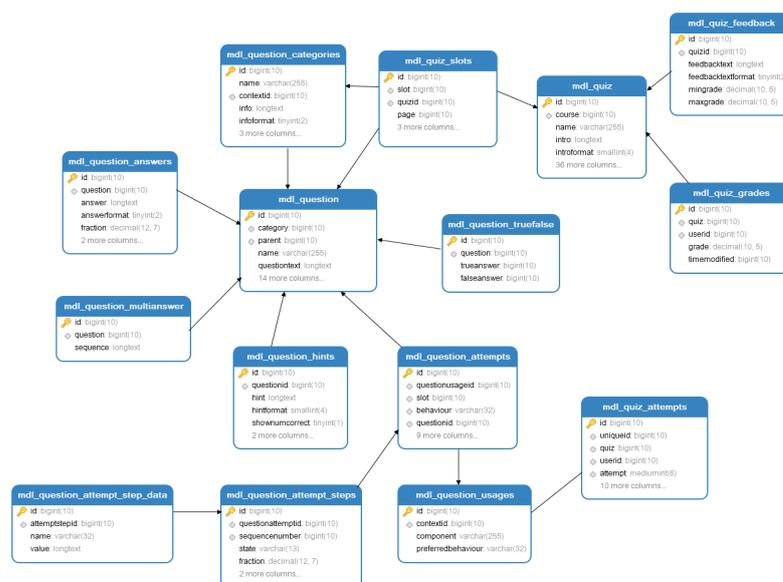


Figura 4.10: Relacionamentos dos Questionários.

A interpretação dos relacionamentos entre as tabelas da figura 4.10 pode ser feita da seguinte forma:

- Usuários com privilégios para elaboração de questionários, gestores e tutores, devem criar as questões que são salvas na tabela *question*. As questões podem pertencer a uma categoria de questões, essa relação questão e categoria é registrada na tabela *question_categories*. As tabelas *question_multichoice* e *question_truefalse* definem o formato de cada questão (múltipla escolha, verdadeira ou falso e discursiva) e por isso também possuem um relacionamento com a tabela *question*;
- Quando uma questão de múltipla escolha é inserida as alternativas desta questão, bem como a alternativa correta, são armazenadas na tabela *question_answers*;
- A tabela *question_usages* armazena o relacionamento entre as questões e os componentes do Moodle que utilizaram a questão, geralmente as questões são podem ser utilizadas em questionários de *feedback* ou *quizzes*;
- Títulos, descrições, prazos, quantidade de tentativas permitidas são algumas das informações que devem ser fornecidas para criação de um *quiz*, todos esses dados são inseridos na tabela *quiz*. O relacionamento entre quais questões pertencem a um determinado *quiz* é representado pela tabela *quiz_question_slots*. A tabela *quiz_attempts* guarda as informações relativas as tentativas dos alunos de realizar o *quiz*. A tabela *quiz_feedback* armazena mensagens de *feedback* inseridas pelos professores para parabenizar ou estimular os alunos após a conclusão do *quiz*. A tabela *quiz_grades* registra as notas de cada aluno nos questionários.

Tarefas

Tarefa é outro método pedagógico para aferição da aprendizagem dos alunos. O tutor pode cadastrar pelos menos duas modalidades de tarefas no Moodle, que diferem quanto à forma como a tarefa deve ser enviada para avaliação do professor, os alunos podem enviar um arquivo (pdf, doc, imagens etc.) ou devem enviar suas respostas diretamente do Moodle, digitando sua resposta em uma caixa de texto. As principais tabelas que descrevem a realização de tarefas no Moodle estão presentes na figura 4.11.

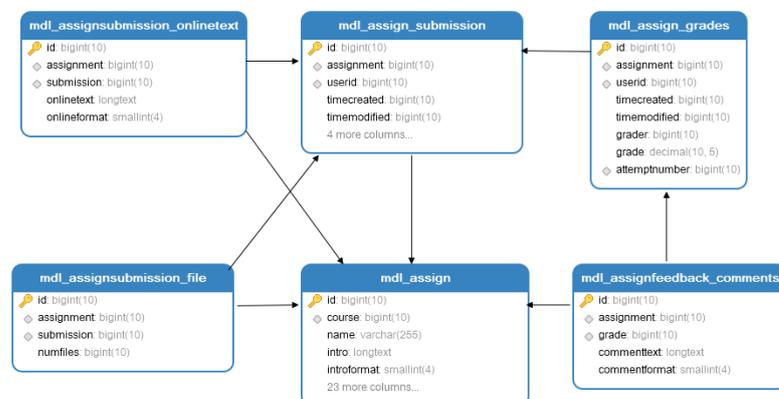


Figura 4.11: Relacionamentos que envolvem Tarefas.

A abstração dos relacionamentos apresentados na figura 4.11 segue os seguintes passos:

- Os administradores cadastram as tarefas que serão utilizadas no contexto do curso, todos os detalhes e informações sobre as tarefas são inseridos na tabela **assign**;
- O envio das tarefas para avaliação é registrado na tabela **assign_submission**;
- As notas atribuídas pelos tutores ao conteúdo enviado por cada aluno é armazenada na tabela **assign_grade** que também faz do sistema de notas do Moodle;
- O *feedback* do tutor para os alunos, em relação as tarefas, avaliadas são registrados na tabela **assignfeedback_coments**.

Notas

Todas as notas atribuídas às atividades pedagógicas, dos cursos ofertados no Moodle, são armazenadas em uma estrutura de tabelas que os desenvolvedores do AVA chamam de livro de notas (*gradebook* em inglês). A figura 4.12 exibe as principais tabelas que fazem parte do *gradebook*.

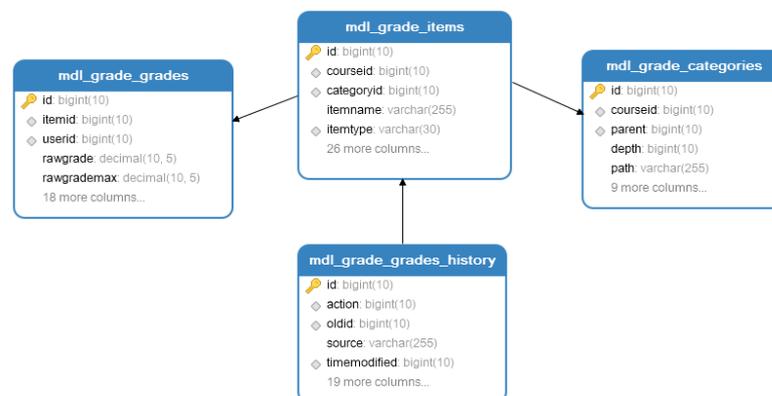


Figura 4.12: Relacionamentos do Gradebook do Moodle.

Cada item que compõe o quadro de avaliação do aluno é armazenado na tabela **grade_items**, nessa tabela o tutor cadastra todos itens que comporão parte da nota final do aluno e os pesos de cada item na avaliação final. Os itens cadastrados para avaliação podem ser organizados em categorias de itens na tabela **grades_categories**, ou seja, os itens podem ser agrupados quanto as suas afinidades e a categoria rotulada, por exemplo, “participação no fórum” que pode incluir itens de avaliação relacionados à utilização do fórum do curso. A relação entre cada item de avaliação e a nota que o aluno recebe para o item é registrado na tabela **grade_grades**. O histórico de notas do aluno e a informação se o aluno foi aprovado ou reprovado, em cada item de avaliação, ficam armazenadas na tabela **grade_grades_history**. No contexto da EJUG um aluno é considerado aprovado

se atinge a nota mínima para aprovação em cada item de avaliação, caso contrário é reprovado no curso.

Logstore

Para garantir a rastreabilidade das ações de cada usuário dentro do AVA foi desenvolvido os relacionamentos entre as tabelas de usuário, módulos dos cursos e *logstore*. Os registros armazenados pela tabela *logstore_standard_log* são utilizados para criação de relatórios, desenvolvidos pelo próprio Moodle, auditorias e identificação de anomalias no funcionamento do AVA. A figura 4.13 exibe os relacionamentos entre as tabelas que fazem parte do sistema de *log* do Moodle.

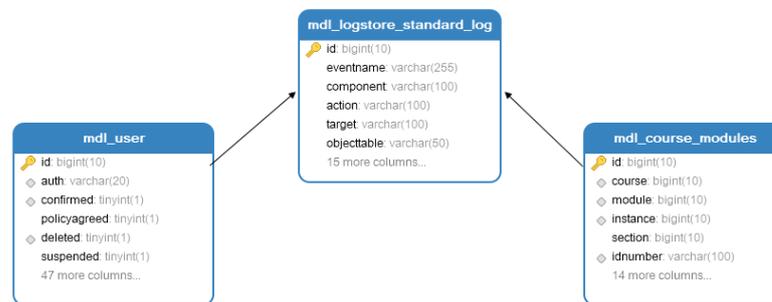


Figura 4.13: Relacionamentos do sistema de log.

A tabela *logstore_standard_log* registra cada atividade dos usuários dentro do ambiente virtual de aprendizagem, é armazenado o tipo de ação realizada, o usuário que provocou a ação e em qual módulo houve alteração. Para identificar o usuário que realizou a ação a tabela *user* é referenciada pelo sistema de *log*. A tabela *course_modules* também se relaciona com o *logstore_standard_log* para evidenciar em qual módulo do Moodle a ação foi realizada.

4.4 Análise Exploratória: Os Cursos do TJGO

Esta análise foi conduzida com o objetivo de gerar uma descrição detalhada dos cursos, corporativos, disponibilizados pelo tribunal de justiça de Goiás, TJGO. Foi realizado um levantamento dos cursos a fim de se identificar padrões e correlações entre variáveis como: número de tutores por curso, quantidade de mensagens trocadas via bate-papo, quantidade de *posts* em fóruns, participações em questionários, quantidade e tipos de recursos disponibilizados.

O processo de análise dos dados se iniciou com a seleção das entidades, a seleção se deu de acordo com os interesses da análise, da base de dados EJUG. Os dados foram pré-processados para eliminar dados faltantes e duplicados. Em seguida a normalização

foi feita para assegurar que anomalias sejam evitadas na associação entre os diferentes atributos. Técnicas de visualização de dados e análise estatística foram empregadas para apresentar os resultados obtidos. E finalmente foi realizada a interpretação dos resultados estatísticos e das informações contidas nos gráficos e tabelas.

4.4.1 Métodos e Ferramentas

Para facilitar a recuperação dos dados, a partir da base da EJUG, e permitir a replicabilidade das consultas feitas ao banco de dados, foi utilizado o conceito de visão de dados (*view*), uma *view* é considerada uma tabela virtual, criada a partir da união das entidades existentes no modelo de dados (seção 4.3.4). Uma *view* garante que atributos de entidades distintas sejam colocados em uma única tabela, permitindo a derivação de novos atributos a partir dos atributos das entidades relacionadas na *view* (ELMASRI; NAVATHE, 2011).

A execução da *view* gerou o conjunto de dados utilizado nesta análise exploratória dos cursos da EJUG. O conjunto de dados obtido contém 621 registros e cada registro possui 28 atributos. Cada registro, do conjunto de dados, representa um curso e seus respectivos atributos. Os dados que formam o conjunto de dados, em análise, foram coletados entre julho de 2009 e junho de 2018, período pré e pós-criação da EJUG.

Atributo	Tabela	Descrição	Atributo	Tabela	Descrição
course_id	course	Identificador do curso.	total_quiz_evaluated	quiz_grades	Qtd. quiz avaliado.
desc_course	course	Nome do curso.	survey_student_course	survey	Qtd. surveys.
start_date	course	Início do curso.	total_task	assign	Qtd. tarefas.
end_date	course	Fim do curso.	total_submitted_task	assign_submission	Qtd. tarefas enviadas.
workload	certificate	Carga horária do curso.	total_task_evaluated	assign_grades	Qtd. tarefa avaliada.
category	course_category	Categoria do curso.	total_chat	chat	Qtd. salas de chat.
total_tutor	role_assignments	Nº de tutores.	total_completion_course	course_completions	Qtd. alunos concluíram
total_student	role_assignments	Nº de alunos.	rate_approval	Derivado: total_student e total_completion_course	Taxa de aprovação
total_access	logstore	Total de acessos.	total_resource_available	url	Tot. Links.
total_forum	forum	Qtd. de Fóruns.	total_doc	file	Tot. arquivos (doc, odt, txt ect.)
total_post	forum_post	Qtd. de Posts.	total_image	file	Tot. imagens.
total_post_tutor	forum_post e role_assignments	Tot. Posts Tutor.	total_video	file	Tot. de vídeos
total_post_student	forum_post e role_assignments	Tot. Posts Alunos.	total_audio	file	Tot. de áudios
total_quiz	quiz	Qtd. de Quizzes	total_pdf	file	Tot. pdf.
total_submitted_quiz	quiz_attempts, quiz	Tot. de Quiz entregue.			

Tabela 4.6: Descrição dos atributos dos cursos da EJUG.

A tabela 4.6 traz uma descrição dos atributos extraídos, e de quais tabelas os dados foram coletados, do conjunto de dados e que serviram de entrada para as análises. Durante a análise estatística, novos atributos foram derivados a fim de gerar novas características implícitas dos cursos, a variável *rate_approval*, por exemplo, foi gerada a partir do atributo *total_aluno* e *total_completion_course*.

4.4.2 Os Cursos do TJGO

A escola judicial oferece cursos em três modalidades: presencial, semipresencial e à distância. Dentre os cursos analisados 63 foram ofertados na modalidade presencial, 14 mistos e 558 a distância. O número de alunos matriculados em cursos presenciais foi de 7749, em cursos mistos o total de alunos inscritos foi de 1364 e em cursos totalmente a distância o número de estudantes matriculados foi de 32870. A carga horária dos cursos ofertados variam entre 5 e 120 horas, sendo a carga horária média de 24 horas por curso. O tempo médio, em semanas, que os cursos permaneceram disponíveis aos alunos foi de 52 semanas. Os cursos analisados podem ser avaliativos ou certificativos. Em cursos avaliativos os alunos necessitam de obter média mínima para aprovação. Nos cursos certificativos os alunos são certificados quanto a realização do curso sem a necessidade de avaliação.

A tabela 4.7 apresenta uma listagem dos cursos mais comumente ofertados no âmbito da escola judicial. Analisando os dados da listagem verificamos que em média foram disponibilizadas oito turmas de cada curso analisado. A partir da análise dos nomes dos cursos fica evidenciado que a EJUG busca atingir seus objetivos fornecendo aos funcionários atualização contínua da literatura judiciária, a exemplo cursos como: “Alienação parental”, “Improbidade administrativa”, “Introdução ao direito constitucional” e “Introdução à lei da infância e adolescência”. Outro tema recorrente nos cursos diz respeito à eficiência e qualidade do serviço prestado à população, como se pode notar nos seguintes treinamentos: “Gerenciamento do tempo”, “Gerenciamento judicial”, “Gerência de projetos”, “Gerenciamento de pessoas”, “Excelência no serviço público” e “Gerência e governança de riscos”. Capacitação em softwares frequentemente utilizada pelos servidores também foram fornecidas, como se pode notar nos treinamentos: “Processo administrativo digital”, “Malote digital”, “LibreOffice calc/writer”. O desenvolvimento humano, social e ambiental dos funcionários também foi tema cursos como: “Água para todos”, “Ética uma questão de escolha” e “Introdução à gerência socioambiental”.

Curso	Qtd. Turma	Tot. Alunos	Curso	Qtd. Turma	Tot. Alunos
Administração do Tempo	9	1778	Gerenciamento Estratégico com uso do BSC	6	758
Administração Judiciária	12	2581	Governança e Gerência de Risco	5	194
Água para Todos	11	1649	Improbidade Administrativa	15	559
Alienação Parental	5	394	Introdução ao Direito Constitucional	11	1517
Aprender à Distância	29	4976	Lei N° 8.666/93, Pregão e Registro de Preço	5	193
Atualização em Gramática da Língua Portuguesa	6	689	LibreOffice Calc	9	733
BNMP	4	308	LibreOffice Writer	15	1503
Comunidade de Aprendizagem dos Educadores/Tutores TJGO	6	219	Malote Digital	14	420
Educação Financeira	8	677	Introdução ao Direito da Infância e Juventude	7	992
Ética, um Questão de Escolha	11	1108	Noções Básicas de Gestão/Fiscalização de Contratos Continuados	3	71
Excelência no Serviço Público	11	1418	O Juiz e o Serviço Extrajudicial	3	31
Formação de Tutores para Administração Pública	2	26	Processo Administrativo Digital	21	1409
Formação de Tutores no Contexto da Magistratura	5	103	Processo Penal Descomplicado	8	1128
Gerenciamento de Projetos	10	1301	Programa 12 S	3	102
Gestão de Processos	6	936	Reforma Ortográfica	10	515

Tabela 4.7: Cursos Comumente Ofertados pela EJUG.

A escola judicial oferece cursos específicos para servidores e magistrados que

desejam atuar como tutores. E eles devem participar dos cursos disponibilizados para formação em tutoria, além de comprovar suficiência técnica acerca do conteúdo do treinamento. Dentre os cursos analisados, 195 cursos foram destinados à qualificação de professores, e representam um total de 31% dos cursos disponibilizados. Foi constatado que em média há 1.7 tutores disponíveis para cada curso ofertado. Alguns dos cursos disponibilizados para o treinamento dos tutores podem ser identificados na tabela 4.7, os cursos mais ofertados foram: “Aprender a distância”, “Formação de Tutores para Administração Pública” e “Formação de Tutores no Contexto da Magistratura”.

Teste de Correlação de Pearson			
<i>cor</i>	<i>df</i>	<i>p-value</i>	<i>t</i>
-0.3637	162	1.686e-06	-4.97

Tabela 4.8: *Correlação: Total de Tutor e Taxa de Aprovação.*

A tabela 4.8 apresenta os resultados da execução do teste de correlação entre os atributos *total_tutor* e *rate_approval*. A associação entre variáveis é moderada, .3, e negativa, indicando que quanto mais professores estiverem envolvidos em curso menor será o índice de alunos que concluem os cursos. A significância mostra que para outras amostras esse resultado tende a se manter, dado que o resultado de significância, 1.686e-06, é menor que o valor de referência, .05. Svetlana (2014) também encontrou resultados similares ao correlacionar total de tutores, envolvidos no curso, e as notas obtidas em um questionário de avaliação dos tutores, pelos alunos. Segundo o autor isto se deve a falta de coordenação entre os professores, diferença de idades, estilos de comunicação, preferências e também devido ao excesso de materiais que cada tutor pode querer compartilhar.

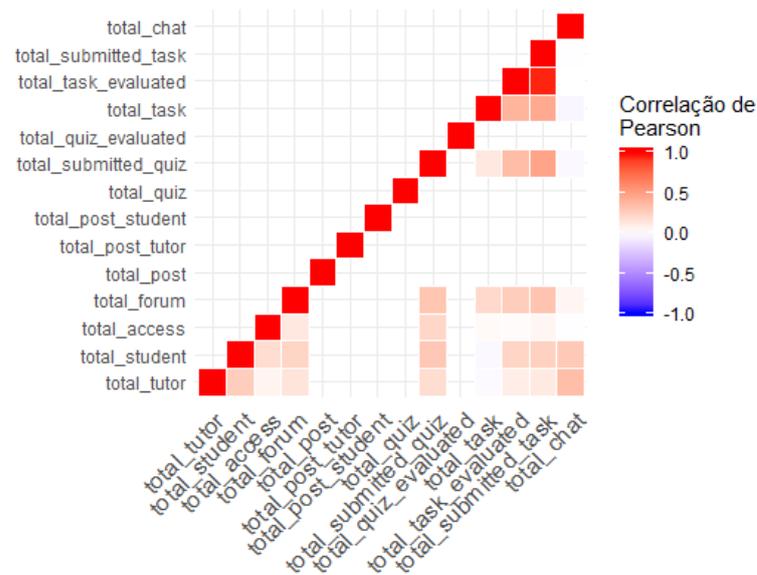


Figura 4.14: Análise Multivariada dos Cursos.

Na figura 4.14 é apresentada uma análise multivariada de alguns atributos do conjunto de dados. A variável *total_tutor* apresenta uma associação positiva com os atributos: *total_forum*, *total_quiz*, *total_quiz_evaluated*, *total_task*, *total_task_evaluated* e *total_chat*. O número de tutores por curso tem um efeito moderado sobre o total de fóruns criados nos cursos. O gráfico exibe que há uma correlação média entre os quizzes ofertados e avaliados e a quantidade de professores envolvidos em um determinado curso. Entretanto a quantidade de tarefas disponibilizadas e corrigidas tem uma relação fraca com a quantidade de professores disponíveis. Outra informação que se pode extrair em relação aos professores envolvidos em um determinado curso é a forte correlação com a utilização do recurso de *chat*, ou seja, os docentes tendem a utilizar mais a comunicação via *chat* do que outros meios como o fórum.

Ao se analisar a correlação entre as variáveis, verifica-se uma correlação positiva e forte entre a quantidade total de alunos e o número de tutores disponíveis no curso, e isto implica que quanto mais alunos houver mais tutores são designados ao curso. Pode-se justificar essa relação como uma forma de equilibrar as atividades de tutoria e evitar uma sobrecarga nas atividades dos docentes, que pode comprometer a qualidade dos cursos.

Pela análise visual percebe-se que os alunos promovem mais interação via fórum de que o tutores, visto que o efeito da correlação entre os alunos e a participação é mais forte do que a dos docentes. O total de alunos apresenta uma forte influência no total de quizzes e tarefas bem como na avaliação destes. Nota-se também que o recurso de bate papo é bastante utilizado pelos alunos.

A interação social entre aluno e professor é um dos elementos fundamentais do processo de aprendizagem, além de refletir um ambiente típico de sala de aula

(STUBBS, 1990). O aprendizado baseado na internet requer adaptações para que as interações ocorram de forma adequada. Uma das ferramentas mais utilizadas para a troca de informações, em treinamentos a distância, é o fórum (PICCIANO, 2002). Pela análise multivariada apresentada na matriz de correlações, verifica-se que há uma associação mediana entre os atributos total de acessos, *total_access*, ao curso e o número de *posts* em fóruns, *total_post*. Isso revela que a maior parte dos acessos aos cursos é para interação via fórum.

Os questionários e as tarefas são recursos da plataforma Moodle que, geralmente, são usados para avaliar os alunos quanto ao conhecimento adquirido no curso. Esses recursos alinham-se à metodologia de avaliação assistida, que consiste em um processo dinâmico de aferição de desempenho em que o aluno pode se auto avaliar de acordo com seu desempenho no *quiz* ou por meio dos *feedbacks* do professor na correção das tarefas (PRICE, 1997). Portanto, devido ao caráter avaliativo dos questionários, e das tarefas, percebe-se uma ligação positiva forte entre o número de acessos e participação em questionários e tarefas.

Um dos principais fatores que influenciam o desempenho dos alunos é a qualidade do ensino. Uma das formas de se avaliar a qualidade de um curso é através da aplicação de questionários de avaliação do curso. Os alunos de cursos à distância podem estar geograficamente distante de seus tutores e as oportunidades de contatos são limitadas, logo o questionário de avaliação é uma ferramenta valiosa para os alunos, pois podem propor melhorias e conseqüentemente melhorar a qualidade do ensino (RAMSDEN, 2006).

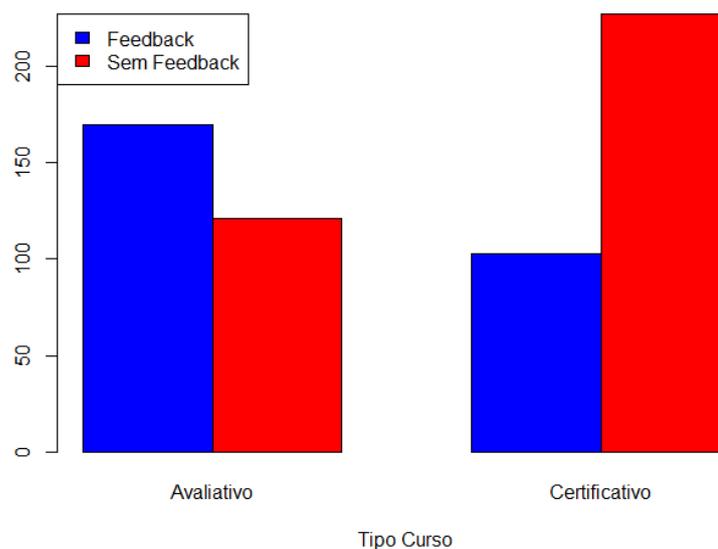


Figura 4.15: Quantidade de Questionários de Feedback por Tipo de Curso.

A figura 4.15 exibe um gráfico em barras que faz a relação entre os tipos de cursos, avaliativos e certificativos, e a oferta de *feedback* do curso para os estudantes. Dentre os cursos avaliativos 58%, 170 dos 291 cursos, disponibilizaram *surveys* de avaliação do curso aos alunos. Entre os cursos certificativos apenas 31%, 103 dos 330 cursos, deram aos alunos a oportunidade de contribuir para a melhoria contínua dos treinamentos. Entre as três modalidades de cursos online, mistos e tradicionais foram aplicadas 255, 10 e 8 questionários de *feedbacks*, respectivamente, aos alunos.

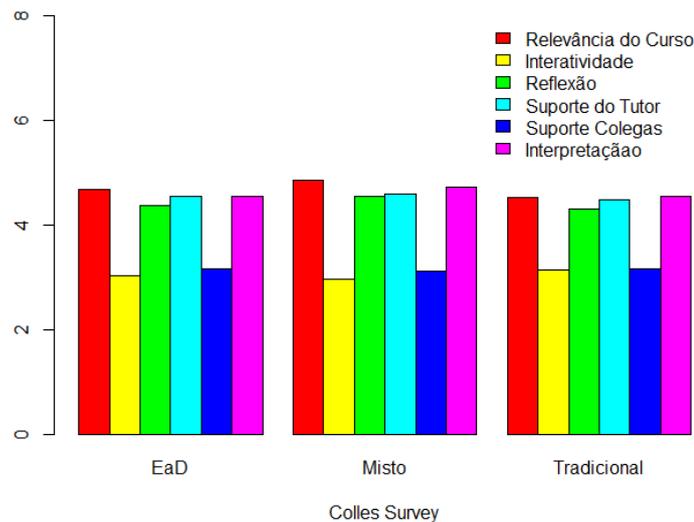


Figura 4.16: Notas Médias COLLES x Grupos de Questões.

O gráfico na figura 4.16 apresenta a média das notas atribuídas, pelos alunos, para cada grupo de questões do *survey* (seção 2.1.3) COLLES, para cada modalidade de ensino. Analisando o gráfico, pode-se notar que de modo geral as três modalidades de cursos seguem um mesmo padrão de notas para cada grupo de questão do *survey*. Verifica-se que alunos de cursos mistos deram maior nota em relação à relevância dos cursos para suas formações profissionais. Cursos tradicionais tiveram maior pontuação em relação à interatividade entre alunos e professores, em contrapartida, obtiveram a menor avaliação em relação ao estímulo de pensamento crítico. Cursos tradicionais, também, conseguiram notas ligeiramente superiores às demais modalidades no quesito suporte dos professores. As três modalidades de ensino tiveram avaliações semelhantes em relação ao suporte obtido de seus colegas. Alunos de cursos online atribuíram notas menores em relação à compreensão e interpretação das informações apresentadas pelos tutores.

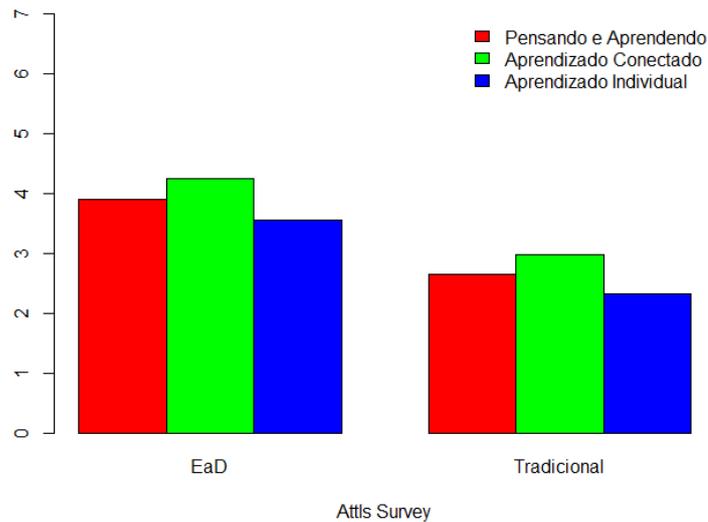


Figura 4.17: *Notas Médias ATTLS x Grupos de Questões.*

De acordo com a figura 4.17 pode-se notar que cursos mistos não utilizaram questionários ATTLS. Analisando o gráfico notamos que alunos de cursos online avaliaram as questões referentes ao encorajamento do pensamento crítico mais positivamente que os alunos de cursos tradicionais. Percebe-se também, segundo o gráfico, alunos de ambos os cursos tendem a apreciar mais o ensino online do que o ensino tradicional.

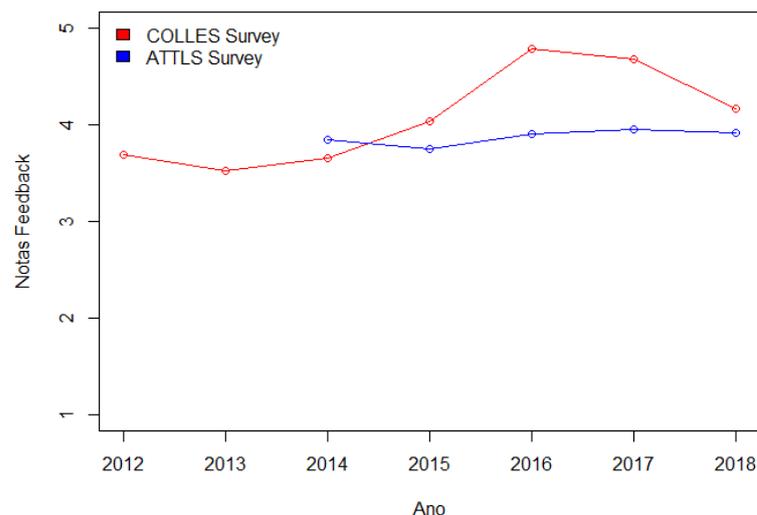


Figura 4.18: *Notas Médias x Ano.*

Para verificar o nível de satisfação dos alunos com os cursos ofertados pelo TJGO com o passar do tempo, realizou-se o cálculo da nota média anual para cada tipo de *survey*. O gráfico da figura 4.18 exhibe a média geral de cada tipo de *survey* por ano, pela análise

visual podemos verificar que a partir do ano 2015, criação da EJUG, há um aumento progressivo no *feedback* fornecido pelos alunos, o que pode ser explicado por uma melhor gestão dos treinamentos oferecidos. Nota-se que a média anual dos questionários que aferem as atitudes que levam o pensamento crítico no ensino, ATTLS, são inferiores às médias dos *surveys* que avaliam o ambiente de ensino online.

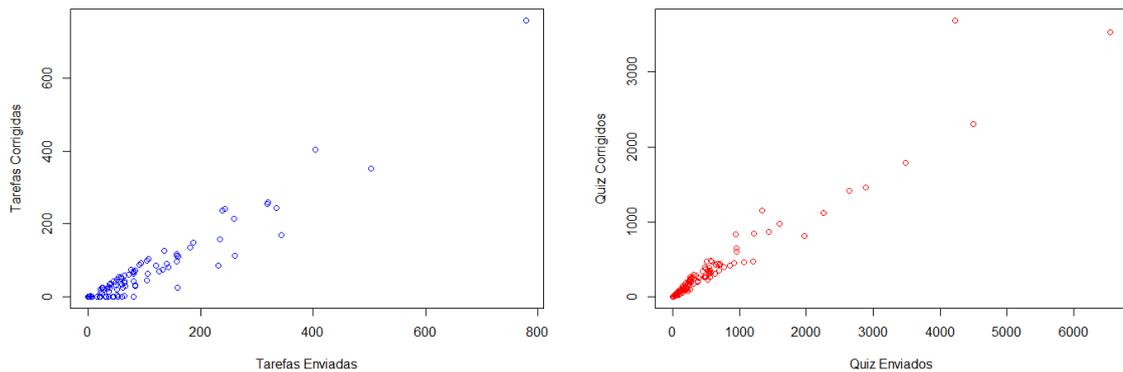


Figura 4.19: *Feedback dos Tutores em Tarefas e Quizzes.*

Assim como a avaliação dos alunos é importante para aferição da qualidade do ensino, os *feedbacks* do professor para com os alunos são fundamentais e demonstra parceria com os estudantes durante o processo de aprendizagem (DOSE, 2017). O *feedback* do professor envolvendo os alunos como parceiros é uma ótima estratégia para melhorar o processo de ensino (FLUCKIGER; TIXIER, 2010).

Os gráficos de dispersão da figura 4.19 mostram a distribuição da quantidade de tarefas e questionários submetidos para a avaliação e o total de avaliações, *feedback*, atribuídas pelos tutores. Observa-se que há um número significativo de tarefas e questionários sem avaliação. O fato de haver questionários sem avaliação pode se justificar devido a existências dos questionários de avaliação de curso que geralmente são feitos de forma anônima e não exigem correção. Entretanto a falta de correção de tarefas é preocupante, pois revela que não há um compromisso por parte de alguns tutores em fornecer *feedbacks* aos seus alunos.

Segundo Curtis (1999), cada aluno tem um estilo de aprendizagem próprio, alunos verbais gostam de áudios, estudantes visuais preferem imagens e vídeos, os sequenciais preferem documentos como "pdf" e *slideshow*, já os alunos considerados globais, possuem afinidade com todos os estilos. Com os recursos adequados a cada estilo de aprendizagem os alunos aprendem de forma mais objetiva e não ficam limitados ao estilo próprio do tutor.

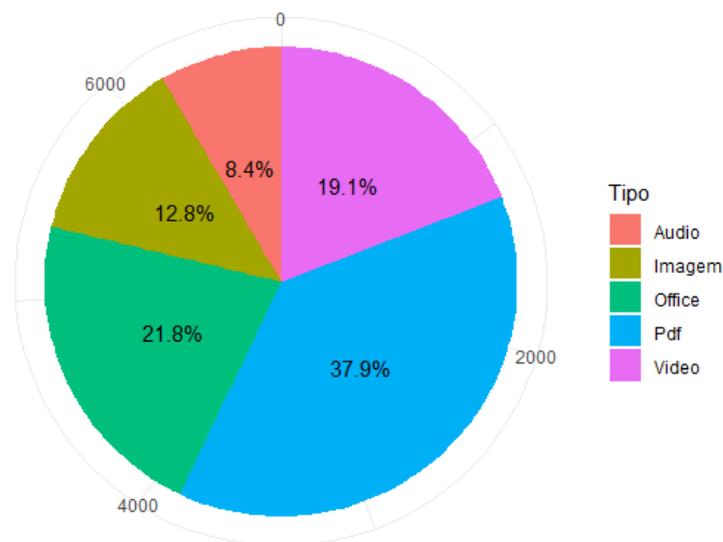


Figura 4.20: *Distribuição de Arquivos.*

A figura 4.20 exibe um gráfico setorizado, cada setor representa o percentual de cada tipo de arquivo utilizado pelos professores. Arquivos de imagens representam 12,8% do total de arquivos. Os recursos de vídeos representam 19% dos arquivos. Slides, "pdf" e documentos de texto representam quase 60% dos materiais disponibilizados, revelando que os cursos analisados privilegiam os alunos com estilo de aprendizagem sequencial. Os recursos sonoros, áudios, possuem pouca representatividade, apenas 15 arquivos, evidenciando a necessidade de mais adequação dos tutores aos alunos com estilo de aprendizagem verbal.

% Evasão por Curso

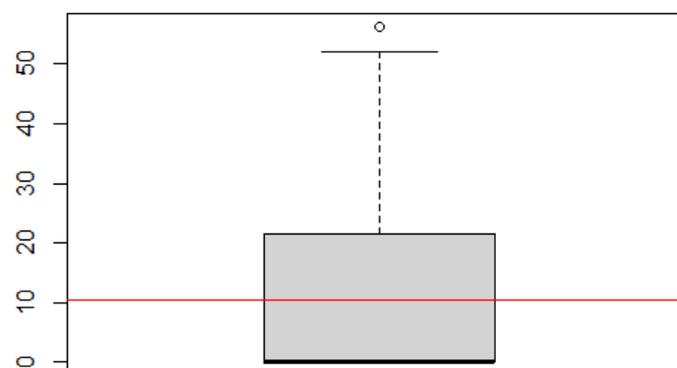


Figura 4.21: *Evasão por Curso.*

A linha vermelha no *boxplot* indica que taxa média de evasão, calculada a partir da proporção entre total de alunos matriculados e total de conclusões, nas ações de treinamento é de 11% . Cerca de 75% dos cursos tiveram níveis de abstenção acima de 21.5%. O curso “Governança, Gestão de Riscos e Controle” liderou o ranque de desistências tendo um percentual de 56% de evasão.

Pierrakeas (2004) realizou um estudo sobre as taxas de desistências em cursos a distância, o autor afirma que universidades europeias apresentam taxas evasão entre 20 e 30%, e reforça sua declaração, afirmando que na Ásia cursos a distância chegam a alcançar taxa de desistência de até 50%. Nesse cenário concluímos que os índices de desistências nos cursos do TJGO estão em um nível aceitável se comparado aos europeus e este fato pode ser justificado pelos incentivos financeiros concedidos servidores que se capacitam e o ambiente corporativo em que os cursos são ministrados.

4.4.3 Conclusões

A partir das análises estatísticas, realizadas sobre a base de dados do Moodle da EJUG, foi identificado que os cursos do tipo avaliativos, ou seja, cursos que exigem pontuação mínima em questionários e tarefas para que o aluno seja aprovado, foram os que ofereceram mais questionários de avaliação dos cursos aos alunos. Entretanto, cursos certificativos foram os cursos mais ofertados pela EJUG, porém, apenas 31% desses cursos deram oportunidade aos alunos de opinarem sobre os cursos. A análise dos *feedbacks* dos professores para os alunos mostrou que alguns tutores não se mostraram totalmente comprometidos em fornecer um retorno avaliativo aos seus alunos. Verificou-se que o total de professores envolvidos por curso teve uma correlação negativa com a taxa de aprovação nos cursos, com isto pode-se inferir que mais tutores não implica em mais qualidade de ensino. Através das observações feitas sobre os tipos de arquivos utilizados no contexto dos cursos da EJUG, verificou-se que há uma tendência a beneficiar alunos com estilo de aprendizagem sequencial, dado que a maior parcela dos arquivos disponibilizados pelos tutores é de recursos textuais. Constatou-se, também, que o índice de desistências dos alunos, 11%, é menor do que as taxas apresentadas em outras pesquisas, tal fato pode estar correlacionado com os incentivos de capacitação oferecidos pelo TJGO.

4.5 Análise Exploratória: Os Tutores da EJUG

A análise do perfil dos tutores de cursos online da EJUG será o objetivo desta análise exploratória. Especificamente será feito o levantamento dos principais aspectos

dos professores que podem estar ligados ao desempenho dos alunos dos cursos oferecidos pela EJUG.

As características de docência presentes no *framework* de características de tutoria (4.2) serão utilizadas nas análises com o intuito de elucidar se os tutores da EJUG estão alinhados com as definições andragógicas e se apresentam os principais atributos de docências ligados ao bom desempenho dos alunos, segundo a literatura acadêmica.

4.5.1 Métodos e Ferramentas

O conjunto de dados utilizados nesta análise foi obtido através de simultâneas consultas, armazenadas em uma visão do banco de dados, a base de dados da EJUG de forma que cada atributo do conjunto de dados foi correlacionado com um ou mais atributos de tutoria presente no *framework* de características de tutores.

A coleta de dados ocorreu entre outubro de 2015 e abril de 2019, a partir da criação da EJUG. Cada registro conjunto de dados é descritos por 47 atributos e representam um usuário e o respectivo curso em que participou como: Gestor, Tutor, Criador de Curso ou Editor de Curso. O conjunto de dados contém 857 registros. A tabela 4.9 traz uma descrição dos atributos extraídos do conjunto de dados e que serviram de entrada para às análises.

Atributo	Tabela	Descrição	Atributos	Tabela	Descrição
userid	user	Código do usuário	total_forum_create	forum	Total de discussões criadas em forums
username	user	Identificador do usuário	total_forum_posts	forum_posts	Total de posts em forums
role	role	Código da função exercida	total_assign_create	assign	Total de tarefas criadas
id_course	course	Código do curso	total_assign_as_grader	assign_grades	Total de tarefas corrigidas
desc_course	course	Descrição do curso	total_book_create	book	Total de livros disponibilizados
course_start	course	Data de início do curso	total_choice	book	Total de formulário criados
course_end	course	Data de término do curso	total_events	events	Total de notificações criadas
completion	course	Identificador de monitoramento de conclusão do curso	total_feedback_create	feedback	Total de feedbacks criados
total_student	role_assignments	Total de alunos no curso	total_feedback_completed	feedback_completed	Total de <i>feedback</i> recebidos
total_completion_course	course_completion	Total de alunos que concluíram	total_quiz_create	quiz	Total de quiz criado
tutor_name	role_assignments	Nome do tutor	quiz_avg_grade	quiz_grades	Média das notas do alunos em quizzes
first_time_tutor	role_assignments	Data início como tutor	total_survey_create	survey	Total de surveys disponibilizados
last_time_tutor	role_assignments	Data que atuou como tutor pela ultima vez	colles_avg	survey_answers	Nota média em surveys do tipo COLLES
gender	user	Gênero sexual	tutor_stimulate_think	survey_answers	Média atribuída ao tutor em relação pensamento crítico
degree	user	Graduações	tutor_encourage_participate	survey_answers	Média atribuída ao tutor em relação estímulo a participação
spec	user	Especializações	tutor_model_discourse	survey_answers	Média atribuída ao tutor em relação estilo de aula
master	user	Mestrado	tutor_model_critical_selfreflection	survey_answers	Média atribuída ao tutor em relação a autoreflexão
doctor	user	Doutorado	atlls_avg	survey_answers	Nota média em surveys do tipo ATLLS
total_chat_create	chat	Total de salas de bate papo criada	total_url_external_content	url	Total de links para materiais externos disponibilizados
total_chat_messages	chat_messages	Total de mensagens enviadas	total_wiki	wiki	Total de wikis criadas
total_imagem	file	Total de imagens utilizadas em curso	total_audio	file	Total de áudios utilizados em curso
total_video	file	Total de vídeos utilizados em curso	total_pdf	file	Total de arquivos pdf utilizados em curso
total_doc_office	file	Total de arquivos do pacote office utilizados em curso			

Tabela 4.9: Descrição dos atributos dos cursos da EJUG.

O critério definido para mensurar o desempenho dos alunos é composto das notas em tarefas, *quizzes*, *surveys* e a taxa de aprovação nos cursos. As notas dos alunos em tarefas, *surveys* e *quizzes* foram calculadas através da média das notas dos alunos da turma, e a média resultante foi normalizada para o intervalo de 0 a 10. A taxa de aprovação, porcentagem, de alunos foi definida a partir da quantidade de alunos matriculados e a quantidade de alunos que efetivamente completaram o curso.

4.5.2 Os Tutores da EJUG

O corpo docente da EJUG é composto de 246 tutores, sendo 78 do sexo masculino e 168 mulheres. O gráfico da figura 4.22 faz uma relação entre a proporção de cada gênero e a formação acadêmica dos tutores, esta análise foi realizada somente entre os docentes que informaram seu histórico acadêmico. Analisando o gráfico verifica-se que proporcionalmente as mulheres possuem mais títulos acadêmicos, nota-se, também, que apenas entre o gênero feminino há ocorrência de doutores.

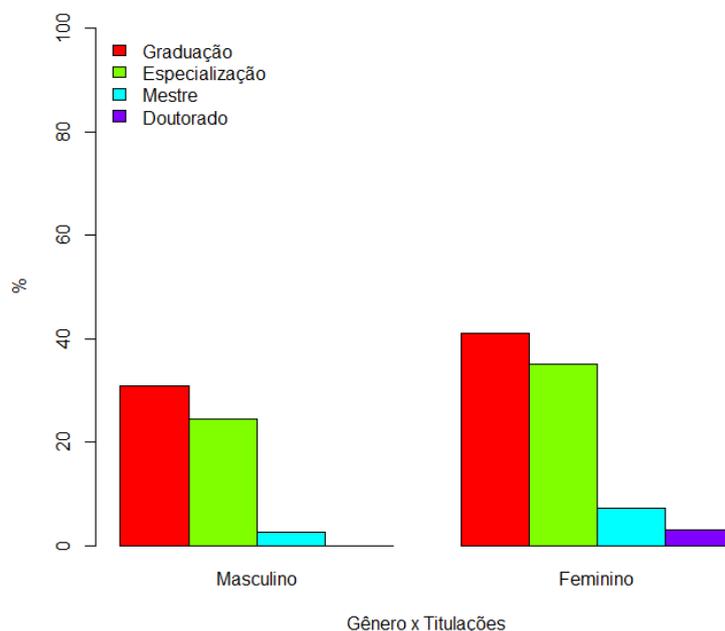


Figura 4.22: Gráfico que relaciona o sexo com a titulação do tutor.

A tabela 4.10 apresenta a listagem dos principais cursos de graduação (*degree*), especialização (*specialization*), mestrado (*master*) e doutorado (*doctor*) frequentados pelos tutores de cursos internos do TJGO. Por se tratar de órgão pertencente ao poder judiciário nota-se que 52% das graduações são de bacharelado em direito. Cerca de 11% dos tutores apresentaram mais de um certificado de graduação. A pós-graduação mais comum entre os docentes são as do tipo *latu sensu*, especializações, 41% do corpo docente possuem título de especialista. Os principais domínios de conhecimento são o direito, 53%, e a docência, 29%. Dentre o total de docentes especializados 32% possuem especialização em mais de uma área de formação. As formações *strictu sensu*, mestrado e doutorado, foram apresentando por 10% dos docentes, sendo a maior parte das formações em direito, 53%.

	Total Tutor	% Aprovação como Tutor	Cursos (Total)
Graduação	93	91%	Administração (6) História (3) Direito (49) Serviço Social (6) Pedagogia (6) Letras (5) Psicologia (17) Design Gráfico (1) Ciências da Computação (3) Musicoterapia (1) Educação Física (1) Economia (1) Marketing (1) Farmácia (1) Odontologia (1)
Especialização	78	85%	Educação (23) Direito Público (7) Direito Constitucional (7) Direito Ambiental (6) Processo Criminal (13) Processo Civil (11) Psicologia Jurídica (3)
Mestrado	14	87%	Educação (3) Direito (6) Ciências Ambientais (1) História (1) Odontologia (1) Ciência da Computação (1) Psicologia (1)
Doutorado	5	79%	Direito (4) Odontologia (1)

Tabela 4.10: Principais titulações dos professores da EJUG.

A verificação do desempenho dos alunos de acordo com o atributo *formação acadêmica*, do *framework*, dos professores foi analisada correlacionando a taxa de aprovação e as titulações dos tutores. De acordo com a tabela 4.10 pode-se ver que maior formação não implicou em melhor desempenho dos alunos. Cursos ministrados por professores com apenas graduação obtiveram maior emissão de certificado, taxa de aprovação 91%, do que aqueles em que os professores tinham maior qualificação acadêmica. Çakır e Bichelmeier (2016), Chu e Loyalka (2015), Canales e Maldonado (2018), Santín e Sicilia (2018), Clotfelter e Ladd (2010) analisaram os dados educacionais de alunos e professores em cursos regulares de nível médio, técnico e superior, coletadas pelos ministérios da educação dos estados unidos, china, chile e Espanha, respectivamente, e encontram resultados semelhantes. Segundo os autores, a formação acadêmica dos professores não teve impacto nas conquistas escolares dos discentes.

A análise do atributo de tutoria *capacitação*, presente no *framework*, foi analisada de acordo com as diretrizes da própria escola judicial. A participação dos tutores em cursos de capacitação sempre que solicitado é umas das obrigações presente no regimento

interno da EJUG (TJGO, 2015). Ainda de acordo com a legislação da EJUG, cada tutor deve participar de treinamentos de capacitação, ao menos, uma vez por ano. Dentro do período analisado, a média de cursos para capacitação de tutores ofertados pela EJUG foi de 1,25 cursos por ano. Em média os tutores da EJUG participam de 1,14 cursos por ano.

A experiência como docente é uma das características dos professores que já foi objeto de estudos de outras pesquisas. Por exemplo, Çakır e Bichelmeyer (2016) observaram que alunos de professores com mais de 10 anos de experiência em docência obtiveram melhores notas nas atividades escolares. Clotfelter e Ladd (2010) também avaliaram o desempenho dos alunos em relação ao tempo de docência e concluiu que professores experientes tendem a manter o bom desempenho dos alunos ao longo dos anos. O tempo médio dos docentes como tutores da EJUG é de 2 anos, sendo que os mais experientes somam 7 anos de docência pelo TJGO.

Teste de Correlação de Pearson			
cor	df	p-value	t
-0.169	59	0.1903	-1.325

Tabela 4.11: *Correlação entre a quantidade de cursos ministrados e Taxa de Conclusão.*

A tabela 4.11 apresenta os resultados da execução do teste de correlação entre o atributo de docência *experiência*, calculada a partir da quantidade de cursos ofertados pelo docente, e o índice de aprovação dos alunos. A correlação sugere que a relação entre as variáveis é muito fraca, .1, em outras palavras, anos experiência como tutor não implicou, diretamente, em maior capacidade, do docente, de manter ou aumentar o interesse dos alunos pelos cursos. A significância mostra que para outras amostras esse resultado tende a se manter, dado que o resultado de significância, 0.19, é menor que o valor de referência, .05. Shukla, Nirban e Dosaya (2018), Stes e Maeyer (2012), Azigwe e Kyriakides (2016) valeram-se da estatística descritiva para analisar a relação entre a experiência dos professores em sala de aula e o desempenho escolar de seus alunos, os autores citados, também, encontraram ausência de relação entre os atributos.

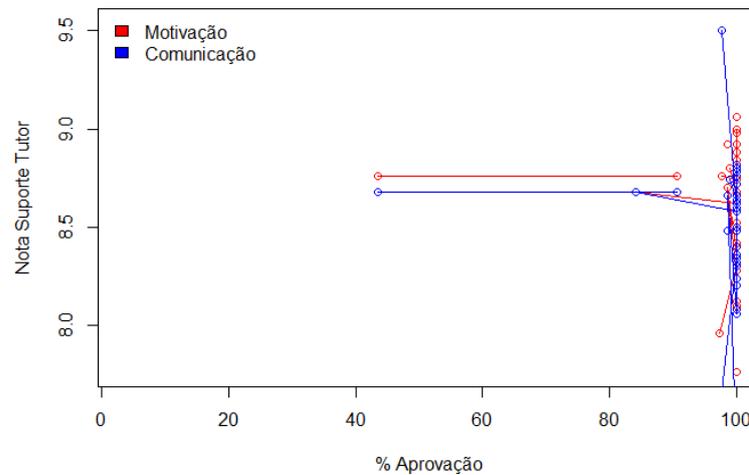


Figura 4.23: *Relação entre Motivação e Comunicação e a Taxa de aprovação.*

A motivação e a forma de comunicação utilizada pelos professores têm sido alvo de pesquisas no meio acadêmico. [You e Dang \(2016\)](#) constataram que a motivação do professor aumentou a determinação dos alunos em atingir seus objetivos e melhorou o desempenho dos alunos nas avaliações. Através da aplicação de questionários e análise de notas dos alunos [Ngang e Yie \(2015\)](#) verificaram que a comunicação, dentro e fora de sala de aula, entre professor e aluno gera impactos positivos no desempenho escolar dos alunos.

Para avaliar os atributos do *framework* de características *motivação* e *comunicação*, entre professores e alunos da EJUG, foi utilizado as notas atribuídas pelos alunos às questões, do *survey* COLLES, referentes ao suporte dado pelo tutor. Para a *motivação* será utilizado à média das notas dadas à pergunta: *O tutor encoraja a participação?*. A *comunicação* será avaliada a partir das médias das notas recebidas para a questão: *O tutor tem um bom modelo de discurso?*. A figura 4.23 exibe a distribuição das médias das notas outorgadas aos professores pelos alunos, em relação a motivação e a qualidade da comunicação entre professor-aluno. A interpretação do gráfico evidencia que as melhores avaliações para ambas as características, médias entre 8 e 9, se concentram nos cursos que obtiveram elevados índices de aprovações, revelando que o encorajamento dos alunos e a boa comunicação no ambiente educacional tem um impacto positivo no desempenho dos alunos da EJUG.

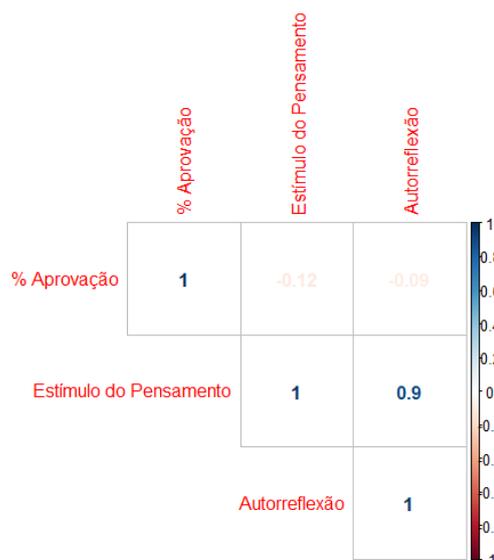


Figura 4.24: Estímulo do pensamento e autorreflexão correlacionado com a taxa de aprovação.

A capacidade do professor de orientar, estimular o pensamento crítico e autorreflexão dos alunos é conhecidamente uma característica de liderança dos docentes. No estudo feito por [Passini e Molinari \(2015\)](#) as notas recebidas no questionário QTI, *Questionnaire on Teacher Interaction*, foram correlacionadas com as notas finais dos alunos. A correlação evidenciou que atributos dos docentes ligados à liderança estão positivamente atrelados ao bom desempenho dos alunos.

No contexto desta pesquisa os aspectos ligados ao atributo de docência *liderança*, dos tutores, foram avaliados de acordo com as notas dadas pelos alunos no questionário COLLES para as seguintes questões: *O tutor estimula o pensamento?* e *O tutor estimula a autorreflexão crítica?*. A matriz de correlação na figura 4.24, mostra que existe uma forte correlação entre as notas recebidas para as questões referente, ao estímulo do pensamento e autorreflexão, fato que nos habilita a analisar tais notas, juntas, em relação a taxa de aprovação. A correlação de Pearson revela que as médias das notas, para o estímulo do tutor ao pensamento crítico e a autorreflexão dos alunos, possuem correlações desprezíveis em relação à taxa de aprovação, mostrando que tais características de liderança não impactaram no desempenho dos alunos da EJUG.

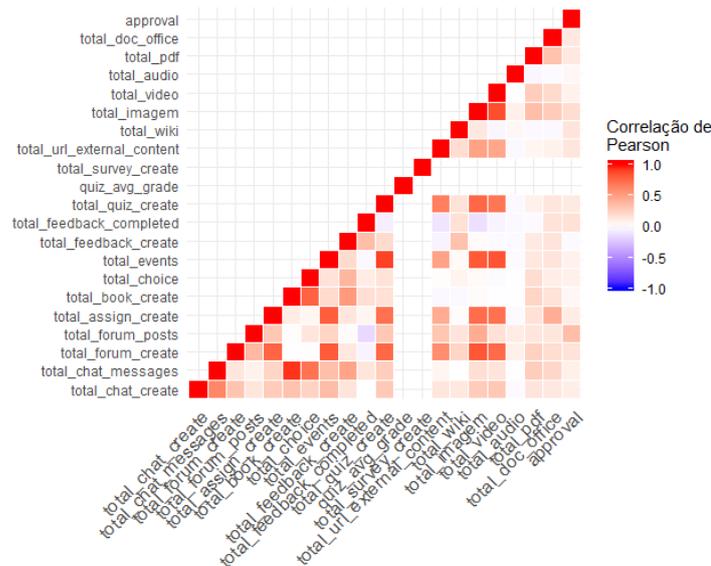


Figura 4.25: Análise multivariada das atividades realizada pelos docentes correlacionadas com a taxa de aprovação.

O comportamento ativo ou passivo do tutor dentro do ambiente do curso e os tipos de recursos utilizados para transmitir a informação, caracterizam o estilo de ensino dos docentes. [Cordero e Gil-Izquierdo \(2018\)](#) analisou o comportamento passivo dos professores, que atuam apenas como orientadores e os alunos como pesquisadores, e constatou que o efeito deste comportamento foi negativo no desempenho dos alunos no teste PISA (*Programme for International Student Assessment*). O gráfico de calor da figura 4.25 foi gerado utilizando correlação de Pearson e correlaciona as atividades ligadas ao atributo *estilo de ensino* do tutor com a taxa de aprovação dos alunos. Percebe-se que atividades como criação de *chats*, discussões em fóruns, *posts* em fóruns, tarefas, *quizzes*, disponibilização de links para conteúdo e criação de *wikis* apresentam correlação moderada com a taxa de aprovação, variável *approval*, portanto, o estilo de ensino ativo dos tutores tende a elevar o índice de conclusão dos cursos ofertados pela EJUG.

Assim como cada professor tem uma metodologia de ensino, cada aluno também possui seu estilo próprio de aprendizagem. Na literatura existem classificações para a maneira como cada aluno absorve mais o conhecimento. Alunos verbais gostam de áudios, estudantes visuais preferem imagens e vídeos, os sequenciais preferem documentos como *pdf* e *slideshow*, há também alunos considerados globais, estes possuem afinidades com todos os tipos de conteúdo. [Choi e Yang \(2011\)](#) avaliaram o desempenho dos alunos em relação ao modo como o conteúdo do curso foi apresentando aos discentes. Um grupo de alunos recebeu a instrução baseada em vídeos a outra parte dos alunos recebeu todas as informações em forma de textos. Alunos que receberam instrução em formato de vídeos tiveram médias significativamente superiores aos alunos que receberam o conteúdo em formato textual. Em questionários de satisfação com o conteúdo do curso, alunos do

grupo de vídeos mostraram-se mais satisfeitos.

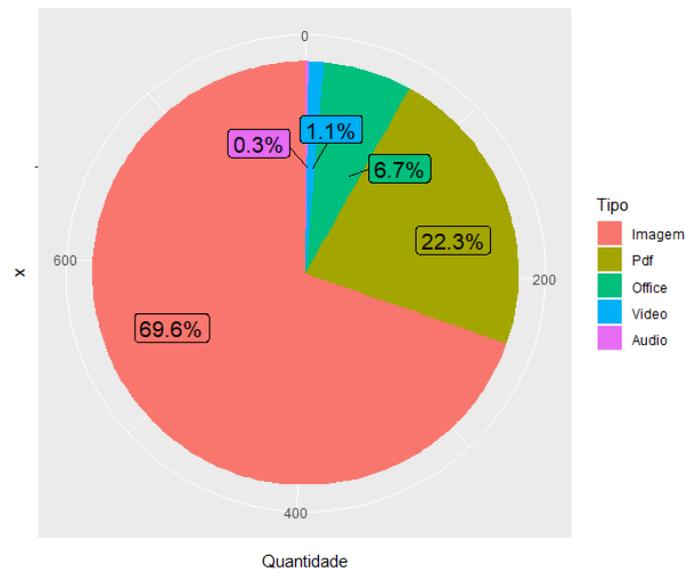


Figura 4.26: *Proporção dos tipos de arquivos utilizados por tutores.*

Em relação aos recursos didáticos utilizados nos cursos oferecidos no TJGO, a figura 4.26 exibe a proporção dos tipos de arquivos mais utilizados nos cursos. Recursos visuais do tipo imagens e vídeos são os mais utilizados nos módulos dos cursos, representando aproximadamente 70% dos arquivos utilizados em fóruns, *quizzes*, formulários e tarefas, em média cada tutor utiliza 3 arquivos do tipo imagem por curso. Recursos textuais *pdfs* e documentos de texto (*office*), representam 29% dos recursos didáticos, sendo utilizados em média pelo menos 1 arquivo textual por curso. Os recursos de áudio são os menos utilizados sendo responsáveis apenas por 0.3% dos arquivos utilizados por docentes da EJUG. Partindo desta análise dos recursos didáticos utilizados no âmbito da EJUG, verifica-se que os alunos sequenciais e visuais são mais beneficiados do que os alunos verbais, que pode induzir o pensamento de que uma parcela dos alunos ficou limitada aos estilos de ensino dos tutores e não consegue aprender de forma objetiva.

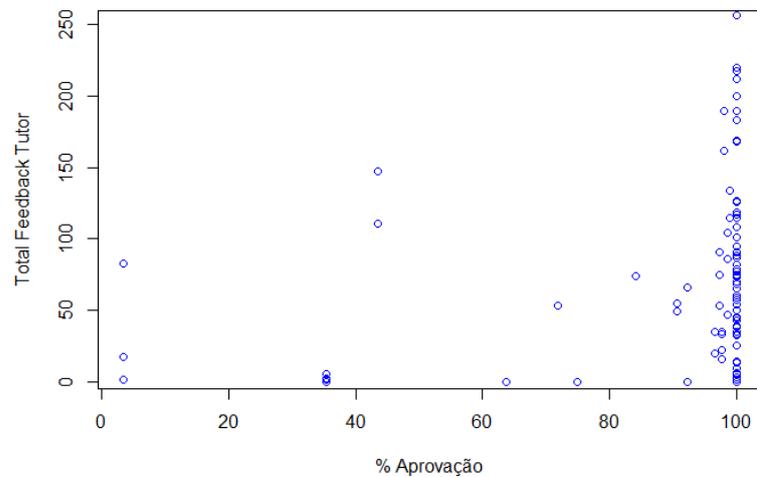


Figura 4.27: Relação entre Total de Feedback e Taxa de Conclusão.

Como avaliado anteriormente, características como qualidade da comunicação e motivação do tutor contribuem significativamente no comportamento escolar dos alunos e denotam parceria entre as partes. Os *feedbacks* do tutor para os alunos são fundamentais no processo de ensino, pois revela o real desempenho dos alunos no curso e mostra interatividade entre docentes e discentes (DOSE, 2017). A figura 4.27 faz uma relação entre o total de *feedback*, atributo desejado em tutores e presente no *framework*, fornecido pelos docentes e a taxa de aprovação. O total de *feedbacks* foi obtido a partir da soma das variáveis: total de mensagens em *chats*, total *posts* em fóruns, total de tarefas corrigidas e totais mensagens de notificações enviadas no curso. O gráfico de dispersão exhibe uma maior concentração dos cursos na taxa de aprovação 100% e entre aproximadamente 10 e 150 ações de *feedbacks* do tutor, o que induz a conclusão que quanto mais retorno o professor dá aos alunos nas atividades do curso, maior o interesses dos alunos nos cursos da EJUG.

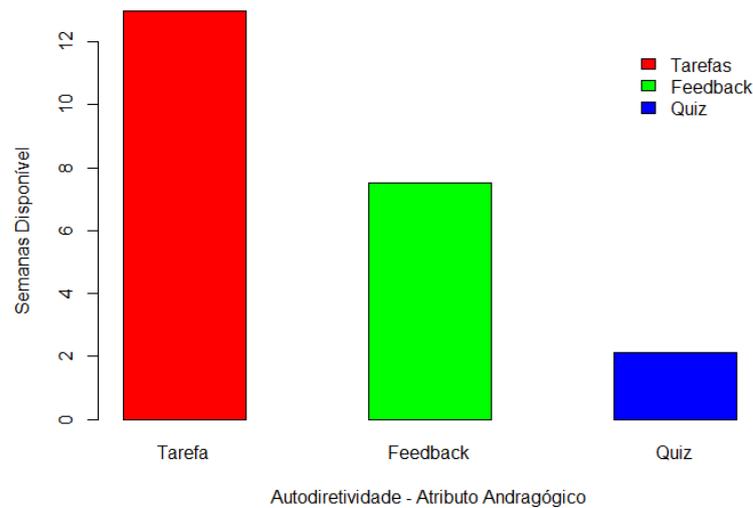


Figura 4.28: Auto-diretividade de acordo com tempo disponível para realização das atividades.

O gráfico em barras da figura 4.28 apresenta a análise de uma das características mais desejadas no processo de ensino de alunos adultos, a auto-diretividade. O atributo de tutoria *gerenciamento do tempo* está associado a auto-diretividade que os alunos independentes necessitam. A *auto-diretividade* nesse trabalho foi analisada do ponto de vista da disponibilidade de tempo que os alunos têm para cumprir com as atividades do curso. Este atributo é considerado um dos mais valiosos para a modalidade de ensino a distância, pois está relacionado à flexibilidade de horário. A disponibilização de atividades com prazos que se adéquem às necessidades dos alunos, que geralmente tem outras atividades profissionais no caso do TJGO, é fundamental para garantir a qualidade do ensino.

Foram calculados os tempos médios de disponibilidade, em semanas, das principais atividades utilizadas nos cursos da EJUG. Observou-se que as tarefas ficam disponíveis para envio por 13 semanas em média, os questionários de *feedbacks* são possíveis de serem realizados por 7.5 semanas em média e os *quizzes* ficam disponíveis normalmente por 1 mês. A definição do tempo para entrega das atividades é discricionária aos professores, entretanto, segundo Ashby (2004) em seu monitoramento da retenção de alunos na universidade aberta do reino unido, uma das maneiras de aumentar a taxa de conclusão dos alunos é a flexibilização das datas limites das atividades.

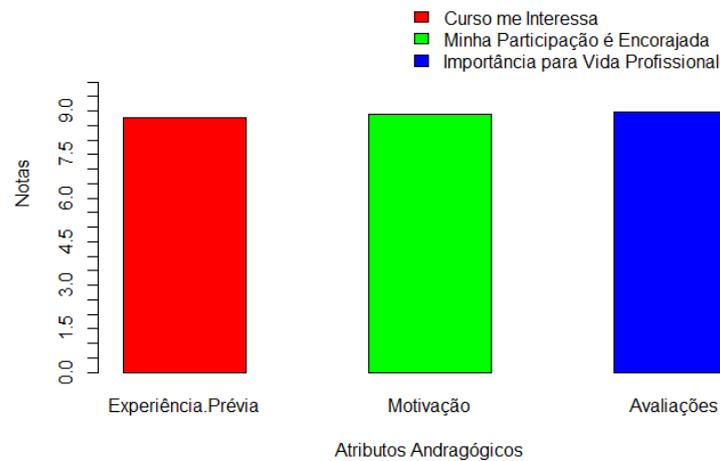


Figura 4.29: Avaliação dos atributos andragógicos: experiência, motivação e avaliações.

Para avaliar os atributos *experiência prévia*, *motivação* e *avaliações*, desejáveis na educação de adultos, foram coletadas as notas dos alunos no questionário de avaliação do ambiente de ensino online, COLLES, referentes às qualidades supracitadas. O estilo de ensino do tutor, segundo a andragogia, deve explorar a *experiência prévia*, dos alunos, de forma a atrair a atenção dos alunos. Para aferir a valorizam dos conhecimentos anteriores dos alunos foi calculada a média das notas dos alunos à seguinte pergunta: *O conteúdo do curso me interessa ?*. A *motivação dos alunos* está ligada à motivação e credibilidade do professor na perspectiva dos discentes, logo, a motivação foi mensurada a partir da seguinte questão: *O tutor encoraja minha participação ?*. Os conteúdos das atividades e *avaliações*, conforme disposto pela andragogia, devem privilegiar questões que reflitam nas atividades profissionais dos alunos e para avaliar esse critério coletamos e calculamos a média das notas para a questão: *O que estou aprendendo é importante para minhas atividades profissionais?*.

O gráfico 4.29 apresenta a média das notas dos alunos para cada atributo andragógico analisado e presente no *framework* de atributos de tutoria. A partir da média das notas evidentes no gráfico 4.29 conclui-se que o nível de satisfação dos alunos com tais características pode ser considerado bom, médias entre 8 e 8.5, sugerindo que os tutores da EJUG apresentam um certo alinhamento com as melhores práticas do ensino de alunos adultos.

4.5.3 Conclusões

A partir de análises estatísticas como correlação de Pearson, gráficos de dispersão e medidas de centralidade foram realizados o levantamento das principais caracterís-

ticas dos professores da EJUG.

Com a análise de gênero se identificou que a maior parte dos tutores é do sexo feminino e possuem melhor qualificação do que docentes do sexo masculino. Foi identificado que a maioria dos títulos de graduação apresentados são na área do direito e que 41% dos professores possuem pós-graduações *latu sensu*, sendo que apenas 10% do corpo docente possui titulação *strictu sensu*.

A análise de correlação entre a taxa de aprovação e os anos de *experiência de docência* dos tutores evidenciou que há uma relação fraca entre as variáveis, entretanto, a correlação foi negativa sugerindo que quanto mais experiente menor a taxa de aprovação.

Através das notas atribuídas pelos alunos nos *surveys* de avaliação dos cursos verificou-se que a *motivação* e qualidade da *comunicação* transmitida pelos tutores teve impacto positivo no desempenho escolar dos alunos da EJUG.

Questões ligadas à capacidade de orientação do tutor, *liderança*, não tiveram impacto na correlação com a taxa de aprovação.

A análise multivariada entre as atividades realizadas pelos tutores, *estilo de ensino* ativo, e os tipos de recursos didáticos utilizados nos cursos revelou ter uma associação moderada e positiva com o índice de conclusão dos treinamentos.

Verificou-se pela distribuição de *feedbacks* aos alunos, que curso em que os professores forneceram mais *feedbacks* aos alunos tiveram níveis de aprovação elevados.

Finalmente foi avaliado o alinhamento das práticas dos professores da EJUG com as condutas desejáveis pela andragogia, isto é, analisou-se a auto-diretividade dos alunos, o estilo de ensino, motivação e avaliações dos docentes sob a óptica andragógica. A *auto-diretividade* foi analisada observando a flexibilidade que os alunos tiveram para cumprir com as atividades escolares. O *estilo de ensino*, *motivação* e *avaliações* foram observados de acordo com as avaliações dos alunos para questões referentes aos respectivos assuntos no questionário COLLES e verificou-se que segundo as avaliações dos alunos os tutores seguem as diretrizes da andragogia.

4.6 A Extensão do Moodle Predicta

O MP foi originalmente desenvolvido para coletar, analisar e prever o desempenho dos alunos dentro do AVA Moodle (seção 2.4). O comportamento dos tutores é totalmente desconsiderado nas análises e na predição de comportamento dos alunos feitas pelo MP, em sua primeira versão. Portanto, um dos objetivos (seção 1.3) desta pesquisa é incluir dados comportamentais dos tutores nas análises e na predição realizada pelo MP. Para tanto se estendeu as funcionalidades da ferramenta MP de formar a incluir preditores relacionados aos professores no *software* Moodle Predicta.

O *framework* de características dos tutores (4.2) foi utilizado como base para extração dos dados relacionados as ações dos tutores dentro do AVA. A extensão do MP incluiu dados dos educadores, nos módulos de visualização e predição, para identificar alunos em risco de reprovação e para acompanhar a evolução dos tutores, na utilização das práticas andragógicas. Desta forma, a extensão do MP objetiva auxiliar gestores educacionais a tomarem ações preventivas a fim de melhorar o desempenho escolar dos alunos e garantir a qualidade do ensino.

A primeira parte da extensão do MP envolveu a troca de tecnologia de gerenciador de banco de dados. Originalmente o MP foi desenvolvido utilizando base de dados MySQL, porém, as versões mais recentes do Moodle estão sendo disponibilizadas utilizando banco de dados PostgreSQL. Todas as conexões ao banco de dados e consultas foram reescritas, para adequação da sintaxe de comunicação com o banco de dados PostgreSQL.

Na base compartilhada entre os módulos de visualização e predição, foram acrescentadas consultas para obtenção de dados referentes aos *Surveys* e *Feedbacks*, essas informações são cruciais para se acompanhar o nível de contentamento dos alunos com os cursos e seus respectivos tutores.

O módulo de visualização foi estendido com o objetivo de possibilitar o rastreamento das ações dos professores dentro do Moodle, e foram inclusos relatórios sobre ações em: fóruns, salas de bate papos, tarefas, questionários e avaliações.

Finalmente, foi acrescido ao módulo de predição dados comportamentais dos professores, possibilitando que novos testes de predição fossem executados, objetivando-se constatar se as atitudes dos docentes interferem no desempenho dos alunos. Foi acrescentada, também, ao módulo de predição a classificação dos tutores de forma a identificar se os tutores seguem as práticas andragógicas.

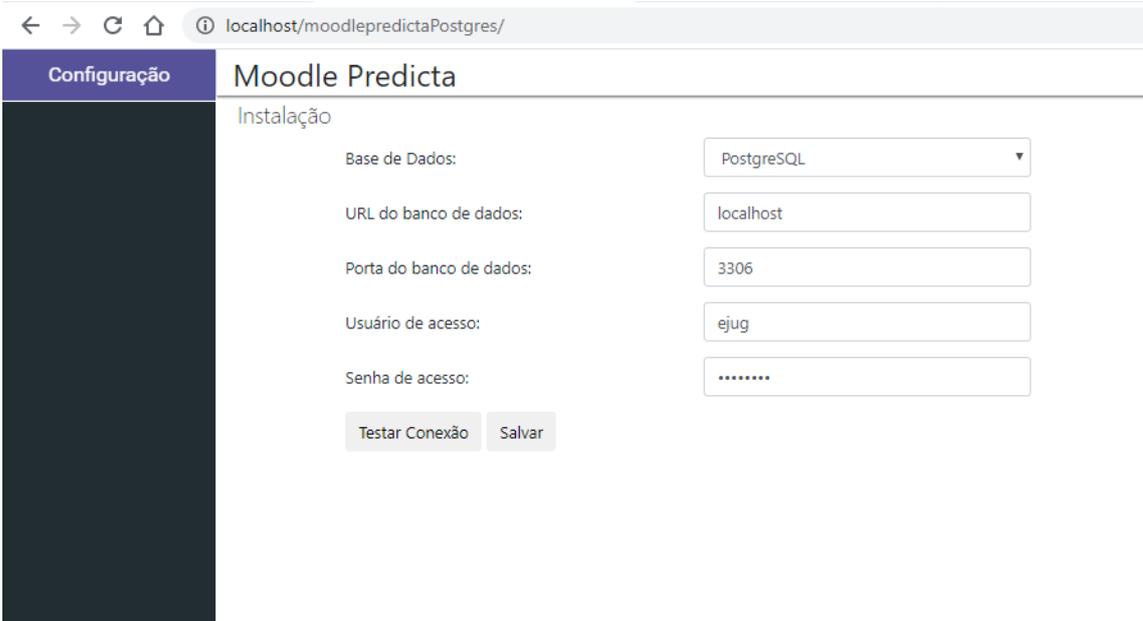
Para se concentrar nos objetivos desta pesquisa todas as análises foram feitas sobre a extensão do MP, dito isso tanto no módulo de visualização como no de predição são apresentadas apenas as alterações quem envolvem os dados dos tutores, para análise completa do MP original recomenda-se o trabalho de [Felix \(2017\)](#).

4.6.1 Configuração do MP

A extensão MP é uma aplicação web desenvolvida seguindo a arquitetura cliente-servidor, no qual uma série de consultas é feita ao servidor de aplicação, e de dados, e os resultados são devolvidos à aplicação *web* que processa e formatam as informações, em seguida os dados são exibidos no navegador (cliente).

A aplicação foi desenvolvida utilizando a linguagem de programação PHP, logo se deve utilizar um servidor de aplicação com suporte ao interpretador PHP versão 5 ou

superior. No escopo deste trabalho foi utilizado o servidor de aplicações “Apache” e PHP versão 7.



The image shows a web browser window with the address bar displaying 'localhost/moodlepredictaPostgres/'. The page title is 'Moodle Predicta' and the section is 'Configuração' (Configuration). Under the 'Instalação' (Installation) section, there are several form fields for database configuration:

- Base de Dados: PostgreSQL (selected in a dropdown menu)
- URL do banco de dados: localhost
- Porta do banco de dados: 3306
- Usuário de acesso: ejug
- Senha de acesso: [masked with dots]

At the bottom of the form, there are two buttons: 'Testar Conexão' (Test Connection) and 'Salvar' (Save).

Figura 4.30: *Configuração MP.*

Os servidores de dados suportados são: MySQL e PostgreSQL. O servidor de dados deve conter uma estrutura de dados do Moodle versão 3.6 ou superior. A figura 4.30 exibe a tela de configuração de acesso ao banco de dados que é utilizado pelo MP.

4.7 O Módulo de Visualização

O módulo de visualização é responsável por apresentar relatórios estatísticos e gráficos, que permitem aos administradores de cursos acompanharem o progresso dos alunos e dos tutores, a partir da extensão do MP. A ferramenta pode produzir relatórios para cada um dos principais módulos do Moodle, que são: fóruns, questionários, tarefas, chats, Logs e Tempo.

4.7.1 Visualização de dados do Tutor

Neste submódulo é possível acompanhar as atividades e participações dos professores em: fóruns, quizzes, tarefas, chats, surveys e feedbacks. As opções de análises disponibilizadas foram selecionadas de acordo com a correlação com os atributos de docência presentes no *framework* de características dos tutores e também de acordo com o que é armazenado na base do Moodle.



Figura 4.31: Relatórios de atividade no Fórum.

O relatório de atividades em Fóruns (figura 4.31) exhibe todos os tópicos de discussões criados pelo tutor, assim como a quantidade de *posts*, leituras, proporção de alunos que acessaram o tópico, quantidade de palavras digitadas pelo docente, dentre outras informações. A participação do professor em fóruns se relaciona com os atributos: estilo de ensino, comunicação e *feedback*. De acordo com a Tabela 4.2, tais atributos podem impactar o desempenho dos alunos, o que justifica a importância da análise comportamental dos tutores em ambientes de interação social, como os fóruns.

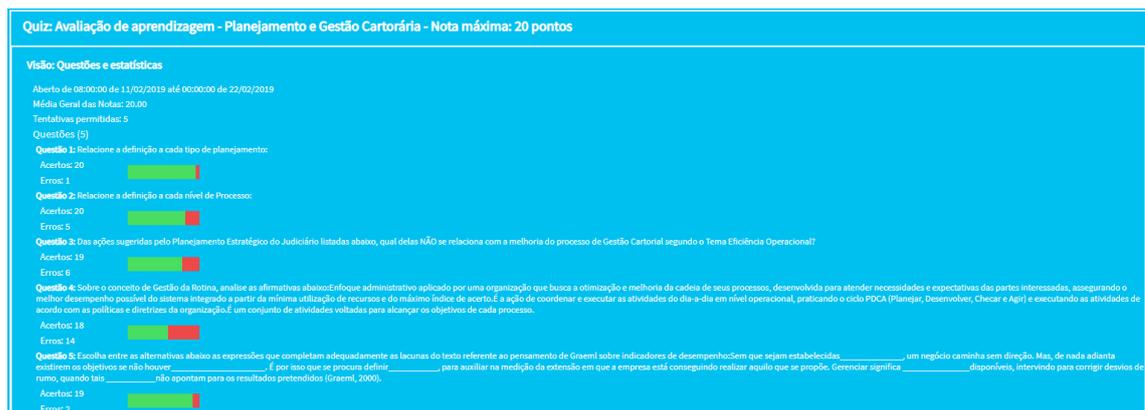


Figura 4.32: Relatórios de Quizzes.

Questionários, *quizzes*, e Tarefas são modalidades de avaliações comuns em cursos EaD. Estas atividades são importantes ferramentas de verificação da aprendizagem dos alunos e, também, de *feedbacks* para o tutor, pois a nota dos alunos revela se o processo de ensino está ocorrendo de maneira satisfatória. Outra função importante das avaliações é verificar a possibilidade de desistência do aluno. As tarefas estão intimamente ligadas às características: avaliações e estilo de ensino. A Figura 4.32 mostra como é feita a supervisão dos *quizzes* criados pelos educadores da EJUG. Para cada questão é calculado o número de acertos e erros, os resultados são exibidos graficamente.



Figura 4.33: Participações em Chats.

Salas de bate-papo, *chats*, são recursos essenciais em plataformas EaD, tendo em vista que pode aproximar aluno e professor, tal como ocorre em cursos presenciais. A falta de interação individualizada entre docentes e discentes é uma das queixas mais comuns em comunidades de ensino *online*, e neste contexto as salas de bate-papo podem ajudar a contornar a barreira geográfica que separa os alunos dos professores. De acordo com a literatura, a participação ativa dos professores em *chats* está ligada aos atributos de comunicação e *feedbacks*, dos docentes. A Figura 4.33 traz os relatórios de atividade dos discentes em salas de bate-papo.



Figura 4.34: Tempo Dedicado ao Curso.

O recurso de *logs* apresenta, detalhadamente, cada ação do tutor dentro do curso. Todos os passos dos discentes são registrados pelo Moodle, e isso possibilita o acompanhamento, de forma cronológica, das ações dos tutores no sistema. A partir dos dados de *logs* criou-se o relatório de Gerenciamento de Tempo, que claramente está ligado a característica de gerência do tempo do *framework* de atributos de tutoria. A figura 4.34 exibe o tempo total em que o tutor permaneceu ativo no Moodle e apresenta graficamente o tempo dispensado, para o curso, diariamente.

Para verificar o alinhamento dos docentes quanto às suposições andragógicas foram criados os submódulos *Surveys* e *Feedbacks*, que são responsáveis por apresentar a avaliação do tutor e do curso, realizadas pelos estudantes. Os *Surveys* são questionários, predefinidos pelo Moodle, que faz uma série de questionamentos, aos alunos, acerca do comportamento do professor no curso em avaliação. Os questionários de *Feedbacks* são criados por docentes, e em geral aborda temas sobre a qualidade dos cursos e da tutoria. A figura 4.35 exibe a média geral das avaliações que os alunos fizeram a respeito do docente e da maneira como o curso é conduzido pelo professor.



Figura 4.35: Survey: Avaliação do Tutor.

As notas médias apresentadas na Figura 4.35 permitem avaliar os atributos andragógicos *Auto-diretividade*, *Experiência*, *Motivação e Aplicabilidade*, desejáveis na educação de adultos. A Auto-diretividade pode ser avaliada pelo *Estimulo do professor a participação, autorreflexão e ao pensamento crítico*. Para aferir a valorização dos conhecimentos anteriores dos alunos foi calculada a média das notas dos alunos a pergunta: *O conteúdo do curso me interessa ?*. A Motivação foi mensurada a partir da seguinte questão: *O tutor encoraja minha participação ?*. Os conteúdos das atividades e avaliações, conforme disposto pela andragogia, devem privilegiar questões que reflitam nas atividades profissionais dos alunos. Para avaliar esse critério utilizamos as notas para a questão: *O que estou aprendendo é importante para minhas atividades profissionais?*.



Figura 4.36: Questionário de Feedback.

A figura 4.36 mostra, um trecho, de um questionário de *feedback* criado pelo tutor, com o objetivo de obter informações que possam melhorar a qualidade do curso, em geral. O caráter independente destes questionários dificulta análises generalizadas, entretanto, denota cumplicidade do tutor com a qualidade do curso e com a troca de experiência e expectativas entre alunos e professor.

4.8 O Módulo de Predição

O principal objetivo do módulo de predição é realizar a predição de aprovação ou reprovação dos alunos, a partir da análise de dados feita sobre os registros comportamentais dos alunos no AVA Moodle. Originalmente a implementação da predição no MP utiliza, exclusivamente, dados dos alunos para realizar a classificação. A predição ocorre a partir da aplicação de técnicas de EDM no conjunto de dados que contém informações comportamentais dos estudantes. A metodologia de predição utilizada envolve a elaboração de um modelo de classificação para cada semana de duração do curso, desta forma é possível fazer uma supervisão semanal da evolução de desempenho dos alunos.

A extensão do MP visa incluir informações sobre o comportamento didático dos tutores na predição de desempenho dos alunos, além de adicionar a funcionalidade de

classificação dos tutores quanto à utilização das definições da andragogia. Os dados dos tutores utilizados para predição de desempenho dos alunos serão extraídos de acordo com a correlação destes dados com as características presente no *framework* de atributos de docência (seção 4.2) que podem impactar positivamente nos alunos.

Nas próximas seções serão apresentadas todas as ações realizadas para implementação das novas funcionalidades presentes na extensão do MP. O desenvolvimento do módulo de predição, da extensão do MP, resumidamente seguiu os seguintes passos: definição da metodologia de predição, seleção dos dados a serem analisados, análise de desempenho dos principais algoritmos de classificação e a implementação da predição.

4.8.1 Metodologia de Predição

A função básica da extensão do MP é fazer a predição de reprovação ou aprovação dos alunos se baseando no comportamento dos alunos e nas ações pedagógicas dos tutores dentro Moodle. Basicamente os algoritmos de classificação determinam a classe de um aluno com base na classificação de outros alunos já classificados, resumidamente o algoritmo classificador deve ser treinado com um conjunto de elementos já classificados de forma a produzir um modelo que servirá para classificar novos elementos com classes desconhecidas.

O conjunto de dados utilizado para elaboração do modelo de classificação será composto por dados de cursos da EJUG já encerrados, pois os registros desse conjunto de dados já estão classificados. Como parte adicional da extensão do MP será acrescida ao conjunto de dados um atributo que indicará se as ações do tutor foram condizentes com as diretrizes da andragogia. O atributo indicador das ações do tutor será valorado com o resultado do algoritmo de classificação dos tutores quanto a aplicação das regras andragógicas.

Portanto, o conjunto de treinamento do algoritmo classificador será composto por $\frac{3}{4}$ do conjunto de dados utilizado para predição. A validação do modelo será feita a partir do $\frac{1}{4}$ de dados restantes do conjunto de dados destinados a criação do modelo.

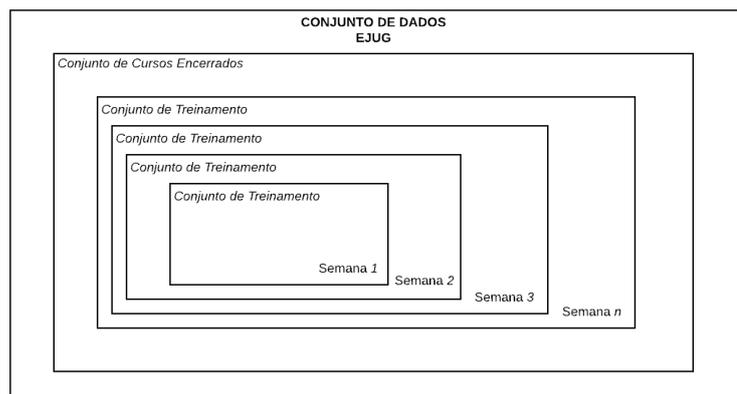


Figura 4.37: *Sistemática de Construção dos Conjuntos de Treinamento.*

Durante o pré-processamento dos dados foi utilizada uma abordagem cronológica para montagem dos conjuntos de treinamentos. Para cada semana do curso é criado um conjunto de treinamento e um modelo de classificação. Os conjuntos de treinamento são criados com reposição de dados, ou seja, cada conjunto de treinamento é formado por registro de semanas anteriores e com registros da semana atual. A figura 4.37 resume a sistemática de formação dos conjuntos de treinamento do algoritmo classificador.

Essa abordagem cronológica é utilizada tanto para classificação dos alunos e dos tutores, permitindo que os gestores do ambiente educacional possam acompanhar a evolução comportamental dos alunos e tutores.

4.8.2 O Subconjunto de Dados Usados para Predição

Conforme descrito na seção 4.8.1 dentre todos os cursos da base de dados da EJUG foram selecionados um subconjunto dos cursos para a formação do conjunto de treinamento e avaliação dos modelos classificadores.

O conjunto de dados usado na predição é formado por registros de cursos já encerrados, oferecido pela EJUG entre 2015 e 2019. Em virtude da metodologia cronológica da predição e da discrepância de duração dos cursos da EJUG, os cursos encerrados foram agrupados por tempo de duração.

Tempo de Duração	Cursos	Total de Registros
5 Semanas	Administração Judiciária; Aprender à Distância; Ética, uma Questão de Escolha; Gestão de Processos; Improbidade Administrativa; Processo Administrativo Digital; Reforma Ortográfica.	1171
6 Semanas	Ética, uma Questão de Escolha; Excelência em Atendimento ao Público; Gerenciamento de Projetos; Gestão Estratégica com o uso do BSC; Introdução a Gestão Socioambiental; Introdução ao Direito Constitucional; LibreOffice Writer; Malote Digital; Moodle para Professores; Reforma Ortográfica; Tribunal do Juri.	943
7 Semanas	Administração Judiciária; Alienação Parental; Educação Financeira; Improbidade Administrativa; Introdução a Gestão Socioambiental; LibreOffice Writer; Processo Penal Descomplicado; Reforma Ortográfica.	638

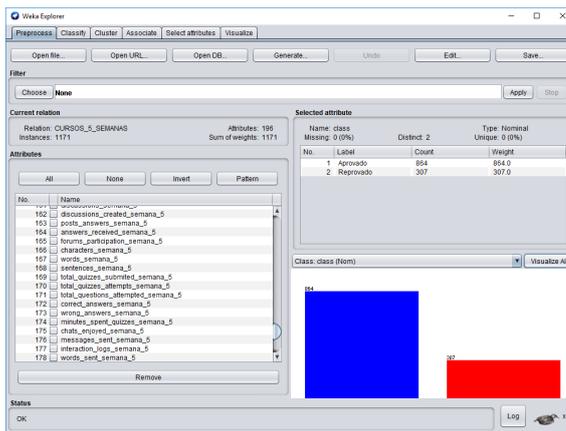
Tabela 4.12: *Subconjunto de Cursos.*

A tabela 4.12 lista os cursos, de acordo com a duração, incluídos na amostra de cursos encerrados que foram utilizados na predição. Cada registro no conjunto de predição descreve o comportamento de um aluno que já concluiu o curso. O total de registros do conjunto de predição é de 2752, desse total, 2064 registros ($\frac{3}{4}$) foram utilizados para geração dos modelos de classificação e o restante foi utilizado para testar e avaliar os modelos gerados.

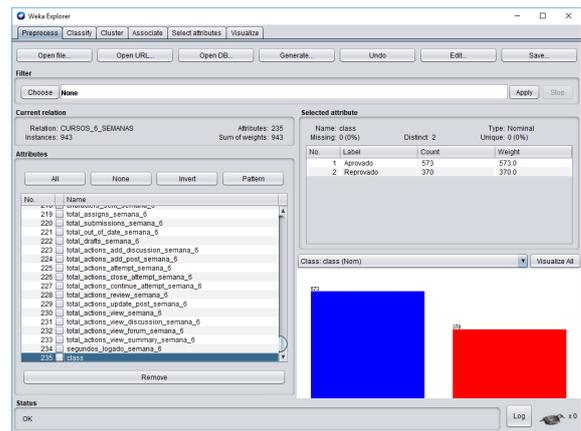
4.8.3 Balanceamento dos Dados

Um conjunto de dados balanceado é aquele em que a quantidade de registros, para cada classe possível no conjunto, são iguais. Porém, em aplicações do mundo real raras são as aplicações que operam com um conjunto de dados balanceado. Segundo [Vipin, Michael e Pang-Ning \(2005\)](#) a métrica de acurácia (seção 2.2.2) é bastante utilizada para mensurar o desempenho de modelos de classificação, pois algoritmos de classificação procuram atingir a maior quantidade de classificações corretas dentre o total de registros classificados e esta proporção, entre o número de classificações corretas e total de classificações, é o conceito propriamente dito da métrica acurácia da predição.

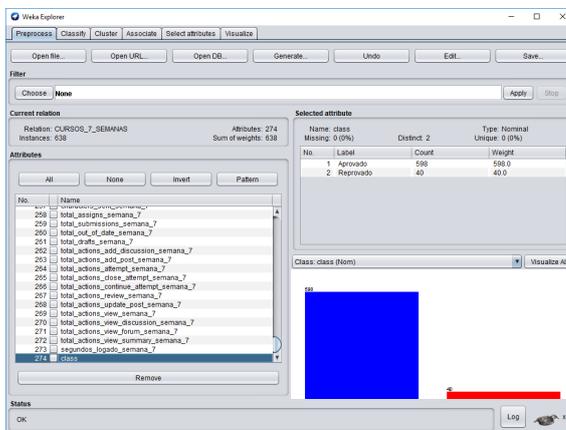
Ao se avaliar o desempenho de um modelo de classificação, gerado a partir de um conjunto de dados desbalanceado, utilizando a métrica de acurácia fica-se sujeito a obter uma medida de performance errônea, pois modelos de classificações gerados por dados desbalanceados tendem a se ajustar aos dados que representam a classe majoritária no conjunto de dados, ou seja, o modelo é construído considerando basicamente apenas os dados da classe dominante. Logo a acurácia, destes modelos, tende ser elevada, pois ao se submeter novos registros ao modelo eles serão classificados como sendo da classe majoritária, elevando a taxa de classificações corretas e conseqüentemente a acurácia do modelo.



(a) Cursos 5 Semanas



(b) Cursos 6 Semanas



(c) Cursos 7 Semanas

Figura 4.38: Proporção de Classes no Conjunto de Dados.

As figuras 4.38 mostram o balanceamento dos subconjuntos de dados utilizados para predição nesta pesquisa. Considerando o alto nível de desbalanceamento dos dados analisados, a métrica de acurácia não fornecerá uma medida de desempenho confiável para os modelos de classificação. Logo, para ter uma medida de desempenho precisa, deve-se aplicar alguma técnica de balanceamento de dados ou utilizar uma métrica de desempenho alternativa, que considera o desbalanceamento dos dados na aferição da performance.

A principal técnica de correção de desbalanceamento é nominada de *Sampling*. Algoritmos baseados em *sampling* detectam as classes com menor quantidade registros, conhecidas como positivas, e geram amostras sintéticas, de modo a equilibrar as quantidades de classes positivas com o número de classes negativas, que possuem maior quantidade de registros. Existem algumas variações da técnica de *sampling* estas são: *undersampling*, *oversampling* e *hybrid*.

Na abordagem de *undersampling* exemplares da classe majoritária, negativa, são escolhidas aleatoriamente para formar um subconjunto de dados em que as classes

positivas e negativas estejam em quantidades uniformes. O problema desta abordagem é que exemplares úteis da classe negativa podem ser descartados na geração do modelo. Na estratégia de *oversampling* réplicas da classe positiva, minoritária, são incluídas até que as quantidades de registros das positivas e negativas estejam iguais. O grande problema desta técnica está no super-ajustamento (*overfitting*) do modelo ao conjunto de dados utilizado para gera-lo, uma vez que os registros são réplicas e não novos registros. A abordagem *hybrid* une a classe majoritária do *undersampling* com as classes minoritárias do *oversampling* até alcançar uma distribuição uniforme das classes, entretanto, esta técnica também está suscetível ao problema de *overfitting*.

Portanto, devido a falta de controle na qualidade dos registros incluídos na técnica de *sampling* e da alta probabilidade de *overfitting* do modelo gerado, nenhuma técnica de balanceamento de dados será implementada no contexto desta pesquisa.

A curva ROC é uma abordagem que exhibe graficamente os custos-benefícios entre as taxas TP e FP, ou seja, é apresentada a proporção de classificações erradas do modelo, a seção 2.2.2 detalha essa métrica. Segundo [Vipin, Michael e Pang-Ning \(2005\)](#) a curva ROC é ideal para se comparar o desempenho de modelos de classificação. A área abaixo da curva ROC (AUC) é uma boa métrica para se avaliar qual modelo de classificação tem melhor desempenho.

De acordo com [Vipin, Michael e Pang-Ning \(2005\)](#) a métrica área sob a curva (AUC), apresentada na seção 2.2.2, é ideal para se comparar o desempenho de modelos de classificação, pois calcula os custos-benefícios entre as taxas TP e FP, ou seja, apresenta a proporção de classificações erradas do modelo, o que é ideal a modelos que podem estar super-ajustados. Logo a métrica AUC tem sido amplamente utilizada em conjunto de dados em que há grande desproporção entre as classes, portanto, para esta pesquisa a métrica de avaliação dos modelos classificadores será o valor da AUC, para cada modelo.

4.8.4 Atributos dos Alunos Utilizados para Predição

O comportamento de cada aluno, dentro do Moodle, é descrito pelo conjunto de 40 atributos listados na tabela 4.13. Cada atributo foi extraído ou derivado de uma ou mais tabelas do Moodle, devido aos relacionamentos entre as tabelas. Adicionalmente foi acrescido o atributo de classe para descrever a classificação do aluno após a predição de desempenho.

Módulo	Descrição Atributos
Fóruns	Total de participação em fóruns; Qtd de posts; Nº atualizações nas publicações; Nº de publicações lidas; Nº de discussões que participou; Qtd de respostas enviadas; Nº de respostas recebidas; Qtd de caracteres digitados; Total de palavras publicadas; Nº de frases enviadas.
Questionários	Total de questionários que participou; Nº de submissões; Total de questões acertadas; Total de questões erradas; Tempo gasto nos questionários.
Chats	Total de chats em que participou; Total de mensagens enviadas; Nº de palavras digitadas; Nº de caracteres digitados.
Tarefas	Qtd de tarefas realizadas; Nº de submissões; Total de tarefas enviadas atrasadas; Qtd de rascunhos salvos.
Logs	Total de interações; Tempo logado.

Tabela 4.13: *Atributos dos Alunos.*

A tabela 4.13 exibe as descrições dos atributos dos alunos coletados para a análise e predição dos alunos no MP. Tais atributos também foram utilizados no trabalho apresentado por Felix (2017).

4.8.5 Atributos dos Tutores Utilizados para Predição

O conjunto de atributos que representam as ações comportamentais dos tutores da EJUG, e que também foi utilizado na classificação dos tutores quanto as aplicação das técnicas andragógicas, foi construído a partir da correlação entre as características presentes no *framework* e os dados armazenados no Moodle.

A tabela 4.14 exibe a correlação entre as características do *framework* e os dados extraídos do Moodle. Cada atributo andragógico está associado a um conjunto de característica de tutoria (seção 4.2), e cada atributo de tutoria foi correlacionado com um, ou mais, dados extraídos da base de dados da EJUG.

Características Andragógica	Características da Literatura Associadas	Atributos Extraídos
Auto-diretividade	Gerenciamento do Tempo	Tempo médio de tarefas disponíveis; Tempo médio de <i>quizzes</i> disponíveis; Tempo médio de <i>survey</i> disponíveis; Tempo médio de <i>feedbacks</i> disponíveis;
	Avaliações	Nº de tarefas criadas; Nº de <i>quizzes</i> criados;
	Motivação	Nº de livros criados; Nº de <i>wikis</i> criadas; Nº de <i>scorms</i> criados; Nº de imagens utilizadas; Nº de vídeos utilizados; Nº de áudios utilizados; Nº de pdf's utilizados; Nº de documentos <i>office</i> utilizados;
Avaliações	Estilo de Ensino	Total de submissões feitas nos <i>quizzes</i> ; Total de submissões feitas nas tarefas; Total de submissões feitas nos <i>feedbacks</i> ;
	Avaliações	Nota média dos <i>quizzes</i> ; Nota média das tarefas;
	Experiência	Nota média para pergunta: qual importância do curso para a vida profissional?
Experiência Prévia	Avaliações	Nota média para pergunta: o curso me interessa?
	Comunicação	Nº de chats criados; Nº de fóruns criados;
	Estilo de Ensino	Nº de <i>workshop</i> criados;
Motivação	Motivação	Total de horas logado;
	Comunicação	Nº de <i>posts</i> em fóruns; Nº de tarefas corrigidas;
	Estilo de Ensino	Nº de <i>feedbacks</i> criados; Nº de <i>surveys</i> criados;
	Liderança	Nota média para pergunta: o tutor encoraja minha participação?

Tabela 4.14: Correlação dos atributos do Framework de Característica do Tutor com os Dados extraídos para predição.

A coluna “Atributos Extraídos” da tabela 4.14 contém todos os atributos que serão utilizados na predição de desempenho dos alunos e na classificação dos tutores com o andragógicos ou não.

4.8.6 Estratégias para Classificação do Tutor

Devido à falta de parâmetros e da dificuldade de encontrar referências no meio acadêmico sobre a classificação de professores, principalmente em cursos EaD, quanto a utilização das diretrizes andragógicas, nos valem de duas técnicas para agrupar os professores dentro das duas classes desejadas: “Andragógico” e “Não-andragogico”. A primeira abordagem consistiu na aplicação da técnica de EDM clusterização (agrupamento). A segunda estratégia de classificação sugerida consistiu em aplicar uma variação

nas técnicas de agrupamento por média que se baseia nas médias individuais e globais de utilização dos recursos disponíveis para os tutores dentro do AVA Moodle.

Clusterização

A técnica de agrupamento foi utilizada no contexto desta pesquisa para tentar agrupar os professores em dois grupos que possam ser descritos como andragógicos ou não andragógicos.

A clusterização dos dados foi realizada com auxílio da ferramenta WEKA, com a aplicação do algoritmo *SimpleKMeans*. O *SimpleKMeans* é uma implementação algorítmica da técnica de agrupamento. Para a execução deste algoritmo deve ser informado um número (k) de grupos (*cluster*) em que se deseja agrupar os dados, de tal forma que o grau de similaridade entre os membros de cada grupo seja o mais alto possível. O *SimpleKMeans* cria os grupos baseado na média aritmética dos atributos dos registros do conjunto de dados, portanto, cada registro é atribuído a um *cluster* com base nos valores médios de seus atributos.

Cada registro no conjunto de dados representa um tutor, portanto, desejou-se agrupá-los conforme a aplicação das boas práticas de tutoria presentes no *framework*, o algoritmo de agrupamento foi executado com valor de “ $k = 2$ ”, que formou dois grupos rotulados como “Andragógicos” e “Não Andragógicos”.

A Tabela 4.15 exibe o resultado da clusterização dos tutores. Foram analisadas informações de 156 professores descritos pelos atributos extraídos para predição comportamental dos tutores (seção 4.8.5). O algoritmo *SimpleKMeans* agrupou os dados dos professores nos *cluster0* e *cluster1*, conforme definido “ $k = 2$ ”. A rotulação dos grupos como andragógicos e não andragógicos se deu a partir das análises médias para cada atributo de tutoria desejado pela andragogia, logo, o *cluster* com médias mais elevadas para os atributos andragógicos foi classificado como grupo de professores “Andragógicos” e o grupo complementar como “Não Andragógico”.

Atributos Andragógico	Atributos Correlacionados	Cluster0	Cluster1
Auto-diretividade	Nº de tarefas criadas;	0.9265	0.65
	Nº de livros criados;	0.0074	0
	Nº de <i>wikis</i> criadas;	0.4338	2.05
	Nº de <i>scorms</i> criados;	0.4853	0.55
	Nº de conteúdos externos;	21.5441	20.7
	Nº de imagens utilizadas;	0.0221	0
	Nº de vídeos utilizados;	1.8824	2.6
	Nº de áudios utilizados;	0.0441	0
	Nº de pdf's utilizados;	0.0074	0
	Nº de documentos <i>office</i> utilizados;	0.7206	0.75
	Tempo médio de tarefas disponíveis;	12.7074	0.675
	Tempo médio de <i>quizzes</i> disponíveis;	0.762	3.2745
	Tempo médio de <i>feedbacks</i> disponíveis;	1.5147	0
Tempo médio de <i>surveys</i> disponíveis.	0.1324	0.65	
Experiência Prévia	Nº de chats criados;	0.0809	0
	Nº de fóruns criados;	3.8162	9.25
	Nº de workshop criados;	0.0441	0
	Nota média para pergunta: o curso me interessa?	0.029	0
Motivação	Nº de <i>posts</i> em fóruns;	6.9779	43.45
	Nº de tarefas corrigidas;	1.6103	10.15
	Nº de <i>quizzes</i> criados;	0.9338	35.4
	Nº de <i>feedbacks</i> criados;	0.1324	0.1
	Nº de <i>surveys</i> criados;	0.2132	0.05
	Total de horas logado;	0	4.2815
Nota média para pergunta: o tutor encoraja minha participação?	0	4.373	
Aplicabilidade	Total de submissões feitas nos <i>quizzes</i> ;	1.6176	0.75
	Total de submissões feitas nas tarefas;	34.1471	17.5
	Total de submissões feitas nos <i>feedbacks</i> ;	1.5147	0
	Nota média dos <i>quizzes</i> ;	0	4.4175
	Nota média das tarefas;	0.5229	2.615
Nota média para pergunta: qual importância do curso para a vida profissional?	0.7132	1.15	

Tabela 4.15: Clusterização dos dados dos Tutores.

Na tabela 4.15 são destacados os atributos com melhores médias para cada atributo de tutoria presente no *framework*. A partir da contagem de atributos de tutoria presentes em cada *cluster* identificou que o *cluster0* obteve 16 atributos com melhores médias, já o *cluster1* contabilizou 15 atributos. Como a divisão dos atributos de boas práticas de tutorias entre os grupos foi praticamente a mesma, diferença de apenas um atributo, conclui-se que a abordagem de clusterização não foi determinística o suficiente para agrupar os professores quanto a utilização dos atributos de tutoria presentes no *framework*.

Algoritmo das Médias

Como a estratégia de clusterização dos dados, 4.8.6, não foi conclusiva na distribuição dos tutores entre os grupos andragógicos e não andragógicos, uma nova abordagem foi seguida. Similarmente a estratégia do algoritmo *SimpleKMeans* foi elaborado um al-

goritmo que classifica os docentes comparando os valores individuais de cada atributo de tutoria com sua respectiva média global.

Algoritmo 4.1: *classificaTutor(R)*

Entrada: Registro $R[X_1, \dots, X_{31}]$
Saída: "Andragógico" ou "Nao Andragogico"

```

1  $X_1, \dots, X_{31}$  // atributos andragógicos
2  $M_1, \dots, M_{31}$  // média global de cada atributo
3  $C_1, C_2, C_3, C_4$  // Total de atributos por classes
4  $T$  // total de classes andragógicas

5 para  $i \leftarrow 1$  até 14 faça
6     se  $(X_i \geq M_i)$  então
7         |  $C_1 = C_1 + 1$ 
8     fim
9 fim

10 para  $i \leftarrow 15$  até 18 faça
11     se  $(X_i \geq M_i)$  então
12         |  $C_2 = C_2 + 1$ 
13     fim
14 fim

15 para  $i \leftarrow 19$  até 24 faça
16     se  $(X_i \geq M_i)$  então
17         |  $C_3 = C_3 + 1$ 
18     fim
19 fim

20 para  $i \leftarrow 25$  até 31 faça
21     se  $(X_i \geq M_i)$  então
22         |  $C_4 = C_4 + 1$ 
23     fim
24 fim

25 se  $(C_1 \geq 7)$  então  $T \leftarrow T + 1$ 
26 se  $(C_2 \geq 2)$  então  $T \leftarrow T + 1$ 
27 se  $(C_3 \geq 3)$  então  $T \leftarrow T + 1$ 
28 se  $(C_4 \geq 3)$  então  $T \leftarrow T + 1$ 

29 se  $(T \geq 3)$  então
30     | retorna "Andragogico"
31 senão
32     | retorna "NaoAndragogico"
33 fim
```

O algoritmo 4.1 faz a classificação de um professor com base no valor médio dos atributos e das classes andragógicas. Um professor possui um determinado atributo andragógico se ele apresenta um valor maior ou igual ao da média global para o respectivo atributo. Através da sistemática do algoritmo das médias o professor possui um atributo andragógico (Auto-diretividade, Experiência Prévia, Motivação e Avaliações) se pelo menos metade dos valores dos atributos, correlacionados ao atributo andragógico, for maior ou igual que a média global para os respectivos atributos. E finalmente um professor é classificado como andragógico, ou não, se ele possui pelo menos 3 dos atributos andragógicos.

Para validar a eficiência do algoritmo em classificar os tutores foi realizado testes de classificação de tutores em que já se sabia a classe comportamental. A validação envolveu a seleção de um subconjunto de tutores que possuíam avaliações positivas quanto às boas práticas de tutoria e registros de atividades para todos os atributos selecionados para predição (seção 4.8.5). Ao se submeter um subconjunto de tutores ao algoritmo das médias todos foram classificados corretamente como “Andragógicos” e de forma complementar selecionou-se dados de tutores com poucos registros de atividades e o algoritmo foi capaz de classifica-los corretamente como “Não Andragógicos”.

Portanto, para cumprir com os objetivos desta pesquisa o algoritmo das médias se mostrou eficiente e suficiente em classificar os tutores quanto ao cumprimento das práticas andragógicas.

4.8.7 Seleção dos Algoritmos Classificadores

Conforme definido na metodologia (capítulo 3), a técnica de mineração de dados escolhida para realização da predição de desempenho dos alunos foi a classificação (3.2). Logo, foram selecionados os principais algoritmos classificadores utilizados na literatura acadêmica e implementados na ferramenta WEKA.

As principais estratégias de classificação e seus respectivos algoritmos, utilizados nesta pesquisa, estão apresentados na listagem abaixo:

- Árvores de Decisão
 - J48
 - Random Forests
 - Random Trees
- Regras de Decisão
 - PART
 - JRip
 - Decision Table
 - OneR
- Redes Neurais
 - Multilayer Perceptron
- Regressão Linear
 - Simple Logistic
- Redes Bayesianas
 - Naive Bayes
 - Bayes Net

Os algoritmos que fazem a classificação de registros a partir da indução de uma árvore de decisão (AD) são os mais empregados em tarefas de classificação, dado que

nesta técnica a representação visual dos atributos utilizados na classificação facilita a compreensão e visualização da tarefa de classificação. A figura 4.39 exibe um exemplo de AD gerada pelo algoritmo de classificação C4.5, implementando no WEKA com o nome de J48.

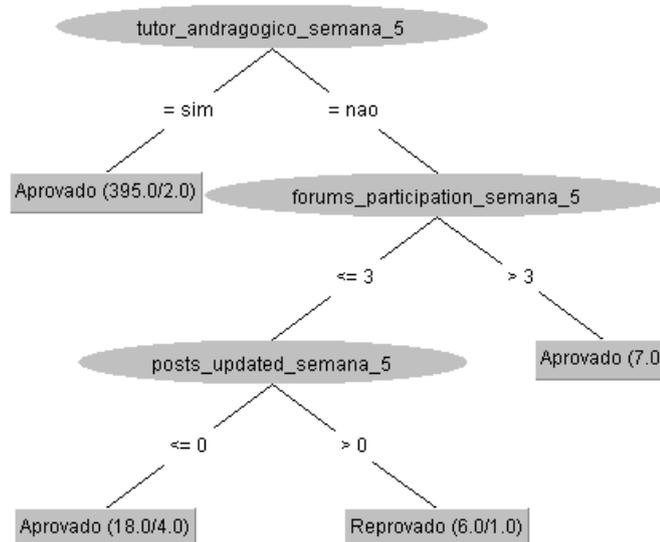


Figura 4.39: *Árvore de Decisão Induzida no Conjunto de Dados da EJUG.*

Apesar das facilidades de visualização e compreensão, a indução de AD pode se tornar lenta e complexa à medida que o conjunto de dados utilizado aumenta. Portanto, algoritmos de classificação alternativos também são propostos. Segundo Fayyad (1996) a classificação por regra de decisão também é bastante utilizada por ser de fácil compreensão para usuário. Sistemas de redes neurais simulam o comportamento do cérebro humano, algoritmos de criação de redes cognitivas podem ser treinados para reconhecer padrões e fazer classificações de registros. A classificação pode ser feita com a definição de funções lineares que descrevem os atributos do conjunto de dados, algoritmos da categoria de regressão linear fazem a previsão de classe a partir da combinação de funções lineares. Algoritmos probabilísticos também são empregados na previsão de classe de registros, classificadores Bayesianos definem a probabilidade de um registro pertencer a uma dada classe a partir do conjunto de registros fornecidos previamente.

Na primeira versão do MP o algoritmo de classificação implementado foi o de *Naive Bayes* (FELIX, 2017). Entretanto, a primeira versão do MP não inclui dados dos tutores na predição de desempenho dos alunos, portanto, para implementação da predição na versão estendida do MP novas análises de desempenho dos classificadores foram conduzidas, a fim de se verificar o desempenho dos classificadores nos conjuntos de dados da EJUG, com e sem os dados de tutores.

4.8.8 Análise de Desempenho dos Classificadores

A análise de desempenho dos classificadores foi conduzida com o propósito de identificar qual algoritmo de classificação gerou o melhor modelo de classificação para o conjunto de dados da EJUG. Conforme justificado na seção 4.8.3 a métrica que foi utilizada para comparação de desempenho dos modelos foi o valor da AUC. No apêndice A é apresentada a análise completa, envolvendo todas as principais métricas de desempenho, para cada algoritmo de classificação.

Dois abordagens de análises foram seguidas. A primeira análise foi feita sem a inclusão de informações dos docentes na elaboração do modelo. A segunda análise foi conduzida com a inserção do atributo que sintetiza as ações comportamentais dos tutores previstas no *framework* de características dos tutores (seção 4.8.5).

- (1) trees.J48 '-C 0.25 -M 2' -217733168393644444
- (2) trees.RandomForest '-P 100 -I 100 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1' 1116839470751428698
- (3) trees.RandomTree '-K 0 -M 1.0 -V 0.001 -S 1' -9051119597407396024
- (4) rules.JRip '-F 3 -N 2.0 -O 2 -S 1' -6589312996832147161
- (5) rules.PART '-M 2 -C 0.25 -Q 1' 8121455039782598361
- (6) rules.DecisionTable '-X 1 -S \\'BestFirst -D 1 -N 5\'' 2888557078165701326
- (7) rules.OneR '-B 6' -3459427003147861443
- (8) functions.MultilayerPerceptron '-L 0.3 -M 0.2 -N 500 -V 0 -S 0 -E 20 -H a' -5990607817048210779
- (9) functions.SimpleLogistic '-I 0 -M 500 -H 50 -W 0.0' 7397710626304705059
- (10) bayes.NaiveBayes '' 5995231201785697655
- (11) bayes.BayesNet '-D -Q bayes.net.search.local.K2 - -P 1 -S BAYES -E bayes.net.estimate.SimpleEstimator - -A 0.5' 746037443258775954

Tabela 4.16: *Parâmetros dos Algoritmos Classificadores.*

A tabela 4.16 mostra os parâmetros utilizados nos algoritmos executados. Todas as análises foram executadas utilizando-se a ferramenta *Experimenter* do WEKA, detalhado na seção 2.2.4.

Análise Sem Inclusão das Ações dos Tutores

O principal objetivo desta análise de desempenho dos classificadores, sem a inclusão dos dados de tutoria, é verificar se há diferença de performance na execução dos classificadores nas bases de dados da EJUG e na utilizada por Felix (2017).

O conjunto de dados utilizado por Felix (2017) foi obtido da plataforma de Moodle utilizada nos cursos EaD da Universidade Federal de Goiás (UFG). Os cursos ofertados pela UFG tem um caráter pedagógico distinto dos ofertados pela EJUG, que tem um viés corporativo. Portanto, essa análise visa verificar se o algoritmo classificador que obteve melhor desempenho na primeira implementação do MP, também apresenta a mesma performance nos cursos corporativos da EJUG.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS	74.74	75.70	73.97	74.58	74.69	74.89	74.64	74.54	74.94	47.63	52.87
CURSOS-6-SEMANAS	85.18	86.32	84.22	85.71	85.58	84.51	76.83	79.43	86.57	76.90	82.24
CURSOS-7-SEMANAS	93.25	92.93	92.84	93.68	93.29	93.90	93.40	93.51	93.67	66.91	79.40

○, ● statistically significant improvement or degradation

Tabela 4.17: Análise da métrica Acurácia para o conjunto de predição da EJUG.

A tabela 4.17 apresenta os resultados das performances dos classificadores, segundo a métrica de acurácia. Para os dados de cursos de 5 semanas o algoritmo *RandomForest* obteve melhor acurácia, para os cursos de 6 semanas o classificador *SimpleLogistic* gerou o melhor modelo e o classificador *DecisionTable* teve melhores taxas de classificações corretas para cursos de 7 semanas. Portanto, nota-se que o algoritmo de *Naive Bayes* não gerou o melhor modelo de classificação para o conjunto de dados da EJUG, conforme havia gerado para o conjunto de dados da UFG.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS	0.69	0.73	0.70	0.52	0.71	0.53	0.52	0.69	0.69	0.66	0.67
CURSOS-6-SEMANAS	0.90	0.94	0.87	0.90	0.90	0.91	0.80	0.92	0.93	0.85	0.90
CURSOS-7-SEMANAS	0.70	0.90	0.81	0.50	0.78	0.77	0.53	0.88	0.58	0.86	0.85

○, ● statistically significant improvement or degradation

Tabela 4.18: Análise da métrica AUC para o conjunto de predição da EJUG.

A tabela 4.18 apresenta o resultado da análise de desempenho dos modelos de classificação para a métrica AUC, definida como métrica de comparação de desempenho no escopo deste trabalho (seção 4.8.3). De acordo com as análises o algoritmo de classificação *RandomForest* (RF) gerou os melhores modelos de classificação, para todos as categorias de cursos.

Contudo, pode-se sugerir que há diferença entre os dados coletados pelo Moodle em ambientes de ensino tradicionais (escolas e universidades) e corporativos. Em nenhuma das análises realizadas sobre os dados da EJUG o algoritmo de *Naive Bayes* conseguiu gerar o melhor classificador, mesmo considerando métricas que dispensam o balanceamento dos dados como a AUC. As diferenças de metodologia de ensino e de público alvo podem justificar a diferença de desempenho dos classificadores em conjunto de dados de domínios distintos.

Análise com a Inclusão das Ações dos Tutores

Esta análise será conduzida com o objetivo de definir qual algoritmo de classificação será utilizado para gerar os modelos de classificação empregados na predição de

desempenho dos alunos na versão estendida do MP.

Para esta análise o subconjunto de dados foi incrementado com um atributo adicional que resume as ações comportamentais dos tutores presentes no *framework* de características de tutoria. O atributo que sintetiza as ações comportamentais dos tutores como andragógicas ou não andragógicas é calculado a partir da submissão dos dados comportamentais dos tutores ao algoritmo 4.1.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS-ANDRAGOGIA	0.67	0.73 ◦	0.70	0.50 •	0.71 ◦	0.53 •	0.52 •	0.72 ◦	0.73 ◦	0.71	0.69
CURSOS-6-SEMANAS-ANDRAGOGIA	0.92	0.95 ◦	0.90	0.92	0.93	0.91	0.81 •	0.94 ◦	0.94 ◦	0.88 •	0.91
CURSOS-7-SEMANAS-ANDRAGOGIA	0.62	0.96 ◦	0.85 ◦	0.60	0.81 ◦	0.76	0.58	0.93 ◦	0.80 ◦	0.87 ◦	0.90 ◦

◦, • statistically significant improvement or degradation

Tabela 4.19: Análise da métrica AUC para o conjunto de predição com dados dos tutores.

Considerando todas as análises de desempenho de classificadores realizadas com o conjunto de dados da EJUG, inclusive as análises sem informações das ações dos tutores nos dados, pode-se inferir que o classificador RF é o mais adequado para ser implementado no módulo que realiza a predição, de desempenho dos alunos, na extensão do MP.

4.8.9 O Classificador *RandomForest*

A partir das análises feitas na seção 4.8.8 definiu-se que o algoritmo utilizado na predição do MP estendido será o classificador *Random Forest*. O RF é um classificador do tipo *ensemble*, classificadores *ensembles* aumentam a precisão de classificação a partir da agregação de predição de múltiplos classificadores. O RF realiza a classificação a partir da indução de um conjunto de árvores de decisão (AD), a classificação é realizada com base nas previsões feitas pela floresta de AD, cada árvore é gerada a partir de um subconjunto de dados independentes e aleatórios. Após a criação da floresta, de árvores de decisão, a classificação do RF é feita com base na votação de uma classe majoritária, contabiliza-se a classificação feita por cada AD.

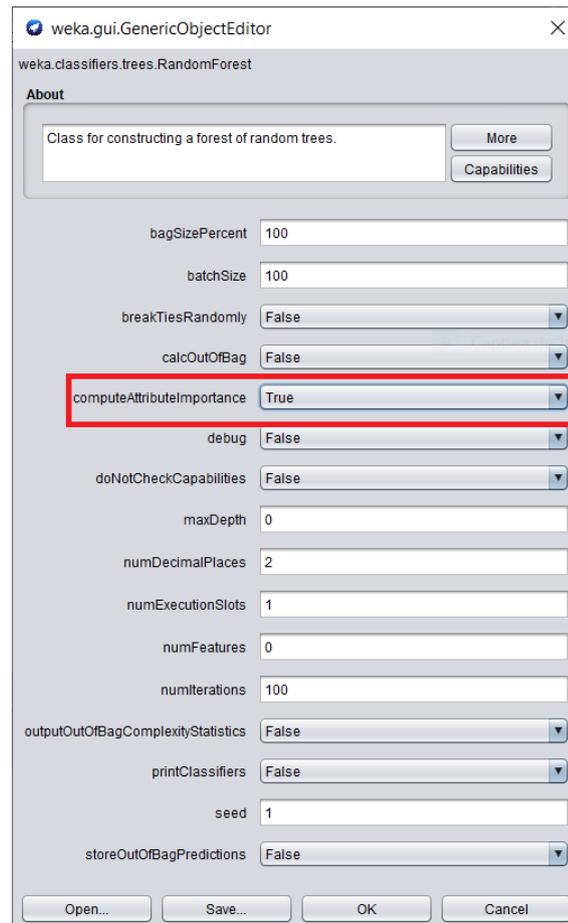


Figura 4.40: Cálculo da Importância dos Atributos: *RandomForest*.

O RF permite que alguns parâmetros sejam configurados para sua execução. A figura 4.40 exibe a configuração do RF na ferramenta WEKA, em destaque nota-se o parâmetro *computeAttributeImportance* habilitado, portanto, ao se executar o RF será gerada uma lista com a proporção de importância de cada atributo na construção das árvores de decisões.

O nível de importância é obtido baseando-se na diminuição do nível de impureza. O grau de impureza se refere a divisão de registros nos nós internos da AD, durante a indução de uma árvore. Quanto menor o grau de impureza melhor é a divisão, pois indica que nós folhas serão gerados nas próximas ramificações da AD, ou seja, é uma forma de podar a árvore e garantir a generalização da árvore de decisão.

Importância dos Atributos dos Tutores		
<i>Cursos de 5 Semanas</i>	<i>Cursos de 6 Semanas</i>	<i>Cursos de 7 Semanas</i>
0.21 (68) tutor_andragogico_semana_1	0.2 (37) tutor_andragogico_semana_1	0.15 (19) tutor_andragogico_semana_1
0.16 (54) tutor_andragogico_semana_2	0.21 (34) tutor_andragogico_semana_2	0.21 (15) tutor_andragogico_semana_2
0.22 (46) tutor_andragogico_semana_3	0.25 (41) tutor_andragogico_semana_3	0.15 (20) tutor_andragogico_semana_3
0.1 (25) tutor_andragogico_semana_4	0.33 (32) tutor_andragogico_semana_4	0.09 (16) tutor_andragogico_semana_4
0.17 (40) tutor_andragogico_semana_5	0.21 (29) tutor_andragogico_semana_5	0.18 (19) tutor_andragogico_semana_5
	0.24 (44) tutor_andragogico_semana_6	0.19 (10) tutor_andragogico_semana_6
		0.18 (16) tutor_andragogico_semana_7

Tabela 4.20: Taxa de Importância do atributo com base na diminuição do grau de impureza.

A tabela 4.20 exibe a importância dos atributos dos tutores na indução das árvores de decisões usadas pelo RF. O nível de importância revela que em todas as categorias, de cursos analisados, os atributos dos docentes tiveram importância na indução das árvores de decisões. Logo, pode se concluir que no contexto desta pesquisa as características dos tutores presentes no *framework* de tutoria podem impactar no desempenho escolar dos alunos.

4.8.10 Implementação da Predição

A implementação da predição foi subdividida em duas partes na extensão do MP. A primeira parte envolveu a predição de desempenho dos alunos, a partir do classificador *RandomForest* implementado no WEKA. A segunda parte da predição foi composta pela implementação do algoritmo das médias (seção 4.8.6) que faz a classificação dos tutores quanto a prática dos atributos de docência ligados ao bom desempenho dos alunos, presente no *framework*. A seguir será apresentado como cada abordagem de classificação foi implementada no contexto desta pesquisa.

Predição de Desempenho dos Alunos

Para implementação da predição de desempenho dos alunos foram utilizados os algoritmos de classificação implementados na ferramenta WEKA. A biblioteca de algoritmos do WEKA foi selecionada por ser amplamente utilizada em pesquisas acadêmicas por ter código aberto e livre de pagamento de licença para fins de pesquisas (seção 2.2.4). O WEKA é totalmente desenvolvido em linguagem de programação Java e disponibiliza uma biblioteca de implementações dos principais classificadores para ser utilizado em programas desenvolvidos em linguagem Java. Logo, para fazer uso da biblioteca de algoritmos do WEKA, a implementação da predição no MP foi feita em linguagem Java e isto implicou em um problema de comunicação entre o módulo de visualização, desenvolvido em linguagem PHP (seção 4.7), e módulo de predição.

A solução para a incompatibilidade de comunicação, entre os módulos do MP, foi a implementação da predição sob a arquitetura de um *Web Service*. Esta arquitetura é dita como orientada a serviços, uma vez que os serviços ofertados são disponibilizados para que outras aplicações, desenvolvidas em qualquer linguagem, possam acessá-los remotamente. Resumidamente, o módulo de predição oferta o serviço de predição, que é acessado pelos usuários da extensão do MP através do módulo de visualização, que por sua vez exibe o resultado da predição aos usuários.

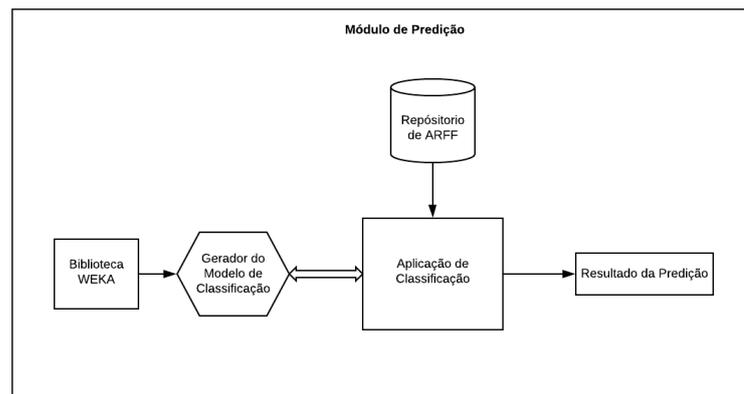


Figura 4.41: Visão interna do módulo de predição.

A figura 4.41 exibe uma visão interna do que foi implementado no módulo de predição. A *aplicação de classificação* possui um *repositório de ARFF*, que armazena os arquivos que estruturam os dados que foram utilizados para geração dos modelos de classificação (seção 2.2.4). Ao receber uma requisição de predição, por parte do cliente, a aplicação faz uma chamada ao *gerador do modelo de classificação*, passando os arquivos ARFF como parâmetro, que gera o modelo a partir da implementação do classificador *RandomForest*, presente no WEKA. Ao obter o modelo de classificação a aplicação submete os dados de predição, enviado pelo cliente, ao modelo que então prediz a classe do aluno como aprovado ou reprovado.

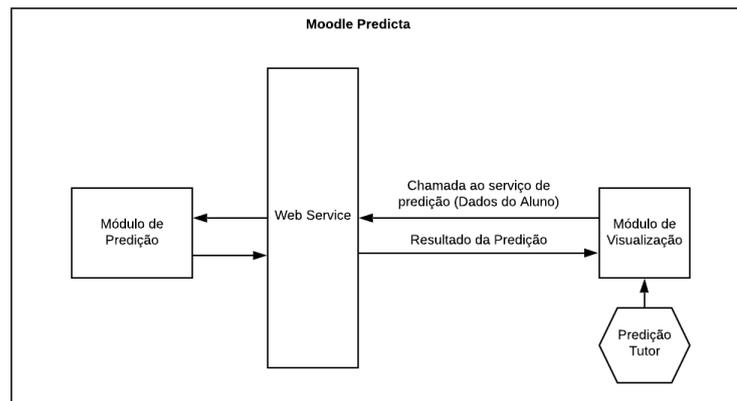


Figura 4.42: Visão interna da extensão do MP.

O funcionamento completo da extensão do MP é apresentado na figura 4.42. Os módulos de visualização e predição se comunicam através da interface de serviços disponibilizada pelo *Web Service*. O cliente, em um navegador *web*, acessa o módulo de visualização e efetua solicitações de predição. Cada solicitação de predição é acompanhada de um conjunto de dados, do aluno que se deseja classificar, que são repassados ao serviço de predição que executa a classificação e envia o resultado ao módulo de visualização, novamente. De posse do resultado da predição, os dados são formatados e apresentados ao usuário, utilizando-se recursos amigáveis de apresentação de resultados disponíveis na visualização de dados.

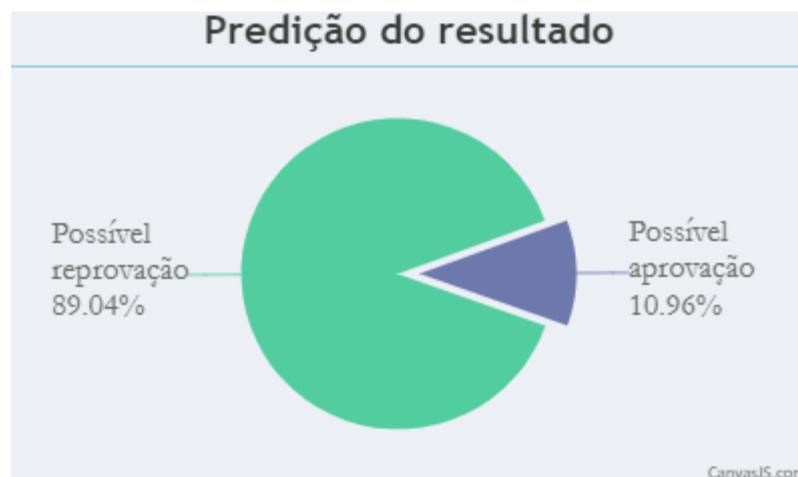


Figura 4.43: Visualização da Predição no Contexto do Curso.

A predição de aprovação ou reprovação dos alunos pode ser visualizada sob duas perspectivas: do curso e dos alunos. No contexto do curso a predição é computada a partir do percentual, total, de alunos classificados como aprovados e reprovados, as proporções de cada classe de alunos são exibidos em um gráfico de setor. Cada setor representa a porcentagem de cada classe e a união dos setores representa o total de alunos da turma.

A figura 4.43 exibe como os resultados das predições de desempenho dos alunos são apresentados aos usuários.

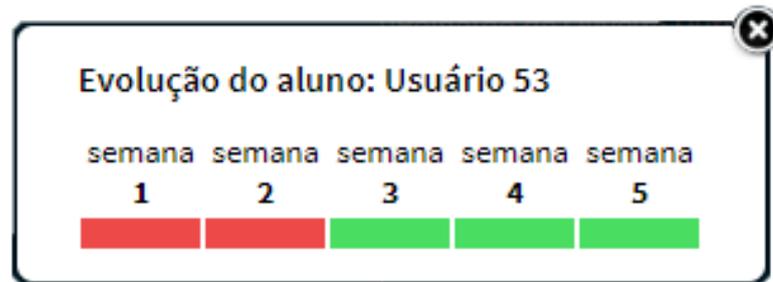


Figura 4.44: Visualização da Predição no Contexto do Aluno.

Do ponto de vista dos alunos a predição é apresentada na forma de evolução do aluno durante as semanas de duração do curso. Na figura 4.44 é apresentada a trajetória comportamental do aluno ao longo de 5 semanas de duração do curso. Os retângulos em vermelho sinalizam as semanas em que o desempenho do aluno se compara ao desempenho de alunos anteriores que reprovaram. Os retângulos com coloração verde sintetizam a informação de que nas respectivas semanas os alunos tiveram desempenho escolar satisfatório e coerente com o comportamento de alunos que obtêm aprovação nos cursos.

Portanto, a partir da predição de desempenho, implementados na extensão do MP, os tutores e gestores educacionais ficam habilitados a acompanhar semanalmente o desempenho escolar dos alunos, podendo a qualquer momento tomar atitudes que possam melhorar a performance dos alunos em semanas subsequentes às analisadas.

Predição dos Tutores

A classificação dos tutores quanto a prática dos atributos presentes no *framework* de boas práticas de tutoria é um dos objetivos (1.3) desta pesquisa. A predição comportamental dos tutores foi realizada com a implementação do algoritmo das médias, proposto como uma alternativa ao algoritmo *SimpleKMeans* (4.8.6).

Dashboard	Moodle Predicta
Seleção de Curso	Análise do comportamento do Professor no curso
Aluno	Curso: Atualização na Área da Infância e Juventude
Curso	Professor: Usuário 69
Professor	Predição Andragógica: Executar

Figura 4.45: Predição de comportamento dos tutores.

A figura 4.42 mostra a ligação da implementação da classificação dos tutores com o módulo de visualização. A partir do módulo de visualização os usuários tem acesso ao submódulo de visualização de dados do tutor (seção 4.7.1) que, também, dá acesso a predição comportamental dos docentes. Ao solicitar a classificação do tutor (figura 4.45), os dados dos tutores são então enviados como parâmetro de entrada para o algoritmo das médias (algoritmo 4.1), após a execução o algoritmo retorna a classificação do tutor como: “Andragógico” ou “Não Andragógico”. A classificação do tutor é feita de forma semanal, ou seja, o algoritmo retorna a classificação do tutor para cada semana de duração do curso.

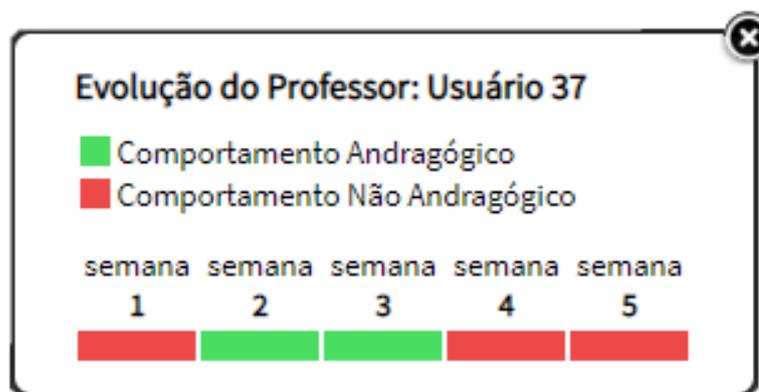


Figura 4.46: Visualização da Classificação do Tutor.

A visualização da evolução do comportamento do tutor, em relação às boas práticas de tutoria, durante o curso é apresentada de forma gráfica de acordo com a classificação do tutor obtida na execução do algoritmo das médias. A figura 4.46 mostra como as ações comportamentais dos tutores são representadas na extensão do MP. No gráfico 4.46 nota-se que em três semanas o comportamento do tutor não foi coerente com as aspirações da andragogia, e que somente durante duas semanas o professor demonstrou as características desejadas para o ensino de alunos adultos. Portanto, a partir da classificação e visualização de dados, oferecidos por esta ferramenta, os gestores de instituições de ensino podem facilmente observar o comportamento dos tutores e propor abordagens diferenciadas para maximizar a qualidade da tutoria.

4.9 Avaliação da Extensão do Moodle Predicta

A avaliação da extensão do MP foi conduzida com o objetivo de se verificar a usabilidade, utilidade e confiabilidade da ferramenta. Para avaliar a ferramenta foram convidados alunos, tutores e gestores da EJUG, para complementar a avaliação um especialista em informática e educação foi convidado a participar da pesquisa de qualidade.

Para realização da avaliação da ferramenta cada usuário convidado recebeu uma explicação teórica do que foi estudado e implementado na extensão do MP. A ferramenta

foi disponibilizada para acesso via internet aos usuários, o manuseio da ferramenta foi assistido de forma *online* para que os usuários pudessem sanar quaisquer dúvidas. Após a utilização da ferramenta os avaliadores foram convidados a responder um questionário avaliativo da ferramenta, o questionário está disponibilizado na íntegra no apêndice A.

4.9.1 Perfil dos Avaliadores

Os participantes escolhidos para participar da avaliação da extensão do MP foram escolhidos de acordo com o perfil que cada usuário exerce ou já exerceu dentro do AVA Moodle, esta metodologia de seleção, por perfil, objetivou abranger todos os perfis disponíveis na extensão do MP, sendo os perfis: gestores, tutores e alunos.

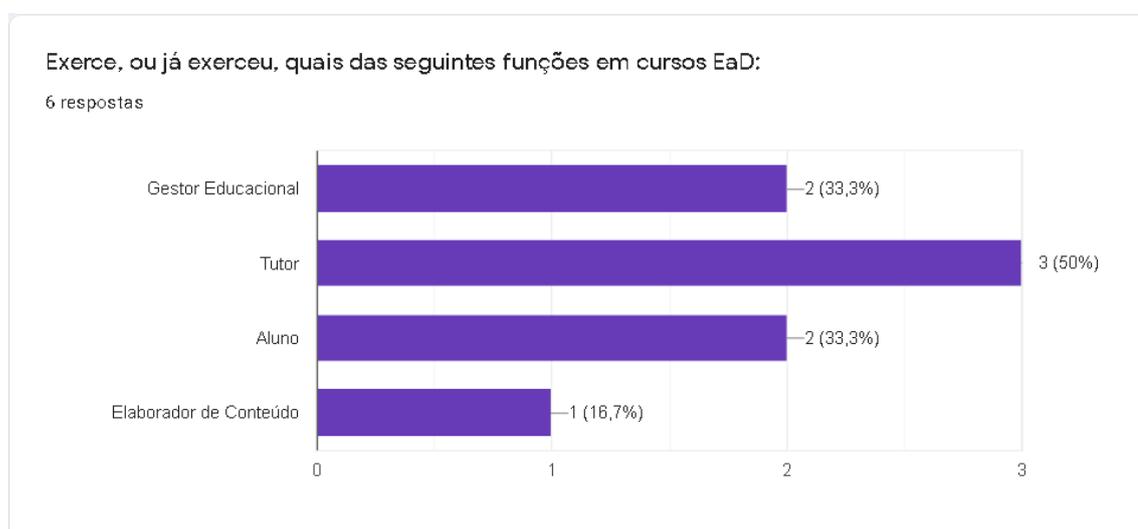


Figura 4.47: Perfil dos usuários que avaliaram a ferramenta.

Excetuando-se o especialista em informática e educação, todos os demais avaliadores possuem vínculo empregatício com o TJGO e possuem algum vínculo com a EJUG. O gráfico 4.47 exibe o quantitativo total de avaliadores e faz a relação com o perfil de cada usuário no ambiente virtual Moodle.

4.9.2 A Avaliação

O questionário de avaliação foi disponibilizado para acesso online aos participantes. Todos os 6 participantes responderam ao questionário avaliativo com 10 questões de múltipla escolha e 1 questão discursiva. Nas questões de múltipla escolha os avaliadores foram orientados a selecionar o nível de concordância com a afirmação feita na questão. Na questão discursiva os usuários foram questionados sobre sugestões de melhorias para a ferramenta extensão do MP.

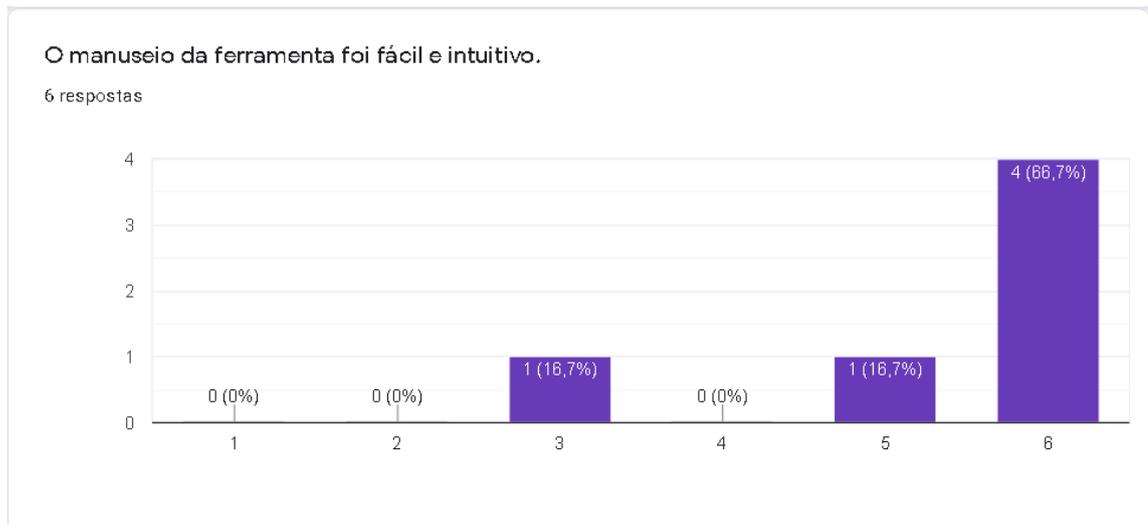


Figura 4.48: Avaliação da facilidade de manuseio da ferramenta.

A primeira questão foi elaborada com a intenção de avaliar a facilidade de se utilizar a ferramenta. O gráfico 4.48 exibe a avaliação da facilidade de manuseio da ferramenta, 5 usuários concordaram fortemente que a utilização da ferramenta foi fácil e intuitivo.

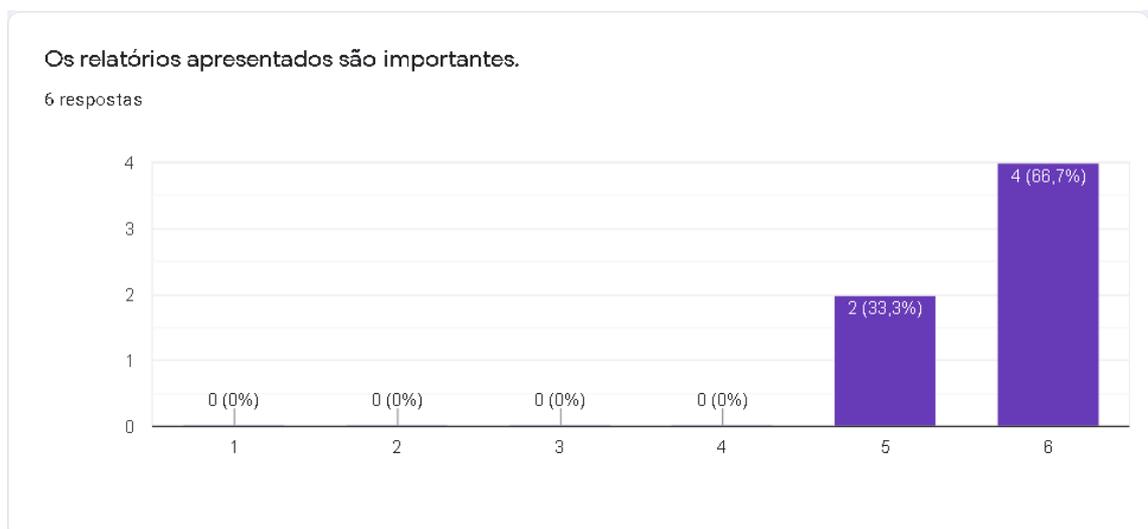


Figura 4.49: Importância dos relatórios implementados.

A importância dos relatórios apresentados aos usuários foi avaliada na segunda questão. Pelo gráfico 4.49 pode-se notar que todos os avaliadores consideraram os relatórios como importantes e substanciais para a gestão de cursos EaD.

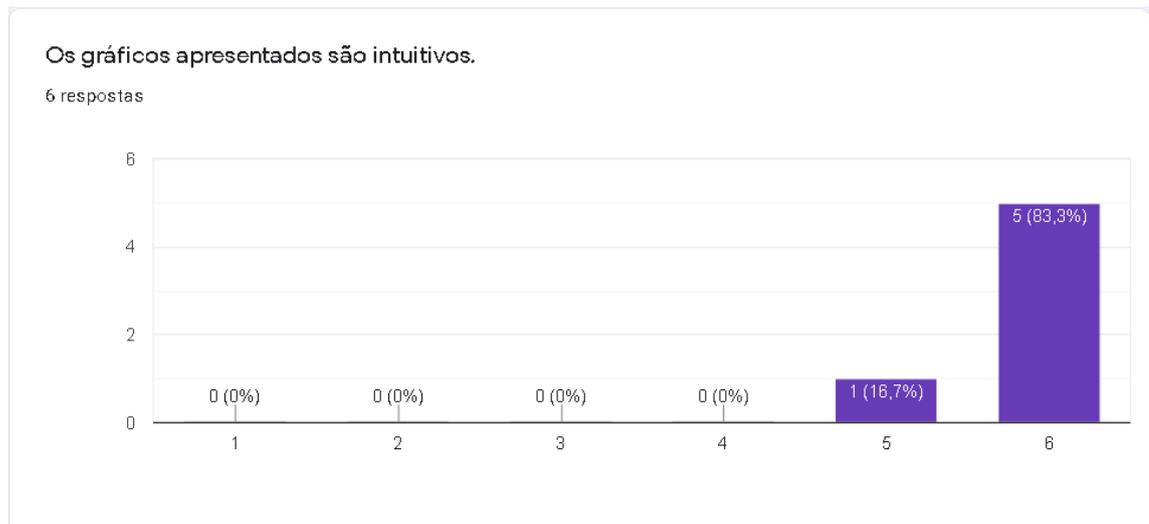


Figura 4.50: *Facilidade de compreensão dos gráficos.*

Gráficos são recursos visuais de apresentação de resultados e são utilizados para facilitar a compreensão do comportamento dos dados. A extensão do MP faz uso abundante deste recurso de visualização de dados, portanto, a terceira questão buscou evidenciar se os gráficos utilizados na ferramenta são intuitivos para os usuários. O gráfico 4.50 revela que todos os usuários avaliaram de maneira positiva a facilidade de compreensão dos gráficos exibidos na extensão do MP.

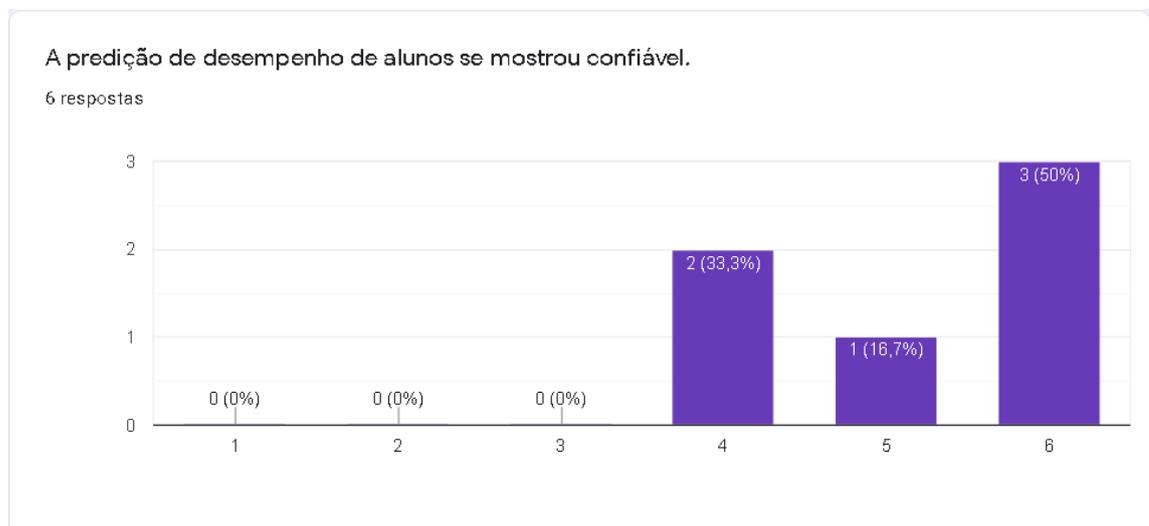


Figura 4.51: *Confiabilidade da predição de desempenho.*

A confiabilidade da predição foi avaliada na quarta questão do questionário. De acordo com o gráfico 4.51 a predição se mostrou relativamente confiável aos avaliadores. A predição de desempenho foi a funcionalidade que mais chamou a atenção dos avaliadores, sendo que vários questionamentos foram feitos sobre a metodologia de predição. A predição de desempenho através da utilização de técnicas de EDM exigem conhecimentos

muito específicos e isso pode ter gerado certa desconfiança dos usuários que distribuíram suas notas acima da concordância média com a afirmação da questão.

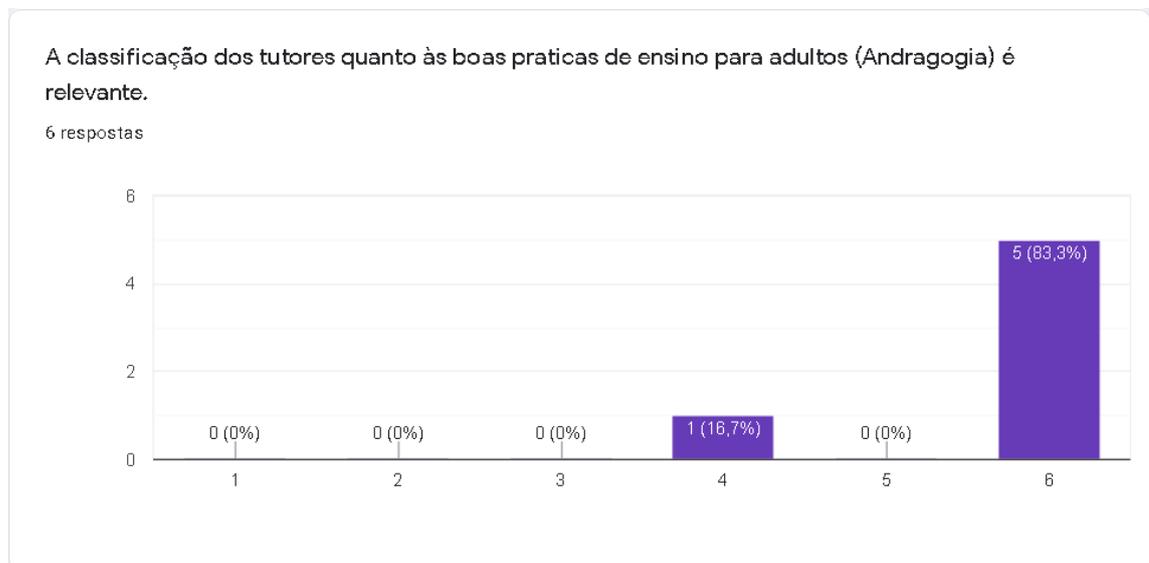


Figura 4.52: *Importância da avaliação comportamental dos tutores.*

A classificação dos tutores quanto as boas práticas de tutoria definidas no *framework*, foi avaliada na quinta questão. O gráfico 4.52 mostra que quase a totalidade dos avaliadores concordaram com a importância de avaliar o comportamento dos tutores.

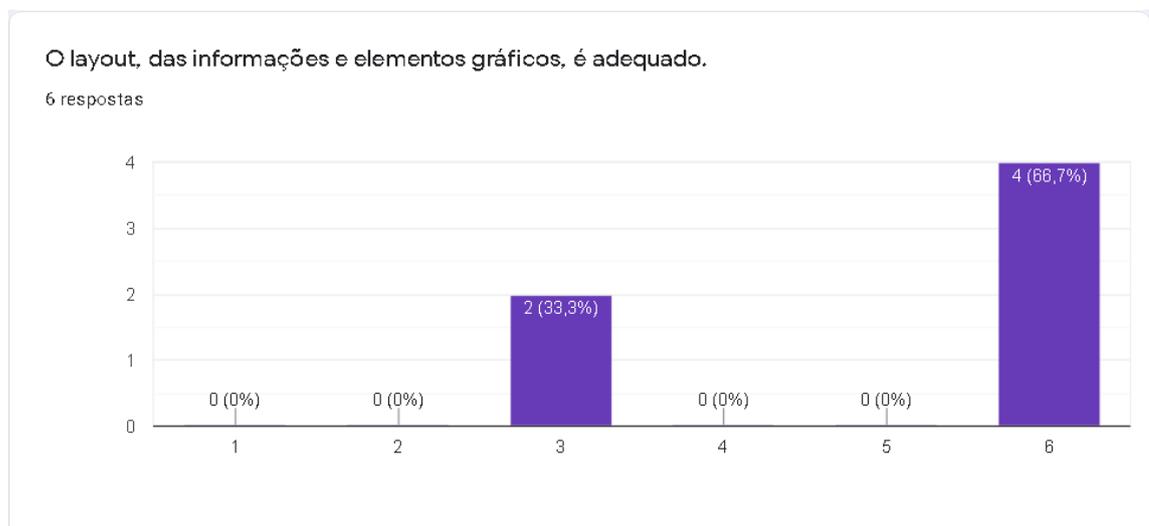


Figura 4.53: *O layout da ferramenta.*

Alguns usuários relataram que os elementos gráficos e as informações apresentadas poderiam estar mais bem organizados dentro do *layout* da ferramenta. O gráfico 4.53 mostra que a satisfação dos usuários com o *layout* da ferramenta não foi total, indicando que melhorias na apresentação dos dados devem ser adotadas.

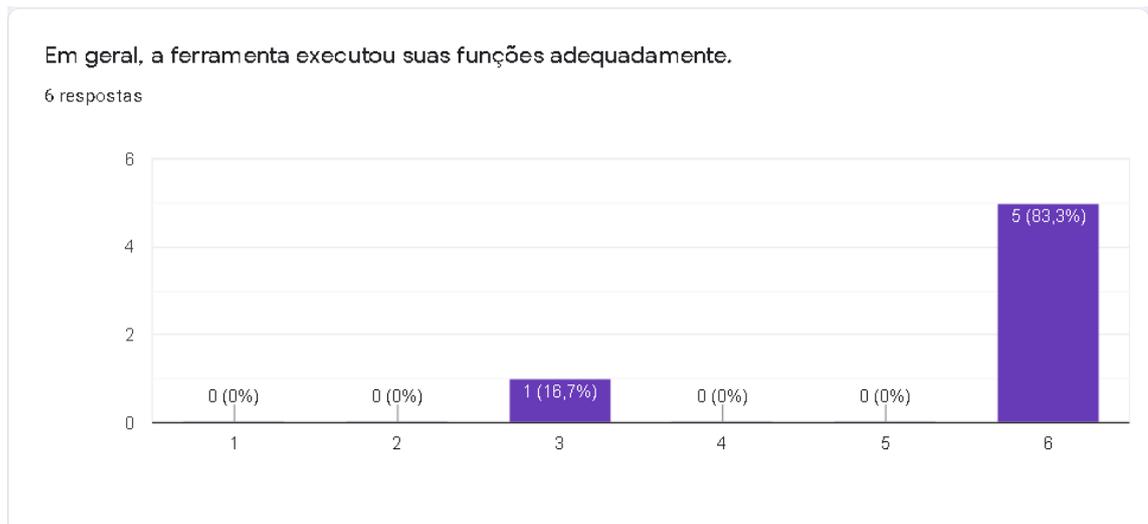


Figura 4.54: Avaliação das funcionalidades implementadas.

A sétima questão do questionário avaliou a eficiência da ferramenta ao executar as funções implementadas. De acordo com o gráfico 4.54 a maioria dos usuários conseguiu executar as funcionalidades disponíveis na ferramenta de maneira satisfatória e sem erros.

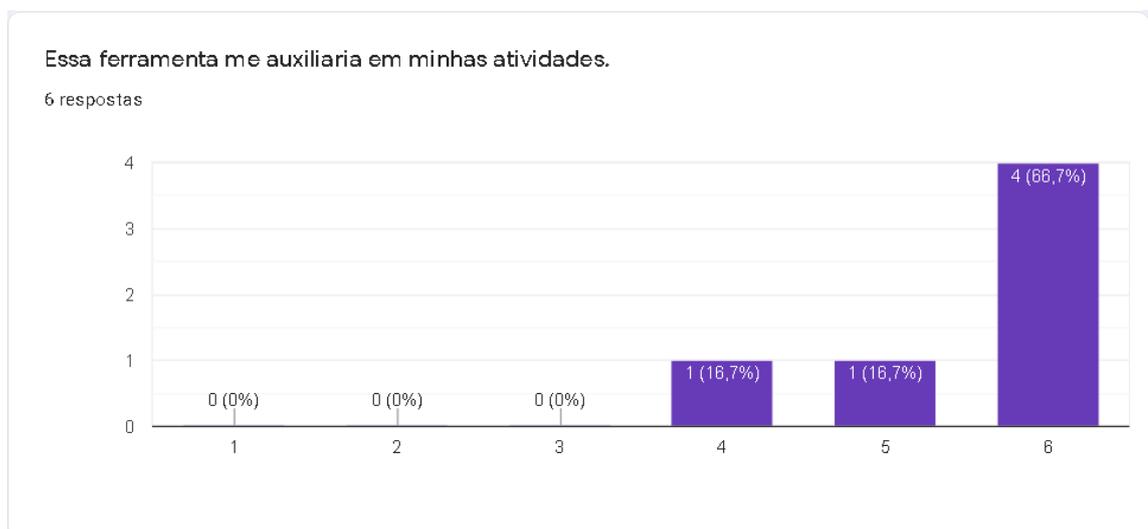


Figura 4.55: Utilização prática da ferramenta.

A oitava questão do questionário avaliou se a ferramenta em avaliação poderia auxiliar os usuários na execução de suas atividades. A avaliação para esta questão foi relativamente positiva, conforme mostra o gráfico 4.55. Essa distribuição irregular das avaliações sugere que a ferramenta pode contribuir na realização das atividades dos usuários, porém, pode exigir melhorias e adequações aos interesses dos usuários.

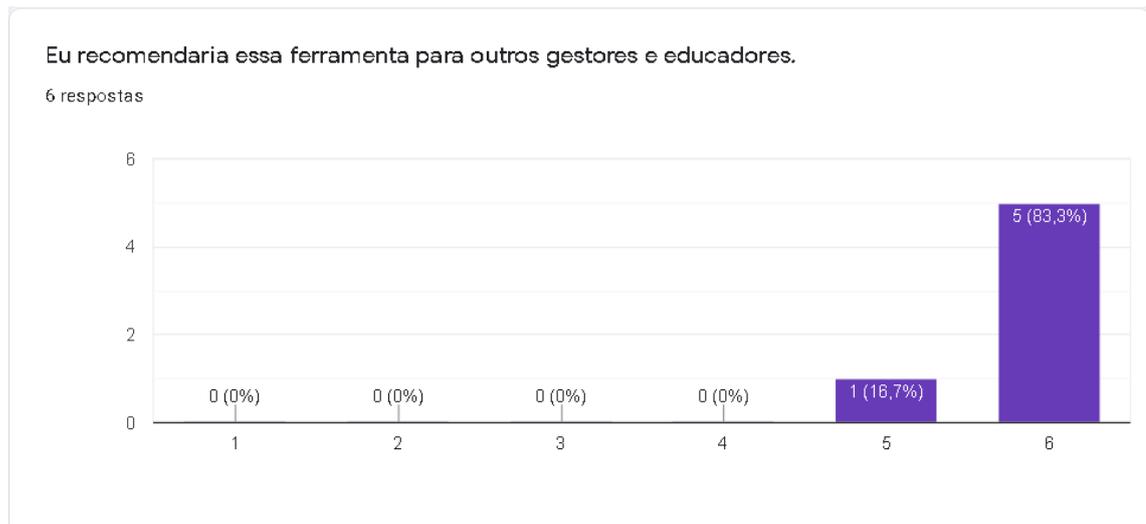


Figura 4.56: Recomendação da ferramenta.

A última questão, de múltipla escolha, buscou evidenciar se os usuários recomendariam a ferramenta extensão do MP a outros usuários. De acordo com as avaliações apresentadas no gráfico 4.56 todos os avaliadores concordaram com a afirmação de que poderiam recomendar a ferramenta a outras pessoas.

4.9.3 Recomendações dos Avaliadores

Uma questão discursiva foi apresentada aos avaliadores com o objetivo de coletar críticas, recomendações e sugestões para melhorias futuras para a ferramenta em avaliação.

As sugestões mais recorrentes dizem respeito ao *layout* e apresentação das informações. Três usuários recomendaram alterações no *layout*, de forma a deixar a interface da ferramenta mais intuitiva e agradável.

Outra solicitação comum entre os avaliadores diz respeito a explicitação dos dados utilizados nas predições feitas pela aplicação, segundo os avaliadores deixar explícito os parâmetros utilizados para classificação, dos alunos e tutores, poderá deixar a predição mais confiável para os usuários.

Em relação as classificação comportamental dos tutores, foi recomendado que as características de docência ausentes, ou deficientes, fiquem evidenciados para os usuários da ferramenta de forma a apresentar um *feedback* mais preciso gestores educacionais.

Portanto, todas as melhorias propostas pelos avaliadores serão consideradas e apresentadas como recomendações para trabalhos futuros na conclusão desta pesquisa.

Considerações Finais

De acordo com os censos realizados pela ABED, o número de alunos e instituições interessadas pelo ensino à distância vem aumentando de forma significativa (CENSO ABED, 2016). A flexibilidade de horário e local de estudo são algumas das características atrativas da modalidade EaD. Contudo, o ensino online requer mudanças de comportamento tanto dos alunos como dos tutores. Os alunos devem ter atitudes proativas, disciplina e principalmente comprometimento com o curso. Os tutores devem atuar de forma ativa: motivando o interesse pelo curso, proporcionando meios para que os alunos estudem de forma independente, desenvolver atividades que reflitam os interesses dos alunos e que abordem as experiências anteriores dos alunos.

A popularização do EaD tem estimulado estudos sobre o comportamento dos alunos e dos docentes, com objetivo de maximizar o desempenho escolar dos alunos. As habilidades dos professores são fundamentais no processo de ensino e conseqüentemente nas conquistas acadêmicas dos alunos. Portanto, para garantir a qualidade do ensino gestores e tutores de EaD devem estar alinhados com as melhores práticas de ensino e habituados com os ambientes virtuais de aprendizagem.

Os ambientes virtuais de aprendizagem são responsáveis por dinamizar o processo de ensino online. AVA's, como o Moodle, permitem a comunicação e interação entre os usuários em tempo real através dos diversos recursos de comunicação disponíveis, como: salas de bate papo, fóruns de notícias, *workshops*, videoconferências etc. Logo, um grande volume de dados educacionais é coletado e armazenado por essas ferramentas.

Para auxiliar gestores educacionais e tutores a maximizarem a performance escolar dos alunos esta dissertação foi desenvolvida com o objetivo de propor um sistema de predição de desempenho dos alunos a partir de um *framework* de características de boas práticas de tutoria. Para realização da predição de desempenho dos alunos foram utilizados dados comportamentais dos alunos e tutores, armazenados pelo AVA Moodle. Os dados coletados pela base de dados educacionais do Moodle foram analisados utilizando técnicas de EDM e de estatística descritiva. A predição de aprovação, ou reprovação, dos alunos e a classificação dos tutores, quanto às boas práticas de tutoria, foram realizadas com aplicação das principais técnicas e métodos de classificação disponíveis na minera-

ção de dados educacionais.

O *framework* de características dos tutores foi construído a partir da correlação entre os principais atributos de docências relacionados ao bom desempenho dos alunos e as características de tutoria desejadas no ensino para jovens/adultos. Os atributos de docência foram elencados através de uma revisão sistemática da literatura acerca das características de docência que podem impactar no desempenho escola dos alunos. As características de tutoria desejadas no ensino de alunos adultos foram extraídas das definições da andragogia.

Para a condução desta pesquisa foi utilizada a base de dados do Moodle utilizado pela EJUG. As extrações dos dados foram realizadas a partir de consultas SQL armazenadas em *views*, foi elaborada uma *view* para extrair dados dos cursos e outra para obter dados comportamentais dos tutores da EJUG. De posse dos dados coletados duas análises exploratórias foram conduzidas, sendo uma análise para se conhecer os cursos corporativos do TJGO e outra para traçar o perfil dos tutores da EJUG.

A predição de desempenho dos alunos no MP, a partir da classificação dos alunos como aprovado ou reprovado, foi originalmente desenvolvida considerando apenas os dados dos alunos. Na extensão do MP realizada neste trabalho foram incluídas informações sobre as ações didáticas dos tutores na predição de desempenho dos alunos, além de implementar a classificação dos tutores segundo as boas práticas de tutoria presentes no *framework*.

A classificação do tutor foi realizada a partir da submissão dos dados comportamentais, extraídos de acordo com as características presentes no *framework* de atributos de tutoria, ao algoritmo das médias. A predição de desempenho dos alunos foi implementada a partir dos dados comportamentais dos alunos em conjunto com os dados que sintetizam as ações didáticas dos tutores.

Por meio de uma análise de desempenho de classificadores selecionou-se o melhor classificador para o conjunto de dados da EJUG. A métrica de desempenho utilizada para comparar os classificadores foi o tamanho da área sob a curva (AUC). De acordo com esta métrica o melhor modelo classificador foi gerado pelo algoritmo *RandomForest* (RF), que conseguiu valores de até 0.96 para a AUC, sendo que $AUC = 1$ é representado pelo modelo ideal. Portanto, o classificador RF foi utilizado na implementação da predição de desempenho dos alunos, na extensão do MP. O modelo de classificação gerado pelo classificador RF incluiu todos os dados dos tutores nos modelos gerados, o que permite inferir que as ações dos tutores podem influenciar na performance escolar dos alunos.

A ferramenta desenvolvida nesta pesquisa foi submetida a avaliação por alguns usuários do EaD ofertado pela EJUG. Os avaliadores da ferramenta extensão do MP afirmaram atuar ou ter atuado com os seguintes perfis de usuário: gestores do Moodle, tutor

e aluno. Além destes usuários um especialista em informática e educação foi convidado para avaliar a ferramenta desenvolvida. A avaliação resultou em elogios, críticas e recomendações. Algumas das recomendações propostas foram atendidas e outras mais complexas, que fogem ao escopo deste trabalho, foram incluídas nas recomendações para trabalhos futuros.

Pelo exposto, o presente trabalho almeja contribuir com o desenvolvimento e aperfeiçoamento de ferramentas e técnicas para o gerenciamento de cursos à distância. Auxiliar gestores educacionais e tutores a melhorar a qualidade do ensino *online* foi o principal objetivo desta dissertação. Espera-se que a predição de desempenho dos alunos auxilie na redução das taxas de reprovação e evasão. E a partir da classificação comportamental dos tutores, quanto às boas práticas de tutoria, deseja-se contribuir para melhoria do ensino EaD, principalmente no que tange a relação aluno e professor.

5.1 Limitações e Ameaças a Validade do Trabalho

Uma das limitações deste trabalho esta relacionado à rastreabilidade de algumas características de tutores dentro do modelo de dados do Moodle. Portanto, apenas o subconjunto de características, que foram possíveis de serem correlacionadas com dados armazenados pelo Moodle, foi incluído no *framework*.

Outro ponto de limitação diz respeito à correlação das diretrizes da andragogia com as características de tutores elencadas a partir da revisão da literatura. Os atributos andragógicos foram segundo a definição de Knowles (1950), portanto, não compreende toda literatura relacionada a andragogia. Em relação às características encontradas na literatura a limitação diz respeito ao ponto de vista dos autores dos trabalhos incluídos na revisão da literatura.

Nas análises exploratórias algumas avaliações tiveram que ser realizadas a partir de subconjuntos dos dados, por exemplo, as análises conduzidas sobre os resultados *surveys*, COLLES e ATTLS, foram feitas considerando apenas cursos que utilizaram esse recurso do Moodle. Portanto, os resultados das análises realizadas sobre subconjuntos devem ser considerados como tendências e não verdades absolutas.

5.2 Sugestões para Trabalhos Futuros

Durante a análise de desempenho dos algoritmos classificadores identificou-se que a performance dos modelos de classificação pode variar de acordo com o domínio do conjunto de dados utilizados para gerar e treinar os classificadores. Constatou-se que o domínio do qual o dados foram coletados e a qualidade dos dados pode impactar na

decisão de qual algoritmo de classificação implementar para se obter a melhor precisão na classificação.

No contexto desta pesquisa todas as análises foram executadas utilizando-se a ferramenta *WEKA Explorer* de forma manual e metódica, confrontando o desempenho de cada classificador a partir dos valores obtidos para cada uma das principais métricas de desempenho.

Portanto, como atividades futuras sugere-se a automatização do processo de seleção do melhor algoritmo classificador. Recomenda-se a elaboração de um processo que determine qual o classificador mais adequado para o conjunto de dados fornecido. Resumidamente o processo deverá receber como entrada um conjunto de dados. As atividades do processo deveram analisar o desempenho dos classificadores, gerados a partir do conjunto de dados fornecido como parâmetro de entrada. E como saída espera-se o modelo de classificação gerado pelo classificador que obteve melhor desempenho nas análises.

De acordo com as avaliações realizadas por gestores, tutores e alunos, foram recomendadas atualizações no *layout* da ferramenta, isso implica na utilização das melhores práticas de engenharia de software no que diz respeito a experiência do usuário na interface da ferramenta. Logo, como trabalho futuro propomos a implementação de um *layout* baseado em UX (do inglês, *user experience*) que é padrão de arquitetura de *software* que tem foco na usabilidade de sistemas.

Outra recomendação que se faz para trabalho futuro é a implementação da ferramenta extensão do MP como *plugin* do Moodle. *Plugins* se destacam pela facilidade de instalação e integração com a ferramenta para qual foi desenvolvido, portanto, implementar a extensão do MP como *plugin* pode aumentar o interesse dos usuários pela utilização da ferramenta. A implementação da ferramenta como aplicativo móvel também se revela como uma boa opção para aumentar aplicabilidade e utilização da ferramenta, tendo em vista a vasta utilização dos *smartphones* no contexto atual da sociedade.

5.3 Artigos Aceitos e Publicados

As análises exploratórias, dos cursos e dos tutores, apresentadas nesta dissertação foram escritas, inicialmente, na forma de artigos que foram aceitos e publicados em congresso nacionais e internacionais, sendo 1 uma publicação nacional, 1 artigo aceito para publicação internacional e 2 publicações internacionais:

1. TRINDADE, Fernando Ribeiro; AMBRÓSIO, Ana Paula. **Corporate Online Courses in the Court of Justice of Goiás**. In *11th International Conference on Computer Supported Education (CSEDU), 2019, Crete-Greece*. (Aceito para publicação)

2. TRINDADE, Fernando Ribeiro; AMBRÓSIO, Ana Paula; FERREIRA, Deller James. **Corporate Online Courses in the Court of Justice of Goiás.** *In 14th International Technology, Education and Development Conference (INTED), 2020, Valencia - Spain.*
3. TRINDADE, Fernando Ribeiro; AMBRÓSIO, Ana Paula; FERREIRA, Deller James. **TJGO Online Corporate Course Tutoring Analysis.** *In 14th International Technology, Education and Development Conference (INTED), 2020, Valencia - Spain.*
4. TRINDADE, Fernando Ribeiro; AMBRÓSIO, Ana Paula. **Predição de Desempenho no Moodle usando Princípios da Andragogia.** *In 7ª ESCOLA REGIONAL DE SISTEMAS DE INFORMAÇÃO DE GOIÁS (ERI-GO), 2019, Goiânia- Brasil.*

Referências Bibliográficas

ABDELLAH, R. Metacognitive awareness and its relation to academic achievement and teaching performance of pre-service female teachers in ajman university in uae. *Procedia - Social and Behavioral Sciences*, 2015.

ADEOSUN, O.; OLADIPO, B.; ONI, A. Affective and cognitive characteristics of nigerian student-teachers: towards developing an effective teacher education framework. *Hiroshima University Library*, 2013.

AKIBA, M.; LIANG, G. Effects of teacher professional learning activities on student achievement growth. *Journal of Educational Research*, 2016.

ASHBY, A. Monitoring student retention in the open university: definition, measurement, interpretation and action. *Open Learning*, 2004.

AZIGWE, J. B.; KYRIAKIDES, L. The impact of effective teaching characteristics in promoting student achievement in ghana. *International Journal of Educational Development*, 2016.

BAKER, R. S. J.; ISOTANI, S. Mineração de dados educacionais: Oportunidades para o brasil. *RBIE*, p. 11, 2011.

BARROS, R. Revisiting knowles and freire: Andragogy versus pedagogy - or the dialogic as the essence of sociopedagogic mediation. *Educação e Pesquisa*, v. 44, 2018.

CANALES, A.; MALDONADO, L. Teacher quality and student achievement in chile: Linking teachers' contribution and observable characteristics. *International Journal of Educational Development*, 2018.

CARVALHO, J. A.; PEDROTE, M.; MOTTA, M. A. Andragogy: Considerations about adult learning. *REMPEC*, 2010.

CHASEN, M.; PITTINSKY, M. *Solve Your Most Critical Challenges in Education*. 2020. <<https://www.blackboard.com/>>. Disponível em: <<https://www.blackboard.com/>>.

CHAUDHRY, N. A.; ARIF, M. Teachers' nonverbal behavior and its impact on student achievement. *International Education Studies*, 2012.

CHIANG, M.; BRINTON, C. *Zoomi Artificial Intelligence for Learning*. 2020. <<https://zoomi.ai/>>. Disponível em: <<https://zoomi.ai/>>.

CHOI, H. J.; YANG, M. The effect of problem-based video instruction on student satisfaction, empathy, and learning achievement in the korean teacher education context. *Higher Education*, 2011.

CHU, J. H.; LOYALKA, P. The impact of teacher credentials on student achievement in china. *China Economic Review*, 2015.

CLOTFELTER, C. T.; LADD, H. F. Teacher credentials and student achievement in high school: A cross-subject analysis with student fixed effects. *Journal of Human Resources*, 2010.

CNJ, C. N. d. J. Auto circunstanciado de inspeção no tribunal de justiça do estado de goiás. In: . [S.l.]: TJGO, 2018.

COMI, S. L.; ARGENTIN, G. Is it the way they use it? teachers, ict and student achievement. *Economics of Education Review*, 2017.

CORDERO, J. M.; GIL-IZQUIERDO, M. The effect of teaching strategies on student achievement: An analysis using talis-pisa-link. *Journal of Policy Modeling*, 2018.

CURTIS, A. C. Enhancing student learning through hypermedia courseware and incorporation of student learning styles. In: . [S.l.]: ieeexplore, 1999.

DOSE, E. M. C. The importance of the feedback in distance education. In: . [S.l.]: RPGE, 2017.

EAD, A. O. *Os possíveis Obstáculos dos Cursos EAD*. 2019. .

EJUG, E. J. d. G. *Missão*. 2017. <http://ejug.tjgo.jus.br/?page_id=129>. Disponível em: <http://ejug.tjgo.jus.br/?page_id=129>.

ELMASRI, R.; NAVATHE, S. B. *Fundamentals of Database Systems*. 6th. ed. [S.l.]: Addison-Wesley, 2011.

FACELI, K.; CARVALHO, A. F.; SOUTO, M. C. P. Algoritmos de agrupamento de dados. *ICMC-USP*, 2005.

FAYYAD, U. From data mining to knowledge discovery in databases. In: . [S.l.]: AI Magazine, 1996.

FELIX, I. M. *Mineração de Dados para Predição de Resultado e Visualização de Informação em Ambiente Virtual de Aprendizagem*. Dissertação (Mestrado) — Instituto de Informática - UFG, Goiânia - GO, 2017.

FLUCKIGER, J.; TIXIER, Y. Formative feedback: Involving students as partners in assessment to enhance learning. In: . [S.l.]: College Teaching, 2010.

FRIEDRICH, A.; FLUNGER, B. Pygmalion effects in the classroom: Teacher expectancy effects on students' math achievement. *Contemporary Educational Psychology*, 2015.

GOLOB, H. M. The impact of teacher's professional development on the results of pupils at national assessment of knowledge. *Procedia - Social and Behavioral Sciences*, 2012.

GUERRIERO, S. Teachers' pedagogical knowledge and the teaching profession. *OECD*, 2017.

HATTIE, J. Teachers make a difference, what is the research evidence? *Australian Council for Educational Research*, 2003.

HEINER, C. Educational data mining workshop. In: . [S.I.]: Educational Data Mining, 2007.

CENSO ABED, A. [Relatório Análítico de Aprendizagem a Distância no Brasil](#). *CensoEAD .BR*, p. 30–39, 2016.

KNOWLES, M. *The modern practice of adult education: from pedagogy to Andragogy*. Englewood Cliffs: Cambridge, 1980.

KNOWLES, M. *The adult learner: A neglected species*. Houston: Routledge, 1990.

KNOWLES, M. *Andragogy in action*. San Francisco: Jossey-Bass, 1990.

KNOWLES, M. *Using Learning Contracts: Pratical Approaches to individualizing and structuring learning*. San Francisco: Jossey-Bass, 1991.

KNOWLES, M. S. Guide for educators based on the writer's experience as a programme organizer in the ymca. *Informal Adult Education*, 1950.

KUKLA-ACEVEDO, S. Do teacher characteristics matter? new results on the effects of teacher preparation on student achievement. *Economics of Education Review*, p. 9, 2009.

KYRIAKIDES, L.; CHRISTOFOROU, C. What matters for student learning outcomes: A meta-analysis of studies exploring factors of effective teaching. *Teaching and Teacher Education*, v. 36, p. 143–152, 2013.

LAPES, L. d. P. e. E. d. S. *StArt*. 2011. <<http://lapes.dc.ufscar.br>>. Disponível em: <<http://lapes.dc.ufscar.br>>.

LEE, H.; LONGHURST, M. Teacher learning in technology professional development and its impact on student achievement in science. *International Journal of Science Education*, v. 39, n. 10, p. 1282–1303, 2017.

MARTINS, K. [A Importância da Educação a Distância na Sociedade Atual](#). *Assessoritec*, 2016.

MILLER, P.; BENNET, T.; STOKKING, K. *X-Ray Learning Analytics*. 2020. <<https://br.blackboardopenlms.com/resource/x-ray-learning-analytics/>>. Disponível em: <<https://br.blackboardopenlms.com/resource/x-ray-learning-analytics/>>.

MILLIGAN, C. Delivering staff and professional development using virtual learning environments. *The Role of Virtual Learning Environments in the Online Delivery in the Online Delivery Staff Developments*, 1999.

MOJAVEZI, A.; TAMIZ, M. P. The impact of teacher self-efficacy on the students' motivation and achievement. *Theory and Practice in Language Studies*, v. 2, n. 3, p. 483–491, 2012.

MOODLE. *Survey settings*. 2017. <https://docs.moodle.org/32/en/Survey_settings#COLLES_-_Constructivist_On-Line_Learning_Environment_Surve>. Disponível em: <https://docs.moodle.org/32/en/Survey_settings#COLLES_-_Constructivist_On-Line_Learning_Environment_Surve>.

MOODLE. *About Moodle*. 2020. <https://docs.moodle.org/38/en/About_Moodle>. Disponível em: <https://docs.moodle.org/38/en/About_Moodle>.

MOODLE. *Managing roles*. 2020. <https://docs.moodle.org/38/en/Managing_roles>. Disponível em: <https://docs.moodle.org/38/en/Managing_roles>.

MUIJS, D. State of the art – teacher effectiveness and professional learning. *Journal School Effectiveness and School Improvement*, v. 25, n. 2, p. 231–256, 2014.

NAIMIE, S.; SIRAJ, S. Have you heard about the new fashion? (tailoring your lesson plan based on learners preferences). *Procedia - Social and Behavioral Sciences*, v. 46, p. 5840–5844, 2012.

NGANG, T. K.; YIE, C. S. Quality teaching: Relationship to soft skills acquisition. *Procedia - Social and Behavioral Sciences*, v. 191, p. 1934–1937, 2015.

NOGUEIRA, S. M. Andragogy: contributions to educational practice? *LINHAS*, 2004.

OLIVEIRA, G. G.; BATISTA, G. A. Andragogia e aprendizagem na modalidade de educação a distância - contribuições da neurociência. *ResearchGate*, 2017.

PASSINI, S.; MOLINARI, L. A validation of the questionnaire on teacher interaction in italian secondary school students: the effect of positive relations on motivation and academic achievement. *Social Psychology of Education*, v. 18, 2015.

PICCIANO, A. G. Beyond students perceptions: Issues of interaction, presence, and performance in online courses. In: . [S.l.]: Journal of Asynchronous Learning Network, 2002. v. 6.

PIERRAKEAS, C. A comparative study of dropout rates and causes for two different distance education courses. In: . [S.l.]: IRRODL, 2004.

POWELL, A.; RABBITT, B.; KENNEDY, K. Inacol blended learning teacher competency framework. *ERIC*, 2014.

PRICE, B. Defining quality student feedback in distance learning. In: . [S.l.]: Journal of Advanced Nursing, 1997. v. 26, p. 154–160.

R, F. *The R Project for Statistical Computing*. 2018. <<https://www.r-project.org/>>. Disponível em: <<https://www.r-project.org/>>.

RAMSDEN, P. A performance indicator of teaching quality in higher education: The course experience questionnaire. In: . [S.l.]: Studies in Higher Education, 2006. v. 16, p. 50–129.

SANTÍN, D.; SICILIA, G. Using dea for measuring teachers performance and the impact on students outcomes: evidence for spain. *Journal of Productivity Analysis*, v. 49, p. 1–15, 2018.

SHUKLA, T.; NIRBAN, V. S.; DOSAYA, D. Experience and qualifications: A study on attributes of teacher professionalism. *Proceedings of the 2018 The 3rd International Conference on Information and Education Innovations*, p. 45–48, 2018.

- STES, A.; MAEYER, S. D. Instructional development for teachers in higher education: Effects on students' learning outcomes. *Teaching in Higher Education*, v. 17, n. 3, p. 295–308, 2012.
- STUBBS, M. *Language, Schools, and Classrooms*. 2nd. ed. [S.l.]: Routledge, 1990.
- SVETLANA, M. S. S. Characteristics and activities of teachers on distance learning programs that affect their ratings. In: . [S.l.]: IRRODL, 2014. v. 15.
- TJGO, T. d. J. d. G. Resolução nº 40/2015. TJGO, 2015.
- TJGO, T. d. J. d. G. Decreto judiciário nº 105/2016. TJGO, 2016.
- TJGO, T. d. J. d. G. Plano de capacitação 2017 - 2019. 2017.
- TRAINA, A. J. M.; JÚNIOR, C. T. Visualização de dados em sistemas de bases de dados relacionais. *ICMC-USP*, 2001.
- VIPIN, K.; MICHAEL, S.; PANG-NING, T. *Introduction to Data Mining*. 3. ed. The address: Addison-Wesley, 2005. v. 4. (10, v. 4). An optional note. ISBN 8573937610.
- WAISMAN, T. Corporate universities and distance learning - a critical analyze by the communication stand point: are the workers really learning? In: . [S.l.]: pucsp, 2015.
- WALKER, R. J. Twelve characteristics of an effective teacher: A longitudinal, qualitative, quasi-research study of in-service and pre-service teachers' opinions. *ERIC*, v. 87, n. 1, p. 61–68, 2018.
- WEKA. *The workbench for machine learning*. 2020. <<https://waikato.github.io/weka-wiki/>>. Disponível em: <<https://www.r-project.org/>>.
- YOU, S.; DANG, M. Effects of student perceptions of teachers motivational behavior on reading, english, and mathematics achievement: The mediating role of domain specific self-efficacy and intrinsic motivation. *Child and Youth Care Forum*, v. 45, n. 2, p. 1–20, 2016.
- ZAKHAROV, A.; CARNOY, M. Which teaching practices improve student performance on high stakes exams evidence from russia. *International Journal of Educational Development*, v. 36, 2014.
- ZHANG, L.; LAI, F. The impact of teacher training on teacher and student outcomes: Evidence from a randomised experiment in beijing migrant schools. *Journal of Development Effectiveness*, 2013.
- ÇAKIR, H.; BICHELMEYER, B. A. Effects of teacher professional characteristics on student achievement: an investigation in blended learning environment with standards-based curriculum. *Interactive Learning Environments*, v. 24, n. 1, p. 20–32, 2016.

Análise Completa de Desempenho dos Classificadores

Este apêndice apresenta os resultados das análises de desempenho dos classificadores selecionados (seção 4.8.7) para comparação de performance e possível implementação na extensão do MP. A análise de desempenho entre os classificadores foi realizada a partir da confrontação dos valores de performance obtidos pelos classificadores para as principais métricas de desempenho disponibilizadas pela ferramenta WEKA (seção 2.2.2).

Todos os parâmetros necessários para execução dos classificadores estão descritos na tabela A.1. As análises foram conduzidas utilizando a ferramenta WEKA Explorer apresentada na seção 2.2.4.

- (1) trees.J48 '-C 0.25 -M 2' -217733168393644444
- (2) trees.RandomForest '-P 100 -I 100 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1' 1116839470751428698
- (3) trees.RandomTree '-K 0 -M 1.0 -V 0.001 -S 1' -9051119597407396024
- (4) rules.JRip '-F 3 -N 2.0 -O 2 -S 1' -6589312996832147161
- (5) rules.PART '-M 2 -C 0.25 -Q 1' 8121455039782598361
- (6) rules.DecisionTable '-X 1 -S \"BestFirst -D 1 -N 5\"' 2888557078165701326
- (7) rules.OneR '-B 6' -3459427003147861443
- (8) functions.MultilayerPerceptron '-L 0.3 -M 0.2 -N 500 -V 0 -S 0 -E 20 -H a' -5990607817048210779
- (9) functions.SimpleLogistic '-I 0 -M 500 -H 50 -W 0.0' 7397710626304705059
- (10) bayes.NaiveBayes '' 5995231201785697655
- (11) bayes.BayesNet '-D -Q bayes.net.search.local.K2 --P 1 -S BAYES -E bayes.net.estimate.SimpleEstimator --A 0.5' 746037443258775954

Tabela A.1: *Parâmetros passado aos Classificadores.*

A.1 Análise Sem Inclusão das Ações dos Tutores

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS	0.84	0.87 ◦	0.84	0.75 •	0.85	0.75 •	0.74 •	0.86 ◦	0.85	0.83	0.84
CURSOS-6-SEMANAS	85.18	86.32	84.22	85.71	85.58	84.51	76.83 •	79.43 •	86.57	76.90 •	82.24 •
CURSOS-7-SEMANAS	93.25	92.93	92.84	93.68	93.29	93.90	93.40	93.51	93.67	66.91 •	79.40 •

◦, • statistically significant improvement or degradation

Tabela A.2: Análise da métrica Acurácia para o conjunto de predição da EJUG.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS	74.74	75.70	73.97	74.58	74.69	74.89	74.64	74.54	74.94	47.63 •	52.87 •
CURSOS-6-SEMANAS	0.82	0.84 ◦	0.82	0.81	0.83	0.83	0.64 •	0.83	0.81	0.63 •	0.74 •
CURSOS-7-SEMANAS	0.99	0.99	0.99	1.00	0.99	1.00	0.99	0.99	1.00	0.65 •	0.79 •

◦, • statistically significant improvement or degradation

Tabela A.3: Análise da métrica True Positive Rate (TP) para o conjunto de predição da EJUG.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS	0.90	0.87	0.86 •	0.96 ◦	0.88	0.95 ◦	0.97 ◦	0.95	0.95 ◦	0.06 •	0.15 •
CURSOS-6-SEMANAS	0.10	0.10	0.13	0.07	0.10	0.13	0.03 •	0.25	0.05 •	0.01 •	0.05 •
CURSOS-7-SEMANAS	0.98	0.99	0.93	1.00	0.95	0.92	0.92	0.93	0.99	0.03 •	0.15 •

◦, • statistically significant improvement or degradation

Tabela A.4: Análise da métrica False Positive Rate (FP) para o conjunto de predição da EJUG.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS	0.75	0.76	0.76	0.75	0.76	0.75	0.74 •	0.75	0.75	0.93 ◦	0.89 ◦
CURSOS-6-SEMANAS	0.93	0.93	0.91	0.95	0.93	0.91	0.97 ◦	0.88	0.97 ◦	0.99 ◦	0.96 ◦
CURSOS-7-SEMANAS	0.94	0.94	0.94	0.94	0.94	0.94	0.94	0.94	0.94	1.00 ◦	0.99 ◦

◦, • statistically significant improvement or degradation

Tabela A.5: Análise da métrica Precision para o conjunto de predição da EJUG.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS	0.98	0.98	0.95 •	1.00 ◦	0.97	1.00 ◦	1.00 ◦	0.99	1.00 ◦	0.31 •	0.41 •
CURSOS-6-SEMANAS	0.82	0.84 ◦	0.82	0.81	0.83	0.83	0.64 •	0.83	0.81	0.63 •	0.74 •
CURSOS-7-SEMANAS	0.99	0.99	0.99	1.00	0.99	1.00	0.99	0.99	1.00	0.65 •	0.79 •

◦, • statistically significant improvement or degradation

Tabela A.6: Análise da métrica Recall para o conjunto de predição da EJUG.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS	0.85	0.86	0.84	0.85	0.85	0.85	0.85	0.85	0.85	0.47	0.56
CURSOS-6-SEMANAS	0.87	0.88	0.86	0.87	0.87	0.87	0.77	0.83	0.88	0.77	0.83
CURSOS-7-SEMANAS	0.96	0.96	0.96	0.97	0.97	0.97	0.97	0.97	0.97	0.78	0.88

○, ● statistically significant improvement or degradation

Tabela A.7: Análise da métrica *F-Measure* para o conjunto de predição da EJUG.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS	0.17	0.22	0.16	0.17	0.17	0.19	0.19	0.18	0.19	0.25	0.25
CURSOS-6-SEMANAS	0.71	0.73	0.68	0.73	0.71	0.69	0.61	0.60	0.75	0.62	0.68
CURSOS-7-SEMANAS	0.03	-0.04	0.02	-0.03	0.01	0.21	0.05	0.11	0.14	0.30	0.34

○, ● statistically significant improvement or degradation

Tabela A.8: Análise da métrica *MCC* para o conjunto de predição da EJUG.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS	0.69	0.73	0.70	0.52	0.71	0.53	0.52	0.69	0.69	0.66	0.67
CURSOS-6-SEMANAS	0.90	0.94	0.87	0.90	0.90	0.91	0.80	0.92	0.93	0.85	0.90
CURSOS-7-SEMANAS	0.70	0.90	0.81	0.50	0.78	0.77	0.53	0.88	0.58	0.86	0.85

○, ● statistically significant improvement or degradation

Tabela A.9: Análise da métrica *AUC* para o conjunto de predição da EJUG.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS	0.84	0.87	0.84	0.75	0.85	0.75	0.74	0.86	0.85	0.83	0.84
CURSOS-6-SEMANAS	0.91	0.96	0.88	0.91	0.91	0.94	0.84	0.95	0.96	0.91	0.94
CURSOS-7-SEMANAS	0.96	0.99	0.98	0.94	0.97	0.97	0.94	0.99	0.95	0.99	0.98

○, ● statistically significant improvement or degradation

Tabela A.10: Análise da métrica *PRC* para o conjunto de predição da EJUG.

A.2 Análise com a Inclusão das Ações dos Tutores

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS-ANDRAGOGIA	76.27	76.10	75.10	75.27	75.90	76.54	76.07	76.05	76.45	47.24	50.71
CURSOS-6-SEMANAS-ANDRAGOGIA	88.88	89.31	87.65	88.93	89.01	87.21	77.80	87.04	89.81	71.95	82.89
CURSOS-7-SEMANAS-ANDRAGOGIA	94.60	95.46	95.52	94.69	95.14	95.17	95.35	95.48	94.80	76.35	79.46

○, ● statistically significant improvement or degradation

Tabela A.11: Análise da métrica *Acurácia* para o conjunto de predição com dados dos tutores.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS-ANDRAGOGIA	0.99	0.99	0.98	1.00 ◦	0.98	1.00 ◦	1.00 ◦	0.99	1.00 ◦	0.31 •	0.39 •
CURSOS-6-SEMANAS-ANDRAGOGIA	0.85	0.86 ◦	0.85	0.84	0.85	0.83	0.66 •	0.83	0.85	0.89	0.74 •
CURSOS-7-SEMANAS-ANDRAGOGIA	0.99	0.99	0.98	0.98	0.98	0.99	0.99	0.99	0.99	0.76 •	0.79 •

◦, • statistically significant improvement or degradation

Tabela A.12: Análise da métrica True Positive Rate (TP) para o conjunto de predição com dados dos tutores.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-6-SEMANAS-ANDRAGOGIA	0.04	0.05	0.08	0.04	0.05	0.07	0.03	0.07	0.03	0.55 ◦	0.04
CURSOS-7-SEMANAS-ANDRAGOGIA	0.90	0.69	0.62 •	0.79	0.66	0.89	0.83	0.66	0.88	0.16 •	0.10 •

◦, • statistically significant improvement or degradation

Tabela A.13: Análise da métrica False Positive Rate (FP) para o conjunto de predição com dados dos tutores.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS-ANDRAGOGIA	0.77	0.76	0.76	0.75 •	0.76	0.76	0.76 •	0.76	0.76	0.95 ◦	0.89 ◦
CURSOS-6-SEMANAS-ANDRAGOGIA	0.97	0.96	0.95	0.97	0.96	0.95	0.97	0.96	0.98	0.74 •	0.97
CURSOS-7-SEMANAS-ANDRAGOGIA	0.96	0.97	0.97 ◦	0.96	0.97	0.96	0.96	0.97	0.96	0.99 ◦	0.99 ◦

◦, • statistically significant improvement or degradation

Tabela A.14: Análise da métrica Precision para o conjunto de predição com dados dos tutores.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS-ANDRAGOGIA	0.99	0.99	0.98	1.00 ◦	0.98	1.00 ◦	1.00 ◦	0.99	1.00 ◦	0.31 •	0.39 •
CURSOS-6-SEMANAS-ANDRAGOGIA	0.85	0.86 ◦	0.85	0.84	0.85	0.83	0.66 •	0.83	0.85	0.89	0.74 •
CURSOS-7-SEMANAS-ANDRAGOGIA	0.99	0.99	0.98	0.98	0.98	0.99	0.99	0.99	0.99	0.76 •	0.79 •

◦, • statistically significant improvement or degradation

Tabela A.15: Análise da métrica Recall para o conjunto de predição com dados dos tutores.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS-ANDRAGOGIA	0.86	0.86	0.85 •	0.86	0.86	0.87	0.86	0.86	0.86	0.47 •	0.54 •
CURSOS-6-SEMANAS-ANDRAGOGIA	0.90	0.91	0.89	0.90	0.90	0.89	0.78 •	0.89	0.91 ◦	0.80 •	0.84 •
CURSOS-7-SEMANAS-ANDRAGOGIA	0.97	0.98	0.98	0.97	0.97	0.98	0.98	0.98	0.97	0.86 •	0.88 •

◦, • statistically significant improvement or degradation

Tabela A.16: Análise da métrica F-Measure para o conjunto de predição com dados dos tutores.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS-ANDRAGOGIA	0.18	0.16	0.11	0.09	0.16	0.23	0.22	0.18	0.22	0.27	0.23
CURSOS-6-SEMANAS-ANDRAGOGIA	0.79	0.79	0.76	0.79	0.79	0.75	0.62 •	0.75	0.81 ◦	0.41 •	0.69 •
CURSOS-7-SEMANAS-ANDRAGOGIA	0.19	0.39	0.46	0.25	0.36	0.26	0.33	0.41	0.20	0.27	0.32

◦, • statistically significant improvement or degradation

Tabela A.17: Análise da métrica MCC para o conjunto de predição com dados dos tutores.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS-ANDRAGOGIA	0.67	0.73 ◦	0.70	0.50 •	0.71 ◦	0.53 •	0.52 •	0.72 ◦	0.73 ◦	0.71	0.69
CURSOS-6-SEMANAS-ANDRAGOGIA	0.92	0.95 ◦	0.90	0.92	0.93	0.91	0.81 •	0.94 ◦	0.94 ◦	0.88 •	0.91
CURSOS-7-SEMANAS-ANDRAGOGIA	0.62	0.96 ◦	0.85 ◦	0.60	0.81 ◦	0.76	0.58	0.93 ◦	0.80 ◦	0.87 ◦	0.90 ◦

◦, • statistically significant improvement or degradation

Tabela A.18: Análise da métrica AUC para o conjunto de predição com dados dos tutores.

Dataset	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
CURSOS-5-SEMANAS-ANDRAGOGIA	0.83	0.88 ◦	0.85	0.75 •	0.86 ◦	0.76 •	0.76 •	0.88 ◦	0.88 ◦	0.86 ◦	0.85 ◦
CURSOS-6-SEMANAS-ANDRAGOGIA	0.93	0.96 ◦	0.91	0.92	0.93	0.93	0.84 •	0.96 ◦	0.96 ◦	0.92	0.94
CURSOS-7-SEMANAS-ANDRAGOGIA	0.97	1.00 ◦	0.99 ◦	0.96	0.98 ◦	0.98 ◦	0.96	0.99 ◦	0.98 ◦	0.99 ◦	0.99 ◦

◦, • statistically significant improvement or degradation

Tabela A.19: Análise da métrica PRC para o conjunto de predição com dados dos tutores.

4g. Em geral, a ferramenta executou suas funções adequadamente.

Discordo —————— Concordo

4h. Essa ferramenta me auxiliaria em minhas atividades.

Discordo —————— Concordo

4i. Essa ferramenta auxiliaria em minhas atividades.

Discordo —————— Concordo

4j. Eu recomendaria essa ferramenta para outros gestores e educadores.

Discordo —————— Concordo

4b. Quais recomendações você gostaria de sugerir para os desenvolvedores da ferramenta?
