



Programa de Pós-Graduação em
Computação Aplicada
Mestrado/Doutorado Acadêmico

LÍDIA MARTINS DA SILVA

**ATHENA: UM MODELO COMPUTACIONAL PARA SERVIÇOS
INTELIGENTES NA EDUCAÇÃO A DISTÂNCIA USANDO HISTÓRICOS DE
CONTEXTOS**

São Leopoldo, 2024

Lídia Martins da Silva

**ATHENA: UM MODELO COMPUTACIONAL PARA SERVIÇOS
INTELIGENTES NA EDUCAÇÃO A DISTÂNCIA USANDO
HISTÓRICOS DE CONTEXTOS**

Tese apresentada como requisito parcial para a obtenção
do título de Doutor pelo Programa de Pós-Graduação em
Computação Aplicada (PPGCA) da Universidade do
Vale do Rio dos Sinos — UNISINOS

Orientador: Prof. Dr. Jorge Luis Victória Barbosa

Coorientador: Prof. Dr. Sandro José Rigo

São Leopoldo

2024

S586a

Silva, Lídia Martins da.

Athena : um modelo computacional para serviços inteligentes na educação a distância usando históricos de contextos / por Lídia Martins da Silva. – 2024.

216 f. : il. ; 30 cm.

Tese (doutorado) — Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, São Leopoldo, RS, 2024.

Orientador: Dr. Jorge Luis Victória Barbosa.

Coorientador: Dr. Sandro José Rigo.

1. Serviços inteligentes.
2. Ambiente virtual de aprendizagem.
3. Contexto.
4. Histórico de contexto.
5. Educação a distância.
6. Estudantes.

I. Título.
CDU: 004.3:37.018.43

Catalogação na Publicação (CIP):
Bibliotecário Alessandro Dietrich - CRB 10/2338

Esta tese é dedicada as pessoas mais importantes em minha vida: minha filha Amanda Martins dos Santos. Sua existência me fez ser uma pessoa melhor, dedicada e forte. Sua alegria, força e bondade sempre me motivou a lutar, mesmo nos momentos mais dificeis. Sempre me apoiou e compreendeu as minhas dificuldades e ausências e ao meu neto Miguel Martins Decol que chegou no momento mais difícil da minha vida, me trouxe alegrias e aumentou as minhas forças para lutar e vencer os problemas que surgiram neste período.

Amo vocês hoje e sempre!

AGRADECIMENTOS

À Deus, pela vida, por tudo que conquistei até agora, por me fazer acreditar que tudo é possível quando se tem amor, dedicação, esforço, perseverança e determinação.

Agradeço ao meu pai, Isidoro Martins Reberte (*in memorian*), e à minha mãe, Ercília Aparecida da Silva Martins (*in memorian*), por terem sido os alicerces que me sustentaram com determinação diante dos desafios que surgiram. Agradeço por todos os ensinamentos e exemplos que me proporcionaram, pois sem eles não teria alcançado meus objetivos. Reconheço-os como a base fundamental da minha educação e carreira, e sou grato pelo amor incondicional que sempre me dedicaram.

À minha querida filha, Amanda Martins dos Santos, pelo constante e generoso amor que sempre me dedicou e por me brindar com o melhor presente "um neto... lindo e amoroso"... meu pequeno Miguel Martins Decol.

Aos meus familiares, pelo apoio e carinho inabaláveis, por permanecerem ao meu lado em todos os momentos, sejam eles de alegrias, tristezas ou dificuldades.

Expresso minha profunda gratidão ao prof. Dr. Jorge Luis Victória Barbosa, meu orientador, exemplo de profissionalismo ao me guiar nos momentos mais difíceis deste projeto. Gratidão pelos ensinamentos e incentivos ao longo dos quatro anos que se passaram.

Gratidão ao prof. Dr. Sandro José Rigo, meu coorientador, pelas contribuições e disponibilidade ao longo deste processo.

Aos estimados professores da banca, cuja aceitação do convite e valiosas contribuições enriqueceram sobremaneira a qualidade deste trabalho.

Não posso deixar de mencionar meus amigos: Emiliano Monteiro, Nitzia, Maria Eloisa Mignoni, Andresa Vargas, Ivo Brites, Deivid Padilha, Waldeci Campos, Ed Wilson, Marcos Guilherme Goulart, Emilton Varanda Júnior, Fernanda Santana Ferreira, Naara Beatriz de Souza e Silva, Cardinale de Paula Campos, Claudete Terezinha May e Anedino Rodrigues Júnior que estiveram ao meu lado nos momentos alegres e desafiadores e aprendi que a caminhada não é solitária, quando se tem amigos como eles. A força dessa amizade foi um dos fatores determinantes que me impulsionaram a superar obstáculos e concluir este trabalho.

Expresso minha gratidão a todos os meus colegas e a cada pessoa que, de forma direta ou indireta, desempenharam um papel importante na concretização deste projeto.

RESUMO

O ambiente educacional tem passado por inúmeras transformações e dentre elas, a ampliação e a democratização do ensino. A Educação a Distância (EaD) visa oferecer um processo de ensino e aprendizagem completo, dinâmico e eficiente, mediado por recursos tecnológicos. A EaD vem crescendo e assumindo um papel importante no meio educacional e tem se apresentado de suma importância na expansão e no acesso ao ensino superior, impulsionada pelo uso das Novas Tecnologias da Informação e da Comunicação (NTIC) e em novos comportamentos no processo de ensino e aprendizagem. No entanto, a alta taxa de evasão em cursos a distância tem causado muitas preocupações, pois nem todos os alunos que ingressam em um curso conseguem chegar até o final por diferentes motivos. A evasão ocorre em todas modalidades de ensino, seja presencial, semipresencial e a distância, tanto em instituições públicas ou privadas. No entanto, a EaD precisa de um olhar mais profundo, visto que a mesma é mediada por tecnologias. Diante desse contexto, a presente tese propõe o Athena, um modelo computacional genérico para serviços inteligentes focados na EaD baseados em históricos de contextos. O modelo tem como objetivo auxiliar gestores e professores no planejamento estratégico, permitindo acompanhar o progresso acadêmico do aluno, bem como auxiliar alunos com dificuldades no processo de aprendizagem através de recomendações de sites, materiais didáticos complementares, vídeos, entre outros recursos. A oferta de serviços inteligentes tem como objetivo oferecer soluções, tais como: monitoramento, intervenção, recomendação, formação de grupos de estudos, motivação e melhoria no processo de aprendizagem dos alunos, evitar reprovão e consequentemente na redução na taxa de evasão. O modelo utiliza uma ontologia para representação do conhecimento no domínio da educação a distância. Além disso, explora elementos do contexto dos alunos que são utilizados na composição de históricos de contextos. A análise de históricos de contextos é usada para personalizar serviços que entregam informações úteis para a EaD. Um protótipo do Athena foi criado e testado com informações de 25 alunos matriculados no curso de Tecnologia em Análise e Desenvolvimento de Sistemas, respaldando a implementação e avaliação de dois serviços inteligentes, o *Forecasting* para prever o desempenho acadêmico dos alunos e o *Grouping* para formação de grupo de estudos. Os resultados obtidos reforçam a hipótese de que é possível desenvolver um modelo computacional que suporte de forma genérica a criação e uso de serviços inteligentes para educação a distância tendo como base os históricos de contextos dos alunos.

Palavras-chave: Serviços inteligentes. Ambiente virtual de aprendizagem. Contexto. Histórico de Contexto. Educação a distância.

ABSTRACT

The educational environment has undergone numerous transformations and among them, the expansion and democratization of teaching. Distance Education aims to offer a complete, dynamic and efficient teaching and learning process, mediated by technological resources. It has been growing and assuming an important role in the educational environment. It has been of paramount importance in the expansion and access to higher education, driven by the use of New Information and Communication Technologies (NICT) and new behaviors in the teaching and learning process. However, the high dropout rate in distance courses has caused many concerns, as not all students who enroll in a course manage to reach the end for different reasons. Evasion occurs in all teaching modalities, whether face-to-face, blended and distance learning, both in public and private institutions. However, distance education needs a deeper look, since it is mediated by technologies. Given this context, this thesis proposal proposes the development of a computational model for intelligent services focused on distance education based on historical contexts. The model aims to assist managers and teachers in strategic planning, allowing them to monitor the student's academic progress, as well as assist students with difficulties in the learning process through website recommendations, complementary teaching materials, videos, among other resources. The aim of offering intelligent services is to offer solutions such as: monitoring, intervention, recommendation, formation of study groups, motivation and improvement in the students' learning process, avoiding failure and consequently reducing the dropout rate. The model uses an ontology to represent knowledge in the field of distance education. Furthermore, it explores elements of the students' context that are used in composing context histories. Context history analysis is used to personalize services that deliver useful information for distance learning. An Athena prototype was created and tested with information from 25 students enrolled in the Technology in Systems Analysis and Development course, supporting the implementation and evaluation of two intelligent services, Forecasting to predict students' academic performance and Grouping for training study group. The results obtained reinforce the hypothesis that it is possible to develop a computational model that generically supports the creation and use of intelligent services for distance education based on students' context histories.

Keywords: Intelligent Services. Virtual learning environment. Context. Historic of Context. Distance education.

LISTA DE FIGURAS

Figura 1: Busca inicial, aplicação de critérios, junção, remoção e resultado	51
Figura 2: Densidade do <i>cluster</i>	85
Figura 3: Conexões do <i>cluster</i> azul	86
Figura 4: Conexões do <i>cluster</i> verde	87
Figura 5: Conexões do <i>cluster</i> vermelho	88
Figura 6: Conexões do <i>cluster</i> amarelo	89
Figura 7: Visão geral da relação entre os termos.....	90
Figura 8: Questões de pesquisa versus objetivos dos artigos mapeados	91
Figura 9: Bases de publicações.....	92
Figura 10: Publicação por ano e por base de busca.....	93
Figura 11: Países de publicação.....	94
Figura 12: Visão geral da arquitetura Athena.....	109
Figura 13: Atores e serviços do modelo Athena.....	113
Figura 14: Arquitetura Geral do Athena.....	117
Figura 15: Interação com o modelo	118
Figura 16: Modelo de Dados	119
Figura 17: Exemplo de histórico de contextos	121
Figura 18: Mapa conceitual dos principais conceitos da OntoAthena	132
Figura 19: Conceitos Educação a Distância, Ambiente Virtual, Alunos, Serviços Inteligentes e demais elementos.....	134
Figura 20: Passos definidos na construção da OntoAthena.....	136
Figura 21: Classes da OntoAthena	140
Figura 22: Hierarquia das classes	141

Figura 23: Classes <i>Context</i> , <i>ContextHistories</i> , <i>user</i> , <i>Profile</i> , <i>StudyHabits</i> , <i>service</i> e subclasses	143
Figura 24: Classes <i>Competence</i> , <i>Evaluation</i> , <i>Risk</i> , <i>Activity</i> , <i>Learning</i> , <i>Tools</i> , <i>TypeDlProblems</i> e subclasses.....	144
Figura 25: Classes da OntoAthena e seus relacionamentos	146
Figura 26: Expressões lógicas	148
Figura 27: Exemplo de Instâncias	150
Figura 28: Regras inferidas.....	152
Figura 29: Resultado sobre Evasão ou Reprovação na OntoAthena.....	153
Figura 30: Resultado da inferência - Escore de risco	153
Figura 31: Consulta SPARQL para alto risco de reprovação ou evasão	154
Figura 32: Resultado da consulta SPARQL alto risco de reprovação ou evasão	155
Figura 33: Consulta SPARQL para risco moderado de reprovação ou evasão	156
Figura 34: Resultado da consulta SPARQL para risco moderado de reprovação ou evasão	156
Figura 35: Consulta SPARQL para baixo risco de reprovação ou evasão	157
Figura 36: Resultado da consulta SPARQL para baixo risco de reprovação ou evasão	157
Figura 37: Consulta SPARQL para hábitos de estudos ou comportamento.....	158
Figura 38: Resultado da Consulta SPARQL para hábitos de estudos ou comportamento	159
Figura 39: Tela inicial do Modelo Athena.....	163
Figura 40: Tela do serviço de predição - <i>Forecasting</i>	164
Figura 41: Tela do serviço para Formação de Grupos de Estudos - <i>Grouping</i>	165
Figura 42: Tela do serviço de Monitoramento - <i>Monitoring</i>	167
Figura 43: Tela de cadastro do serviço de Recomendação - <i>Recommending</i>	168
Figura 44: Tela de conteúdo do serviço de Recomendação - <i>Recommending</i>	169
Figura 45: Exemplo da base de dados	171
Figura 46: Resultado da análise de predição	177
Figura 47: Resultado da Formação de grupos de estudos	181

LISTA DE TABELAS

Tabela 1: Questões de pesquisa	48
Tabela 2: Definição de termos de pesquisa	49
Tabela 3: Bases de dados pesquisados	49
Tabela 4: Critérios de inclusão (CI) e exclusão (CE).....	50
Tabela 5: Relação dos artigos mapeados.....	51
Tabela 6: Relação dos artigos com métodos/técnicas de análise de dados	59
Tabela 7: Relação dos artigos que contêm serviços inteligentes.....	74
Tabela 8: Relação dos artigos que contêm métodos de análise utilizando históricos de registros	82
Tabela 9: Principais <i>clusters</i> , termos e números de ocorrência.....	85
Tabela 10: Comparativo dos trabalhos relacionados	98
Tabela 11: Comparaçao de trabalhos relacionados	128
Tabela 12: Perguntas e respostas ao tema focal	130
Tabela 13: Lista de propriedades da OntoAthena	146
Tabela 14: Regras SQWRL para inferência de risco de reprovação ou evasão	148
Tabela 15: Métricas da OntoAthena	150

LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
BD	Banco de Dados
COM	<i>Ontological Constraints Manager</i>
DAML	<i>Darpa agent markup language</i>
DLL	<i>Linguagem de logica de descrição</i>
DLN	<i>Developmental Learning Networks</i>
DPU	<i>Duhok Polytechnic University</i>
EaD	Educação a Distância
EM	<i>Expectation-Maximization</i>
EQN	<i>Exercises Q-Network</i>
EQNM	<i>Exercices Q-Network Markov</i>
EQNR	<i>Exercices Q-Network Recurrent</i>
ER	<i>Entidade Relacionamento</i>
ETL	<i>Extract Transform Load</i>
FACT	<i>Fully Automated Compiling Technique</i>
FSLSM	<i>Felder-Silverman Learning Style Model</i>
HTML	<i>HyperText Markup Language</i>
IA	Inteligência Artificial
IDE	<i>Integrated Development Environment</i>
IOT	<i>Internet of Things</i>
KNN	<i>K-nearest neighbors</i>
LA	<i>Learning Analytics</i>
LBA	<i>Learner Behavior Analytics</i>
LBPN	<i>Learning Behavioral Petri Nets</i>

LMS	<i>Learning Management System</i>
MGT	<i>Mixed term chart</i>
ML	<i>Machine learning</i>
MLP	<i>Multi-layer Perceptron</i>
MOOC	<i>Massive Open Online Course</i>
OAT	<i>Ontomarkup Annotation Tool</i>
OCML	<i>Operational Conceptual Modelling Language</i>
OER	<i>Open Educational Resources</i>
OIL	<i>Ontology Inference Layer</i>
OilEd	<i>Ontology Editor for the Semantic Web</i>
OWL	<i>Web Ontology Language</i>
PCA	<i>Principal Component Analysis</i>
PPGCA	Programa de Pós-Graduação em Computação Aplicada
RDF	<i>Resource Description Framework</i>
RDFs	<i>Resource Description Framework Schema</i>
REA	Recursos Educacionais Abertos
RNN	<i>Recurrent Neural Network</i>
SDN	<i>software defined network</i>
SGA	Sistemas de Gerenciamento de Aprendizagem
SEDM	Sistema de Mineração de Dados Educacionais
SPARQL	<i>Simple Protocol and RDF Query Languag</i>
SQL	<i>Structured Query Language</i>
SVM	<i>Support Vector Machine</i>
SVR	<i>Support Vector Regression</i>
SWRL	<i>Semantic Web Rule Language</i>
TAM	<i>Technical Architecture Modeling</i>

TIC	Tecnologias da Informação e da Comunicação
TI	Tecnologia da Informação
UML	<i>Unified Modeling Language</i>
UNISINOS	Universidade do Vale do Rio dos Sinos
WebODE	<i>Workbench for ontological engineering that eases the modelling of ontologies</i>
WebOnto	<i>Editing Ontologies on the Web</i>
W3C	<i>World Wide Web Consortium</i>
XML	<i>Extensible Markup Language</i>

SUMÁRIO

1 INTRODUÇÃO	17
1.1 Definição do problema e questão de pesquisa.....	19
1.2 Objetivos.....	21
1.2.1 Objetivo Geral	21
1.2.2 Objetivos Específicos.....	21
1.3 Metodologia.....	22
1.4 Organização da tese	22
2 FUNDAMENTAÇÃO TEÓRICA.....	24
2.1 Educação a distância	24
2.2 Ambientes virtuais de aprendizagem	26
2.3 Serviços inteligentes	28
2.4 Learning Analytics.....	30
2.5 Contexto e Históricos de Contextos	33
2.6 Ontologia e Web Semântica.....	36
2.6.1 Componentes de uma ontologia	39
2.6.2 Tipos de ontologia.....	40
2.6.3 Metodologias.....	43
2.6.4 Motores de inferência	45
2.7 Considerações sobre o capítulo	46
3 TRABALHOS RELACIONADOS	47
3.1 Procedimentos metodológicos	47
3.1.1 Questões de Pesquisa.....	48
3.1.2 Termos de buscas	48
3.1.3 Processo de seleção.....	50
3.2 Resultados e discussões	51
3.2.1 QG1 – Quais métodos/técnicas de análise de dados vêm sendo aplicados em ambientes de educação à distância?	54
3.2.2 QG2 – Quais tipos de serviços inteligentes vêm sendo oferecidos no âmbito da EaD?	60
3.2.3 QG3 – Quais estratégias vêm sendo aplicadas para obtenção de benefícios para discentes, docentes e gestores por meio da análise de dados no âmbito da EaD?	77
3.2.4 QF1 – Existem métodos/técnicas de análise que vêm utilizando históricos de registros de logs dos alunos no âmbito da EaD?	80
3.2.5 QF2 - Existem serviços inteligentes para grupos colaborativos de alunos na área de educação à distância?	83
3.2.6 FQ3 - Quais são as tendências percebidas?	84
3.2.7 QE1 – Em quais bases de dados os trabalhos foram publicados?	92
3.2.8 QE2 – Onde os trabalhos foram desenvolvidos?	93

3.3 Trabalhos selecionados e comparativo.....	94
3.4 Considerações sobre o capítulo	107
4 MODELO ATHENA.....	108
4.1 Visão Geral	108
4.2 Casos de Uso	112
4.3 Arquitetura Athena	116
4.4 Modelo de dados.....	118
4.5 Um Cenário de histórico de contextos	121
4.6 Considerações sobre o capítulo	122
5 ONTOLOGIA ONTOATHENA	123
5.1 Trabalhos relacionados às Ontologias na Educação a Distância.....	123
5.2 Mapa conceitual da OntoAthena	129
5.3 Construção da OntoAthena	135
5.4 Determinar o domínio e o escopo da OntoAthena	137
5.5 Reutilização de ontologias existentes	138
5.6 Termos importantes da ontologia	138
5.7 Classes e hierarquias da OntoAthena	138
5.8 Definir as propriedades das classes.....	145
5.9 Definir as regras (restrições de propriedades).....	147
5.10 Criar as instâncias	149
5.11 Avaliação da Ontologia	151
5.11.1 QC1: Qual aluno tem alto risco de reprovar ou abandonar o curso?	154
5.11.2 QC2: Qual aluno tem risco moderado de abandonar o curso?	155
5.11.3 QC3: Qual aluno tem baixo risco de reprovar ou abandonar o curso?	157
5.11.4 QC4: Quais são os hábitos de estudos ou padrão de comportamento do aluno que abandona o curso?	158
5.12 Considerações sobre o capítulo	159
6 AVALIAÇÃO E RESULTADOS.....	161
6.1 Problematização	161
6.2 Descrição do Protótipo	162
6.3 Avaliação	170
6.3.1 Cenário de Avaliação.....	170
6.3.2 Forecasting- Serviço inteligente para prever o desempenho acadêmico dos alunos	172
6.3.3 Grouping - Serviço inteligente para formação de grupos de estudos.....	178
6.4 Considerações sobre o capítulo	181
7 CONCLUSÃO.....	182
7.1 Considerações Finais.....	182
7.2 Contribuições.....	183
7.3 Limitações e trabalhos futuros.....	185
7.4 Publicações	186

REFERÊNCIAS.....	188
ANEXO A - PARECER COMITÊ DE ÉTICA	214

1 INTRODUÇÃO

O mundo vive um período de significativas mudanças na sociedade contemporânea — especialmente, pelo surgimento de tecnologias digitais que perpassam e afetam às diferentes instâncias sociais, como é o caso da esfera educacional. Com isso, a educação tem sido provocada a repensar e dar um novo significado às suas práticas pelo uso conjuntivo de múltiplas tecnologias nos ambientes escolares, como recursos subsidiadores para os processos de ensino-aprendizagem na era digital.

O avanço da Educação a Distância (EaD) se configura pelo aporte tecnológico disponível em Ambientes Virtuais de Aprendizagem (AVA), também conhecidos como Sistemas de Gerenciamento de Aprendizagem (SGA), que potencializam o dinamismo, a proatividade e a personalização do processo de ensino-aprendizagem (DIAS, 2017), permitindo a interação entre os agentes do processo e a interatividade do material disponibilizado para os estudos.

De forma geral, o número de dispositivos conectados apresentou crescimento exponencial e, se o foco for colocado sobre o acesso ao AVA, esse fenômeno também se aplica na geração de grandes volumes de dados conforme discutido por Cambruzzi; Rigo; Barbosa (2015). Esse grande volume de dados ultrapassa a capacidade das instituições de entendê-los, fazendo pouco uso dessas informações que são geradas pelos alunos.

A utilização de AVA gera grandes volumes e diferentes tipos de dados e as instituições de ensino podem tirar vantagens dessas informações que são coletadas, analisadas e utilizadas em diferentes sistemas computacionais. As informações geradas podem ser organizadas em históricos de contextos e disponibilizá-las para análises futuras (LARENTIS et al., 2021); (VIELITZ et al., 2019); (RODRIGUES et al., 2022); (MACHADO et al., 2021); (GARCIA MARTINS et al., 2021); (MARTINI et al., 2021); (ARANDA et al., 2021); (WIEDEMANN et al., 2020); (FILIPPETTO; LIMA; BARBOSA, 2021); (LIMA et al., 2022).

Os dados gerados nos AVA podem ser utilizados para analisar o comportamento e prever o desempenho dos alunos, analisar frequências e notas para identificar o andamento da aprendizagem e obter melhorias no processo educacional, através de ferramentas como *Learning Analytics* (LA), oferecendo melhores experiências de aprendizagem aos alunos através de *feedback* e suportes oportunos. Para Joksimovic; Kovanovic; Dawson (2019), a LA

usa os dados de aprendizagem disponíveis dos alunos para estabelecer indicadores iniciais de perda de alunos e desempenho acadêmico.

Informações como atividades realizadas, dispositivos, localização, tempo, idioma, hábitos de estudos, interatividades, estilo de aprendizagem, mídias de aprendizagem, dados socioeconômicos, entre outros, podem compor o perfil do aluno. Os dados armazenados podem ser utilizados para auxiliar professores, administradores e tutores nas resoluções de problemas que ocorrem nos ambientes de aprendizagem, além de fornecer estratégias de aprimoramento ou melhorias de cursos EaD através de serviços inteligentes.

LA tem como objetivo avaliar os dados gerados a partir da execução de cursos, como participação em ambientes virtuais de aprendizagem, frequência e notas para identificar situações como o andamento da aprendizagem e comportamento dos alunos com o intuito de melhorar o ensino (DIAS, 2017).

O armazenamento, análise e interpretação apropriada dos dados são os pontos iniciais para o desenvolvimento de serviços inteligentes (ACATECH, 2018) e podem ser personalizados de acordo com os requisitos de cada usuário.

Segundo Koldewey et al. (2019), os serviços inteligentes foram descritos pela primeira vez por Allmendinger; Lombreglia (2005) que os entendem como serviços baseados em dados e que esses serviços digitais conectados a objetos inteligentes, permitem uma comunicação contínua, *feedback* interativo e soluções por meio de análise de dados (KOLDEWEY et al., 2020) e de acordo com Beverungen (et al., 2019) produtos inteligentes permitem a cocriação de serviços inteligentes como monitoramento, otimização, controle e adaptação autônoma de produtos.

Esses serviços inteligentes auxiliam as instituições na tomada de decisões de curto, médio e longo prazo. Os sistemas também possibilitam ações para melhorar o processo de ensino e aprendizagem e reduzir o índice de reprovação e evasão. Esses sistemas identificam as características e perfis dos alunos e predizem seu comportamento (ZAOUDI; BELHADAOUUI, 2020), habilidades cognitivas (ANGELINE; RAMASUBRAMANIAN; JAMES, 2020), sucesso acadêmico (KIM; KIM, 2020; HASHIM; AWADH; HAMOUD, 2020), desempenho (IATRELLIS et al., 2021), estilos de aprendizagem (EL FOUKI; AKNIN; EL. KADIRI, 2017) e potencial abandono (CHEN et al., 2020a; FREITAS et al., 2020).

Embora os serviços inteligentes ofereçam potencial para novas oportunidades de negócios e criação de valor, é essencial identificar oportunidades de inovação concretas para serviços inteligentes em primeiro lugar. Somente então uma empresa ou instituição poderá alcançar ou manter sua vantagem competitiva (KOLDEWEY et al., 2020).

Diante das considerações apresentadas, é estratégico que as instituições busquem adaptações e desenvolvam abordagens computacionais que estejam sintonizadas com os desafios enfrentados pelos estudantes. Isso implica em conceber sistemas que possam efetivamente enriquecer o processo de ensino e aprendizagem, aproveitando as vantagens das mais recentes tecnologias e aprimorando a excelência da EaD, tudo isso tendo em mente as vivências dos estudantes nos ambientes virtuais de aprendizagem.

1.1 Definição do problema e questão de pesquisa

Atualmente tem se falado em serviços inteligentes e como eles podem contribuir nos processos de ensino e aprendizagem, principalmente em cursos a distância (KAPEMBE; QUENUM, 2020); (JOY; RAJ; G, 2019); (DAHDOUH et al., 2019); (HUANG et al., 2019); (KIM; KIM, 2020); (WANG; SUN; CHEN, 2019); (HASHIM; AWADH; HAMOUD, 2020); (VILLEGAS CH; ROMÁN CAÑIZARES; PALACIOS PACHECO, 2020) (VILLEGAS CH; ARIAS NAVARRETE; PALACIOS PACHECO, 2020); (NIKNAM; THULASIRAMAN, 2020); (FREITAS et al., 2020); (BARLYBAYEV et al., 2020a); (LIN; LI; LIAN, 2020); (CHEN et al., 2020a); (CHEN et al., 2020b); (KHOSRAVI; SADIQ; GASEVIC, 2020a); (RAJKUMAR; GANAPATHY, 2020); (MAÂLOUL; BAHOU, 2021); (NUGURI et al., 2021); (HAN; XU, 2021); (MENDES et al., 2021).

Uma revisão sistemática foi realizada no período de janeiro de 2010 a junho de 2020, com o objetivo de identificar como LA e os serviços inteligentes vêm sendo aplicados em ambientes EaD (SILVA; BARBOSA; RIGO, 2021). Nessa revisão, 51 artigos foram analisados, e observou-se que a maioria dos trabalhos apresentaram diferentes serviços inteligentes. Posteriormente foi realizado um mapeamento sistemático que teve como foco a análise de aprendizagem e grupos colaborativos de alunos em EaD (SILVA et al., 2022).

A pesquisa anteriormente conduzida passou por uma expansão e aprimoramento significativos, culminando na sua publicação em um periódico internacional como uma revisão de literatura abordando a aplicação de serviços inteligentes na área de EaD (SILVA et al., 2021). Apesar das pesquisas terem identificado diversos serviços inteligentes, este estudo

revelou uma lacuna relacionada à ausência de modelos computacionais abordando a utilização de históricos de contextos em diferentes tipos de serviços inteligentes.

Dessa forma, o presente trabalho apresenta um modelo computacional para serviços inteligentes com foco em educação a distância baseado no uso dos históricos de contextos. O modelo contribui com o suporte à criação de diferentes serviços usando históricos de contextos de usuários dos cursos à distância que estão armazenados nas bases de dados dos ambientes virtuais. A partir disso, a presente pesquisa buscou responder a seguinte questão de pesquisa:

Como seria um modelo computacional que suportasse de forma genérica a criação e uso de serviços inteligentes para educação a distância tendo como base os históricos de contextos dos alunos?

Após a definição da questão de pesquisa é defendida a seguinte hipótese: O modelo desenvolvido é genérico, pois o mesmo não é específico apenas para um tipo de serviço. O modelo computacional genérico embasado em registros contextuais, é capaz de abrigar uma variedade de serviços inteligentes, proporcionando auxílio tanto a educadores envolvidos na educação à distância quanto aos estudantes no processo de ensino e aprendizagem.

A vantagem fundamental desse modelo para a educação a distância reside na habilidade de empregar históricos de contextos para estruturar e sistematizar informações acerca dos usuários de cursos a distância. Essa utilidade se manifesta em função do volume substancial de dados que são preservados nos registros de atividades dos ambientes virtuais.

Esses dados podem ser coletados, analisados e processados, gerando informações úteis sobre os perfis de estudantes, comportamentos ou previsão de comportamentos (MACHADO et al., 2021), proporcionando tomadas de decisões assertivas e permitindo utilizar essas informações no desenvolvimento de programas institucionais de combate à evasão através de políticas de retenção no decorrer do curso, com planejamento de ações, acompanhamento de resultados e coleta de experiências bem-sucedidas, além disso, fornecendo uma aprendizagem personalizada e adaptada às características de cada aluno através de diferentes serviços inteligentes.

1.2 Objetivos

Nesta seção serão apresentados o objetivo geral e os específicos alcançados no desenvolvimento da tese.

1.2.1 Objetivo Geral

O objetivo geral desta tese consistiu na criação de um modelo computacional genérico para serviços inteligentes na educação a distância baseados em históricos de contextos que auxilie instituições, professores e alunos no processo de ensino e aprendizagem.

1.2.2 Objetivos Específicos

Este estudo definiu os seguintes objetivos específicos para orientar o processo de investigação e atingir o objetivo principal:

- a) realizar um estudo sobre o estado da arte de sistemas inteligentes, educação a distância, ambientes virtuais de aprendizagem, *learning analytics* e históricos de contextos e como estes podem ser utilizados na educação a distância;
- b) identificar trabalhos relacionados a ontologias na área da educação a distância através de uma pesquisa bibliográfica para conhecer as metodologias, domínios, assim como avaliações realizadas;
- c) desenvolver uma ontologia (OntoAthena) focada no domínio de serviços inteligentes para educação a distância baseados em históricos de contextos;
- d) projetar um modelo genérico (Athena) para serviços inteligentes no ensino a distância baseado em históricos de contextos;
- e) avaliar a ontologia por meio da análise de consistência e completude, juntamente com a abordagem das questões de competência;
- f) avaliar o modelo por meio da elaboração de um protótipo contendo elementos que viabilizem sua utilização;

1.3 Metodologia

Após definição de um modelo computacional para promover serviços inteligentes com o uso de históricos de contextos para EaD e a construção de um protótipo foi possível fazer uma avaliação para o teste da hipótese definida na seção 1.1, através de dois serviços inteligentes. Para isso, foram realizadas as seguintes etapas:

- a) na primeira etapa foram realizados os estudos sobre os temas básicos da pesquisa, tais como Educação a Distância, Ambientes Virtuais de Aprendizagem, *Learning Analytics*, Serviços Inteligentes, Históricos de Contextos e Ontologias;
- b) a segunda etapa envolveu a pesquisa dos trabalhos relacionados sobre a utilização de modelos computacionais para serviços inteligentes. Um mapeamento sistemático da literatura foi realizado utilizando-se de palavras-chave sobre temas estratégicos com objetivos de identificar lacunas e oportunidades de pesquisas na aplicação da computação para assistência educacional na modalidade a distância;
- c) na terceira etapa foi especificado o modelo, incluindo a definição conceitual, sua arquitetura e o modelo de dados;
- d) a quarta etapa envolveu a pesquisa dos trabalhos relacionados sobre ontologias para EaD, a elaboração do mapa conceitual e a definição e implementação da OntoAthena. Além disso, realizou-se uma avaliação por meio de motores de inferência e consultas SPARQL;
- e) na etapa final, os resultados foram documentados e as publicações da tese foram consolidadas. As conclusões foram enfatizadas, juntamente com as contribuições e limitações do modelo, bem como sugestões para trabalhos futuros.

1.4 Organização da tese

Esta tese está organizada em sete capítulos, sendo que, no capítulo 1, encontra-se a introdução, definição do problema e questões de pesquisa, objetivos, metodologia e organização da proposta. Os demais capítulos são apresentados a seguir:

O capítulo 2 apresenta a fundamentação teórica, que trata dos principais conceitos utilizados neste trabalho. Neste capítulo, são descritos os conceitos referentes a educação a

distância, ambientes virtuais de aprendizagem, *learning analytics*, serviços inteligentes e históricos de contextos.

O capítulo 3 expõe os estudos correlatos, fornecendo um levantamento abrangente acerca da análise de dados e serviços inteligentes empregados na EaD. Isso compreende uma parcela significativa de um estudo sistemático voltado para a análise do processo de aprendizagem e a dinâmica de grupos colaborativos de alunos em contextos educacionais virtuais. Além disso, abrange segmentos específicos da revisão da literatura dedicada aos serviços inteligentes aplicados na EaD (SILVA; BARBOSA; RIGO, 2021; SILVA et al., 2021; SILVA et al., 2022).

O capítulo 4 apresenta o modelo computacional para serviços inteligentes utilizando históricos de contextos dos alunos da EaD; O capítulo 5 introduz a OntoAthena, uma ontologia para representar o conhecimento no domínio da EaD e ofertas de serviços inteligentes baseados em históricos de contextos e a avaliação da ontologia contendo inferências e consultas;

O capítulo 6 apresenta os serviços inteligentes desenvolvidos e os seus resultados e o capítulo 7 apresenta as conclusões finais, contendo as contribuições, limitações, trabalhos futuros, publicações, e por fim as referências utilizadas e anexo.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo sistematiza os principais conceitos básicos utilizados para desenvolvimento do modelo computacional apresentado nessa tese, intitulado Athena. Primeiramente são abordados conceitos sobre Educação a Distância e Ambientes Virtuais de Aprendizagem. Em seguida é apresentada uma breve descrição sobre Serviços Inteligentes e *Learning Analytics*. Posteriormente são abordados os conceitos de Contextos e Históricos de contextos, tópicos estratégicos no desenvolvimento de serviços inteligentes. Por fim, são apresentados conceitos principais sobre *Web Semântica* e Ontologias.

2.1 Educação a distância

Em um mundo globalizado a EaD passou a ocupar uma posição de destaque, na qual a mediação didático-pedagógica nos processos de ensino e aprendizagem ocorre através da utilização de tecnologias, de forma flexível, com professores e alunos desenvolvendo atividades em diferentes locais e horários.

Para Cambruzzi; Rigo; Barbosa (2015), alguns objetivos relevantes dos cursos de EaD dependem da interação do aluno, geralmente suportada por ferramentas de mediação digital e elementos de mídia digital. Na maior parte dos cursos EaD também ocorrem atividades de interação em grupo, relacionadas ao desenvolvimento de diversas habilidades importantes dos alunos.

A EaD pode ser entendida como a modalidade educacional em que a mediação didático pedagógica nos processos de ensino e aprendizagem ocorre com a utilização de tecnologias da informação e da comunicação (TICs), com atividades educativas desenvolvidas por estudantes e educadores que estejam em lugares e tempos diversos (BRASIL, 2017).

Segundo Kara et al. (2019), a EaD é definida como as atividades planejadas de ensino e aprendizagem fornecidas por meio do uso de um canal de comunicação dentro de uma organização institucional, sem qualquer limitação de tempo e lugar.

A educação a distância é caracterizada pelo ensino e aprendizagem remotos, onde o aluno está fisicamente separado do professor enquanto participa de uma atividade de aprendizagem planejada (BERGDAHL; NOURI, 2021).

Bertiz; Kocaman Karoglu (2020), definem EaD como atividade de ensino em que o aluno e o professor estão em locais diferentes e a educação é ministrada simultaneamente ou em diferentes momentos usando as TICs atuais. Segundo os autores, a EaD torna-se possível devido ao fato de que pode ser realizada independente de horário e local. A EaD oferece ambientes de aprendizagem flexíveis e eficientes, permitindo que os alunos estudem independentemente de localização e horário. Esse formato possibilita que os estudantes aprendam no seu próprio ritmo, de maneira não linear, facilitando a aprendizagem autônoma (BERTIZ; KOCAMAN KAROGLU, 2020).

Existe uma variedade de conceitos de EaD, mas todos apontam para as principais características desta modalidade educacional: não presencial, não compartilham os mesmos espaços físicos, estudam em tempos diversos e são mediadas por tecnologias capazes de gerenciar várias atividades envolvidas nos processos educacionais.

A EaD tem desempenhado um papel significativo nos processos de aprendizagem dos alunos, exigindo ambientes tecnológicos capazes de gerenciar uma ampla gama de atividades envolvidas no processo educacional. Consequentemente, ela gera uma grande quantidade de dados que podem ser utilizados como matéria-prima para pesquisas, devido ao alto nível de mediação digital (CAMBRUZZI; RIGO; BARBOSA, 2015), como registros de acesso, diversas interações com o sistema, mensagens em fóruns, entre outros. No entanto, grande parte desses dados não são analisados, o que se constitui uma lacuna significativa para a realização de pesquisas, dada a quantidade de informações valiosas que potencialmente podem ser extraídas (RABELO; CAMPOS; SILVA, 2021).

Romero; Ventura (2020), afirmam que o gerenciamento de dados é um dos maiores desafios das instituições de ensino, uma vez que tem crescido exponencialmente. De acordo com Waheed et al. (2020), os dados educacionais foram substanciados como um campo de estudo multidisciplinar envolvendo várias disciplinas de pesquisa, gerando diversos termos associados a esta exploração de dados educacionais, tais como análise acadêmica, análise preditiva, análise de aprendizagem e, por fim, ciência de dados educacionais. De acordo com Ramos et al. (2018), os dados extraídos de ambientes virtuais podem indicar as características comportamentais dos alunos e, portanto, permite análises inferenciais e preditivas baseadas na tecnologia.

A modalidade a distância contribui para o desenvolvimento da autonomia do aluno. Além disso, a utilização da tecnologia da informação (TI) oferece conhecimento de maneira

rápida e ampla, estimulando o aluno a buscar novos conhecimentos e atribuindo a ele um perfil ativo em relação à aprendizagem (FERNÁNDEZ-LÓPEZ et al., 1999).

Traxler (2018), aponta que a EaD exige a autonomia do aluno e se associada ao uso da tecnologia da informação, promove o conhecimento de forma rápida e ampla, estimulando o aluno a buscar novos conhecimentos.

Segundo Kara et al. (2019), os alunos podem gerenciar os processos de aprendizagem onde e quando desejarem por meio dos ambientes de aprendizagem *online*. Além disso, os alunos têm a oportunidade de se envolver em mais interação por meio das ferramentas de discussão e bate-papo, entre outras, oferecidas por ambientes de aprendizagem *online*, podendo assim, desenvolver habilidades de formação de equipes virtuais e controlar seus próprios processos de aprendizagem.

Yilmaz Ince; Kabul; Diler (2020), afirmam que, apesar das inúmeras vantagens da EaD, como disponibilidade, flexibilidade, economia de dinheiro e tempo, além de conjuntos específicos de conhecimentos e habilidades, ainda há muitos problemas que precisam de soluções. Entre esses problemas estão a qualidade do ensino, o uso indevido da tecnologia e as atitudes de instrutores, alunos e administradores. Segundo os autores, desvantagens como a falta de interação ou participação social, podem causar um sentimento de isolamento, enquanto a ausência de ambiente social pode minimizar a motivação e interação e agravar o processo de aprendizagem.

2.2 Ambientes virtuais de aprendizagem

Ao se tratar de EaD, vale destacar o uso de ambientes virtuais de aprendizagem (AVA) ou sistema de gerenciamento de aprendizagem (SGA) que amparam os processos educacionais. Esses ambientes oferecem diferentes recursos de aprendizagem, tais como: compartilhamento de conteúdo, desenvolvimento de atividades e a comunicação entre as pessoas envolvidas no processo de ensino e aprendizagem (ANDRADE; RIGO; BARBOSA, 2022).

Segundo Wang et al. (2020), os AVA incluem uma gama significativa de tecnologias, fornecendo uma infinidade de funcionalidades, recursos e possibilidades. O escopo das

modalidades em um AVA é conhecido por ser uma das influências mais significativas e diretas na eficácia de um mundo virtual em termos de ensino e aprendizagem.

Nos ambientes virtuais de aprendizagem, existe um grande número de atividades realizadas pelos alunos que são de fundamental importância para facilitar o trabalho dos tutores por meio da utilização de ferramentas tecnológicas (ALENCAR; NETTO, 2020). O uso desses ambientes contribui na geração de dados que podem ser analisados e transformados em conhecimentos e utilizados pelas instituições no aprimoramento dos processos de ensino e aprendizagem.

Segundo Moran J. M; Behrens (2013), AVA são tecnologias organizadas e ordenadas, e por isso permitem que se tenha certo controle de quem acessa o ambiente e do que é preciso realizar em cada etapa de um curso.

De acordo com Anjos (2015), os AVA são espaços virtuais estruturados, dotados de recursos tecnológicos e imbuídos de significados pedagógicos que possibilitam uma ressignificação das práticas educacionais pela ocorrência de interações e mediações entre os sujeitos do processo educativo.

Segundo Alshammari (2020), os AVA são projetados para oferecer recursos de aprendizagem adequados e relevantes para apoiar o processo de aprendizagem. O principal desafio na concepção de AVA é descobrir a abordagem apropriada necessária para atender as necessidades, motivação e preferências dos alunos, e para entregar uma experiência de aprendizagem mais personalizada, com potencial para criar melhorias significativas no ensino e aprendizagem.

Almeida Maia; Silva (2020), definem AVA como um *software* computacional que integra diferentes mídias e recursos e por meio da internet possibilita a veiculação de informação, o armazenamento e compartilhamento de dados, a comunicação síncrona e assíncrona, além de contribuir na geração de dados digitais que podem ser analisados para avaliar o comportamento dos alunos, transformados em conhecimentos úteis e ajudar os gestores e professores a melhorar o processo de aprendizagem dos alunos.

Waheed et al. (2020), definem AVA como um *software* computacional que agrupa diferentes mídias e recursos, permitindo a propagação de informações. Permite o armazenamento, recuperação e distribuição de dados, bem como a comunicação bidirecional síncrona e assíncrona, contribuindo para a geração de dados digitais que podem ser usados na

avaliação dos alunos. As interações dos alunos em ambientes virtuais de aprendizagem são de suma importância. Os dados gerados pelas interações dos alunos podem ser analisados por meio de técnicas de inteligência Artificial (IA) para estimular e motivar os alunos, além de identificar emoções diversas, como frustração, isolamento, desânimo e desmotivação (ALENCAR; NETTO, 2020).

Segundo Clow (2013), existe uma grande quantidade de dados disponíveis sobre os usuários, devido ao aumento da utilização de ambientes de aprendizagem *online*. Nesse sentido, o uso crescente dos AVA fornece ferramentas para desenvolver padrões de aprendizagem adaptáveis ao perfil do usuário (GASEVIC; KOVANOVIC; JOKSIMOVIC, 2017). A crescente adoção e sofisticação de tecnologias educacionais na aprendizagem e no ensino proporcionaram uma busca paralela no uso e análise de dados de alunos (CLOW, 2013). A adoção em larga escala de SGA forneceu novas oportunidades para reunir análise de dados, *design* de aprendizagem e tecnologia para repensar e desenvolver os modelos de aprendizagem adaptativa e personalizada (GASEVIC; KOVANOVIC; JOKSIMOVIC, 2017).

2.3 Serviços inteligentes

De acordo com Cummaudo et al. (2019) e Hosseini et al. (2017), ao contrário dos serviços convencionais da *web*, os serviços inteligentes são desenvolvidos com componentes baseados em IA. Esses componentes são diferentes dos paradigmas tradicionais de engenharia de *software*, pois são dependentes de dados e não derivam em resultados determinísticos.

Esses serviços fazem previsões futuras sobre novos dados com base exclusivamente em seu conjunto de dados de treinamento; sendo os resultados expressos como probabilidades de que a inferência feita corresponda a rótulos em seus dados de treinamento (CUMMAUDO et al., 2019).

Segundo Cummaudo et al. (2019), esses serviços são frequentemente comercializados como em constante evolução e aprimoramento. Isso significa que seus grandes conjuntos de dados de treinamento podem atualizar continuamente os classificadores de predição que fazem as inferências, resultando em dados probabilísticos e não determinísticos. Serviços inteligentes são serviços digitais, que se baseiam nos dados gerados por um produto físico e fornecem valor para as partes interessadas (KOLDEWEY et al., 2020).

Serviços de valor agregado baseados em novas possibilidades técnicas, por exemplo: plataformas digitais e análise de dados são chamadas de serviços inteligentes (FRANK et al., 2019). Esses serviços baseados em TI usam os dados dos produtos físicos correspondentes para gerar valor (PALUCH, 2017).

Almeida Neto (2017), define serviço inteligente como sendo a instanciação de uma tarefa inteligente dentro de um sistema computacional de forma a ser oferecido o seu acesso a outros sistemas computacionais e Marquardt (2017), apresenta cinco características para definir os serviços inteligentes:

- Conexão entre o mundo físico e o digital;
- Atualização da criação de valor e eficiência econômica;
- Extensão de produtos e serviços em nível digital;
- Transformação do produto em parte do serviço;
- Mudança de modelos de negócios centrados no produto para modelos de negócios centrados no cliente.

O projeto *Smart Urban Services* definiu serviços inteligentes como serviços adaptados a casos de uso específicos de clientes com ajuda de dados e processamento inteligente (HERMANN, 2016). É por isso que para o *design* e desenvolvimento de serviço inteligente é essencial entender o cliente e seu entorno, ter dados e plataformas inteligentes para integrar e processar os dados e mudar os modelos de negócios e a mentalidade da empresa.

Na área de computação, serviços inteligentes referem-se a soluções e sistemas que utilizam tecnologias avançadas, tais como IA, aprendizado de máquina e processamento de linguagem para oferecer funcionalidades automatizadas, melhorando a eficiência e a tomada de decisões. Exemplos incluem assistentes virtuais, recomendações personalizadas, processamento de linguagem natural, análise avançada de dados, visão computacional, sistemas de recomendação, automação de processos, aprendizado de máquina em saúde, carros autônomos e segurança cibernética inteligente. Esses serviços estão transformando diversos setores, proporcionando soluções eficientes e adaptativas, com perspectiva de evolução contínua.

2.4 Learning Analytics

O surgimento do termo *Learning Analytics* (LA) foi definido formalmente na primeira conferência internacional em 2011 (LAK11: *Proceedings of the 9th International Conference on Learning Analytics & Knowledge*), realizado em Banff, Canadá. O congresso reuniu cerca de cem pesquisadores de todo o mundo com foco na compreensão da aprendizagem dos alunos através do uso de aprendizado de máquina, *data mining* e métodos de visualização de dados (DAWSON et al., 2019; JOKSIMOVIC; KOVANOVIC; DAWSON, 2019).

Para Joksimovic; Kovanic; Dawson (2019), LA é considerada um campo de pesquisa que abrange várias disciplinas. Baseia-se em teorias e métodos de aprendizado de máquina e ciência de dados, educação, psicologia cognitiva, estatística, ciência da computação, neurociência e ciências sociais e de aprendizagem, entre outros. Ela visa identificar, por meio da extração e análise de dados de forma automática, perfis de alunos, problemas ou padrões com um determinado conteúdo programático, reconhecimento entre o sucesso e insucesso de trajetórias de aprendizagem, detecção de lições complexas, entre outras.

LA estuda o processo de aprendizagem para otimizar as oportunidades de aprendizagem. Refere-se à aplicação de técnicas analíticas para analisar dados educacionais, tais como, dados sobre as atividades do aluno e do professor, a identificação de padrões de comportamento e o fornecimento de informações que possam ser utilizadas para melhorar o aprendizado.

Segundo Viberg; Khalil; Baars (2020), LA está preocupada em medir, coletar, analisar e relatar dados para melhorar as experiências de aprendizagem dos alunos e otimizar a aprendizagem e os ambientes em que ela ocorre.

De acordo com Andrade; Rigo; Barbosa (2022), LA é um campo de pesquisa em rápido crescimento, focado no desenvolvimento e aplicação de processos e ferramentas para coletar, explorar e analisar grandes quantidades de dados, para entender melhor o comportamento de aprendizagem dos alunos, ajudar os professores a dar melhor suporte e intervenções adequadas e, finalmente, melhorar a qualidade da aprendizagem e do ensino, bem como os resultados educacionais

LA refere-se à aplicação de técnicas analíticas para analisar dados educacionais, como dados sobre atividades de alunos e professores, a identificação de padrões de comportamento e o fornecimento de informações que podem ser usadas para melhorar a aprendizagem (CAMBRUZZI; RIGO; BARBOSA, 2015) e para Romero; Ventura (2020), LA pode ser definida como a medição, coleta, análise e relatório de dados sobre os alunos e seus contextos, com o propósito de compreender e otimizar a aprendizagem e os ambientes em que ocorre. De acordo com os autores, existem três elementos cruciais envolvidos nesta definição: dados, análise e ação.

Segundo Matcha et al. (2020), LA concentra-se na coleta, análise e relatório de dados sobre alunos e contextos nos quais a aprendizagem ocorre. A LA faz uso de métodos de ciência de dados para analisar dados e relatar os resultados da análise com diferentes abordagens visuais e textuais.

Para Larrabee Sonderlund; Hughes; Smith (2019), LA integra vários tipos de dados, como por exemplo, comportamento de aprendizagem e ensino, desempenho acadêmico, *status* socioeconômico, análise estatística e modelagem preditiva para informar as intervenções na forma como os alunos aprendem, os professores ensinam e as instituições educacionais elaboram seus currículos.

Segundo Aldowah; Al-Samarraie; Fauzy (2019), LA é normalmente aplicada para identificar problemas de aprendizagem, avaliando as interações dos alunos e os resultados de aprendizagem. As informações resultantes dessas avaliações podem ajudar a estimar ou alterar o nível de suporte necessário para aumentar a autoconsciência dos alunos sobre a atividade e o conteúdo.

O uso da LA para analisar os comportamentos de aprendizagem e as interações dos alunos com os recursos do curso pode facilitar a avaliação da eficácia educacional e auxiliar na concepção de estratégias de intervenção para melhorar as habilidades cognitivas dos alunos (ALDOWAH; AL-SAMARRAIE; FAUZY, 2019).

De acordo com Waheed et al. (2020), por meio de plataformas de análise de aprendizagem, LA apoia estratégias pedagógicas, oferecendo opiniões e recomendações em tempo real por meio de painéis de análise de aprendizagem e sistemas de visualização de AVA.

Os dados de atividades relacionadas ao curso, como fóruns de discussão, entrega de conteúdo e avaliação, podem ser usados para associar objetos de nível de sistema às preferências dos alunos, fornecendo uma oportunidade para o instrutor obter uma visão abrangente dos possíveis resultados da aprendizagem, bem como descobrir comportamentos indesejáveis entre os alunos quando ocorre um controle inadequado sobre o processo de aprendizagem (ALDOWAH; AL-SAMARRAIE; FAUZY, 2019).

LA usa dados educacionais e os traduz em informações úteis para a tomada de decisão, com base em respostas e registros da vida acadêmica dos alunos disponíveis em plataformas de aprendizagem *online* (WAHEED et al., 2020). Esses sistemas de *feedback* auxiliam na construção de uma plataforma mais robusta para medir, examinar e prever o envolvimento do aluno, contribuindo com a aprendizagem autorregulada e impulsionando fatores motivacionais para regular o cumprimento de metas bem-sucedidas.

Segundo Dias (2017), LA permite avaliar o aluno de forma mais assertiva com base nas respostas inseridas na plataforma de ensino e nos registros de sua vida acadêmica, pode ser transformado em análises possíveis de serem cruzadas e obter resultados. LA tem como objetivo fornecer aos educadores, alunos e tomadores de decisão uma visão prática para as atividades em sala de aula e em nível de curso.

Em resumo, LA é uma área que se concentra na coleta, análise e interpretação de dados relacionados ao processo de ensino e aprendizagem. Ela utiliza técnicas de análise de dados, estatísticas e tecnologias de informação para extrair *insights* e informações valiosas sobre como os estudantes estão aprendendo, como os professores estão ensinando e como os sistemas educacionais estão funcionando.

Seu objetivo é otimizar a experiência de aprendizagem em níveis individuais e coletivos, através de dados como interações *online*, resultados de testes e participação em aulas. Isso permite o monitoramento do progresso dos alunos, identificação de padrões, personalização do ensino, previsão de desempenho, avaliação de cursos e melhoria contínua do processo de ensino e aprendizagem.

2.5 Contexto e Históricos de Contextos

O uso de ambientes virtuais deixa rastros de interações praticadas pelos usuários, tais como registros das entradas dos usuários, atividades realizadas, materiais acessados, identificação do equipamento utilizado, tempo de acesso, eventos, entre outros que são armazenados na forma de históricos e que podem conter informações úteis.

De acordo com Sudhana; Raj; Suresh (2013), o tema contexto surgiu em muitas áreas de aplicações de computador e se tornou um importante tópico de pesquisa relacionado ao domínio do *e-learning*. O contexto em sistemas de *e-learning* é utilizado para personalização, adaptação e recomendação de material de aprendizagem adequado ao usuário de acordo com estratégias como, em que situação o aluno se encontra, qual é o seu ambiente de aprendizagem e qual é o seu modo ou estilo de leitura.

De acordo Sudhana; Raj; Suresh (2013), fatores contextuais podem se referir a muitas coisas. No ambiente de *e-learning*, o contexto pode ser visto da perspectiva do aluno, considerando todos os fatores que influenciam o estilo de aprendizagem do aluno. Fatores contextuais no ambiente de *e-learning* pode estar relacionado ao domínio, atividade ou ambiente de aprendizagem.

Segundo Dey (2001), contexto pode ser caracterizado como qualquer informação que possa ser usada para descrever as circunstâncias referentes a uma entidade, tais como pessoas, locais ou objetos. Uma entidade é um usuário, um local ou um objeto físico ou computacional considerado relevante para a interação entre um usuário e um aplicativo, incluindo o próprio usuário e o aplicativo.

De acordo com Aranda et al. (2021), contexto caracteriza qualquer informação relacionada a pessoas (por exemplo, indivíduos ou grupos) e informações relacionadas a coisas, em particular, dispositivos vestíveis e recursos computacionais. Segundo D'Avila; Farias; Barbosa (2020), os contextos têm atributos, como identidade, *status*, data e hora. Todas essas informações ajudam a determinar a ordem cronológica em que os eventos ocorreram e essa ordem cronológica compõe os históricos de contextos.

Para Heckler e Barbosa (2022), contexto é um conjunto de informações que pode caracterizar circunstâncias de entidades, como uma pessoa, objeto ou lugar. Geralmente, o contexto trata da localização, identidade e estado de pessoas, grupos e objetos físicos e

computacionais e de acordo com Barbosa et al. (2018) e Dupont; Barbosa; Alves (2020), históricos de contextos podem ser usados para obtenção de mais informações sobre a entidade.

Segundo Filippetto (2020), o contexto de um usuário pode conter um número grande de informações, como por exemplo, atributos do local físico, estado fisiológico, o estado emocional, história pessoal, padrões de comportamento, entre outros. De acordo com o autor, uma questão fundamental é obter informações diversas a respeito dos usuários, ambientes físicos, *hardware* e *software* para que funcione de uma maneira ciente de contexto.

Um contexto é um termo vasto que pode considerar vários aspectos; por exemplo, o círculo social de um usuário, hora, humor, local, clima, empresa, gênero e idioma. Normalmente, o comportamento de classificação dos usuários varia em diferentes contextos (IQBAL et al., 2019).

De acordo com Mayrhofer (2005), os históricos de contextos, quando registrados a longo prazo, oferecem uma variedade de possibilidades para melhorar os serviços oferecidos por algum sistema de computador. Segundo o autor, essas possibilidades compreendem inferência das ações atualizadas e passadas do usuário, seleção de dispositivos, entre outros.

Históricos de contextos são dados temporais passados de contextos específicos dos usuários. Os modelos de previsão têm a capacidade de inferir os contextos futuros dos usuários ao analisar esses dados passados com as informações presentes. A computação sensível a contextos permite a análise dos históricos de contextos para compreender o passado, avaliar o presente através do contexto atual, perfil do usuário, ou ambos, e antecipar o futuro por meio da predição de contextos, utilizando os dados atuais e passados de uma entidade como base (GÁRCIA MARTINS et al., 2021).

Um sistema é considerado consciente do contexto quando utiliza o contexto para disponibilizar informações e/ou serviços relevantes para o usuário, sendo que a relevância depende da tarefa do usuário (DEY,2001). Para adquirir informações de contextos, Abowd; Mynatt (2000) identificaram cinco dimensões fundamentais:

- Quem: Essa dimensão considera informações de contextos relacionadas a outros usuários e aspectos sociais presentes em um ambiente compartilhado, que devem ser utilizadas pelos sistemas.

- O que: A capacidade de perceber e interpretar as ações do usuário é essencial. Identificar o que um usuário está fazendo em um momento específico é uma tarefa considerada altamente complexa.
- Onde: A localização é um elemento crítico nos sistemas conscientes do contexto. Essa informação está também associada a outras dimensões, como o aspecto temporal (quando) e a identificação (quem), proporcionando novas funcionalidades às aplicações. O uso dessas informações pode dar origem a inúmeras situações diferentes para o usuário.
- Quando: O aspecto temporal é utilizado para organizar os registros capturados ou para informar por quanto tempo um usuário permaneceu em um local específico.
- Por que: A capacidade de compreender o motivo por trás das ações do usuário representa um dos principais desafios da computação consciente do contexto e envolve o raciocínio em relação às outras dimensões mencionadas.

As informações úteis encontradas nos históricos de contextos, tais como preferências, hábitos dos usuários, padrões, entre outros, podem ser utilizados em serviços automatizados, personalizados e inteligentes. Além disso, os históricos de contextos podem ser usados para melhorar as recomendações e fornecer análises com base nas atividades anteriores dos usuários (HUET et al., 2021), permitindo principalmente previsão de contextos, personalização de conteúdo ou cursos, recomendar ações aos usuários com base na análise de similaridade de contexto e para melhorar a experiência do usuário (SANTOS et al., 2021; FILIPPETTO; LIMA; BARBOSA, 2021).

Resumindo, históricos de contextos são registros cronológicos que descrevem eventos e ações ao longo do tempo, moldando uma situação específica. São usados para entender desenvolvimentos, causas e efeitos, informando decisões. Por exemplo, na análise de dados, rastreiam tendências. Na história, descrevem eventos importantes. Requerem coleta de dados relevantes, ordenação cronológica e interpretação para construir uma narrativa coesa. Esses históricos fornecem uma visão abrangente do passado, orientando compreensão e decisões no presente, sendo úteis para explorar causas e entender mudanças.

2.6 Ontologia e *Web Semântica*

O termo ontologia foi criado pelos filósofos Rudolf Goclenius e Jacob Lorhard em 1613, representa a existência da essência do ser no mundo e é derivado do grego: onto (ser) e logos (palavra) (ALEXANDRA; ALVARENGA; OLIVEIRA, 2004 citada por PICCOLO, 2020).

Ontologia é uma especificação formal, devido ao fato de a teoria do ser estar sendo utilizada para categorizar a realidade, e explícita – modelando formalmente e melhorando a ambiguidade, as entidades e as relações dos sistemas – de uma conceituação compartilhada das coisas do mundo, gerando a construção de bases de conhecimento através de novos vocabulários (SOUZA; MARTINS; RAMALHO, 2018).

Ontologias são artefatos de representação da informação, úteis para integração de dados e para garantir interoperabilidade semântica das informações que elas representam (ALEXANDRA; ALVARENGA; OLIVEIRA, 2004). Uma ontologia pode ser definida como um conjunto de conceitos fundamentais e suas relações, que capta como as pessoas entendem ou interpretam o domínio em questão e permite a representação de tal entendimento de maneira formal, compreensível por humanos e computadores (CARCHEDI et al., 2018).

Ontologias estão desempenhando um papel cada vez mais importante na representação do conhecimento. Em geral, eles fornecem uma representação estruturada do conhecimento em que os conceitos são armazenados juntamente com suas propriedades e as relações entre eles (ECHARTE et al., 2007).

Segundo Grimm; Wissmann (2011), uma ontologia é uma descrição formal de conceitos de um domínio do conhecimento, sendo utilizada para buscar respostas a questões formuladas para esse domínio.

De acordo com Chung et al. (2018), ontologia pode ser entendida como um artefato de *software* fornecendo um vocabulário geral sobre determinado domínio para representação do conhecimento nele contido, dotando os sistemas de inteligência e autonomia.

Para Sharma; Ahuja (2016), ontologias permitem especificar formal e explicitamente os conceitos que aparecem em um domínio concreto, suas propriedades e relacionamentos. Em um contexto computacional, ontologias apoderam-se de conhecimentos sobre um domínio específico e são usados para representar implicações semânticas imprescindíveis para o

suporte de raciocínio, também retrata os conceitos do domínio e as relações que existem entre os conceitos (PAI; HSU; CHUNG, 2016).

Breitman; Casanova; Truszkowski (2007), também apresentam uma definição de ontologia voltada para a área de computação. Segundo os autores, ontologias são modelos que capturam e explicam o vocabulário utilizado nas aplicações semânticas. Servem como base para garantir uma comunicação livre de ambiguidades.

Segundo Carchedi et al. (2018), no contexto da Ciência da Computação, uma ontologia permite definir primitivas de representação que podem modelar um domínio específico de conhecimento. Essas primitivas podem ser classes, atributos e relacionamentos que podem conferir significado a um determinado conceito. As ontologias também permitem adicionar um nível de abstração de modelos de dados, com o objetivo de modelar o conhecimento sobre indivíduos, seus atributos e relacionamentos.

Conforme Barlybayev et al. (2020b), uma ontologia é uma ferramenta poderosa e amplamente utilizada para modelar relacionamentos entre objetos pertencentes a diferentes áreas temáticas. No contexto das ciências da computação e da informação, a ontologia define um conjunto de primitivas representativas com as quais se pode modelar um campo de conhecimento ou discurso. As primitivas representativas geralmente são classes (ou conjuntos), atributos (ou propriedades) e relacionamentos (ou relacionamentos entre membros de uma classe).

De acordo com Hitzler (2021), em um sentido mais preciso, uma ontologia é realmente uma base de conhecimento (no sentido de inteligência artificial simbólica) de conceitos e suas relações, especificadas em uma linguagem de representação do conhecimento baseada em uma lógica formal.

Segundo Gruber (2009), no contexto das ciências da computação e da informação, uma ontologia define um conjunto de primitivas representacionais com as quais se pode modelar um domínio de conhecimento ou discurso. As primitivas representacionais são tipicamente classes (ou conjuntos), atributos (ou propriedades) e relacionamentos (ou relações entre membros de classe). As definições das primitivas representacionais incluem informações sobre seu significado e restrições em sua aplicação logicamente consistente. No contexto de sistemas de banco de dados, a ontologia pode ser vista como um nível de abstração de modelos de dados, análogo aos modelos hierárquicos e relacionais, mas

destinado a modelar o conhecimento sobre os indivíduos, seus atributos e seus relacionamentos com outros indivíduos.

O termo ontologia ganhou popularidade na comunidade científica na década de 1990. Sua origem veio da filosofia, definido como uma disciplina dedicada à natureza e à existência dos elementos (GRUBER, 1993).

Segundo Vieira; Maia (2019), a representação dos dados por meio das ontologias traz benefícios ao desenvolvimento de aplicações para EaD, sendo fundamental para a normalização de conceitos e as relações semânticas estabelecidas entre eles. Uma ontologia “define os termos básicos e as relações que compõem o vocabulário de uma área temática, bem como as regras para combinar termos e relações para definir extensões ao vocabulário” (VIEIRA; MAIA, 2019).

De acordo com Grivokostopoulou et al. (2019), as ontologias são utilizadas com grande sucesso na educação porque permitem formular a representação de um domínio de aprendizagem especificando todos os conceitos envolvidos, relações entre conceitos e todas as propriedades e condições existentes.

Em um contexto da *Web Semântica*, ontologia é o principal veículo para integração, compartilhamento e descoberta de dados, e uma ideia motriz é que as próprias ontologias devem ser reutilizáveis por outros (HITZLER, 2021).

A *Web Semântica* é a teia de conexões entre diferentes formas de dados que permitem que uma máquina faça algo que não era capaz de fazer diretamente. Segundo Bikakis et al. (2013), a *Web Semântica* tem como objetivo tornar os dados da internet legíveis pelas máquinas, ela é uma extensão da web com padrões definidos pelo *World Wide Web Consortium* (W3C).

Para permitir a codificação da semântica com os dados, utiliza-se tecnologias como *Web Ontology Language* (OWL) e *Resource Description Framework* (RDF). Essas tecnologias podem representar formalmente os metadados, possibilitando raciocínio sobre dados e operação com fontes de dados variadas. Permitem descrever conceitos, relacionamentos entre entidades e categorias de coisas (CHUNG et al., 2018).

A OWL é a linguagem padrão para definir e instanciar ontologias da *Web*. Uma Classe OWL é definida usando a construção *owl:Class* e representa um conjunto de indivíduos com

propriedades. Todas as classes OWL são consideradas subclasses da classe *owl:Thing* e superclasses da classe *owl:Nothing* (BIKAKIS et al., 2013).

RDF é uma linguagem de propósito geral para representar informações sobre recursos na Web. Até certo ponto, RDF é uma linguagem de ontologia leve. Possui um modelo de dados muito simples e flexível, baseado no conceito central da declaração RDF. As instruções RDF são triplas (sujeito, predicado, objeto) que consistem no recurso (o sujeito) que está sendo descrito, uma propriedade (o predicado) e um valor de propriedade (o objeto) (MANOLA F., 2004).

2.6.1 Componentes de uma ontologia

Ao compor uma ontologia, observa-se uma diversidade de definições, bem como vários tipos de ontologias, funções, metodologias, linguagens e ferramentas. Embora sua estrutura varie conforme os objetivos a que cada uma se propõe, alguns componentes são comuns na maioria das ontologias.

Conforme Noy; McGuinness (2001), uma ontologia é constituída por classes, propriedades, restrições e instâncias. Ramalho (2010) apresenta uma descrição dos componentes de uma ontologia de modo a detalhar cada elemento e, sob seu ponto de vista, conceitua:

- Classes e Subclasses: As classes e subclasses de uma ontologia agrupam um conjunto de elementos, “coisas”, do “mundo real”, que são representadas e categorizadas de acordo com suas similaridades, levando-se em consideração um domínio concreto. Os elementos podem representar coisas físicas ou conceituais, desde objetos inanimados até teorias científicas ou correntes teóricas;
- Propriedades Descritivas: Descrevem as características, adjetivos e/ou qualidades das classes;
- Propriedades Relacionais: Trata-se dos relacionamentos entre classes pertencentes ou não a uma mesma hierarquia, descrevendo e rotulando os tipos de relações existentes no domínio representado;

- Regras e Axiomas: Enunciados lógicos que possibilitam impor condições como tipos de valores aceitos, descrevendo formalmente as regras da Ontologia e possibilitando a realização de inferências automáticas a partir de informações que não necessariamente foram explicitadas no domínio, mas que podem estar implícitas na estrutura da Ontologia;
- Instâncias: Indicam os valores das classes e subclasses, constituindo uma representação de objetos ou indivíduos pertencentes ao domínio modelado, de acordo com as características das classes, relacionamentos e restrições definidas;
- Valores: Atribuem valores concretos às propriedades descritivas, indicando os formatos e tipos de valores aceitos em cada classe.

Segundo Souza Júnior (2015), as ontologias permitem formalizar o conhecimento e, a depender de como esses componentes são utilizados, adotam diferentes formatos. Sendo assim, qualquer ontologia deverá demonstrar conjuntos de termos e suas especificações. Para a composição da ontologia, é necessário entender tais elementos, e, quando comparada a outros sistemas de organização do conhecimento, sua composição é mais complexa, pois armazena maior riqueza semântica (ARAÚJO, 2021).

2.6.2 Tipos de ontologia

Existem características e componentes básicos comuns presentes em grande parte das ontologias, isso porque elas nem sempre possuem a mesma estrutura. Mesmo apresentando propriedades diferentes, é possível identificar inúmeros tipos de ontologias, onde as mesmas são subdivididas quanto a função, grau de formalismo, aplicação, estrutura e conteúdo. Sendo assim, é necessário identificar cada tipo de ontologia e relacionar com o objetivo que se pretende alcançar.

De acordo com Guarino (1994), as ontologias são classificadas:

- a) quanto à generalidade
 - Ontologias de nível superior – descrevem conceitos muito genéricos, tais como espaço, tempo, matéria, objeto, ação, eventos e etc. Estes seriam a princípio,

independentes de domínio e poderiam ser reutilizados na confecção de novas ontologias." (BREITMAN; CASANOVA; TRUSZKOWSKI, 2007).

- Ontologias de domínio: Reutilizáveis no domínio, fornecem vocabulário sobre conceitos, seus relacionamentos, sobre atividades e regras que os governam (MIZOGUCHI; WELKENHUYSEN; IKEDA, 1995). Alguns exemplos são citados por Guizzardi (2000), tais como medicina ou automóveis. É o tipo de ontologia mais comum, geralmente "[...] são construídas para serem utilizadas em um “micromundo”.
 - Ontologias de tarefa: Fornecem um vocabulário sistematizado de termos, especificando tarefas que podem ou não estar no mesmo domínio.
 - Ontologias gerais: Incluem um vocabulário relacionado a coisas, eventos, tempo, espaço, casualidade, comportamento, funções, entre outros.
- b) Quanto ao grau de formalismo (USCHOLD; GRUNINGER, 1996):
- Ontologias altamente informais: Expressa livremente em linguagem natural.
 - Ontologias semi-informais: Expressa em linguagem natural de forma restrita e estruturada.
 - Ontologias semiformais: Expressa em uma linguagem artificial definida formalmente.
 - Ontologia rigorosamente formal: Os termos são definidos com semântica formal, teoremas e provas.
- c) Quanto à aplicação (USCHOLD et al., 1999):
- Ontologias de autoria neutra: Quando um aplicativo é escrito em uma língua neutra e depois convertido para uso em diversos sistemas, reutilizando-se as informações.
 - Ontologias como especificação: Cria-se uma ontologia para um domínio, a qual é usada para documentação e manutenção no desenvolvimento de *softwares*.
 - Ontologias de acesso comum à informação: Quando o vocabulário é inacessível, a ontologia torna a informação inteligível, proporcionando conhecimento compartilhado dos termos.

d) Quanto à estrutura (HAAV; LUBI, 2001):

- Ontologias de alto nível: Descrevem conceitos relacionados a todos os elementos da ontologia (espaço, tempo, matéria, objeto, evento, ação, etc.) os quais são independentes do problema ou domínio.
- Ontologias de domínio: Descrevem o vocabulário relacionado a um domínio específico.
- Ontologias de tarefa: Descrevem uma tarefa ou atividade, como por exemplo, diagnósticos ou compras, mediante inserção dos termos especializados na ontologia. Sua principal motivação é facilitar a integração dos conhecimentos de tarefa e domínio em uma abordagem mais uniforme e consistente, tendo por base o uso de ontologias (GUIZZARDI, 2000).

e) Quanto ao conteúdo (HEIJST; SCHREIBER; WIELINGA, 1997):

- Ontologias terminologias: Especificam termos que serão usados para representar o conhecimento em um domínio (por exemplo, os léxicos).
- Ontologias da informação: Especificam a estrutura de registros de banco de dados (exemplo: os esquemas de banco de dados).
- Ontologias de modelagem do conhecimento: Especificam conceitualizações do conhecimento, têm uma estrutura interna semanticamente rica e são refinadas para uso no domínio do conhecimento que descrevem.
- Ontologias de aplicação: Contêm as definições necessárias para modelar o conhecimento em uma aplicação. Descrevem conceitos que dependem tanto de um domínio particular quanto de uma tarefa específica.
- Ontologias de domínio: Expressam conceitualizações que são específicas para um determinado domínio do conhecimento (GUIZZARDI, 2000). Ontologias de domínio tem como objetivo apresentar uma visão de mundo que se deseja representar, tendo como função definir o conhecimento do domínio com suas especificações explícitas, resolvendo problemas de ambiguidade e contribuindo para a partilha de conhecimento (SOUZA JÚNIOR, 2015), contribuem para o uso de bases de conhecimento permitindo a construção de objetos operacionalizados e compreensíveis por máquina.

- Ontologias genéricas: Similares às ontologias de domínio, mas os conceitos que as definem são considerados genéricos e comuns a vários campos. De acordo com (GUIZZARDI, 2000), pesquisas enfocando ontologias genéricas procuram construir teorias básicas do mundo, de caráter bastante abstrato, aplicáveis a qualquer domínio (conhecimento de senso comum).
- Ontologias de representação: Explicam as conceitualizações que estão por trás dos formalismos de representação do conhecimento, procurando tornar claros os compromissos ontológicos embutidos nestes formalismos (GUIZZARDI, 2000). Um exemplo desta categoria é a ontologia de *frames*, utilizada em Ontolíngua (GRUBER, 1991).

As ontologias fazem partes dos sistemas de organização do conhecimento, permitem formas de representação baseadas em lógica, possibilitando o uso de mecanismos de inferência para criar novo conhecimento a partir do existente.

Com o uso de ontologias é possível dar um salto qualitativo na utilização de motores de busca, ou seja, ao em vez da busca ser por palavras-chave, serão utilizados agentes de *softwares* inteligentes pelo uso de conceitos, permitindo migrar de uma simples recuperação para a obtenção de respostas precisas a consultas concretas (SOUZA JÚNIOR, 2015).

2.6.3 Metodologias

Ao longo dos anos, várias metodologias foram desenvolvidas e disponibilizadas para a utilização pela comunidade científica. Entretanto, a falta de um consenso amplo persiste quanto à escolha da metodologia mais apropriada. No âmbito desta tese, a autora oferece uma apresentação e descrição sucinta de cada uma dessas metodologias, as quais abrangem:

- a) A metodologia *Systematic Approach for Building Ontologies* (SABiO) de Falbo (2014), permite a criação de ontologias de domínio e propõe processos de suporte. A versão 2.0 é uma evolução da versão 1.0 desenvolvida por Falbo em 1998.
- b) O método *Ontology Development 101*, introduzido por Noy, Natalya F et al. (2003), teve sua origem na construção de uma ontologia para vinhos e

alimentos, elaborada com o auxílio do *software Protégé* (NOY et al., 2003; MUSEN, 2015). Essa abordagem é caracterizada por um processo iterativo.

- c) A metodologia *Toronto Virtual Enterprise* (TOVE), de Grüninger; Fox (1995), originou-se do projeto TOVE, com o objetivo de estabelecer um modelo comum de processos empresariais. Ela resultou na criação de ontologias para descrever modelos de atividades em organizações públicas e privadas. A abordagem segue uma sequência linear de etapas, finalizando com a entrega da ontologia.
- d) A metodologia *Network Ontology* (*NeOn*), proposta por Baonza (2010), fundamenta-se no processo de desenvolvimento colaborativo de *software*.
- e) A metodologia *Distributed, Loosely-controlled and evolvinG Engineering of Ontologies* (DILIGENT), proposta por Pinto; Staab; Tempich (2004), viabiliza a criação de um conjunto de ontologias que podem ser compartilhadas e ampliadas.
- f) O método desenvolvido por Uschold; King (1995), inicialmente proposto por eles, foi posteriormente ampliado por Uschold; Grüninger (1996) durante o desenvolvimento da *Enterprise Ontology*. Essa ontologia foi elaborada para descrever processos de modelagem no contexto empresarial. A metodologia segue uma abordagem semelhante à da metodologia TOVE de Grüninger; Fox (1995), isto é, uma sequência de etapas é definida para a criação da ontologia.
- g) A metodologia *Up for Ontology* (UPON), desenvolvida por De Nicola; Missikoff; Navigli (2005), foi empregada na construção de ontologias derivadas do processo unificado (*Unified Process - UP*) de desenvolvimento de *software*.
- h) A *On-to-Knowledge Methodology* (OTKM), proposta por Sure; Staab; Studer (2004), viabiliza a elaboração de ontologias voltadas para a gestão de conhecimento em organizações.
- i) A *Methontology*, permite a construção de ontologias por meio da reengenharia, utilizando o conhecimento específico de um determinado domínio, (GÓMEZ-PÉREZ, 2004).

É importante observar que a escolha da metodologia é influenciada pelo contexto, objetivos e recursos disponíveis. Frequentemente, adota-se uma abordagem iterativa, na qual a ontologia é aprimorada ao longo do tempo à medida que novos requisitos e conhecimentos são integrados. Adicionalmente, a utilização de ferramentas de desenvolvimento de ontologias pode facilitar tanto a construção quanto a manutenção dessas estruturas.

2.6.4 Motores de inferência

Os motores de inferência ou raciocinadores são ferramentas de *softwares* que mapeiam uma base de conhecimentos existente inferindo conhecimentos adicionais e mostrando informações implícitas (FILHO; LÓSCIO DE CAMPOS, 2008) e desempenham um papel importante no desenvolvimento e uso de uma ontologia, bem como na verificação de inconsistências. Além da inferência de informações, os raciocinadores têm a capacidade de responder consultas em cima do conhecimento provido e inserido, bem como a checagem de consistência de ontologias.

Segundo Helfer (2022), um motor de inferência semântica, também chamado de *reasoner* ou raciocinador, é um *software* capaz de inferir consequências lógicas de um conjunto de fatos ou axiomas afirmados. As regras de inferência são comumente especificadas por meio de uma linguagem de ontologia (SWRL) e, muitas vezes, uma linguagem de lógica de descrição.

Motores de inferência são componentes fundamentais em sistemas de processamento de conhecimento, como sistemas especialistas e sistemas baseados em regras. Eles desempenham um papel crucial na tomada de decisões lógicas e na dedução de informações a partir de um conjunto de regras e fatos.

O principal objetivo de um motor de inferência é analisar as informações fornecidas, seja na forma de regras ou de fatos, e determinar as conclusões ou inferências lógicas que podem ser obtidas a partir desses dados. Isso é feito seguindo um conjunto de regras de inferência predefinidas e aplicando princípios de lógica formal.

Motores de inferência operam em bases de conhecimento, usando regras de inferência para deduzir novas informações. Eles seguem sequências de regras para criar cadeias de dedução, usando métodos como *backward chaining* (retroativo) ou *forward chaining*

(progressivo). A resolução de conflitos determina quais regras aplicar quando várias são relevantes. A eficiência é essencial, e esses motores são usados em várias áreas para tomar decisões lógicas automatizadas, simulando raciocínio humano.

2.7 Considerações sobre o capítulo

Este capítulo apresentou os principais conceitos sobre educação a distância, ambientes virtuais de aprendizagem, *learning analytics*, históricos de contextos, *web semântica* e ontologia, que irão compor o desenvolvimento da tese. O próximo capítulo apresenta os trabalhos relacionados e o comparativo dos artigos selecionados que nortearam o desenvolvimento da tese.

3 TRABALHOS RELACIONADOS

Para seleção dos trabalhos relacionados, foram considerados os três artigos publicados a seguir. Utilizou-se o primeiro mapeamento em sua totalidade e partes do segundo mapeamento e da revisão da literatura. A pesquisa realizada no período de 2010 a junho de 2020 possibilitou o desenvolvimento de um mapeamento sistemático com o objetivo de identificar como LA e como os serviços inteligentes vêm sendo empregados na EaD, após, foi realizado o segundo mapeamento com foco em aprendizagem e grupos colaborativos de alunos em EaD. A pesquisa anterior foi ampliada, permitindo o desenvolvimento de uma revisão da literatura sobre serviços inteligentes aplicados a EaD, sendo:

- Um mapeamento sistemático sobre análise de dados e serviços inteligentes aplicados na educação à distância, foi publicado na Revista Brasileira de Informática na Educação – RBIE (SILVA; BARBOSA; RIGO, 2021).
- Um mapeamento sistemático com foco em análise de aprendizagem e grupos colaborativos, publicado na revista *Informatics in Education* – INFOEDU (SILVA et al., 2022).
- Uma revisão da literatura especificamente focada em serviços inteligentes com o objetivo de identificar quais serviços inteligentes estão sendo aplicados no ensino a distância, publicado no periódico internacional *Education Sciences* (SILVA et al., 2021).

3.1 Procedimentos metodológicos

Para o desenvolvimento dos dois primeiros artigos utilizou-se como metodologia o mapeamento sistemático, pois, de acordo com Petersen; Vakkalanka; Kuzniarz (2015), essa metodologia proporciona uma visão geral dos estudos e seus resultados. No terceiro artigo utilizou-se a metodologia de revisão da literatura segundo (NORONHA; FERREIRA, 2000), essa metodologia analisa a produção bibliográfica em determinada área temática, dentro de um recorte de tempo, fornecendo uma visão geral ou um relatório do estado da arte sobre um tópico específico, evidenciando novas ideias, métodos, subtemas que têm recebido maior ou menor ênfase na literatura selecionada.

Os mapeamentos apresentam as seguintes etapas em sua execução: a) definição das questões de pesquisa; b) definição do processo de busca; c) definição dos critérios de inclusão; d) definição dos critérios de exclusão; e) execução das análises e f) classificação dos resultados.

3.1.1 Questões de Pesquisa

Para condução do estudo foram definidas questões que são mostradas na Tabela 1, sendo elas: Questões Gerais (QG), Questões Focais (QF) e Questões Estatísticas (QE).

Tabela 1: Questões de pesquisa

ID	Questões de pesquisa	Categorias
QG1	Quais métodos/técnicas de análise de dados vêm sendo aplicados em ambientes EAD??	Métodos / Análise de dados.
QG2	Quais tipos de serviços inteligentes vêm sendo oferecidos no âmbito da EaD?	Serviços Inteligentes.
QG3	Que benefícios têm sido obtidos para alunos, professores e gestores por meio da análise de dados na educação a distância?	Benefícios.
QF1	Existem métodos/técnicas de análise de dados que vem utilizando históricos de registros de <i>logs</i> dos alunos no âmbito da EaD?	Históricos de registros.
QF2	Existem serviços inteligentes para grupos colaborativos de alunos na área da educação a distância?	Serviços / Inteligentes / Colaborativos.
QF3	Quais são as tendências percebidas?	Tendência.
QE1	Em quais bases de dados os trabalhos foram publicados?	Bases de dados.
QE2	Onde os trabalhos foram desenvolvidos?	Países.

Fonte: Elaborado pela autora

3.1.2 Termos de buscas

A partir da definição das questões de pesquisa, procurou-se definir os termos principais que respondam às questões elaboradas. O estudo de termos para a definição da *string* de busca baseou-se nas palavras: *Distance, Education, Learning, Educational, environment, analysis, Data Science e Data mining*. Os termos definidos foram unidos pelas

expressões booleanas *AND* e *OR* em três conjuntos. A fim de estabelecer os interesses da pesquisa, foi definida a seguinte *string* de busca, representada na Tabela 2.

Tabela 2: Definição de termos de pesquisa

Termos principais	Termos da pesquisa
<i>Distance Learning</i>	(<i>Distance learning OR Distance education OR E-Learning OR online education OR Educational technology OR virtual learning environment OR learning management system</i>).
<i>Learning Analytics</i>	<i>AND (Learning Analytics OR learning analytic OR data analysis data Science OR educational data mining OR learning data mining OR academic data mining OR school data mining)</i> .
<i>Intelligent Services</i>	<i>AND (Smart services OR smart service OR smart methods OR intelligent service OR intelligents services OR inteligente task OR intelligents systems OR smart processes OR intelligent processes)</i> .

Fonte: Elaborado pela autora

A Tabela 3 mostra as bases de dados nas quais a *string* de busca foi executada e a quantidade de artigos inicialmente encontrados.

Tabela 3: Bases de dados pesquisados

Bases de dados	Pesquisa inicial
<i>ACM Digital Library</i>	45.969
<i>IEEE Xplore Digital Library</i>	6.519
<i>ScienceDirect</i>	3.487
<i>Springer Library</i>	3.036
<i>Scopus</i>	308

Fonte: Elaborado pela autora

A Tabela 4 apresenta os critérios de inclusão e exclusão aplicados no processo de seleção dos artigos. Os critérios foram utilizados para selecionar os estudos mais alinhados com as questões da pesquisa e, também, para excluir os ruídos gerados pela pesquisa. O estudo considerou os seguintes critérios de inclusão (CI) e critérios de exclusão (CE):

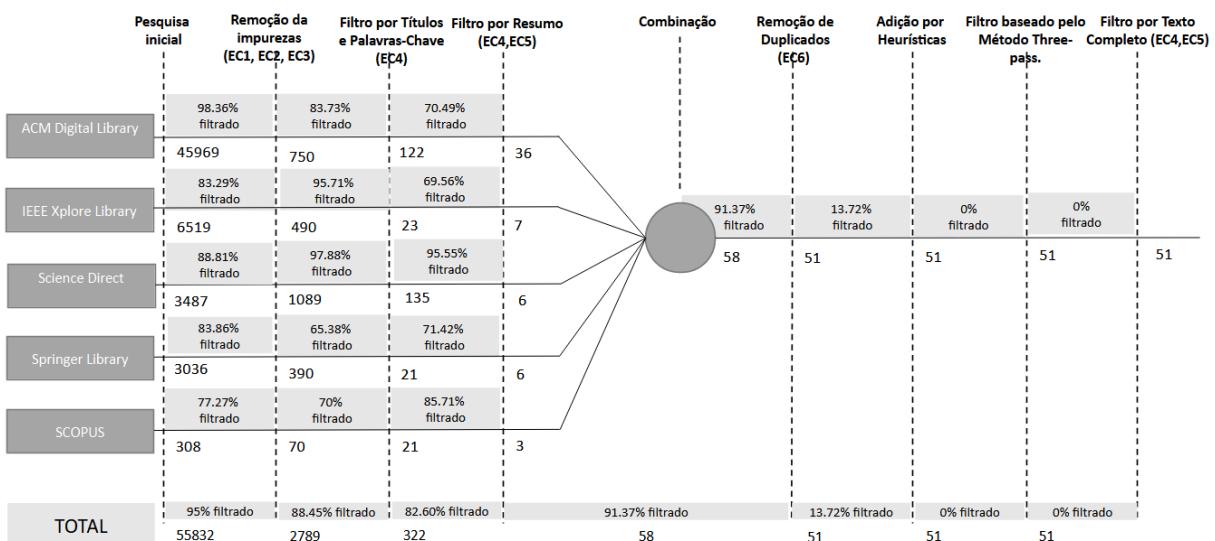
Tabela 4: Critérios de inclusão (CI) e exclusão (CE)

Ref	Critério
CI1	Publicações com conteúdos completos e acesso livre.
CI2	Publicações em conferências, <i>journals</i> e <i>workshops</i> .
CI3	Publicações que possuem métodos de análise de dados aplicados na EaD.
CI4	Publicações que ofereçam algum tipo de serviço inteligente para a área de EaD.
CI5	Publicações de 2010 até junho de 2020.
CE1	Publicações que antecedem o ano de 2010.
CE2	Publicações com idioma diferente do Inglês.
CE3	Teses, dissertações, resumos, livros e revisões sistemáticas.
CE4	Publicações não relacionadas ao tema.
CE5	Artigos relacionados a cursos de curta duração.
CE6	Publicações duplicadas.

Fonte: Elaborado pela autora

3.1.3 Processo de seleção

A pesquisa inicial identificou 55.832 artigos nas cinco bases de dados pesquisadas. Após a pesquisa inicial, foi realizado o processo de filtragem para identificação dos artigos relevantes sobre o tema pesquisado. A Figura 1 mostra o processo completo de filtragem. A filtragem inicial removeu as impurezas utilizando os critérios de exclusão EC1, EC2 e EC3. Em seguida, os textos foram filtrados pelo critério EC4 considerando título e palavras-chave. Finalmente, os estudos foram filtrados de acordo com os resumos usando os critérios EC4 e EC5. Esse processo resultou em 58 artigos. Sete textos duplicados foram excluídos segundo o critério EC6, resultando em 51 obras. Os passos de adição por heurística e filtro pelo método de três passos não incluíram artigos, resultando a filtragem completa em 51 artigos que foram lidos na íntegra para garantir sua adequação nesse estudo.

Figura 1: Busca inicial, aplicação de critérios, junção, remoção e resultado

Fonte: Elaborado pela autora.

3.2 Resultados e discussões

A Tabela 5 apresenta a lista dos artigos selecionados, contendo autores, ano de publicação, país dos autores, base de dados da publicação do artigo e resumo sobre o foco do artigo. O identificador usado na coluna referências é usado nas figuras 10 (Publicação por ano e por base de busca) e 11 (Países de publicação).

A próxima seção discute os resultados da revisão da literatura, descrevendo os artigos que responderam às perguntas da pesquisa de acordo com a metodologia de análise em ordem cronológica de publicação

Tabela 5: Relação dos artigos mapeados

Referências	Países	Base	Resumo
1. (ALTAF; SOOMRO; RAWI, 2019)	Paquistão Nova Zelândia Malásia	ACM	Redes neurais.
2. (ANAYA; LUQUE; GARCÍA-SAIZ, 2013)	Espanha	ACM	Sistemas de recomendação baseado em um diagrama de influência.
3. (KOLEKAR; PAI; M.M., 2018)	Espanha	ScienceDirect	Interface personalizada.
4. (BALDERAS et al., 2013)	Espanha	ACM	Linguagem específica de domínio.

Referências	Países	Base	Resumo
5. (CHAFFAI; HASSOUNI; ANOUN, 2017)	Marrocos	ACM	Arquitetura da infraestrutura de pipeline.
6. (CHANAA; FADDOULI, 2018)	Marrocos	IEEE	Modelo personalizado.
7. (CHANG; CHU, 2010)	China	ScienceDirect	Modelo comportamental de aprendizagem baseado em LBPN (<i>learning behavioral Petri nets</i>).
8. (CHEN et al., 2020a)	China França	IEEE	Método de recomendação aprimorado.
9. (CLARIZIA et al., 2018)	Itália	ACM	Gráfico misto de termos.
10. (DAHDOUH et al., 2018)	Marrocos	Springer	Sistemas de aprendizado.
11. (DAHDOUH et al., 2019)	Marrocos	Springer	Sistemas de recomendação de cursos distribuídos.
12. (DIMOPOULOS; PETROPOULOU; RETALIS, 2013)	Grécia	ACM	Ferramenta de avaliação.
13. (EL FOUKI; AKNIN; EL KADIRI, 2017)	Marrocos	ACM	Sistema de tomada de decisão para ajudar os instrutores.
14. (EL MOUSTAMID; EN-NAIMI; BOUHDIDI, 2017)	Espanha Holanda Colômbia	Springer	Protótipo.
16. (GRAF et al., 2011)	Canadá	ACM	Ferramenta de análise acadêmica.
17. (GUO; YAN; LI, 2020)	China	ACM	Método baseada em LA.
18. (HAMADA, 2012)	Japão	Springer	Modelo de um sistema de e-learning baseado na tecnologia Java2D.
19. (HUANG et al., 2019)	China USA	ACM	Estrutura de aprendizado de reforço profundo.
20. (HUSSAIN et al., 2018)	China Índia Grécia	ACM	Técnica estatística de machine learning.
21. (IQBAL et al., 2019)	Inglaterra Paquistão Coréia	IEEE	Algoritmo Kernel Context Recommender System.
22. (ISLAM; SIDDIQUI; ALJOHANI, 2020)	Arábia Saudita	ACM	Técnicas de mineração de dados como agrupamento e associação.
23. (JOY; RAJ; G, 2019)	India	ACM	Modelo de ontologia.
24. (JOVANOVIĆ et al., 2020)	Sérvia Austrália USA	ACM	Modelo explicativo do comportamento do aluno.
25. (KAPEMBE; QUENUM, 2020)	Namíbia	ACM	Recomendação híbrida.
26. (KIM; KIM, 2020)	Coréia	ACM	Tutor individualizado de inteligência artificial.

Referências	Países	Base	Resumo
27. (KOTSIANTIS; PATRIARCHEAS; XENOS, 2010)	Grécia	ScienceDirect	Sistema que combina uma versão incremental do <i>Naive Bayes</i> , os algoritmos 1-NN e <i>WINNOW</i> .
28. (KOZIERKIEWICZ; ZYSK, 2013)	Polônia	Springer	Algoritmo com base na técnica de otimização de colônias de formigas.
29. (LAGMAN; MANSUL, 2017)	Filipinas	ACM	Sistema de captura.
30. (LARA et al., 2014)	Espanha	Scopus	Sistema de mineração de dados educacionais.
31. (LAVOIE; PROULX, 2020)	Canadá	ACM	Sistema de gerenciamento de aprendizagem.
32. (MANHÃES; CRUZ; ZIMBRÃO, 2014)	Brasil	ACM	Arquitetura <i>WAVE</i> .
33. (OKUBO et al., 2017)	Japão	ACM	Rede neural Recorrente.
34. (OLIVÉ et al., 2018)	Austrália	ACM	Estruturas de <i>softwares</i> .
35. (OMAR; ABDESELAM, 2017)	Algéria	ACM	Algoritmos de <i>clustering</i> aplicados a uma plataforma de <i>e-learning</i> .
36. (PEÑAFIEL et al., 2018)	Equador Espanha	ACM	Técnicas computacionais, como mineração de texto e análise de sentimentos.
37. (QU et al., 2018)	China	IEEE	Estrutura de previsão de desempenho do aluno.
38. (OLANREWAJU et al., 2016)	Malásia Índia	Scopus	Mecanismo de Análise de <i>Feedback</i> distribuído para <i>Big Data</i> .
39. (RAYÓN; GUENAGA; NUÑEZ, 2014)	Espanha	ACM	Sistema SCALA – Avaliação de Competência Escalável.
40. (ROS et al., 2017)	Espanha	ACM	Algoritmo PCA - <i>Principal Component Analysis</i> .
41. (SHARMA; AHUJA, 2016)	Índia	ACM	Recomendação semântica
42. (SOROUR; GODA; MINE, 2015)	Japão	ACM	Métodos baseados em uma classe estatística.
43. (SPATIOTIS et al., 2018)	Grécia Reino Unido	ACM	Plataforma de mineração.
44. (THAI-NGHE et al., 2010)	Alemanha	ScienceDirect	Técnicas de sistema de recomendação para mineração de dados educacionais.
45. (UZIR et al., 2020)	Reino Unido Sérvia Austrália	ACM	Técnicas complementares (<i>cluster</i> hierárquico aglomerativo, análise epistêmica de redes e mineração de processos).
46. (VENUGOPALAN; SRINATH; RODRIGUES, 2016)	Índia	ACM	Sistema de recomendação baseado em conteúdo.
47. (WANG; SUN; CHEN, 2019)	China	IEEE	Sistema inteligente de assistente de ensino.
48. (YANG et al., 2014)	China	IEEE	Técnica de reconhecimento de padrões.

Referências	Países	Base	Resumo
49. (ZAKRZEWSKA, 2010)	Polônia	Springer	Sistema de recomendações baseada em agentes.
50. (ZAOUDI; BELHADAOUI, 2020)	Marrocos	ACM	Modelo de LBA (<i>Learner Behavior Analytics</i>).
51. (ZORRILLA; GARCÍA;	Espanha	ACM	Sistema orientado para análise dos resultados.

Fonte: Elaborado pela autora

3.2.1 QG1 – Quais métodos/técnicas de análise de dados vêm sendo aplicados em ambientes de educação à distância?

Dentre os 51 artigos selecionados, 39% (24 artigos) contêm métodos/técnicas de análise de dados aplicados à educação a distância. Também se observou que alguns autores desenvolveram plataforma de mineração (SPATIOTIS et al., 2018), sistemas orientados para análise de resultados (ZORRILLA; GARCÍA; ÁLVAREZ, 2010); (KOTSIANTIS; PATRIARCHEAS; XENOS, 2010), métodos baseados em classe estatística (SOROUR; GODA; MINE, 2015), criaram estruturas de *softwares* (OLIVÉ et al., 2018) estruturas de previsão (OLANREWAJU et al., 2016), arquitetura de infraestrutura (CHAFFAI; HASSOUNI; ANOUN, 2017), modelo comportamental (CHANG; CHU, 2010), implementaram algoritmos para análises de dados (ROS et al., 2017), técnicas de *Big Data* e LA (OLANREWAJU et al., 2016).

Os autores Kotsiantis; Patriarcheas; Xenos (2010), propuseram um sistema que combina uma versão incremental do *Naive Bayes*, os algoritmos 1-NN e *WINNOW*, usando a metodologia de votação para prever o desempenho dos alunos em um sistema de ensino à distância. Com a ajuda da técnica proposta, os tutores estão em posição de saber quais de seus alunos concluirão um módulo ou um curso com precisão.

Chang; Chu (2010), apresentaram um modelo comportamental de aprendizagem baseado em *Learning Behavioral Petri Nets* (LBPN) para simular uma situação em que alunos participam de um curso de *e-learning* e, em seguida, gerar seus padrões comportamentais que podem ser usados para recomendar conteúdos de aprendizagem apropriados para alunos de maneira automática e eficiente.

Zorrilla; García; Álvarez (2010), apresentaram um sistema orientado para análise dos resultados e genérico para diferentes plataformas de *e-learning*. O sistema foi projetado com base em uma arquitetura modular para executar as tarefas de pré-processamento relacionadas à aplicação de algoritmos de mineração de dados e para armazenar esses dados no banco de dados do *Data Warehouse*. Os autores fizeram uso de três pacotes de *software* de mineração de dados de código aberto, sendo *RapidMiner*, *Weka* e *Keel*.

Graf et al. (2011), apresentaram uma ferramenta de análise acadêmica desenvolvida no projeto *Moodle Analytics* que incorpora funcionalidade para analisar dados relacionados ao comportamento dos alunos nos sistemas de aprendizagem.

Yang et al. (2014), propuseram um método de previsão de estilo de aprendizagem baseado em uma técnica de reconhecimento de padrões, que funciona como uma forma de *middleware* que pode ser aplicado a outros sistemas de tutorias inteligentes, enquanto pode processar dados dependentes de tópicos para fazer o rastreamento e atualizar os resultados do estilo de aprendizado de maneira recursiva.

Por sua vez, Lara et al. (2014), apresentaram um Sistema de Mineração de Dados Educacionais (SEDM), baseado no estudo de dois grupos de alunos para cada curso, sendo: 1) os alunos que abandonam o curso antes de fazer o exame final e 2) os que não abandonam, passam na avaliação continuam e realizam o exame final. Foram utilizados os dados de *log* de operações dos alunos armazenados em um banco de dados interno do *Moodle* utilizando técnicas de mineração de dados tais como: agrupamento, associação, classificação e análise de tempo, com o objetivo de descobrir os padrões representativos de cada grupo.

Rayon; Guenaga; Nunez (2014), projetaram e desenvolveram o SCALA - Avaliação de Competência Escalável, um sistema de análise que integra como o usuário interage com recursos e como alunos e professores interagem entre eles. O sistema rastreia os dados para apoiar avaliação de competência e em termos de descoberta de conhecimento, os resultados são obtidos aplicando algoritmos de mineração de regras de agrupamento e associação.

Sorour; Goda; Mine (2015), propuseram novos métodos baseados em uma classe estatística latente para a tarefa de previsão da nota do aluno; os métodos convertem os comentários dos alunos usando análise semântica latente, análise semântica latente probabilística e geram modelos de previsão usando máquina de vetor de suporte e Rede Neural Artificial para prever as notas finais dos alunos.

Olanrewaju et al. (2016), introduziram uma nova abordagem denominada Mecanismo de Análise de *Feedback* Distribuído para *Big Data* baseado em conhecimento que pode ser aplicável ao aprimoramento dos conceitos associados aos mecanismos de *e-learning* na plataforma de nuvem.

Os autores Omar; Abdesselam (2017), realizaram estudos com os algoritmos de *clustering* aplicados a uma plataforma de *e-learning*. Foram aplicados os algoritmos nos traços de interação com uma plataforma de *e-learning* e, especificamente, em um arquivo de *log* extraído da plataforma de *e-learning* da Universidade de *Bechar* e realizados experimentos em alguns algoritmos de classificação, para testar e comparar o desempenho desses algoritmos. Trabalhou-se com três algoritmos que tocam as duas grandes famílias de classificação (particionamento, hierárquica): *K-means*, CLARA e *BIRCH*.

Okubo et al. (2017), usaram um método para prever notas finais de alunos por uma Rede Neural Recorrente (RNN) a partir dos dados de registro armazenados nos sistemas educacionais. Os dados do registro representavam as atividades de aprendizagem dos alunos que usavam o sistema de gerenciamento de aprendizagem, o sistema de portfólio eletrônico e o sistema de *e-book*.

Os autores Chaffai; Hassouni; Anoun (2017), criaram uma arquitetura da infraestrutura de *pipeline* ETL escalável, usando o *Spark* no *Hadoop Yarn* como seu principal mecanismo de computação que pode fornecer dados novos para painéis reativos, a fim de resumir as interações dos alunos. O *design* do sistema ilustra o *pipeline* de dados a partir do qual coletam dados e transformam, analisam, armazenam e implantam o modelo em produção para relatar os resultados da análise. Esses autores utilizaram uma abordagem baseada no conceito de *Big Data* para projetar um *pipeline* de dados moderno em tempo real.

Ros et al. (2017), implementaram um algoritmo PCA (*Principal Component Analysis*) para reduzir os parâmetros e estudar os mais representativos na classificação do comportamento dos alunos, reduzindo assim a dimensionalidade dos conjuntos de dados.

Hussain et al. (2018), aplicaram técnica estatística de *Machine Learning* (ML) usando o campo da análise preditiva. O modelo prediz o resultado ou o comportamento com base em dados de registros no *Moodle*, identificando alunos com baixo desempenho e inativos permitindo ao instrutor tomadas de decisões inteligentes antes do exame final.

Os autores Olivé et al. (2018), propuseram a criação de estruturas de *softwares* para desenvolvimento de modelos de previsão de mineração de dados Educacionais (EDM) e LA que são capazes de prever quais alunos correm o risco de abandonar um curso antes de seu término. Esses modelos permitem que os educadores tomem medidas de intervenção apropriada antes do final do curso.

Qu et al. (2018), também criaram uma estrutura de previsão de desempenho do aluno, que inclui processamento de dados usando dados no *data warehouse*, propuseram um método baseado em *perceptron* multicamada supervisionado por camada (MLP) para prever o desempenho dos alunos e as supervisões fornecidas a cada camada oculta correspondente do MLP para melhorar o desempenho do aluno.

Peñafiel et al. (2018), usaram uma aplicação da mineração de dados usando técnicas computacionais, como mineração de texto e análise de sentimentos, com o objetivo de avaliar as questões em aberto das pesquisas *online* realizadas pelos professores da universidade. Os resultados permitiram obter informações relevantes em relação ao tempo que os professores utilizam ao incorporar plataformas *online* no processo de ensino aprendizagem, aceitação ou rejeição do uso dessas ferramentas pelos professores.

Clarizia et al. (2018), propuseram o uso do gráfico misto de termos (MGTs), obtido pelo uso da abordagem de alocação de diretórios latentes, como ferramenta para a classificação de sentimentos. O método baseia-se na construção dos MGTs de referência a partir de documentos rotulados de acordo com seus sentimentos. O método proposto foi aplicado no *e-learning* para medir o humor de uma sala de aula em relação a tópicos permitindo ao professor a opção de ajustar melhor sua abordagem de ensino.

Spatiotis et al. (2018), apresentaram uma plataforma de mineração de opinião capaz de classificar as opiniões dos participantes nas aulas de acordo com sua polaridade e analisá-las para contribuir para a melhoria do procedimento de ensino.

Islam; Siddiqui; Aljohani (2020), fizeram uma exploração dos vários aspectos dos dados de interação do aluno usando técnicas de mineração de dados como agrupamento e associação para identificar padrões relevantes de comportamentos e possíveis atributos-chave que têm maior grau de influência nos alunos do ensino à distância fornecendo base para prever o desempenho final acadêmico que se espera de um aluno.

O objetivo da pesquisa de Altaf; Soomro; Rawi (2019), foi avaliar se as redes neurais podem ser usadas para prever o desempenho dos alunos com base nos dados do arquivo de *log* de um Sistema de Gerenciamento de Campus (CMS).

Uzir et al. (2020), apresentaram uma nova metodologia de análise de aprendizado que combina três técnicas complementares - *cluster* hierárquico aglomerativo, análise epistêmica de redes e mineração de processos. A metodologia permite a identificação e a interpretação da aprendizagem autorregulada em termos do uso de estratégias de aprendizagem.

Guo; Yan; Li (2020), apresentaram um método baseada em LA, que possui uma estrutura projetada e implementada para atender o problema de previsão da atitude dos alunos em relação a certas aulas de aprendizado misto. Para melhorar o desempenho da previsão, os autores introduziram a análise de sentimentos para transformar dados textuais em pontuação numérica de sentimento, também realizaram comparações entre vários algoritmos típicos de classificação (SVM) e regressão (SVR) que apresentaram melhor desempenho de previsão.

O artigo dos autores Jovanovic et al. (2020), teve como objetivo estabelecer um modelo explicativo do comportamento do aluno, identificando padrões na atividade *online*, oferecendo novas oportunidades para identificar padrões que podem ser facilmente interpretados pelos instrutores, resultando em oportunidades para intervenções que envolvem julgamento humano.

A Tabela 6 apresenta o resultado dos artigos mapeados que apresentaram métodos e técnicas de análise de dados que estão sendo aplicadas em ambientes de EaD. Os métodos e técnicas em 39% dos artigos mapeados são de mineração de dados, algoritmos de classificação, associação, clusterização, sistemas orientados a análises, estruturas/arquiteturas de *softwares*, técnicas computacionais, métodos baseados em classe estatística, modelos explicativos, ferramentas de análise, redes neurais artificiais, *Big Data* e LA.

A aplicação de métodos e técnicas de análises de dados identificam padrões de comportamento dos alunos, previsão do progresso acadêmico e de possível abandono do curso, possibilitando aos professores e gestores nas tomadas de decisões diante dos problemas encontrados.

Tabela 6: Relação dos artigos com métodos/técnicas de análise de dados

Referências	Métodos/técnicas de análise de dados
1. (ALTAF; SOOMRO; RAWI, 2019)	Redes Neurais para prever o desempenho dos alunos com base nos dados do arquivo de <i>log</i> .
2. (CHAFFAI; HASSOUNI; ANOUN, 2017)	Arquitetura da infraestrutura de <i>pipeline ETL</i> escalável.
3. (CHANG; CHU, 2010)	Modelo comportamental de aprendizagem baseado em <i>Learning Behavioral Petri Nets</i> .
4. (CLARIZIA et al., 2018)	Gráfico misto de termos, obtido pelo uso da abordagem de alocação de diretórios latentes, como ferramenta para a classificação de sentimentos.
5. (GRAF et al., 2011)	Ferramenta de análise acadêmica desenvolvida no projeto <i>Moodle Analytics</i> .
6. (GUO; YAN; LI, 2020)	Método baseada em LA, que possui uma estrutura projetada e implementada para atender o problema de previsão da atitude dos alunos.
7. (HUSSAIN et al., 2018)	Técnica estatística de <i>Machine Learning</i> usando o campo da análise preditiva.
8. (ISLAM; SIDDIQUI; ALJOHANI, 2020)	Técnicas de mineração de dados como agrupamento e associação.
9. (JOVANOVIC et al., 2020)	Modelo explicativo do comportamento do aluno, identificando padrões na atividade <i>online</i> .
10. (KOTSIANTIS; PATRIARCHEAS; XENOS, 2010)	Sistema que combina uma versão incremental do <i>Naive Bayes</i> , os algoritmos 1-NN e <i>WINNOW</i> , usando a metodologia de votação.
11. (LARA et al., 2014)	Sistema de Mineração de Dados Educacionais.
12. (OKUBO et al., 2017)	Método para prever notas finais de alunos por uma Rede Neural Recorrente a partir dos dados de registro armazenados nos sistemas educacionais.
13. (OLIVÉ et al., 2018)	Estruturas de <i>softwares</i> para desenvolvimento de modelos de previsão de mineração de dados Educacionais e LA.
14. (OMAR; ABDESELAM, 2017)	Algoritmos de <i>clustering</i> aplicados a uma plataforma de <i>e-learning</i> .
15. (PEÑAFIEL et al., 2018)	Aplicação da mineração de dados usando técnicas computacionais, como mineração de texto e análise de sentimentos.
16. (QU et al., 2018)	Estrutura de previsão de desempenho do aluno, que inclui processamento de dados usando <i>data warehouse</i> .
17. (OLANREWAJU et al., 2016)	Abordagem denominada Mecanismo de Análise de <i>Feedback</i> distribuído para <i>Big Data</i> .
18. (RAYON; GUENAGA; NUNEZ, 2014)	Sistema SCALA - Avaliação de Competência Escalável por meio de uma abordagem de Análise de Aprendizagem.
19. (ROS et al., 2017)	Algoritmo PCA (<i>Principal Component Analysis</i>).
20. (SOROUR; GODA; MINE, 2015)	Métodos baseados em uma classe estatística latente para a tarefa de previsão da nota do aluno.
21. (SPATIOTIS et al., 2018)	Plataforma de mineração de opinião capaz de classificar as opiniões dos participantes nas aulas.

Referências	Métodos/técnicas de análise de dados
22. (UZIR et al., 2020)	Metodologia de análise de aprendizado que combina três técnicas complementares (<i>cluster</i> hierárquico aglomerativo, análise epistêmica de redes e mineração de processos).
23. (YANG et al., 2014)	Método de previsão de estilo de aprendizagem baseado em uma técnica de reconhecimento de padrões.
24. (ZORRILLA; GARCÍA; ÁLVAREZ, 2010)	Sistema orientado para análise dos resultados, genérico para diferentes plataformas de <i>e-learning</i> .

Fonte: Elaborado pela autora

3.2.2 QG2 – Quais tipos de serviços inteligentes vêm sendo oferecidos no âmbito da EaD?

Dentre os artigos mapeados, 51 publicações apresentaram algum serviço inteligente que está sendo utilizado no âmbito da EaD. Os tipos de serviços inteligentes encontrados são categorizados como:

- a) sistemas de gerenciamentos de aprendizagem com recursos exclusivos (UZIR et al., 2020);
- b) abordagem de recomendação (SHARMA; AHUJA, 2016; KAPEMBE; QUENUM, 2020; THAI-NGHE et al., 2010),
- c) estrutura de aprendizado (HUANG et al., 2019);
- d) arquiteturas que fornecem informações úteis de alunos (MANHÃES; CRUZ; ZIMBRÃO, 2014; ZAOUDI; BELHADAOUI, 2020);
- e) sistemas de tomadas de decisões (EL FOUKI; AKNIN; EL. KADIRI, 2017);
- f) linguagem específica de domínio (BALDERAS et al., 2013);
- g) sistema inteligente (WANG; SUN; CHEN, 2019; EL MOUSTAMID; EN-NAIMI; BOUHDIDI, 2017; HAN; XU, 2021; BARLYBAYEV et al., 2020a);
- h) sistema de aprendizado (DAHDOUH et al., 2018; KHOSRAVI; SADIQ; GASEVIC, 2020b);
- i) algoritmos personalizados (KOZIERKIEWICZ; ZYSK, 2013; IQBAL et al., 2019);
- j) protótipo de indicadores (FLORIAN et al., 2011);

- k) índice de estilo de aprendizagem (HAMADA, 2012);
- l) sistema de captura (LAGMAN; MANSUL, 2017);
- m) modelo personalizado de análise (CHANAA; FADDOULI, 2018);
- n) ontologia (JOY; RAJ; G, 2019), (CHANG; CHU, 2010);
- o) ferramenta de avaliação (DIMOPOULOS; PETROPOULOU; RETALIS, 2013);
- p) interface do usuário personalizada (KOLEKAR; PAI; M.M., 2018);
- q) tutor individualizado de inteligência artificial (THAI-NGHE et al., 2010);
- r) sistemas de recomendações (VENUGOPALAN; SRINATH; RODRIGUES, 2016; ZARZEWSKA, 2010; ANAYA; LUQUE; GARCÍA-SAIZ, 2013; CHEN et al., 2020a; DAHDOUH et al., 2019; MAÂLOUL; BAHOU, 2021; SHI et al., 2020; NIKNAM; THULASIRAMAN, 2020);
- s) Sistema de controle para ambientes de aprendizagem (LEITHARDT et al., 2012);
- t) integração de tecnologias (VILLEGAS CH; ARIAS NAVARRETE; PALACIOS PACHECO, 2020);
- u) sistema de análise de aprendizagem (RUANGVANICH; NILSOOK; WANNAPIROON, 2020);
- v) classificador capaz de identificar o estilo de aprendizagem (AZZI et al., 2020);
- w) modelo IoT baseado em rede definida por *Software* (ULLAH et al., 2020);
- x) sistema de ambiente de aprendizagem de realidade virtual (NUGURI et al., 2021);
- y) ferramenta educacional (MENDES et al., 2021);
- z) questionário VARK modificado (RAJKUMAR; GANAPATHY, 2020);
- aa) estrutura de recomendação (LIN; LI; LIAN, 2020);
- bb) arquitetura para a integração (VILLEGAS CH; ARIAS NAVARRETE; PALACIOS PACHECO, 2020);
- cc) abordagem de aprendizado de máquina (IATRELLIS et al., 2021);

- dd) algoritmo de otimização Harris Hawks (TURABIEH et al., 2021);
- ee) análises de aprendizagem (ZHANG; GHANDOUR; SHESTAK, 2020);
- ff) análise discriminante (ANGELINE; RAMASUBRAMANIAN; JAMES, 2020);
- gg) modelo de previsão (CHEN et al., 2020a);
- hh) comparação de vários algoritmos (HASHIM; AWADH; HAMOUD, 2020);
- ii) detecção e classificação de alunos em risco de evasão (FREITAS et al., 2020; CHEN et al., 2020a).

A seguir são apresentados os resumos dos tipos de serviços inteligentes utilizados na EaD em ordem cronológica.

Thai-Nghe et al. (2010), propuseram uma nova abordagem que utiliza técnicas de sistema de recomendação para mineração de dados educacionais, especialmente para prever o desempenho do aluno. Para validar essa abordagem, foram comparadas técnicas de sistema de recomendação com métodos tradicionais de regressão, como regressão logística e linear, usando dados educacionais para sistemas de tutoria inteligentes.

Zakrzewska et al (2010), apresentaram um sistema de recomendação baseado em agentes, que, para cada novo aluno, sugere um grupo de estudantes de perfis semelhantes e, consequentemente, indica recursos de aprendizagem adequados. Supõe-se que os grupos de estudantes já tenham sido criados e que consistem em aprendizes de características semelhantes, como estilos cognitivos, preferências de usabilidade ou cujos comportamentos históricos eram muito parecidos. As recomendações são baseadas em três coleções de dados: dos atributos dos membros dos grupos, dos materiais de ensino equipados com bandeiras indicando os alunos-alvo de um novo recurso do aluno.

Forian et al. (2011), apresentaram um estudo baseado em dois modelos: a Teoria da Atividade de *Engeström* e o modelo Atuador-Indicador como pilares para implementar um modelo de aprendiz baseado em atividades no *Moodle*.

Os autores desenvolveram um protótipo que implementa indicadores como exemplos de aplicações analíticas de aprendizado. O processo de prototipagem indicou que o rastreamento de atividades do *Moodle* inclui dados sobre estruturas sociais mais complexas no decorrer do AVA.

O autor Hamada (2012), desenvolveu uma versão aprimorada de um índice de estilo de aprendizagem, levando em consideração as diferenças culturais. O modelo foi implementado de uma maneira que permite aos alunos verificar facilmente suas preferências de aprendizado. Além disso, os professores podem ter uma visão mais ampla das preferências de aprendizado de seus alunos. Os autores também integraram o modelo a um sistema de *e-learning* baseado na tecnologia Java2D que contém um conjunto intensivo de materiais de aprendizado para dar suporte a todos os tipos de alunos.

Leithardt et al. (2012), desenvolveram um sistema de controle para ambientes de aprendizagem especializados em educação especial. Entre seus muitos usos possíveis, o sistema se concentra no gerenciamento do atendimento às aulas de alunos de educação especial, professores e outros usuários de sala de aula por meio do uso de tecnologias difundidas e onipresentes. O sistema visa contribuir para a extensão dos sistemas de computação pervasiva para ambientes educacionais.

Kozierkiewicz; Zysk (2013), propuseram um método para determinar um cenário de aprendizado de abertura com base na técnica de otimização de colônias de formigas. O algoritmo tenta escolher o material de aprendizagem mais adequado aos estilos de aprendizagem do aluno e ao nível de conhecimento atual armazenado no perfil do aluno. O método para determinar um cenário de aprendizado inicial exigia a definição de um perfil de aluno e uma representação de conhecimento.

Anaya; Luque; García-Saiz (2013), apresentaram um sistema de recomendação baseado em um Diagrama de Influência (DI) no contexto de aprendizado colaborativo no ambiente de *e-learning*. A solução de DI forneceu uma tabela de decisão de recomendação, que alerta sobre situações problemáticas. O objetivo do sistema não consiste apenas em analisar o acompanhamento dos alunos e as avaliações de colaboração, mas também encontrar uma recomendação pessoal para um aluno-alvo.

Balderas et al. (2013), desenvolveram sistema de apoio para classificação das competências de aprendizagem de acordo com o desempenho dos alunos em um curso *online*. Os autores implementaram *EvalCourse*, um sistema de computador que executa consultas escritas nessa linguagem, fornecendo na saída as informações solicitadas. Dessa forma, os professores podem recuperar facilmente indicadores de informações armazenadas nos registros de atividades do *Moodle* sem nenhum conhecimento técnico em bancos de dados ou programação de computadores.

Dimopoulos; Petropoulou; Retalis (2013), apresentaram uma ferramenta de avaliação, chamada Rubrica Enriquecida de análise de Aprendizagem, que foi desenvolvida como um *plugin* do *Moodle*. A ferramenta permite que os professores criem facilmente “rubricas enriquecidas” contendo critérios e níveis de classificação relacionados. Para isso são utilizados dados extraídos da análise da interação dos alunos e do comportamento de aprendizagem em um curso *Moodle*, tais como o número de mensagens postadas, horários de acesso, material e notas de tarefas.

Manhães; Cruz; Zimbrão (2014), forneceram aos gestores e acadêmicos de universidades públicas brasileiras, não especialistas em EDM, uma arquitetura *WAVE*, que fornece informações úteis sobre o desempenho de estudantes de graduação e prevê aqueles que estão em risco de abandono.

Sharma; Ahuja (2016), apresentam uma abordagem integrada de recomendação semântica usando ontologia para recomendar conteúdo de aprendizagem relevante e personalizado para os alunos com base em quatro abordagens básicas:

1. Abordagem de recomendação baseada em perfil de usuário;
2. Recomendação de pré-requisito do caminho de aprendizagem, recomenda o conteúdo do curso, que deve ser aprendido antes de se obter um conteúdo específico do curso;
3. Recomendação de filtragem colaborativa e;
4. Recomendação baseada em semelhança semântica.

Venugopalan; Srinath; Rodrigues (2016), propuseram um sistema de recomendação baseado em conteúdo, abalizado na modelagem pedagógica de conteúdo, expandindo a consulta com base na taxonomia e nos detalhes necessários. O sistema de recomendação classifica as consultas do usuário com base no conteúdo disponível no repositório e encontra a melhor correspondência.

El Fouki; Aknin; El. Kadiri (2017), propuseram um sistema de tomada de decisão que ajuda os instrutores a responder a problemas usando técnicas gerais inteligentes aplicadas aos dados coletados em plataformas de *e-learning*.

El Moustamid; En-Naimi; Bouhdidi (2017), desenvolveram um sistema capaz de analisar o perfil dos alunos e indexar vídeos na *web*, a fim de oferecer aos alunos um banco de dados com cursos que correspondem aos seus níveis. Os autores propuseram uma arquitetura

de um sistema de recomendação de cursos multimídia, que ajuda professores a avaliar os alunos e identificar suas lacunas, além de ajudar a encontrar os cursos que correspondem aos seus níveis, sem se perder no grande volume de vídeos disponíveis na internet.

O estudo de Lagman; Mansul (2017), foi conduzido principalmente com aprendizado individualizado e personalizado, adaptado a requisitos específicos e preferências de aprendizado. A pesquisa se concentra nas avaliações dos alunos e na aprendizagem como seu principal componente-chave dos processos de *e-learning*. O sistema captura caminhos de *e-learning* de cada aluno e determina tópicos e assuntos difíceis, nos quais é essencial fornecer intervenção acadêmica aos alunos. O sistema serve como ferramenta educacional complementar para ajudar os alunos a melhorar seu desempenho acadêmico.

O artigo apresentado por Kolekar; Pai (2018), teve como objetivo entender as características dos alunos e gerar a interface do usuário personalizada de acordo com seus estilos de aprendizado, baseados em análise do *log* da *web*. O Modelo de Estilo de Aprendizagem *Felder-Silverman* (FSLSM) é uma combinação de três outros modelos que combinam o melhor de todos esses modelos. FSLSM categoriza os alunos em um conjunto predefinido de classes de estilo de aprendizagem e possui oito categorias ou classes de aprendizes: Sensível, Intuitivo, Global, Sequencial, Verbal, Visual, Reflexivo e Ativo.

Chanaa; Faddouli (2018), propuseram um modelo personalizado com três componentes principais, análise sentimental, análise cognitiva e estilo de aprendizagem, que utiliza as trilhas e a pegada dos usuários quando usam um sistema de gerenciamento de aprendizado a fim de encontrar informações convenientes sobre os alunos e explorá-las com sucesso, além de melhorar a taxa de conclusão do curso e fornecer a eles conteúdos adequados que atendam às suas necessidades e preferências individuais.

Também foi desenvolvido um sistema de recomendação de cursos distribuídos para a plataforma de *e-learning* por Dahdouh et al. (2018), com objetivo de descobrir as relações entre as atividades do aluno usando o método de regras de associação. O objetivo do sistema é ajudar o aluno a escolher os materiais de aprendizagem mais adequados. Também se utilizou da análise de dados históricos passados das matrículas nos cursos ou dados de registro. O artigo discutiu particularmente o conceito de conjuntos de itens frequentes para determinar as regras interessantes no banco de dados de transações. Em seguida, são usadas as regras extraídas para encontrar o catálogo de cursos mais adequados, de acordo com os

comportamentos e preferências do aluno. O sistema de recomendação utiliza tecnologias e técnicas de *Big Data*.

A contribuição de Dahdouh et al. (2019), foi o desenvolvimento de uma nova abordagem para sistemas de aprendizado *online* baseados em tecnologias de *Big Data* na computação em nuvem. Os autores sugeriram uma metodologia para usar a enorme quantidade de dados produzidos pelas plataformas de aprendizado *online*.

Huang et al. (2019), propuseram uma nova estrutura de aprendizado de reforço profundo para recomendação de exercícios. Na estrutura, foram propostas duas redes Q do exercício (EQN) para selecionar recomendações de exercícios seguindo mecanismos diferentes, ou seja, um EQNM direto com propriedade de *Markov* e um EQNR sofisticado com maneira recorrente. Também foram aproveitadas três recompensas específicas de domínios para caracterizar os benefícios de fatores como revisão e exploração, suavidade e engajamento, para permitir que a estrutura encontre a estratégia de recomendação ideal.

Wang; Sun; Chen (2019), propuseram um sistema inteligente de assistente de ensino que substitui a maneira de esperar pela resposta manual, de forma a responder de maneira inteligente à pergunta do usuário, para que ele possa obter a resposta imediatamente e continuar aprendendo, o que melhora a continuidade da aprendizagem. O sistema usa a tecnologia de processamento de linguagem natural (PNL) como ferramenta de desenvolvimento e *design*. O assistente foi criado para plataformas de aprendizagem *online* para fornecer *feedback* aos alunos e aumentar seu entusiasmo pelo aprendizado.

No artigo apresentado por Joy; Raj; G (2019), verificou-se um modelo de ontologia que engloba o perfil do aluno e os atributos do objeto de aprendizagem, que podem ser usados para a recomendação de conteúdo em uma plataforma de *e-learning*. O modelo de ontologia conceitua as características do aluno e do objeto de aprendizagem que podem ser usadas para recomendação de conteúdo em um ambiente de aprendizado adaptável. São consideradas as características estáticas e dinâmicas de um aluno para modelá-las.

Os autores Iqbal et al. (2019), criaram um novo algoritmo, o *Kernel Context Recommender System*, que é uma estrutura de mapeamento de kernel flexível, rápida e precisa que reconhece a importância do contexto e incorpora as informações contextuais usando o truque do *kernel* ao fazer previsões. Foi proposta uma estrutura sensível ao contexto para as versões baseada em usuário e item, usando o conceito de mapeamento do *kernel* na filtragem colaborativa.

O algoritmo do sistema de recomendação de mapeamento do *kernel* é baseado em uma nova técnica de aprendizado de estrutura. Essa estrutura tem flexibilidade para explorar vários contextos relacionados a usuários e itens durante o processo de recomendação, usando diferentes *kernels* que influenciam o desempenho do sistema, melhorando os fatores preditivos de precisão, escalabilidade e flexibilidade. Foi criado um modelo de processamento automatizado capaz de resolver problemas de aprendizagem sem exigir intervenção humana.

Lavoie; Proulx (2020), desenvolveram um sistema de gerenciamento de aprendizagem com recursos exclusivos orientados para “cursos invertidos” que permite aos alunos assistir vídeos e interagir nos *Jupyter Notebooks*. O sistema de gerenciamento de aprendizagem cria automaticamente gráficos de progressão para cada aluno e envia mensagens automáticas relacionadas à sua progressão. Para os instrutores, o sistema cria automaticamente estatísticas sobre a progressão geral do curso ao longo das aulas e exercícios e permite direcionar alunos com dificuldade, que podem ser ajudados individualmente e diminuir a taxa de falhas.

Kapembe; Quenum (2020), apresentaram uma abordagem de recomendação híbrida, baseada no perfil do aluno, na relevância e qualidade dos objetos de aprendizagem para o programa em que o aluno está matriculado e no *feedback* dos alunos. A abordagem usa as preferências de aprendizagem, o desempenho e os interesses do aluno para recomendar objetos de aprendizagem com base no perfil exclusivo do aluno.

Ruangvanich; Nilsook; Wannapiroon (2020), desenvolveram um sistema de análise de aprendizagem como uma ferramenta para apoiar a aprendizagem dos alunos. As tecnologias têm sido propostas como um meio de apoiar a prática reflexiva com base em dados do instrutor, essas tecnologias são consideradas uma prioridade na pesquisa e inovação educacional. O sistema é composto por dez elementos, a saber: ambiente virtual de aprendizagem, análise de aprendizagem, alerta, LMS, registros de aprendizagem, partes interessadas, dados, informações do aluno, aprendizagem direta e informações de relatório

Chen et al. (2020a), criaram um método de recomendação aprimorado denominado Recomendação Adaptativa com base no *Online Learning Style*. Este método é integrado a um modelo abrangente de estilo de aprendizagem para alunos *online*. O método faz recomendações considerando o estilo de aprendizagem como conhecimento prévio. Primeiro, gera grupos de alunos de diferentes estilos de aprendizagem e segundo, os padrões comportamentais representados pela matriz de similaridade de recursos de aprendizado e regras de associação de cada *cluster*, são extraídos usando o histórico de navegação dos

alunos e por fim, cria um conjunto de recomendações personalizadas de tamanho variável de acordo com os resultados de mineração de dados das etapas anteriores.

Kim; Kim (2020), desenvolveram um tutor individualizado de IA como um sistema que integra três DLNs (*Developmental Learning Networks*) estendendo a rede teoria da ressonância adaptativa profunda (*Deep ART*) para ajudar um aluno a alcançar um alto nível de sucesso acadêmico, sugerindo conteúdos de aprendizagem adequados que correspondem ao currículo educacional padrão.

Zaoudi; Belhadaoui (2020), propuseram um modelo de LBA (*Learner Behavior Analytics*) baseado em um sistema chamado SBAN para analisar os resultados e o comportamento dos alunos, responsável por monitorar e avaliar continuamente o nível real do aluno ao longo de sua trajetória de treinamento. Os autores pretendem detalhar mais esses modelos, propondo uma arquitetura e protótipos que permitirão modelar melhor o sistema LBA, permitindo apresentar um conteúdo mais adaptável aos perfis dos alunos em evolução.

Khosravi; Sadiq; Gasevic (2020b), desenvolveram um sistema de aprendizagem adaptável, escalável e independente de conteúdo que depende de *crowdsourcing* (contribuição colaborativa) e parceria com alunos para desenvolver recursos de aprendizagem. É um sistema de aprendizagem adaptável que recomenda atividades personalizadas aos alunos, com base no seu estado de conhecimento. O sistema recomenda a partir de um agrupamento de atividades de aprendizagem *crowdsourced* que são gerados e avaliados pelos próprios educadores e alunos.

Villegas Ch; Arias Navarrete; Palacios Pacheco (2020), propuseram a integração de tecnologias, como inteligência artificial e análise de dados, com sistemas de gerenciamento de aprendizagem. A proposta foi baseada em um modelo de educação *online* de uma universidade do Equador. Como ferramenta, o modelo utilizava um LMS, onde os alunos tinham seções com recursos e atividades que serviam para o treinamento do modelo.

Chang et al. (2020), desenvolveram uma ontologia capaz de mapear dados de interação do aluno para um conjunto de ações de tutoria. Esse mecanismo permitiu que um tutor artificial observasse os alunos em termos de suas interações com o ambiente de aprendizagem. Também fornece uma ação de tutoria adequada para melhorar o processo de aprendizagem. O ambiente divide o processo de aprendizagem em uma sequência de atividades, e os dados de interação do aluno vêm da última atividade, mas também inclui um conjunto de dados agregando informações anteriores (histórico de estudo). Embora

normalmente uma ontologia seja construída por humanos (engenheiros do conhecimento e especialistas na área), neste trabalho, os autores propuseram um processo automático de construção de ontologia.

Azzi et al. (2020), propuseram um classificador capaz de identificar o estilo de aprendizagem do aluno no sistema de *e-Learning*. O comportamento de aprendizagem do aluno foi capturado em diferentes contextos, geralmente em diferentes cursos relacionados a um assunto específico. A mineração de uso da web foi utilizada para capturar os comportamentos dos alunos e, em seguida, os estilos de aprendizagem foram mapeados para as categorias *Felder-Silverman Learning Style Model* (FSLSM). Os autores utilizaram o algoritmo *Fuzzy C Means* para agrupar os dados de aprendizagem comportamental.

Ullah et al. (2020), propuseram o modelo IoT baseado em Rede Definida por *Software* (RDS) para interação de alunos, que interconecta alunos a um professor em um ambiente de cidade inteligente. Alunos e professores são livres para se deslocar para qualquer lugar, a qualquer hora e com qualquer *hardware*. Um modelo RDS-IMSI interconecta os alunos com o professor por meio de seus dispositivos IoT heterogêneos.

O trabalho proposto por Rajkumar; Ganapathy (2020), encontrou uma correlação entre os tipos de personalidade introvertida e extrovertida e seus estilos de aprendizagem correspondentes. O questionário VARK modificado foi implementado como um *chatbot* para classificar os indivíduos. Após as avaliações do *chatbot*, todos os alunos (introvertidos e extrovertidos) assistiram ao conteúdo visual e auditivo em um ambiente totalmente silencioso. Enquanto assiste ao conteúdo, as ondas cerebrais Beta dos alunos foram registradas e um conjunto de dados foi criado em um intervalo de um segundo. Este conjunto de dados foi validado usando algoritmos de classificação de aprendizado de máquina, como *Naïve Bayes*, árvore N48 e algoritmos de agrupamento, melhorando a precisão da classificação dos alunos.

Shi et al. (2020), propuseram um modelo de recomendação de caminho de aprendizagem baseado em uma estrutura de grafo de conhecimento multidimensional. Inicialmente, os autores projetaram uma estrutura de grafo de conhecimento multidimensional que armazena separadamente objetos de aprendizagem organizados em várias classes. Em seguida, eles propuseram seis relações semânticas principais entre os objetos de aprendizagem no grafo de conhecimento. Em segundo lugar, eles projetaram um modelo de recomendação de caminho com base na estrutura do gráfico de conhecimento multidimensional. O modelo gera e sugere caminhos de aprendizagem personalizados de acordo com o objeto de

aprendizagem alvo do aluno. Os resultados da experiência indicaram que o modelo proposto pode gerar e recomendar caminhos de aprendizagem qualificados e personalizados para melhorar as experiências de aprendizagem.

Lin; Li; Lian (2020), criaram uma estrutura de recomendação complementar para calouros sob restrições ou requisitos, com base em padrões orientados a metas. Os alunos podem obter os resultados das recomendações de acordo com diferentes tipos de objetivos de aprendizagem. A estrutura desenvolvida pelos autores apresenta as seguintes contribuições: (1) *framework* de otimização convexa através da integração das características dos cursos e alunos da Universidade; (2) algoritmo de aprendizado de máquina baseado em dados usando recursos extraídos de dados formatados e não formatados.

Iknam; Thulasiraman (2020), projetaram e implementaram um sistema de recomendação de caminhos de aprendizagem. O sistema agrupa os alunos e escolhe um caminho de aprendizagem adequado com base em seus conhecimentos anteriores. O componente de *clustering* usou o *Fuzzy Algoritmo C-Mean* (FCM), que pode recomendar mais de um caminho de aprendizagem para alunos localizados nos limites do *cluster*. A eficácia do sistema LPR foi avaliada através do desenvolvimento e oferta de um curso de banco de dados para alunos reais.

zhang; ghandour; shestak (2020), realizaram análises de aprendizagem para descobrir possibilidades de melhorar o processo de aprendizagem e reduzir o número de alunos com baixo desempenho usando *plugins* do ambiente virtual *Moodle*. A análise considerou registros de 124 participantes, para verificar a relação entre a quantidade de registros no e-curso e as notas finais dos alunos. Os autores também realizaram uma análise de correlação para determinar o impacto da atividade educacional dos alunos no sistema *Moodle* na avaliação final.

Villegas Ch; Arias Navarrete; Palacios Pacheco (2020), propuseram uma arquitetura para a integração de um *chatbot* com inteligência artificial em um campus inteligente para melhorar o aprendizado. Os autores elaboraram um modelo que integra a identificação e avaliação de variáveis por meio da análise de dados que os alunos geram nos sistemas acadêmicos. Os resultados da análise dos dados são transferidos para uma ferramenta de IA para tomada de decisão.

Angeline; Ramasubramanian; James (2020), usaram a análise discriminante para medir o desempenho dos alunos. A técnica de mineração de dados identificou as habilidades

cognitivas dos alunos e seus comportamentos associados em uma sala de aula virtual com instrutor. Os conjuntos de dados coletados no estudo de pesquisa referem-se a diferentes assuntos abordados por alunos de graduação em engenharia do Dr. G. U. *Pope College of Engineering (Hyderabad, Índia)*. Os desempenhos dos alunos nos respectivos pré-requisitos da disciplina foram coletados dos registros departamentais de resumos de resultados relacionados ao curso de ciência da computação e à disciplina de engenharia. Segundo os autores, a análise discriminante funciona bem com o conjunto de dados cobrindo todos os grupos de dados e fornece uma melhor previsão.

Hashim; Awadh; Hamoud (2020), compararam o desempenho de vários algoritmos de aprendizado de máquina supervisionado para prever o sucesso acadêmico dos alunos e seu desempenho no ensino superior. Os autores utilizaram um conjunto de dados fornecidos pelos cursos dos Programas de Licenciatura da Faculdade de Informática e Tecnologia da Informação da Universidade de *Basra*, nos anos letivos 2017-2018 e 2018-2019, para prever o desempenho dos alunos nos exames finais. Os experimentos mostraram que o algoritmo classificador de Regressão Logística apresentou o melhor desempenho.

Freitas et al. (2020), propuseram uma abordagem para detectar e classificar os alunos em risco de evasão com base em seus dados socioeconômicos. A plataforma IoT foi projetada para permitir que essa tarefa seja realizada em qualquer dispositivo conectado à internet. Métodos de aprendizado de máquina foram usados para identificar a possibilidade de evasão.

Barlybayev et al. (2020a), propuseram a criação de um sistema inteligente para avaliar os níveis de competências profissionais dos alunos em *e-learning*. Modelos e métodos matemáticos foram usados para avaliar a formação das habilidades profissionais dos alunos no nível das disciplinas, módulos e todo o programa educacional. Avaliações de competência (conhecimento), foram realizadas em três níveis do programa educacional. Para avaliar o conhecimento, relacionamentos binários difusos foram usados, respostas padrão da base de conhecimento e as respostas dos alunos.

Os autores usaram cálculos *fuzzy* em dados obtidos pelo algoritmo de comparação. A construção dos cálculos *fuzzy* utilizou o método *Mamdani* implementado no *Matlab*. O estudo permitiu a identificação de publicações sobre serviços inteligentes aplicados ao ensino a distância. Entre os serviços inteligentes, apresentavam sistemas de aprendizagem, sistemas de recomendação, modelos ou sistemas de previsão e ferramentas de avaliação. O estudo indicou que sistemas de recomendação e sistemas de aprendizagem são tendências de pesquisa. Esses

sistemas analisam perfis de alunos, identificam padrões de comportamento, detectam baixo desempenho e identificam probabilidades de evasão dos cursos. A maioria dos trabalhos de pesquisa analisa o perfil de aprendizagem para indicar conteúdo personalizado e cursos ou atividades extracurriculares que contribuem para o aprendizado do aluno. Além disso, as obras permitem que professores e gestores educacionais tomem ações preventivas para minimizar possíveis problemas nas trajetórias de aprendizagem.

Chen et al. (2020c), propuseram um modelo de previsão em fases para prever alunos em risco em diferentes semestres. Foram analisadas as características dos alunos e os comportamentos de aprendizagem *online*. O modelo proposto tem três contribuições principais: (1) estratégias de restrição para obter recursos valiosos; (2) um modelo de previsão dinâmica; e (3) pode prever alunos em risco em diferentes fases do semestre.

Nuguri et al. (2021), apresentaram o vSocial, um sistema de ambiente de aprendizagem de realidade virtual baseado em nuvem que pode ser implantado em redes de alta velocidade usando a plataforma de “VR social” de alta fidelidade. Para o desenvolvimento do vSocial, os autores contaram com a utilização de um AVA de educação especial já existente, o iSocial que forma jovens com Desordem do Espectro do Autismo através da implementação do currículo de Intervenção por Competência Social.

Mendes et al. (2021), propuseram uma ferramenta educacional baseada na detecção de movimento usando o sensor *Kinect* em um jogo que é projetado na parede da sala de aula. Os alunos usam bolas para acertar os elementos projetados. Essas colisões são detectadas pelo sensor e registradas no programa, completando assim a tarefa em questão. Segundo os autores, o sistema e a arquitetura foram projetados para facilitar a vida dos professores na promoção da atividade física em combinação com o aprendizado em sala de aula. O sistema proposto é baseado na projeção de atividades educacionais e na possibilidade de alunos ou usuários interagirem com elas por meio de exercícios.

Maâloul; Bahou (2021), propuseram um sistema de recomendação que se baseia fundamentalmente em uma técnica de aprendizagem digital (ou seja, aprendizagem semi-supervisionada) e que determina o grau de similaridade entre os alunos, para recomendar os itens correspondentes ao interesse do aluno. O sistema visa processar perfis de alunos a partir da plataforma de *e-learning*. A proposta visa prever e determinar as preferências dos alunos com base nas informações compartilhadas em suas diferentes redes sociais.

Han; Xu (2021), criaram um sistema educacional inteligente que foi customizado para fornecer aos alunos recursos adequados às suas percepções ao iniciar a plataforma. Os sistemas fornecem um ambiente com uma gama completa de ferramentas de comunicação assíncrona e síncrona. O sistema projetado requer uma combinação de sensores, dispositivos, *software*, aplicativos e serviços em tempo real.

Iatrellis et al. (2021), propuseram uma abordagem de aprendizado de máquina em dois estágios que usa técnicas de aprendizado supervisionado e não supervisionado para prever resultados para alunos no ensino superior. O objetivo da pesquisa foi prever os resultados dos alunos dos cursos de graduação em ciência da computação oferecidos por instituições de ensino superior na Grécia. Os alunos envolvidos no estudo de caso foram agrupados com base na similaridade de fatores e métricas relacionados à educação. O algoritmo *K-means* foi usado nos experimentos de agrupamento, e o resultado produziu evidências de que a abordagem proposta pode contribuir para a precisão da previsão dos resultados dos alunos.

Turabieh et al. (2021), simularam a modificação proposta do algoritmo de otimização *Harris Hawks* como um algoritmo de seleção de recursos para o problema de previsão de desempenho dos alunos. A abordagem proposta melhora o algoritmo de Otimização *Harris Hawks* original e apoia a afirmação de que o controle da diversidade populacional melhora o processo de exploração do algoritmo.

O estudo permitiu a identificação de publicações sobre serviços inteligentes aplicados ao ensino a distância. Entre os serviços inteligentes, apresentavam sistemas de aprendizagem, sistemas de recomendação, modelos ou sistemas de previsão e ferramentas de avaliação. O estudo indicou que sistemas de recomendação e sistemas de aprendizagem são tendências de pesquisa. Esses sistemas analisam perfis de alunos, identificam padrões de comportamento, detectam baixo desempenho e identificam probabilidades de evasão dos cursos.

A maioria dos trabalhos de pesquisa analisa o perfil de aprendizagem para indicar conteúdo personalizado e cursos ou atividades extracurriculares que contribuem para o aprendizado do aluno. Além disso, as obras permitem que professores e gestores educacionais tomem ações preventivas para minimizar possíveis problemas nas trajetórias de aprendizagem.

A Tabela 7 apresenta os tipos de serviços inteligentes que vêm sendo ofertados no âmbito da educação à distância. Os principais serviços oferecidos são categorizados como sistemas de gerenciamentos, sistemas de recomendação semântica, sistemas de tomadas de

decisões, sistemas de recomendações, baseado em conteúdo, sistemas de recomendações baseado em agentes, sistemas para análises de perfis, arquiteturas, algoritmos, linguagens específicas de domínios, sistema inteligente de assistente de ensino, tutor inteligente, estruturas e modelos baseados nos perfis de alunos que oferecem recomendações de conteúdo para melhorias no processo de ensino e aprendizagem.

Tabela 7: Relação dos artigos que contêm serviços inteligentes

Referências	Serviços Inteligentes.
1. (THAI-NGHE et al., 2010)	Técnicas de sistema de recomendação para mineração de dados educacionais, especialmente para prever o desempenho do aluno.
2. (ZAKRZEWSKA, 2010)	Sistema de recomendação baseado em agentes, que, para cada novo sugere um grupo de estudantes de perfis semelhantes.
3. (FLORIAN et al., 2011)	Protótipo que implementa indicadores como exemplos de aplicações analíticas de aprendizado.
4. (HAMADA, 2012)	Modelo de um sistema de <i>e-learning</i> baseado na tecnologia Java2D e que contém um conjunto intensivo de materiais de aprendizado para dar suporte a todos os tipos de alunos.
5. (LEITHARDT et al., 2012)	Sistema de controle para ambientes de aprendizagem especializados em educação especial.
6. (KOZIERKIEWICZ; ZY SK, 2013)	Algoritmo para determinar um cenário de aprendizado de abertura com base na técnica de otimização de colônias de formigas.
7. (ANAYA; LUQUE; GARCÍA-SAIZ, 2013)	Sistema de recomendação baseado em um DI no contexto de aprendizado colaborativo no ambiente de <i>e-learning</i> .
8. (BALDERAS et al., 2013)	Linguagem específica de domínio para personalizar as avaliações de aprendizado <i>online</i> no <i>Moodle</i> .
9. (DIMOPOULOS; PETROPOULOU; RETALIS, 2013)	Ferramenta de avaliação, chamada Rubrica Enriquecida de Análise de Aprendizagem, que foi desenvolvida como um <i>plugin</i> do <i>Moodle</i> .
10. (MANHÃES; CRUZ; ZIMBRÃO, 2014)	Arquitetura <i>WAVE</i> que fornece informações úteis sobre o desempenho de estudantes.
11. (SHARMA; AHUJA, 2016)	Recomendação semântica usando ontologia para recomendar conteúdo de aprendizagem relevante e personalizado para os alunos.
12. (VENUGOPALAN; SRINATH; RODRIGUES, 2016)	Sistema de recomendação baseado em conteúdo.
13. (EL FOUKI; AKNIN; EL. KADIRI, 2017)	Sistema de tomada de decisão para ajudar os instrutores.
14. (EL MOUSTAMID; EN-NAIMI; BOUHDIDI, 2017)	Sistema capaz de analisar o perfil dos alunos e indexar vídeos na <i>web</i> , a fim de oferecer aos alunos um banco de dados com cursos que correspondem aos seus níveis.

Referências	Serviços Inteligentes.
15. (LAGMAN; MANSUL, 2017)	Sistema que captura caminhos de <i>e-learning</i> de cada aluno e pode determinar tópicos e assuntos difíceis, nos quais é essencial fornecer intervenção acadêmica aos alunos.
16. (KOLEKAR; PAI; M.M., 2018)	Interface do usuário personalizada conforme seus estilos de aprendizado, baseados em análise do <i>log</i> da web.
17. (CHANAA; FADDOULI, 2018)	Modelo personalizado com 3 componentes principais, análise sentimental, análise cognitiva e estilo de aprendizagem.
18. (DAHDOUH et al., 2018)	Sistemas de aprendizado <i>online</i> baseados em tecnologias de <i>Big Data</i> na computação em nuvem.
19. (DAHDOUH et al., 2019)	Sistema de recomendação de cursos distribuídos para a plataforma de <i>e-learning</i> .
20. (HUANG et al., 2019)	Estrutura de aprendizado de Reforço Profundo para Recomendação de Exercícios.
21. (WANG; SUN; CHEN, 2019)	Sistema inteligente de assistente de ensino que substitui a maneira de esperar pela resposta manual.
22. (JOY; RAJ; G, 2019)	Modelo de ontologia que engloba o perfil do aluno e os atributos do objeto de aprendizagem, que podem ser usados para a recomendação de conteúdo em uma plataforma de <i>e-learning</i> .
23. (IQBAL et al., 2019)	Algoritmo <i>Kernel Context Recommender System</i> , que é uma estrutura de mapeamento de <i>kernel</i> flexível, rápida e precisa que reconhece a importância do contexto e incorpora as informações contextuais usando o truque do <i>kernel</i> ao fazer previsões.
24. (LAVOIE; PROULX, 2020)	Sistema de gerenciamento de aprendizagem (LMS) com recursos exclusivos orientados para “cursos invertidos”.
25. (KAPEMBE; QUENUM, 2020)	Recomendação híbrida (RS), baseada no perfil do aluno, na relevância e qualidade dos objetos de aprendizagem para o programa em que o aluno está matriculado e no <i>feedback</i> dos alunos.
26. (RUANGVANICH; NILSOOK; WANNAPIROON, 2020)	Sistema de análise de aprendizagem como uma ferramenta para apoiar a aprendizagem dos alunos.
27. (CHEN et al. 2020)	Método de recomendação aprimorado denominado Recomendação Adaptativa com base no <i>Online Learning Style</i> .
28. (KIM; KIM, 2020)	Tutor individualizado de Inteligência Artificial (IA) como um sistema que integra três DLNS (<i>Developmental Learning Networks</i>).
29. (ZAOUDI; BELHADAOUI, 2020)	Modelo de LBA (<i>Learner Behavior Analytics</i>) baseado em um sistema chamado SBAN (<i>Score and Behavior Analytics</i>) para analisar os resultados e o comportamento dos alunos.
30. (KHOSRAVI; SADIQ; GASEVIC, 2020)	Sistema de aprendizagem adaptável, escalável e independente de conteúdo que depende de <i>crowdsourcing</i> .
31. (VILLEGAS-CH; ARIAS NAVARRETE; PALACIOS PACHECO, 2020)	Integração de tecnologias, como IA e análise de dados, com sistemas de gerenciamento de aprendizagem para melhorar a aprendizagem.

Referências	Serviços Inteligentes.
32. (CHANG et al., 2020)	Ontologia para mapear dados de interação do aluno para um conjunto de ações de tutoria.
33. (AZZI et al., 2020)	Classificador capaz de identificar o estilo de aprendizagem do aluno no sistema de <i>e-Learning</i> .
34. (ULLAH et al., 2020)	Modelo IoT baseado em Rede Definida por <i>software</i> para interação de alunos.
35. (RAJKUMAR; GANAPATHY, 2020)	Questionário VARK modificado foi implementado como um <i>chatbot</i> para classificar os indivíduos.
36. (SHI et al., 2020)	Modelo de recomendação de caminho de aprendizagem baseado em uma estrutura de grafo de conhecimento multidimensional.
37. (LIN; LI; LIAN, 2020)	Estrutura de recomendação complementar para calouros sob restrições ou requisitos, com base em padrões orientados a metas.
38. (NIKNAM; THULASIRAMAN, 2020)	Sistema de recomendação de caminhos de aprendizagem.
39. (VILLEGAS-CH; ARIAS NAVARRETE; PALACIOS PACHECO, 2020)	Arquitetura para a integração de um <i>chatbot</i> com inteligência artificial em um campus inteligente para melhorar o aprendizado.
40. (ZHANG; GHANDOUR; SHESTAK, 2020)	Análises de aprendizagem para descobrir possibilidades de melhorar o processo de aprendizagem e reduzir o número de alunos com baixo desempenho usando plugins do ambiente virtual <i>Moodle</i> .
41. (ANGELINE; RAMASUBRAMANIAN; JAMES, 2020)	Análise discriminante para medir o desempenho dos alunos.
42. (HASHIM; AWADH; HAMOUD, 2020)	Comparação do desempenho de vários algoritmos de aprendizado de máquina supervisionado para prever o sucesso acadêmico dos alunos e seu desempenho no ensino superior.
43. (FREITAS et al., 2020)	Abordagem para detectar e classificar os alunos em risco de evasão com base em seus dados socioeconômicos.
44. (BARLYBAYEV et al., 2020a)	Sistema inteligente para avaliar os níveis de competências profissionais dos alunos em <i>e-learning</i> .
45. (CHEN et al., 2020c)	Modelo de previsão em fases para prever alunos em risco em diferentes semestres.
46. (HAN; XU, 2021)	Sistema de educação inteligente que foi customizado para fornecer ao aluno recursos adequados às suas percepções ao iniciar a plataforma.
47. (NUGURI et al., 2021)	Sistema de ambiente de aprendizagem de realidade virtual baseado em nuvem.
48. (MENDES et al., 2021)	Ferramenta educacional baseada na detecção de movimento usando o sensor <i>Kinect</i> .
49. (MAÂLOUL; BAHOU, 2021)	Sistema de recomendação que se baseia fundamentalmente em uma técnica de aprendizagem digital.

Referências	Serviços Inteligentes.
50. (IATRELLIS et al., 2021)	Abordagem de aprendizado de máquina em dois estágios que usa técnicas de aprendizado supervisionado e não supervisionado para prever resultados para alunos no ensino superior.
51. (TURABIEH et al., 2021)	Algoritmo de otimização <i>Harris Hawks</i> como um algoritmo de seleção de recursos para o problema de previsão de desempenho dos alunos.

Fonte: Elaborado pela autora

3.2.3 QG3 – Quais estratégias vêm sendo aplicadas para obtenção de benefícios para discentes, docentes e gestores por meio da análise de dados no âmbito da EaD?

Os artigos indicam estratégias que vêm sendo aplicadas por meio de análise de dados dos alunos que ficam armazenados em ambientes virtuais ou em sistemas de gestão acadêmicas. As estratégias podem ser categorizadas em dois aspectos: 1) aplicação de métodos e técnicas de análises e 2) serviços inteligentes. As estratégias categorizadas como aplicação de métodos e técnicas de análises de dados são:

- a) estruturas de *softwares* para desenvolvimento de modelos de previsão, sistema de mineração de dados educacionais (LARA et al., 2014);
- b) infraestrutura de pipeline (CHAFFAI; HASSOUNI; ANOUN, 2017);
- c) estrutura de previsão de desempenho do aluno (QU et al., 2018);
- d) sistema orientado para análise dos resultados (ZORRILLA; GARCÍA; ÁLVAREZ, 2010);
- e) algoritmo PCA (ROS et al., 2017);
- f) métodos baseados em uma classe estatística latente (SOROUR; GODA; MINE, 2015);
- g) aplicação da mineração de dados usando técnicas computacionais (PEÑAFIEL et al., 2018);
- h) gráfico misto de termos (CLARIZIA et al., 2018);
- i) plataforma de mineração de opinião (SPATIOTIS et al., 2018);

- j) técnicas de mineração de dados como agrupamento e associação (ISLAM; SIDDIQUI; ALJOHANI, 2020);
- k) técnica estatística de *Machine Learning* (HUSSAIN et al., 2018);
- l) mecanismo de análise de *feedback* distribuído para *Big Data* (ALTAF; SOOMRO; RAWI, 2019);
- m) redes neurais para prever o desempenho (OLANREWAJU et al., 2016);
- n) método de previsão de estilo de aprendizagem (YANG et al., 2014);
- o) sistema que usa a metodologia de votação (KOTSIANTIS; PATRIARCHEAS; XENOS, 2010);
- p) modelo comportamental de aprendizagem baseado em LBPN (CHANG; CHU, 2010);
- q) algoritmos de *clustering* (OMAR; ABDESELAM, 2017);
- r) método para prever notas finais de alunos por uma rede neural recorrente (OKUBO et al., 2017);
- s) ferramenta de análise acadêmica (GRAF et al., 2011);
- t) técnicas complementares - *cluster* hierárquico (RAYON; GUENAGA; NUNEZ, 2014);
- u) metodologia de análise de aprendizado (UZIR et al., 2020); y) método baseada em LA (GUO; YAN; LI, 2020) e;
- v) modelo explicativo do comportamento do aluno (JOVANOVIc et al., 2020).

As estratégias categorizadas como serviços inteligentes são:

- a) sistema de gerenciamento de aprendizagem (LAVOIE; PROULX, 2020);
- b) recomendação semântica usando ontologia (SHARMA; AHUJA, 2016);
- c) recomendação híbrida baseada no perfil do aluno (KAPEMBE; QUENUM, 2020);
- d) estrutura de aprendizado de reforço profundo (HUANG et al., 2019);
- e) sistema de tomada de decisão (EL FOUKI; AKNIN; EL. KADIRI, 2017);
- f) sistema de recomendação baseado em conteúdo (VENUGOPALAN; SRINATH; RODRIGUES, 2016);

- g) linguagem específica de domínio (BALDERAS et al., 2013);
- h) arquitetura WAVE (MANHÃES; CRUZ; ZIMBRÃO, 2014);
- i) sistema inteligente de assistente de ensino (WANG; SUN; CHEN, 2019);
- j) sistema de análise de perfil (EL MOUSTAMID; EN-NAIMI; BOUHDIDI, 2017);
- k) algoritmo com base na técnica de otimização de colônias de formigas (KOZIERKIEWICZ; ZYSK, 2013);
- l) protótipo de indicadores (FLORIAN et al., 2011);
- m) sistemas de aprendizado *online* baseados em tecnologias de *Big Data* (DAHDOUH et al., 2018);
- n) sistema de recomendação baseado em agentes (ZAKRZEWSKA, 2010);
- o) sistema de *e-learning* baseado na tecnologia Java2D (HAMADA, 2012);
- p) sistema de recomendação baseado em um DI (ANAYA; LUQUE; GARCÍA-SAIZ, 2013);
- q) sistema de captura (LAGMAN; MANSUL, 2017);
- r) modelo personalizado (CHANAA; FADDOULI, 2018);
- s) modelo de ontologia (JOY; RAJ; G, 2019);
- t) ferramenta de avaliação (DIMOPOULOS; PETROPOULOU; RETALIS, 2013);
- u) método de recomendação adaptativa (CHEN et al., 2020a);
- v) algoritmo *Kernel Context Recommender System* (IQBAL et al., 2019);
- w) sistemas de recomendação de cursos distribuídos (DAHDOUH et al., 2019);
- x) interface do usuário personalizada (KOLEKAR; PAI; M.M., 2018);
- y) técnicas de sistema de recomendação para mineração de dados educacionais (THAINGHE et al., 2010);
- z) tutor individualizado de inteligência artificial (KIM; KIM, 2020) e;
- aa) modelo de LBA baseado em um sistema chamado SBAN (ZAoudi; BELHADAoui, 2020).

A aplicação de métodos e técnicas de análises de dados fornecem previsão de nota do aluno, detecção de padrão de comportamento do aluno, previsão do progresso acadêmico do aluno, modelagem do perfil do aluno, previsão de riscos de abandono do curso e fornecimento de *feedback* de desempenho do aluno para os professores.

Além disso, gestores e professores podem oferecer sistemas de recomendações para solucionar problemas no processo de ensino e aprendizagem ofertando conteúdos adequados que atendam às necessidades e preferências individuais dos alunos.

A utilização da análise de dados beneficia não somente alunos e professores, mas também os gestores que podem usar modelos analíticos para realizar campanhas mais direcionadas, oferecer serviços diferenciados de acordo com o perfil do aluno, entre outros. As informações obtidas por meio das análises de dados dos alunos, ajudam gestores na tomada de decisão a curto, médio e a longo prazo.

3.2.4 QF1 – Existem métodos/técnicas de análise que vêm utilizando históricos de registros de *logs* dos alunos no âmbito da EaD?

Dos 51 artigos mapeados, onze artigos apresentam a aplicação de métodos de análise nos traços de interação dos alunos deixados nos registros de *logs* dos sistemas de gerenciamento de aprendizagem disponíveis nos ambientes virtuais de aprendizagem.

O artigo apresentado por Kolekar; Pai (2018), teve como objetivo entender as características dos alunos e gerar a interface do usuário personalizada conforme seus estilos de aprendizado, baseados em análise do *log* da *web*.

Graf et al. (2011), apresentaram uma ferramenta de análise acadêmica desenvolvida no *Moodle Analytics* que incorpora funcionalidade para analisar dados relacionados ao comportamento dos alunos.

Florian et al. (2011), desenvolveram um protótipo que implementa indicadores como exemplos de aplicações analíticas de aprendizado. O processo de prototipagem indicou que o rastreamento de atividades do *Moodle* inclui dados sobre estruturas sociais mais complexas em ambientes virtuais de aprendizagem.

Dimopoulos; Petropoulou; Retalis (2013), apresentaram uma ferramenta de avaliação, chamada Rubrica Enriquecida de análise de Aprendizagem, que foi desenvolvida como um *plugin* do *Moodle* contendo critérios e níveis de classificação relacionados que estão associados aos dados extraídos da análise da interação dos alunos e do comportamento de aprendizagem em um curso *Moodle*.

Os autores Lara et al. (2014), utilizaram técnicas de mineração de dados nos *logs* do banco de dados interno do *Moodle* com o objetivo de descobrir os padrões representativos de cada grupo de alunos.

Omar; Abdesselam (2017), usaram algoritmos de classificação nos traços de interação com uma plataforma de *e-learning* e, especificamente, em arquivo de *log* extraído da plataforma de *e-learning* da Universidade de *Bechar* com o objetivo de testar e comparar o desempenho dos algoritmos.

Lagman; Mansul (2017), criaram um sistema que captura os percursos de *e-learning* de cada aluno e pode determinar tópicos e assuntos difíceis nos quais é essencial fornecer intervenção acadêmica aos alunos, servindo como ferramenta educacional complementar para ajudá-los a melhorar seu desempenho acadêmico.

Hussain et al. (2018), aplicaram técnicas estatísticas nos dados de registros de *logs* no *Moodle*, para identificar alunos com baixo desempenho ou inativos e permitir ao instrutor tomadas de decisões inteligentes antes do exame final.

Islam; Siddiqui; Aljohani (2020), empregaram técnicas de mineração de dados aplicadas nos dados de interação dos alunos para identificar padrões de comportamentos e possíveis atributos-chaves para prever o desempenho final acadêmico.

Altaf; Soomro; Rawi (2019), utilizaram as redes neurais artificiais para prever o desempenho dos alunos baseando-se nos dados de *logs* de um sistema de gerenciamento de campus.

Para melhorar a taxa de conclusão do curso e fornecer conteúdos adequados que atendam às necessidades e preferências individuais do aluno, Chanaa; Faddouli (2018), propuseram um modelo personalizado composto que utiliza as trilhas e a pegada dos alunos quando utilizam um sistema de gerenciamento de aprendizado a fim de encontrar informações convenientes sobre os alunos e explorá-las com sucesso.

A Tabela 8 apresenta os métodos/técnicas encontrados nos artigos que utilizaram análise de dados usando históricos de registros de *logs* com objetivo de identificar padrões de comportamento de aprendizagem, identificar alunos com baixo desempenho ou inativos e intervir oferecendo ferramentas ou conteúdo personalizado como apoio educacional.

Os métodos e técnicas aplicadas na EaD compreendem as técnicas de mineração de dados educacionais (LARA et al., 2014); (ISLAM; SIDDIQUI; ALJOHANI, 2020), técnicas estatísticas (HUSSAIN et al., 2018), redes neurais artificiais (ALTAF; SOOMRO; RAWI, 2019), algoritmos de classificação (OMAR; ABDESELAM, 2017), ferramenta de análise (GRAF et al., 2011), protótipos de indicadores (FLORIAN et al., 2011), sistemas de captura (LAGMAN; MANSUL, 2017), modelo personalizado (CHANAA; FADDOULI, 2018), ferramenta de avaliação (DIMOPOULOS; PETROPOULOU; RETALIS, 2013) e interface personalizada (KOLEKAR; PAI; M.M., 2018).

Tabela 8: Relação dos artigos que contêm métodos de análise utilizando históricos de registros

Referências	Métodos/técnicas de Análise
1. (ALTAF; SOOMRO; RAWI, 2019)	Redes neurais para prever o desempenho dos alunos baseando-se nos dados de <i>logs</i> .
2. (KOLEKAR; PAI; M.M., 2018)	Interface do usuário personalizada conforme seus estilos de aprendizado, baseados em análise do <i>log</i> da <i>web</i> .
3. (CHANAA; FADDOULI, 2018)	Modelo personalizado com 3 componentes principais, análise sentimental, análise cognitiva e estilo de aprendizagem.
4. (DIMOPOULOS; PETROPOULOU; RETALIS, 2013)	Ferramenta de avaliação, chamada Rubrica Enriquecida de Análise de Aprendizagem.
5. (FLORIAN et al., 2011)	Protótipo que implementa indicadores como exemplos de aplicações analíticas de aprendizado.
6. (GRAF et al., 2011)	Ferramenta de análise acadêmica desenvolvida no <i>Moodle Analytics</i> .
7. (HUSSAIN et al., 2018)	Técnicas estatística nos dados de registros de <i>logs</i> no <i>Moodle</i> .
8. (ISLAM; SIDDIQUI; ALJOHANI, 2020)	Técnicas de mineração de dados aplicadas nos dados de interação dos alunos.
9. (LAGMAN; MANSUL, 2017)	Sistema que captura caminhos de <i>e-learning</i> de cada aluno.
10. (LARA et al., 2014)	Técnicas de mineração de dados nos dados de <i>logs</i> no banco de dados interno do <i>Moodle</i> .
11. (OMAR; ABDESELAM, 2017)	Algoritmos de classificação nos traços de interação com uma plataforma de <i>e-learning</i> .

Fonte: Elaborado pela autora.

3.2.5 QF2 - Existem serviços inteligentes para grupos colaborativos de alunos na área de educação à distância?

O trabalho em grupo é um importante recurso para os professores promoverem a aprendizagem colaborativa, mas são muitas as dificuldades em identificar alunos com perfis semelhantes na formação de grupos, no caso dos cursos à distância essas dificuldades aumentam e pesquisas sobre sistemas de análise de perfis de alunos para recomendar grupos de estudo colaborativos ainda são escassos. Dentre os 51 artigos mapeados, três artigos contêm a temática abordada na questão focal 2.

Kolekar; Pai (2018), desenvolveram um aplicativo de *e-learning* baseado no framework *Moodle* que captura dados de uso do aluno e analisa esses dados para identificar os alunos do grupo de acordo com o estilo de aprendizagem, gerando uma interface personalizada para o usuário. O modelo de estilo de aprendizagem *Felder-Silverman Learning Style Model* (FSLSM) é uma combinação de três outros modelos que combinam o melhor de todos esses modelos (*Kolb, Pask, Dunn-Dunn, Myers-Briggs, Felder-Silverman*, entre outros). Este modelo (FSLSM) categoriza os alunos em um conjunto predefinido de classes de estilo de aprendizagem e tem oito categorias ou classes de alunos, a saber: sensitivo, intuitivo, global, sequencial, verbal, visual, reflexivo e ativo.

O sistema de recomendação de grupos proposto por Zakrzewska (2010), visa sugerir que os novos alunos escolham colegas, com os quais possam aprender juntos, utilizando os mesmos recursos do curso. Pressupõe-se que os grupos de alunos já tenham sido criados e que sejam constituídos por alunos com características semelhantes, como estilos cognitivos, preferências de usabilidade ou com comportamentos históricos muito semelhantes. As recomendações são baseadas em três coletas de dados: os atributos dos membros do grupo, os materiais de ensino equipados com bandeiras que indicam os alunos-alvo e a terceira de um novo recurso do aluno.

O sistema executa duas tarefas: recomendar materiais de ensino para grupos e recomendar grupos para novos alunos. No sistema apresentado pelos autores, os agentes são Análise de aprendizagem e grupos colaborativos de alunos em educação a distância: um estudo de mapeamento sistemático implementado para fornecer a cada novo aluno recomendações de turmas de alunos de perfis semelhantes e, consequentemente, indicar

recursos de aprendizagem adequados, ou encaminhe o aluno para o tutor se algum grupo de colegas semelhantes não existir.

Anaya; Luque; García-Saiz (2013), propuseram um diagrama de influência, que inclui as variáveis observáveis relevantes para avaliar a colaboração e a variável que representa se o aluno colabora ou não. O objetivo principal era criar um sistema que analisasse as avaliações de acompanhamento e colaboração dos alunos para identificar as circunstâncias do aluno e propor uma recomendação pessoal ao aluno-alvo. A análise fornece aos professores e alunos uma explicação amigável que pode ajudá-los a corrigir deficiências no processo de colaboração, aumentando assim sua confiança e melhorando seu aprendizado.

Os principais sistemas de recomendação têm características semelhantes, ou seja, baseiam-se na análise de perfis de alunos e, em sua maioria, oferecem recomendação de conteúdo de aprendizagem (SHARMA; AHUJA, 2016; VENUGOPALAN; SRINATH; RODRIGUES, 2016; CHANAA; FADDOULI, 2018; JOY; RAJ; G, 2019; KIM; KIM, 2020), recomendação de objetos de aprendizagem (KAPEMBE; QUENUM, 2020), recomendação de exercício (HUANG et al., 2019), recomendação de curso (EL MOUSTAMID; EN-NAIMI; BOUHDIDI, 2017; DAHDOUH et al., 2019) e recursos de aprendizagem (CHEN et al., 2020a).

3.2.6 FQ3 - Quais são as tendências percebidas?

A ferramenta de mapeamento bibliométrico *VOSViewer* (VAN ECK; WALTMAN, 2018) foi usada para estudar o interesse de pesquisa nos 51 artigos mapeados e publicados de 2010 a 2020 na Biblioteca Digital ACM, Biblioteca Digital *IEEE Xplore*, Biblioteca *Springer*, *ScienceDirect* e bases de dados *Scopus*.

A ferramenta foi usada para identificar *clusters* que indicaram áreas de interesse compartilhadas com base no conteúdo das publicações. Após a normalização dos termos, ou seja, a identificação e classificação dos sinônimos, a ferramenta *VOSViewer* identificou 48 itens e 4 *clusters* entre as 51 publicações selecionadas. A Tabela 09 mostra os termos e o número de ocorrências dos artigos.

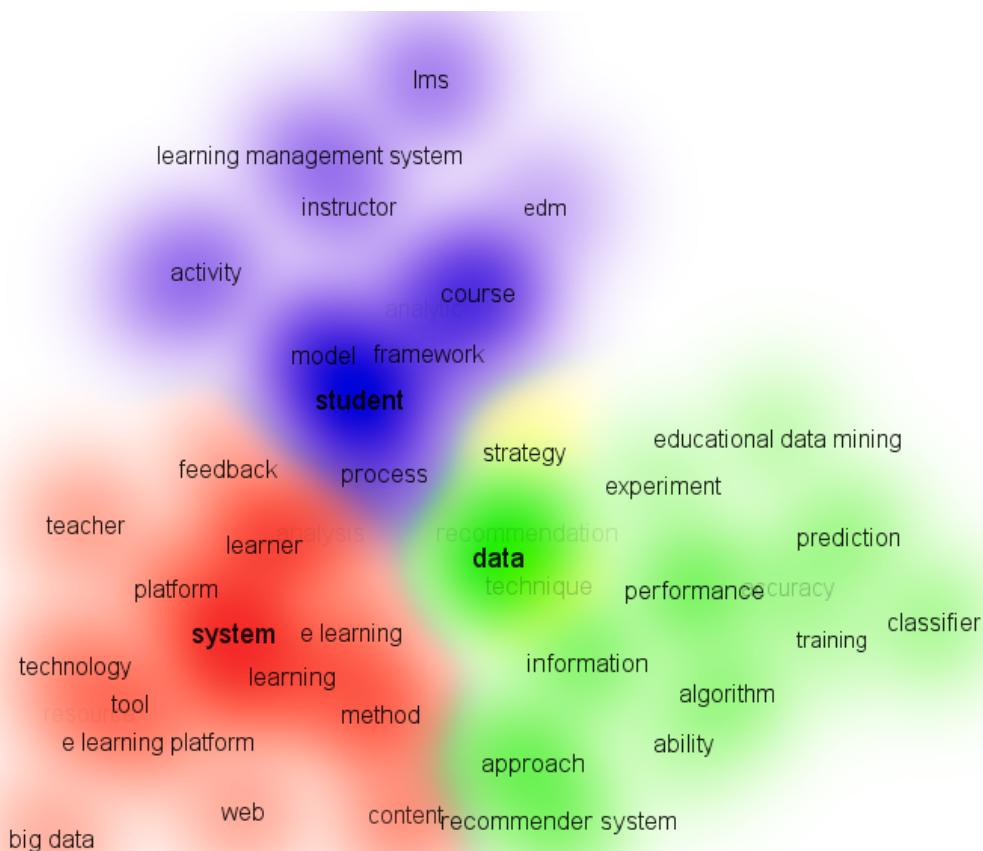
Tabela 9: Principais clusters, termos e números de ocorrência

Cluster	Termos	Número de ocorrências
Azul	Estudante	80
Vermelho	Sistema	77
Verde	Dados	76
Amarelo	Técnicas	29

Fonte: Elaborado pela autora.

A Figura 2 mostra a densidade dos termos e a formação dos clusters de interesse, agrupados por cores de acordo com a proximidade dos termos.

Figura 2: Densidade do cluster

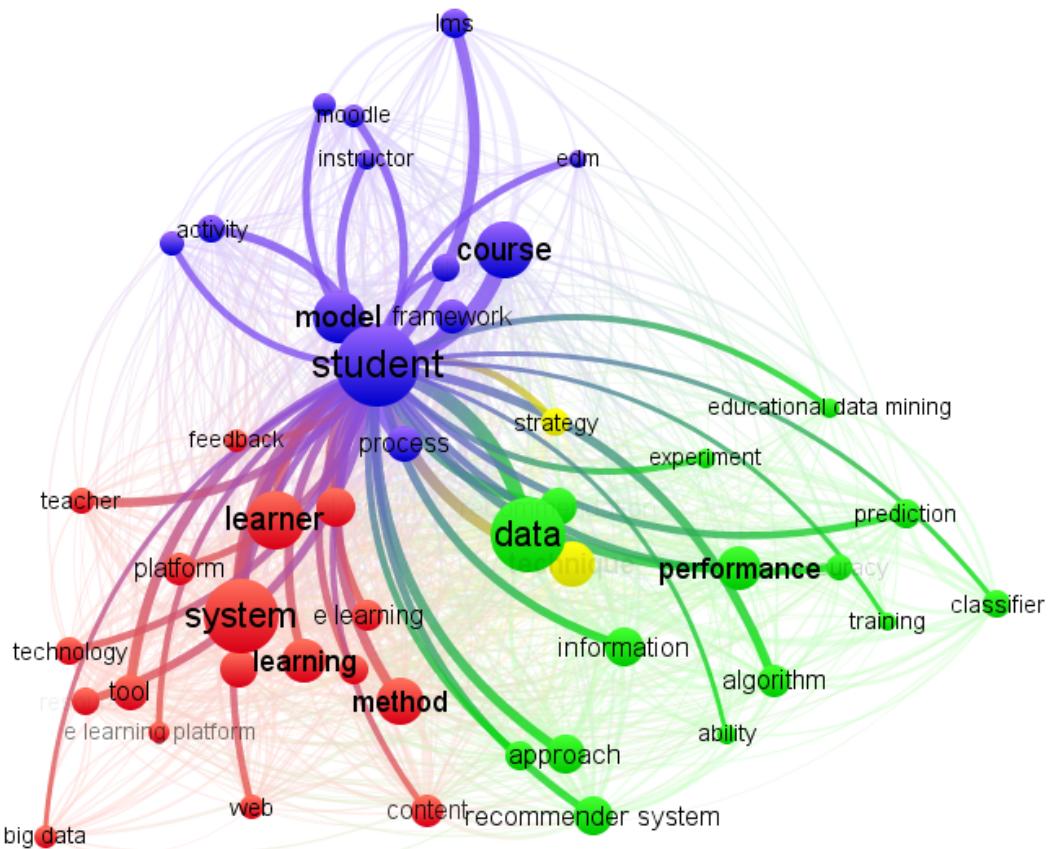


Fonte: Elaborado pela autora.

Os *clusters* são caracterizados da seguinte forma:

- *Cluster Azul*: Este cluster é composto por 13 itens, sendo que o termo “Aluno” se destacou dos demais com 80 ocorrências. Este *cluster* também se relaciona com o curso, modelo, estrutura, atividade, instrutor, processo, LMS, indicando relações no contexto de alunos e cursos. Este *cluster* também se conecta a outros clusters, conforme destacado na Figura 3.

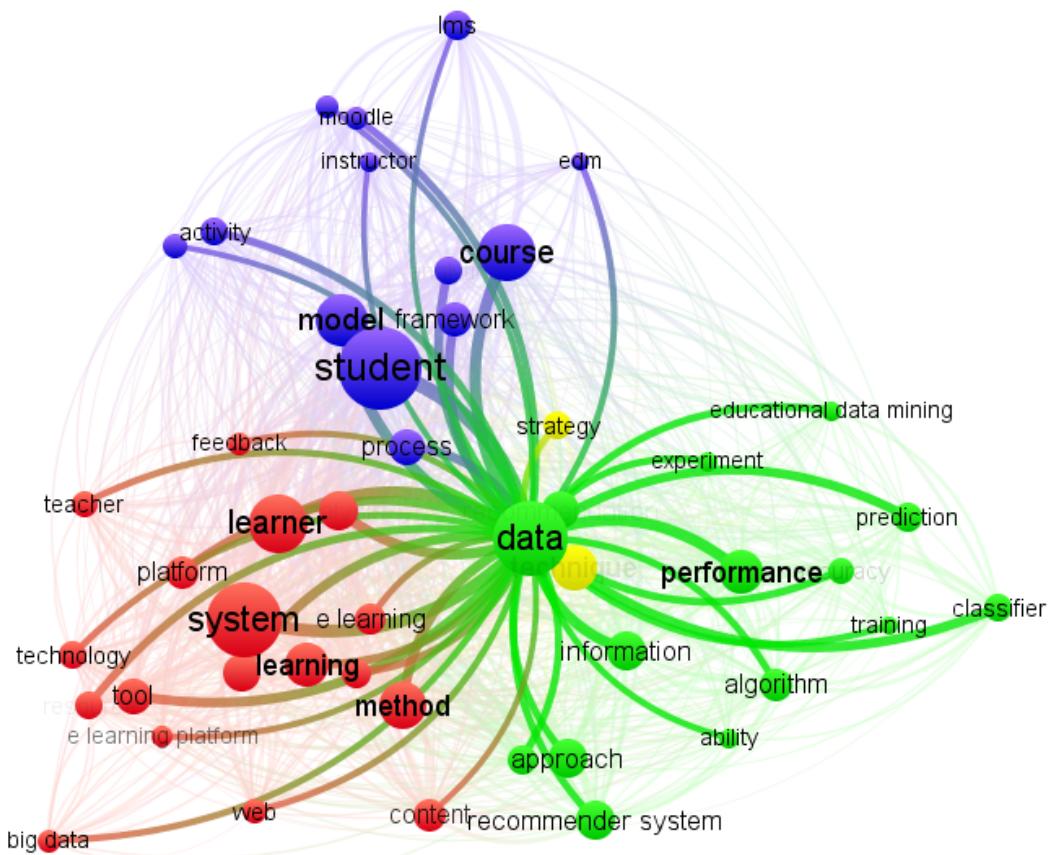
Figura 3: Conexões do *cluster* azul



Fonte: Elaborado pela autora.

- *Cluster Verde*: Este cluster abriga 15 itens. Neste *cluster*, o destaque se refere ao termo “dados” que foi observado em 76 ocorrências e referentes a diversos algoritmos. A Figura 4 apresenta a conexão do termo principal com outros *clusters* e outros termos.

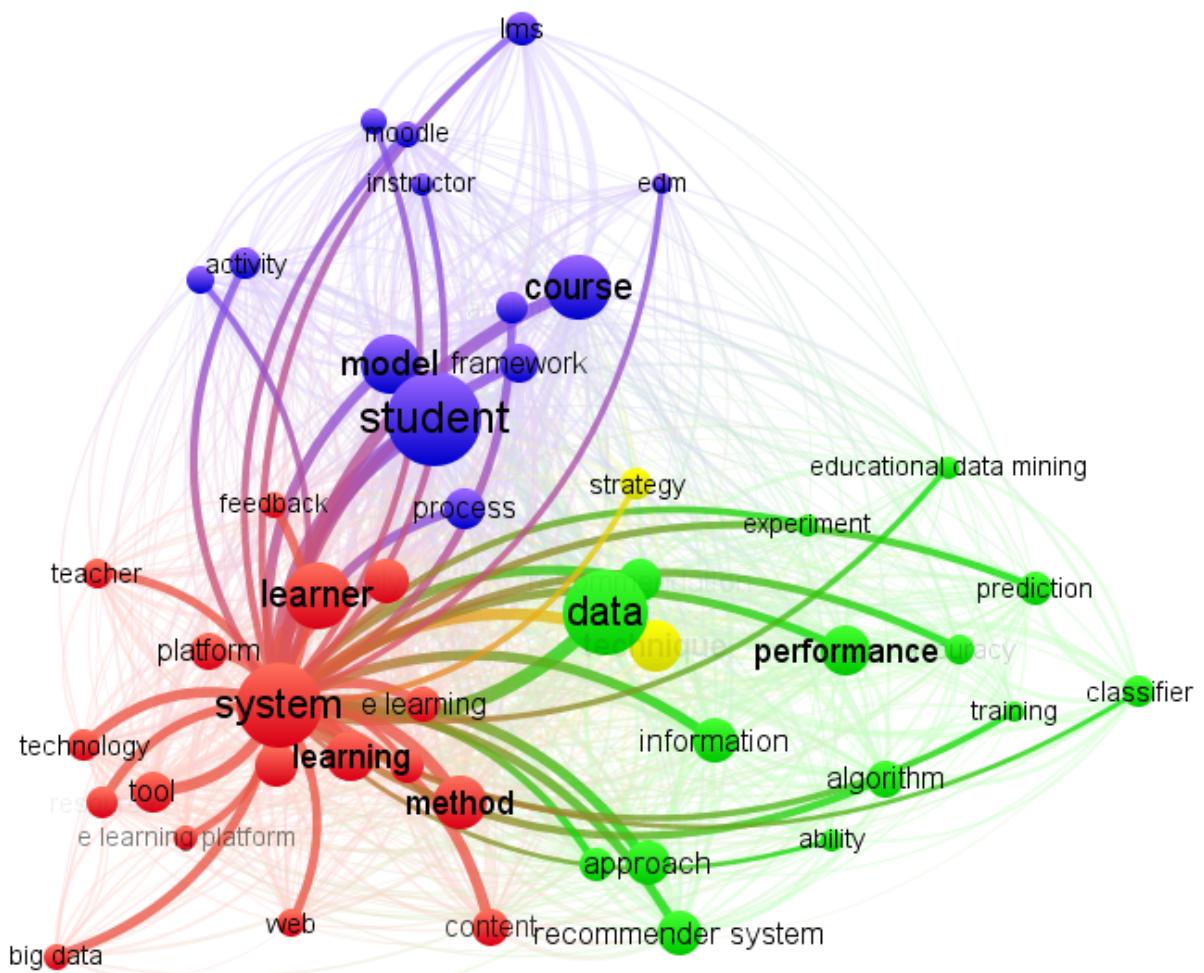
Figura 4: Conexões do *cluster* verde



Fonte: Elaborado pela autora.

- *Cluster Vermelho:* Este é o maior cluster, composto por 18 itens, com foco em “sistemas” com 77 ocorrências, seguido de outros termos com ocorrências menores, como “aprendiz”, com 44, e “aprendizagem”, com 26. A Figura 5 mostra que o termo “sistema” se conecta com os outros *clusters* e com os outros termos.

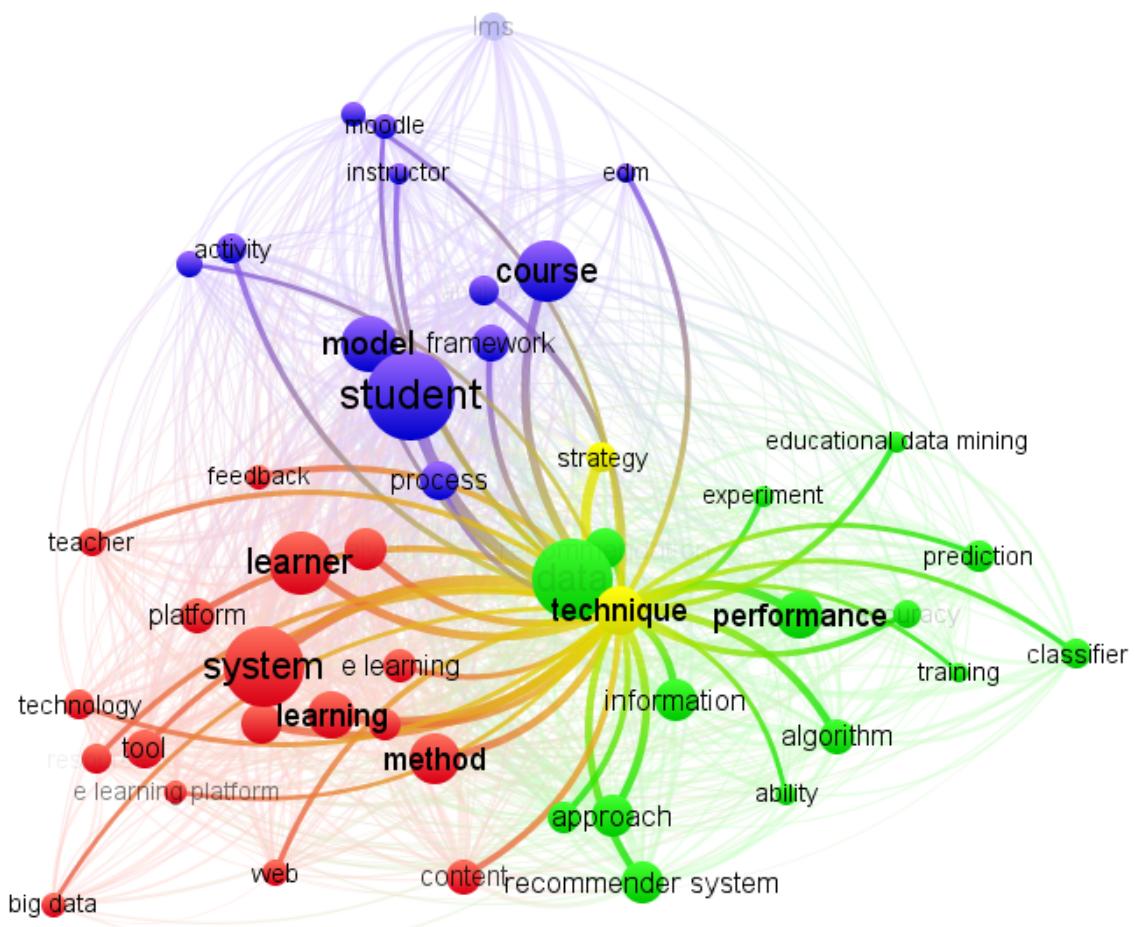
Figura 5: Conexões do *cluster* vermelho



Fonte: Elaborado pela autora.

- *Cluster Amarelo*: cluster menor, composto por apenas 2 itens, e o termo “técnica” tem 29 ocorrências e o termo “estratégia” 11. Como os outros, o *cluster* amarelo tem conexões com outros *clusters* e outros termos, conforme mostrado na Figura 6.

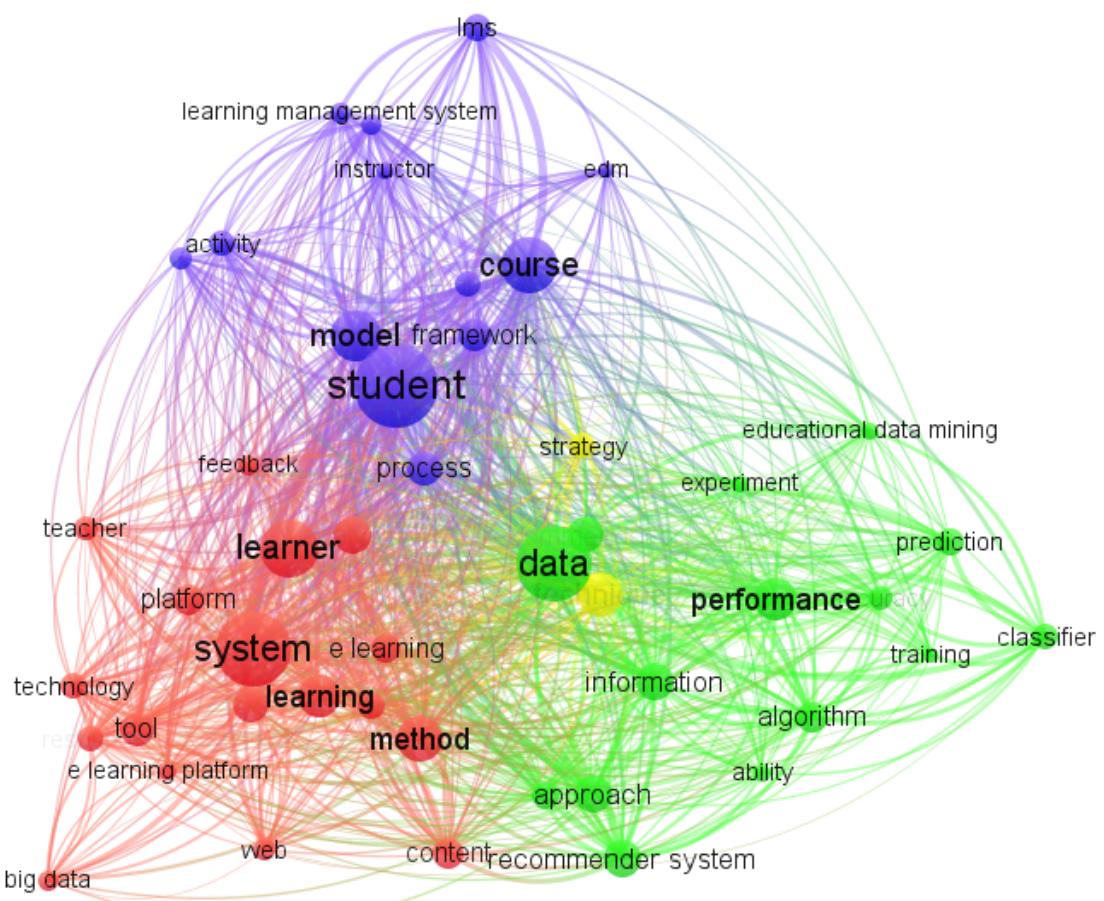
Figura 6: Conexões do *cluster* amarelo



Fonte: Elaborado pela autora.

A Figura 7 fornece uma visão geral das conexões entre os termos do mesmo *cluster* ou de diferentes *clusters*. As conexões são determinadas por fatores como a ocorrência de termos em artigos. Este modelo representa a sobreposição da incidência cronológica de termos no mapa de *cluster*.

Figura 7: Visão geral da relação entre os termos



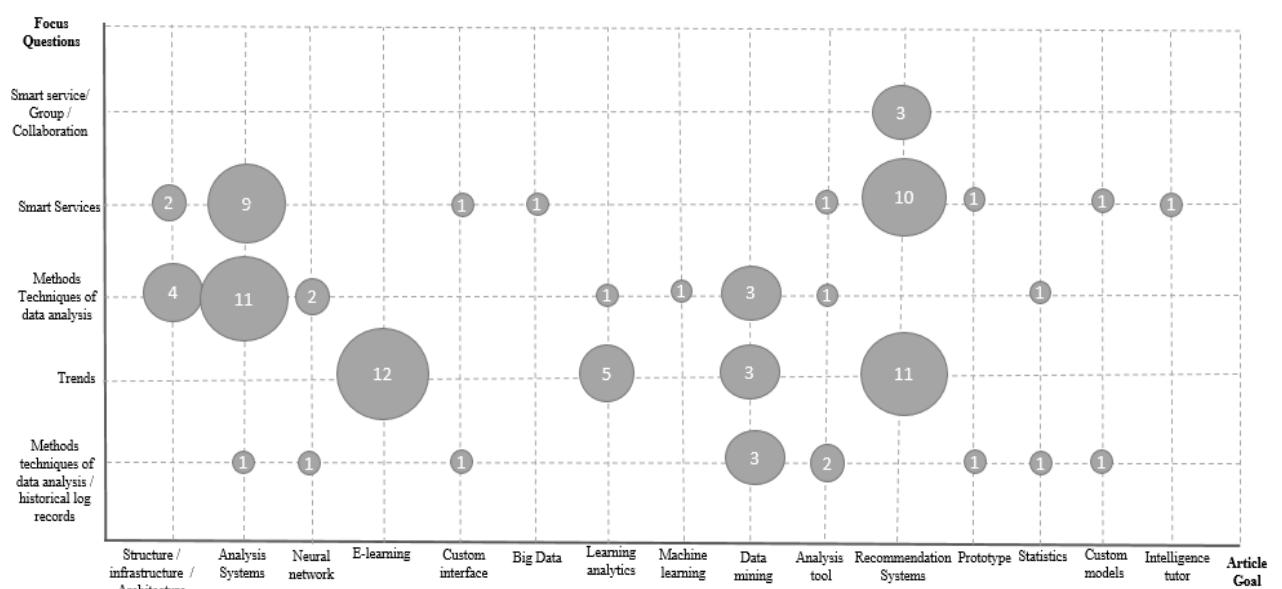
Fonte: Elaborado pela autora.

A identificação e apresentação dos *clusters* apontam para os principais termos explorados no corpus final composto por 51 artigos. Após a análise dos 48 termos do agrupamento, foram identificados 6 termos que se destacam como tendência de busca, sendo: sistema de recomendação (THAI-NGHE et al., 2010; ANAYA; LUQUE; GARCÍA-SAIZ, 2013; VENUGOPALAN; SRINATH; RODRIGUES, 2016; KAPEMBE; QUENUM, 2020; IQBAL et al., 2019; DAHDOUH et al., 2019), mineração de dados educacionais (THAI-

NGHE et al., 2010; LARA et al., 2014; OLIVÉ et al., 2018), Análise (ZORRILLA; GARCÍA; ÁLVAREZ, 2010; GRAF et al., 2011; OLANREWAJU et al., 2016; ROS et al., 2017; PEÑAFIEL et al., 2018; UZIR et al., 2020), sistema de gestão de aprendizagem (OKUBO et al., 2017; OLIVÉ et al., 2018; CHANAA; FADDOULI, 2018), *e-learning* e plataforma de *e-learning* (CHANG; CHU, 2010; ZORRILLA; GARCÍA; ÁLVAREZ, 2010; HAMADA, 2012; ANAYA; LUQUE; GARCÍA-SAIZ, 2013; OLANREWAJU et al., 2016; OMAR; ABDESELAM, 2017; EL FOUKI; AKNIN; EL. KADIRI, 2017; LAGMAN; MANSUL, 2017; CLARIZIA et al., 2018; JOY; RAJ; G, 2019; DAHDOUH et al., 2019). Esses termos estão dentro dos *clusters* vermelho, azul e verde e têm conexões entre si e conexões com os outros *clusters*.

A Figura 8 enfoca as questões de pesquisa versus os objetivos dos artigos mapeados e o resultado corrobora as tendências identificadas por meio da ferramenta *VOSViewer*. Os artigos selecionados referem-se principalmente aos sistemas inteligentes de recomendações, sistemas de análise e aos termos *learning analytics* e *e-learning*. A Figura 8 mostra que os serviços inteligentes como sistemas de recomendação são destacados. Um cenário menos explorado é o de serviços inteligentes colaborativos para identificação e criação de grupos. Apenas três artigos abordaram este tema (ANAYA; LUQUE; GARCÍA SAIZ, 2013; ZAKRZEWSKA, 2010; DAHDOUH et al., 2019).

Figura 8: Questões de pesquisa versus objetivos dos artigos mapeados

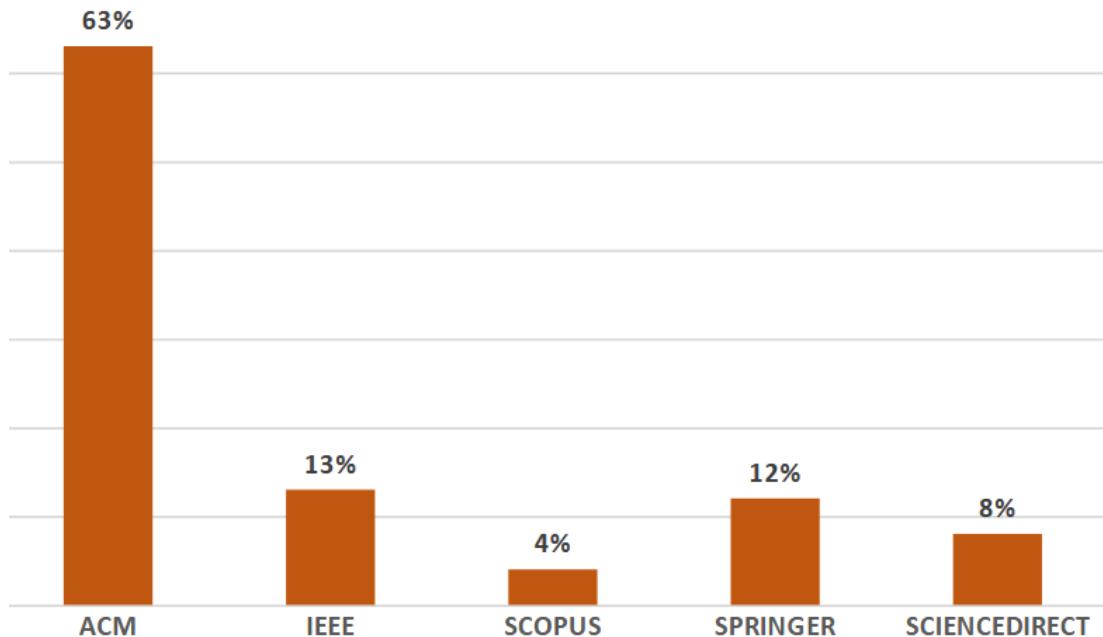


Fonte: Elaborado pela autora.

3.2.7 QE1 – Em quais bases de dados os trabalhos foram publicados?

A Figura 9 apresenta a porcentagem de publicações dos 51 artigos mapeados sobre a temática no período de 2010 a junho de 2020. Pode-se observar que a maioria das publicações encontradas foram na base de dados da *ACM Digital Library* com 63% dos artigos, seguida pelas bases *IEEE Xplore Digital Library* com 13%, *Springer Library* com 12%, *ScienceDirect* com 8%, e *Scopus* com apenas 4%.

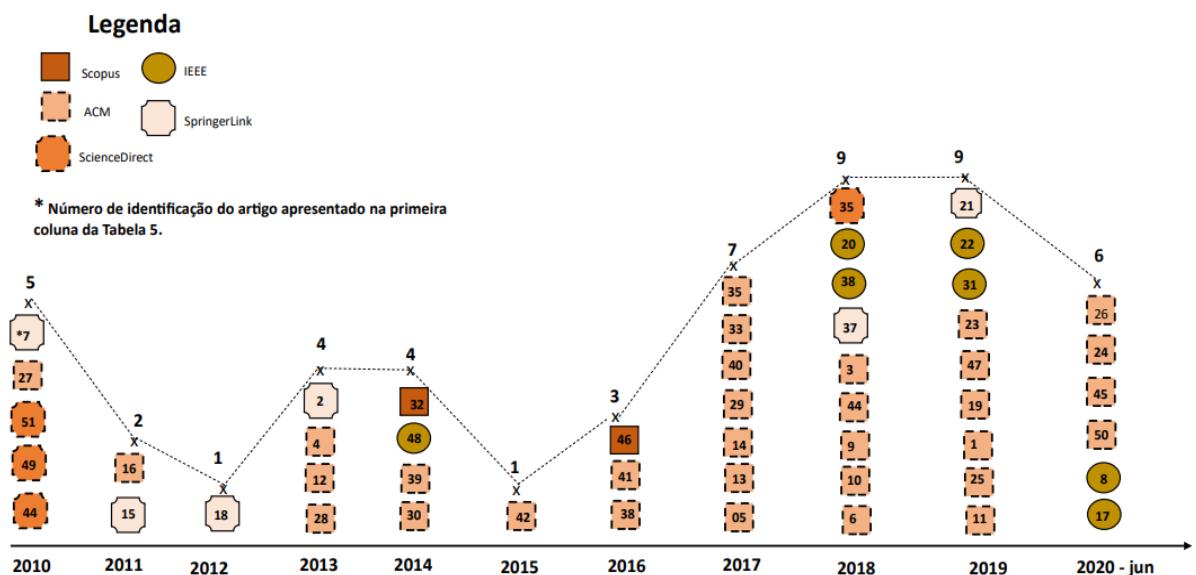
Figura 9: Bases de publicações



Fonte: Elaborado pelo autor.

Observa-se na Figura 10 que em 2010 foram publicados 5 artigos, tendo um declínio nos anos de 2011 e 2012, um aumento de publicação nos anos de 2013 e 2014, um declínio expressivo nos anos de 2015, um aumento no ano de 2016 e um crescimento significativo entre os anos de 2017 a 2020, sendo 7 publicações em 2017, 9 publicações nos anos de 2018 e 2019 e 6 publicações de janeiro a junho de 2020.

Figura 10: Publicação por ano e por base de busca

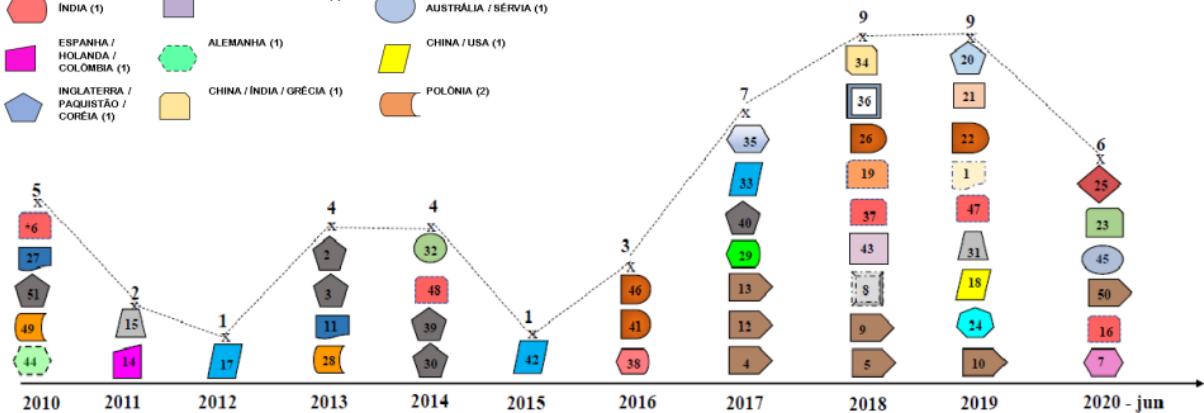
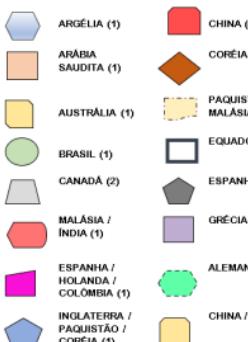


Fonte: Elaborado pela autora.

3.2.8 QE2 – Onde os trabalhos foram desenvolvidos?

Na identificação da origem da publicação sobre a temática foi observado o local de desenvolvimentos dos estudos. Observa-se que o maior número de artigos publicados sobre a temática pesquisada vem da China com 8 artigos publicados, seguido de Marrocos com 7, Espanha com 6, Alemanha com 5, Grécia e Japão com 3 e os demais países com menos publicações.

Na Figura 11 os artigos foram divididos por ano de publicação. Cada peça representa o país dos autores e os números dentro da peça faz menção a identificação da referência dos artigos relacionados na tabela 5 organizados em ordem alfabética, onde são destacados os autores, países, bases e um resumo do foco do artigo.

Figura 11: Países de publicação**Legenda e Quantidade**

Fonte: Elaborado pela autora.

3.3 Trabalhos selecionados e comparativo

Esta seção apresenta uma comparação entre os trabalhos relacionados e o modelo proposto. A comparação é focada em modelos computacionais para serviços inteligentes aplicados na educação a distância. O comparativo é realizado utilizando artigos coletados nos três trabalhos publicados. Para selecionar os 75 trabalhos, foram considerados os artigos encontrados nos mapeamentos sistemáticos e na revisão da literatura apresentados na capítulo 3. A pesquisa realizada possibilitou o desenvolvimento de um mapeamento sistemático com o objetivo de identificar o uso de LA e serviços inteligentes na EaD. Posteriormente, foi realizado um segundo mapeamento com foco na aprendizagem e grupos colaborativos de alunos em EaD. A Tabela 10 apresenta 75 artigos selecionados nos mapeamentos sistemáticos e na revisão de literatura realizadas que apresentam itens que foram utilizados para comparação. Dentre os 75 artigos, 24 são os artigos da revisão de literatura. Inicialmente, através do mapeamento sistemático, foram selecionados 51 artigos, posteriormente a pesquisa foi expandida e 24 artigos foram adicionados, totalizando 75 artigos selecionados, sendo estes: (HAN; XU,2021); (BARLYBAYEV et al., 2020a); (KHOSRAVI; SADIQ; GASEVIC,

2020b); (CHEN et al., 2020a); (MAÂLOUL; BAHOU, 2021); (SHI et al., 2020); (NIKNAM; THULASIRAMAN, 2020); (LEITHARDT et al., 2012); (VILLEGAS CH; ARIAS NAVARRETE; PALACIOS PACHECO, 2020); (RUANGVANICH; NILSOOK; WANNAPIROON, 2020); (AZZI et al., 2020); (ULLAH et al., 2020); (NUGURI et al., 2021); (MENDES et al., 2021); (RAJKUMAR; GANAPATHY, 2020); (LIN; LI; LIAN, 2020); (IATRELLIS et al., 2021); (TURABIEH et al., 2021); (ZHANG; GHANDOUR; SHESTAK, 2020); (ANGELINE; RAMASUBRAMANIAN; JAMES, 2020); (HASHIM; AWADH; HAMOUD, 2020); (CHEN et al., 2020b) e (FREITAS et al., 2020).

A partir dos 75 artigos selecionados foi realizada uma avaliação dos trabalhos que auxiliam os gestores, professores e alunos no processo de ensino e aprendizagem com foco nos seguintes critérios de comparação:

- Serviços inteligentes: Quais os tipos de serviços inteligentes estão sendo ofertados na educação a distância;
- Grupos ou atividades colaborativas: Se o trabalho considerou no seu desenvolvimento a formação de grupos ou atividades colaborativas;
- Contextos: Tem por objetivo identificar se os trabalhos apresentaram ou têm a intenção de utilizar históricos de contextos, armazenando informações do usuário em um determinado espaço de tempo;
- O que é o trabalho: Se o trabalho apresentado é um modelo computacional ou um sistema computacional;
- Genérico: Se o trabalho é um modelo computacional ou um sistema computacional que suporta diferentes tipos de serviços inteligentes;
- Técnicas ou tecnologias: Quais técnicas ou tecnologias foram abordados no trabalho;
- Ontologia: Identifica se o trabalho apresenta estratégias de ontologias.

O critério “**O que é o trabalho**” foi categorizado como modelo computacional e sistema computacional. A categoria modelo computacional trata de aplicações de modelos matemáticos e técnicas de computação, já a categoria sistema computacional consiste num conjunto de dispositivos capaz de processar informações de acordo com um programa.

Os trabalhos considerados modelos computacionais foram desenvolvidos pelos seguintes autores: (KOTSIANTIS; PATRIARCHEAS; XENOS, 2010); (CHANG; CHU,

2010); (ZORRILLA; GARCÍA; ÁLVAREZ, 2010); (YANG et al., 2014); (LARA et al., 2014); (RAYON; GUENAGA; NUNEZ, 2014); (SOROUR; GODA; MINE, 2015); (OLANREWAJU et al., 2016); (OMAR; ABDESELAM, 2017); (OKUBO et al., 2017); (ROS et al., 2017); (HUSSAIN et al., 2018); (OLIVÉ et al., 2018); (QU et al., 2018); (PEÑAFIEL et al., 2018); (CLARIZIA et al., 2018); (ISLAM; SIDDIQUI; ALJOHANI, 2020); (ALTAF; SOOMRO; RAWI, 2019); (UZIR et al., 2020); (GUO; YAN; LI, 2020); (JOVANOVIC et al., 2020); (THAI-NGHE et al., 2010); (KOZIERKIEWICZ; ZYSK, 2013); (ANAYA; LUQUE; GARCÍA-SAIZ, 2013); (MANHÃES; CRUZ; ZIMBRÃO, 2014); (SHARMA; AHUJA, 2016); (EL FOUKI; AKNIN; EL. KADIRI, 2017); (EL MOUSTAMID; EN-NAIMI; BOUHDIDI, 2017); (ZAKRZEWSKA, 2010); (CHANAA; FADDOULI, 2018); (LAVOIE; PROULX, 2020); (KAPEMBE; QUENUM, 2020); (WANG; SUN; CHEN, 2019); (IQBAL et al., 2019); (CHEN et al., 2020a); (KIM; KIM, 2020); (ZAOUDI; BELHADAoui, 2020); (HAN; XU, 2021); (CHEN et al., 2020b); (AZZI et al., 2020); (ULLAH et al., 2020); (RAJKUMAR; GANAPATHY, 2020); (MAÂLOUL; BAHOU, 2021); (SHI et al., 2020); (IATRELLIS et al., 2021); (ANGELINE; RAMASUBRAMANIAN; JAMES, 2020); (HASHIM; AWADH; HAMOUD, 2020); (FREITAS et al., 2020) e (BARLYBAYEV et al., 2020a).

Os trabalhos categorizados como sistemas computacionais foram desenvolvidos pelos seguintes autores: (GRAF et al., 2011), (CHAFFAI; HASSOUNI; ANOUN, 2017); (SPATIOTIS et al., 2018); (FLORIAN et al., 2011); (KOLEKAR; PAI; M.M., 2018); (HAMADA, 2012); (BALDERAS et al., 2013); (DIMOPOULOS; PETROPOULOU; RETALIS, 2013); (VENUGOPALAN; SRINATH; RODRIGUES, 2016); (VILLEGAS CH; ARIAS NAVARRETE; PALACIOS PACHECO, 2020); (LAGMAN; MANSUL, 2017); (DAHDOUH et al., 2018); (HUANG et al., 2019); (JOY; RAJ; G, 2019); (DAHDOUH et al., 2019); (KHOSRAVI; SADIQ; GASEVIC, 2020b); (RUANGVANICH; NILSOOK; WANNAPIROON, 2020); (NUGURI et al., 2021); (LEITHARDT et al., 2012); (MENDES et al., 2021); (LIN; LI; LIAN, 2020); (NIKNAM; THULASIRAMAN, 2020) e (ZHANG; GHANDOUR; SHESTAK, 2020).

Os trabalhos realizados por (ANAYA; LUQUE; GARCÍA-SAIZ, 2013); (BALDERAS et al., 2013); (SHARMA; AHUJA, 2016); (ZAKRZEWSKA, 2010); (CHEN et al., 2020a); (NIKNAM; THULASIRAMAN, 2020) e (IATRELLIS et al., 2021) são modelos e sistemas computacionais que abordam grupos ou atividades colaborativas e os trabalhos dos

autores (SHARMA; AHUJA, 2016), (CHANAA; FADDOULI, 2018) e (IQBAL et al., 2019) abordam em seu desenvolvimento a ideia de contexto de acordo (DEY, 2001).

ZORRILLA; GARCÍA; ÁLVAREZ, (2010); YANG et al. (2014); OLIVÉ et al. (2018) desenvolveram modelos computacionais genéricos, FLORIAN et al. (2011); MENDES et al. (2021), desenvolveram sistemas computacionais genéricos, utilizados por diferentes serviços inteligentes aplicados para ensino a distância, já os autores CHANG; CHU, 2010; JOY; RAJ; G. (2019); ZAKRZEWSKA (2010); SHARMA; AHUJA (2016); VENUGOPALAN; SRINATH; RODRIGUES (2016), apresentam em seus trabalhos desenvolvimento de ontologias.

O artigo de SHARMA; AHUJA (2016), contempla seis critérios dos sete itens analisados. Esses autores apresentam um sistema de recomendação integrado que combina os melhores métodos de vários sistemas de recomendação adaptados à plataforma de *e-learning*. O sistema de recomendação apresentado leva em consideração o contexto do aluno.

O contexto do aluno nesse sistema é dinâmico e envolve conhecimento prévio, interesses, velocidade, estilo de aprendizagem e objetivos. O sistema usa a tecnologia da *web* semântica para ajudar os usuários a encontrar o conteúdo apropriado na *web*. O sistema usa duas ontologias: a ontologia do aluno e a ontologia do domínio de aprendizagem para representar e modelar o conhecimento sobre o aluno e o domínio de aprendizagem, respectivamente.

Para recomendar o conteúdo mais adequado aos usuários, a técnica de recomendação integra quatro abordagens básicas: correspondência de perfil de usuário, construção de caminhos de aprendizado de pré-requisitos, filtragem colaborativa e técnica de similaridade semântica.

Considerando o resultado do comparativo entre os trabalhos, pode-se observar na Tabela 10 que nenhum artigo contempla todos os aspectos avaliados, tendo como foco um modelo computacional para serviços inteligentes baseados nos históricos de contextos. O modelo Athena apresentado nesta tese se diferencia dos demais trabalhos nos aspectos apresentados a seguir. O primeiro diferencial apresentado é que o Athena é um modelo computacional genérico, isto é, suporta diferentes serviços inteligentes. Essa característica é importante devido a diversidade de serviços inteligentes disponíveis na atualidade. Assim, as instituições podem criar diferentes estratégias que possam ajudar tanto os gestores, como

professores e alunos nos processos de ensino e aprendizagem, contribuindo em melhorias e diminuindo a evasão escolar.

O segundo diferencial consiste na utilização de históricos de contextos dos alunos de cursos à distância. O uso de históricos de contextos permite a utilização de informações estratégicas sobre o aluno, pois o histórico armazena uma sequência de eventos contendo como, onde e quando os recursos foram utilizados pelo usuário. Esses contextos podem ser utilizados para consultas, geração de perfis e recomendações de diferentes serviços.

Tabela 10: Comparativo dos trabalhos relacionados

Referência	Qual serviço inteligente?	O trabalho considerou grupos / atividades de colaboração?	O trabalho considerou a ideia de contextos?	O que é o trabalho?	O trabalho suporta serviços genéricos ?	Qual técnica / tecnologia foi utilizada?	O trabalho apresenta ontologia ?
(KOTSIANTIS et al., 2010)	Previsão do desempenho	Não	Não	Modelo computacional	Não	Combinação de uma versão incremental do <i>Naive Bayes</i> , os algoritmos 1-NN e <i>WINNOW</i> utilizando a metodologia de votação.	Não
(CHANG et al. 2010)	Recomendação conteúdos de aprendizagem.	Não	Não	Modelo computacional	Não	Redes de Petri comportamentais de aprendizagem.	Não
(ZORRILA et al., 2010)	Sistema de tomada de decisão.	Não	Não	Modelo computacional	Sim	Algoritmos de mineração de dados (<i>RapidMiner</i> , <i>Weka</i> , <i>Keel</i>).	Não
(KOLEKAR et al., 2010)	Sistema de <i>E-Learning</i> Adaptativo.	Não	Não	Sistema Computacional	Não	Modelo de Estilo de Aprendizagem <i>Felder-Silverman</i> , <i>Moodle Framework</i> .	Não
(THAI-NGHE et al., 2010)	Sistema de recomendação para prever o desempenho do aluno especialmente na previsão de desempenho dos alunos.	Não	Não	Modelo computacional	Não	Técnicas de sistema de recomendação com métodos tradicionais de regressão, como regressão logística e linear.	Não

Referência	Qual serviço inteligente?	O trabalho considerou grupos / atividades de colaboração?	O trabalho considerou a ideia de contextos?	O que é o trabalho?	O trabalho suporta serviços genéricos ?	Qual técnica / tecnologia foi utilizada?	O trabalho apresenta ontologia ?
(GRAF et al., 2011)	Sistema de consultas analíticas simples e complexas sobre o comportamento dos alunos.	Não	Não	Sistema Computacional	Não	Arquitetura <i>DeleS / Moodle / PHP</i> .	Não
(FLORIAN et al., 2011)	Protótipo que implementa indicadores como exemplos de aplicações analíticas de aprendizado.	Não	Não	Arquitetura Computacional	Sim	Arquitetura baseada no modelo <i>Activity Theory</i> e no modelo atuador indicador, <i>Moodle</i> .	Não
(HAMADA, 2012)	Modelo de estilo de aprendizagem baseado na web que pode ajudar os alunos a encontrar um caminho de aprendizagem em um sistema de <i>e-learning</i> .	Não	Não	Sistema Computacional	Não	Modelo <i>Felder-Silverman</i> , tecnologia Java2D.	Não
(LEITHARDT et al., 2012)	Sistema de controle para ambientes de aprendizagem especializados em educação especial.	Não	Não	Sistema Computacional	Não	<i>Middleware</i> híbrido, Computação pervasiva, <i>Bluetooth</i> , sensores <i>SunSpot</i> , banco de dados <i>MySQL</i> .	Não
(KOZIERKIEWICZ-HETMAŃSKA E ZYŚK, 2013)	Método para determinar um cenário de aprendizado.	Não	Não	Modelo computacional	Não	Algoritmo heurístico baseado na técnica de otimização de colônias de formigas.	Não
(ANAYA et al., 2013)	Sistema de recomendação baseado em um diagrama de influência no contexto de aprendizado colaborativo no ambiente de <i>e-learning</i> .	Não	Não	Modelo computacional	Não	Técnicas de aprendizado de máquina: seletor de atributos, algoritmo de árvore de decisão.	Não
(BALDERAS et al., 2013)	Sistema de apoio para classificação das competências de aprendizagem de acordo com o desempenho dos alunos em um curso <i>online</i> .	Não	Não	Sistema Computacional	Não	<i>Moodle, EvalCourse, Eclipse IDE</i> .	Não

Referência	Qual serviço inteligente?	O trabalho considerou grupos / atividades de colaboração?	O trabalho considerou a ideia de contextos?	O que é o trabalho?	O trabalho suporta serviços genéricos ?	Qual técnica / tecnologia foi utilizada?	O trabalho apresenta ontologia ?
(DIMOPOULOS et al. 2013)	Ferramenta de avaliação, chamada Rubrica Enriquecida de análise de Aprendizagem.	Não	Não	Sistema Computacional	Não	<i>Puglin Moodle.</i>	Não
(MANHÃES et al., 2014)	<i>WAVE</i> : uma arquitetura para prever a evasão em cursos de graduação.	Não	Não	Modelo computacional	Não	Técnicas de classificação: <i>Naïve Bayes</i> , <i>Multilayer Perceptron</i> , <i>Support Vector Machine</i> com <i>kernel</i> polinomial (SVM1) e <i>kernel RBF</i> (SVM2) e <i>Decision Table</i> .	Não
(YANG et al., 2014)	Método de predição de estilos de aprendizagem.	Não	Não	Modelo computacional	Sim	Técnica de reconhecimento de padrões.	Não
(LARA et al., 2014)	Sistema de Mineração de Dados Educacionais.	Não	Não	Modelo computacional	Não	Técnicas de mineração de dados (agrupamento, associação, classificação e análise de tempo).	Não
(RAYÓN et al., 2014)	Sistema de Avaliação de Competência.	Não	Não	Modelo computacional	Não	IMS <i>Caliper Learning Analytics</i> , Algoritmos de mineração de regras de agrupamento e associação.	Não
(SOROUR et. al., 2015)	Métodos baseados em uma classe estatística latente para a tarefa de previsão da nota.	Não	Não	Modelo computacional	Não	Técnicas de mineração de textos (PLSA, LSA, ANN e SVM).	Não
(RASHIDAH et al., 2016)	Mecanismo de análise de <i>feedback</i> de dados educacionais baseado em conhecimento.	Não	Não	Modelo computacional	Não	<i>Apache Hadoop</i> , <i>WEKA3</i> .	Não
(SHARMA, AHUJA, 2016)	Sistema de recomendação integrado que combina os melhores métodos de vários sistemas de recomendação adaptados à plataforma de <i>e-learning</i> .	Sim	Sim	Modelo Computacional	Não	Tecnologia da web semântica.	Sim

Referência	Qual serviço inteligente?	O trabalho considerou grupos / atividades de colaboração?	O trabalho considerou a ideia de contextos?	O que é o trabalho?	O trabalho suporta serviços genéricos ?	Qual técnica / tecnologia foi utilizada?	O trabalho apresenta ontologia ?
(VENUGOPALAN et al. 2016)	Sistema de recomendação baseado em conteúdo.	Não	Não	Sistema Computacional	Não	.NET e sistema ASP.	Sim
(EL FOUKI et al., 2017)	Sistema de tomada de decisão.	Não	Não	Modelo Computacional	Não	Algoritmos de redes neurais profundas e aprendizado por reforço.	Não
(EL MOUSTAMID et al., 2017)	Sistema de análise de perfil de alunos e indexação de vídeos na web.	Não	Não	Modelo Computacional	Não	Técnicas de mineração de dados.	Não
(LAGMAN; MANSUL, 2017)	Sistema de <i>e-learning</i> adaptativo ou plataforma de aprendizagem personalizada que ajuda a melhorar o desempenho acadêmico desse aluno.	Não	Não	Arquitetura computacional	Não	<i>Rapid Application Development.</i>	Não
(OMAR; ABDESELAM, 2017)	Classificação de usuários na plataforma sem classes previamente conhecidas.	Não	Não	Modelo Computacional	Não	Algoritmos de agrupamento.	Não
(OKUBO et al., 2017)	Método para prever notas finais de alunos.	Não	Não	Modelo Computacional	Não	Rede Neural Recorrente.	Não
(CHAFFAI et al., 2017)	Arquitetura da infraestrutura de <i>pipeline ETL</i> escalável para análise exploratória dos dados dos alunos.	Não	Não	Arquitetura computacional	Não	<i>Hadoop e Spark.</i>	Não
(ROS et al., 2017)	Análise exploratória de dados.	Não	Não	Modelo Computacional	Não	Algoritmo PCA (<i>Principal Component Analysis</i>).	Não
(HUSSAIN et al., 2018)	Modelo preditivo de resultado ou o comportamento com base em dados de registros no <i>Moodle</i> .	Não	Não	Modelo Computacional	Não	Técnica estatística de <i>Machine Learning</i> .	Não
(OLIVÉ et al., 2018)	Modelos de previsão de mineração de dados Educacionais.	Não	Não	Modelo Computacional	Sim	API12 do <i>Moodle Analytics</i> , back-end de <i>Machine Learning</i> .	Não

Referência	Qual serviço inteligente?	O trabalho considerou grupos / atividades de colaboração?	O trabalho considerou a ideia de contextos?	O que é o trabalho?	O trabalho suporta serviços genéricos ?	Qual técnica / tecnologia foi utilizada?	O trabalho apresenta ontologia ?
(QU et al., 2018)	Estrutura de previsão de desempenho do aluno.	Não	Não	Modelo Computacional	Não	<i>Perceptron</i> multicamada supervisionado por camada.	Não
(PEÑAFIEL et al., 2018)	Aplicação de mineração de dados para avaliar as questões em aberto das pesquisas <i>online</i> realizadas pelos professores.	Não	Não	Modelo Computacional	Não	Técnicas computacionais, como mineração de texto e análise de sentimentos.	Não
(CLARIZIA et al., 2018)	Método probabilístico para classificação de sentimentos.	Não	Não	Modelo Computacional	Não	Alocação de <i>Dirichlet Latente</i> .	Não
(SPATIOTIS et al., 2018)	Plataforma para classificação de opinião.	Não	Não	Arquitetura Computacional	Não	Técnicas de mineração de textos.	Não
(DAHDOUH et al., 2018)	Sistema de aprendizagem <i>online</i> .	Não	Não	Sistema Computacional	Não	Tecnologias de <i>Big Data</i> e computação em nuvem.	Não
(ZAKRZEWSKA, 2018)	Sistema de recomendação baseado em agentes para formação de grupos.	Sim	Não	Modelo Computacional	Não	Algoritmo <i>Naive Bayesiano</i> .	Sim
(CHANAA; FADDOULI, 2018)	Modelo personalizado de recomendação.	Não	Sim	Modelo Computacional	Não	Algoritmo de rede neural LSTM.	Não
(ISLAM et al., 2019)	Mineração de dados para prever comportamentos dos alunos.	Não	Não	Modelo Computacional	Não	grupamento <i>k-mean</i> , mineração de regras de associação, <i>Map-Reduce</i> , IQR.	Não
(LAVOIE; PROULX, 2019)	Sistema de gerenciamento de aprendizagem.	Não	Não	Modelo Computacional	Não	Algoritmos de Aprendizado de máquina e inteligência artificial.	Não
(KAPEMBE; GHISLAIN, 2019)	Um sistema híbrido e personalizado de recomendação de objetos de aprendizagem.	Não	Não	Modelo Computacional	Não	<i>Deep Neural Networks</i> .	Não
(HUANG et al., 2019)	Estrutura de aprendizado de reforço profundo para recomendação de exercícios.	Não	Não	Sistema Computacional	Não	Redes Q de Exercícios diferentes para o agente para gerar recomendações seguindo a propriedade de <i>Markov</i> .	Não

Referência	Qual serviço inteligente?	O trabalho considerou grupos / atividades de colaboração?	O trabalho considerou a ideia de contextos?	O que é o trabalho?	O trabalho suporta serviços genéricos ?	Qual técnica / tecnologia foi utilizada?	O trabalho apresenta ontologia ?
(WANG et al., 2019)	Sistema inteligente de assistente de ensino.	Não	Não	Modelo Computacional	Não	Tecnologia de aprendizado profundo e processamento de linguagem natural.	Não
(JOY et al., 2019)	Um modelo de ontologia para recomendação de conteúdo em ambiente de aprendizagem personalizado.	Não	Não	Sistema Computacional	Não	<i>Resource Description Framework (RDF). JAVA.</i>	Sim
(IQBAL et al., 2019)	Algoritmo, o <i>Kernel Context Recommender System</i> .	Não	Não	Modelo Computacional	Não	Técnica de aprendizagem de estrutura.	Não
(DAHDOUH et al., 2019)	Sistema de recomendação inteligente aplicado em um ambiente de aprendizagem online.	Não	Não	Sistema computacional	Não	Tecnologias e técnicas de <i>Big Data, Spark Framework, Hadoop</i> .	Não
(ALTAF et al., 2019)	Previsão do desempenho.	Não	Não	Modelo Computacional	Não	Rede Neural.	Não
(RUANGVANICH et al. 2019)	Sistema de análise de aprendizagem como uma ferramenta para apoiar a aprendizagem dos alunos.	Não	Não	Sistema computacional	Não	Ciclo de vida de desenvolvimento de sistema.	Não
(UZIR et al., 2020)	Metodologia de análise de aprendizado.	Não	Não	Modelo Computacional	Não	<i>Cluster hierárquico aglomerativo, análise epistêmica de redes e mineração de processos.</i>	Não
(GUO et al., 2020)	Modelo de previsão da atitude do aluno em relação ao ensino híbrido com base na análise de sentimentos.	Não	Não	Modelo Computacional	Não	algoritmos típicos de classificação (SVM) e regressão de aprendizado de máquina SVR).	Não
(JOVANOVIĆ et al., 2020)	Modelo explicativo do comportamento do aluno, identificando padrões na atividade online dos alunos.	Não	Não	Modelo Computacional	Não	Algoritmo <i>Expectation-Maximization (EM)</i> adaptado para tarefas de mineração de processos, pacote <i>pMineR</i> .	Não

Referência	Qual serviço inteligente?	O trabalho considerou grupos / atividades de colaboração?	O trabalho considerou a ideia de contextos?	O que é o trabalho?	O trabalho suporta serviços genéricos ?	Qual técnica / tecnologia foi utilizada?	O trabalho apresenta ontologia ?
(CHEN et al., 2020a)	Recomendação Adaptativa com base no <i>Online Learning Style</i> .	Sim	Não	Modelo Computacional	Não	Algoritmo <i>Apriori</i> , - <i>Kmeans</i> .	Não
(CHEN et al., 2020b)	Modelo de previsão em fases para prever alunos em risco em diferentes semestres.	Não	Não	Modelo Computacional	Não	Algoritmos <i>K-means</i> .	Não
(KIM; KIM, 2020)	Tutor individualizado de Inteligência Artificial que sugere conteúdos de aprendizagem.	Não	Não	Modelo Computacional	Não	Rede de teoria de ressonância adaptativa profunda, IA.	Não
(ZAOUDI E BELHADAOU, 2020)	Modelo LBA (<i>Learner Behavior Analytics</i>) para analisar o nível e o comportamento dos alunos.	Não	Não	Modelo Computacional	Não	<i>User Behavior Analytics</i> , IA, <i>Learner Behavior Analytics</i> , <i>Score and Behavior Analytics</i> .	Não
(KHOSRAVI et al., 2020)	Sistema de aprendizagem adaptável que recomenda atividades de aprendizagem personalizadas aos alunos.	Não	Não	Sistema computacional	Não	<i>Insights</i> de <i>crowdsourcing</i> , ciências da aprendizagem e aprendizagem adaptativa.	Não
(VILLEGAS-CH et al., 2020)	Integração de tecnologias, como inteligência artificial (IA) e análise de dados, com sistemas de gerenciamento de aprendizagem para melhorar a aprendizagem.	Não	Não	Arquitetura computacional	Não	Plataforma LMS, IA.	Não
(CHANG et al., 2020)	Ontologia capaz de mapear dados de interação do aluno para um conjunto de ações de tutoria.	Não	Não	Modelo Computacional	Não	<i>W3C Web Ontology Language</i> , redes neurais artificiais, aprendizado por reforço, mineração de regras.	Sim
(AZZI et al., 2020)	Classificador capaz de identificar o estilo de aprendizagem do aluno no sistema de <i>e-Learning</i> .	Não	Não	Modelo Computacional	Não	<i>Felder-Silverman Learning Style Model</i> , <i>Fuzzy C Means</i> .	Não

Referência	Qual serviço inteligente?	O trabalho considerou grupos / atividades de colaboração?	O trabalho considerou a ideia de contextos?	O que é o trabalho?	O trabalho suporta serviços genéricos ?	Qual técnica / tecnologia foi utilizada?	O trabalho apresenta ontologia ?
(ULLAH et al., 2020)	Modelo IoT baseado em SDN (Rede definida por software) para a interação dos alunos.	Não	Não	Modelo Computacional	Não	Linguagem de Processamento Natural, Tecnologia SDN, análise semântica latente, algoritmo matemático - <i>Singular Value Decomposition</i> .	Não
(RAJKUMAR; GANAPATH, 2020)	Sistema de recomendação para aumentar a precisão da classificação entre os e-learners.	Não	Não	Modelo Computacional	Não	Questionários VARK, Chatbot, Naïve Bayes, N48 e Canopy.	Não
(SHI et al., 2020)	Modelo de recomendação de caminho de aprendizagem qualificados e personalizados para melhorar as experiências de aprendizagem.	Não	Não	Modelo Computacional	Não	Estrutura de grafo de conhecimento multidimensional.	Não
(LIN et al., 2020)	Estrutura de recomendação complementar para calouros sob restrições ou requisitos, com base em padrões orientados a metas.	Não	Não	Sistema computacional	Não	MATLAB 2015b (CoreII 2.54, Win 7)	Não
(NIKNAM; THULASIRAMANA, 2020)	Sistema de recomendação de caminhos de aprendizagem.	Não	Não	Sistema computacional	Não	Teoria de aprendizagem significativa de Ausubel e algoritmo de otimização de colônia de formigas Fuzzy Algoritmo C-Mean.	Não
(VILLEGAS-CH et al., 2020)	Arquitetura para a integração de um chatbot com inteligência artificial em um campus inteligente para melhorar o aprendizado através de recomendação de atividades.	Não	Não	Arquitetura computacional	Não	Chatbot, IA, IOT, computação em nuvem, análise de dados.	Não
(ZHANG et al., 2020)	Análise de aprendizagem para reduzir o número de alunos com baixo desempenho.	Não	Não	Sistema computacional	Não	Plugins do ambiente virtual Moodle.	Não

Referência	Qual serviço inteligente?	O trabalho considerou grupos / atividades de colaboração?	O trabalho considerou a ideia de contextos?	O que é o trabalho?	O trabalho suporta serviços genéricos ?	Qual técnica / tecnologia foi utilizada?	O trabalho apresenta ontologia ?
(ANGELINE et al., 2020)	Análise discriminante para medir o desempenho dos alunos.	Não	Não	Modelo Computacional	Não	Técnica de mineração de dados, Análise discriminante.	Não
(HASHIM et al. 2020)	Modelo de previsão de desempenho do aluno baseado em algoritmos de aprendizado de máquina supervisionado.	Não	Não	Modelo Computacional	Não	Árvore de decisão, <i>Naïve Bayes</i> , regressão logística, máquina de vetores de suporte, vizinho mais próximo K, otimização sequencial mínima e rede neural.	Não
(FREITAS et al., 2020)	Sistema IoT para previsão do abandono escolar usando técnicas de aprendizado de máquina com base em dados socioeconômicos.	Não	Não	Modelo Computacional	Não	Aprendizado de máquina, como árvore de decisão, regressão logística, máquina de vetores de suporte, vizinhos K, <i>perceptron</i> multicamadas e aprendizado profundo.	Não
(BARLYBAYEV et al., 2020)	Sistema inteligente para avaliar os níveis de competências profissionais dos alunos em <i>e-learning</i> .	Não	Não	Modelo Computacional	Não	Relações binárias <i>fuzzy</i> , método <i>Mamdani</i> , <i>Matlab</i> .	Não
(HAN; XU, 2021)	Plataforma de educação inteligente com aprendizagem profunda e detecção de imagem.	Não	Não	Modelo Computacional	Não	<i>Python</i> , algoritmo de aprendizagem profunda.	Não
(IATRELLIS et al., 2021)	Uma abordagem de aprendizado de máquina em duas fases para prever os resultados dos alunos.	Não	Não	Modelo Computacional	Não	Técnicas de aprendizado supervisionado e não supervisionado, algoritmo <i>K-Means</i> .	Não

Referência	Qual serviço inteligente?	O trabalho considerou grupos / atividades de colaboração?	O trabalho considerou a ideia de contextos?	O que é o trabalho?	O trabalho suporta serviços genéricos ?	Qual técnica / tecnologia foi utilizada?	O trabalho apresenta ontologia ?
(TURABIEH et al., 2021)	Algoritmo de otimização <i>Harris Hawks</i> como um algoritmo de seleção de recursos para o problema de previsão de desempenho dos alunos.	Não	Não	Modelo Computacional	Não	Conjunto de classificadores de aprendizado de máquina, como KNN, rede neural recorrente em camadas, <i>Naïve Bayes</i> e rede neural artificial.	Não
(MAÂLOUL; BAHOU, 2021)	Sistema de recomendação que se baseia fundamentalmente em uma técnica de aprendizagem digital.	Não	Não	Modelo Computacional	Não	Técnica de aprendizado de máquina baseada em aprendizado semi-supervisionado (algoritmo J48), ferramentas APIs.	Não
(NUGURI et al., 2021)	Sistema de ambiente de aprendizagem de realidade virtual baseado em nuvem.	Não	Não	Sistema computacional	Não	VR social, plataforma de VR social de código aberto <i>High Fidelity</i> .	Não
(MENDES et al., 2021)	Ferramenta educacional baseada na detecção de movimento.	Não	Não	Sistema computacional	Não	Sensor <i>Kinect</i> , <i>Web Server</i> , <i>Api (Node JS)</i> , <i>Database (MongoDB)</i> , <i>.NET Framework</i> .	Não

Fonte: Elaborado pela autora

3.4 Considerações sobre o capítulo

Neste capítulo foi realizado um estudo comparativo entre os trabalhos relacionados ao tema modelo computacional para serviços inteligentes na educação a distância baseados em históricos de contextos. Durante o estudo observou-se que a maioria dos artigos se concentram em modelos computacionais, principalmente para serviços específicos e não de forma genérica. Foram observados também a falta de trabalhos que consideram o uso de históricos de contextos em seu desenvolvimento. No próximo capítulo serão abordados os principais conceitos referentes ao modelo Athena, como visão geral, casos de uso, arquitetura e modelo de dados.

4 MODELO ATHENA

Este capítulo apresenta um modelo computacional para ofertas de serviços inteligentes em educação a distância baseados em históricos de contextos dos alunos. Esses serviços inteligentes oferecem uma variedade de benefícios que podem transformar positivamente a experiência do aluno, aumentando a eficiência operacional e promovendo melhores resultados nos processos de ensino e aprendizagem. Dessa forma, este capítulo apresenta o modelo Athena, onde são abordadas características gerais, casos de uso, arquitetura, modelagem de dados e considerações sobre o capítulo.

4.1 Visão Geral

As instituições de ensino que oferecem cursos na modalidade a distância enfrentam uma série de desafios que podem impactar a qualidade do ensino e a experiência do aluno. Superar esses desafios exige um compromisso contínuo com a inovação, o desenvolvimento de estratégias eficazes e a adaptação às necessidades e preocupações dos alunos em um ambiente de aprendizado em constante evolução.

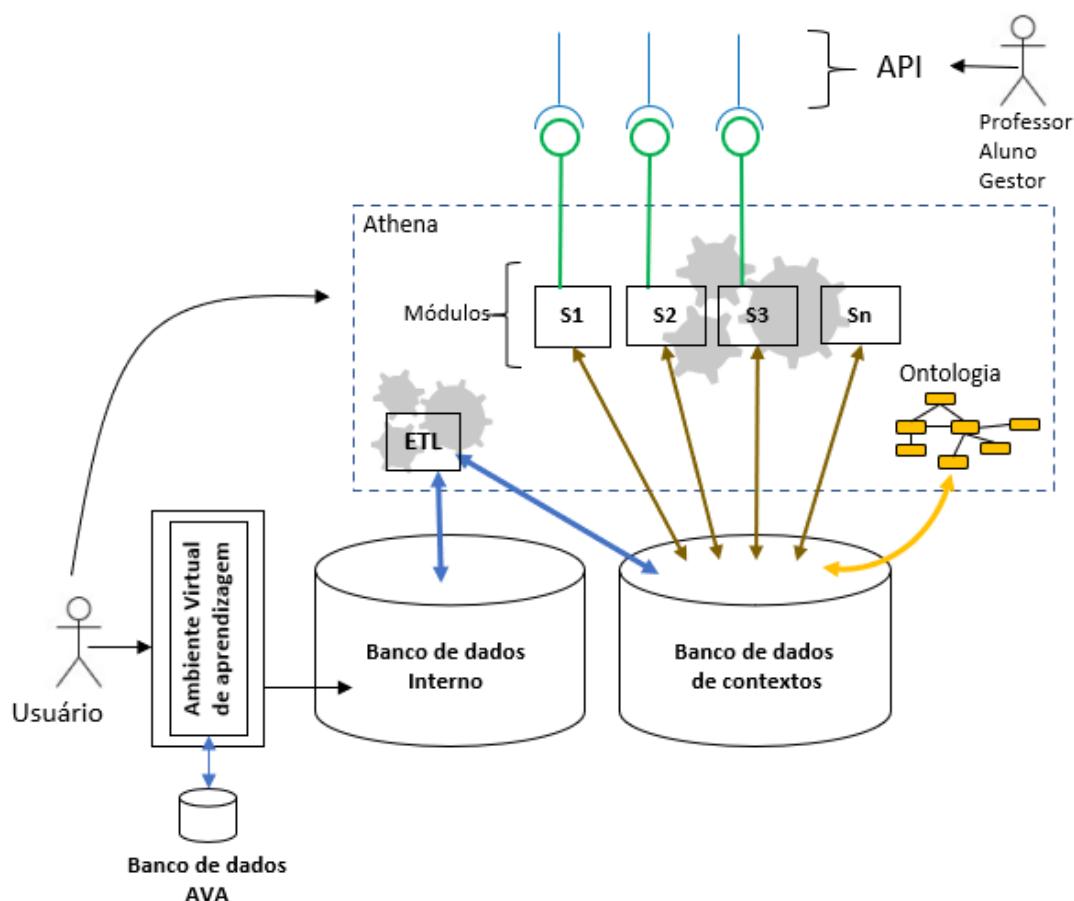
Para enfrentar esses desafios, as instituições precisam implementar estratégias eficazes para promover a participação dos alunos. Isso pode incluir a oferta de orientação acadêmica personalizada, tutoria individualizada, formação de grupos de estudo, atividades colaborativas e fóruns de discussão *online* para facilitar a interação entre os alunos. Além disso, é importante fornecer *feedback* personalizado e disponibilizar recursos de aprendizagem adicionais, como materiais complementares, livros específicos da área e vídeos educativos. Essas abordagens podem ajudar a manter os alunos engajados e motivados ao longo do curso de educação a distância (CAMPOS et. al. 2017).

Além de implementar essas estratégias, o emprego de tecnologias educacionais, como análise preditiva e intervenção oportuna, pode auxiliar as instituições na identificação precoce de alunos em situação de risco (Flach, 2022). Isso permite intervir antes que a situação se agrave, contribuindo para melhorar a experiência de aprendizagem e aumentar a taxa de sucesso dos alunos.

Os serviços inteligentes podem coletar e analisar os dados de forma rápida e eficiente. Essa análise de dados pode fornecer *insights* sobre o desempenho dos alunos, padrões de frequência, tendências de desempenho e muito mais, permitindo que os administradores tomem decisões informadas para melhorar os resultados acadêmicos e operacionais. O modelo proposto fundamenta-se na oferta de serviços inteligentes que auxiliem tanto os professores e gestores quanto os alunos nos processos de ensino e aprendizagem.

Na figura 12 observa-se a visão geral do modelo composto por usuário, ambiente virtual de aprendizagem, banco de dados do ambiente virtual, banco de dados interno, banco de dados de contextos, API, serviços inteligentes e pela ontologia. A seguir serão descritos os componentes do modelo em relação a sua função de armazenamento ou processamento.

Figura 12: Visão geral da arquitetura Athena



Fonte: Elaborado pela autora.

- Usuário: qualquer pessoa que interage com a plataforma *online*, seja para acessar conteúdo educacional, participar de atividades, colaborar com outros usuários ou realizar tarefas administrativas. Esses usuários podem incluir alunos, professores, tutores e administradores, dependendo das funcionalidades e permissões concedidas pelo sistema.
- Ambiente Virtual de Aprendizagem: facilita a interação entre alunos e professores, além de proporcionar acesso a uma variedade de recursos educacionais, interação entre alunos e instrutores, e ferramentas de comunicação e colaboração. Ele cria um espaço *online* onde os participantes podem se envolver em atividades educativas, colaborar em estudos, acessar materiais didáticos e participar de discussões, avaliações e outras atividades relacionadas ao aprendizado. Em suma, o ambiente virtual de aprendizagem desempenha um papel fundamental no cenário educacional atual, proporcionando uma plataforma flexível e interativa para facilitar o ensino e aprendizagem. Ao oferecer acesso a conteúdo educativo, ferramentas de interação e comunicação e atividades de aprendizagem, esse ambiente virtual cria um espaço rico e dinâmico que promove o engajamento dos alunos e facilita o processo de aprendizagem.
- Banco de dados AVA: local onde ficam armazenados os registros das ações realizadas pelo usuário ao acessar um curso específico, permitindo um acompanhamento detalhado do progresso e das interações dos participantes.
- Banco de dados internos: local onde são armazenados os dados dos alunos retirados do banco do ambiente virtual de aprendizagem.
- Banco de dados de contextos: estrutura de armazenamento que contém informações contextuais relevantes, é utilizado para armazenar e gerenciar dados que descrevem o ambiente no qual um sistema está operando, incluindo informações sobre o usuário, suas atividades, preferências, histórico de interações e outras variáveis contextuais relevantes para posterior análise e utilização.
- ETL: faz a integração dos dados em três etapas (extração, transformação, carregamento) do banco de dados interno e exporta para o banco de dados de contextos. O módulo de ETL pode ser *scripts* de banco (*script SQL*) usados para

movimentar dados do banco do ambiente virtual de aprendizagem para o banco interno e deste para o banco de contextos.

- Ontologia: estrutura formal que representa o conhecimento sobre o domínio educação a distância, histórico de contextos e serviços inteligentes. Ao fornecer uma estrutura semântica para descrever o domínio educacional, ela possibilita uma série de benefícios, incluindo interoperabilidade, personalização, análise de dados, desenvolvimento de sistemas inteligentes e padronização de recursos educacionais.
- Módulos s1...sn: são os possíveis serviços inteligentes do modelo Athena que podem ser utilizados por professores e gestores na melhoria contínua do processo de ensino e aprendizagem. Ao integrar tecnologias inteligentes ao ambiente de aprendizagem *online*, as instituições de ensino podem criar experiências educacionais mais envolventes, personalizadas e eficazes para uma variedade de alunos. Além disso, esses serviços podem fornecer suporte personalizado, promover a colaboração e o engajamento dos alunos e facilitar a tomada de decisões pedagógicas.
- *Application Program interface* (API): faz a comunicação entre o modelo computacional e os serviços inteligentes. Fornece um ponto no qual os usuários podem trocar dados fornecendo determinados parâmetros, é a parte de integração e acesso aos serviços inteligentes.
- Alunos: usuário que desempenha um papel ativo no sistema Athena, participandoativamente das interações que ocorrem dentro do ambiente. Consequentemente, ele se torna a principal fonte de dados para o sistema, fornecendo informações valiosas que são utilizadas na oferta de serviços inteligentes, que possam contribuir no processo de aprendizado do aluno. Esses serviços são desenvolvidos utilizando os históricos de contextos dos alunos, visando fornecer uma experiência de aprendizagem mais eficaz e personalizada.
- Professor: usuário que utiliza o ambiente virtual de aprendizagem para disponibilizar conteúdo, criar atividades, gerenciar turmas, avaliar o desempenho dos alunos e fornecer suporte educacional através dos serviços inteligentes disponibilizados pelo modelo Athena.
- Gestor (coordenador): desempenha um papel fundamental no ambiente virtual de aprendizagem. Sua função inclui o acompanhamento das atividades dos professores,

o monitoramento do progresso dos alunos no curso e o acesso a relatórios e métricas relacionadas à participação, desempenho em atividades e interação com o conteúdo, entre outros indicadores relevantes. Ademais, o gestor exerce um papel de gestão e coordenação específica de um curso dentro do ambiente virtual de aprendizagem, contribuindo para a qualidade e eficácia das atividades educacionais oferecidas aos alunos.

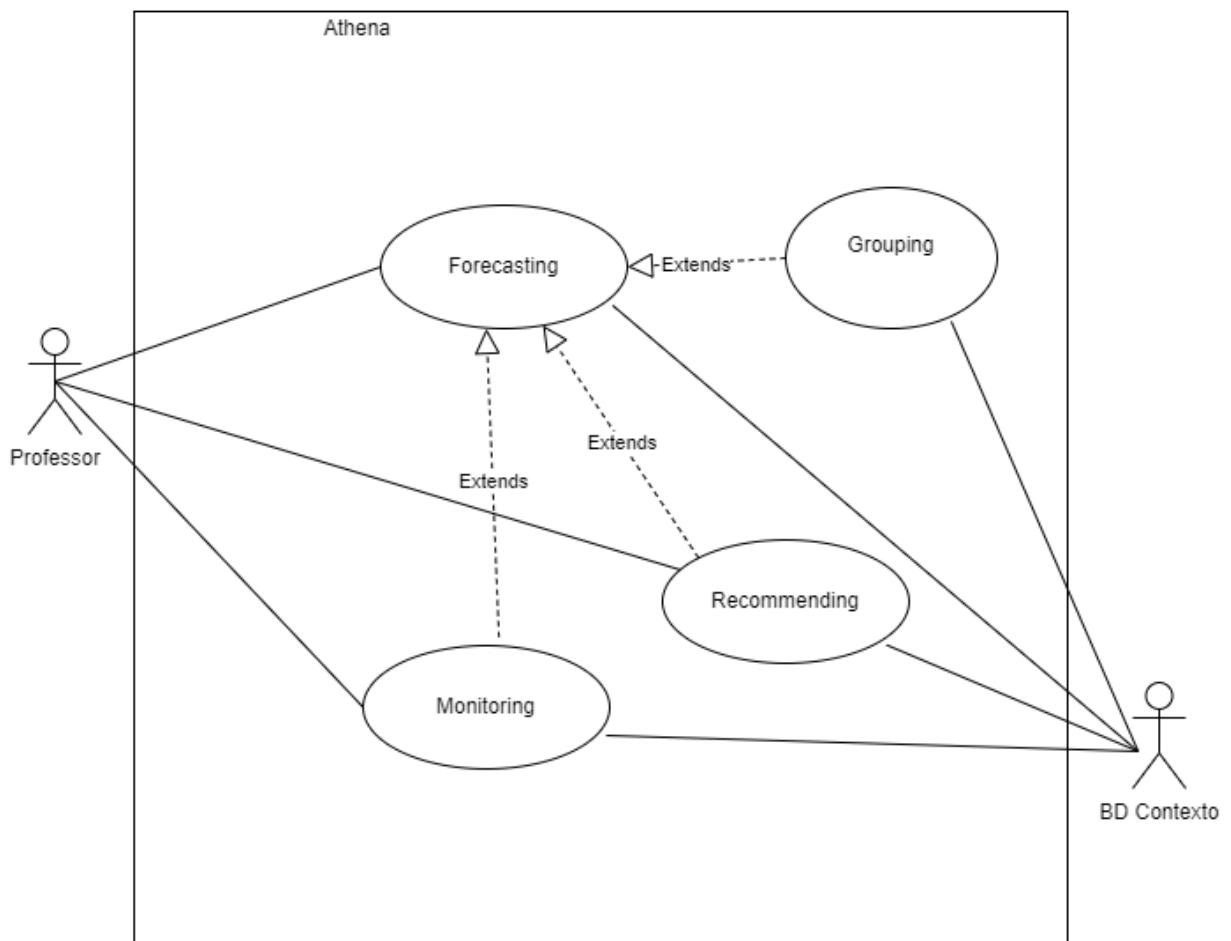
O funcionamento do modelo ocorre da seguinte forma. O usuário faz *login* no ambiente virtual utilizando seu nome de usuário e senha. A partir de então, ele pode acessar o curso, a turma e a disciplina em que está matriculado. Todas as interações e atividades realizadas pelo usuário são registradas no banco de dados do ambiente. No entanto, o modelo não acessa diretamente o banco de dados do ambiente para realizar pesquisas. Em vez disso, os dados são exportados para um repositório e depois transferidos para o banco de dados de contextos. Essas informações podem ser empregadas para fornecer uma ampla gama de serviços inteligentes aos usuários.

Todas as mudanças realizadas no banco de dados do ambiente virtual são atualizadas no banco de dados de contextos, via operações ETL realizadas em tempos definidos pelos usuários diretos (professores e gestores). Diversos serviços podem fazer uso dos históricos de contextos dos alunos. As informações coletadas são disponibilizadas e utilizadas por um interveniente (professor ou gestor) para ofertas de serviços inteligentes.

4.2 Casos de Uso

Os casos de uso são utilizados para registrar os requisitos funcionais do sistema, abrangendo serviços, tarefas ou funcionalidades essenciais ao *software* e acessíveis aos atores que interagem com o sistema. Ao fornecer uma visão detalhada das interações esperadas entre os usuários e o sistema, eles descrevem e documentam os comportamentos desejados para as funções do *software* (GUEDES, 2018). Um caso de uso identifica os atores envolvidos em uma interação e dá nome ao tipo de interação. Essa é, então, complementada por informações adicionais que descrevem a interação com o sistema (SOMMERVILLE, 2011). A figura 13 mostra o caso de uso do Athena e a seguir são descritos os atores e os serviços deste modelo.

Figura 13: Atores e serviços do modelo Athena



Fonte: Elaborado pela autora.

O ator professor é aquele que atua diretamente com o ator aluno, desempenha um papel fundamental no ambiente educacional, interagindo diretamente com os alunos e promovendo o processo de ensino-aprendizagem. Ele é responsável por criar diversas atividades, tais como avaliações, questionários, trabalhos, fóruns de discussão, entre outras. Ele define os parâmetros específicos de cada atividade, como prazos de entrega, critérios de avaliação e configurações de acesso. Além de criar atividades, o ator professor estimula a interação entre os alunos, criando espaços virtuais para discussões, colaboração e troca de informações. Ele monitora e participa ativamente das discussões nos fóruns e salas de *chat*, fornecendo *feedback* e esclarecendo dúvidas dos alunos.

Uma das principais responsabilidades do ator professor é avaliar o desempenho dos alunos. Ele revisa e pontua as atividades submetidas pelos alunos, fornecendo comentários

detalhados sobre seus trabalhos, destacando pontos fortes e áreas de melhoria. Ele identifica através dos serviços inteligentes ofertados pelo Athena, alunos que necessitam de apoio adicional em seu aprendizado, ajusta sua abordagem de ensino conforme necessário, oferecendo suporte personalizado, tais como, formação de grupos de estudos e orientações adicionais para ajudar os alunos a alcançarem seu potencial máximo. Essas atividades realizadas pelo ator Professor são essenciais para garantir uma experiência de aprendizagem eficaz e enriquecedora para os alunos, promovendo o desenvolvimento acadêmico e pessoal de cada um deles.

O ator BD Contexto é uma estrutura de armazenamento projetada para gerenciar informações contextuais relacionadas aos alunos e ao seu ambiente de aprendizagem *online*. É uma ferramenta para entender melhor os alunos, personalizar a experiência de aprendizagem e melhorar a eficácia e a eficiência do ensino *online*. Ao analisar e utilizar eficientemente esses dados, as instituições de ensino podem desenvolver ambientes de aprendizagem mais envolventes, adaptáveis e eficazes para uma variedade de alunos. Algumas características e benefícios importantes de um banco de dados de contextos para alunos em educação a distância são:

- Perfil do Aluno: O banco de dados pode conter informações sobre o perfil do aluno, como idade, gênero, histórico educacional, preferências de aprendizagem, interesses e objetivos educacionais. Essas informações ajudam os professores e os sistemas de aprendizagem a personalizar a experiência de aprendizagem para cada aluno.
- Hábitos de Estudo: Registrar os hábitos de estudo dos alunos, como horários preferenciais de estudo, frequência de acesso ao sistema, duração das sessões de estudo e padrões de interação com o conteúdo do curso. Esses dados podem ser usados para otimizar a entrega de conteúdo e o *design* de cursos para melhor se adequarem aos padrões de estudo.
- Ambiente Tecnológico: Registrar informações sobre o ambiente tecnológico dos alunos, como dispositivos utilizados (computador *desktop*, *laptop*, *tablet*, *smartphone*), sistemas operacionais, navegadores da *web* e velocidade da conexão à internet. Esses dados são cruciais para garantir que o conteúdo do curso seja acessível em diferentes dispositivos e plataformas e para identificar possíveis problemas de compatibilidade.

- Interatividade com o Ambiente Virtual: Registrar as interações dos alunos com o ambiente virtual de aprendizagem, como visualizações de páginas, tempo gasto em atividades, participação em fóruns de discussão, envio de trabalhos e interações com colegas e professores. Esses dados fornecem *insights* sobre o envolvimento dos alunos e podem ser utilizados para avaliar o progresso e identificar aqueles que possam precisar de intervenção adicional.
- Desempenho Acadêmico: Registrar o desempenho acadêmico dos alunos, como notas em testes e trabalhos, participação em atividades de grupo e conclusão de tarefas. Esses dados ajudam a avaliar o progresso do aluno em relação aos objetivos de aprendizagem do curso e a identificar áreas onde os alunos podem precisar de suporte adicional.
- *Feedback* dos Alunos: Registrar o *feedback* dos alunos sobre o curso, incluindo avaliações e comentários sobre a qualidade do conteúdo, a eficácia das atividades de aprendizagem e a experiência geral do curso. Essas informações são valiosas para avaliar a eficácia do curso e identificar áreas de melhoria.

Por fim, a principal finalidade de um banco de dados de contextos é fornecer uma base de dados centralizada para armazenar informações relevantes para entender o ambiente em que uma atividade ocorre. Isso pode ser particularmente útil em sistemas de recomendação, sistemas de aprendizado adaptativo, sistemas de monitoramento educacional, sistema de tutoria virtual inteligente, entre outros.

Dentre os serviços que podem ser disponibilizados pelo Athena, destacam-se:

- *Forecasting*: Serviço para prever o desempenho acadêmico dos alunos, identificar riscos de evasão ou reprovação, fundamental para ajudar as instituições de ensino e instrutores a identificar alunos que possam estar enfrentando dificuldades ou que precisem de apoio adicional.
- *Grouping*: Serviço que utiliza informações do perfil do aluno, como interesses, habilidades, experiência prévia e estilo de aprendizagem, para agrupar alunos com interesses semelhantes ou complementares. Isso ajuda a garantir que os grupos sejam heterogêneos o suficiente para promover a diversidade de perspectivas, mas também compatíveis o suficiente para facilitar a colaboração eficaz. É um serviço para promover a colaboração e o engajamento dos estudantes no curso. Ao utilizar informações do perfil

do aluno, análise de desempenho e preferências de grupo, o serviço forma grupos eficazes que facilitam o aprendizado colaborativo e enriquecedor.

- *Monitoring:* Serviço para coletar, analisar e interpretar dados relacionados ao desempenho dos alunos, interações com o ambiente virtual de aprendizagem e outros aspectos relevantes do ambiente educacional *online*. Um serviço de monitoramento na EaD desempenha um papel fundamental em acompanhar o progresso dos alunos, identificar áreas de preocupação e oportunidades de melhoria, e fornecer suporte personalizado para promover o sucesso acadêmico dos discentes. Ao empregar dados de maneira eficiente, o serviço pode aprimorar consideravelmente a qualidade e a eficácia do ensino e da aprendizagem *online*.
- *Recommending:* Serviço que sugere conteúdo de aprendizagem personalizado com base nas preferências, históricos de contextos e desempenho acadêmico dos alunos. Isso auxilia os alunos a descobrir recursos relevantes e aprofundar seus conhecimentos em áreas específicas.

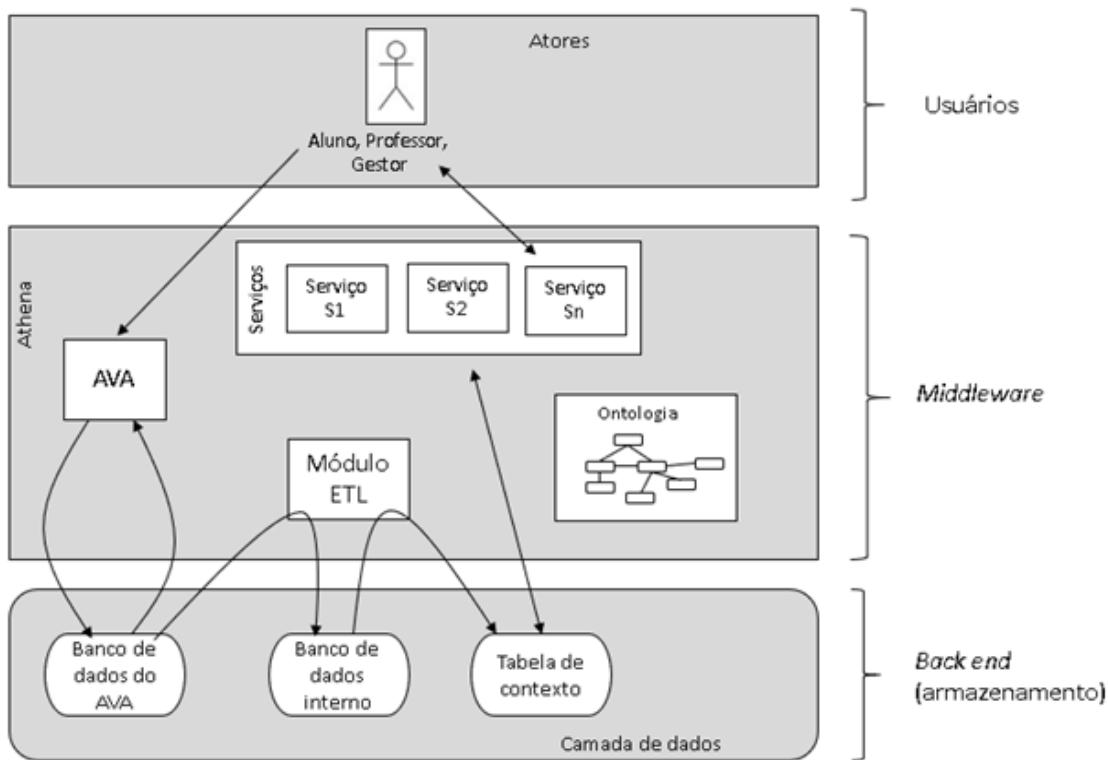
O desenvolvimento contínuo do modelo pode revelar novos participantes, enquanto a variedade de serviços oferecidos irá crescer à medida que o modelo se fortalecer. A estratégia adotada identificou os atores e serviços mais significativos para descrever e tornar tangível o modelo.

4.3 Arquitetura Athena

A arquitetura do Athena teve como base o padrão interno da TAM - *Standard for Technical Architecture Modeling* proposta pela SAP. *Standardized Technical Architecture Modeling* (2007)¹. A Figura 14 apresenta a arquitetura geral do modelo Athena.

¹ <http://www.fmc-modeling.org/download/fmc-and-tam/SAP-TAMStandard.pdf>

Figura 14: Arquitetura Geral do Athena

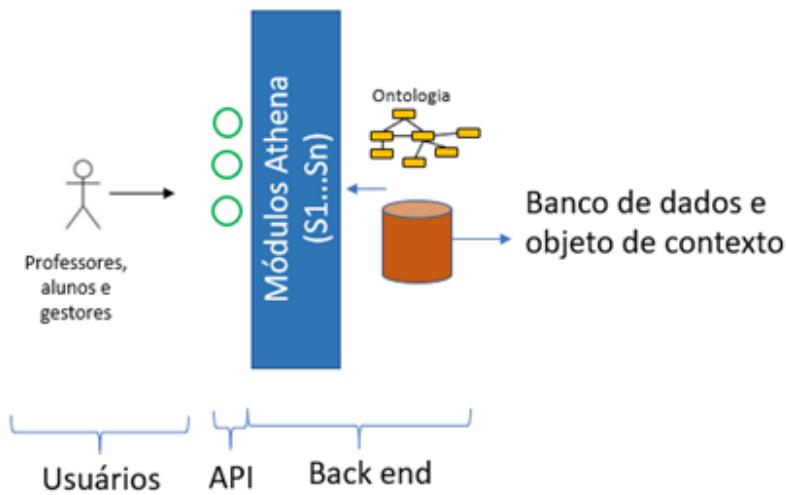


Fonte: Elaborado pela autora

A arquitetura está dividida em três camadas, sendo: a) na primeira camada encontra-se o *Back end* (bancos de dados do ambiente virtual, o banco de dados interno e o banco de dados de contextos); b) na segunda camada encontra-se o *Middleware* composto pelo AVA, que é o ambiente virtual de aprendizagem, nele ficam armazenados os dados de acesso e todas as atividades desenvolvidas pelos alunos (contextos), o módulo ETL que faz a movimentação dos dados entre os bancos do AVA, dos dados interno e do contexto, os módulos de serviços inteligentes e a ontologia serve como base de conhecimento sobre o domínio educação à distância e serviços inteligentes; c) na terceira camada encontram-se os atores, ou seja, os usuários dos serviços inteligentes (discentes, docentes e gestores).

A Figura 15 ilustra uma representação visual da interação entre os usuários e o modelo Athena. A imagem destaca a arquitetura em termos de segmentação, delineando claramente as partes conforme sua proximidade com os usuários, que incluem professores, alunos e gestores.

Figura 15:Interação com o modelo



Fonte: Elaborado pela autora

Os usuários (professores, alunos e gestores) interagem com o modelo por meio de vários serviços inteligentes, sendo que a API atua como o elo entre os usuários e esses serviços. No *back end*, encontram-se os módulos dos serviços inteligentes (Módulos s1, S2...Sn), juntamente com a ontologia que serve como base de conhecimento e o banco de dados de contextos, onde são armazenadas todas as informações geradas pelos alunos. Tais informações são utilizadas e sincronizadas para análise de históricos de contextos, podendo ser acessados pelos professores, gestores e por diferentes serviços inteligentes.

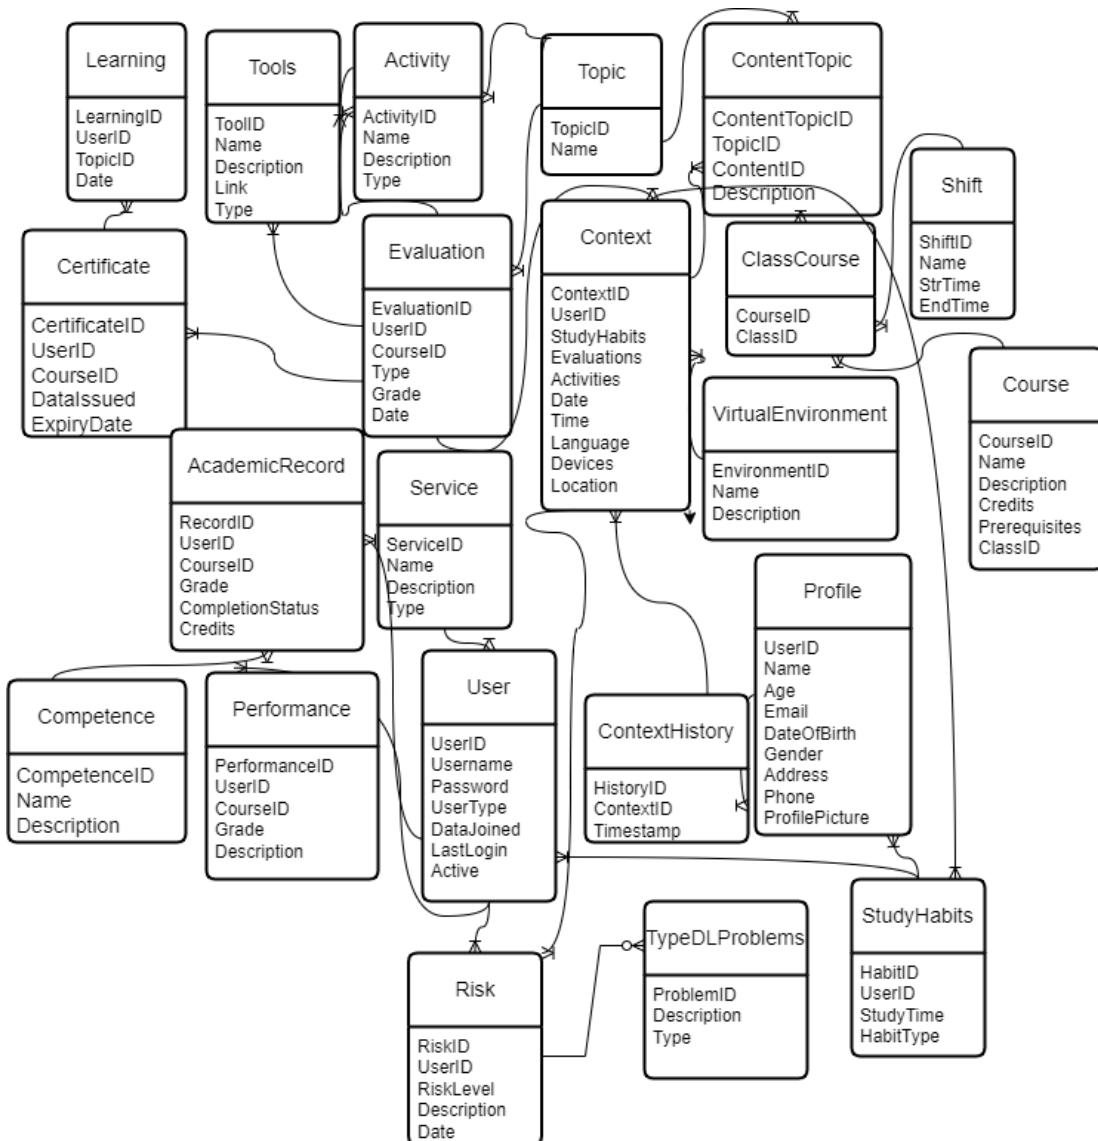
4.4 Modelo de dados

Para armazenar as informações associadas ao contexto e perfil do aluno, foi decidido usar um banco de dados relacional. O banco de dados foi construído com base no modelo Entidade-Relacionamento (ER), com o objetivo de fornecer suporte tanto para a coleta quanto para a predição realizada pelo Athena.

A Figura 16 representa o modelo ER, concebido para acomodar as informações que constituem os históricos de contextos dos alunos e para armazenar os dados do modelo

Athena. Na elaboração do modelo ER, empregou-se a ferramenta Draw.io², uma ferramenta de diagramação *online* gratuito, capaz de criar uma variedade de diagramas, como fluxogramas, diagramas de processos, organogramas, UML (*Unified Modeling Language*, ER (Entidade Relacionamento) e diagramas de rede. As entidades são representadas no modelo por meio de tabelas *AcademicRecord*, *Activity*, *Certificate*, *ClassCourse*, *Competence*, *ContentTopic*, *Context*, *ContextHistories*, *Course*, *Evaluation*, *Learning*, *Performance*, *Service*, *Profile*, *Risk*, *Shift*, *StudyHabits*, *Tools*, *Topic*, *TypeDL-Problems*, *User*, *VirtualEnvironment*.

Figura 16: Modelo de Dados



Fonte: Elaborada pela autora

² <https://app.diagrams.net/>

A tabela *AcademicRecord* contém informações sobre dados cadastrais e acadêmicos do aluno. A tabela *Activity* refere-se às atividades realizadas pelo aluno. A atividade caracteriza a ação do aluno no contexto, identificada pelo código e nome da atividade, podendo ser um fórum, uma atividade *online* e avaliações. A tabela *Certificate* guarda informações, tais como nome do aluno, do curso e titulação e *ClassCourse* armazena o código da turma dentro do ambiente virtual. A tabela *Competence* contém a identificação e descrição das competências de aprendizagem como atitudes, aptidão, habilidades, conhecimento e autoconhecimento. A tabela *ContentTopic* armazena o código, nome, descrição e carga horária da disciplina.

A tabela *Course* armazena nome do curso, código, descrição, créditos, pré-requisitos e aulas. A tabela *Evaluation* contém a identificação da avaliação, do usuário, do curso, da nota e da data e, a tabela *Learning* armazena a identificação do usuário, conteúdos e data. A tabela *Performance* identifica o usuário, o curso e a nota. A tabela *Service* armazena a identificação do serviço, nome, descrição e tipo de serviço. A tabela *Profile* armazena a identificação do usuário, nome, *e-mail*, data de nascimento, gênero, endereço, telefone e foto de perfil. A tabela *Risk* armazena o código do risco, a descrição, o usuário e classificação do risco. Na tabela *Shift* encontram-se a identificação, nome, descrição do turno, tempo como início e fim.

A tabela *StudyHabits* armazena o código, o tipo de hábito e o usuário. A tabela *Tools* armazena o código, nome, descrição, tipo de ferramenta e *Topic* guarda a identificação e o nome do conteúdo. A tabela *TypeDL-Problems* armazena o código do problema, sua descrição e o tipo do problema. A tabela *User* armazena o código, o usuário, senha, tipo de usuário, data de acesso e de saída, atividades e *VirtualEnvironment* contêm informação sobre o ambiente virtual, como código, nome e a descrição do ambiente.

A tabela *Context* armazena informações sobre as atividades realizadas, avaliações, localização, hábitos de estudos, dispositivos, idioma, data, hora e tipo de conexão utilizada. A tabela *ContextHistories* é composto pelos dados contidos na tabela *Context*. A cada interação do aluno no ambiente virtual, um registro é inserido na tabela *Context* para futuras consultas. A tabela *Context History* mantém registros do contexto do aluno e por fim, uma Ontologia foi desenvolvida para a representação deste conhecimento.

4.5 Um Cenário de histórico de contextos

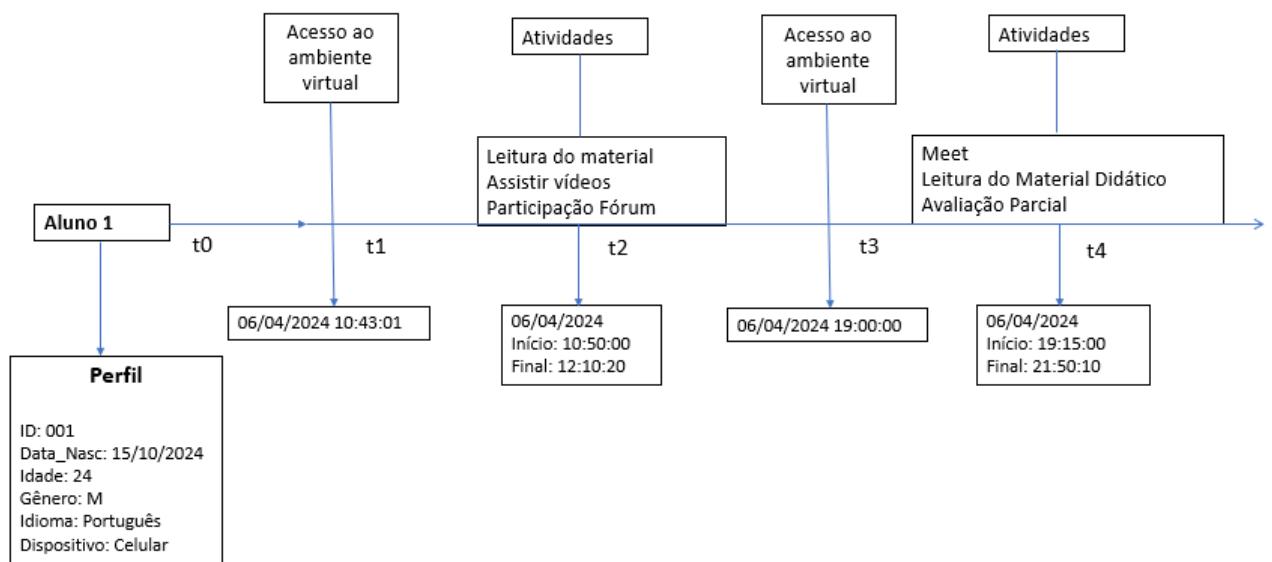
Esta seção apresenta na sequência um evento num cenário educacional, a fim de representar informações que podem compor o histórico de contextos. O usuário X é aluno do curso de tecnologia em análise de sistemas da universidade Y, fazendo o curso na modalidade a distância.

Para conseguir desenvolver a disciplina o aluno precisa acessar o curso no ambiente virtual, participar de *chats*, fóruns, receber e enviar mensagens, participar das aulas remotas ofertadas para auxiliar na compreensão do tema proposto, acessar os materiais didáticos, assistir os vídeos, desenvolver as atividades propostas e realizar as avaliações parciais e oficiais obrigatórias durante o semestre.

A análise do cenário permite identificar contextos como a participação nos fóruns e *meet*, vídeos assistidos, acesso ao material didático, entregas das atividades, realização das avaliações, participação das aulas remotas, idioma, dispositivo utilizado, entre outros.

A Figura 17 apresenta um exemplo do histórico de contextos do aluno 1. O exemplo inclui detalhes de identificação do indivíduo, tipo de atividade realizada, data e hora de acesso, bem como a data de início e conclusão da atividade. Tais informações compõem o histórico de contextos do aluno 1.

Figura 17: Exemplo de histórico de contextos



Fonte: Elaborado pela autora.

4.6 Considerações sobre o capítulo

Este capítulo apresentou o Athena, um modelo computacional voltado para serviços inteligentes na educação a distância, com base na análise de históricos de contextos. Inicialmente, uma visão geral do modelo e seus componentes é apresentada, seguida pelo caso de uso dos atores e serviços do modelo. A arquitetura é detalhada, composta por três camadas: na camada inferior, encontra-se o *Back End*, que abriga os bancos de dados do ambiente virtual, incluindo o banco de dados interno e o banco de dados de contextos; na camada intermediária está o *Middleware*, composto pelo AVA, o módulo ETL, os módulos de serviços inteligentes e a ontologia; e na camada superior estão os usuários do modelo computacional. Além disso, uma representação visual da interação dos usuários com o Athena é apresentada, juntamente com o modelo de dados, onde o conhecimento representado pela OntoAthena foi utilizado na criação do modelo ER. A próxima seção aborda a ontologia para a representação do domínio relacionado à educação a distância e serviços inteligentes.

5 ONTOLOGIA ONTOATHENA

Neste capítulo, é introduzida a OntoAthena, uma ontologia desenvolvida para educação a distância e serviços inteligentes. Destaca-se que a OntoAthena serviu como base para um artigo publicado no *International Journal of Metadata, Semantics and Ontologies* (SILVA et al., 2024).

Uma ontologia é uma representação formal e organizada do conhecimento em uma determinada área. No contexto da EaD, uma ontologia pode ser útil para estruturar conceitos e relações relevantes para essa modalidade de ensino e através da *Web Ontology Language*, é possível descrever classes que representam conceitos e suas relações com axiomas que podem restringir o significado dos conceitos e relações, permitindo assim, a inferência de conhecimentos implícitos.

A OntoAthena é uma ontologia para representar o conhecimento no domínio da Educação a Distância e ofertas de serviços inteligentes baseados em elementos do contexto dos indivíduos que são utilizados na composição de históricos de contextos. Esta seção apresenta trabalhos relacionados às ontologias na Educação a Distância, o mapa conceitual, a OntoAthena e sua implementação, as questões de competências, classes e hierarquias.

5.1 Trabalhos relacionados às Ontologias na Educação a Distância

Na área de tecnologia aplicada à educação a distância, várias pesquisas têm se concentrado na criação de ontologias. Nesta seção são descritas ontologias aplicadas no domínio de educação, educação a distância, ambientes virtuais de aprendizagem, recomendação de conteúdos, recursos educacionais, entre outros.

Os trabalhos foram pesquisados nas seguintes bases *ACM Digital Library*, *IEEE Xplore Digital Library*, *ScienceDirect*, *Springer Library*, *Scopus*, utilizando os seguintes critérios: a) artigos publicados entre 2015 a junho 2021; b) artigos publicados em conferências, *workshop* ou periódico. O estudo de termos para a definição da *string* de busca baseou-se nas palavras: (*Ontology; distance education, contexts, historical context*). A fim de estabelecer os interesses da pesquisa, foi definida a seguinte *string* de busca: (*Distance learning OR Distance education OR E-Learning OR online Learning education OR*

Educational technology OR virtual learning environment OR learning management system AND ontology AND contexts OR historical context).

Os ambientes de *e-learning* têm se apresentado com potencial para a educação a distância, fornecendo contribuições significativas nos processos de ensino e aprendizagem, dentre eles, o uso de ontologias como forma de representar o domínio do conhecimento. Esta seção apresenta os trabalhos relacionados que abordam o desenvolvimento de ontologias com foco na educação a distância.

Marzano; Notti (2015), criaram de maneira colaborativa, utilizando o ambiente Edu *OntoWiki*, a Eduonto, uma ontologia para avaliação educacional. Os autores investigaram aplicações da *web* semântica nos contextos educativos e formativos integrando as instâncias inovadoras e atuais relacionadas com o *e-learning* e a *web* semântica através da co-construção e teste de um ambiente de aprendizagem integrado com o objetivo de proporcionar uma ferramenta de consulta, comparação e aprendizado para comunidades acadêmicas, escolas e outras instituições de ensino.

Kharraz; El Mezouary; Mahani (2018), propuseram uma ontologia para modelagem de aluno consciente de contexto, no campo do sistema de ensino a distância, enriquecida a partir de modelos existentes. O foco da ontologia não se restringiu a modelar as características do aluno, mas engloba tanto as características do aluno quanto informações específicas sobre o contexto de aprendizagem. A ontologia desenvolvida permite a troca de informações do aluno entre os diferentes componentes do sistema e a extração de novos conhecimentos por meio do raciocínio sobre essas informações.

Sabbir M. Rashid (2018), apresentaram uma ontologia de padrões educacionais que têm o potencial de simplificar o planejamento de aulas para professores, fornecer suporte aos alunos vinculando recursos relevantes e fornecer uma terminologia para uso em uma língua franca para comunicação com várias comunidades sobre componentes educacionais. De acordo com os autores, uma ontologia baseada em padrões *Common Core* pode ajudar no projeto de sistemas de tutoria *online* e pode reduzir a ambiguidade da terminologia codificando definições explícitas de computador e humanamente comprehensíveis.

Saida Ulfa Deddy Barnabas Lasfeto (2019), expuseram uma ontologia que se concentra nos seguintes elementos: análise e avaliação comportamental; detecção de estilos de aprendizagem; desenvolvimento de perfis de aprendizes que levam em conta os conhecimentos; preferências e atitudes dos aprendizes. Segundo os autores, essa ontologia

realiza um sistema de aprendizagem adaptativo que permite a adaptação do conteúdo pedagógico de acordo com as necessidades atuais do aluno, monitorando e avaliando o aluno durante a sequência de aprendizagem.

Carlos et al. (2019), apresentaram a *LESD-Onto*, uma ontologia para o mapeamento semântico de dados entre ambientes de aprendizagem. A ontologia é capaz de descrever o modelo de dados do ambiente de aprendizagem *Moodle* e da *Youubi API*, que fornece um conjunto de serviços para a construção de aplicações para computação ubíqua, utilizando no ambiente Edubi, mas com capacidade de expansão para outros ambientes virtuais.

Faqihi; Daoudi; Ajhoun (2019), criaram uma ontologia de pesquisa de Recursos de Aprendizagem e propuseram a criação de um sistema de recomendação para o autor, baseado nessa ontologia. O autor deve especificar o domínio, o objetivo geral e o objetivo específico, todos inspirados na ontologia criada. Além de ser uma ontologia de pesquisa, é ao mesmo tempo uma recomendação, independente do ambiente utilizado, seja REA, MOOC ou *E-Learning*.

Zeebaree et al. (2019), desenvolveram uma ontologia de um Sistema de Gerenciamento de *E-learning* da *Duhok Polytechnic University* (ELMS-DPU) para corrigir os problemas existentes na universidade na região do Curdistão, incluindo a falta de relação entre a necessidade do usuário e o conteúdo dos documentos. O sistema de *e-learning* consiste em três seções principais: Administrador, Professor e Aluno.

Joy Jeevamol; G. (2019), criaram um modelo de ontologia que conceitua as características do aluno e do objeto de aprendizagem que podem ser usadas para recomendação de conteúdo em um ambiente de aprendizagem adaptativo. Foram consideradas as características estáticas e dinâmicas de um aprendiz para modelá-las. O modelo ontológico suporta a personalização baseada em *Felder-Silverman Learning Style Model* (FSLSM). Os objetos de aprendizagem foram modelados usando metadados *IEEE LOM* padronizados. Neste estudo, os autores consideraram os atributos necessários para um ambiente de *e-learning* personalizado para recomendar objetos de aprendizagem adequados com base nas características de aprendizagem do aluno.

Bourekkache et al. (2019), propuseram uma abordagem ontológica para a representação do perfil do aluno e estilos de aprendizagem. Os autores representaram os perfis e estilos de aprendizagem dos alunos usando o aspecto semântico (ontologias e seus relacionamentos) para simplificar a extração de informações e garantir os caminhos de

aprendizagem personalizados. O sistema adaptativo oferece a oportunidade de ajustar os cursos e estratégias (estilos) para um aprendizado personalizado para cada aluno de acordo com suas preferências e características.

Grivokostopoulou et al. (2019), apresentaram uma ontologia genérica que agrupa conceitos e propriedades usados para modelar perfis de usuários, completa e extensível em sistemas de *e-learning*. A ontologia consiste em informações pessoais, cognitivas e sociais dos alunos, bem como, informações sobre seu desempenho e habilidades. A abordagem ontológica é independente de domínio podendo ser utilizada como modelo de referência para representação de aprendizes em sistemas tutores inteligentes no ensino superior e à distância. A modelagem do aluno foi integrada a um sistema educacional existente. Segundo os autores, uma vantagem do modelo é a formulação e integração de regras semânticas. Essas regras em conjunto com o mecanismo de inferência são capazes de analisar a aprendizagem dos alunos e extrair conhecimento sobre seu desempenho.

O artigo desenvolvido pelos autores Mohemad et al. (2020), apresenta uma nova ontologia de domínio, chamada ONT-SLD, com o objetivo de conceituar formalmente elementos e regras essenciais, abrangendo as características das dificuldades de aprendizagem específicas do aluno e das atividades educacionais. O modelo de ontologia apresentado foi avaliado em um caso do mundo real para identificar precocemente alunos com dificuldades de aprendizagem e recomendar atividades educacionais adequadas. A avaliação da taxonomia foi realizada usando SPARQL para mostrar que o modelo ontológico é capaz de detectar conflitos semânticos.

Bolock; Abdennadher; Herbert (2021), desenvolveram a CCOnto, uma ontologia que descreve o comportamento humano baseado em situações em relação a estados e traços psicológicos. Neste trabalho, os autores usaram e aplicaram a CCOnto como um sistema de descrição teórica e formal para categorizar fatores psicológicos que influenciam o comportamento do discente durante a situação do COVID-19. Ao fazer isso, eles mostraram o valor agregado das ontologias, ou seja, sua capacidade de organizar automaticamente informações de dados humanos não estruturados, identificando e categorizando conceitos psicológicos relevantes.

Deambrosis; Motz; Eliseo (2021), apresentaram a *UDLOntology*, uma ontologia no domínio da Educação baseada nos princípios do *Design Universal* para aprendizagem. A ontologia tem como objetivo inferir recomendações de materiais educacionais que facilitam e

estimulam o aprendizado do aluno de acordo com suas habilidades e pontos fortes individuais de aprendizado. A *UDLOntology* em conjunto com a plataforma de autoria de cursos SELI (*Smart Ecosystem for Learning and Inclusion*) orienta e auxilia professores e educadores na construção de recursos didáticos para apoiar e capacitar pessoas com deficiência.

Ilkou et al. (2021), desenvolveram a EduCOR- uma Ontologia de Recomendação Educacional e Orientada à Carreira. A EduCOR fornece uma base para representar recursos de aprendizado *online* para sistemas de aprendizado personalizados. A ontologia foi projetada para permitir que os repositórios de materiais de aprendizagem ofereçam recomendações de caminhos de aprendizagem, que correspondam às metas e preferências de aprendizagem do usuário, parâmetros acadêmicos e psicológicos e habilidades do mercado de trabalho. A ontologia apresenta as classes e propriedades necessárias para construir um ambiente de *e-learning* que suporte recomendações personalizadas.

Paquette (2021), construíram a COMP2, uma ontologia de competência definida em termos da linguagem de ontologia RDFS, aplicando os princípios da *web* semântica. A ontologia possui as seguintes propriedades principais: é genérica, especializada para qualquer perfil ou modelo de competência, e em qualquer assunto ou domínio de conhecimento; flexível em seu uso, o que significa que pode abranger uma grande variedade de aplicações educacionais ou de gestão do conhecimento onde as competências estão associadas a pessoas e os recursos podem ser expressos, comparados e avaliados e com conexões com o crescente número de vocabulários e ontologias educacionais que povoam a teia de dados abertos vinculados. Ela fornece uma base sólida para construir ambientes de aprendizagem ou de trabalho baseados em competências.

A ontologia proposta neste trabalho tem como objetivo apresentar o domínio do conhecimento da educação a distância. A tabela 11 apresenta um comparativo dos trabalhos relacionados e, observa-se que apenas um dos trabalhos mencionam o uso de contextos no desenvolvimento da ontologia. O termo contexto é abordado por Carlos et al. (2019), mas os autores não descrevem ou fazem uso de contextos no seu trabalho.

Já o trabalho apresentado por Akharraz et al. (2018), teve como principal objetivo propor uma modelagem do aluno consciente do contexto, baseado em ontologia e enriquecida a partir de modelos existentes, dotando os sistemas de ensino à distância com capacidades de reagir de acordo com cada educando. Portanto, fornecendo-lhes algumas formas de inteligência. Entretanto, o trabalho apresentado, mesmo se tratando da modalidade a distância,

o domínio é sobre o modelo do aluno e não sobre educação a distância, bem como, os autores não mencionam serviços inteligentes.

Tabela 11: Comparaçāo de trabalhos relacionados

Referência	Domínio	Metodologia	Regras	Consultas	Reuso	Contexto	Avaliação
MARZANO; NOTTI (2015)	Avaliação Educacional	Própria. Conceitos organizados em cinco dimensões.	Não	Não	Não	Não	Protocolo de Experimentação.
AKHARRAZ; EL MEZOUARY; MAHANI (2018)	Modelo do Aluno.	<i>Methontology</i> .	Não	Não	Sim	Não	Não
SABBIR M. RASHID (2018)	Padrões de educação.	Própria. Uso de tags HTML para extrair informações para gerar classes.	Não	Não	Não	Não	Não
SAIDA ULFA DEDDY BARNABAS LASFETO (2019)	Modelo do aprendiz na EaD.	Não mencionado.	Não	Não	Não	Não	Não
CARLOS et al. (2019)	Ambientes virtuais de aprendizagem.	<i>Ontology Development 101</i> .	Não	SPARQL	Não	Menciona, mas não descreve	Consistência completude e concisão, através de <i>reasoner</i> e consultas SPARQL
FAQIHI; DAOUDI; AJHOUN (2019)	Recursos educacionais para MOOCs, OERs, plataformas de e-learning.	Não mencionado	Não	Não	Não	Não	Distância Euclidianas, uso dataset para buscar recursos educacionais.
ZEEBAREE et al. (2019)	Sistemas de Educação a distância.	Não mencionado	Não	Não	Não	Não	<i>Reasoner HermiT</i> , consistência e classificação.
JOY JEEVAMOL; G. (2019)	Recomendação de conteúdo.	Não mencionado	Não	Não	Não	Não	Não
BOUREKKAC HE et al. (2019)	Estilos de aprendizagem e perfil do aluno.	Não mencionado	Regras de adaptação	SPARQL	Não	Não	Não
GRIVOKOST OPOULOU et al. (2019)	Genérica.	Não mencionado	Regras da Web Rule Language.	SPARQL	Não	Não	Regra para responder uma questão de pesquisa.
MOHEMAD et al. (2020)	Educação especial (dislexia, discalculia, disgrafia) em sistemas de e-learning.	Define três passos: especificação, conceitualização, formalização e implementação	Regras da Web Rule Language.	SPARQL	Não	Não	Não

Referência	Domínio	Metodologia	Regras	Consultas	Reuso	Contexto	Avaliação
BOLOCK; ABDENNADH ER; HERBERT (2021)	Estado psicológico de estudantes durante a pandemia.	<i>Methontology</i>	Regras da <i>Web Rule Language</i> .	Não	Não	Não	Não
DEAMBROSIS ; MOTZ; ELISEO (2021)	Educação e diversidade.	Não mencionado	Não	Não	Não	Não	Regra para responder uma questão de pesquisa
ILKOU et al. (2021)	Recursos de aprendizagem em sistemas de <i>e-learning</i> .	Própria. Análise de requisitos.	Não	SPARQL	Sim. IEEE LOM, CCSO, DCMI, SKOS, schema.org.	Não	Questões de competências respondidas por consultas SPARQL.
PAQUETTE G. (2021)	Descrição de competência e perfis de competência.	Não	Não	SPARQL	Não	Não	Não

Fonte: Elaborado pela autora.

Considerando o resultado do comparativo entre os trabalhos relacionados, a OntoAthena se diferencia nos seguintes aspectos: a) a OntoAthena se destaca na modelagem do conhecimento voltado para educadores no contexto do ensino à distância; b) tem como foco principal a utilização dos históricos de contextos dos alunos na modalidade a distância e na oferta de serviços inteligentes. Seu principal objetivo é oferecer suporte nos processos de ensino e aprendizagem, além de evitar reprovações e desistências, utilizando as informações disponíveis nos registros de contexto.

Vale ressaltar que, entre os artigos relacionados, apenas o estudo de Carlos et al. (2019) menciona o termo "contextos", mas não explora ou utiliza esse conceito em suas pesquisas. Ademais, a flexibilidade da OntoAthena permite sua reutilização ou expansão de acordo com as necessidades específicas da instituição. Ela também usa regras para inferir resultados e resolver questões de competência por meio de consultas SPARQL, utilizando os históricos de contextos do aluno.

5.2 Mapa conceitual da OntoAthena

A construção do mapa conceitual foi realizada a partir da definição do tema focal: Serviços Inteligentes na Educação a Distância usando históricos de contextos. Foram elaboradas dezenove perguntas através de estudos teóricos e vivências profissionais. A

elaboração das perguntas e suas respostas tiveram como objetivo auxiliar na construção do conhecimento e são apresentadas na tabela 12.

Para formular os conceitos, foram selecionadas palavras das perguntas e respostas elaboradas anteriormente sobre o tema em foco. Por exemplo, da questão ID2, "Quais são as competências de aprendizagem?", foi extraída a palavra "competência"; na questão "Quem são os usuários do ambiente virtual?", foi extraída a palavra "usuário", e assim sucessivamente.

Os conceitos delineados nos mapas conceituais foram expressos em linguagem natural em português. A utilização da linguagem natural simplifica a compreensão dos conceitos e das relações estabelecidas entre eles. Após a elaboração dos conceitos, as proposições, ou seja, as frases de conexão, foram determinadas para representar a relação entre dois conceitos.

Tabela 12: Perguntas e respostas ao tema focal

ID	Pergunta	Resposta	Referência
1	Quais são os tipos de atividades que representam a aprendizagem no ambiente virtual?	Online e presencial.	Definido pela autora.
2	Quais são as competências de aprendizagem?	Atitude, aptidão, habilidades, conhecimento e autoconhecimento.	Definido pela autora.
3	Quais são os tipos de hábitos de estudos?	Vídeos assistidos, acesso de conteúdo, preferências do aluno.	Definido pela autora.
4	Que tipos de interação existem no ambiente virtual?	Assíncrona e síncrona.	Definido pela autora.
5	Que tipos de problemas podem impactar no desenvolvimento educacional do aluno?	Abandono e reprovação.	Definido pela autora.
6	Quais são os turnos existentes no ambiente virtual?	Matutino, vespertino e noturno.	Definido pela autora.
7	Que tipos de ferramentas existem no ambiente virtual?	Ferramenta de auxilio, de sistemas, de interação.	Ambiente Virtual <i>Moodle</i> .
8	Quais as ferramentas de auxilio existentes no ambiente virtual?	Glossário, lição, pesquisa de opinião, questionário, tarefas.	Ambiente Virtual <i>Moodle</i> .
9	Quais as ferramentas de sistemas existentes no ambiente virtual?	Agenda, calendário, <i>e-mail</i> , lista.	Ambiente Virtual <i>Moodle</i> .
10	Quais as ferramentas de interação existentes no ambiente virtual?	<i>Chat</i> , Diário, Fórum, mensagem, <i>wiki</i> .	Ambiente Virtual <i>Moodle</i> .
11	Quem são os usuários do ambiente virtual?	Professor, coordenador, visitante, aluno, gestor, tutor, suporte técnico.	Ambiente Virtual <i>Moodle</i> .

ID	Pergunta	Resposta	Referência
12	Que dados compõe o perfil do usuário dentro do ambiente virtual?	Dados pessoais (nome, endereço, <i>e-mail</i> , senha, telefone.), acadêmicos e profissionais do usuário.	Ambiente Virtual <i>Moodle</i> .
13	Quais informações contém no contexto?	Localização, hábitos de estudos, dispositivos, atividades, idioma, data, hora, tipo de conexão.	Definido pela autora.
14	Quais informações estão contidas no histórico de contextos de alunos no ambiente virtual?	Acesso, tempo de acesso, atividades realizadas, vídeos assistidos, avaliações realizadas.	Definido pela autora.
15	Quais serviços inteligentes podem ser oferecidos para os alunos que possuem risco de abandono ou reprovação na EaD?	Formação de grupos, sistema de predição, Sistema de aprendizagem, sistemas de recomendação, sistema de tomadas de decisões, sistema de análise de dados.	Definido pela autora.
16	Que tipos de notificações existem no ambiente virtual?	Mensagens, eventos e e-mails.	Ambiente Virtual <i>Moodle</i> .
17	Que tipos de avaliações podem ser aplicadas aos alunos na EaD?	Autoavaliativa, Somativa, Diagnóstica, Ipsilon ³ .	Definido pela autora.
18	Que variáveis normalmente são utilizadas para avaliar o desempenho do aluno?	Avaliações, atividades, atividades em grupo, hábitos de estudos (conteúdo acessado, mensagem trocada (chat, fórum), vídeo assistido, preferência (assistir vídeo ou ler texto), atividade realizada ou não realizada).	Definido pela autora.
19	Como classificar risco de abandono e retenção dos alunos nos cursos EaD?	Alto, médio e baixo.	Definido pela autora.

Fonte: Elaborado pela autora.

Para organizar o conteúdo e apresentar os conceitos definidos para o tema focal foi utilizada a ferramenta *CmapTools*⁴. A Figura 18 apresenta os principais conceitos definidos no mapa conceitual sendo suas relações destacadas através das proposições.

O mapa conceitual é composto pelos conceitos Educação a Distância (amarelo escuro), Acompanhamento Acadêmico (verde), Prevenção (azul), Ambiente Virtual (Amarelo claro), Aluno (Vermelho) e serviços inteligentes de apoio às práticas educacionais, que contemplam os principais temas abordados pela ontologia.

O conceito “Educação a Distância” relaciona-se com o conceito “Aluno” através da relação “para”. O conceito “Aluno” relaciona-se com o conceito “Curso” através da relação “Matriculado”. Caso o aluno tenha um diagnóstico para evasão ou retenção a OntoAthena

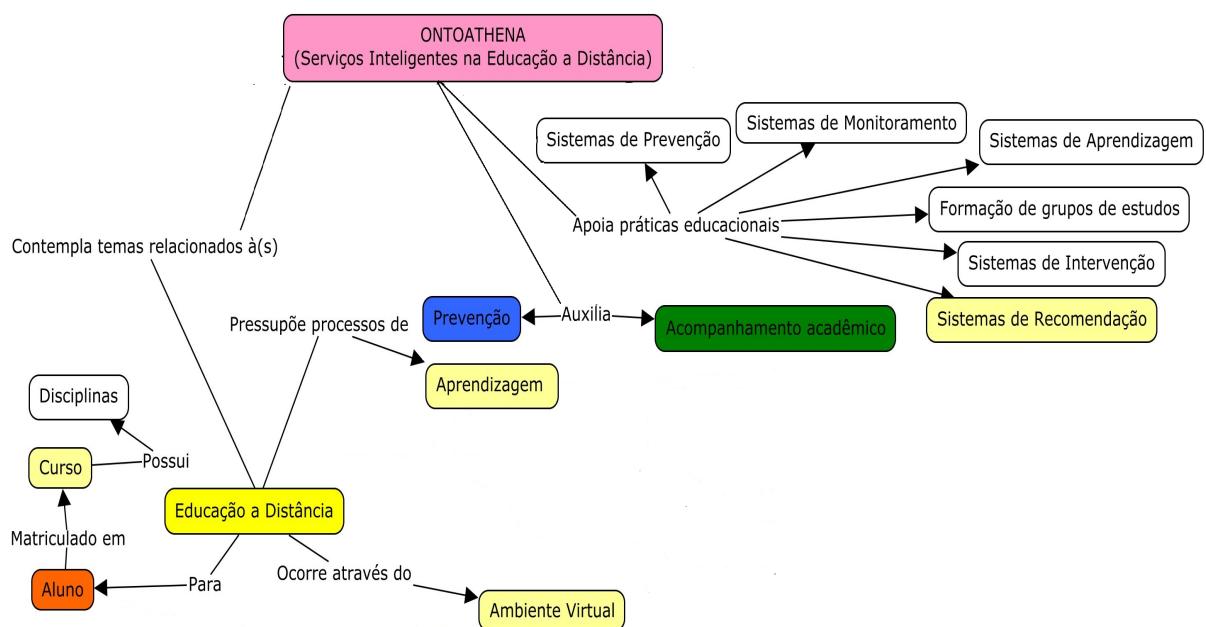
³Mede a performance de cada aluno em relação ao desempenho obtido no passado. Portanto, o método permite comparar os resultados atuais com os que já foram registrados anteriormente, evitando que ocorra comparações entre a turma.

⁴ <https://cmap.ihmc.us/cmaptools/>

auxilia no âmbito da prevenção, representada pelo conceito “Acompanhamento Acadêmico” e apoiado pelas “Práticas Educacionais” através de ofertas de “Serviços Inteligentes”, tais como sistemas de monitoramento, prevenção, aprendizagem, intervenção, recomendação e formação de grupos de estudos.

A Figura 18 ilustra o conceito “Educação a distância” (indicado em amarelo escuro, no canto inferior à esquerda da figura 18) e os elementos relacionados aos conceitos de Aprendizagem, Aluno (vermelho) e ambiente virtual (destacados em amarelo claro).

Figura 18: Mapa conceitual dos principais conceitos da OntoAthena



Fonte: Elaborado pela autora.

No contexto da OntoAthena, o conceito “Educação a distância” é a modalidade educacional na qual a mediação didático-pedagógica nos processos de ensino e aprendizagem ocorre com a utilização de meios e tecnologias de informação e comunicação (ambiente virtual), com estudantes e professores desenvolvendo atividades educativas em lugares ou tempos diversos, e tem como finalidade descrever os elementos que têm um impacto direto na oferta de cursos à distância.

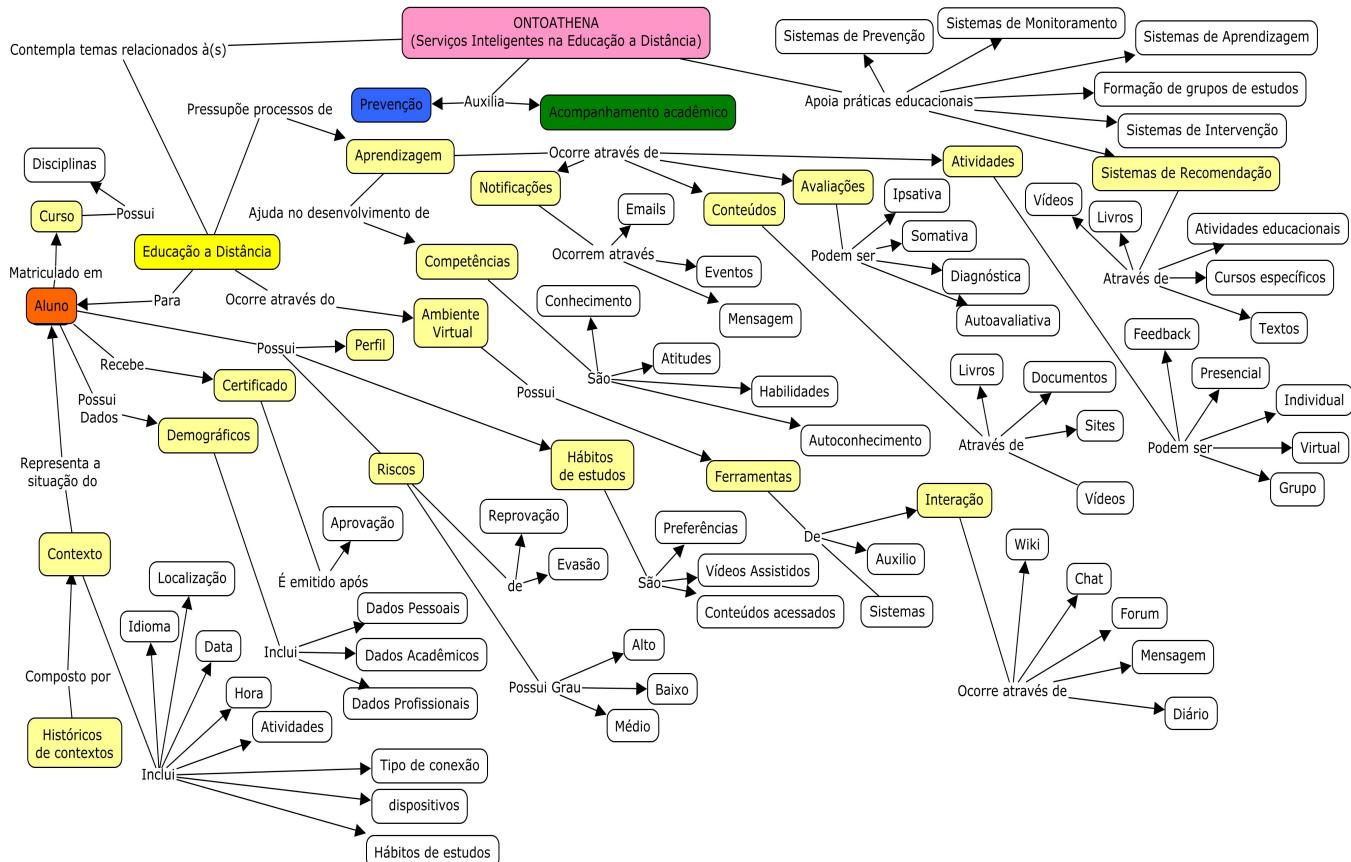
O mapa conceitual demonstra três conexões principais: uma com os processos de aprendizagem, outra com aluno e outra com o ambiente virtual. Por sua vez, o conceito de “Aprendizagem” se refere a forma de aprendizado que ocorre por meio de “Notificações” através de *e-mails*, eventos e mensagem; ofertas de conteúdos através de livros, documentos, vídeos e sites; “Avaliações” que podem ser somativa, diagnóstica, autoavaliativa ou ipsativa (avaliação ipsativa mede o desempenho de cada aluno em relação ao desempenho obtido no passado), e auxiliam no planejamento e a revisão dos processos de ensino-aprendizagem.

O propósito dessas avaliações é conduzir uma análise detalhada do desempenho atual dos estudantes. A partir desse diagnóstico, torna-se viável planejar e implementar atividades, metodologias e práticas que estejam em consonância com as principais necessidades identificadas dos alunos.

As “Atividades” podem ser realizadas de forma virtual ou presencial, individual ou em grupo, como *feedback* dos conteúdos apresentados. As avaliações e atividades possuem foco no aperfeiçoamento, no aumento de desempenho e desenvolvimento de habilidades dos discentes, e servem como ferramentas para conhecer o desempenho e o perfil dos alunos, além da realização de acompanhamento e apoio em melhorias no processo de ensino-aprendizagem. O processo de aprendizagem também ajuda no desenvolvimento das competências, tais como atitudes, habilidades, conhecimento e autoconhecimento.

O conceito “Aluno” (destacado em vermelho no canto inferior esquerdo da Figura 19) constitui uma classificação de informações do aluno representados através do conceito “Perfil”, conceito “Dados Demográficos”, que inclui dados pessoais, acadêmicos e profissionais.

Figura 19: Conceitos Educação a Distância, Ambiente Virtual, Alunos, Serviços Inteligentes e demais elementos.



Fonte: Elaborado pela autora.

O conceito de “Contexto” (Destacado em amarelo no canto inferior esquerdo da Figura 19) foi incorporado para representar a situação de uma entidade, neste caso, o estudante, que é representado pelo conceito “Aluno” no mapa conceitual.

O propósito é descrever quais são os elementos do contexto que caracterizam a interação do aluno com o modelo. Isso inclui detalhes como a natureza da atividade realizada, o local onde a atividade ocorreu, o momento em que a atividade foi executada (incluindo data e horário), o idioma utilizado, os hábitos de estudo, o dispositivo utilizado e o tipo de conexão.

A sequência de atividades executadas ao longo do tempo pela entidade, no caso, o aluno, cria um histórico que é representado pelo conceito “Históricos de contextos” (canto inferior esquerdo, destacado em amarelo claro na Figura 19).

O conceito “Ambiente Virtual” foi incluído para representar o local onde o curso é oferecido e acessado pelo aluno, possui ferramentas de auxílio, sistemas e interação que promovem a comunicação dos alunos, professores, gestores e apoio técnico dentro do ambiente educacional virtual.

Na Figura 19, observa-se que o mapa conceitual abrange 81 conceitos e incorpora 30 frases de conexão. Importante ressaltar que esse mapa conceitual não está restrito a esses números, pois pode ser expandido e utilizado para oferecer serviços inteligentes que se fundamentem nos históricos de contextos.

Esses serviços têm o propósito de auxiliar gestores, professores e alunos no aprimoramento do processo de ensino e aprendizagem. Após a definição dos conceitos e das relações necessárias para o desenvolvimento da OntoAthena por meio da teoria dos mapas conceituais, a próxima seção descreve a construção da ontologia.

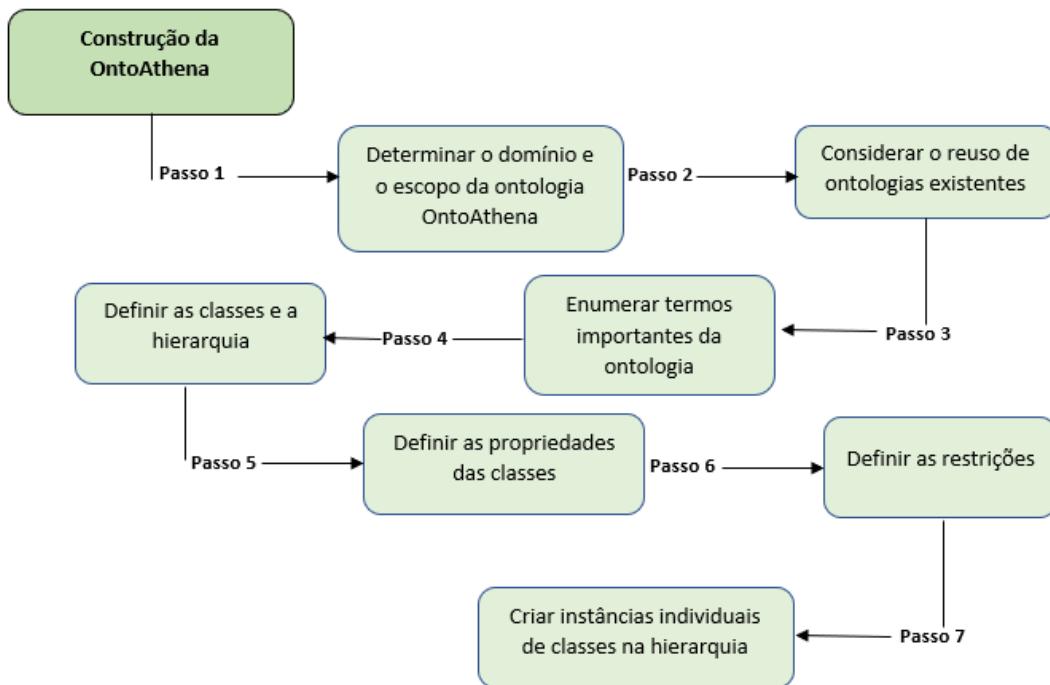
5.3 Construção da OntoAthena

Para orientar o desenvolvimento da ontologia, foi adotada a metodologia *Ontology Development 101*. Essa metodologia consiste em um processo iterativo e simples no desenvolvimento de ontologias, fundamentado em regras essenciais que fornecem suporte para a tomada de decisões de projeto ao longo da construção da ontologia.

A escolha dessa metodologia se justifica pela sua simplicidade e por ser amplamente utilizada na construção de ontologias, além de possuir um conjunto de passos bem definidos. (NOY; MCGUINNESS, 2001).

Seus passos envolvem todo o processo de desenvolvimento, inclusive contemplando a definição de hierarquias de classe e propriedades de classes e instâncias (NOY; MCGUINNESS, 2001). A metodologia *Ontology Development 101* preconiza sete passos, representadas na figura 20 e listados a seguir.

Figura 20: Passos definidos na construção da OntoAthena



Fonte: Elaborado pela autora.

- 1) Determinar o domínio e o escopo da ontologia OntoAthena: Neste passo, busca-se esclarecer “qual será o campo de abrangência da ontologia?” “qual é a finalidade de sua utilização?”, “para quais tipos de perguntas se espera que a ontologia forneça respostas?” e “quem será responsável pelo uso e manutenção contínua da ontologia?”;
- 2) Considerar o reuso de ontologias existentes: realiza-se a busca por ontologias que tenham relação com a ontologia a ser desenvolvida;
- 3) Enumerar termos importantes da ontologia: consiste na identificação de um conjunto de termos frequentemente utilizados em um domínio de conhecimento;
- 4) Definir as classes e a hierarquia: consiste em definir um conjunto de classes e organizá-las de forma hierárquica;
- 5) Definir as propriedades das classes: tem como objetivo dar sentido aos relacionamentos entre as classes;
- 6) Definir as restrições: são definidas as restrições das propriedades das classes;

7) Criar instâncias individuais de classes na hierarquia: definir uma instância individual de uma classe requer escolher uma classe, criar uma instância individual dessa classe e preencher os valores dos slots.

5.4 Determinar o domínio e o escopo da OntoAthena

A ontologia OntoAthena pode ser utilizada por sistemas educacionais que auxiliam os estudantes, professores e gestores em seu processo de ensino e aprendizagem. O objetivo é fornecer um mapeamento de conceitos sobre educação a distância, serviços inteligentes e históricos de contextos, permitir compartilhamento, reuso e evolução da ontologia pela comunidade e apresentar as questões de competências (QC).

As questões de competência exercem um papel fundamental em todo o ciclo de desenvolvimento de ontologias, uma vez que elas representam os requisitos funcionais da ontologia. Pode-se definir as questões de competência como um conjunto de perguntas e suas respectivas respostas, expressas em linguagem natural, que a ontologia deve ser capaz de responder corretamente (BEZERRA; FREITAS; SILVA, 2013).

As questões a seguir, são utilizadas tanto para estabelecer um limite do escopo da ontologia, como servir de base para a validação da ontologia. São exemplos que podem ser adaptadas para diferentes serviços inteligentes.

QC1: Qual aluno tem alto risco de reprovar ou abandonar o curso?

QC2: Qual aluno tem risco moderado de reprovar ou abandonar o curso?

QC3: Qual aluno tem baixo risco de reprovar ou abandonar o curso?

QC4: Quais são os hábitos de estudos ou padrão de comportamento do aluno que abandona o curso?

QC5: Qual seria a recomendação adequada para evitar que o aluno abandone o curso?

QC6: Qual seria a recomendação adequada para evitar que o aluno seja reprovado?

QC7: Qual serviço inteligente seria adequado para predizer se o aluno vai desistir do curso?

QC8: Qual serviço inteligente seria adequado para predizer se o aluno será reprovado de alguma disciplina?

QC9: Como formar grupos de estudos?

QC10: Como realizar o acompanhamento de um grupo de estudos?

5.5 Reutilização de ontologias existentes

Nesta etapa foi considerado o reuso de outra ontologia. A OntoAthena foi construída com base na OntoSALUS desenvolvida por Larentis (2022), onde foram reaproveitados conceitos como contexto, históricos de contextos, competência, *learning* e riscos. A OntoSALUS explora elementos do contexto dos indivíduos que são utilizados na composição de históricos de contextos.

5.6 Termos importantes da ontologia

Esta etapa consistiu em enumerar os termos importantes da ontologia. A OntoSALUS serviu como apoio na definição dos termos da OntoAthena. Além disso, o mapa conceitual elaborado e apresentado na seção 5.2 serviu para apoiar na definição dos termos principais da OntoAthena. Foi utilizado o idioma português em linguagem natural na definição dos conceitos no mapa conceitual, pois é a linguagem utilizada no dia a dia, facilita a compreensão dos conceitos e suas relações.

Os termos utilizados na composição da OntoAthena foram: *AcademicRecord*, *Activity*, *Certificate*, *ClassCourse*, *Competence*, *ContentTopic*, *Context*, *ContextHistories*, *Course*, *Evaluation*, *Learning*, *Performance*, *Service*, *Profile*, *Risk*, *Shift*, *StudyHabits*, *Tools*, *Topic*, *TypeDLProblems*, *User*, *VirtualEnvironment*. A língua inglesa foi utilizada porque permite uma maior visibilidade e reutilização da ontologia. Outros conceitos foram selecionados e utilizados nas definições de subclasses da OntoAthena.

5.7 Classes e hierarquias da OntoAthena

Para especificar a ontologia, utilizou-se a modelagem desenvolvida com o software *Protégé* versão desktop 5.5.0 e a linguagem OWL. O *Protégé* é um editor de ontologias *open*

source e framework para desenvolvimento de sistemas inteligentes, o qual foi desenvolvido e sendo mantido pelo *Stanford Center for Biomedical Informatics Research* (BMIR).

Protégé apresenta flexibilidade, pois possibilita a exportação do modelo ontológico gerado em formato RDF/RDFS, OWL, XML Schema. Assim, possibilitando a integração entre ferramentas durante o desenvolvimento, proporcionando condições de elaboração de ontologias dos mais diversos níveis de complexidades. O *Protégé* auxilia no processo de verificação da ontologia, garantindo a consistência do modelo ontológico.

É uma ferramenta extensível, onde suas funcionalidades podem ser estendidas com a utilização de *plugins* que torna o *Protégé* uma base flexível para prototipagem rápida e desenvolvimentos de aplicativos, também conta com apoio da comunidade de usuários acadêmicos, órgãos governamentais e corporativos, para construir soluções baseadas no conhecimento em várias áreas.

A versão *Protégé* para *desktop* apoia a criação e edição de uma ou mais ontologias em um único espaço de trabalho através de uma interface de usuário personalizável. Ferramentas de visualização, integradas por meio de *plugins*, permitem a navegação interativa nas relações da ontologia. Também oferece ferramenta para verificação de inconsistências, fusão de ontologias, consulta de dados via linguagem SPARQL e raciocínio utilizando máquinas de inferências (*Protégé*, 2019).

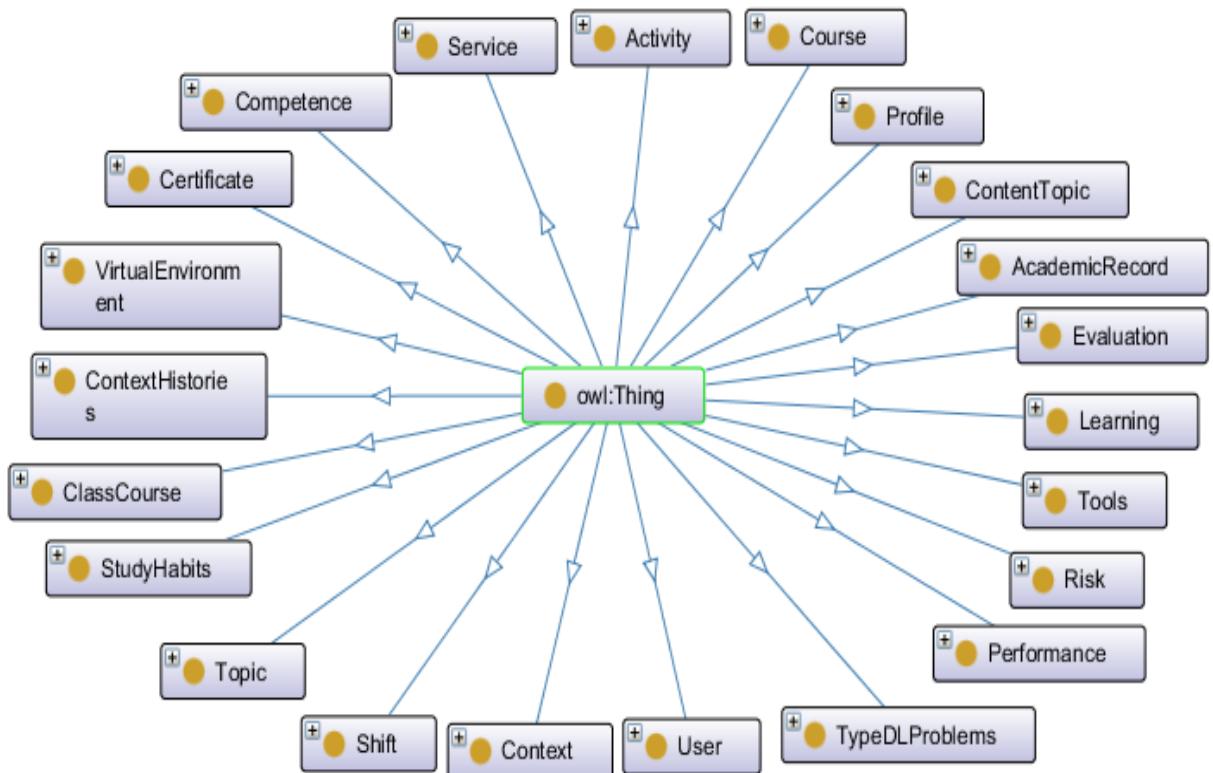
A Figura 21 mostra que as classes e suas relações representam um conjunto de conceitos relacionados ao domínio da OntoAthena, seja *AcademicRecord*, *Activity*, *Certificate*, *ClassCourse*, *Competence*, *ContentTopic*, *Context*, *ContextHistories*, *Course*, *Evaluation*, *Learning*, *Performance*, *Service*, *Profile*, *Risk*, *Shift*, *StudyHabits*, *Tools*, *Topic*, *TypeDLProblems*, *User*, *VirtualEnvironment*.

A OntoAthena está assim estruturada:

- a) classes e subclasses, que representa a taxonomia do domínio e abrange um conjunto de classes e sua respectiva hierarquia;
- b) propriedades, que podem ser de dois tipos, *Object Property* (qualificam ou relacionam as classes) e *Datatype Property* (representam atributos das classes);
- c) instâncias, que representam indivíduos das classes;

- d) restrições representam afirmações lógicas das quais outras afirmações podem ser inferidas;
 - e) consultas SPARQL, que realizam as consultas na ontologia.

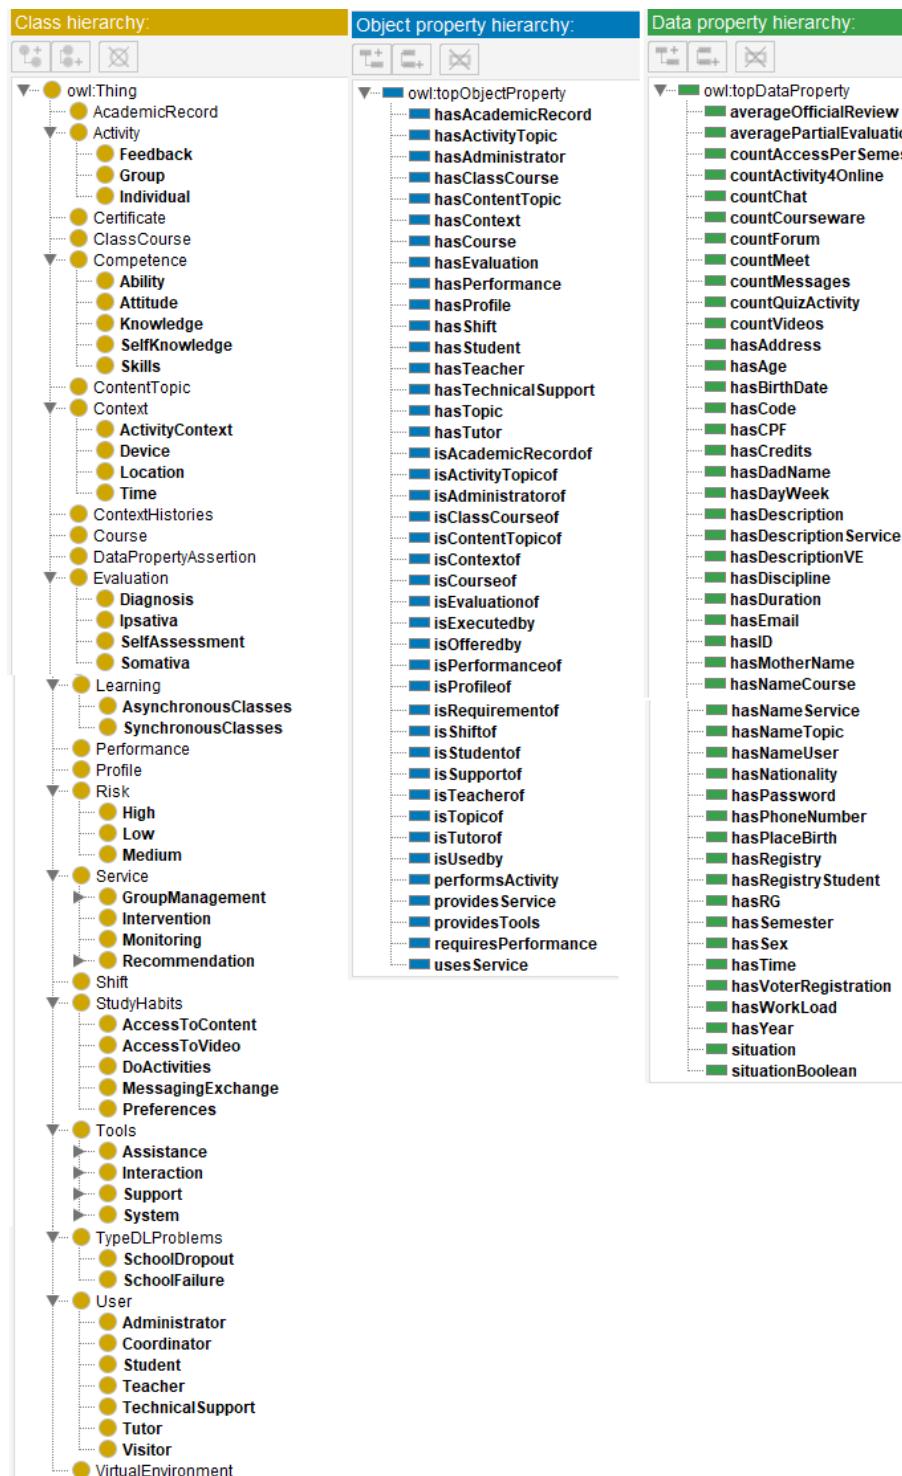
Figura 21: Classes da OntoAthena



Fonte: Elaborado pela autora.

A Figura 22 apresenta uma visão hierárquica das classes da ontologia - *class hierarchy* (amarelo), incluindo as subclasses. Os relacionamentos entre as classes estão destacados em azul (*object property*) e os atributos das classes destacados em verde (*data property*).

Figura 22: Hierarquia das classes



Fonte: Elaborado pela autora.

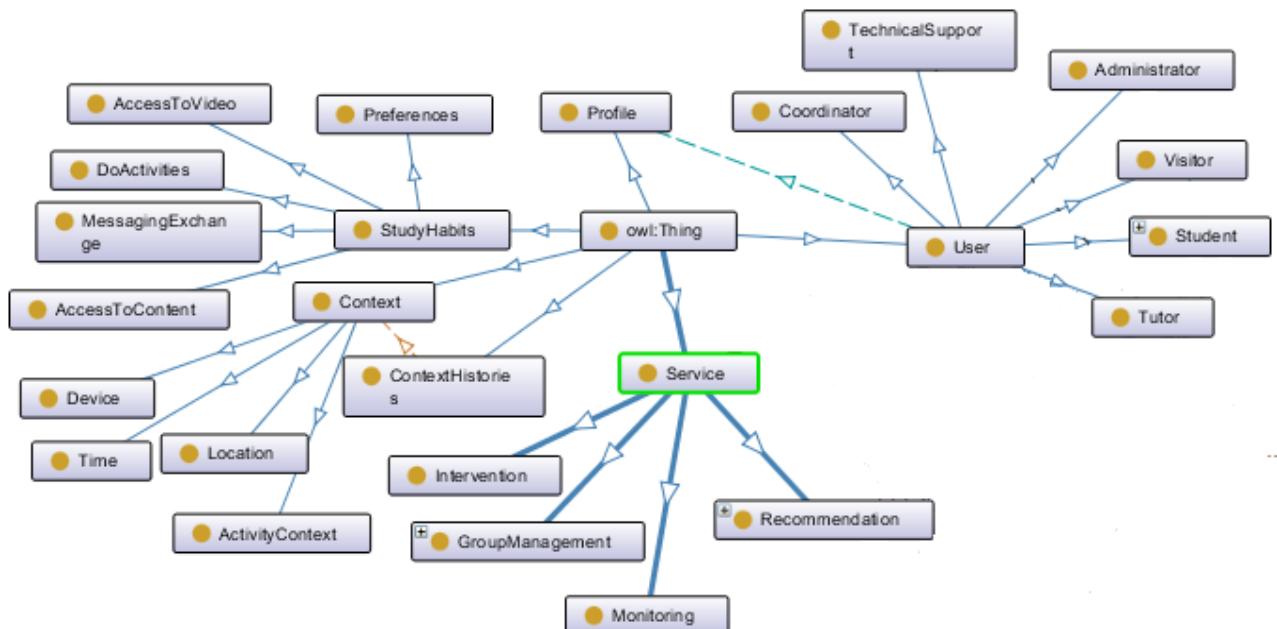
A seguir são apresentadas as descrições das principais classes da OntoAthena. Cada classe pode representar uma ou mais instâncias.

- *AcademicRecord* é composta pelos dados cadastrais e acadêmicos do aluno.
- *Activity* é composta pelas atividades presenciais ou *online* e avaliações.
- *Certificate* é composta pelo nome do aluno, nome do curso e titulação
- *ClassCourse* representa o código da turma dentro do ambiente virtual.
- *Competence* é composta por competências de aprendizagem como atitudes, aptidão, habilidades, conhecimento e autoconhecimento.
- *ContentTopic* é composta pelo código, nome, descrição e carga horária da disciplina.
- *Context* é composta por informações sobre localização, hábitos de estudos, dispositivos, atividades, avaliações, idioma, data, hora e tipo de conexão utilizada.
- *ContextHistories* é composta por um conjunto de contextos que representam as atividades realizadas no ambiente, registrados ao longo do tempo.
- *Course* é composta por nome do curso, código do curso, carga horária do curso, turno do curso e duração do curso.
- *Evaluation* é composta por nome da disciplina, código da disciplina, nome do professor, nome do aluno, nota do aluno.
- *Learning* é uma representação da aprendizagem no ambiente virtual.
- *Performance* é composta por ação, desempenho, funcionamento, atividade, comportamento, execução, exercício, prática.
- *Service*: comprehende diversos serviços inteligentes, tais como: formação de grupos, sistema de predição, sistema de aprendizagem, sistemas de recomendação, sistema de tomada de decisão, sistema de análise de dados.
- *Profile* inclui dados pessoais, acadêmicos e profissionais do usuário.
- *Risk* representa as classificações de abandono e reprovação (alto, médio e baixo).
- *Shift* refere a descrição do turno (matutino, vespertino, noturno).
- *StudyHabits* é composto por vídeos assistidos, acesso de conteúdo, avaliações realizadas, atividades entregues, preferências do aluno, tais como hora e tempo de acesso.

- *Tools* apresenta os tipos de interação que ocorrem no ambiente virtual de aprendizagem (assíncrona e síncrona).
- *Topic* é composta por nome e código da disciplina, código e nome do aluno, carga horária da disciplina, notas, semestre da disciplina, horário e local.
- *TypeDLProblems* composta por problemas que podem impactar no desenvolvimento do aluno tais como abandono e reaprovação.
- *User* representa a pessoa dentro de um ambiente de educação a distância, podendo ser um administrador do ambiente virtual, aluno, professor, tutor ou suporte técnico.
- *VirtualEnvironment* é o ambiente virtual que caracteriza o ensino a distância.

Os conceitos, suas propriedades e relacionamentos formam a base de qualquer ontologia, tem como objetivo definir a semântica de seus termos para construir os axiomas, que são utilizados para modelar sentenças verdadeiras. A figura 23 mostra a classe *Context*, *User*, *Profile*, *Service*, *StudyHabits*, suas subclasses e ramificações.

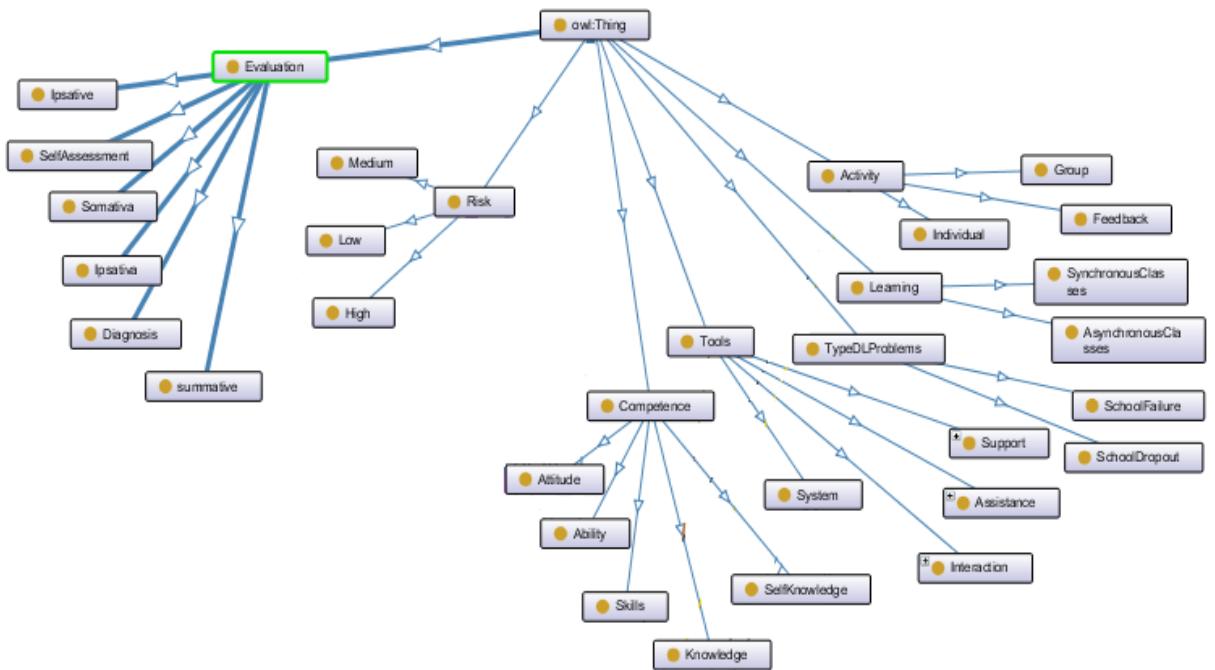
Figura 23: Classes *Context*, *ContextHistories*, *user*, *Profile*, *StudyHabits*, *service* e subclasses



Fonte: Elaborado pela autora.

Seguindo na definição das classes e subclasses, a figura 24 representa as classes *Competence*, *Evaluation*, *Risk*, *Learning*, *Tools*, *Activity*, *TypeDlProblems* e subclasses

Figura 24: Classes *Competence*, *Evaluation*, *Risk*, *Activity*, *Learning*, *Tools*, *TypeDlProblems* e subclasses



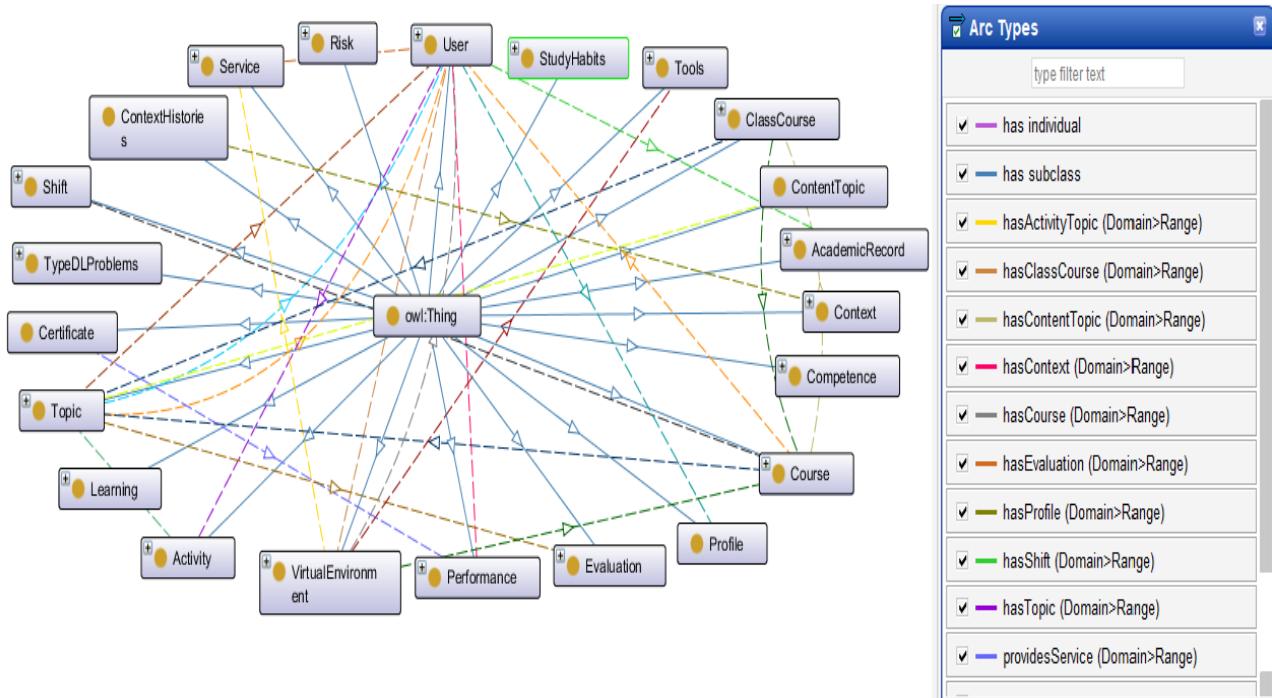
Fonte: Elaborado pela autora.

- A classe *Competence* está associada às Subclasses *Ability*, *Attitude*, *Knowledge*, *Skills*.
- *Ability*: é ter capacidade de utilizar os conhecimentos armazenados durante o desenvolvimento das aulas de forma prática e produtiva.
- *Attitude* refere-se ao desejo de realizar, é a motivação que impulsiona a colocar em prática as habilidades e conhecimentos.
- *Knowledge*: Reflete a habilidade de assimilar informações de forma significativa.
- *Skills*: Refere-se as aptidões, o método e a destreza aplicados por cada pessoa em uma tarefa específica. Todos formam um conjunto de termos que podem ser desenvolvidos durante a realização do curso.

- A Classe *Evaluation* está associada às Subclasses *Diagnosis*, *Ipsative*, *SelfAssessment* e *summative*. São avaliações que podem ser realizadas para verificar o nível de aprendizagem do aluno durante o curso.
- A classe *Risk* representa as situações que interferem na probabilidade de um aluno reprovar ou evadir do curso e possui as subclasses *High*, *Low* e *Medium*. As subclasses *Low* e *Medium* constituem dois fatores de risco que podem ser evitados através de ações que promovam intervenção, tais como ofertas de serviços inteligentes.
- A classe *Activity* refere-se às atividades desenvolvidas pelo usuário dentro do ambiente virtual, como por exemplo avaliações, interações nos fóruns, *chats*, *meet*, envio de mensagens, atividades avaliativas realizadas, materiais acessados. *Feedback*, *Group* e *Individual* são subclasses associadas à classe *Activity*.
- *AsynchronousClasses* e *SynchronousClasses* são subclasses da classe *Learning* e representa as ações *online* ou *offline* que podem ser realizadas no desenvolvimento das competências do aluno.
- A Classe *Tools* representa as ferramentas de apoio existentes dentro do ambiente virtual e está associada às subclasses *Assistence*, *Interaction*, *Support* e *System*. A Classe *TypeDIProblems* está associada às subclasses *SchoolDropout* e *SchoolFailure*.

5.8 Definir as propriedades das classes

Nesta etapa foram definidas as propriedades das classes usando o *Protégé 5.5.0*. A Tabela 13 descreve as *properties* incluindo: *domains*, ou seja, o domínio da propriedade; *ranges*, ou seja, que classe pode ser classificada para aquele domínio e *inverse* (quando aplicável). A Figura 25 apresenta as principais classes da OntoAthena e seus relacionamentos.

Figura 25: Classes da OntoAthena e seus relacionamentos

Fonte: Elaborado pela autora.

Os relacionamentos definidos na Tabela 13 e cadastrados no *Protégé* conforme constam na Figura 25 (em azul) podem ser visualizados através de uma representação gráfica gerada pelo *OntoGraf*, um plugin instalado e disponível na versão *default* do *Protégé*. À direita da Figura 25 é possível visualizar diferentes tipos de relacionamentos entre as classes e as subclasses existentes, instâncias criadas e *object property* (*domain*, *range*). Cada relacionamento definido entre as classes é representado por uma cor.

Tabela 13: Lista de propriedades da OntoAthena

<i>OntoAthena (properties)</i>	<i>Domains</i>	<i>Ranges</i>	<i>Inverse</i>
<i>hasAcademicRecord</i>	<i>Student</i>	<i>AcademicRecord</i>	<i>isAcademicRecordof</i>
<i>hasActivityTopic</i>	<i>Topic</i>	<i>Activity i</i>	<i>sActivityTopicof</i>
<i>hasAdministrator</i>	<i>VirtualEnvironment</i>	<i>Administrator</i>	<i>isAdministratorof</i>
<i>hasClassCourse</i>	<i>Course</i>	<i>ClassCourse</i>	<i>isClassCourseof</i>
<i>hasContentTopic</i>	<i>Topic</i>	<i>ContentTopic</i>	<i>isContentTopicof</i>
<i>hasContext</i>	<i>ContextHistories</i>	<i>Context</i>	<i>isContextof</i>
<i>hasCourse</i>	<i>VirtualEnvironment/ClassCourse</i>	<i>Course</i>	<i>isCourseof</i>

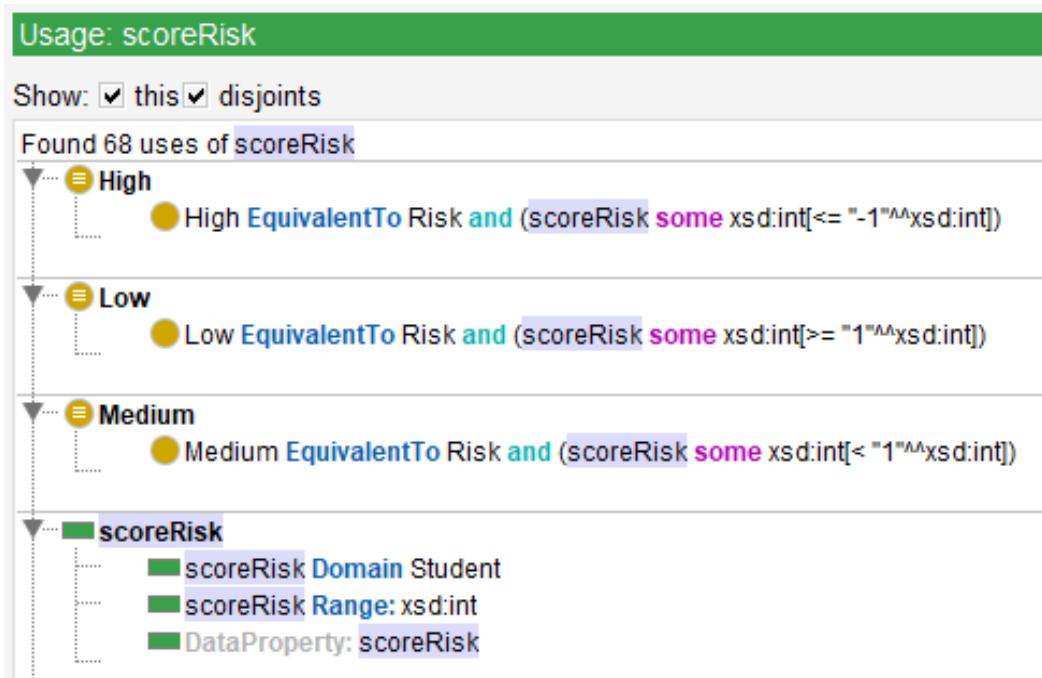
<i>OntoAthena (properties)</i>	<i>Domains</i>	<i>Ranges</i>	<i>Inverse</i>
<i>hasEvaluation</i>	<i>Topic</i>	<i>Evaluation</i>	<i>isEvaluationof</i>
<i>hasPerformance</i>	<i>Student</i>	<i>Performance</i>	<i>isPerformanceof</i>
<i>hasProfile</i>	<i>User</i>	<i>Profile</i>	<i>isProfileof</i>
<i>hasShift</i>	<i>Course</i>	<i>Shift</i>	<i>isShiftof</i>
<i>hasStudent</i>	<i>Course / Topic</i>	<i>Student</i>	<i>isStudentof</i>
<i>hasTeacher</i>	<i>Topic</i>	<i>Teacher</i>	<i>isTeacher</i>
<i>hasTechnicalSupport</i>	<i>VirtualEnvironment</i>	<i>TechnicalSupport</i>	<i>isSupportof</i>
<i>hasTopic</i>	<i>Course / ClassCourse</i>	<i>Topic</i>	<i>isTopicof</i>
<i>hasTutor</i>	<i>Topic</i>	<i>Tutor</i>	<i>isTutorof</i>
<i>performsActivity</i>	<i>Student</i>	<i>Activity</i>	<i>isExdcutedby</i>
<i>providesService</i>	<i>VirtualEnvironment</i>	<i>Service i</i>	<i>sOfferedby</i>
<i>providesTools</i>	<i>VirtualEnvironment</i>	<i>Tools</i>	<i>isOfferedby</i>
<i>requiresPerformance</i>	<i>Certificate</i>	<i>Performance</i>	<i>isRequirementof</i>
<i>usesService</i>	<i>User</i>	<i>Service</i>	<i>isUsedby</i>

Fonte: Elaborado pela autora.

5.9 Definir as regras (restrições de propriedades)

Na OntoAthena foram definidas regras de equivalência para a classe *Risk*. Uma vez que as questões de competência QC1, QC2, QC3, QC4 definidas na Seção 5.4 referem-se à probabilidade de aprovação ou evasão do aluno nos cursos EaD, foram criadas expressões lógicas para responder estas quatro QCs. Essas expressões lógicas descrevem o axioma de equivalência para (≤ -1) *High*, (≥ 1) *Low* e (< 1) *Medium*.

A Figura 26 apresenta as três expressões lógicas criadas no axioma de equivalência para *low*, *medium* e *high*. A primeira expressão lógica na figura pode ser lida da seguinte forma “Se o escore de risco para reprovação ou evasão for igual ou menor que -1, o nível de risco é classificado como *High*. A segunda expressão lógica como: “Se o escore de risco for maior ou igual a 1, o nível de risco é classificado como *Low*. E a terceira expressão como: “Se o escore de risco for menor que 1 o nível de risco é classificado como *Medium*. As expressões foram criadas e associadas à classe *Risk*.

Figura 26: Expressões lógicas

Fonte: Elaborada pela autora.

Para fins de avaliação, foram criadas 14 regras. Essas regras foram criadas através de SQWRL e permitem inferência de conteúdo considerando os principais fatores de risco para evasão e reprovação. As regras contabilizam os contextos dos alunos e retornam em qual situação de risco os alunos se encontram, ou seja, se o risco de reprovação ou evasão é médio, alto ou baixo. Essas regras estão representadas na tabela 14.

Tabela 14: Regras SQWRL para inferência de risco de reprovação ou evasão

Nome	Regras
S1	$swrlb:lessThan(?v, 20) \text{ countAccessPerSemester}(?u, ?v) -> valCountAccessPerSemester(?u, -1)$
S2	$swrlb:lessThan(?v, 30) swrlb : greaterThan(?v, 19) \text{ countAccessPerSemester}(?u, ?v) -> valCountAccessPerSemester(?u, 0)$
S3	$cswrlb:greaterThan(?v, 29) \text{ countAccessPerSemester}(?u, ?v) -> valCountAccessPerSemester(?u, 1)$
S4	$\text{countForum}(?u, ?v) swrlb : lessThan(?v, 6) -> valCountForum(?u, -1)$
S5	$\text{countForum}(?u, ?v) swrlb : lessThan(?v, 7) swrlb:greaterThan(?v, 5) -> valCountForum(?u, 0)$

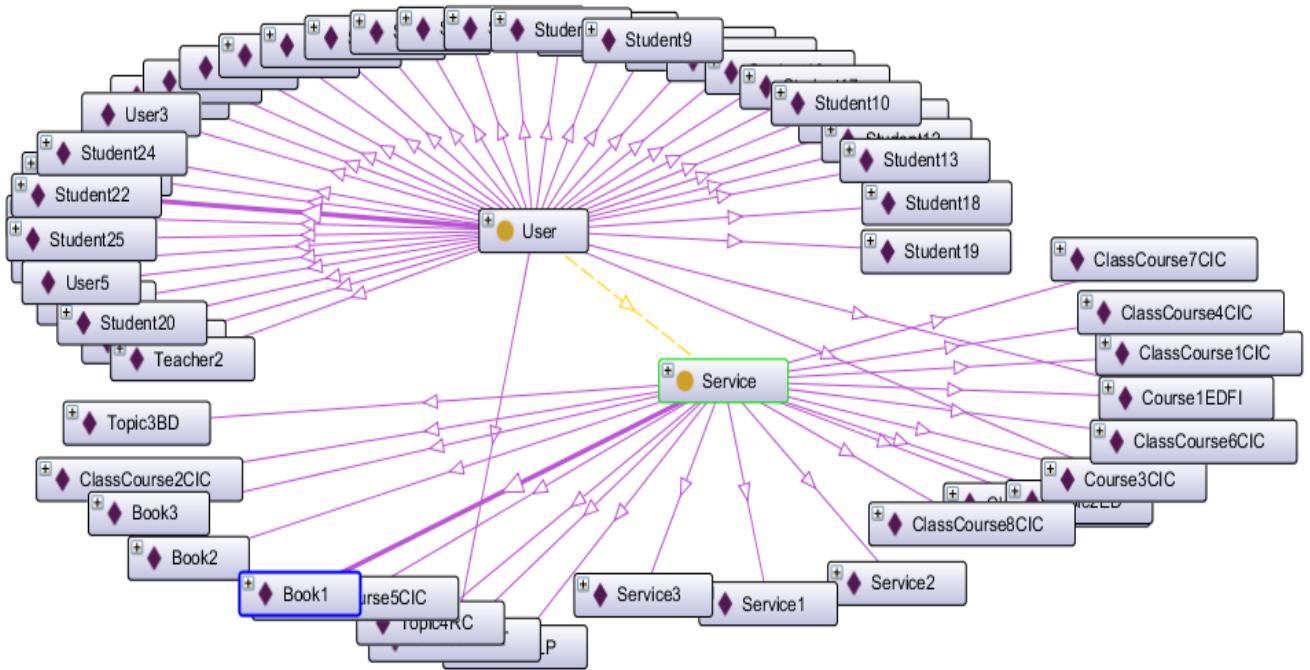
Nome	Regras
S6	<i>countForum(?u, ?v) swrlb : greaterThan(?v, 7) -> valCountForum(?u, 1)</i>
S7	<i>swrlb:lessThan(?v, 2) countActivity4Online(?u, ?v) -> valCountActivity4Online(?u, -1)</i>
S8	<i>cswrlb:greaterThan(?v, 1) swrlb : lessThan(?v, 4) countActivity4Online(?u, ?v) -> valCountActivity4Online(?u, 0)</i>
S9	<i>countActivity4Online(?u, ?v) swrlb : greaterThan(?v, 3) -> valCountActivity4Online(?u, 1)</i>
S10	<i>countActivity(?u, ?v) swrlb : lessThan(?v, 10) -> valCountActivity(?u, -1)</i>
S11	<i>swrlb:lessThan(?v, 12) swrlb : greaterThan(?v, 9) countActivity(?u, ?v) -> valCountActivity(?u, 0)</i>
S12	<i>ontology:countActivity(?u, ?v) swrlb : greaterThan(?v, 11) -> ontology:valCountActivity(?u, 1)</i>
S13	<i>Student(?u) valCountForum(?u, ?b) swrlb:add(?w, ?a, ?b, ?c, ?d) valCountActivity4Online(?u, ?c) valCountActivity(?u, ?d) valCountAccessPerSemester(?u, ?a) -> scoreRisk(?u, ?w)</i>
S14	<i>swrlb:add(?score, ?a, ?b, ?c) valCountForum(?student, ?b) Student(?student) valCountActivity4Online(?student, ?c) valCountAccessPerSemester(?student, ?a) name(?student, ?identify) -> sqwrl : select(?student, ?identify, ?score)</i>

Fonte: Elaborado pela autora.

5.10 Criar as instâncias

Na etapa final, conduziu-se a criação de instâncias, que correspondem aos dados concretos da base de conhecimento, com o intuito de avaliar a capacidade de inferência e responder às consultas relacionadas às questões de competência estabelecidas.

O termo “instâncias” refere-se ao conceito de *Individuals* no software *Protégé*. Em outras palavras, uma instância é a materialização de uma classe. Cada instância representa um indivíduo único dentro de uma hierarquia. Foram criadas instâncias para representar as classes *user* e *service* no *Protégé*, as quais podem ser visualizadas na Figura 27.

Figura 27: Exemplo de Instâncias

Fonte: Elaborada pela autora.

A Tabela 15 apresenta métricas da OntoAthena extraídas do *Protégé*. A métrica Axiomas representa a quantidade de expressões lógicas que definem um conceito. Total de classes e total de subclasses representam a quantidade de elementos da ontologia. A métrica total de propriedades de objetos indica as relações existentes entre dois indivíduos (instâncias). E, por sua vez, a métrica total de propriedades de dados indica a quantidade de tipos de dados literais, que podem ser um número, data ou texto. As instâncias criadas são representadas pela métrica total de indivíduos.

Tabela 15: Métricas da OntoAthena

Métricas	Valores
Axiomas	1161
Axiomas lógicos	907
Declaração de axiomas	243
Total de classes e subclasses	93
Total de propriedades de objetos	41
Total de propriedades de dados	52
Total de indivíduos (instâncias)	56

Fonte: Elaborada pela autora.

5.11 Avaliação da Ontologia

A avaliação da OntoAthena foi realizada através das seguintes etapas: 1) Inserção no Protégé dos dados reais anonimizados⁵ de uma turma de Tecnologia em Análise e Desenvolvimento de Dados, 2) execução do motor de inferência e 3) consulta SPARQL. A base continha dados de 25 alunos no período de 2022/1 a 2023/2 e foram utilizados dados do primeiro semestre para popular as instâncias da classe estudantes. Os dados incluíam informações de acesso ao ambiente virtual, participação nos fóruns, participação em chat, reuniões virtuais, envio de mensagens, avaliações e atividades.

Com os dados dos 25 alunos disponíveis foi calculado um valor de escore de risco para Alto, Médio e Baixo que foram utilizados nos contextos desses alunos. Se o estudante tiver um escore de risco igual ou menor que -1, ele possui um alto risco de reprovar ou evadir do curso, se o escore de risco for menor que 1, o risco é médio e se for maior ou igual a 1, o escore de risco é baixo.

O cálculo do escore é determinado conforme as diretrizes estabelecidas na Tabela 14, levando em consideração critérios como acesso ao ambiente virtual, participação em fóruns, entrega de atividades, presença em *chats* e reuniões virtuais, envio de mensagens e desempenho em avaliações realizadas.

Após a criação das instâncias, a OntoAthena foi avaliada por meio de um processo de raciocínio automático utilizando o plugin *Pellet* versão 2.2.0, integrado ao *Protégé*. O *Pellet*, reconhecido como um motor de inferência, foi empregado para identificar possíveis inconsistências entre as classes declaradas na ontologia. Essas inconsistências englobam a organização das classes, incluindo subclasses e classes disjuntas, bem como os relacionamentos entre elas, como os domínios e intervalos, os tipos de atributos atribuídos aos objetos (propriedades de dados) e as regras de equivalência definidas na ontologia.

⁵ Essa parte do código trata da importação de códigos de terceiros ou de outras funções dentro do projeto:

Após a habilitação do *reasoner Pellet* para execução, este também efetua inferências com base nas regras de equivalência estipuladas na Seção 5.9. As expressões lógicas descritas em cada uma dessas regras foram processadas pelo *reasoner*. Essas regras podem ser visualizadas na Figura 28.

Figura 28: Regras inferidas

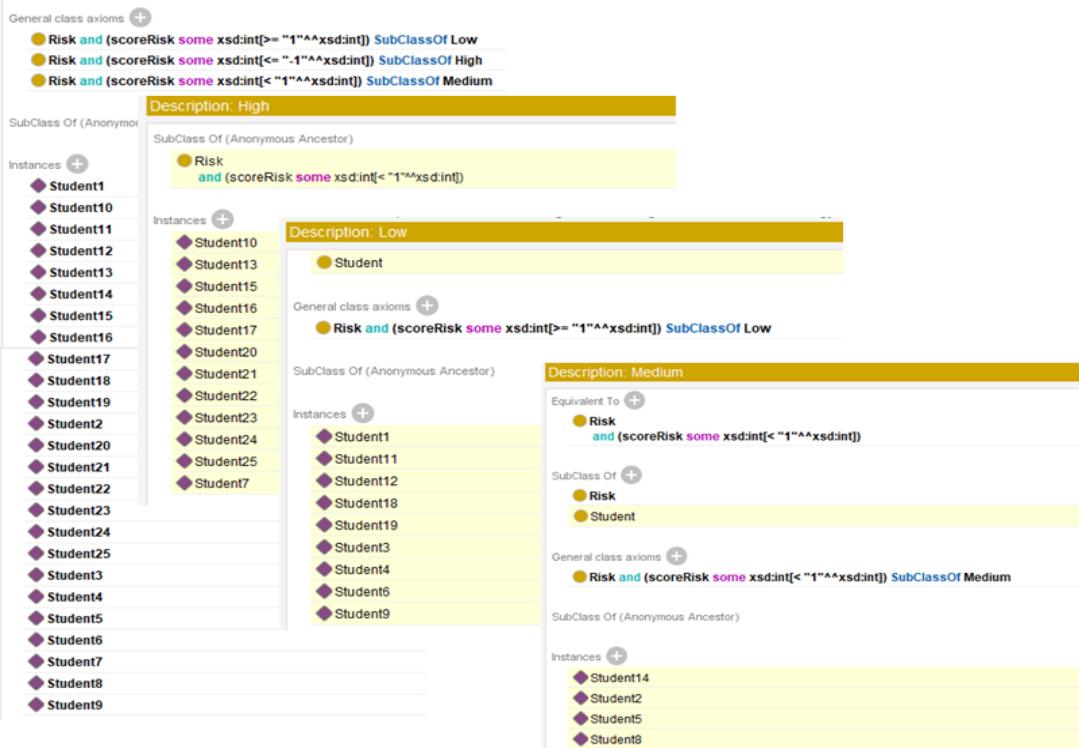
Name		Rule
<input checked="" type="checkbox"/>	S1	countAccessPerSemester(?u, ?v) ^ swrlb:lessThan(?v, 20) -> ontology:valCountAccessPerSemester(?u, -1)
<input checked="" type="checkbox"/>	S10	ontology:countActivity(?u, ?v) ^ swrlb:lessThan(?v, 10) -> ontology:valCountActivity(?u, -1)
<input checked="" type="checkbox"/>	S11	ontology:countActivity(?u, ?v) ^ swrlb:greaterThan(?v, 9) ^ swrlb:lessThan(?v, 12) -> ontology:valCountActivity(?u, 0)
<input checked="" type="checkbox"/>	S12	ontology:countActivity(?u, ?v) ^ swrlb:greaterThan(?v, 11) -> ontology:valCountActivity(?u, 1)
<input checked="" type="checkbox"/>	S13	Student(?u) ^ ontology:valCountAccessPerSemester(?u, ?a) ^ ontology:valCountForum(?u, ?b) ^ ontology:valCountActivity4Online(?u, ?c) ^ ontology:valCountActivity(...
<input type="checkbox"/>	S14	Student(?student) ^ ontology:name(?student, ?identify) ^ ontology:valCountAccessPerSemester(?student, ?a) ^ ontology:valCountForum(?student, ?b) ^ ontology:val...
<input checked="" type="checkbox"/>	S2	countAccessPerSemester(?u, ?v) ^ swrlb:greaterThan(?v, 19) ^ swrlb:lessThan(?v, 30) -> ontology:valCountAccessPerSemester(?u, 0)
<input checked="" type="checkbox"/>	S3	countAccessPerSemester(?u, ?v) ^ swrlb:greaterThan(?v, 29) -> ontology:valCountAccessPerSemester(?u, 0)
<input checked="" type="checkbox"/>	S4	countForum(?u, ?v) ^ swrlb:lessThan(?v, 6) -> ontology:valCountForum(?u, -1)
<input checked="" type="checkbox"/>	S5	countForum(?u, ?v) ^ swrlb:greaterThan(?v, 5) ^ swrlb:lessThan(?v, 7) -> ontology:valCountForum(?u, 0)
<input checked="" type="checkbox"/>	S6	countForum(?u, ?v) ^ swrlb:greaterThan(?v, 7) -> ontology:valCountForum(?u, 1)
<input checked="" type="checkbox"/>	S7	countActivity4Online(?u, ?v) ^ swrlb:lessThan(?v, 2) -> ontology:valCountActivity4Online(?u, -1)
<input checked="" type="checkbox"/>	S8	countActivity4Online(?u, ?v) ^ swrlb:greaterThan(?v, 1) ^ swrlb:lessThan(?v, 4) -> ontology:valCountActivity4Online(?u, 0)
<input checked="" type="checkbox"/>	S9	countActivity4Online(?u, ?v) ^ swrlb:greaterThan(?v, 3) -> ontology:valCountActivity4Online(?u, 1)

Control	Rules	Asserted Axioms	Inferred Axioms	OWL 2 RL
			A	
<pre> Student16 name "Aluno16"^^rdfs:Literal Student15 Type User Email SubClassOf Tools Student17 countActivity "8"^^xsd:int Class: Feedback ClassCourse6CIC hasCode "CIC61" Text SubClassOf Service Student(?student), name(?student, ?identify), valCountAccessPerSemester(?student, ?a), valCountForum(?student, ?b), valCountActivity4Online(?student, ?c), add(?score, ?a, ?b, ?c) -> select(?student, ?identify, ?score) Class: Profile Book1 Type VirtualEnvironment hasClassCourse Domain Course Class: Recommendation Lesson SubClassOf Tools Individual: Student7 ObjectProperty: hasTutor </pre>				

Fonte: Elaborado pela autora.

Após a análise realizada pelo *reasoner*, os seguintes resultados foram obtidos. Na Figura 29, são apresentados os 25 alunos associados à classe *Risk*, onde, após a inferência, foram identificados doze (12) alunos com risco alto de reprovação ou evasão, enquanto quatro (4) apresentaram risco moderado, e nove (9) estão associados a um risco baixo.

Figura 29: Resultado sobre Evasão ou Reprovação na OntoAthena



Fonte: Elaborado pela autora.

A figura 30 mostra o escore de risco para cada aluno depois da realização da inferência. Se o escore for igual ou menor que -1, o aluno é identificado com risco alto, com escore igual ou maior que 1 o risco é baixo e se o escore for menor que 1 o risco é médio.

Figura 30: Resultado da inferência - Escore de risco

Student1	Student1 scoreRisk 3	Student17	Student17 scoreRisk -2	Student25	Student25 scoreRisk -2
Student10	Student10 scoreRisk -2	Student18	Student18 scoreRisk 2	Student3	Student3 scoreRisk 2
Student11	Student11 scoreRisk 3	Student19	Student19 scoreRisk 3	Student4	Student4 scoreRisk 3
Student12	Student12 scoreRisk 3	Student2	Student2 scoreRisk 0	Student5	Student5 scoreRisk 0
Student13	Student13 scoreRisk -4	Student20	Student20 scoreRisk -2	Student6	Student6 scoreRisk 3
Student14	Student14 scoreRisk 0	Student21	Student21 scoreRisk -4	Student7	Student7 scoreRisk -1
Student15	Student15 scoreRisk -4	Student22	Student22 scoreRisk -3	Student8	Student8 scoreRisk 0
Student16	Student16 scoreRisk -4	Student23	Student23 scoreRisk -1	Student9	Student9 scoreRisk 2
		Student24	Student24 scoreRisk -2		

Fonte: Elaborado pela autora.

Depois de testada, a ontologia com o processo de raciocínio automático, é viável realizar consultas utilizando o SPARQL, que é similar ao SQL. Consequentemente, foram elaboradas consultas para exibir os dados inseridos na OntoAthena por meio das instâncias.

As consultas efetuadas foram fundamentadas nos históricos de contextos de 25 alunos. Quatro consultas foram criadas utilizando critérios definidos com a adição da função FILTER e realizadas por meio da SPARQL *Query*. O objetivo foi investigar as seguintes questões de competências:

5.11.1 QC1: Qual aluno tem alto risco de reprovar ou abandonar o curso?

A figura 31 apresenta a consulta da questão de competência "QC1". Todas as consultas foram editadas e executadas no *Protégé* através do SPARQL *Query*. Após a execução da consulta, conforme ilustrado na Figura 32, o resultado obtido foi a identificação de doze (12) alunos com alto risco de reprovação ou evasão. A consulta foi conduzida de acordo com os critérios estabelecidos na consulta (Figura 31), os quais são detalhados nas colunas da Figura 32.

Figura 31: Consulta SPARQL para alto risco de reprovação ou evasão

```
PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>
PREFIX ex: <http://www.semanticweb.org/andre/ontologies/2022/3/untitled-ontology-92#>

SELECT ?Student ?Registro ?Nome ?Risco ?ValQtdeAcessoSem ?ValQtdeAtiv
?ValQtdeAtivOnline ?ValQtdeForum ?QtdeAcessoSem ?QtdeAtiv ?QtdeAtivOnline ?QtdeForum
WHERE {
?Student ex:hasRegistryStudent ?Registro .
?Student ex:name ?Nome .
?Student ex:scoreRisk ?Risco .
?Student ex:valCountAccessPerSemester ?ValQtdeAcessoSem .
?Student ex:valCountActivity ?ValQtdeAtiv .
?Student ex:valCountActivity4Online ?ValQtdeAtivOnline .
?Student ex:valCountForum ?ValQtdeForum .
?Student ex:countAccessPerSemester ?QtdeAcessoSem .
?Student ex:countActivity ?QtdeAtiv .
?Student ex:countActivity4Online ?QtdeAtivOnline .
?Student ex:countForum ?QtdeForum .
FILTER (?Risco <= -1)
} ORDER BY ?Risco
```

Fonte: Elaborado pela autora.

Na primeira coluna (*Student*) são listadas as instâncias (indivíduos); a segunda coluna (*Registro*) mostra os registros de cada aluno; na terceira coluna (*Nome*) são apresentados os nomes dos alunos (ex: aluno1, aluno2...); na quarta coluna (*Risco*) é exibido o valor do escore de risco total para nível alto (ex: -4, -3 ...); na quinta coluna (*valCountAccessPerSemester*) é apresentado o valor do escore para acesso ao ambiente virtual por semestre; na sexta coluna (*valCountActivity*) é mostrado o valor do escore para atividades realizadas, como questionários e avaliações; na sétima coluna (*valCountActivity4Online*) é indicado o valor do escore para participação em atividades *online*, como envio de mensagens e participação em reuniões virtuais; na oitava coluna (*valCountForum*) é apresentado o valor do escore para participação em fóruns; e as demais colunas (QtdeAcessoSemestre, QtdeAtividades, QtdeAtividadesOnline, QtdeForum) exibem a quantidade de acessos por semestre, quantidade de atividades enviadas e a quantidade de participações nos fóruns.

Figura 32: Resultado da consulta SPARQL alto risco de reprovação ou evasão

Student	Registro	Nome	Risco	ValQtdeAcessoSem	ValQtdeAtiv	ValQtdeAtivOnline	ValQtdeForum	QtdeAcessoSem	QtdeAtiv	QtdeAtivOnline	QtdeForum
Student13	"2013"	<http://www."Aluno13">	"W-4"	<http://www."-1">	<http://www.w3."-1">	<http://www.w2."-1">	<http://www.w3."-1">	"9"	<http://www.w3.c."0">	<http://www.w3.or."5">	<http://www.w3.or."0">
Student15	"2015"	<http://www."Aluno15">	"W-4"	<http://www."-1">	<http://www.w3."-1">	<http://www.w2."-1">	<http://www.w3."-1">	"9"	<http://www.w3.c."0">	<http://www.w3.or."4">	<http://www.w3.or."0">
Student21	"2021"	<http://www."Aluno21">	"W-4"	<http://www."-1">	<http://www.w3."-1">	<http://www.w2."-1">	<http://www.w3."-1">	"5"	<http://www.w3.c."0">	<http://www.w3.or."0">	<http://www.w3.or."0">
Student16	"2016"	<http://www."Aluno16">	"W-4"	<http://www."-1">	<http://www.w3."-1">	<http://www.w2."-1">	<http://www.w3."-1">	"15"	<http://www.w3.c."0">	<http://www.w3.or."3">	<http://www.w3.or."0">
Student22	"2022"	<http://www."Aluno22">	"W-3"	<http://www."-1">	<http://www.w3."-1">	<http://www.w2.c."0">	<http://www.w3.c."0">	"15"	<http://www.w3.c."4">	<http://www.w3.c."2">	<http://www.w3.or."0">
Student17	"2017"	<http://www."Aluno17">	"W-2"	<http://www."1">	<http://www.w3.c."1">	<http://www.w2."-1">	<http://www.w3.c."1">	"56"	<http://www.w3.c."8">	<http://www.w3.c."0">	<http://www.w3.or."4">
Student24	"2024"	<http://www."Aluno24">	"W-2"	<http://www."1">	<http://www.w3.c."1">	<http://www.w2."-1">	<http://www.w3.c."1">	"30"	<http://www.w3.c."5">	<http://www.w3.c."0">	<http://www.w3.or."2">
Student25	"2025"	<http://www."Aluno025">	"W-2"	<http://www."0">	<http://www.w3.c."-1">	<http://www.w2."-1">	<http://www.w3.c."-1">	"25"	<http://www.w3.c."5">	<http://www.w3.c."1">	<http://www.w3.or."0">
Student10	"2010"	<http://www."Aluno10">	"W-2"	<http://www."0">	<http://www.w3.c."-1">	<http://www.w2."-1">	<http://www.w3.c."-1">	"0"	<http://www.w3.c."20">	<http://www.w3.c."6">	<http://www.w3.or."0">
Student20	"2020"	<http://www."Aluno20">	"W-2"	<http://www."1">	<http://www.w3.c."-1">	<http://www.w2."-1">	<http://www.w3.c."-1">	"52"	<http://www.w3.c."6">	<http://www.w3.c."3">	<http://www.w3.or."0">
Student23	"2023"	<http://www."Aluno23">	"W-1"	<http://www."1">	<http://www.w3.c."-1">	<http://www.w2."0">	<http://www.w3.c."-1">	"65"	<http://www.w3.c."2">	<http://www.w3.or."4">	<http://www.w3.or."0">
Student7	"2007"	<http://www."Aluno07">	"W-1"	<http://www."1">	<http://www.w3.c."-1">	<http://www.w2."-1">	<http://www.w3.c."-1">	"35"	<http://www.w3.c."6">	<http://www.w3.c."0">	<http://www.w3.or."6">

Fonte: Elaborado pela autora.

5.11.2 QC2: Qual aluno tem risco moderado de abandonar o curso?

A figura 33 apresenta a consulta realizada para verificação de alunos com risco moderado de abandonar o curso. A figura apresenta os critérios definidos com a adição da função FILTER.

Figura 33: Consulta SPARQL para risco moderado de reprovação ou evasão

```

PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>
PREFIX ex: <http://www.semanticweb.org/andre/ontologies/2022/3/untitled-ontology-92#>

SELECT ?Student ?Registro ?Nome ?Risco ?ValQtdeAcessoSem ?ValQtdeAtiv ?ValQtdeAtivOnline
?ValQtdeForum ?QtdeAcessoSem ?QtdeAtiv ?QtdeAtivOnline ?QtdeForum
WHERE {
?Student ex:hasRegistryStudent ?Registro .
?Student ex:name ?Nome .
?Student ex:scoreRisk ?Risco .
?Student ex:valCountAccessPerSemester ?ValQtdeAcessoSem .
?Student ex:valCountActivity ?ValQtdeAtiv .
?Student ex:valCountActivity40nline ?ValQtdeAtivOnline .
?Student ex:valCountForum ?ValQtdeForum .
?Student ex:countAccessPerSemester ?QtdeAcessoSem .
?Student ex:countActivity ?QtdeAtiv .
?Student ex:countActivity40nline ?QtdeAtivOnline .
?Student ex:countForum ?QtdeForum .
FILTER (?Risco > -1 && ?Risco < 1)
} ORDER BY ?Risco

```

Fonte: Elaborado pela autora.

A Figura 34 exibe quatro alunos que necessitam de acompanhamento para evitar a reprovação ou a desistência do curso, pois estão identificados com um risco moderado. Além da identificação dos alunos, apresentada nas três primeiras colunas, a figura mostra os valores dos escores de risco para os acessos semestrais, envio de atividades e participação nos fóruns, os quais, em conjunto, determinam o escore total para o risco moderado de reprovação ou evasão (coluna Risco).

Figura 34: Resultado da consulta SPARQL para risco moderado de reprovação ou evasão

Fonte: Elaborada pela autora.

5.11.3 QC3: Qual aluno tem baixo risco de reprovar ou abandonar o curso?

Também foram conduzidas consultas para identificar quais alunos têm probabilidade baixa de reprovar ou abandonar o curso. A consulta correspondente está representada na Figura 35.

Figura 35: Consulta SPARQL para baixo risco de reprovação ou evasão

```

PREFIX rdf: <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>
PREFIX ex: <http://www.semanticweb.org/andre/ontologies/2022/3/untilted-ontology-92#>

SELECT ?Student ?Registro ?Nome ?Risco ?ValQtdeAcessoSem
?ValQtdeAtiv ?ValQtdeAtivOnline ?ValQtdeForum
?QtdeAcessoSem ?QtdeAtiv ?QtdeAtivOnline ?QtdeForum
WHERE {
?Student ex:hasRegistryStudent ?Registro .
?Student ex:name ?Nome .
?Student ex:scoreRisk ?Risco .
?Student ex:valCountAccessPerSemester ?ValQtdeAcessoSem .
?Student ex:valCountActivity ?ValQtdeAtiv .
?Student ex:valCountActivity40nline ?ValQtdeAtivOnline .
?Student ex:valCountForum ?ValQtdeForum .
?Student ex:countAccessPerSemester ?QtdeAcessoSem .
?Student ex:countActivity ?QtdeAtiv .
?Student ex:countActivity40nline ?QtdeAtivOnline .
?Student ex:countForum ?QtdeForum .
FILTER (?Risco >= 1)
} ORDER BY ?Risco

```

Fonte: Elaborado pela autora.

Após a realização da consulta, nove alunos foram classificados com baixo risco de abandono, como evidenciado na Figura 36.

Figura 36: Resultado da consulta SPARQL para baixo risco de reprovação ou evasão

Student	Registro	Nome	Risco	ValQtdeAcessoSem	ValQtdeAtiv	ValQtdeAtivOnline	ValQtdeForum	QtdeAcessoSem	QtdeAtiv	QtdeAtivOnline	QtdeForum
Student18	"2018"^^xsd:int	"Aluno18"	1	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int
Student3	"2003"^^xsd:int	"Aluno3"	1	"2"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int
Student9	"2009"^^xsd:int	"Aluno9"	1	"2"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int
Student4	"2004"^^xsd:int	"Aluno4"	1	"3"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int
Student6	"2006"^^xsd:int	"Aluno6"	1	"3"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int
Student11	"2011"^^xsd:int	"Aluno11"	1	"3"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int
Student1	"2001"^^xsd:int	"Aluno1"	1	"3"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int
Student19	"2019"^^xsd:int	"Aluno19"	1	"3"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int
Student12	"2012"^^xsd:int	"Aluno12"	1	"3"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int	"1"^^xsd:int

Fonte: Elaborado pela autora.

As primeiras três colunas da Figura 36 exibem dados sobre os alunos. Nas demais colunas, são apresentados os valores dos escores e as quantidades referentes ao acesso semestral, envio de atividades e participação nos fóruns. A soma desses critérios determina o valor do escore total apresentado na coluna 4.

5.11.4 QC4: Quais são os hábitos de estudos ou padrão de comportamento do aluno que abandona o curso?

A consulta para hábitos de estudos ou padrão de comportamento de aluno é apresentada na figura 37. Para realizar a consulta, foram utilizados critérios como entrega de atividades como questionários, avaliações parciais e oficiais, quantidade de participação em atividades *online* e participação em fóruns de discussões.

Figura 37: Consulta SPARQL para hábitos de estudos ou comportamento

```
PREFIX owl: <http://www.w3.org/2002/07/owl#>
PREFIX rdfs: <http://www.w3.org/2000/01/rdf-schema#>
PREFIX xsd: <http://www.w3.org/2001/XMLSchema#>
PREFIX ex: <http://www.semanticweb.org/andre/ontologies/2022/3/untitled-ontology-92#>

SELECT ?Student ?Registro ?Nome ?Risco ?QtdeAtiv ?QtdeAtivOnline ?QtdeForum
WHERE {
?Student ex:hasRegistryStudent ?Registro .
?Student ex:name ?Nome .
?Student ex:scoreRisk ?Risco .
?Student ex:countActivity ?QtdeAtiv .
?Student ex:countActivity40nline ?QtdeAtivOnline .
?Student ex:countForum ?QtdeForum .
FILTER (?Risco <= -1 && ?QtdeAtiv < 9 && ?QtdeAtivOnline < 5 && ?QtdeForum < 6)
} ORDER BY ?Nome
```

Fonte: Elaborado pela autora.

A figura 38 mostra o resultado da consulta para hábitos dos alunos com alta probabilidade de evadir do curso, as primeiras três colunas mostram os indivíduos (*instances students*), os números de registros dos estudantes (Registro) e os nomes dos discentes, a quarta coluna (Risco) apresenta os escores de risco e as próximas colunas apresentam a quantidade de atividades realizadas e enviadas durante o semestre (QtdeAtiv), a quantidade de

participação nas atividades disponibilizadas virtualmente (QtdeAtivOnline), tais como *meet*, *chat*, envio de mensagens e a quantidade de participação nos fóruns (QtdeForum).

Figura 38: Resultado da Consulta SPARQL para hábitos de estudos ou comportamento

Student	Registro	Nome	Risco	QtdeAtiv	QtdeAtivOnline	QtdeForum
Student13	"2013"^^ http://www.w3.org/2001/XMLSchema#string	"Aluno13"^^ http://www.w3.org/2001/XMLSchema#string	"4"^^ http://www.w3.org/2001/XMLSchema#int	"4"^^ http://www.w3.org/2001/XMLSchema#int	"5"^^ http://www.w3.org/2001/XMLSchema#int	"5"^^ http://www.w3.org/2001/XMLSchema#int
Student15	"2015"^^ http://www.w3.org/2001/XMLSchema#string	"Aluno15"^^ http://www.w3.org/2001/XMLSchema#string	"4"^^ http://www.w3.org/2001/XMLSchema#int	"4"^^ http://www.w3.org/2001/XMLSchema#int	"6"^^ http://www.w3.org/2001/XMLSchema#int	"6"^^ http://www.w3.org/2001/XMLSchema#int
Student16	"2016"^^ http://www.w3.org/2001/XMLSchema#string	"Aluno16"^^ http://www.w3.org/2001/XMLSchema#string	"4"^^ http://www.w3.org/2001/XMLSchema#int	"4"^^ http://www.w3.org/2001/XMLSchema#int	"6"^^ http://www.w3.org/2001/XMLSchema#int	"6"^^ http://www.w3.org/2001/XMLSchema#int
Student17	"2017"^^ http://www.w3.org/2001/XMLSchema#string	"Aluno17"^^ http://www.w3.org/2001/XMLSchema#string	"2"^^ http://www.w3.org/2001/XMLSchema#int	"2"^^ http://www.w3.org/2001/XMLSchema#int	"8"^^ http://www.w3.org/2001/XMLSchema#int	"8"^^ http://www.w3.org/2001/XMLSchema#int
Student18	"2018"^^ http://www.w3.org/2001/XMLSchema#string	"Aluno18"^^ http://www.w3.org/2001/XMLSchema#string	"4"^^ http://www.w3.org/2001/XMLSchema#int	"4"^^ http://www.w3.org/2001/XMLSchema#int	"6"^^ http://www.w3.org/2001/XMLSchema#int	"6"^^ http://www.w3.org/2001/XMLSchema#int
Student19	"2019"^^ http://www.w3.org/2001/XMLSchema#string	"Aluno19"^^ http://www.w3.org/2001/XMLSchema#string	"4"^^ http://www.w3.org/2001/XMLSchema#int	"4"^^ http://www.w3.org/2001/XMLSchema#int	"6"^^ http://www.w3.org/2001/XMLSchema#int	"6"^^ http://www.w3.org/2001/XMLSchema#int
Student20	"2020"^^ http://www.w3.org/2001/XMLSchema#string	"Aluno20"^^ http://www.w3.org/2001/XMLSchema#string	"2"^^ http://www.w3.org/2001/XMLSchema#int	"2"^^ http://www.w3.org/2001/XMLSchema#int	"6"^^ http://www.w3.org/2001/XMLSchema#int	"6"^^ http://www.w3.org/2001/XMLSchema#int
Student21	"2021"^^ http://www.w3.org/2001/XMLSchema#string	"Aluno21"^^ http://www.w3.org/2001/XMLSchema#string	"4"^^ http://www.w3.org/2001/XMLSchema#int	"4"^^ http://www.w3.org/2001/XMLSchema#int	"6"^^ http://www.w3.org/2001/XMLSchema#int	"6"^^ http://www.w3.org/2001/XMLSchema#int
Student22	"2022"^^ http://www.w3.org/2001/XMLSchema#string	"Aluno22"^^ http://www.w3.org/2001/XMLSchema#string	"3"^^ http://www.w3.org/2001/XMLSchema#int	"3"^^ http://www.w3.org/2001/XMLSchema#int	"4"^^ http://www.w3.org/2001/XMLSchema#int	"2"^^ http://www.w3.org/2001/XMLSchema#int
Student23	"2023"^^ http://www.w3.org/2001/XMLSchema#string	"Aluno23"^^ http://www.w3.org/2001/XMLSchema#string	"1"^^ http://www.w3.org/2001/XMLSchema#int	"1"^^ http://www.w3.org/2001/XMLSchema#int	"5"^^ http://www.w3.org/2001/XMLSchema#int	"2"^^ http://www.w3.org/2001/XMLSchema#int
Student24	"2024"^^ http://www.w3.org/2001/XMLSchema#string	"Aluno24"^^ http://www.w3.org/2001/XMLSchema#string	"2"^^ http://www.w3.org/2001/XMLSchema#int	"2"^^ http://www.w3.org/2001/XMLSchema#int	"5"^^ http://www.w3.org/2001/XMLSchema#int	"2"^^ http://www.w3.org/2001/XMLSchema#int

Fonte: Elaborado pela autora.

Hábitos de estudo eficazes são cruciais para o sucesso acadêmico na modalidade a distância. A abordagem de estudo de um aluno pode impactar significativamente sua compreensão, retenção e desempenho geral. Desenvolver bons hábitos de estudo requer disciplina, organização e compromisso com o aprendizado.

O aluno corre risco de reprovação ou evasão quando: a) não participa ativamente de fóruns; b) não realiza as atividades propostas; c) não estuda o material didático disponível; d) não participa de reuniões virtuais; e) não envia mensagens quando tem dúvidas; e f) não faz as avaliações. Para combater ou eliminar esses hábitos prejudiciais, a instituição deve realizar monitoramentos regulares dos alunos, identificar suas causas e implementar estratégias que possam auxiliá-los.

5.12 Considerações sobre o capítulo

Neste capítulo, foi apresentado a OntoAthena, uma ontologia elaborada para explorar o domínio da educação a distância. A OntoAthena tem como objetivo principal representar o conhecimento no âmbito da educação a distância e serviços inteligentes, sendo empregada na criação do modelo ER do Athena.

A OntoAthena foi desenvolvida no software *Protégé*, composta por 1161 axiomas, 93 classes, sendo 22 classes principais, 71 subclasses, 41 propriedades de objetos, 52 propriedades de dados e 56 instâncias (representadas na Tabela 15). Após a representação do

conhecimento, as informações foram armazenadas através da criação das instâncias. Um mecanismo de inferência foi empregado para garantir a consistência entre as classes e para inferir previsões nos relacionamentos estabelecidos. Além disso, foram realizadas consultas SPARQL para abordar as questões de competência propostas. Foram definidas dez questões de competências, mas para efeito de validação da completude da ontologia, apenas quatro consultas foram elaboradas utilizando critérios definidos juntamente com a função FILTER.

É relevante ressaltar que essa ontologia foi publicada em um periódico internacional e encontra-se disponível no *International Journal of Metadata, Semantics and Ontologies* (SILVA et al., 2024).

Em resumo, o capítulo apresentou detalhes sobre o processo de desenvolvimento da ontologia, abrangendo:

- A realização de uma pesquisa bibliográfica com objetivo de encontrar trabalhos relacionados a ontologia na educação a distância utilizando históricos de contextos. Desta pesquisa, resultou em um quadro comparativo com 15 trabalhos relacionados à OntoAthena e às ontologias na área da educação à distância;
- Um mapa conceitual cujo tema focal foi "Serviços Inteligentes na Educação a Distância usando históricos de contextos". Após o desenvolvimento do mapa conceitual, tornou-se possível identificar os principais conceitos e suas relações;
- Uma ontologia para representação do conhecimento no domínio da Educação a Distância e ofertas de serviços inteligentes baseados em elementos do contexto dos alunos. A ontologia foi construída seguindo os passos definidos na metodologia *Ontology Development 101* (NOY; MCGUINNESS, 2001);
- Uma avaliação foi realizada para verificar a consistência e a completude da ontologia. A consistência foi verificada por meio da execução do motor de inferência *Pellet*, enquanto a completude foi avaliada através de consultas SPARQL. Tanto a verificação de consistência quanto a de completude evidenciaram definições abrangentes em conformidade com o domínio especificado;
- Um artigo publicado em periódico internacional *An Ontology for Intelligent Services in Distance Education* (SILVA et al., 2024).

6 AVALIAÇÃO E RESULTADOS

Esta tese propôs o modelo computacional Athena, especialmente concebido para a EaD e serviços inteligentes, considerando históricos de contextos dos alunos, com objetivos de auxiliá-los no processo de aprendizagem e consequentemente minimizar reprovações e evasões. Diante disso, a seguinte questão de pesquisa foi definida (seção 1.1).

“Como seria um modelo computacional que suportasse de forma genérica a criação e uso de serviços inteligentes para educação a distância tendo como base os históricos de contextos dos alunos?”

Para atender a esta questão, uma hipótese foi definida e apresentada na Seção 1.1.

“O modelo desenvolvido é genérico, pois o mesmo não é específico apenas para um tipo de serviço. O modelo computacional genérico embasado em registros contextuais, é capaz de abrigar uma variedade de serviços inteligentes, proporcionando auxílio tanto a educadores envolvidos na educação a distância quanto aos estudantes no processo de ensino e aprendizagem”.

A validade da hipótese pôde ser verificada através de dois serviços inteligentes como instrumentos de avaliação. O primeiro serviço destina-se a auxiliar os instrutores dessa modalidade a avaliar o progresso dos alunos, identificando aqueles que possam estar enfrentando dificuldades no processo de aprendizagem. Ele emprega registros contextuais para detectar os estudantes que necessitam de suporte educacional. O segundo serviço tem como meta oferecer apoio aos alunos com desempenho inferior, através da formação de grupos de estudo, com o intuito de promover a aprendizagem por meio da colaboração e do envolvimento entre os alunos.

6.1 Problematização

A educação a distância enfrenta diversos desafios, e a oferta de serviços inteligentes desempenha um papel crucial na superação desses obstáculos. Alguns problemas comuns incluem a sensação de solidão e desconexão em ambientes virtuais de aprendizagem, o que pode impactar negativamente o desempenho acadêmico dos alunos; dificuldades de personalização, uma vez que cada aluno possui um estilo de aprendizagem e necessidades

específicas, demandando uma abordagem individualizada; a falta de identificação precoce de alunos com problemas acadêmicos ou em risco de evasão, sem um sistema eficiente de monitoramento e intervenção; e a dificuldade em formar grupos de estudo que promovam uma colaboração eficaz e a troca de conhecimentos entre os alunos.

A oferta de serviços inteligentes pode abordar esses problemas de várias maneiras. Primeiramente, através da personalização do ensino, os serviços inteligentes podem analisar o desempenho e o comportamento de aprendizagem de cada aluno, oferecendo recomendações personalizadas de materiais de estudo, atividades e suporte adicional com base em suas necessidades individuais. Além disso, esses serviços podem monitorar continuamente o progresso dos alunos, identificando padrões que indiquem dificuldades acadêmicas ou riscos de evasão. Isso possibilita uma intervenção precoce por parte dos instrutores, que podem oferecer suporte personalizado para ajudar os alunos a superar obstáculos. Os serviços inteligentes também podem formar grupos de estudo com base nas habilidades, interesses e estilos de aprendizagem dos alunos, promovendo uma colaboração mais produtiva e enriquecedora. Além disso, eles podem oferecer *feedback* em tempo real, incentivos personalizados e recursos interativos para aumentar o engajamento e a motivação dos alunos.

6.2 Descrição do Protótipo

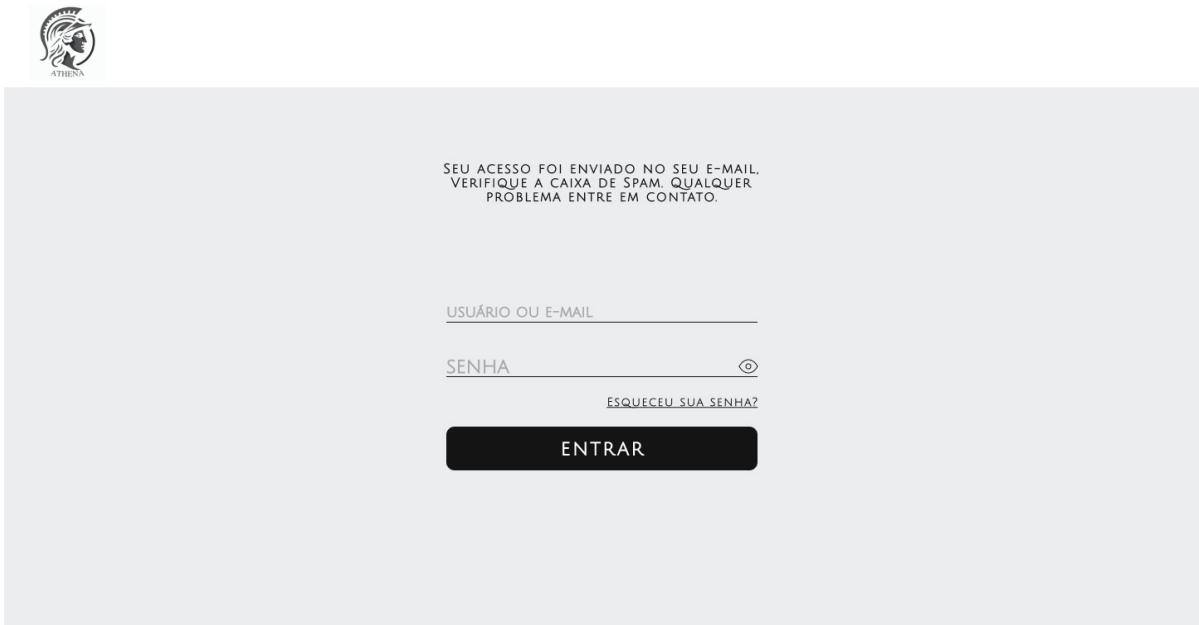
Um protótipo do modelo Athena foi desenvolvido usando a ferramenta Figma⁶, onde são apresentados os serviços ofertados pelo Athena, sendo *Forecasting*, *Grouping*, *Monitoring* e *Recommending*. É importante ressaltar que, entre esses serviços, apenas o *Forecasting* e *Grouping* foram implementados e utilizados na avaliação do modelo. As figuras a seguir (39 a 44) ilustram a modelagem das telas do sistema e suas respectivas funcionalidades.

⁶ <https://www.figma.com/>

Editor gráfico de vetor e prototipagem de projetos de *design* baseado principalmente no navegador *web*.

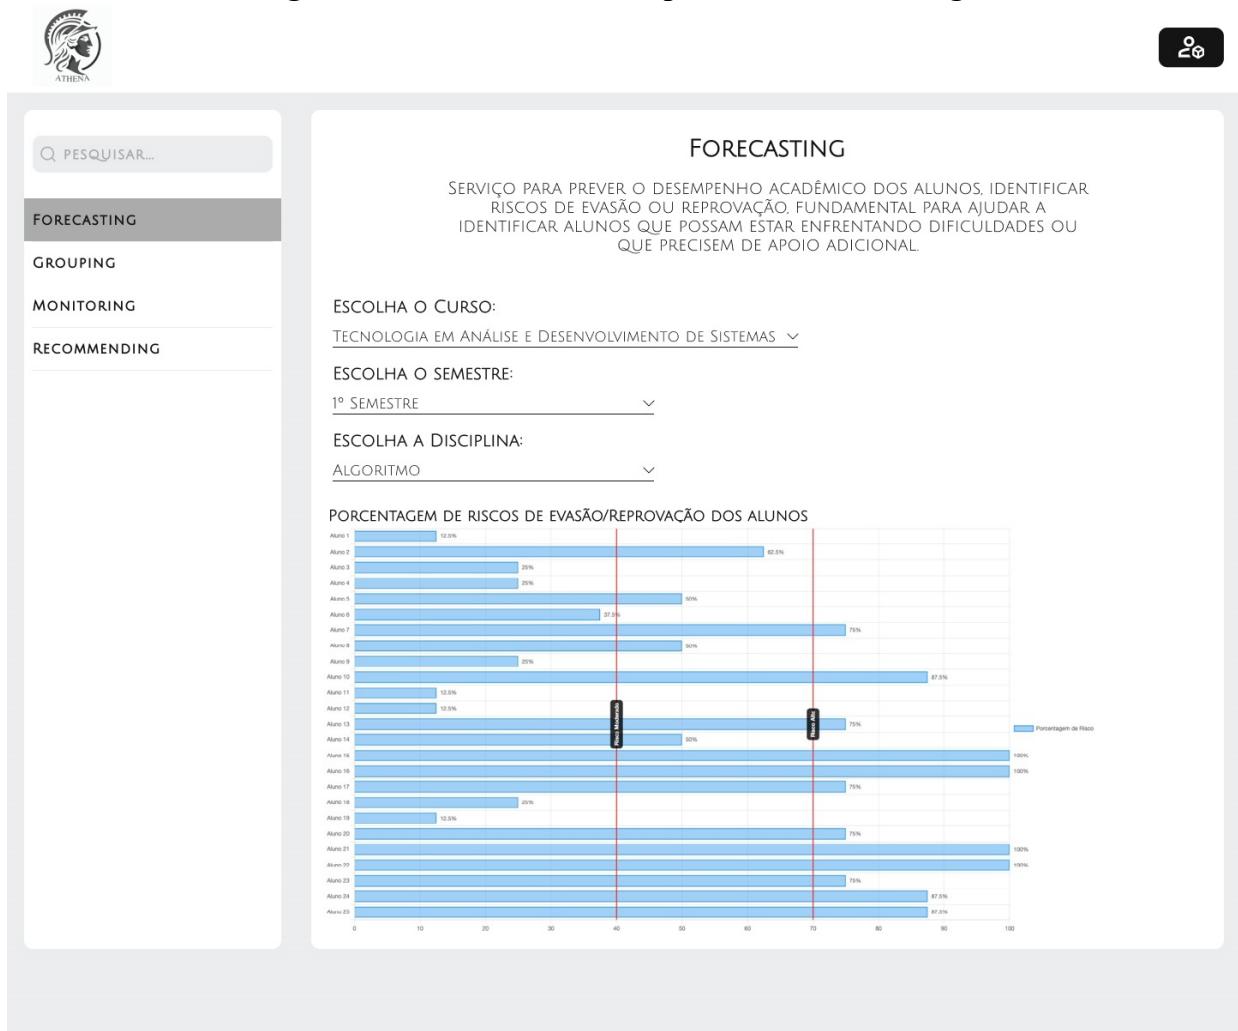
A Figura 39 apresenta a tela inicial do protótipo. Para acessar o Athena, o usuário deve inserir um *e-mail*. No primeiro acesso, um *e-mail* de validação será enviado. Após a validação, o usuário terá acesso aos serviços inteligentes.

Figura 39: Tela inicial do Modelo Athena



Fonte: Elaborado pela autora.

A Figura 40 apresenta a interface do *Forecasting*, um serviço concebido para prever o desempenho dos alunos, visando identificar possíveis dificuldades no seu progresso acadêmico, como reprovações ou desistências. Para acessar o serviço *Forecasting*, é preciso clicar no botão do serviço localizado ao lado esquerdo da tela (Figura 40). Após a seleção do serviço, é possível escolher o curso, o semestre e a disciplina, disponível ao lado direito da tela, na parte inferior da tela, é apresentado um gráfico que mostra a porcentagem de risco de cada aluno. Os nomes dos discentes são listados no lado esquerdo do gráfico, enquanto as porcentagens correspondentes são mostradas no lado direito. Além disso, o gráfico indica a classificação de risco para cada aluno (Baixo, médio e alto).

Figura 40: Tela do serviço de predição - *Forecasting*

Fonte: Elaborado pela autora.

Ao utilizar o serviço de predição, os educadores podem identificar padrões e tendências que ajudam a entender melhor os fatores que influenciam o desempenho dos estudantes na EaD. Isso permite que eles ajustem suas práticas de ensino e desenvolvam estratégias mais eficazes para apoiar o sucesso dos alunos.

O objetivo de um serviço de predição para alunos na EaD é utilizar análises de dados para antecipar e abordar as necessidades dos estudantes, promovendo o sucesso acadêmico e melhorando a experiência de aprendizagem *online*. O serviço de predição pode ajudar os professores a melhorar a retenção de alunos na EaD. Isso contribui para o sucesso dos alunos e para a reputação da instituição de ensino.

A Figura 41 exibe a interface do serviço inteligente *Grouping*, dedicado à formação de grupos de estudo. O acesso a este serviço ocorre ao clicar no botão com o nome do serviço, localizado ao lado esquerdo da tela (Figura 41). Na tela do serviço *Grouping*, apresentada à direita, o professor encontra opções para criar grupos de estudo, selecionando o curso, o semestre e a disciplina. Os grupos formados são apresentados na parte inferior da tela. Para utilizar o serviço, basta clicar no serviço disponível ao lado esquerdo da tela.

Figura 41: Tela do serviço para Formação de Grupos de Estudos - *Grouping*

The screenshot shows the 'ATHENA' platform interface. On the left, there's a sidebar with a search bar ('PESQUISAR...') and four service buttons: 'FORECASTING' (disabled), 'GROUPING' (selected and highlighted in grey), 'MONITORING' (disabled), and 'RECOMMENDING' (disabled). The main content area has a title 'GROUPING' and a subtitle explaining the service's purpose: 'SERVIÇO QUE UTILIZA INFORMAÇÕES DO PERFIL DO ALUNO, COMO INTERESSES, HABILIDADES, EXPERIÊNCIA PRÉVIA E ESTILO DE APRENDIZAGEM, PARA AGRUPAR ALUNOS COM INTERESSES SEMELHANTES OU COMPLEMENTARES'. It includes dropdown menus for 'ESCOLHA O CURSO' (set to 'CIÊNCIAS DA COMPUTAÇÃO'), 'ESCOLHA O SEMESTRE' (set to '1º SEMESTRE'), and 'ESCOLHA A DISCIPLINA' (set to 'ALGORITMO'). Below these are five groups of students, each with a 'FORMAR' button:

GRUPO	ALUNOS	Botão FORMAR
1	ALUNO 11, ALUNO 21, ALUNO 12, ALUNO 16, ALUNO 1	FORMAR
2	ALUNO 18, ALUNO 2, ALUNO 4, ALUNO 25, ALUNO 9	FORMAR
3	ALUNO 14, ALUNO 17, ALUNO 7, ALUNO 23, ALUNO 20	FORMAR
4	ALUNO 8, ALUNO 5, ALUNO 13, ALUNO 6, ALUNO 24	FORMAR
5	ALUNO 10, ALUNO 3, ALUNO 22, ALUNO 19, ALUNO 15	FORMAR

Fonte: Elaborado pela autora.

Quando um professor identifica alunos com dificuldades no desenvolvimento de uma disciplina específica, ele pode recorrer a esse serviço como uma ferramenta de auxílio. Formar grupos de estudos possui uma série de objetivos relevantes. Inicialmente, busca promover a troca de conhecimento, aproveitando as diversas habilidades e conhecimentos individuais dos membros do grupo. Esse compartilhamento de informações contribui para enriquecer a compreensão geral do assunto em estudo. Além disso, a dinâmica de grupo contribui para manter todos os participantes motivados e responsáveis. A sensação de responsabilidade compartilhada pode ser um poderoso estímulo para manter o compromisso e a concentração nos estudos.

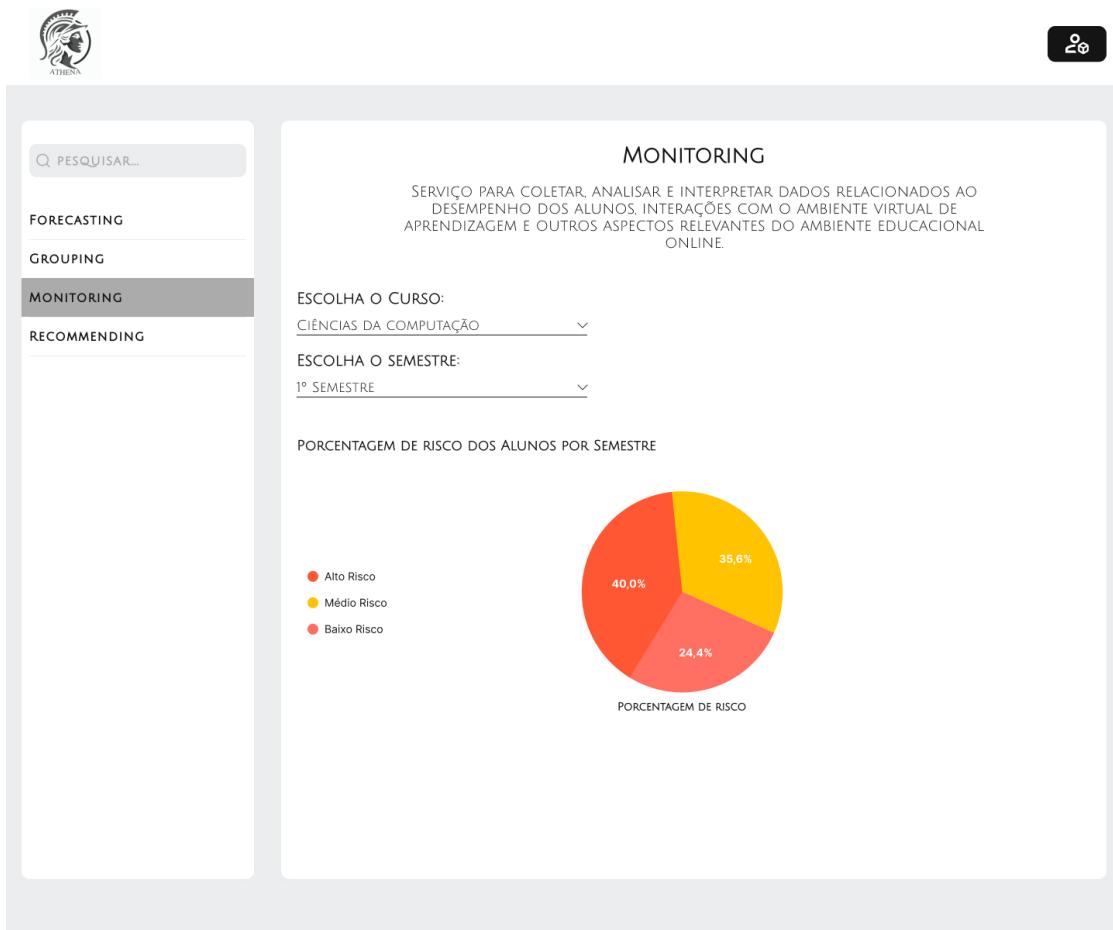
Outro ponto relevante é que o estudo em grupo permite que os membros abordem o material de diferentes perspectivas, o que pode resultar em *insights* valiosos e uma compreensão mais abrangente do tema. Além disso, a interação possibilita *feedback* imediato sobre ideias e conceitos, proporcionando oportunidades de esclarecimento e aprofundamento. A divisão de tarefas entre os membros do grupo também é uma vantagem significativa. Isso não apenas torna o estudo mais eficiente, mas também alivia a carga de trabalho de cada indivíduo, tornando-o menos sobrecarregado.

Por fim, formar grupos de estudos é uma oportunidade para desenvolver habilidades essenciais de colaboração, comunicação e trabalho em equipe. Essas competências são fundamentais tanto no ambiente acadêmico quanto no profissional, e o estudo em grupo oferece um espaço propício para aprimorá-las.

A Figura 42 mostra a tela do *Monitoring*, um serviço de monitoramento de alunos em cursos de educação a distância cujo principal propósito é auxiliar os gestores no acompanhamento do progresso e engajamento dos estudantes ao longo do curso *online*. Esse serviço de monitoramento é direcionado aos gestores/coordenadores, onde os mesmos podem verificar qual curso e semestre necessita de atenção específica.

Para que o gestor ou coordenador acessar esse serviço, é necessário entrar no Athena, clicar no botão “*Monitoring*” localizado no lado esquerdo da tela (Figura 42), selecionar o curso e o semestre desejados para análise, disponível no lado direito da imagem. O resultado é exibido na parte inferior da tela em formato de gráfico, mostrando a porcentagem de classificação de cada risco do semestre selecionado.

Figura 42: Tela do serviço de Monitoramento - *Monitoring*



Fonte: Elaborado pela autora.

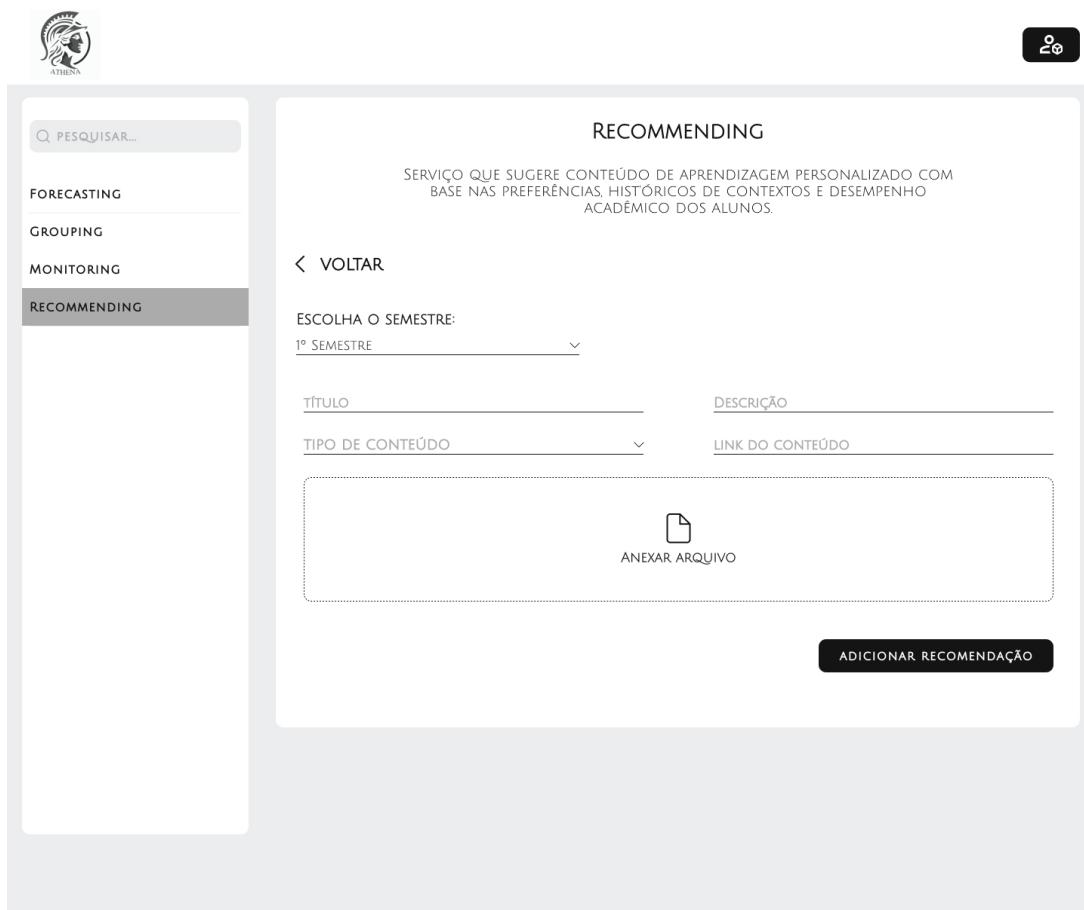
Ao identificar previamente os alunos que podem necessitar de suporte adicional, as instituições de ensino otimizam seus recursos, direcionando-os para onde são mais necessários. Isso, por sua vez, possibilita a melhoria da experiência do aluno, permitindo a otimização do *design* do curso e das estratégias de ensino para melhor atender às suas necessidades e preferências. Essa abordagem pode abranger a alocação de pessoal, o desenvolvimento de programas de intervenção específicos, a distribuição de materiais educacionais, entre outras medidas.

O serviço também tem como objetivo a intervenção precoce, identificando alunos em risco de evasão ou com dificuldades acadêmicas. Isso permite a implementação de medidas de intervenção antecipadas, como oferecer suporte tutorial adicional ou direcionar o aluno para recursos de apoio específicos. Além disso, o serviço possibilita a avaliação da eficácia do curso, fornecendo dados valiosos sobre o desempenho, auxiliando gestores e desenvolvedores

a avaliar a eficácia do curso e a realizar os ajustes necessários para melhorar a experiência de aprendizagem.

As figuras 43 e 44 exibem as telas do *Recommending*. O objetivo do serviço de recomendação para alunos em risco é oferecer suporte adicional e recursos complementares que possam ajudá-los a melhorar seu desempenho acadêmico e reduzir a probabilidade de reprovação. Ao identificar estudantes em situação de vulnerabilidade, o serviço de recomendação pode sugerir materiais específicos adequados às necessidades individuais de cada aluno, auxiliando-os a compreender melhor os conteúdos, aprofundar seu conhecimento e desenvolver habilidades essenciais para o sucesso acadêmico. Dessa forma, o serviço de recomendação busca fornecer um apoio personalizado e direcionado, visando aumentar as chances de êxito dos alunos em situação de risco de reprovação ou evasão.

Figura 43: Tela de cadastro do serviço de Recomendação - *Recommending*



Fonte: Elaborado pela autora.

A Figura 43 exibe uma tela na qual o professor pode cadastrar diversas recomendações. Para cadastrar as recomendações é preciso acessar o serviço disponível ao

lado esquerdo da tela e após, ao lado direito da tela, selecionar o semestre, inserir um título, especificar o tipo de conteúdo, adicionar uma descrição e, opcionalmente, incluir um *link* ou anexar um arquivo. Essas opções ficam disponibilizadas ao lado direito da tela (Figura 43). Após preencher as solicitações, basta clicar no botão "Adicionar Recomendação", disponível no canto inferior direito da tela.

Essas recomendações podem abranger uma ampla variedade de recursos educacionais, como livros, artigos acadêmicos, vídeos educativos, objetos de aprendizagem, tutoriais *online* e outros materiais de estudo pertinentes ao conteúdo do curso; recursos didáticos, como exercícios práticos, enquetes, questionários, simuladores, laboratórios virtuais e outras ferramentas interativas para reforçar o aprendizado; atividades complementares, como projetos práticos, estudos de caso, fóruns de discussão, grupos de estudo *online*, workshops e outras atividades que promovam a interação e a aplicação do conhecimento.

Figura 44: Tela de conteúdo do serviço de Recomendação - *Recommending*

ATHENA

PESQUISAR...

FORECASTING

GROUPING

MONITORING

RECOMMENDING

SERVIÇO QUE SUGERE CONTEÚDO DE APRENDIZAGEM PERSONALIZADO COM BASE NAS PREFERÊNCIAS, HISTÓRICOS DE CONTEXTOS E DESEMPENHO ACADÉMICO DOS ALUNOS.

ESCOLHA O SEMESTRE:

1º SEMESTRE

+ ADICIONAR NOVA RECOMENDAÇÃO

VÍDEO: BITS E BYTES	>
APRESENTAÇÃO: GERAÇÃO DE COMPUTADORES	>
VÍDEO: CIRCUITO E EXPRESSÃO BOOLEANA	>
LIVRO: ARQUITETURA E ORGANIZAÇÃO DE COMPUTADORES	>
VÍDEO: SISTEMAS DE NUMERAÇÃO	>
LIVRO: ARQUITETURA DE COMPUTADORES	>
APRESENTAÇÃO: TABELA VERDADE	>

1 2 3 4 >

Fonte: Elaborado pela autora.

A Figura 44 apresenta as recomendações cadastradas pelos professores. Para acessar, basta clicar sobre a recomendação e seu conteúdo será exibido. Além disso, no canto superior à direita da tela é possível adicionar mais recomendações sem a necessidade de voltar a tela inicial.

O serviço inteligente de recomendação proporciona vantagens aos professores, podendo incluir por exemplo, economia de tempo, personalização do ensino, motivação, melhoria do engajamento e avaliação contínua. Ao reduzir o tempo gasto na busca por materiais, permitem que os professores se concentrem na criação de conteúdo e no suporte direto aos alunos.

6.3 Avaliação

A seção anterior apresentou o protótipo do Athena. Nela foi apresentada a modelagem das telas dos possíveis serviços ofertados pelo modelo. Nesta seção é apresentada a implementação e a avaliação de dois serviços, o *Forecasting* e o *Grouping*.

Para avaliar esses dois serviços foi implementado uma estrutura computacional que conta com uma aplicação *web*⁷ para serviços inteligentes com o propósito de disponibilizar soluções inteligentes direcionadas à comunidade acadêmica.

6.3.1 Cenário de Avaliação

Para a composição dos serviços *Forecasting* e *Grouping*, foram utilizados dados anonimizados de 25 alunos em um ambiente virtual de aprendizagem. Os dados foram coletados entre os períodos de 2022/1 e 2023/2 no curso de tecnologia em Análise e Desenvolvimento de Sistemas de uma Universidade com autorização do Comitê de Ética da Universidade Unisinos (Anexo A).

Os dados coletados nesta etapa permitiram a composição de perfis, por meio de históricos de contextos, considerando as atividades realizadas no ambiente virtual de aprendizagem, tais como, acesso semestral, atividades como avaliações parciais, oficiais,

⁷ <https://modelo-athena.vercel.app/home>

questionários, total de atividade *online*, como participação em *chat*, *meet*, envio de mensagens e participação em fórum. A Figura 45 mostra um exemplo da base de dados utilizada no serviço de predição e na formação de grupos de estudos.

A Figura 45 apresenta a base de dados que consolida os históricos de contextos agrupados por semestre. A base mostra a identificação, nome dos alunos, gênero, ano, curso, semestre, disciplina. Além disso, também apresenta a quantidade de acessos dos alunos durante o semestre, a participação nos *chats*, mensagens, fórum, *meet*, vídeos, total das atividades realizadas, material didático, avaliações parciais e oficiais realizadas no semestre.

Figura 45: Exemplo da base de dados

ID	NOME	IDADE	GÊNERO	ANO	CURSO	SEMESTRE	DISCIPLINA	ACESSO P/ CHAT	MENSAGENS	FÓRUM	MEET	VÍDEOS	TOTAL ATIV.	MATERIAL	ATIVIDADES	AVALIAÇÃO PARCIAL	AVALIAÇÃO OFICIAL	AVALIAÇÃO SEMESTRAL	TOTAL ATIVIDADES	
1	aluno 1	19	Feminino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	99	2	2	12	1	4	5	10	3	3	2	2	10
2	aluno 2	22	Feminino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	20	0	0	6	0	2	0	5	1	2	1	2	6
3	aluno 3	30	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	80	1	5	12	1	4	7	10	2	3	2	2	9
4	aluno 4	20	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	86	2	3	12	1	4	6	10	3	4	2	2	10
5	aluno 5	25	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	50	0	0	10	0	4	0	10	2	3	2	2	9
6	aluno 6	19	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	50	1	2	12	1	4	4	10	2	4	2	2	10
7	aluno 7	23	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	30	0	0	6	0	3	0	6	1	2	1	2	6
8	aluno 8	21	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	30	1	1	6	1	2	5	5	3	2	1	1	7
9	aluno 9	35	Feminino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	81	2	2	12	1	4	5	10	2	3	2	2	9
10	aluno 10	18	Feminino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	20	0	0	6	0	2	0	5	2	2	1	1	6
11	aluno 11	19	Feminino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	80	1	5	12	1	4	7	10	2	4	2	2	10
12	aluno 12	23	Feminino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	70	2	2	12	1	3	5	8	2	4	2	2	10
13	aluno 13	18	Feminino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	35	0	0	5	0	2	0	8	1	4	0	1	6
14	aluno 14	21	Feminino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	49	0	0	8	0	1	0	5	1	2	1	1	5
15	aluno 15	20	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	20	0	0	1	0	1	0	6	1	1	2	2	6
16	aluno 16	26	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	15	0	0	3	0	1	0	4	2	2	1	0	5
17	aluno 17	31	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	56	0	0	4	0	3	0	10	2	3	1	2	8
18	aluno 18	30	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	89	2	9	12	1	3	12	8	2	4	1	2	9
19	aluno 19	34	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	90	2	10	12	1	4	13	7	2	4	2	2	10
20	aluno 20	21	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	52	1	0	3	0	2	1	5	2	2	1	1	6
21	aluno 21	36	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	5	0	0	0	0	0	0	3	1	0	0	0	1
22	aluno 22	24	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	15	0	2	2	0	1	2	3	1	1	1	1	4
23	aluno 23	19	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	65	1	0	4	1	2	2	7	1	2	1	1	5
24	aluno 24	20	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	30	0	0	2	1	0	1	5	1	2	1	1	5
25	aluno 25	29	Masculino	2022/1	Tec. em Análise e Desenv. de Sistemas	1º	Algoritmo	25	0	0	6	1	1	1	6	1	2	1	1	5

Fonte: Elaborado pela autora.

As análises foram desenvolvidas na linguagem *TypeScript*⁸, juntamente com as bibliotecas *React*⁹, *Next*¹⁰ e o *Prisma ORM*¹¹. O banco de dados utilizado foi *Postgresql*¹². As ferramentas *Chart.js* e *React-Chart.js* foram utilizadas na criação dos gráficos no *React*.

Nas próximas seções são apresentados os resultados dos dois serviços inteligentes implementados.

⁸ é uma linguagem de programação de código aberto desenvolvida pela Microsoft. É um superconjunto sintático estrito de *JavaScript* e adiciona tipagem estática opcional à linguagem.

⁹ Biblioteca *front-End JavaScript* de código aberto com foco em criar interfaces de usuário em páginas web para criar as interfaces.

¹⁰ Biblioteca escrita em *Javascript* para desenvolvimento de interfaces baseada em componentes.

¹¹ Biblioteca que facilita a integração como banco de dados

¹² Sistema gerenciador de banco de dados objeto relacional, desenvolvido como projeto de código aberto.

6.3.2 Forecasting- Serviço inteligente para prever o desempenho acadêmico dos alunos

O *Forecasting* é um serviço inteligente que faz uso de históricos de contextos para a predição da situação de alunos em EaD. A premissa básica para avaliação do serviço são as ações geradas dentro de um ambiente virtual de aprendizagem, por parte do aluno. Verificar e identificar o perfil, tempo de acesso e quais atividades que o aluno realizou, são características que fornecem base para traçar métricas bem como ações para um grupo específico de perfis classificados culminando com definições assertivas para contribuir e impulsionar as atividades docentes.

O processo de previsão foi realizado por meio da análise dos históricos de contextos agrupados por semestre, sendo: quantidade de acessos, atividades realizadas, participação em *chats* e reuniões *online*, interações por meio de mensagens e participação em fóruns de discussão.

Alguns critérios foram utilizados para a realização da análise: a) se a quantidade de acesso por semestre na disciplina for maior que trinta, o risco de reprovar ou evadir é baixo, se for igual a trinta, o risco é médio e menor que trinta o risco é alto; b) se a quantidade de atividades realizadas por semestre, tais como, avaliações parciais, oficiais, questionários, atividades práticas, entre outras, for igual ou maior que doze, o risco de reprovação ou evasão é baixo, se for igual a dez, o risco é médio e se for menor ou igual a nove, o risco é alto; c) se a quantidade de participação por semestre em *meet*, *chat*, envios de mensagens for maior ou maior que sete, o risco é baixo, se for igual a seis o risco é médio e menor que cinco o risco é alto; d) se a participação por semestre em fóruns de discussões for maior ou igual a oito o risco é baixo, se for igual a seis o risco é médio e se for menor que seis o risco é alto.

A seleção dos critérios seguiu um processo prático e acessível no contexto específico. Basicamente, foram selecionados porque eram fáceis de medir e aplicar, estavam prontamente disponíveis e faziam sentido para a análise em questão, considerando as limitações de tempo, recursos e dados. Esses critérios foram escolhidos para facilitar a análise e obtenção de resultados de maneira eficiente.

A seguir é apresentado o funcionamento do código do serviço de predição que analisa dados de estudantes para calcular o risco de evasão ou reprovação com base nos critérios citados anteriormente.

A parte do código a seguir trata da importação de códigos de terceiros ou de outras funções dentro do projeto:

```
import { prisma } from "@/lib/prisma";
import { StudentAnalyzeResult } from "@/domain/AnalyzeStudents";
import { ParamsServices } from "@/domain/ParamsServices";
```

- *prisma*: importa o cliente Prisma, que é usado para interagir com o banco de dados.
- *StudentAnalyzeResult*: importa o tipo ou interface que define a estrutura dos resultados da análise de estudantes.
- *ParamsServices*: importa o tipo ou interface que define a estrutura dos parâmetros de entrada da função.

O trecho do código a seguir trata-se da definição da função *analyzeStudentsService*. A função *analyzeStudentsService* é exportada para ser utilizada em outras partes do projeto, a função recebe um objeto com *idCurso*, *idSemestre* e *idDisciplina* como parâmetros e retorna uma *Promise* no *JavaScript* para trabalhar com funções assíncronas e devolve uma requisição para um *array* de *StudentAnalyzeResult*, que é uma interface que define a estrutura dos resultados da análise de estudantes.

```
export const analyzeStudentsService = async ({
  idCurso,
  idSemestre,
  idDisciplina,
}: ParamsServices): Promise<StudentAnalyzeResult[]> => {
```

O trecho apresentado a seguir realiza a busca no banco de dados com base no curso, semestre e disciplina do aluno. A função utiliza Prisma para interagir de forma eficiente com o banco de dados e retorna os resultados da análise na estrutura definida por *StudentAnalyzeResult*, armazenando-os na variável *studentsDatabase*. A constante *studentsAnalyzed* é declarada como um *array* vazio do tipo *StudentAnalyzeResult[]*, que

define o *array* como uma lista de objetos seguindo a estrutura ou interface *StudentAnalyzeResult*.

```
const studentsDatabase = await prisma.aluno.findMany({
    where: { idSemestre, idCurso, idDisciplina },
});
const studentsAnalyzed: StudentAnalyzeResult[] = [];
```

Essa parte do código inicializa uma lista vazia que é preenchida com os resultados da análise de cada aluno. Cada item desta lista representa um aluno analisado e contém as informações específicas sobre o risco de evasão ou reprovação calculado.

O objetivo dos códigos mostrados acima, é preparar os dados necessários para a análise subsequente dos estudantes. A constante *const studentsDatabase = await prisma.aluno.findMany* recupera os dados dos alunos do banco de dados com base em critérios específicos, e a constante *const studentsAnalyzed: StudentAnalyzeResult[]* prepara uma estrutura para armazenar os resultados da análise desses dados:

- Consulta ao Banco de Dados: Garante que apenas os alunos que atendem aos critérios específicos de semestre, curso e disciplina sejam considerados para a análise.
- Inicialização da Lista: Prepara um local para armazenar os resultados da análise, que incluirão informações detalhadas sobre o risco de cada aluno.

O código a seguir apresenta o cálculo da soma dos riscos de reprovação ou evasão de acordo com os históricos de contextos e os critérios apresentados anteriormente.

Ao percorrer o banco de dados, os riscos são avaliados e somados da seguinte maneira: se o aluno tem mais de trinta acessos na disciplina por semestre, adiciona-se +0 (risco baixo); se tem exatamente trinta acessos, adiciona-se +1 (risco médio); e se tem menos de trinta acessos, adiciona-se +2 (risco alto). Esse cálculo é realizado consistentemente em todos os contextos.

O código a seguir mostra o *loop* de análise, o qual itera sobre cada estudante no *studentsDatabase*. A constante *const student of studentsDatabase* calcula o risco de evasão

inicializando *evasionRisk* em 0 e vai incrementando-o com base nos critérios apresentados seguir:

- Acessos no semestre: +1 se igual a 30, +2 se menor que 30.
- Atividades avaliativas realizadas: +1 se igual a 10, +2 se menor ou igual a 9.
- Atividades online: +1 se igual a 6, +2 se menor que 5.
- Participação em fóruns: +1 se igual a 6, +2 se menor que 6.

```

for (const student of studentsDatabase) {
    let evasionRisk = 0;

    if (student.acessoSemestre === 30) {
        evasionRisk += 1;
    } else if (student.acessoSemestre < 30) {
        evasionRisk += 2;
    }

    if (student.totalAtividades === 10) {
        evasionRisk += 1;
    } else if (student.totalAtividades <= 9) {
        evasionRisk += 2;
    }

    if (student.totalAtividadesOnline === 6) {
        evasionRisk += 1;
    } else if (student.totalAtividadesOnline < 5) {
        evasionRisk += 2;
    }

    if (student.forum === 6) {
        evasionRisk += 1;
    } else if (student.forum < 6) {
        evasionRisk += 2;
    }
}

```

A porcentagem mostrada no gráfico na Figura 46, é feita através da linha de código `const riskPorcentage=(100*evasionRisk)/8;` essa função calcula a porcentagem de risco de evasão/reprovação. O valor máximo de `evasionRisk` é 8, então a fórmula `(100*evasionRisk)/8` converte esse valor para uma porcentagem, conforme apresentado no trecho do código a seguir:

```
const riskPorcentage = (100 * evasionRisk) / 8;
studentsAnalyzed.push({
    id: student.id,
    nome: student.nome,
    porcentagemDeRisco: riskPorcentage,
});
}
```

As linhas de códigos a seguir tem a função de adicionar e retornar o estudante analisado à lista. A função adiciona cada estudante analisado, com seu *ID*, nome e porcentagem de risco, à lista `studentsAnalyzed`.

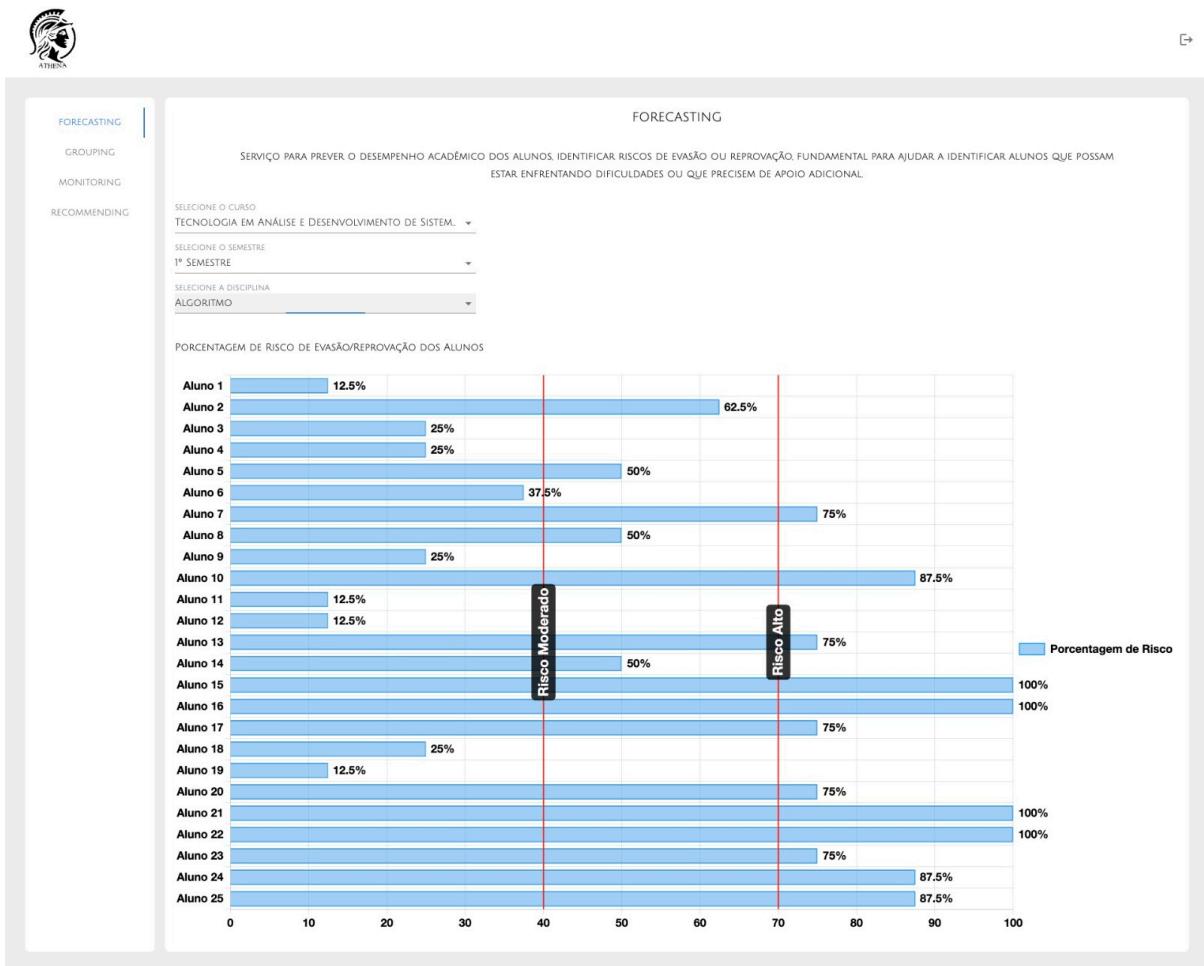
```
studentsAnalyzed.push({
    id: student.id,
    nome: student.nome,
    porcentagemDeRisco: riskPorcentage,
});
}
return studentsAnalyzed;
};
```

A função `return studentsAnalyzed` retorna a lista de estudantes analisados, cada um com sua respectiva porcentagem de risco de evasão ou reprovação. Resumindo, a função coleta dados de estudantes do banco de dados usando Prisma, analisa esses dados para calcular o risco de evasão ou reprovação com base nos critérios definidos e apresentados

anteriormente e, retorna uma lista de resultados com a porcentagem de risco para cada estudante.

A Figura 46 apresenta a tela do serviço inteligente *Forecasting* e o resultado da análise de 25 alunos do curso de Tecnologia em Análise e Desenvolvimento de Sistema. A análise foi realizada com alunos do primeiro semestre da disciplina de algoritmo. Foram identificados doze (12) alunos com risco alto de reprovação, enquanto quatro (4) apresentaram risco moderado, e nove (9) foram associados a um risco baixo.

Figura 46: Resultado da análise de predição



Fonte: Elaborado pela autora.

O gráfico apresentado na Figura 46 exibe, à esquerda, os nomes dos 25 alunos analisados. No centro, observa-se a divisão da classificação dos riscos: alunos com risco baixo à esquerda, alunos com risco médio no centro e alunos com risco alto à direita. Além disso, o gráfico mostra a porcentagem de risco para cada aluno, de acordo com a quantidade de

acessos realizados na disciplina, quantidade de atividades realizadas, participação em atividades *online* e participação em fóruns de discussão. Dentre os doze alunos identificados com alto grau de reprovação ou evasão, oito não conseguiram terminar o curso.

6.3.3 *Grouping* - Serviço inteligente para formação de grupos de estudos

O *Grouping* é um serviço inteligente que utiliza históricos de contextos para formar grupos de estudo com base na situação dos alunos em curso. Em uma fase anterior, o serviço *Forecasting* realiza a previsão do desempenho dos alunos em relação a uma determinada disciplina, classificando-os como em situação de risco, com possibilidade de reprovação ou evasão, ou em situação aceitável e até mesmo excelente em seus estudos.

A formação de grupos, como parte do segundo serviço inteligente, é relevante para criar grupos compostos principalmente por alunos enfrentando dificuldades em uma disciplina, juntamente com aqueles que estão progredindo bem. Isso resulta em grupos heterogêneos, ou seja, envolve a criação de grupos de estudantes com diferentes habilidades e conhecimentos, promovendo a aprendizagem colaborativa e a troca de saberes entre os participantes. Verificar e identificar o perfil, acesso e quais atividades foram realizadas, são características que fornecem base para traçar métricas bem como ações para um grupo específico de perfis classificados culminando com definições assertivas para contribuir e impulsionar as atividades docentes.

Para formar os grupos, o serviço de agrupamento (*grouping*) inicialmente recebe do serviço *Forecasting* uma lista de alunos classificados pela porcentagem de risco. Após ordenar essa lista, são formados cinco grupos para este experimento específico.

Os trechos do código a seguir, são responsáveis pela formação de grupos de estudos. sendo detalhadas cada parte do código para entender seu funcionamento.

Este trecho do código importa três elementos essenciais para o funcionamento do serviço, sendo:

```
import { StudentAnalyzeResult } from "@/_domain/AnalyzeStudents";
import { ParamsServices } from "@/_domain/ParamsServices";
import { analyzeStudentsService } from "@/_services/analyze-students-service";
```

- *StudentAnalyzeResult* contém o resultado da análise dos estudantes.

- *ParamsServices* define os parâmetros necessários para o serviço.
- *analyzeStudentsService* realiza a análise dos estudantes e retorna os resultados.

O código a seguir mostra a definição da Função *groupRecommendationService*. Ela é definida como uma função assíncrona que recebe um objeto de parâmetros (*ParamsServices*) e retorna uma *Promise* no *JavaScript* e devolve uma requisição para uma matriz de *arrays* de *StudentAnalyzeResult*.

```
export async function groupRecommendationService({
  idCurso,
  idSemestre,
  idDisciplina,
}: ParamsServices): Promise<StudentAnalyzeResult[][]>
```

O trecho do código a seguir tem como objetivo obter e ordenar os resultados. A função recebe a lista de análise dos estudantes e chama *analyzeStudentsService* passa os parâmetros recebidos e espera a lista de resultados da análise dos estudantes. A lista de estudantes é ordenada com base na porcentagem de risco em ordem crescente.

```
const studentsAnalysisResult = await analyzeStudentsService({
  idCurso,
  idSemestre,
  idDisciplina,
});

const orderStudents = studentsAnalysisResult.sort((a, b) => {
  return a.porcentagemDeRisco - b.porcentagemDeRisco;
});
```

Para formar os grupos, inicia-se uma lista vazia para armazená-los usando a constante *const groups = []*. O processo para criar grupos balanceados é o seguinte: o código percorre a lista ordenada e forma grupos de cinco estudantes, combinando alunos com diferentes níveis de risco, conforme mostrado no trecho de código a seguir.

```

for (let i = 0; i < orderStudents.length; i += 5) {
    const group = [orderStudents[i]];

    if (i + 4 < orderStudents.length) {
        group.push(orderStudents[orderStudents.length - 1 - i]);
    }

    if (i + 1 < orderStudents.length) {
        group.push(orderStudents[i + 1]);
    }

    if (i + 3 < orderStudents.length) {
        group.push(orderStudents[orderStudents.length - 2 - i]);
    }

    if (i + 2 < orderStudents.length) {
        group.push(orderStudents[i + 2]);
    }

    groups.push(group);
}

return groups;
}

```

A lógica deste código visa garantir que cada grupo contenha uma mistura de estudantes de baixo, médio e alto risco, para formar grupos equilibrados. Finalmente, a função *return groups* retorna a lista de grupos formados.

A Figura 47 ilustra a formação de cinco grupos. A formação é realizada ordenando os alunos de acordo com seus níveis de risco, do menor para o maior. O processo consiste em selecionar, a cada repetição, o primeiro aluno da lista juntamente com o último, prosseguindo assim até que cinco alunos sejam alocados em um grupo. Esse procedimento é repetido até que se formem cinco grupos de alunos.

Figura 47: Resultado da Formação de grupos de estudos

Fonte: Elaborado pela autora.

Os grupos são identificados como Grupo 1, Grupo 2, e assim por diante, até o Grupo 5. Após a formação dos grupos, é possível confirmá-lo clicando no botão "Formar Grupo", localizado abaixo de cada grupo formado.

6.4 Considerações sobre o capítulo

Este capítulo apresentou um protótipo do modelo Athena, discutiu a avaliação e os resultados obtidos com dois serviços inteligentes que utilizam históricos de contextos. O *Forecasting* é um serviço inteligente projetado para prever o desempenho acadêmico dos alunos, enquanto o *Grouping* é voltado para a formação de grupos de estudo.

Foi implementado uma estrutura *web* para validar dois serviços inteligentes. A avaliação concentrou-se na previsão de reprovação ou evasão dos alunos com base em seus históricos de contextos, bem como, na formação de grupos de estudo, demonstrando assim a capacidade do modelo Athena.

7 CONCLUSÃO

Serviços inteligentes na EaD têm modificado a forma como as pessoas aprendem e interagem com o conhecimento. Com o crescimento da tecnologia e o desenvolvimento de algoritmos cada vez mais sofisticados, a educação a distância se tornou mais personalizada, adaptativa e acessível. Os serviços inteligentes têm o objetivo comum de tornar as operações mais eficientes, os produtos e serviços mais personalizados e a experiência do usuário mais conveniente e gratificante.

Desta forma, esta tese apresentou o ATHENA, um modelo computacional para serviços inteligentes na educação a distância usando históricos de contextos. O modelo fundamenta-se na oferta de serviços inteligentes que auxiliem tanto os professores e gestores quanto os alunos nos processos de ensino e aprendizagem. Este capítulo apresenta as considerações finais do trabalho, ressalta suas contribuições, descreve as limitações e destaca os trabalhos futuros e publicações desta tese.

7.1 Considerações Finais

O mapeamento sistemático revelou uma ampla gama de serviços oferecidos na área da EaD e foi crucial para identificar trabalhos relacionados à proposta do Athena. Isso permitiu a comparação dos critérios e a identificação das principais diferenças e contribuições do modelo proposto. Ao examinar os estudos comparativos, disponíveis na tabela 10, foi observado que os trabalhos apresentados geralmente se concentram em modelos computacionais para serviços específicos, em contraste com a abordagem mais genérica do Athena. Além disso, esses estudos não levam em consideração a utilização de históricos de contextos.

Também foi conduzido um estudo sobre ontologias destinadas à educação a distância e serviços inteligentes, fazendo uso de históricos de contextos. Ao comparar os resultados, apresentados na tabela 11, é evidente que existem várias ontologias voltadas para a educação a distância. No entanto, essas ontologias não abordam especificamente serviços inteligentes nem fazem uso de históricos de contextos. Nesse sentido, destaca-se a OntoAthena pela sua abordagem na modelagem do conhecimento direcionado aos educadores da educação a

distância, usando de históricos de contextos e serviços inteligentes, com o propósito de oferecer suporte nos processos de ensino e aprendizagem.

A avaliação do modelo Athena ocorre por meio da apresentação de dois serviços inteligentes voltados para professores e gestores. O primeiro, *Forecasting*, tem como objetivo analisar o desempenho acadêmico dos alunos e identificar possíveis riscos de evasão ou reprovação. Essa análise é essencial para auxiliar instituições de ensino e instrutores a identificar alunos enfrentando dificuldades ou que necessitam de apoio adicional. Já o segundo serviço, *Grouping*, foca na formação de grupos de estudo, buscando criar grupos diversificados que promovam o aprendizado colaborativo e enriquecedor.

Uma avaliação conduzida com 25 alunos matriculados em um curso superior de Tecnologia em Análise e Desenvolvimento de Sistemas permitiu a coleta e análise de dados relacionados ao perfil e contextos dos alunos. Essas informações possibilitaram a criação de históricos de contextos, os quais foram empregados na avaliação do modelo. Os testes realizados forneceram evidências que sugerem a viabilidade do uso desses históricos de contextos na previsão de reprovação e evasão, assim como na formação de grupos de estudo. O resultado, está alinhado com a principal hipótese deste estudo, que é a utilização de diferentes serviços inteligentes que se baseiam em históricos de contexto.

7.2 Contribuições

Uma vez confirmada a hipótese e respondida a questão de pesquisa, torna-se possível descrever as contribuições desta tese para as áreas da computação e educação, tanto no âmbito social, acadêmico e científico.

Socialmente, esse modelo possibilita a personalização do ensino, adaptando conteúdo e metodologia de acordo com as necessidades individuais de cada aluno. Ademais, ele auxilia na identificação de alunos com dificuldades de aprendizagem, permitindo intervenções personalizadas e promovendo melhorias no processo de ensino e aprendizagem.

Academicamente, esse modelo impulsiona a pesquisa em dados educacionais, gerando *insights* sobre padrões de aprendizagem e eficácia de intervenções. Ele também inspira o desenvolvimento de novas metodologias pedagógicas, promove a análise e aprimoramento contínuo dos serviços educacionais e fomenta a colaboração interdisciplinar entre professores e alunos.

O desenvolvimento da tese contribuiu com:

- Criação do modelo Athena e avaliação de dois serviços inteligentes;
- Desenvolvimento de um mapa conceitual para educação a distância. A principal contribuição do mapa conceitual reside na representação gráfica dos conceitos abordados nesta tese, que incluem educação a distância, ambiente virtual de aprendizagem, acompanhamento, prevenção e apoio a práticas educacionais. O mapa conceitual desenvolvido descreveu um conjunto de conceitos e relações que fundamentaram a construção da OntoAthena. Essa abordagem foi adotada devido à capacidade da estrutura gráfica do mapa em organizar ideias, conceitos, informações e relações de forma visual e organizada.
- Criação da Ontologia OntoAthena. Desenvolvida para representar o conhecimento no domínio da educação a distância e ofertas de serviços inteligentes baseados em elementos do contexto dos alunos que são utilizados na composição de históricos de contextos.
- Ainda foram conduzidos estudos, incluindo um mapeamento sistemático sobre análise de dados e serviços inteligentes na educação a distância; um mapeamento sistemático com ênfase na análise de aprendizagem e grupos colaborativos; uma revisão da literatura centrada em serviços inteligentes para identificar sua aplicação no ensino a distância.

O diferencial científico do Athena reside na aplicação de dados contextuais, como acessos, interações em fórum, *chats* e *meet*, envio de atividades, entre outros para proporcionar suporte educacional através de ofertas de diferentes serviços inteligentes.

Os principais diferenciais científicos incluem: a) análise contextual através do uso dos históricos de contextos para captar o comportamento e desempenho dos alunos e verificar suas necessidades educacionais; b) identificar os sinais precoces de dificuldades, realizar intervenções rápidas e eficazes antes dos problemas se agravarem; c) fornecer suporte personalizado e identificar problemas precocemente, diminuindo as taxas de reprovação e evasão, melhorando os resultados acadêmicos gerais. Esses diferenciais destacam o modelo computacional como uma ferramenta inovadora que utiliza dados contextuais para melhorar significativamente a eficácia e a personalização da educação a distância, promovendo uma aprendizagem mais envolvente e bem-sucedida.

7.3 Limitações e trabalhos futuros

A elaboração de um modelo computacional, assim como qualquer produção intelectual, pode ser impactada pelo viés do pesquisador, o que implica que certos aspectos que podem ter sido inadvertidamente menosprezados em comparação com outros, e, portanto, estão abertos a debate.

Algumas limitações do modelo Athena são destacadas a seguir:

- Escolha das informações que compõem os históricos de contextos dos alunos.
- O mapa conceitual foi criado através da elaboração de uma tabela contendo perguntas e respostas sobre EaD. Cada pergunta foi respondida por meio de pesquisa no ambiente virtual *Moodle* e pela experiência pessoal da autora. No entanto, embora tenham sido formuladas 19 perguntas, a ausência de contribuições de profissionais da educação pode ter limitado a representação do conhecimento relacionado ao suporte educacional em EaD.
- A ontologia foi desenvolvida seguindo a metodologia *Ontology Development 101*, que permitiu a definição e estruturação da OntoAthena por meio de um conjunto bem definido de etapas. Outro sim, a teoria dos mapas conceituais foi empregada para organizar e representar o conhecimento de forma abrangente, auxiliando na construção da ontologia. Entretanto, a avaliação da ontologia não contou com a participação de especialistas em EaD. A contribuição de especialistas nesse campo pode ser valiosa para avaliar o conhecimento modelado, as questões de competências formuladas e os resultados obtidos na avaliação.

Com base nos resultados obtidos pela avaliação do Athena, é possível explorar novas oportunidades e projetos futuros:

- Avaliar a OntoAthena com especialistas em EaD;
- Avaliar o modelo em um cenário com uma quantidade maior de dados;
- Desenvolver todos os serviços inteligentes integralmente;
- Integrar o Athena no ambiente virtual *moodle* ou outros ambientes virtuais de aprendizagem.

7.4 Publicações

Partes desta tese incluindo o mapeamento sistemático da literatura e o desenvolvimento de uma ontologia foram temas de artigos publicados:

Silva, L. M. D., Barbosa, J. L. V., Rigo, S. J., Larentis, A. V., Monteiro, E. S. (2023). *OntoAthena: an ontology for intelligent services in distance education*. International Journal of Metadata, Semantics and Ontologies, 16(3), 251-259. DOI: <https://doi.org/10.1504/IJMSO.2024.10061855>

Silva, L. M.; Barbosa, J. L. V.; Rigo, S. J. (2021) *Data Analysis and Intelligent Services Applied in Distance e Education: a systematic mapping* (Análise de Dados e Serviços Inteligentes Aplicados na Educação à Distância: um mapeamento sistemático). *Brazilian Journal of Computers in Education* (Revista Brasileira de Informática na Educação - RBIE), 29, 331-357. DOI: <http://dx.doi.org/10.5753/rbie.2021.29.0.331>.

Da Silva, Lidia; DIAS, Lucas; Barbosa, Jorge; Rigo, Sandro; ANJOS, Julio Geyer, Claudio Leithardt, Valderi. (2021). *Learning analytics and collaborative groups of learners in distance education*. DOI: <https://doi.org/10.15388/infedu.2022.05>.

Da Silva, L.M.; Dias, L.P.S.; Rigo, S.; Barbosa, J.L.V.; Leithardt, D.R.F.; Leithardt, V.R.Q. *A Literature Review on Intelligent Services Applied to Distance Learning*. Educ. Sci. 2021, 11, 666. DOI: <https://doi.org/10.3390/educsci11110666>.

Além dos artigos específicos da tese, também foram publicados outros em parceria com colegas do doutorado, sendo:

Brites, I.S.G.; da Silva, L.M.; Barbosa, J.L.V.; Rigo, S.J.; Correia, S.D.; Leithardt, V.R.Q. *Machine Learning and IoT Applied to Cardiovascular Diseases Identification through Heart Sounds: A Literature Review*. Informatics 2021, 8, 73. DOI: <https://doi.org/10.3390/informatics8040073>.

Brites, I., Silva, L., Rigo, S. e Barbosa, J. 2022. Aplicação da internet das coisas e aprendizado de máquina na identificação de doenças cardíacas pelas bulhas: um mapeamento sistemático. Revista Brasileira de Computação Aplicada. 14, 1 (mar. 2022), 16-29. DOI: <https://doi.org/10.5335/rbca.v14i1.1291>.

Monteiro ES, Righi R. da Rosa, Rigo S, Barbosa JLV, da Silva LM, Larentis AV. *Ontology for pervasive traceability of agrochemicals. Ontology of designing.* 2023; 13(2): 217-231. DOI: <https://doi.org/10.18287/2223-9537-2023-13-2-217-231>

Emiliano Monteiro, Rodrigo da Rosa Righi, Jorge Luis Victória Barbosa, Perla Haydée da Silva, Lídia Martins da Silva, Maria Eloisa Mignoni. *Evasão Blockchain Ethereum como plataforma para o combate à evasão escolar em tempos de COVID-19.* Volume 5, número 1, dezembro de 2021. Revista Eletrônica. ISSN: 2595.8178. <http://revista.institutoinvest.edu.br/index.php/revistainvest/article/view/62>.

REFERÊNCIAS

- A. EL MOUSTAMID, E. EN-NAIMI, J. (2017). El BOUHDIDI. Integration of data mining techniques in e-learning systems: Clustering Profil of Lerners and Recommender Course System. In **Proceedings of the 2nd international Conference on Big Data, Cloud and Applications** (BDCA'17). Association for Computing Machinery, New York, NY, USA, Article 97, 1–4. DOI: <https://doi.org/10.1145/3090354.3090453>
- ABOWD, G. D.; MYNATT, E. D. (2000). Charting past, present, and future research in ubiquitous computing. **ACM Trans. Comput.-Hum. Interact.** 7, 1 (March 2000), 29–58. DOI: <https://doi.org/10.1145/344949.344988>
- ACATECH (2018). **Smart service welt 2018 - Wo stehen wir? wohin gehen wir?** Disponível em: <https://www.acatech.de/publikation/smart-service-welt-2018-wo-stehen-wir-wohin-gehen-wir/>. Acesso em: mai 27 2021.
- AKHARRAZ, L.; EL MEZOUARY, A.; MAHANI, Z. (2018). To context-aware learner modeling based on ontology. **IEEE Global Engineering Education Conference (EDUCON)**, Santa Cruz de Tenerife, Spain, 2018, pp. 1326-1334, DOI: 10.1109/EDUCON.2018.8363383.
- ALDOWAH, H.; AL-SAMARRAIE, H.; FAUZY, W. M. (2019). Educational Data Mining and Learning Analytics for 21st century higher education: A Review and Synthesis. **Telematics and Informatics**. DOI: <https://doi.org/10.1016/j.tele.2019.01.007>.
- ALENCAR, M.; MAGALHAES NETTO, J. (2020). Improving Learning in Virtual Learning Environments Using Affective Pedagogical Agent. **International Journal of Distance Education Technologies**. 18. 1-16. DOI: 10.4018/IJDET.2020100101.
- ALEXANDRA, M.; ALVARENGA, L.; OLIVEIRA, A. (2004). O nível do conhecimento e os instrumentos de representação: tesouros e ontologias. **Datagramazero**, [S.l.], v. 5, p. 1, 01. 2004.
- ALLMENDINGER, G.; LOMBREGLIA, R. Four strategies for the age of smart services. (2005). **Harvard business review**. v. 83, p. 131–4, 136, 138 passim.

ALMEIDA MAIA, M. D. S. de; SILVA, D. G. (2020). Práticas pedagógicas em ambientes virtuais de aprendizagem: usos e abusos. **Em Rede-Revista de Educação a Distância**, [S.l.], v. 7, n. 1, p. 81–95. DOI: <https://doi.org/10.53628/emrede.v7i1.555>.

ALMEIDA NETO, F. A. D. **Um Framework para Criação de Serviços Inteligentes em Ambientes Flexíveis na Web.** (2017). 1-216 p. Disponível em: https://oasisbr.ibict.br/vufind/Record/BRCRIS_41ffdbd90c56112e3b4e30b876a54969.

ALSHAMMARI, M. (2020). Design and evaluation of an adaptive framework for virtual learning environments. **International Journal of ADVANCED AND APPLIED SCIENCES**, [S.l.], v. 7, p. 39–51. DOI: <https://doi.org/10.21833/ijaas.2020.05.006>.

ALTAF, S.; SOOMRO, W.; RAWI, M. I. M. (2019). Student Performance Prediction using Multi-Layers Artificial Neural Networks: A Case Study on Educational Data Mining. **In Proceedings of the 2019 3rd International Conference on Information System and Data Mining (ICISDM '19)**. Association for Computing Machinery, New York, NY, USA, 59–64. DOI: <https://doi.org/10.1145/3325917.3325919>.

ANAYA, A. R.; LUQUE, M.; GARCÍA-SAIZ, T. (2013). Recommender system in collaborative learning environment using an influence diagram. **Expert Systems with Applications**, [S.l.], v. 40, n. 18, p. 7193–7202. DOI: <https://doi.org/10.1016/j.eswa.2013.07.030>.

ANDRADE, T. L. de; RIGO, S. J.; BARBOSA, J. L. V. (2022). Active Methodology, Educational Data Mining and Learning Analytics: a systematic mapping study. **Informatics in Education**. 20 no. 2, 171-204, DOI: <https://doi.org/10.15388/infedu.2021.09>.

ANGELINE, D. M. D.; RAMASUBRAMANIAN, P.; JAMES, I. S. P. (2020). The Discriminant Analysis Approach for Evaluating Effectiveness of Learning in an Instructor-Led Virtual Classroom. **International Journal on Smart Sensing and Intelligent Systems**, Sydney, v. 13, n. 1, p. 1–15, 2. DOI: <https://doi.org/10.21307/ijssis-2020-035>.

ANJOS, R. A. V. (2015). **Referencial Pedagógico Para Análise de Ambientes Virtuais de Aprendizagem**. Disponível m: <http://ri.ufmt.br/handle/1/74>.

ARANDA, J. A. S.; BAVARESCO, R. S.; CARVALHO, J. V. et al. (2023). A computational model for adaptive recording of vital signs through context histories. **J Ambient Intell Human Comput.** 14, 16047–16061 (2023). DOI: <https://doi.org/10.1007/s12652-021-03126-8>.

ARAÚJO, W. J. **Proposta Metodológica para Enriquecimento de Ontologias de Domínio.** 2021. 1-275 p. <http://hdl.handle.net/1843/38983>.

AZZI, I., JEGHAL, A., RADOUANE, A. et al. (2020). A robust classification to predict learning styles in adaptive E-learning systems. **Education and Information Technologies.** V. 25, 437–448 (2020). DOI: <https://doi.org/10.1007/s10639-019-09956-6>.

BALDERAS, A.; RUIZ-RUBE, I.; PALOMO-DUARTE, M.; DODERO, J. M. (2013). A Generative Computer Language to Customize Online Learning Assessments. In: **Hernández-Leo, D., Ley, T., Klamma, R., Harrer, A. (eds) Scaling up Learning for Sustained Impact. EC-TEL 2013.** Lecture Notes in Computer Science, vol 8095. Springer, Berlin, Heidelberg. DOI: https://doi.org/10.1007/978-3-642-40814-4_66.

BAONZA, M. (2010). NeOn Methodology for Building Ontology Networks: **Specification, Scheduling and Reuse.**

BARBOSA, J.; TAVARES, J.; CARDOSO, I.; ALVES, B.; MARTINI, B. (2018). TrailCare: an indoor and outdoor context-aware system to assist wheelchair users. **International Journal of Human-Computer Studies,** v. 116, p. 1–14, ISSN 1071-5819, DOI: <https://doi.org/10.1016/j.ijhcs.2018.04.001>.

BARLYBAYEV, A.; KADERKEYEVA, Z.; BEKMANOVA, G.; SHARIPBAY, A.; OMARBEKOVA, A.; ALTYNBEK, S. (2020) Intelligent System for Evaluating the Level of Formation of Professional Competencies of Students, in **IEEE Access**, vol. 8, pp. 58829-58835, 2020, DOI: <https://doi.org/10.1109/ACCESS.2020.2979277>.

BERGDAHL, N.; NOURI, J. (2021). Covid-19 and Crisis-Prompted Distance Education. in **Sweden. Technology, Knowledge and Learning,** v. 26, n. 3, p. 443–459, Sep 2021. DOI: <https://doi.org/10.1007/s10758-020-09470-6>.

BERTIZ, Y.; KOCAMAN KAROGLU, A. (2020). Distance Education Students Cognitive Flexibility Levels and Distance Education Motivations. **International Journal of Research in Education and Science, (IJRES)**, 6(4), 638-648. DOI: <https://doi.org/10.46328/ijres.v6i4.1022>.

BEVERUNGEN, D., MÜLLER, O., MATZNER, M. et al. Conceptualizing smart service systems. **Electron Markets** 29, 7–18 (2019). DOI: <https://doi.org/10.1007/s12525-017-0270-5>.

BEZERRA, C.; FREITAS, F.; SANTANA DA SILVA, F. (2013). CQChecker: A Tool to Check the Satisfaction of Description Logic Competency Questions on Ontologies.

BIKAKIS, N., TSINARAKI, C., GIOLDASIS, N., STAVRAKANTONAKIS, I., CHRISTODOULAKIS, S. (2013). The XML and Semantic Web Worlds: Technologies, Interoperability and Integration: A Survey of the State of the Art. In: **Anagnostopoulos, I., Bieliková, M., Mylonas, P., Tsapatsoulis, N. (eds) Semantic Hyper/Multimedia Adaptation. Studies in Computational Intelligence**, vol 418. Springer, Berlin, Heidelberg. DOI: https://doi.org/10.1007/978-3-642-28977-4_12.

BOLOCK, A. El.; ABDENNADHER, S.; HERBERT, C. An Ontology-Based Framework for Psychological Monitoring in Education During the COVID-19 Pandemic. **Frontiers in Psychology**, v. 12, 2021. ISSN=1664-1078. DOI: <https://doi.org/10.3389/fpsyg.2021.673586>. <https://www.frontiersin.org/journals/psychology/articles/10.3389/fpsyg.2021.673586>.

BOUREKKACHE, S.; KAZAR, O.; ABIK, M.; TIGANE, S.; KAHLOUL, L. Ontology based approach for representing the learner profile and learning styles, 2019. **Third International Conference on Intelligent Computing in Data Sciences (ICDS)**, Marrakech, Morocco, 2019, pp. 1-6, DOI: <https://doi.org/10.1109/ICDS47004.2019.8942276>.

BRASIL. DECRETO Nº 9.057, DE 25 DE MAIO DE 2017. **Diário Oficial [da] República Federativa do Brasil**, Brasília, DF, 2017. https://www.planalto.gov.br/ccivil_03/_ato2015-2018/decreto/d9057.htm.

BREITMAN, K.; CASANOVA, M. A.; TRUSZKOWSKI, W. Semantic web: concepts, technologies and applications. [S.l.]: **Springer Science & Business Media**, 2007.

CAMBRUZZI, W. L.; RIGO, S.; BARBOSA, J. (2015). Dropout Prediction and Reduction in Distance Education Courses with the Learning Analytics Multitrail Approach. **Journal of Universal Computer Science**. 21. 23-47. DOI: <https://doi.org/10.3217/jucs-021-01-0023>.

CAMPOS, A.; HOLLERWEGER, L.; SANTOS, G.; FARIAS, A. F.; BEHAR, P. A. Mapeamento de Soluções tecnológicas em Sistemas de Recomendação Educacionais em âmbito brasileiro. **Informática na Educação: teoria & prática**, Porto Alegre, v. 20, n. 3, p. 79-96, set./dez. 2017.

CARCHEDI, L. C.; SOUZA; BARRÉRE, E.; MENDONÇA, F. M., SOUZA, J. F. (2018). Onto4LA: uma ontologia para integração de dados educacionais. **II Congresso Brasileiro de Informática na Educação (CBIE 2018) Anais dos Workshops do VII Congresso Brasileiro de Informática na Educação (WCBIE, 2018)**. DOI: 10.5753/cbie.wcbie.2018.439. <http://repositorio.ufc.br/handle/riufc/44031>.

CARLOS, D.; NETO, A.; MENDES NETO, F.; MONTEIRO, B.; DANTAS, S.; SANTOS, I. (2019). **Ontologia para o mapeamento semântico entre ambientes virtuais de aprendizagem e ambiente de aprendizagem ubíqua**. 1761. DOI: 10.5753/cbie.sbie.2019.1761.

CHAFFAI, A.; HASSOUNI, L.; ANOUN, H. (2017). E-Learning Real Time Analysis Using Large Scale Infrastructure. **In Proceedings of the 2nd international Conference on Big Data, Cloud and Applications (BDCA'17)**. Association for Computing Machinery, New York, NY, USA, Article 23, 1–6. DOI: <https://doi.org/10.1145/3090354.3090378>.

CHANAA, A.; FADDOULI, N.-e. E. Deep Learning for a Smart e-Learning System. (2018). **4th International Conference on Cloud Computing Technologies and Applications (Cloudtech)**, Brussels, Belgium, 2018, pp. 1-8, DOI: <https://doi.org/10.1109/CloudTech.2018.8713335>.

CHANG, M.; D'ANIELLO, G.; GAETA, M.; ORCIUOLI, F.; SAMPSON, D.; SIMONELLI, C. (2020). Building Ontology-Driven Tutoring Models for Intelligent Tutoring Systems Using Data Mining. **IEEE Access**, vol. 8, pp. 48151-48162, 2020, DOI: <https://doi.org/10.1109/ACCESS.2020.2979281>.

CHANG, Y.-C.; CHU, C.-P. Applying learning behavioral Petri nets to the analysis of learning behavior in web-based learning environments. (2010). **Information Sciences**, Volume 180, Issue 6, 2010, Pages 995-1009, ISSN 0020-0255. DOI: <https://doi.org/10.1016/j.ins.2009.11.022>.<https://www.sciencedirect.com/science/article/pii/S002025509004927>.

CHEN, H.; YIN, C.; LI, R.; RONG, W.; XIONG, Z.; DAVID, B. (2020). Enhanced learning resource recommendation based on online learning style model, in **Tsinghua Science and Technology**, vol. 25, no. 3, pp. 348-356, June 2020, DOI: <https://doi.org/10.26599/TST.2019.9010014>.

CHEN, Y.; ZHENG, Q.; JI, S.; TIAN, F.; ZHU, H.; LIU, M. (2020). Identifying at-risk students based on the phased prediction model. **Knowledge and Information Systems**. 62. DOI: <https://doi.org/10.1007/s10115-019-01374-x>.

CHUNG, S.-H.; TAI, W.; O'SULLIVAN, D.; BORAN, A. (2018). The MOUSE approach: mapping ontologies using UML for system engineers. Computer Reviews Journal Vol 1 No 1 (2018) ISSN: 2581-6640. Disponível em: <http://purkh.com/index.php/tocomp>.

CLARIZIA, F.; COLACE, F.; DE SANTO, M.; LOMBARDI, M.; PASCALE, F.; PIETROSANTO, A. (2018). E-learning and sentiment analysis: a case study. 111-118. DOI: <https://doi.org/10.1145/3178158.3178181>.

CLOW, D. (2013). An overview of learning analytics. **Teaching in Higher Education**, 18(6), 683–695. DOI: <https://doi.org/10.1080/13562517.2013.827653>.

CUMMAUDO, A.; VASA, R.; GRUNDY, J.; ABDELRAZEK, M.; CAIN, A. (2019). Losing Confidence in Quality: Unspoken Evolution of Computer Vision Services, 2019 **IEEE International Conference on Software Maintenance and Evolution (ICSME)**, Cleveland, OH, USA, 2019, pp. 333-342. DOI: <https://doi.org/10.1109/ICSME.2019.00051>.

DAHDOUH, K.; DAKKAK, A.; OUGHDIR, L.; IBRIZ, A. (2019). Large-scale e-learning recommender system based on Spark and Hadoop. **Journal of Big Data**, 6, 2 (2019). DOI: <https://doi.org/10.1186/s40537-019-0169-4>.

- DAHDOUH, K.; DAKKAK, A.; OUGHDIR, L.; MESSAOUDI, F. (2018). Big data for online learning systems. ***Education and Information Technologies***, 23, 2783–2800 (2018). DOI: <https://doi.org/10.1007/s10639-018-9741-3>.
- DAWSON, S.; JOKSIMOVIC, S.; POQUET, O.; SIEMENS, G. (2019). Increasing the Impact of Learning Analytics. In ***Proceedings of the 9th International Conference on Learning Analytics & Knowledge (LAK19)***. Association for Computing Machinery, New York, NY, USA, 446–455. DOI: <https://doi.org/10.1145/3303772.3303784>.
- DA SILVA, L.; BARBOSA, J.; RIGO, S. (2021). Análise de Dados e Serviços Inteligentes Aplicados na Educação à Distância: um mapeamento sistemático. ***Revista Brasileira de Informática na Educação***. 29. 331-357. DOI: <https://doi.org/10.5753/rbie.2021.29.0.331>.
- DA SILVA, L. M.; DIAS, L. P. S.; RIGO, S.; BARBOSA, J. L. V.; LEITHARDT, D. R. F., LEITHARDT, V. R. Q. (2021). A Literature Review on Intelligent Services Applied to Distance Learning. ***Education Sciences*** 11, no. 11: 666. DOI: <https://doi.org/10.3390/educsci11110666>.
- DA SILVA, L.; DIAS, L.; BARBOSA, J.; RIGO, S. ANJOS, J.; GEYER, C.; LEITHARDT, V. (2021). Learning analytics and collaborative groups of learners in distance education: a systematic mapping study. ***Informatics in Education***. 21. DOI: <https://doi.org/10.15388/infedu.2022.05>.
- DA SILVA, Lídia Martins, BARBOSA, Jorge Luis Victória, RIGO, Sandro José, LARENTIS, Andrêsa Vargas, and MONTEIRO, Emiliano Soares. (2024). OntoAthena: an ontology for intelligent services in distance education. ***Int. J. Metadata Semant. Ontologies*** 16, 3 (2023), 251–259. DOI: <https://doi.org/10.1504/ijmso.2023.137178>.
- DE NICOLA, A.; MISSIKOFF, M.; NAVIGLI, R. (2005). A Proposal for a Unified Process for Ontology Building: UPON. In: Andersen, K.V., Debenham, J., Wagner, R. (eds) Database and Expert Systems Applications. DEXA 2005. Lecture Notes in Computer Science, vol 3588. Springer, Berlin, Heidelberg. DOI: https://doi.org/10.1007/11546924_64.
- DEAMBROSIS, M.; MOTZ, R.; ELISEO, M. (2021). UDL Ontology: ***an ontology for education in the diversity***. 2021. p. 244–254. DOI: https://doi.org/10.1007/978-3-030-72660-7_24.

- DEY, A. **Understanding and Using Context. Personal and Ubiquitous Computing.** v. 5, n. 1, p. 4–7, Feb 2001. DOI: <https://doi.org/10.1007/s007790170019>.
- DIAS, R. S. (2017). Caracterização do Learning Analytics na Educação a Distância - **Anais do Seminário de Pesquisa e Inovação Tecnológica - SEPIT.** 2017.
- DIMOPOULOS, I.; PETROPOULOU, O.; RETALIS, S. (2013). Assessing students' performance using the learning analytics enriched rubrics. In **Proceedings of the Third International Conference on Learning Analytics and Knowledge (LAK '13).** Association for Computing Machinery, New York, NY, USA, 195–199. DOI: <https://doi.org/10.1145/2460296.2460335>.
- DUPONT, D.; BARBOSA, J. L. V.; ALVES, B. M. (2020). CHSPAM: a multi-domain model for sequential pattern discovery and monitoring in contexts histories. *Pattern Anal Applic* 23, 725–734 (2020). DOI: <https://doi.org/10.1007/s10044-019-00829-9>.
- D'AVILA, L. F.; FARIAS, K.; BARBOSA, J. L. V. (2020). Effects of contextual information on maintenance effort: a controlled experiment. **Journal of Systems and Software**, v. 159, p. 110443, 2020, 110443, ISSN 0164-1212. DOI: <https://doi.org/10.1016/j.jss.2019.110443>. <https://www.sciencedirect.com/science/article/pii/S0164121219302171>.
- ECHARTE, F., ASTRAIN, J. J., CÓRDOBA, A. & VILLADANGOS, J. E. (2007). Ontology of Folksonomy: A New Modelling Method. In **S. Handschuh, N. Collier, T. Groza, R. Dieng, M. Sintek & A. de Waard (eds.),** SAAKM: CEUR-WS.org.
- EL FOUKI, M.; AKNIN, N.; EL. KADIRI, K. E. (2017). Intelligent Adapted eLearning System based on Deep Reinforcement Learning. In **Proceedings of the 2nd International Conference on Computing and Wireless Communication Systems (ICCWCS'17).** Association for Computing Machinery, New York, NY, USA, Article 85, 1–6. DOI: <https://doi.org/10.1145/3167486.3167574>.
- FALBO, R. (2014). SABiO: Systematic approach for building ontologies. **CEUR Workshop Proceedings**, v. 1301, 01 2014.
- FAQIHI, B.; DAOUDI, N.; AJHOUN, R. (2019). Proposition of the recommendation system for the author based on similarity degrees, **2019 1st International Conference on Smart**

Systems and Data Science (ICSSD), Rabat, Morocco, 2019, pp. 1-7, DOI: <https://doi.org/10.1109/ICSSD47982.2019.9002699>.

FERNÁNDEZ-LÓPEZ, M.; GOMEZ-PEREZ, A.; PAZOS, A.; PAZOS, J. (1999). Building a chemical ontology using Methontology and the Ontology Design Environment, in **IEEE Intelligent Systems and their Applications**, vol. 14, no. 1, pp. 37-46, Jan.-Feb. 1999, DOI: <https://doi.org/10.1109/5254.747904>.

FLACH, L. **Uso de algoritmos de machine learning para prever a evasão escolar no ensino superior: um estudo no Instituto Federal de Santa Catarina**. Dissertação (mestrado profissional) - Universidade Federal de Santa Catarina, Centro Sócio-Econômico, Programa de Pós-Graduação em Administração Universitária, Florianópolis, 2022. Disponível em: <https://repositorio.ufsc.br/handle/123456789/238320>.

FILHO, F. W. B. H; LÓSCIO, B. F; DE CAMPOS, G. L. (2008). Inferência sobre Ontologias no contexto da Web Semântica. In: **Congresso Tecnológico InfoBrasil**, Fortaleza, 2008.

FILIPPETTO, A. S. (2020). **Átropos: um modelo para predição de riscos em projetos baseado em históricos de contextos**. 2020. Tese doutorado. Disponível em: <http://www.repositorio.jesuita.org.br/handle/UNISINOS/9098>.

FILIPPETTO, A. S.; LIMA, R.; BARBOSA, J. L. V. (2021). A risk prediction model for software project management based on similarity analysis of context histories. **Information and Software Technology**, v. 131, p. 106497, 2021. ISSN: 0950-5849, DOI: 10.1016/j.infsof.2020.106497. <https://www.sciencedirect.com/science/article/pii/S0950584920302391>.

FLORIAN, B.; GLAHN, C.; DRACHSLER, H.; SPECHT, M.; FABREGAT GESA, R. (2011). Activity-Based Learner-Models for Learner Monitoring and Recommendations in Moodle. **Business Strategy and The Environment**. 6964. 111-124. DOI: https://doi.org/10.1007/978-3-642-23985-4_10.

FRANK, M.; RABE, M.; KOLDEWEY, C.; DUMITRESCU, R.; GAUSEMEIER, J.; REINHOLD, J. (2019). Classification-based Planning of Smart Service Portfolios. **This paper was presented at ISPIM Connects Ottawa**, Ottawa, Canadá on 7-10 April 2019. The publication is available to ISPIM members at www.ispim.org.

FREITAS, F. A. d. S.; VASCONCELOS, F. F. X.; PEIXOTO, S. A.; HASSAN, M. M.; DEWAN, M. A. A.; ALBUQUERQUE, V. H. C. d.; FILHO, P. P. R. (2020) IoT System for School Dropout Prediction Using Machine Learning Techniques Based on Socioeconomic Data. **Electronics**, v. 9, n. 10: 1613. DOI: <https://doi.org/10.3390/electronics9101613>.

GARCIA MARTINS, M.; NESI, L.; SILVA PEREIRA, P. R. d.; BARBOSA, J. L. V. (2021). DELFOS: A Model for Multitemporal Analysis based on Contexts History, in **IEEE Latin America Transactions**, vol. 19, no. 9, pp. 1478-1485, Sept. 2021, DOI: <https://doi.org/10.1109/TLA.2021.9468440>.

GAŠEVIĆ, D., KOVANOVIĆ, V.; JOKSIMOVIĆ, S. (2017). Piecing the learning analytics puzzle: a consolidated model of a field of research and practice. **Learning: Research and Practice**, 3(1), 63–78. DOI: <https://doi.org/10.1080/23735082.2017.1286142>.

GÓMEZ-PÉREZ, ASUNCIÓN, MARIANO FERNÁNDEZ-LÓPEZ, AND OSCAR CORCHO. "Methodologies and methods for building ontologies." **Ontological Engineering: with examples from the áreas of Knowledge Management, e-Commerce and the Semantic Web** (2004): 107-197.

GRAF, S.; IVES, C.; RAHMAN, N.; FERRI, A. (2011). AAT - A tool for accessing and analysing students' behaviour data in learning systems. **ACM International Conference Proceeding Series**. DOI: <https://doi.org/174-179. 10.1145/2090116.2090145>.

GRIMM, S.; WISSMANN, J. (2011). Elimination of Redundancy in Ontologies. In: THE SEMANTIC WEB: RESEARCH AND APPLICATIONS, 2011, Berlin, Heidelberg. **Anais** . . . Springer Berlin Heidelberg, 2011. p. 260–274.

GRIVOKOSTOPOULOU, F.; PERIKOS, I.; PARASKEVAS, D.; HATZILYGEROUDIS, I. (2019). An Ontology-based Approach for User Modelling and Personalization in E-Learning Systems, **2019 IEEE/ACIS 18th International Conference on Computer and Information Science (ICIS)**, Beijing, China, 2019, pp. 1-6, DOI: <https://doi.org/10.1109/ICIS46139.2019.8940269>.

GRUBER, T. R. (2009). Ontology. in the Encyclopedia of Database Systems, Ling Liu and M. Tamer Özsu (Eds.), **Springer-Verlag**, 2009.

GRUBER, T. R. Ontolingua: a mechanism to support portable ontologies. In: 1991. **Anais...**
<https://api.semanticscholar.org/CorpusID:13891298>

GRUBER, T. R. (1993). A **translation approach to portable ontology specifications**. **Knowledge Acquisition**, v. 5, n. 2, p. 199–220, 1993. issn: 1042-8143, DOI:
<https://doi.org/10.1006/knac.1993.1008>.
<https://www.sciencedirect.com/science/article/pii/S1042814383710083>.

GRÜNINGER, M.; FOX, M. (1995). Methodology for the Design and Evaluation of Ontologies. **International Joint Conference on Artificial Intelligence**,
<https://api.semanticscholar.org/CorpusID:16641142>.

GUARINO, N. **The Ontological Level**. PHILOSOPHY AND THE COGNITIVE SCIENCES, p. 443--456, 1994.

GUEDES, G. (2018). **UML 2 - Uma Abordagem Prática**. 3^a ed. Novatec Editora, 2018. ISBN ebook: 978-85-7522-644-5. Ano: 2018. p: 496.

GUIZZARDI, G. (2000). **Desenvolvimento para e com reuso**: um estudo de caso no domínio de vídeo sob demanda. 2000. 202 p. Dissertação (Mestrado em Ciência da Computação) — UFES, 2000.

GUO, C.; YAN, X.; LI, Y. (2020). Prediction of Student Attitude towards Blended Learning Based on Sentiment Analysis. In Proceedings of the 2020 9th International Conference on Educational and Information Technology (ICEIT 2020). **Association for Computing Machinery**, New York, NY, USA, 228–233. DOI: <https://doi.org/10.1145/3383923.3383930>.

HAAV, H.-M.; LUBI, T.-L. (2001). A Survey of Concept-based Information Retrieval Tools on the Web. Proc 5th East-European Conference **ADBIS**.2.

HAMADA, M. (2012). Learning Style Model for e-Learning Systems. In: Huang, R., Ghorbani, A.A., Pasi, G., Yamaguchi, T., Yen, N.Y., Jin, B. (eds) Active Media Technology. AMT 2012. Lecture Notes in Computer Science, vol 7669. **Springer**, Berlin, Heidelberg. DOI: https://doi.org/10.1007/978-3-642-35236-2_19.

HAN, Z.; XU, A. (2021). RETRACTED: Ecological evolution path of smart education platform based on deep learning and image detection, *Microprocessors and Microsystems*,

Volume 80, 2021, 103343, ISSN 0141-9331, DOI: <https://doi.org/10.1016/j.micpro.2020.103343>.
<https://www.sciencedirect.com/science/article/pii/S0141933120305020>.

HASHIM, A; AKEEL, W. KHALAF, A. (2020). Student Performance Prediction Model based on Supervised Machine Learning Algorithms. IOP Conference Series: **Materials Science and Engineering**. 928. 032019. 10.1088/1757-899X/928/3/032019.

HECKLER, W. F.; de Carvalho, J. V.; BARBOSA, J. L. V. (2020). Machine learning for suicidal ideation identification: a systematic literature review. **Computers in Human Behavior**, v. 128, p. 107095, 2022. issn: 0747-5632. DOI: <https://doi.org/10.1016/j.chb.2021.107095>.
<https://www.sciencedirect.com/science/article/pii/S0747563221004180>.

HEIJST, G. van; SCHREIBER, G.; WIELINGA, B. J. Using explicit ontologies in KBS development. **International Journal of Human-Computer Studies**. Volume 46, Issues 2–3, 1997, Pages 183-292, ISSN 1071-5819, DOI: <https://doi.org/10.1006/ijhc.1996.0090>.
<https://www.sciencedirect.com/science/article/pii/S1071581996900907>.

HELPFER, G. A. (2022). **Tellus: um modelo computacional para análise de solo na agricultura ubíqua baseado em históricos de contextos**. 2022. 127 p.
<http://www.repositorio.jesuita.org.br/handle/UNISINOS/11263>.

HERMANN S (2016). **Was sind smart services?** [video file]. Available in: <http://www.servlab.eu/?p=1333>, access: May 27 2021.

HITZLER, P. (2021). **A review of the semantic web field**. **Commun. ACM** 64, 2 (February 2021), 76–83. DOI: <https://doi.org/10.1145/3397512>.

HOSSEINI, S. S.; AGBOSSOU, K.; KELOUWANI, S.; CARDENAS, A. (2017). Non-intrusive load monitoring through home energy management systems: **a comprehensive review**. **Renewable and Sustainable Energy Reviews**, Volume 79, 2017, Pages 1266-1274, ISSN 13640321. DOI: <https://doi.org/10.1016/j.rser.2017.05.096>. <https://www.sciencedirect.com/science/article/pii/S1364032117307359>.

HUANG, Z.; LIU, Q.; ZHAI, C.; YIN, Y.; CHEN, E.; GAO, W.; HU, G. (2019). Exploring Multi-Objective Exercise Recommendations in Online Education Systems. In **Proceedings of the 28th ACM International Conference on Information and Knowledge Management (CIKM '19)**. Association for Computing Machinery, New York, NY, USA, 1261–1270. DOI: <https://doi.org/10.1145/3357384.3357995>.

HUET, A.; SEGONDS, F.; PINQUIE, R.; VERON, P.; GUEGAN, J.; MALLET, A. (2021). Context-aware cognitive design assistant: Implementation and study of design rules recommendations, **Advanced Engineering Informatics**, Volume 50, 2021, 101419, ISSN 1474-0346, DOI: <https://doi.org/10.1016/j.aei.2021.101419>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1474034621001713>.

HUSSAIN, M.; HUSSAIN, S.; ZHANG, W.; ZHU, W.; THEODOROU, P.; ABIDI, S. M. R. (2018). Mining Moodle Data to Detect the Inactive and Lowperformance Students during the Moodle Course. In **Proceedings of the 2nd International Conference on Big Data Research (ICBDR 2018)**. Association for Computing Machinery, New York, NY, USA, 133–140. DOI: <https://doi.org/10.1145/3291801.3291828>.

IATRELLIS, O.; SAVVAS, I. K.; FITSILIS, P.; GEROGIANNIS, V. C. Iatrellis O, Savvas IK, Fitsilis P, Gerogiannis VC (2021). A two-phase machine learning approach for predicting student outcomes. **Education and Information Technologies** 26(1):69–88, DOI: <https://doi.org/10.1007/s10639-020-10260-x>.

ILKOU, E.; ABU-RASHEED, H.; TAVAKOLI, M.; HAKIMOV, S.; KISMİHÓK, G.; AUER, S.; NEJDL, W. (2021). Educor: An educational and career-oriented recommendation ontology. In **Hotho, A., Blomqvist, E., Dietze, S., Fokoue, A., Ding, Y., Barnaghi, P., Haller, A., Dragoni, M., and Alani, H., editors, The Semantic Web – ISWC 2021**, pages 546–562, Cham. Springer International Publishing.

IQBAL, M.; GHAZANFAR, M. A.; SATTAR, A.; MAQSOOD, M.; KHAN, S.; MEHMOOD, I.; BAIK, S. W. (2019). Kernel Context Recommender System (KCR): A Scalable Context-Aware Recommender System Algorithm, in **IEEE Access**, vol. 7, pp. 24719-24737, 2019, DOI: <https://doi.org/10.1109/ACCESS.2019.2897003>.

ISLAM, O.; SIDDIQUI, M.; ALJOHANI, N. R. (2019). Identifying Online Profiles of Distance Learning Students Using Data Mining Techniques. In **Proceedings of the 2019 The**

3rd International Conference on Digital Technology in Education (ICDTE 2019). Association for Computing Machinery, New York, NY, USA, 115–120. DOI: <https://doi.org/10.1145/3369199.3369249>.

JOKSIMOVIC, S.; KOVANOVIC, V.; DAWSON, S. (2019). The Journey of Learning Analytics., [S.l.], v. 6, p. 37–63, 01 2019. JOVANOVIC, J.; DAWSON, S.; JOKSIMOVIC, S.; SIEMENS, G. (2020). Supporting actionable intelligence: reframing the analysis of observed study strategies. In **Proceedings of the Tenth International Conference on Learning Analytics & Knowledge (LAK '20)**. Association for Computing Machinery, New York, NY, USA, 161–170. DOI: <https://doi.org/10.1145/3375462.3375474>.

JOY, J.; RAJ, N. S.; G, R. V. (2019). An ontology model for content recommendation in personalized learning environment. In **Proceedings of the Second International Conference on Data Science, E-Learning and Information Systems (DATA'19)**. Association for Computing Machinery, New York, NY, USA, Article 9, 1–6. DOI: <https://doi.org/10.1145/3368691.3368700>.

KAPEMBE, S. S.; QUENUM, J. G. (2019). A Personalised Hybrid Learning Object Recommender System. 2019, isbn 9781450362382, **Association for Computing Machinery**, New York, NY, USA. DOI: <https://doi.org/10.1145/3297662.3365810>.

KARA, M.; ERDOGDU, F.; KOKOC, M.; CAGILTAY, K. (2019). Challenges faced by adult learners in online distance education: A literature review. **Open Praxis**, 11(1), 5–22. <https://search.informit.org/doi/10.3316/informit.234110355704611>.

KHOSRAVI, H.; SADIQ, S.; GASEVIC, D. (2020) Development and adoption of an adaptive learning system: Reflections and lessons learned. In: **Proceedings of the 51st ACM Technical Symposium on Computer Science Education**, Association for Computing Machinery, New York, NY, USA, SIGCSE '20, p 58–64, DOI: <https://doi.org/10.1145/3328778.3366900>.

KIM, W.; KIM, J. (2020). Individualized AI Tutor Based on Developmental Learning Networks, in **IEEE Access**, vol. 8, pp. 27927-27937, 2020, DOI: <https://doi.org/10.1109/ACCESS.2020.2972167>.

KOLDEWEY, C., GAUSEMEIER, J., DUMITRESCU, R., EVERS, H.H., FRANK, M., REINHOLD, J. (2021). Development Process for Smart Service Strategies: Grasping the Potentials of Digitalization for Servitization. In: Schallmo, D.R.A., Tidd, J. (eds) *Digitalization. Management for Professionals.* Springer, Cham. DOI: https://doi.org/10.1007/978-3-030-69380-0_12

KOLDEWEY, C.; MEYER, M.; STOCKBRÜGGER, P.; DUMITRESCU, R.; GAUSEMEIER, J. (2020). Framework and Functionality Patterns for Smart Service Innovation, **Procedia CIRP**, Volume 91, 2020, Pages 851-857, ISSN 2212-8271, DOI: <https://doi.org/10.1016/j.procir.2020.02.244>.

KOLEKAR, S. V.; PAI, R. M.; M.M., M. P. (2018). Adaptive User Interface for Moodle based E-learning System using Learning Styles. **Procedia Computer Science**. Volume 135, 2018, Pages 606-615, ISSN 1877-0509, DOI: <https://doi.org/10.1016/j.procs.2018.08.226>. <https://www.sciencedirect.com/science/article/pii/S1877050918315229>.

KOTSIANTIS, S.; PATRIARCHEAS, K.; XENOS, M. (2010). A combinational incremental ensemble of classifiers as technique for predicting students' performance in distance education, **Knowledge-Based Systems**, Volume 23, Issue 6, 2010, Pages 529-535, ISSN 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2010.03.010>.

KOZIERKIEWICZ, A. H.; ZYSK, D. D. (2013) A Method for Determination of an Opening Learning Scenario in Intelligent Tutoring Systems. In: Selamat A., Nguyen N.T., Haron H. (eds) **Intelligent Information and Database Systems. ACIIDS 2013.** Lecture Notes in Computer Science, vol 7803. Springer, Berlin, Heidelberg. DOI: https://doi.org/10.1007/978-3-642-36543-0_14.

LAGMAN, A. C.; MANSUL, D. M. (2017). Extracting Personalized Learning Path in Adaptive E-Learning Environment Using Rule Based Assessment. In **Proceedings of the 2017 International Conference on Information Technology (ICIT 2017).** Association for Computing Machinery, New York, NY, USA, 335–340. DOI: <https://doi.org/10.1145/3176653.3176679>.

LARA, J. A.; LIZCANO, D.; MARTÍNEZ, M. A.; PAZOS, J.; RIERA, T. (2014). A system for knowledge discovery in e-learning environments within the European Higher Education Area – Application to student data from Open University of Madrid, UDIMA, **Computers &**

Education, Volume 72, 2014, Pages 23-36, ISSN 360- 1315. DOI: 10.1016/j.compedu.2013.10.009. <https://doi.org/10.1016/j.compedu.2013.10.009>.

LARENTIS, A. V.; NETO, E. G. d. A.; BARBOSA, J. L. V.; BARBOSA, D. N. F.; LEITHARDT, V. R. Q.; CORREIA, S. D. (2021). Ontology-Based Reasoning for Educational Assistance in **Noncommunicable Chronic Diseases**. **Computers** 2021, 10, 128. DOI: <https://doi.org/10.3390/computers10100128>.

LARRABEE Sonderlund, Anders & Hughes, Emily & Smith, Joanne. (2019), The efficacy of learning analytics interventions in higher education: A systematic review. **Br J Educ Technol**, 50: 2594-2618. DOI: <https://doi.org/10.1111/bjet.12720>.

LAVOIE, F. B.; PROULX, P. (2019). A Learning Management System for Flipped Courses. **In Proceedings of the 2019 The 3rd International Conference on Digital Technology in Education (ICDTE 2019)**. Association for Computing Machinery, New York, NY, USA, 73–76. DOI: <https://doi.org/10.1145/3369199.3369216>.

LEITHARDT, V. R. Q.; ROLIM, C.; ROSSETTO, A.; GEYER, C.; DANTAS, M. A. R.; SILVA, J. S.; NUNES, D. (2012). Percontrol: A pervasive system for educational environments. In: **2012 International Conference on Computing, Networking and Communications (ICNC)**, pp 131–136, DOI: <https://doi.org/10.1109/ICCNC.2012.6167396>.

LIMA, R.; FILIPPETTO, A. S.; HECKLER, W.; BARBOSA, J. L. V.; LEITHARDT, V. R. Q. (2022). Towards ubiquitous requirements engineering through recommendations based on context histories. **PeerJ Computer Science** 8: e794. DOI: <https://doi.org/10.7717/peerj-cs.794>.

LIN, J.; LI, Y.; LIAN, J. (2020). A novel recommendation system via l0-regularized convex optimization. **Neural Computing and Applications** 32(6):1649–1663, DOI <https://doi.org/10.1007/s00521-019-04213-w>.

MACHADO, S. D.; TAVARES, J. E. d. R.; MARTINS, M. G.; BARBOSA, J. L. V.; GONZÁLEZ, G. V.; LEITHARDT, V. R. Q. (2021). Ambient Intelligence Based on IoT for Assisting People with Alzheimer's Disease Through Context Histories. **Electronics** 2021, 10, 1260. DOI: <https://doi.org/10.3390/electronics10111260>.

MANHÃES, L. M. B.; CRUZ, S. M. S. DA; ZIMBRÃO, G. WAVE: (2014). WAVE: an architecture for predicting dropout in undergraduate courses using EDM. In Proceedings of the 29th Annual ACM Symposium on Applied Computing (SAC '14). **Association for Computing Machinery**, New York, NY, USA, 243–247. DOI: <https://doi.org/10.1145/2554850.2555135>.

MANOLA F., (2004). MILLER. E. **RDF Primer**. W3C Recommandation, 2004. <http://www.w3.org/TR/rdf-primer>.

MARQUARDT, K. (2017). Smart services – characteristics, challenges, opportunities and business models. **Proceedings of the International Conference on Business Excellence** 11(1):789–801, DOI: <https://doi.org/10.1515/picbe2017-0084>.

MARTINI, B. G.; HELFER, G. A.; BARBOSA, J. L. V.; ESPINOSA MODOLLO, R. C.; SILVA, M. R. FIGUEIREDO, R. M. de; MENDES, A. S.; SILVA, L. A.; LEITHARDT, V. R. Q. (2021.) **Indoorplant: A model for inteligente services in indoor agriculture based on context histories**. Sensors (Basel, Switzerland) 21(5):1631, DOI: <https://doi.org/10.3390/s21051631>.

MARZANO, A.; NOTTI, A. (2015). Eduonto: an ontology for educational assessment. **Journal of E-Learning and Knowledge Society**, 11:69–82. DOI: <https://doi.org/10.20368/1971-8829/978>.

MATCHA, W.; UZIR, N. A.; GAŠEVIC, D.; PARDO, A. (2020). A Systematic Review of Empirical Studies on Learning Analytics Dashboards: A Self-Regulated Learning Perspective, in **IEEE Transactions on Learning Technologies**, vol. 13, no. 2, pp. 226-245, 1 April-June 2020, DOI: <https://doi.org/10.1109/TLT.2019.2916802>.

MAYRHOFER, R. (2005). Context Prediction based on Context Histories: Expected Benefits, Issues and Current State-ofthe-Art. Proc. {ECHISE 2005}: **1st International Workshop on Exploiting Context Histories in Smart Environments**. Disponível em: <http://www.pervasive.ifi.lmu.de/workshops/w8/papers/echise2005-s17-ContextPredictionBasedOnContextHistories-Mayrhofer.pdf>.

MAÂLOUL, M. H.; BAHOU, Y. (2021). Learning Management System based on Machine Learning: The Case Study of Ha'il University - KSA. **International Journal of Advanced**

Computer Science and Applications. 12. DOI:
<https://doi.org/10.14569/IJACSA.2021.0120127>.

MENDES, A. S.; SILVA, L. A.; BLAS, H. S. S.; LA IGLESIA, D. H. de; ENCINAS, F. G.; LEITHARDT, V. R. Q.; GONZÁLEZ, G. V. (2021). Physical movement helps learning: Teaching using tracking objects with depth camera. In: **Rocha A, Adeli H, Dzemyda G, Moreira F, Ramalho Correia AM (eds) Trends and Applications in Information Systems and Technologies**, Springer International Publishing, Cham, pp 183–193. DOI: https://doi.org/10.1007/978-3-030-72654-6_18.

MIZOGUCHI, R.; WELKENHUYSEN, J.; IKEDA, M. (1995). **Task ontology for reuse of problem solving knowledge**. Towards Very Large Knowledge Bases.

MOHEMAD, R.; AKMA, F.; MAIZURA, N.; CHE ALHADI, A. (2020). ONT-SLD: A domain ontology for learning disability. **Indian Journal of Computer Science and Engineering**. 11. 568-581. DOI: <https://doi.org/10.21817/indjcse/2020/v11i5/201105187>.

MORAN J. M; BEHRENS, M. M. Integrar as tecnologias de forma inovadora. Moran, J. M; Behrens, MA; Masetto, MT **Novas Tecnologias e Mediação Pedagógica**, [S.l.], v. 21, p. 36–46, 2013.

NIKNAM, M., THULASIRAMAN, P. (2020). LPR: A bio-inspired intelligent learning path recommendation system based on meaningful learning theory. **Educ Inf Technol** 25, 3797–3819 (2020). DOI: <https://doi.org/10.1007/s10639-020-10133-3>

NORONHA, D. P.; FERREIRA, S. M. (2000). **Revisões de literatura**. In: CAMPOLLO, Bernadete Santos; CONDÓN, Beatriz Valadares; KREMER, Jeannette Marguerite (orgs.) **Fontes de informação para pesquisadores e profissionais**. Belo Horizonte: UFMG, 2000.

NOY, N. F.; MCGUINNESS, D. L. (2004). **Ontology development 101: A guide to creating your first ontology**. 2001. See <http://protege.stanford.edu/publications>.

NOY, N. F; CRUBEZY, M; FERGERSON, R.W; KNUBLAUCH, H; TU, S.W; VENDETTI J; MUSEN, M. A. (2003). Protégé-2000: an open-source ontology-development and knowledge-acquisition environment. **AMIA Annu Symp Proc**. 2003; 2003:953. PMID: 14728458; PMCID: PMC1480139.

- NUGURI, S. S.; CALYAM, P.; ORUCHE, R.; GULHANE, A.; VALLURIPALLY, S.; STICHTER, J.; HE, Z. (2021). vSocial: a cloud-based system for social virtual reality learning environment applications in special education. **Multimedia Tools and Applications** 80(11):16827–16856, DOI: <https://doi.org/10.1007/s11042-020-09051-w>.
- OKUBO, F.; YAMASHITA, T.; SHIMADA, A.; OGATA, H. (2017). A neural network approach for students' performance prediction. In **Proceedings of the Seventh International Learning Analytics & Knowledge Conference (LAK '17)**. Association for Computing Machinery, New York, NY, USA, 598–599. DOI: <https://doi.org/10.1145/3027385.3029479>.
- OLANREWAJU, R.; KHAN, B.; MIR, R.; BABA, A.; ANWAR, F. (2016). DFAM: A Distributed Feedback Analysis Mechanism For Knowledge Based Educational Big Data. **Jurnal Teknologi**, 78. 31-38. DOI: <https://doi.org/10.11113/jt.v78.10020>. Disponível em: <https://journals.utm.my/jurnalteknologi/article/view/10020>
- OLIVÉ, D. M.; HUYNH, D. Q.; REYNOLDS, M.; DOUGIAMAS, M.; WIESE, D. (2018). A supervised learning framework for learning management systems. In **Proceedings of the First International Conference on Data Science, E-learning and Information Systems (DATA '18)**. Association for Computing Machinery, New York, NY, USA, Article 18, 1–8. DOI: <https://doi.org/10.1145/3279996.3280014>.
- OMAR, L.; ABDESELAM, B. (2017). Applying Clustering Algorithms to Solve E-learning Problems. SIG Proceedings Paper in word Format. In **Proceedings of ACM ICCES conference**, Istanbul, Turkey, July 2017 (ICCES '17), 5 pages. DOI: <https://dl.acm.org/doi/10.1145/3129186.3129195>.
- PAI, F.-P.; HSU, I.-C.; CHUNG, Y.-C. (2016). Semantic web technology for agent interoperability: a proposed infrastructure. **Appl Intell** 44, 1–16 (2016). DOI: <https://doi.org/10.1007/s10489-015-0690-x>.
- PALUCH, S. (2017). Smart Services-Analyse von strategischen und operativen Auswirkungen. In: **Dienstleistungen 4.0: Geschäftsmodelle-Wertschöpfung-Transformation. Band 2. Forum Dienstleistungsmanagement**. Springer Fachmedien Wiesbaden, 2017. p. 161-182.

PAQUETTE G., MARINO. O.; BEJAOURI. R. (2021). A new competency ontology for learning environments personalization. **Smart Learn. Environ.** 8, 16 (2021). DOI: <https://doi.org/10.1186/s40561-021-00160-z>.

PEÑAFIEL, M.; VÁSQUEZ, S.; VÁSQUEZ, D.; ZALDUMBIDE, J.; LUJÁN-MORA, S. (2018). Data Mining and Opinion Mining: A Tool in Educational Context. In **Proceedings of the 2018 International Conference on Mathematics and Statistics (ICoMS 2018)**. Association for Computing Machinery, New York, NY, USA, 74–78. DOI: <https://doi.org/10.1145/3274250.3274263>.

PETERSEN, K.; VAKKALANKA, S.; KUZNIARZ, L. (2015). **Guidelines for conducting systematic mapping studies in software engineering: An update**, *Information and Software Technology*, Volume 64, 2015, Pages 1-18, ISSN 0950-5849, DOI: <https://doi.org/10.1016/j.infsof.2015.03.007>. <https://www.sciencedirect.com/science/article/pii/S0950584915000646>.

PICCOLO, P. (2020). **Um Sistema de Recomendação de Serviços para Uma Cidade Inteligente**. Porto Alegre: PPGC da UFRGS – 2020. 90 f.:il. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Computação. Porto Alegre, BR – RS, 2020.

PINTO, H. S.; STAAB, S.; TEMPICH, C. (2004). DILIGENT: Towards a fine-grained methodology for Distributed, Loosely-controlled and evolving Engineering of oNTologies. **Proceedings of the 16th European Conference on Artificial Intelligence (ECAI 2004)**. 393-397.

PROTÉGÉ. Disponível em: <https://protege.stanford.edu/>. Acesso em 03 fev. 2022.

QU, S.; LI, K.; ZHANG, S.; WANG, Y. (2018). Predicting Achievement of Students in Smart Campus, in **IEEE Access**, vol. 6, pp. 60264-60273, 2018, DOI: <https://doi.org/10.1109/ACCESS.2018.2875742>.

RABELO, E.; CAMPOS, F. C.; SILVA, L. M. C. (2021). Aplicação de um modelo de descoberta de conhecimento na era do Big Data. **Brazilian Journal of Production Engineering**, v. 7, n. 3, p. 106–125, ago. 2021. DOI: <https://doi.org/10.47456/bjpe.v7i3.35743>.

RAJKUMAR, R.; GANAPATHY, V. (2020) Bio-inspiring learning style chatbot inventory using brain computing interface to increase the efficiency of e-learning. **IEEE Access** 8:67377–67395, DOI: <https://doi.org/10.1109/ACCESS.2020.2984591>.

RAMALHO, R. A. S. (2010). **Desenvolvimento e utilização de ontologias em bibliotecas digitais:** uma proposta de aplicação. 2010. 1-146 p.

RAMOS, J.; SEDRAZ, J.; PRADO, L.; GOMES, A.; RODRIGUES, R. (2018). **Um estudo comparativo de classificadores na previsão da evasão de alunos em EAD.** 10.5753/cbie.sbie.2018.1463.

RAYON, A.; GUENAGA, M.; NUNEZ, A. (2014). Supporting competencyassessment through a learning analytics approach using enriched rubrics. In **Proceedings of the Second International Conference on Technological Ecosystems for Enhancing Multiculturality (TEEM '14)**. Association for Computing Machinery, New York, NY, USA, 291–298. DOI: <https://doi.org/10.1145/2669711.2669913>.

RODRIGUES, F. C.; FILIPPETTO, A. S.; LIMA, R. K. D.; HECKLER, W. F.; BARBOSA, J. L. V. (2020). Kairós: using context histories for predictions and recommendations in projects time management. **International Journal of Agile Systems and Management**, [S.l.], v. 15, n. 1, p. 31–52, 2022. DOI: <https://doi.org/10.1504/IJASM.2022.124168>.

ROMERO, C.; VENTURA, S. (2020). Educational Data Mining and Learning Analytics: **An Updated Survey**. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**. 10.1002/widm.1355.

ROS, S.; LÁZARO, J. C.; ROBLES-GÓMEZ, A.; CAMINERO, A. C.; TOBARRA, L.; PASTOR, R. (2017). Analyzing Content Structure and Moodle Milestone to Classify Student Learning Behavior in a Basic Desktop Tools Course., isbn 9781450353861, **Association for Computing Machinery**, New York, NY, USA. DOI: <https://doi.org/10.1145/3144826.3145392>.

RUANGVANICH, S.; NILSOOK, P.; WANNAPIROON, P. (2020). System Architecture of Learning Analytics in Intelligent Virtual Learning Environment. **International Journal of e-Education, e-Business, e-Management and e-Learning**. 10. 33-42. DOI: <https://doi.org/10.17706/ijeeee.2020.10.1.33-42>.

SABBIR, R.; MCGUINNESS, D. (2018). Creating and Using an Education Standards Ontology to Improve Education. **ISWC 2018 Workshop - Semantic Web for Social Good At:** Monterey, California. Disponível em: https://www.researchgate.net/publication/327867296_Creating_and_Using_an_Education_Standards_Ontology_to_Improve_Education.

SAIDA ULFA DEDDY BARNABAS LASFETO, C. K. (2019). Modelling The Learner Model Based Ontology In **Adaptive Learning Environment. Journal of Disruptive Learning Innovation (JODLI)**. 1. 34. DOI: <https://doi.org/10.17977/um072v1i12019p34-45>.

SANTOS, P. R. dos; BARBOSA, D. N. F.; NETO, E. G. A.; BARBOSA, J. L. V.; CORREIA, S. D.; LEITHARDT, V. R. (2021). Learning and Well-Being in Educational Practices with Children and Adolescents Undergoing Cancer Treatment. **Educ. Sci.** 2021, *11*, 442. DOI: <https://doi.org/10.3390/educsci11080442>.

SAP. **Standardized technical architecture modeling.** (2007). <https://community.sap.com/t5/additional-blogs-by-sap/how-to-communicate-architecture-technical-architecture-modeling-at-sap-part/ba-p/12864807>.

SHARMA, M.; AHUJA, L. (2016). A Novel and Integrated Semantic Recommendation System for E-Learning using Ontology. **In Proceedings of the Second International Conference on Information and Communication Technology for Competitive Strategies (ICTCS '16)**. Association for Computing Machinery, New York, NY, USA, Article 52, 1–5. DOI: <https://doi.org/10.1145/2905055.2905110>.

SHI, D.; WANG, T.; XING, H.; XU, H. (2020). A learning path recommendation model based on a multidimensional knowledge graph framework for e-learning. **Knowledge-Based Systems** 195:105618, DOI: <https://doi.org/10.1016/j.knosys.2020.105618>.

SOMMERVILLE, I. **Engenharia de Software.** [S.l.]: São Paulo: Pearson Prentice Hall, 2011.

SOROUR, S.; GODA, K.; MINE, T. (2015). Correlation of Topic Model and Student Grades Using Comment Data Mining. **In Proceedings of the 46th ACM Technical Symposium on Computer Science Education (SIGCSE '15)**. Association for Computing Machinery, New York, NY, USA, 441–446. DOI: <https://doi.org/10.1145/2676723.2677259>.

SOUZA, J. L.; MARTINS, P. G. M.; RAMALHO, R. A. S. (2018). Modelos de representação semântica na era do Big Data. **Brazilian Journal of Information Science: research trends**, v. 12, n. 3, p. 34 ao 40–34 40, 1 out. 2018.

SOUZA JÚNIOR, M. B. (2015). Análise de tipos de ontologias nas áreas de Ciência da Informação e Ciência da Computação. **Encontros Bibl: revista eletrônica de biblioteconomia e ciência da informação**, [S. l.], v. 20, n. 43, 2015. Disponível em: <https://periodicos.ufsc.br/index.php/eb/article/view/40090>.

SPATIOTIS, N.; PERIKOS, I.; MPORAS, I.; PARASKEVAS, M. (2018). Evaluation of an Educational Training Platform Using Text Mining. In **Proceedings of the 10th Hellenic Conference on Artificial Intelligence (SETN '18)**. Association for Computing Machinery, New York, NY, USA, Article 42, 1–5. DOI: <https://doi.org/10.1145/3200947.3201049>.

SUDHANA, K. M.; RAJ, V. C.; SURESH, R. M. (2013). An ontology-based framework for contextaware adaptive e-learning system, 2013 **International Conference on Computer Communication and Informatics**, 2013, pp. 1-6, DOI: <https://doi.org/10.1109/ICCCI.2013.6466162>.

STAAB, S.; STUDER, R. (Ed.). (2004). On-To-Knowledge Methodology (OTKM). In: Staab, S., Studer, R. (eds) **Handbook on Ontologies**. International Handbooks on Information Systems. Springer, Berlin, Heidelberg. DOI: https://doi.org/10.1007/978-3-540-24750-0_6

THAI-NGHE, N.; DRUMOND, L.; KROHN-GRIMBERGHE, A.; SCHMIDT-THIEME, L. (2010). Recommender system for predicting student performance, **Procedia Computer Science**, Volume 1, Issue 2, 2010, Pages 2811-2819, ISSN 877-0509, DOI: <https://doi.org/10.1016/j.procs.2010.08.006>. <http://www.sciencedirect.com/science/article/pii/S1877050910003194>.

TRAXLER, J. (2018). Distance learning: predictions and possibilities. **Education Sciences** 8(1), DOI: <https://doi.org/10.3390/educsci8010035>.

TURABIEH, H.; AZWARI, S. A.; ROKAYA, M.; ALOSAIMI, W.; ALHARBI, A.; ALHAKAMI, W.; ALNFIAI, M. (2021) Enhanced harris hawks' optimization as a feature

selection for the prediction of student performance. **Computing.** DOI: <https://doi.org/10.1007/s00607-020-00894-7>.

ULLAH, F.; WANG, J.; FARHAN, M.; JABBAR, S.; NASEER, M. K.; ASIF, M. LSA (2020). LSA based smart assessment methodology for sdn infrastructure in iot environment.

International Journal of Parallel Programming 48(2):162–177, DOI: <https://doi.org/10.1007/s10766-018-0570-1>.

USCHOLD, M; JASPER, R. A Framework for Understanding and Classifying Ontology Applications. (1999). **Proceedings of the IJCAI-99 workshop on Ontologies and Problem-Solving Methods (KRR5)** Stockholm, Sweden, August 2, 1999.

USCHOLD, M.; GRUNINGER, M (1996). Ontologies: Principles, methods and applications. **The Knowledge Engineering Review.** 11.

USCHOLD, M.; KING, M. (1995). Towards a methodology for building ontologies. In Workshop on Basic Ontological Issues in Knowledge Sharing, held in conjunction with IJCAI-95.

UZIR, N. A.; GAŠEVIĆ, D.; JOVANOVIĆ, J.; MATCHA, W.; LIM, L.A.; FUDGE, A. (2020). Analytics of time management and learning strategies for effective online learning in blended environments. **In Proceedings of the Tenth International Conference on Learning Analytics & Knowledge (LAK '20).** Association for Computing Machinery, New York, NY, USA, 392–401. DOI: <https://doi.org/10.1145/3375462.3375493>.

VENUGOPALAN, S.; SRINATH, M. V.; RODRIGUES, P. (2016). Recommender System for ELearning through Content and Profile Based Approach. **In Proceedings of the Second International Conference on Information and Communication Technology for Competitive Strategies (ICTCS '16).** Association for Computing Machinery, New York, NY, USA, Article 45, 1–5. DOI: <https://doi.org/10.1145/2905055.2905103>.

VIBERG, O.; KHALIL, M.; BAARS, M. (2020). Self Regulated Learning and Learning Analytics in Online Learning Environments: A Review of Empirical Research. **In Proceedings of the 10th International Conference on Learning Analytics & Knowledge (LAK'20).** ACM, New York, NY, USA, 10 pages. DOI: <https://doi.org/10.1145/3375462.3375483>.

VIEIRA, T. T.; MAIA, L. C. G. (2019). Ontologias em ambientes virtuais de aprendizagem: revisão sistemática da literatura. **Ci. Inf.**, Brasília, DF, v.48 n.3, p.252-267, set./dez. 2019.

VIELITZ, F. L.; MARTINS, M. G.; BARBOSA, J. L. V.; OLIVEIRA, K. F. de; DIAS, L. P. S.; WOLF, A. (2019). CMFRAME: a Framework for Managing Dynamic and Hierarchical Context Histories, **2019 XLV Latin American Computing Conference (CLEI)**, Panama, Panama, 2019, pp. 1-8, DOI: <https://doi.org/10.1109/CLEI47609.2019.235107>.

VILLEGRAS CH, W.; ARIAS NAVARRETE, A.; PALACIOS PACHECO, X. (2020). Proposal of an architecture for the integration of a chatbot with artificial intelligence in a smart campus for the improvement of learning. **Sustainability** 12(4), DOI: <https://doi.org/10.3390/su12041500>.

VILLEGRAS CH, W.; ROMÁN CAÑIZARES, M.; PALACIOS PACHECO, X. (2020). Improvement of an online education model with the integration of machine learning and data analysis in an lms. **Applied Sciences** 10(15), DOI: <https://doi.org/10.3390/app10155371>.

WAHEED, H.; HASSAN, S.-U.; ALJOHANI, N. R.; HARDMAN, J.; ALEYANI, S.; NAWAZ, R. (2020). Predicting academic performance of students from VLE big data using deep learning models. **Computers in Human Behavior**, [S.l.], v. 104, p. DOI: <https://doi.org/106189>, 2020.

WANG, R.; LOWE, R.; NEWTON, S.; KOCATURK, T. (2020). Task complexity and learning styles in situated virtual learning environments for construction higher education, **Automation in Construction**, Volume 113, 2020, 103148, ISSN 0926- 5805, DOI: <https://doi.org/10.1016/j.autcon.2020.103148>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0926580519311252>.

WANG, Y.; SUN, Y.; CHEN, Y. (2019) Design and Research of Intelligent Tutor System Based on Natural Language Processing. **IEEE International Conference on Computer Science and Educational Informatization (CSEI)**, Kunming, China, 2019, pp. 33-36, DOI: <https://doi.org/10.1109/CSEI47661.2019.8939031>.

WIEDEMANN, T.; BARBOSA, J.; MATTER, V.; GONçALES, L.; NESI, L.; FARIA, K.; RIGO, S. SIMCOP: (2021). SIMCOP: a framework for similarity analysis of context

histories. **International Journal of Business Information Systems**, v. 1, p. 1-29, 2021. DOI: <https://doi.org/10.1504/IJBIS.2020.10036955>.

YANG, J.; HUANG, Z. X.; GAO, Y. X.; LIU, H. T. (2014). Dynamic Learning Style Prediction Method Based on a Pattern Recognition Technique, in **IEEE Transactions on Learning Technologies**, vol. 7, no. 2, pp. 165-177, April-June 2014, DOI: <https://doi.org/10.1109/TLT.2014.2307858>.

YILMAZ INCE, E.; KABUL, A.; DILER. (2020). Distance education in higher education in the COVID-19 pandemic process: A case of Isparta Applied Sciences University. **International Journal of Technology in Education and Science (IJTES)**, 4(4), 343-351.

ZAKRZEWSKA, D. (2010) Building Group Recommendations in E-Learning Systems. In: **Jędrzejowicz P., Nguyen N.T., Howlet R.J., Jain L.C. (eds) Agent and Multi-Agent Systems: Technologies and Applications. KES-AMSTA 2010**. Lecture Notes in Computer Science, vol 6070. Springer, Berlin, Heidelberg. DOI: https://doi.org/10.1007/978-3-642-13480-7_41.

ZAOUDI, M.; BELHADAOUI, H. (2020) Adaptive e-learning: Adaptation of content according to the continuous evolution of the learner during his training. In: **Proceedings of the 3rd International Conference on Networking, Information Systems and Security, Association for Computing Machinery**, New York, NY, USA, NISS2020, DOI: <https://doi.org/10.1145/3386723.3387890>.

ZEEBAREE, S.; AL-ZEBARI, A.; JACKSI, K.; SELAMAT, A. (2019). Designing an Ontology of E-learning system for Duhok Polytechnic University Using Protégé OWL Tool. **Journal of Advanced Research in Dynamical and Control Systems**. 11. 5.

ZHANG, Y.; GHANDOUR, A.; SHESTAK, V. (2020). Using Learning Analytics to Predict Students Performance in Moodle LMS. **International Journal of Emerging Technologies in Learning (iJET)**. 15. DOI: <https://doi.org/10.1.3991/ijet.v15i20.15915>.

ZORRILLA, M.; GARCÍA, D.; ÁLVAREZ, E. (2010). A decision support system to improve e-learning environments. In **Proceedings of the 2010 EDBT/ICDT Workshops (EDBT '10)**. Association for Computing Machinery, New York, NY, USA, Article 11, 1-8. DOI: <https://doi.org/10.1145/1754239.1754252>.

ANEXO A - PARECER COMITÊ DE ÉTICA

UNIVERSIDADE DO VALE DO
RIO DOS SINOS - UNISINOS



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: ATHENA: UM MODELO COMPUTACIONAL PARA SERVIÇOS INTELIGENTES NA EDUCAÇÃO A DISTÂNCIA USANDO HISTÓRICOS DE CÔNTEXTOS

Pesquisador: LIDIA MARTINS DA SILVA

Área Temática:

Versão: 3

CAAE: 62609722.9.0000.5344

Instituição Proponente: Universidade do Vale do Rio dos Sinos - UNISINOS

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 5.715.703

Apresentação do Projeto:

Trata-se de projeto para realização da tese de doutorado da aluna Lídia Martins da Silva, sob orientação do Profº Drº Jorge Luís Victória Barbosa e co-orientação do Profº Drº Sandro José Rigo. Pretende desenvolver um modelo computacional genérico para serviços inteligentes na educação a distância e, para tanto, utilizará dados coletados diretamente do ambiente virtual de aprendizagem de cerca de 1000 alunos do EAD do Centro Universitário Metropolitano de São Paulo. Tais dados serão coletados mensalmente em cursos de graduação pelo administrador do ambiente virtual, serão retiradas as informações que possam identificar o aluno, tais como nome, CPF, telefone e endereço, e enviados em planilha de Excel para a pesquisadora. Após seu desenvolvimento, o modelo será avaliado por cerca de 20 professores e gestores educacionais.

Objetivo da Pesquisa:

O objetivo geral é propor um modelo computacional genérico para serviços inteligentes na educação a distância baseados em históricos de contextos, que auxilie instituições, professores, alunos e gestores no processo de ensino e aprendizagem. Já os objetivos específicos são 1. projetar um modelo genérico (ATHENA) para serviços inteligentes no ensino a distância baseado em históricos de contextos; e 2. desenvolver um protótipo para validação do modelo proposto e avaliar o modelo através dos históricos de contextos dos alunos, utilizando dados coletados no ambiente virtual de aprendizagem.

Endereço: Av. Unisinos, 950 - Ramal 3219

Bairro: Cristo Rei

CEP: 93.022-000

UF: RS

Município: SAO LEOPOLDO

Telefone: (51)3591-1122

Fax: (51)3591-3219

E-mail: cep@unisinos.br

UNIVERSIDADE DO VALE DO
RIO DOS SINOS - UNISINOS



Continuação do Parecer: 5.715.703

Avaliação dos Riscos e Benefícios:

Como riscos, a pesquisadora considera-os relacionados à necessidade de uma nova coleta de dados, o que geraria um possível desconforto pela perda de tempo para o pesquisador e entrevistados. Entre os benefícios, a pesquisadora menciona a possibilidade de utilizar os históricos de contextos na organização de informações sobre usuários de cursos à distância, gerando informações úteis sobre o perfil de estudantes, comportamentos ou previsão de comportamentos.

Comentários e Considerações sobre a Pesquisa:

A pesquisa é relevante para o seu campo e pode gerar conhecimento aplicável a essa realidade.

Considerações sobre os Termos de apresentação obrigatória:

É apresentado um termo de concordância para uso de dados de propriedade da instituição parceira, devidamente identificado e assinado. Também é apresentado um TCLE voltado para professores e/ou gestores que avaliarão o protótipo. Este termo está bem redigido e adequado.

Recomendações:

Não há.

Conclusões ou Pendências e Lista de Inadequações:

Não há.

Considerações Finais a critério do CEP:

Conforme "Parecer Consustanciado do CEP", o projeto está aprovado (neste parecer encontrará o número de aprovação). Acesse a Plataforma Brasil e localize o TCLE aprovado e carimbado, em folha timbrada. É obrigatório o uso desse TCLE para reproduzir cópias e entregar aos participantes da coleta de dados. Instruções para localização do TCLE aprovado: Na aba "Pesquisador", clicar na lupa da coluna "Ações", em "Documentos do Projeto de Pesquisa", na Árvore de Arquivos, expandir as pastas totalmente, com as setas apontadas para baixo, até encontrar TCLE/Terminos de Assentimento, clicando encontrará TCLE aprovado (em pdf), data 21/10/2022. Dúvidas, faça contato com Adriana Capriolli, 51- 3591-1122 ramal 3219.

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJECTO_2006403.pdf	14/10/2022 17:57:45		Aceito

Endereço: Av. Unisinos, 950 - Ramal 3219

Bairro: Cristo Rei

CEP: 93.022-000

UF: RS

Município: SAO LEOPOLDO

Telefone: (51)3591-1122

Fax: (51)3591-3219

E-mail: cep@unisinos.br

UNIVERSIDADE DO VALE DO
RIO DOS SINOS - UNISINOS



Continuação do Parecer: 5.715.703

Projeto Detalhado / Brochura Investigador	Projeto_detalhado.pdf	14/10/2022 17:57:16	LIDIA MARTINS DA SILVA	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_termo_consentimento.pdf	14/10/2022 17:56:03	LIDIA MARTINS DA SILVA	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_TERMOS_ASSENTIMENTO.pdf	16/09/2022 11:44:13	LIDIA MARTINS DA SILVA	Aceito
Declaração de concordância	Declaracao_de_concordancia.pdf	28/08/2022 11:21:15	LIDIA MARTINS DA SILVA	Aceito
Folha de Rosto	folhaDeRosto_assinado.pdf	28/08/2022 11:16:59	LIDIA MARTINS DA SILVA	Aceito
Cronograma	Cronograma_execucao.pdf	25/08/2022 14:03:45	LIDIA MARTINS DA SILVA	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_LIDIAMARTINSDASILVA.pdf	21/10/2022 16:05:34	Cátia de Azevedo Fronza	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

SAO LEOPOLDO, 21 de Outubro de 2022

Assinado por:
Cátia de Azevedo Fronza
(Coordenador(a))

Endereço: Av. Unisinos, 950 - Ramal 3219	CEP: 93.022-000
Bairro: Cristo Rei	Município: SAO LEOPOLDO
UF: RS	Fax: (51)3591-3219
Telefone: (51)3591-1122	E-mail: cep@unisinos.br