

ATHENA: Um Modelo Computacional para Serviços Inteligentes na Educação a Distância usando Históricos de Contextos

Title: ATHENA: A Computational Model for Intelligent Services in Distance Education Using Context History

Titulo: ATHENA: Un modelo computacional para servicios inteligentes en educación a distancia utilizando historiales de contexto

Lídia Martins da Silva
Centro Universitário UNIVEST
ORCID: [0000-0002-9480-8005](https://orcid.org/0000-0002-9480-8005)
lidiarmartins10@gmail.com

Andréa Vargas Larentis
Universidade Feevale
ORCID: [000-0003-4164-6687](https://orcid.org/000-0003-4164-6687)
andrea.vargas@gmail.com

Sandro José Rigo
Applied Computing Graduate Program (PPGCA),
University of Vale do Rio dos Sinos (UNISINOS)
ORCID: [0000-0001-6550-3651](https://orcid.org/0000-0001-6550-3651)
rigo@unisinis.br

Jorge Luis Victória Barbosa
Applied Computing Graduate Program (PPGCA),
University of Vale do Rio dos Sinos (UNISINOS),
ORCID: [0000-0002-0358-2056](https://orcid.org/0000-0002-0358-2056)
jbarbosa@unisinis.br

Resumo

A Educação a Distância (EaD) tem ganhado destaque na expansão e democratização do ensino superior, beneficiada pelas Novas Tecnologias da Informação e da Comunicação (NTIC) e por mudanças nos processos de ensino e aprendizagem. Contudo, a alta taxa de evasão nos cursos à distância é uma preocupação significativa, já que muitos alunos não concluem os cursos devido a diversos fatores. Essa evasão não se limita à EaD, mas também afeta o ensino presencial e semipresencial, em instituições públicas e privadas. Diante desse cenário, o artigo apresenta o Athena, um modelo computacional projetado para oferecer serviços inteligentes na EaD com base em históricos de contextos dos alunos. O Athena visa ajudar gestores e professores no planejamento estratégico e no acompanhamento do progresso acadêmico dos alunos. O modelo oferece serviços para prever o desempenho acadêmico dos alunos e para a formação de grupos de estudo. Esses serviços têm como objetivo melhorar o processo de aprendizagem, reduzir a taxa de reprovação e, conseqüentemente, diminuir a evasão. O Athena utiliza uma ontologia para representar o conhecimento em EaD e analisa os históricos de contextos dos alunos para personalizar os serviços oferecidos. Um protótipo foi testado com dados de 25 alunos de um curso de Tecnologia em Análise e Desenvolvimento de Sistemas. Os testes avaliaram dois serviços: o *Forecasting*, que antecipa o desempenho acadêmico, e o *Grouping*, que organiza grupos de estudo. Os resultados confirmam a viabilidade do modelo para suportar a criação e o uso de diferentes serviços inteligentes na EaD, baseados em históricos contextuais dos alunos.

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

Abstract

Distance Education (EaD) has gained prominence in the expansion and democratization of higher education, benefiting from New Information and Communication Technologies (NICT) and changes in teaching and learning processes. However, the high dropout rate in distance learning courses is a significant concern, as many students do not complete their courses due to a variety of factors. This dropout rate is not limited to distance learning, but also affects in-person and blended learning in both public and private institutions. In

Cite as: Silva, L. M., Larentis, A. V., Rigo, S. J., & Barbosa, J. L. V. (2026). ATHENA: Um Modelo Computacional para Serviços Inteligentes na Educação a Distância usando Históricos de Contextos. Revista Brasileira de Informática na Educação, 34, 626-668. <https://doi.org/10.5753/rbie.2026.5487>

light of this scenario, the article presents Athena, a computational model designed to offer intelligent services in distance education based on students' contextual histories. Athena aims to help managers and teachers in strategic planning and in monitoring students' academic progress. Athena aims to help managers and teachers with strategic planning and monitoring students' academic progress. The model offers services to predict students' academic performance and to form study groups. These services aim to improve the learning process, reduce the failure rate and, consequently, reduce dropout rates. The model uses an ontology to represent knowledge in distance learning and analyzes students' context histories to personalize the services offered. A prototype of Athena was tested with data from 25 students in a Technology in Systems Analysis and Development course the tests evaluated two services: Forecasting, which anticipates academic performance, and Grouping, which organizes study groups. The results confirm the viability of the model to support the creation and use of different intelligent services in distance education, based on students' contextual histories.

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

Resumen

La Educación a Distancia (EaD) ha ganado protagonismo en la expansión y democratización de la educación superior, beneficiándose de las Nuevas Tecnologías de la Información y las Comunicaciones (NTIC) y de los cambios en los procesos de enseñanza y aprendizaje. Esta evasión no se limita a la educación a distancia, sino que también afecta a la enseñanza presencial y semipresencial, en instituciones públicas y privadas. Ante este escenario, el artículo presenta Athena, un modelo computacional diseñado para ofrecer servicios inteligentes en educación a distancia basados en las historias contextuales de los estudiantes. Athena tiene como objetivo ayudar a directivos y profesores con la planificación estratégica y el seguimiento del progreso académico de los estudiantes. El modelo ofrece servicios para predecir el rendimiento académico de los estudiantes y formar grupos de estudio. Estos servicios tienen como objetivo mejorar el proceso de aprendizaje, reducir la tasa de fracaso y, en consecuencia, reducir las tasas de abandono. Athena utiliza una ontología para representar el conocimiento del aprendizaje a distancia y analiza las historias contextuales de los estudiantes para personalizar los servicios ofrecidos. Un prototipo fue probado con datos de 25 estudiantes del curso de Tecnología en Análisis y Desarrollo de Sistemas. Las pruebas evaluaron dos servicios: Forecasting, que anticipa el rendimiento académico, y Grouping, que organiza grupos de estudio. Los resultados confirman la viabilidad del modelo para apoyar la creación y el uso de diferentes servicios inteligentes en la educación a distancia, basados en las historias contextuales de los estudiantes.

Palabras clave: Servicios inteligentes. Entorno virtual de aprendizaje. Contexto. Historia del contexto. Educación a distancia.

1 Introdução

Em um mundo globalizado, a Educação a Distância (EaD) ganhou destaque, permitindo que a mediação didático-pedagógica nos processos de ensino e aprendizagem ocorra por meio da tecnologia. Essa abordagem flexível possibilita que professores e alunos realizem atividades em diferentes locais e horários.

A EaD é definida por Bertiz e Kocaman Karoglu (2020), como uma forma de ensino em que alunos e professores estão em locais diferentes, recebendo a educação simultaneamente ou em momentos distintos, utilizando as tecnologias de informação e comunicação (TICs). Esse modelo proporciona ambientes de aprendizagem flexíveis e eficientes, permitindo que os alunos estudem a qualquer hora e em qualquer lugar. Assim, os estudantes têm a oportunidade de aprender no seu próprio ritmo e de maneira não linear, promovendo a aprendizagem autônoma.

O uso de Ambientes Virtuais de Aprendizagem ou Sistemas de Gerenciamento de Aprendizagem sustentam os processos educacionais na EaD. Esses ambientes disponibilizam diversos recursos, como: compartilhamento de conteúdo, desenvolvimento de atividades e comunicação entre os participantes do processo de ensino-aprendizagem (Andrade; Rigo; Barbosa, 2022).

O desenvolvimento da EaD é impulsionado pela tecnologia disponível em Ambientes Virtuais de Aprendizagem (AVA), ou Sistemas de Gerenciamento de Aprendizagem (SGA). Esses recursos promovem dinamismo, proatividade e personalização no processo de ensino-aprendizagem (Dias, 2017), facilitando a interação entre os participantes e a interatividade do material de estudo. A adoção de AVA produz grandes volumes de dados variados, e as instituições de ensino podem aproveitar essas informações coletadas, analisadas e integradas em diferentes sistemas. Esses dados podem ser organizados em históricos contextuais, facilitando análises futuras (Vielitz et al., 2019; Almeida Maia, 2020; Rodrigues et al., 2022; Machado et al., 2021; Garcia Martins et al., 2021; Martini et al., 2021; Aranda et al., 2023; Wiedemann et al., 2021; Heckler et al., 2023, Filippetto; Lima; Barbosa, 2021 e Lima et al., 2022).

As instituições de ensino que ofertam cursos na modalidade a distância enfrentam diversos desafios que podem comprometer tanto a qualidade do ensino quanto a experiência dos estudantes. Entre esses desafios destacam-se: 1) a necessidade de manter padrões de qualidade pedagógica; 2) proporcionar uma experiência de aprendizagem significativa e engajadora; 3) adaptar-se às diferentes necessidades e perfis dos alunos e, 4) acompanhar as constantes transformações tecnológicas e metodológicas do cenário educacional. A superação desses desafios requer um compromisso contínuo com a inovação, o desenvolvimento e a implementação de estratégias pedagógicas eficazes, além da capacidade de adaptação às demandas emergentes de um ambiente de aprendizagem em permanente evolução (Costa, 2021).

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.

Almeida Neto (2017) define um serviço inteligente como a implementação de uma tarefa inteligente dentro de um sistema computacional, permitindo que seu acesso seja disponibilizado a outros sistemas.

Segundo Cummaudo et al. (2019), esses serviços são frequentemente apresentados como em constante evolução e melhoria. Isso significa que, graças aos seus vastos conjuntos de dados de treinamento, eles conseguem atualizar continuamente os modelos de previsão, gerando resultados probabilísticos em vez de certezas. Os serviços inteligentes, portanto, são soluções digitais que se baseiam nos dados coletados de produtos físicos, trazendo valor significativo para todos os envolvidos. Na área de computação, serviços inteligentes referem-se a soluções que empregam tecnologias avançadas, como inteligência artificial, aprendizado de máquina e processamento de linguagem natural, para automatizar funções e melhorar a eficiência e a tomada de decisões. Entre os exemplos estão assistentes virtuais, recomendações personalizadas e análise de dados.

De acordo com Koldewey et al. (2021), os serviços inteligentes foram introduzidos por Allmendinger e Lombreglia (2005) como serviços fundamentados em dados. Esses serviços digitais, conectados a objetos inteligentes, possibilitam uma comunicação contínua, *feedback* interativo e soluções por meio da análise de dados (Koldewey et al. 2020). Além disso, Beverungen et al. (2019) afirmam que produtos inteligentes viabilizam a cocriação de serviços, como monitoramento, otimização, controle e adaptação autônoma.

Esses serviços inteligentes ajudam as instituições de ensino na tomada de decisões, promovem melhorias nos processos de ensino e aprendizagem, contribuindo para a redução das taxas de reprovação e evasão. Eles têm a capacidade de identificar as características e perfis dos alunos, prever seu comportamento (Zaoudi; Belhadaoui, 2020), habilidades cognitivas (Angeline; Ramasubramanian; James, 2020), sucesso acadêmico (Kim; Kim, 2020; Hashim; Awadh; Hamoud, 2020), desempenho acadêmico (Iatrellis et al., 2021), estilos de aprendizagem (El Fouki; Aknin; El. Kadiri, 2017) e potencial abandono (Chen et al., 2020a; Chen et al., 2020; Freitas et al., 2020).

Diante das considerações apresentadas, é estratégico que as instituições de ensino busquem adaptações e desenvolvam soluções computacionais que estejam sintonizadas com os desafios enfrentados pelos estudantes. Isso implica em conceber soluções que possam efetivamente enriquecer o processo de ensino e aprendizagem, aproveitando as vantagens das mais recentes tecnologias.

Nesse contexto, o modelo Athena fundamenta-se na oferta de serviços inteligentes que auxiliem tanto os professores e gestores quanto os alunos nos processos de ensino e aprendizagem. Dentre suas contribuições destacam-se: 1) a personalização do ensino, adaptando conteúdo e metodologia de acordo com as necessidades de cada aluno; 2) o auxílio na identificação de alunos com dificuldades de aprendizagem, permitindo intervenções personalizadas e melhorias quando indicadas; 3) o impulso na pesquisa em dados educacionais, gerando *insights* sobre padrões de aprendizagem e eficácia de

intervenções; 4) inspira o desenvolvimento de novas metodologias pedagógicas; 5) a promoção da análise e do aprimoramento contínuo dos serviços educacionais e, 6) fomenta a colaboração interdisciplinar entre professores e alunos.

Este artigo está estruturado em cinco seções. A seção dois descreve os trabalhos relacionados. A seção três apresenta o Modelo Athena. A seção quatro descreve os resultados da avaliação. A seção cinco é destinada às considerações finais. Por fim, foram incluídos três Apêndices: Apêndice A (Comparativo dos trabalhos relacionados), Apêndice B (Comparativo dos trabalhos relacionados com Ontologias) e Apêndice C (Resumo dos artigos de autoria dos autores).

2 Trabalhos relacionados

Foi realizada uma pesquisa dos trabalhos relacionados com o objetivo de identificar o uso de modelos computacionais para serviços inteligentes com foco na EaD. Utilizando um mapeamento sistemático da literatura, palavras-chave estratégicas foram selecionadas para identificar lacunas e oportunidades de pesquisa sobre o uso da computação na assistência educacional em EaD. A pesquisa, permitiu desenvolver um mapeamento inicial, destacando o uso de *Learning Analytics* e serviços inteligentes na EaD (Silva; Barbosa; Rigo, 2021). Em seguida, foi conduzido um segundo mapeamento, focado na aprendizagem e nos grupos colaborativos de alunos na EaD (Silva et al., 2022).

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: *Distance Learning, Learning Analytics* e *Intelligent Services*. A fim de estabelecer os interesses da pesquisa, foi definida a seguinte *string* de busca: *Distance Learning: (Distance learning OR Distance education OR E-Learning OR online education OR Educational technology OR virtual learning environment OR learning management system); Learning Analytics: 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); Intelligent Services: 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)*.

Os trabalhos foram pesquisados nas seguintes bases *ACM Digital Library, IEEE Xplore Digital Library, ScienceDirect, Springer Library, Scopus*, utilizando os seguintes critérios de inclusão: 1) Publicações com conteúdos completos e acesso livre, 2) Publicações em conferências, *journals* e *workshops*, 3) Publicações que possuem métodos de análise de dados aplicados na EaD e, 4) Publicações que ofereçam algum tipo de serviço inteligente para a área de EaD.

A partir de uma seleção dos 75 artigos apresentados no Apêndice A, foram analisados estudos que apoiam gestores, professores e alunos no processo de ensino e aprendizagem, com foco nos seguintes critérios de comparação: 1) Tipos de serviços inteligentes ofertados na EaD; 2) Consideração de grupos ou atividades colaborativas durante o desenvolvimento do trabalho; 3) Utilização de históricos de contextos, com armazenamento de informações do usuário ao longo do tempo; 4) Classificação do trabalho como modelo computacional ou sistema computacional; 5) Compatibilidade do modelo ou sistema computacional com diferentes tipos de serviços inteligentes; 6) Técnicas e tecnologias empregadas e, 7) Presença de estratégias baseadas em ontologias. Essa avaliação buscou destacar como essas

abordagens contribuem para a inovação e a efetividade da EaD, auxiliando na criação de ambientes mais interativos e personalizados.

Ao analisar os trabalhos, observou-se que nenhum deles abrange todos os aspectos avaliados. Nesse cenário, o Athena se destaca, apresentando os seguintes diferenciais. O primeiro diferencial do Athena é seu caráter genérico como modelo computacional, ou seja, ele suporta uma variedade de serviços inteligentes. Essa flexibilidade é essencial, dado o crescente número de serviços inteligentes disponíveis atualmente, permitindo que instituições desenvolvam estratégias personalizadas para auxiliar gestores, professores e alunos nos processos de ensino e aprendizagem. Isso contribui para melhorias na qualidade do ensino e para a redução da evasão escolar. O segundo diferencial do Athena é utilizar os históricos de contextos dos alunos de cursos à distância.

O registro contínuo desses históricos permite a obtenção de informações estratégicas sobre o aluno, armazenando uma sequência de eventos que descrevem como, onde e quando os recursos foram utilizados. Esses dados de contexto possibilitam consultas aprofundadas, a criação de perfis personalizados e a recomendação de serviços diversos, otimizando a experiência educacional na EaD.

Um outro estudo foi conduzido sobre ontologias destinadas à educação a distância e serviços inteligentes, fazendo uso de históricos de contextos. Os trabalhos foram pesquisados nas seguintes bases: *ACM Digital Library*, *IEEE Xplore Digital Library*, *ScienceDirect*, *Springer Library*, *Scopus*. 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*).

Ao analisar o resultado dos 15 artigos selecionados, apresentados no Apêndice B, verificou-se 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. 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.

Considerando o resultado do comparativo entre os trabalhos relacionados, a OntoAthena se diferencia nos seguintes aspectos: 1) sua modelagem do conhecimento é voltada para educadores no contexto do ensino à distância e, 2) 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.

3 Modelo Athena

Athena é 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.

O modelo desenvolvido é genérico e aplicável a diversos tipos de serviços. Baseado em registros contextuais, ele auxilia educadores e estudantes no processo de ensino e aprendizagem. Sua principal vantagem reside na capacidade de utilizar históricos contextuais para organizar informações sobre os usuários de cursos *online*, aproveitando o grande volume de dados gerados nas atividades virtuais. Esses dados podem ser coletados e analisados, gerando *insights* sobre perfis e comportamentos dos alunos, o que facilita a tomada de decisões assertivas (Machado et al., 2021).

Além disso, o modelo pode ser utilizado no desenvolvimento de programas institucionais para combater a evasão, através de políticas de retenção, planejamento de ações e monitoramento de resultados. Também permite uma aprendizagem personalizada, adaptando-se às características individuais de cada aluno por meio de serviços inteligentes. A seguir é apresentada uma visão geral da arquitetura do Athena, um cenário de históricos de contextos e a ontologia OntoAthena.

3.1 Visão geral

A Figura 1 apresenta a visão geral do modelo composto por usuário, ambiente virtual de aprendizagem, banco de dados do ambiente virtual, banco de dados do Athena, banco de dados de contextos, *Application Program Interface* (API), serviços inteligentes e pela ontologia. A seguir serão descritos os componentes do modelo em relação a sua função de armazenamento ou processamento:

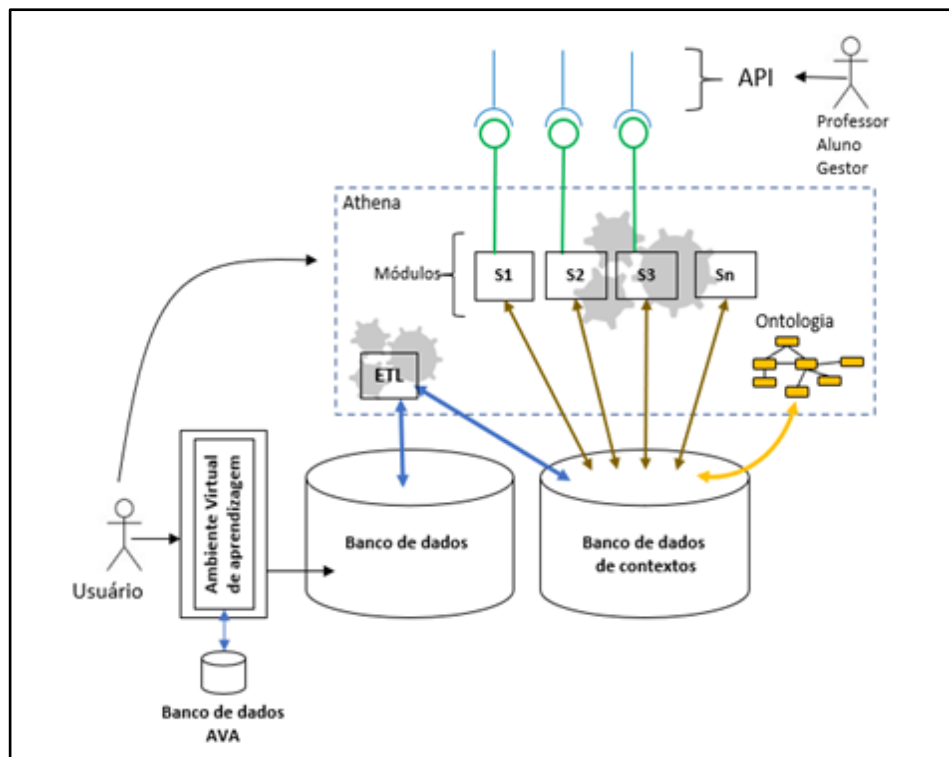


Figura 1: Arquitetura Athena.

- **Usuário:** qualquer pessoa que interage com a plataforma *online*, como alunos, professores, tutores e administradores, para acessar conteúdo, participar de atividades, colaborar ou realizar tarefas administrativas, de acordo com as permissões do sistema.

- **Ambiente Virtual de Aprendizagem:** facilita a interação entre alunos e professores, oferecendo acesso a recursos educacionais, ferramentas de comunicação e colaboração. Ele cria um espaço *online* para atividades educativas, estudos em grupo, acesso a materiais didáticos e discussões. Fundamental no cenário educacional atual, o AVA proporciona uma

plataforma flexível que promove o engajamento dos alunos e facilita o processo de aprendizagem (Anjos, 2015).

- 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: espaço destinado ao armazenamento das informações dos alunos extraídas do banco de dados do ambiente virtual de aprendizagem.

- Banco de dados de contextos: estrutura de armazenamento que contém informações contextuais, utilizado para armazenar e gerenciar dados que descrevem o ambiente no qual um sistema está operando. Inclui informações sobre o usuário, suas atividades, preferências, histórico de interações e outras variáveis contextuais para posterior análise e utilização.

- *Extract, Transform, Load* (ETL): faz a integração dos dados em três etapas (extração, transformação, carregamento) do banco de dados do Athena 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 AVA para o banco de dados do Athena e deste para o banco de contextos.

- Ontologia: Estrutura formal que representa o conhecimento sobre educação a distância, contextos e serviços inteligentes. Ela oferece uma base semântica para descrever o domínio educacional, permitindo interoperabilidade, personalização, análise de dados, desenvolvimento de sistemas inteligentes e padronização de recursos educacionais.

- Módulos s1...sn: são os serviços inteligentes do 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.

- 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: usuários ativos no Athena, que participam das interações no ambiente e são a principal fonte de dados. Suas informações são utilizadas para oferecer serviços inteligentes que aprimoram o processo de aprendizado, com base em seus históricos de contextos, visando uma experiência de aprendizagem mais eficaz e personalizada.

- Professor: usuário que utiliza o AVA para disponibilizar conteúdo, criar atividades, gerenciar turmas, avaliar o desempenho dos alunos e fornecer suporte educacional através dos serviços inteligentes disponibilizados pelo Athena.

- Gestor (coordenador): desempenha um papel essencial no ambiente virtual de aprendizagem, monitorando as atividades dos professores e o progresso dos alunos. Ele acessa relatórios sobre participação, desempenho e interação, além de coordenar um curso no AVA, contribuindo para a qualidade e eficácia das atividades educacionais.

O funcionamento do modelo ocorre da seguinte forma: o usuário faz *login* no AVA 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 AVA 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.

Dentre os serviços que podem ser disponibilizados pelo Athena, destacam-se, o *Forecasting* e o *Grouping*. Esses dois serviços representam soluções inteligentes aplicadas à educação, com o objetivo de promover uma aprendizagem mais eficaz, personalizada e engajadora. O *Forecasting* é um serviço que realiza a previsão do desempenho acadêmico dos estudantes, identificando, com base na análise de dados como notas, frequência e participação, possíveis riscos de evasão ou reprovação. A partir desses diagnósticos, torna-se possível a adoção de intervenções proativas por parte da instituição, favorecendo a retenção e o apoio direcionado aos alunos que apresentam sinais de dificuldade. Trata-se, portanto, de um exemplo de uso de inteligência preditiva no contexto educacional. O *Grouping* consiste em um serviço voltado à formação inteligente de grupos, fundamentado na análise de informações sobre os perfis dos estudantes, como interesses, habilidades, experiências prévias e estilos de aprendizagem. O serviço busca estabelecer um equilíbrio entre diversidade e compatibilidade, de modo a promover a colaboração, o engajamento e o aprendizado adaptativo entre os participantes.

Além disso, o *Grouping* configura-se como uma ferramenta que vai além da identificação de riscos de evasão, utilizando critérios múltiplos e personalizados para formar grupos mais eficazes e produtivos. Dependendo da finalidade do agrupamento e da configuração adotada, é possível considerar outros critérios relevantes, tais como: diversidade de gênero e cultural, com vistas à promoção da inclusão, localização geográfica (particularmente em cursos híbridos ou presenciais), objetivos profissionais dos estudantes e disponibilidade de tempo para a realização de atividades em grupo. Dessa forma, esse serviço contribui significativamente para a criação de ambientes colaborativos mais dinâmicos, equitativos e alinhados às necessidades dos alunos.

Ambos os serviços são considerados inteligentes porque utilizam dados e tecnologias para melhorar o desempenho, o engajamento e a experiência dos estudantes na educação. 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.

3.2 Arquitetura Athena

A arquitetura do Athena teve como base o padrão interno da TAM - *Standard for Technical Architecture Modeling* proposta pela SAP (2007)¹. A Figura 2 apresenta a arquitetura geral do Athena que 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 do Athena 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, do Athena e do contexto, os módulos de serviços inteligentes e a ontologia serve como base de conhecimento sobre o domínio

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

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).

Os usuários (professores, alunos e gestores) interagem com o modelo por meio dos serviços inteligentes, sendo que a API atua como um elo entre os usuários e esses serviços. No *Middleware* 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.

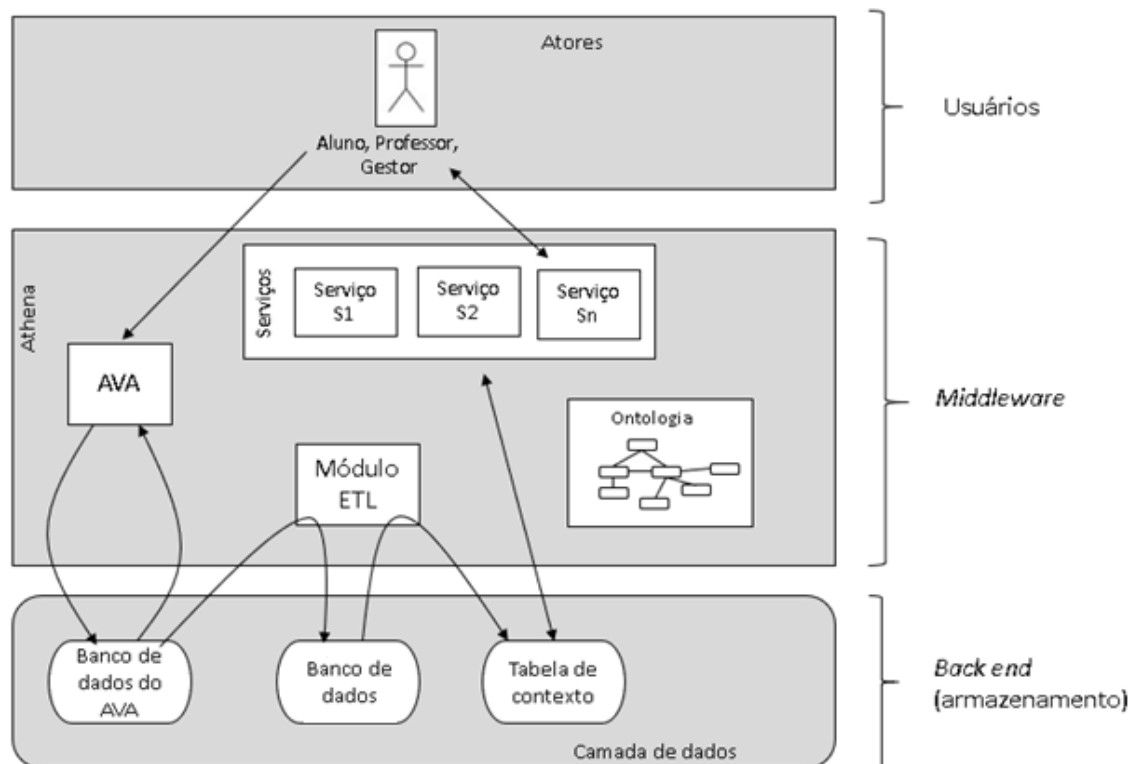


Figura 2: Arquitetura Geral do Athena.

3.3 Modelo de dados

Para armazenar as informações associadas ao contexto e perfil do aluno, foi utilizado 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 análise realizada pelo Athena.

A Figura 3 apresenta o modelo ER, que foi concebido para acomodar as informações que constituem os históricos de contextos dos alunos e para armazenar os dados do Athena. 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*.

O sistema organiza diversos dados dos alunos e seu contexto de aprendizado em várias tabelas. *AcademicRecord* armazena dados cadastrais e acadêmicos, enquanto *Activity*, *Evaluation*, e *Performance* registram atividades e avaliações. *Certificate*, *ClassCourse*, *Course*, e *ContentTopic* contêm informações sobre cursos, disciplinas, turmas e certificados. *Competence* descreve competências, e *StudyHabits* registra hábitos de estudo. *Profile* guarda dados pessoais, e *User*, informações de *login*. *Service* identifica serviços, e *Tools*

detalha ferramentas. *Risk* e *Shift* registram riscos e turnos. *Context* contém informações do contexto do aluno, incluindo hábitos de estudo, avaliações, atividades realizadas, informações de tempo, localização e dispositivos utilizados. *ContextHistories* representa um conjunto de contextos registrados na linha do tempo, ou seja, um histórico das suas interações com o ambiente virtual. Uma vez criado um registro na tabela *Context*, a cada interação com o ambiente virtual é registrado uma linha na tabela *ContextHistories*, seja para uma avaliação, uma atividade extra-classe, um estudo em grupo, etc. Os serviços inteligentes utilizam os dados contidos na tabela *ContextHistories* para gerar resultados conforme seus objetivos. Uma ontologia organiza esses dados, facilitando sua consulta e análise no ambiente virtual.

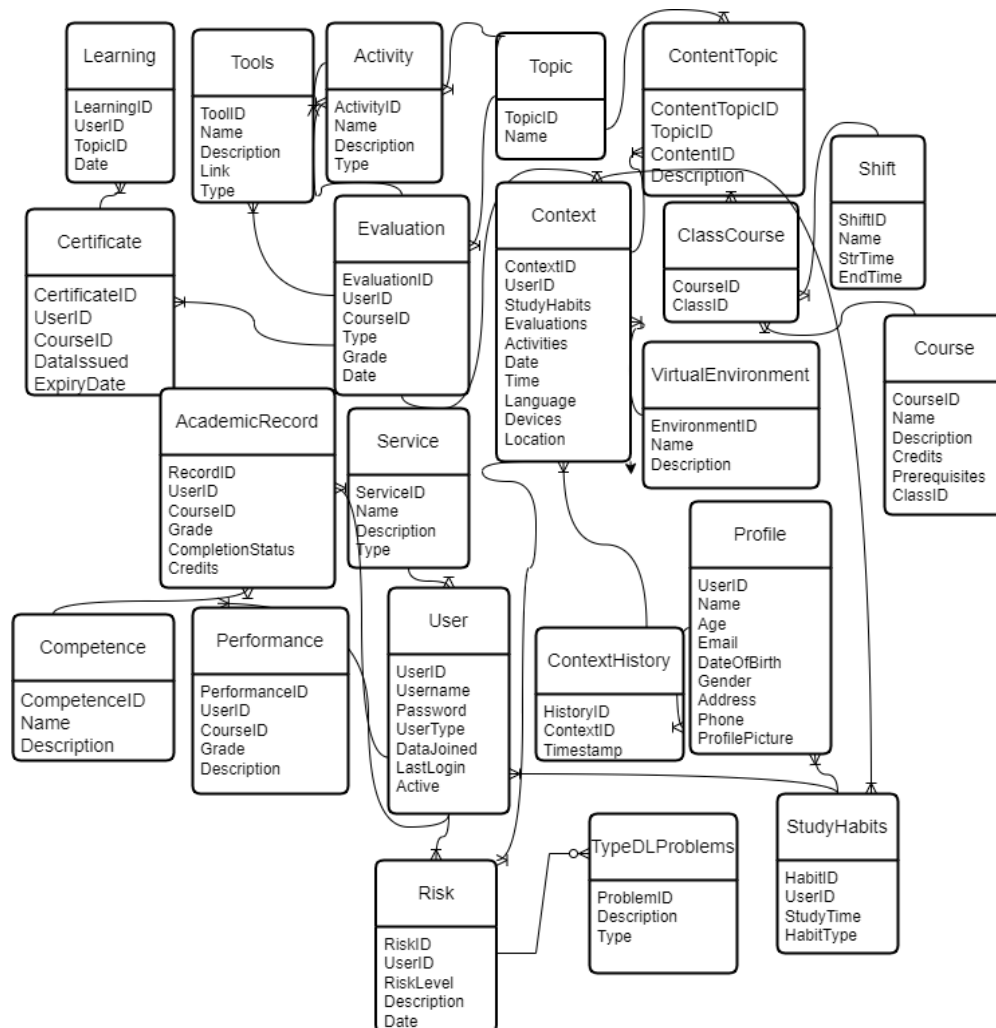


Figura 3: Modelo ER.

3.4 Um Cenário de históricos de contextos

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 aos 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, ou

seja, contexto caracteriza qualquer informação relacionada a pessoas (por exemplo, indivíduos ou grupos) e informações relacionadas a coisas, em particular, dispositivos vestíveis e recursos computacionais (Aranda et al. 2023). 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.

A Figura 4 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.

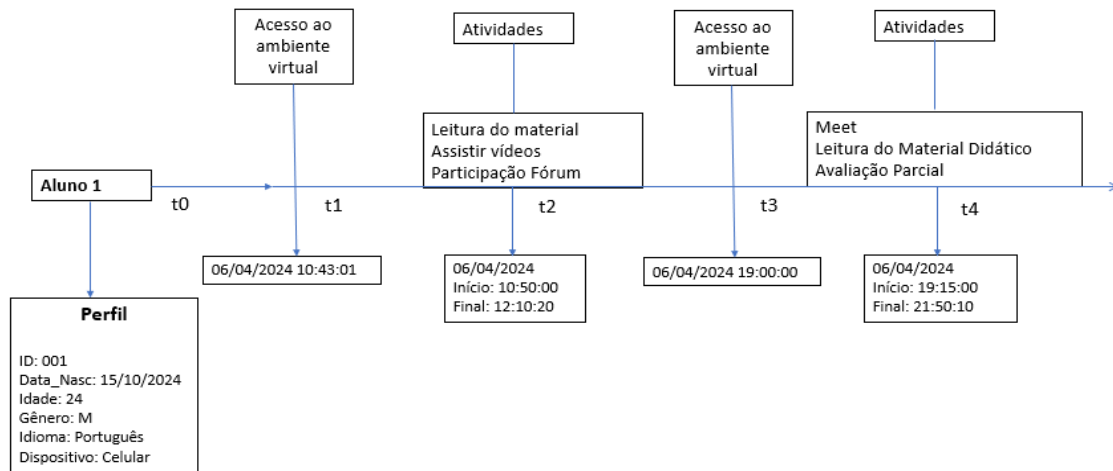


Figura 4: Exemplo de históricos de contextos.

3.5 Ontologia OntoAthena

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 para essa modalidade de ensino. 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.

As questões de competência (QC) 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 (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 prever se o aluno vai desistir do curso?
- QC8: Qual serviço inteligente seria adequado para prever se o aluno será reprovado de alguma disciplina?
- QC9: Como formar grupos de estudos?
- QC10: Como realizar o acompanhamento de um grupo de estudos?

3.5.2 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.

3.5.3 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 serviu para apoiar na definição dos termos principais da OntoAthena.

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.

3.5.4 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*, o qual foi desenvolvido e é mantido pelo *Stanford Center for Biomedical Informatics Research* (BMIR).

A Figura 6 apresenta as classes e suas relações como 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 representam 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, e) consultas SPARQL, que realizam as consultas na ontologia.

Os conceitos, suas propriedades e relacionamentos formam a base de qualquer ontologia e tem como objetivo definir a semântica de seus termos para construir os axiomas, que são utilizados para modelar sentenças verdadeiras.

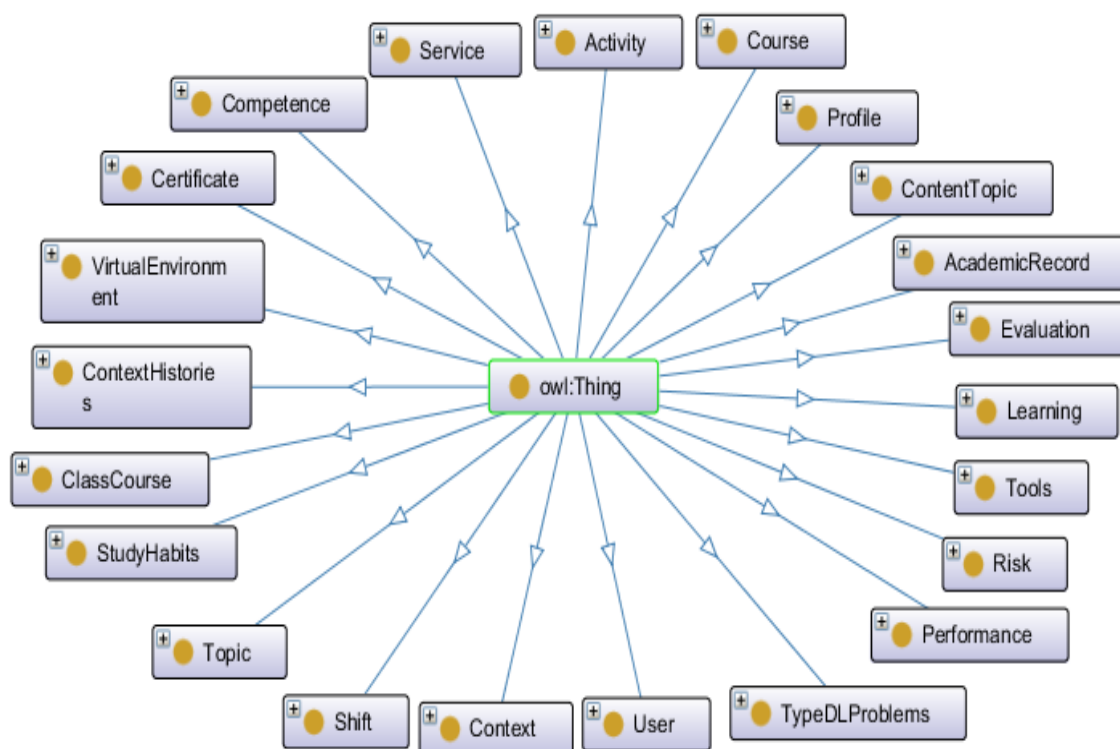


Figura 6: Classes da OntoAthena.

3.5.5 Definir as propriedades das classes

Nesta etapa foram definidas as propriedades das classes usando o *Protégé 5.5.0*. A Tabela 1 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).

Tabela 1: 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>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>hasShif</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>

3.5.6 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 anteriormente referem-se à probabilidade de aprovação ou evasão do aluno nos cursos EaD, foram criadas expressões lógicas para responder estas quatro QCs. As expressões lógicas descrevem o axioma de equivalência para (≤ -1) *High*, (≥ 1) *Low* e (< 1) *Medium*.

A Figura 7 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*.

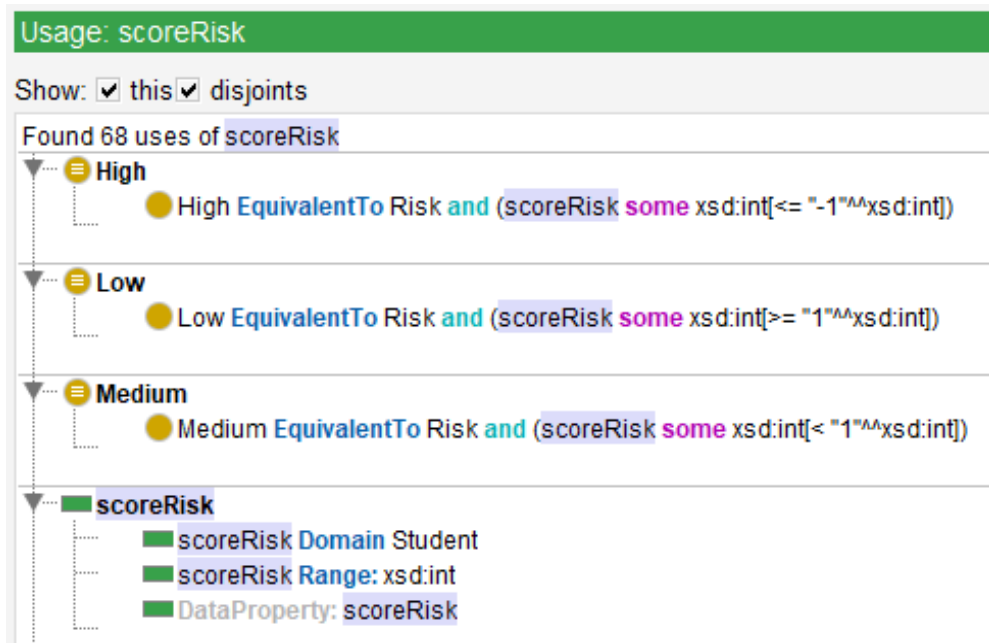


Figura 7: Expressões lógicas.

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 2.

Tabela 2: Regras SQWRL para inferência de risco de reprovação ou evasão.

Nome	Regras
S1	<code>swrlb:lessThan(?v, 20) countAccessPerSemester(?u, ?v) -> valCountAccessPerSemester(?u, -1)</code>
S2	<code>swrlb:lessThan(?v, 30) swrlb : greaterThan(?v, 19) countAccessPerSemester(?u, ?v) -> valCountAccessPerSemester(?u, 0)</code>
S3	<code>csowlb:greaterThan(?v, 29) countAccessPerSemester(?u, ?v) -> valCountAccessPerSemester(?u, 1)</code>
S4	<code>countForum(?u, ?v) swrlb : lessThan(?v, 6) -> valCountForum(?u, -1)</code>
S5	<code>countForum(?u, ?v) swrlb : lessThan(?v, 7) swrlb:greaterThan(?v, 5) -> valCountForum(?u, 0)</code>
S6	<code>countForum(?u, ?v) swrlb : greaterThan(?v, 7) -> valCountForum(?u, 1)</code>
S7	<code>swrlb:lessThan(?v, 2) countActivity4Online(?u, ?v) -> valCountActivity4Online(?u, -1)</code>
S8	<code>csowlb:greaterThan(?v, 1) swrlb : lessThan(?v, 4) countActivity4Online(?u, ?v) -> valCountActivity4Online(?u, 0)</code>
S9	<code>countActivity4Online(?u, ?v) swrlb : greaterThan(?v, 3) -> valCountActivity4Online(?u, 1)</code>
S10	<code>countActivity(?u, ?v) swrlb : lessThan(?v, 10) -> valCountActivity(?u, -1)</code>
S11	<code>swrlb:lessThan(?v, 12) swrlb : greaterThan(?v, 9) countActivity(?u, ?v) -> valCountActivity(?u, 0)</code>
S12	<code>ontology:countActivity(?u, ?v) swrlb : greaterThan(?v, 11) -> ontology:valCountActivity(?u, 1)</code>
S13	<code>Student(?u) valCountForum(?u, ?b) swrlb:add(?w, ?a, ?b, ?c, ?d) valCountActivity4Online(?u, ?c) valCountActivity(?u, ?d) valCountAccessPerSemester(?u, ?a) -> scoreRisk(?u, ?w)</code>
S14	<code>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)</code>

3.5.7 Criar as instâncias

Desenvolvimento de Dados e avaliados pelo Comitê de Ética da Unisinos; 2) Execução do motor de inferência e, 3) Consulta SPARQL. A base continha dados de 25 alunos do período de 2022/1 a 2023/2 e foram utilizados dados do primeiro semestre para popularizar as instâncias da classe estudante. 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 2, 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.

Após a habilitação do *reasoner Pellet* para execução, este também efetua inferências com base nas regras de equivalência na Tabela 2. As expressões lógicas descritas em cada uma dessas regras foram processadas pelo *reasoner*. Essas regras podem ser visualizadas na Figura 9.

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

Control	Rules	Asserted Axioms	Inferred Axioms	OWL 2 RL
A				
Student16 name "Aluno16"^^rdfs:Literal				
Student15 Type User				
Email SubClassOf Tools				
Student17 countActivity "8"^^xsd:int				
Class: Feedback				
Class:Course6CIC hasCode "CIC61"				
Text SubClassOf Service				
Student(?student), name(?student, ?identify), valCountAccessPerSemester(?student, ?a), valCountForum(?student, ?b), valCountActivity4Online(?student, ?c), add				
Class: Profile				
Book1 Type VirtualEnvironment				
hasClassCourse Domain Course				
Class: Recommendation				
Lesson SubClassOf Tools				
Individual: Student7				
ObjectProperty: hasTutor				

Figura 9: Regras inferidas.

Após análise realizada pelo *reasoner*, os seguintes resultados foram obtidos. Na Figura 10, 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.

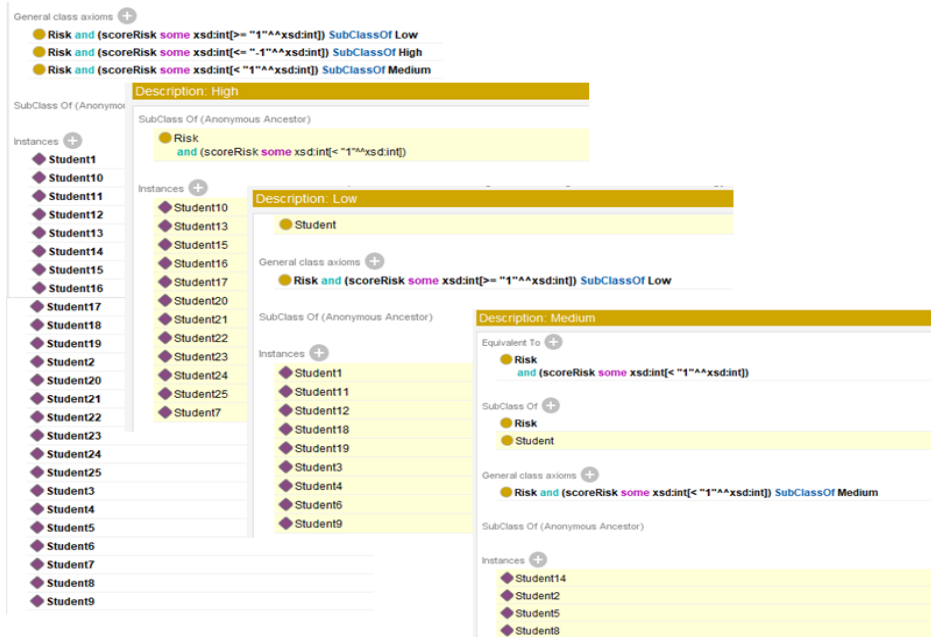


Figura 10: Resultado sobre Evasão ou Reprovação na OntoAthena.

A Figura 11 apresenta 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.

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	

Figura 11: Resultado da inferência - Escore de risco.

Depois de testada a ontologia com o processo de raciocínio automático, é viável realizar consultas utilizando o SPARQL, que é similar ao SQL. Conseqüentemente, 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:

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

A Figura 12 apresenta a consulta da questão de competência "QC1". Todas as consultas foram editadas e executadas no Protégé através do SPARQL Query (Web Protégé, 2023) Após a execução da consulta, conforme ilustrado na Figura 11, 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 10), os quais são detalhados nas colunas da Figura 13 e Figura 14.

```
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
```

Figura 12: Consulta SPARQL para alto risco de reprovação ou evasão.

Na Figura 13, na primeira coluna (*Student*) são listadas as instâncias (indivíduos); a segunda coluna (*Registro*) apresenta 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 (*ValQtdeAcessoSemestre*) é apresentado o valor do escore para acesso ao ambiente virtual por semestre.

Student	Registro	Nome	Risco	ValQtdeAcessoSem
Student13	"2013"	"Aluno13"	-4	-1
Student15	"2015"	"Aluno15"	-4	-1
Student21	"2021"	"Aluno21"	-4	-1
Student16	"2016"	"Aluno16"	-4	-1
Student22	"2022"	"Aluno22"	-3	-1
Student17	"2017"	"Aluno17"	-2	-1
Student24	"2024"	"Aluno24"	-2	-1
Student25	"2025"	"Aluno025"	-2	0
Student10	"2010"	"Aluno10"	-2	0
Student20	"2020"	"Aluno20"	-2	-1
Student23	"2023"	"Aluno23"	-1	-1
Student7	"2007"	"Aluno7"	-1	-1

Figura 13: Resultado da consulta SPARQL alto risco de reprovação ou evasão.

Na Figura 14, na primeira coluna (*Student*) são listadas as instâncias (indivíduos) e na próxima coluna (*ValCountActivity*) é apresentado 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*) exibe a quantidade de acessos por semestre, quantidade de atividades enviadas e a quantidade de participações nos fóruns.

Student	ValQtdeAtiv	ValQtdeAtivOnline	ValQtdeForum	QtdeAcessoSem	QtdeAtiv	QtdeAtivOnline	QtdeForum
Student13	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"19^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"6^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"5^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student15	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"19^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"6^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student21	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"5^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student16	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"15^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"5^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"3^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student22	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"15^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"4^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"2^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"2^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student17	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"56^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"8^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"4^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student24	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"30^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"5^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"2^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student25	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"25^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"5^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"6^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student10	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"20^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"6^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"6^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student20	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"52^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"6^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"3^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student23	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"65^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"5^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"2^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"4^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student7	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"35^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"6^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"6^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>

Figura 14: Continuação do resultado da consulta SPARQL alto risco de reprovação ou evasão.

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

A Figura 15 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.

```

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:valCountActivity40Online ?ValQtdeAtivOnline .
  ?Student ex:valCountForum ?ValQtdeForum .
  ?Student ex:countAccessPerSemester ?QtdeAcessoSem .
  ?Student ex:countActivity ?QtdeAtiv .
  ?Student ex:countActivity40Online ?QtdeAtivOnline .
  ?Student ex:countForum ?QtdeForum .
  FILTER (?Risco > -1 && ?Risco < 1)
} ORDER BY ?Risco

```

Figura 15: Consulta SPARQL para risco moderado de reprovação ou evasão.

A Figura 16 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 apresenta o valor do escore de risco considerando 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).

Student	Registro	Nome	Risco	ValQtdeAcesso...	ValQtdeAtiv
Student2	"2002^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"Aluno2^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student8	"2008^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"Aluno8^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student5	"2005^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"Aluno5^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>
Student14	"2014^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"Aluno14^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"0^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>	"-1^AA<http://www.w3.org/1999/02/22-rdf-syntax-ns#>

Figura 16: Resultado da consulta SPARQL para risco moderado de reprovação ou evasão.

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

Foram conduzidas consultas para identificar quais alunos têm probabilidade baixa de reprovar ou abandonar o curso. A consulta correspondente está representada na Figura 17.

```

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

```

Figura 17: Consulta SPARQL para baixo risco de reprovação ou evasão.

Após a realização da consulta, nove alunos foram classificados com baixo risco de abandono, como evidenciado na Figura 18.

Student	Registro	Nome	Risco	ValQtdeAcessoSem	ValQtdeAtiv
Student18	"2018"	"Aluno18"	"2"	"1"	"1"
Student3	"2003"	"Aluno3"	"2"	"1"	"1"
Student9	"2009"	"Aluno9"	"2"	"1"	"1"
Student4	"2004"	"Aluno4"	"3"	"1"	"0"
Student6	"2006"	"Aluno6"	"3"	"1"	"0"
Student11	"2011"	"Aluno11"	"3"	"1"	"0"
Student1	"2001"	"Aluno1"	"3"	"1"	"0"
Student19	"2019"	"Aluno19"	"3"	"1"	"0"
Student12	"2012"	"Aluno12"	"3"	"1"	"0"

Figura 18: Resultado da consulta SPARQL para baixo risco de reprovação ou evasão.

As primeiras três colunas da Figura 18 exibem dados sobre os alunos. Nas demais colunas, são apresentados o valor do escore de risco considerando os acessos semestrais, envio de atividades e participação nos fóruns. Algumas colunas foram omitidas para melhor apresentação dos resultados. A soma desses critérios determina o valor do escore total apresentado na coluna 4 (Risco).

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 do aluno é apresentada na Figura 19. 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.

```

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:countActivity4Online ?QtdeAtivOnline .
  ?Student ex:countForum ?QtdeForum .
  FILTER (?Risco <= -1 && ?QtdeAtiv < 9 && ?QtdeAtivOnline < 5 && ?QtdeForum < 6)
} ORDER BY ?Nome

```

Figura 19: Consulta SPARQL para hábitos de estudos ou comportamento.

A Figura 20 apresenta o resultado da consulta para hábitos dos alunos com alta probabilidade de evadir do curso, as primeiras três colunas mostram os indivíduos (instâncias *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). Duas colunas foram omitidas para melhor apresentação dos resultados, a quantidade de participação nas atividades disponibilizadas virtualmente (QtdeAtivOnline), tais como *meet*, *chat*, envio de mensagens e a quantidade de participação nos fóruns (QtdeForum).

Student	Registro	Nome	Risco	QtdeAtiv
Student13	"2013" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"Aluno13" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"-4" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"6" ^{AA} <http://www.w3.org/2001/XMLSchema#>
Student15	"2015" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"Aluno15" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"-4" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"6" ^{AA} <http://www.w3.org/2001/XMLSchema#>
Student16	"2016" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"Aluno16" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"-4" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"5" ^{AA} <http://www.w3.org/2001/XMLSchema#>
Student17	"2017" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"Aluno17" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"-2" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"8" ^{AA} <http://www.w3.org/2001/XMLSchema#>
Student20	"2020" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"Aluno20" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"-2" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"6" ^{AA} <http://www.w3.org/2001/XMLSchema#>
Student21	"2021" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"Aluno21" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"-4" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"1" ^{AA} <http://www.w3.org/2001/XMLSchema#>
Student22	"2022" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"Aluno22" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"-3" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"4" ^{AA} <http://www.w3.org/2001/XMLSchema#>
Student23	"2023" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"Aluno23" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"-1" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"5" ^{AA} <http://www.w3.org/2001/XMLSchema#>
Student24	"2024" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"Aluno24" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"-2" ^{AA} <http://www.w3.org/2001/XMLSchema#>	"5" ^{AA} <http://www.w3.org/2001/XMLSchema#>

Figura 20: Resultado da Consulta SPARQL para hábitos de estudos ou comportamento.

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.

4.2 Avaliação do Modelo Athena

A educação a distância enfrenta desafios, e a oferta de serviços inteligentes desempenha um papel estratégico para superá-los. Alguns desafios incluem: 1) a sensação de solidão e desconexão em ambientes virtuais de aprendizagem, o que pode impactar negativamente o desempenho acadêmico dos alunos; 2) dificuldades de personalização, uma vez que cada aluno possui um estilo de aprendizagem e necessidades específicas, demandando uma abordagem individualizada; 3) a falta de identificação precoce de alunos com problemas acadêmicos ou em risco de evasão, sem um sistema eficiente de monitoramento e

intervenção e, 4) 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, ou seja, 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 professores, 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. O uso inteligente dos recursos das tecnologias de informação é essencial para a criação e disponibilidade destes serviços.

4.2.1 Cenário de Avaliação dos serviços inteligentes

Para validar o Athena, foram implementados e avaliados dois serviços inteligentes específicos para professores e gestores: o *Forecasting* e o *Grouping*. O primeiro analisa o desempenho acadêmico dos alunos e identificar possíveis riscos de evasão ou reprovação. Já o segundo, forma grupos de estudos personalizados para promover o aprendizado colaborativo entre os alunos.

Uma aplicação *Web*³ foi desenvolvida com o propósito de disponibilizar os serviços para validação do modelo. Uma vez logado na aplicação, um professor pode utilizar o serviço *Forecasting* para identificar padrões e tendências que ajudam a entender melhor os fatores que influenciam o desempenho dos seus alunos. Isso permite que eles ajustem suas práticas de ensino e desenvolvam estratégias mais eficazes para apoiar o sucesso dos alunos.

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, conforme parecer número 5.715.703.

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, questionários, total de atividade *online*, como participação em *chat*, *meet*, envio de mensagens e participação em fórum.

As Figuras 21 e 22 apresentam um exemplo da base de dados utilizada no serviço de análise e na formação de grupos de estudos. Esta consolida os históricos de contextos agrupados por semestre.

³ <https://modelo-athena.vercel.app/home>

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

Figura 21: Exemplo de dados dos alunos na base de dados.

Na Figura 21 são apresentados os dados de identificação, nome dos alunos, idade, gênero, ano, curso, semestre, disciplina, acesso dos alunos durante o semestre, a participação nos chats e mensagens. Na Figura 22 são apresentados os dados de identificação, nome dos alunos, a participação em fórum, *meet*, vídeos, total de atividades realizadas, material didático, avaliações parciais e oficiais realizadas no semestre.

As análises foram desenvolvidas na linguagem *Typescript*⁴, juntamente com as bibliotecas *React*⁵, *Next*⁶ e o *Prisma ORM*⁷. O banco de dados utilizado foi *Postgresql*⁸. As ferramentas *Chart.js* e *React-Chart.js* foram utilizadas na criação dos gráficos no *React*.

ID	NOME	FÓRUM	MEET	VÍDEOS	TOTAL ATIVIDADES	MATERIAL	ATIVIDADE	ATIVIDADE	AVALIAÇÃO PARCIAL SEMESTRAL	AVALIAÇÃO OFICIAL SEMESTRAL	TOTAL ATIVIDADES
1	aluno 1	12	1	4	5	10	3	3	2	2	10
2	aluno 2	6	0	2	0	5	1	2	1	2	6
3	aluno 3	12	1	4	7	10	2	3	2	2	9
4	aluno 4	12	1	4	6	10	3	4	2	2	10
5	aluno 5	10	0	4	0	10	2	3	2	2	9
6	aluno 6	12	1	4	4	10	2	4	2	2	10
7	aluno 7	6	0	3	0	6	1	2	1	2	6
8	aluno 8	6	1	2	5	5	3	2	1	1	7
9	aluno 9	12	1	4	5	10	2	3	2	2	9
10	aluno 10	6	0	2	0	5	2	2	1	1	6
11	aluno 11	12	1	4	7	10	2	4	2	2	10
12	aluno 12	12	1	3	5	8	2	4	2	2	10
13	aluno 13	5	0	2	0	8	1	4	0	1	6
14	aluno 14	8	0	1	0	5	1	2	1	1	5
15	aluno 15	1	0	1	0	6	1	1	2	2	6
16	aluno 16	3	0	1	0	4	2	2	1	0	5
17	aluno 17	4	0	3	0	10	2	3	1	2	8
18	aluno 18	12	1	3	12	8	2	4	1	2	9
19	aluno 19	12	1	4	13	7	2	4	2	2	10
20	aluno 20	3	0	2	1	5	2	2	1	1	6
21	aluno 21	0	0	0	0	3	1	0	0	0	1
22	aluno 22	2	0	1	2	3	1	1	1	1	4
23	aluno 23	4	1	2	2	7	1	2	1	1	5
24	aluno 24	2	1	0	1	5	1	2	1	1	5
25	aluno 25	6	1	1	1	6	1	2	1	1	5

Figura 22: Complemento aos dados da Figura 21.

⁴ 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.

⁵ Biblioteca *front-End JavaScript* de código aberto com foco em criar interfaces de usuário em páginas web para criar as interfaces.

⁶ Biblioteca escrita em *Javascript* para desenvolvimento de interfaces baseada em componentes.

⁷ Biblioteca que facilita a integração com o banco de dados.

⁸ Sistema gerenciador de banco de dados objeto relacional, desenvolvido como projeto de código aberto.

4.2.2 *Forecasting* - Serviço inteligente para antecipar o desempenho acadêmico dos alunos

O *Forecasting* é um serviço inteligente que faz uso de históricos de contextos para antecipar a 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 antecipação 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.

A seleção dos critérios para reprovação ou evasão 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. Além destes, outros podem ser utilizados ampliando desta forma a capacidade do modelo. Um parâmetro utilizado na composição das regras para formação de grupos foi a quantidade de acessos no semestre (30), número que representa uma quantidade mínima esperada para o acesso de um aluno no seu ambiente virtual de aprendizagem.

Os critérios utilizados para a definição dos grupos por riscos foram: 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 Figura 23 apresenta a tela do serviço inteligente *Forecasting* e o resultado da análise de 25 alunos do curso de Tecnologia em Análise e Desenvolvimento de Sistemas. 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. O gráfico apresentado na Figura 23 exhibe, 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.

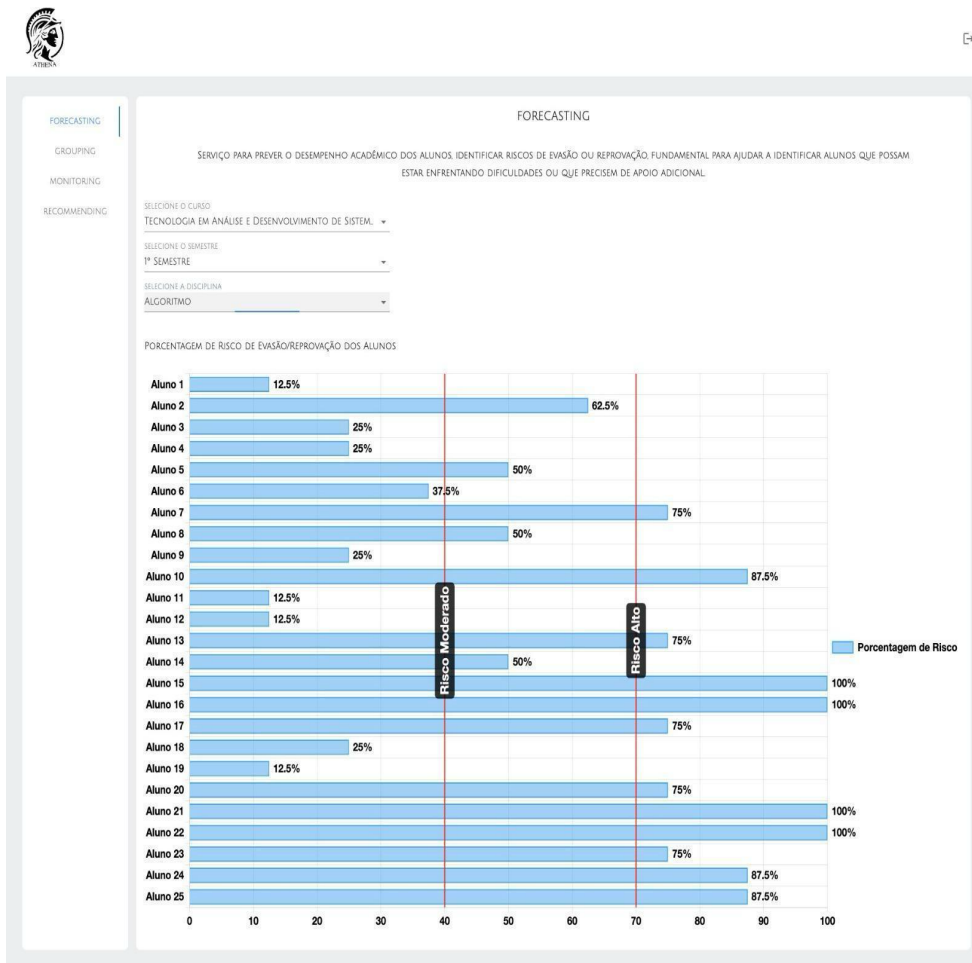


Figura 23: Resultado da análise.

Além disso, o gráfico apresenta 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. Esses alunos foram acompanhados durante 5 semestres e dentre os doze alunos identificados com alto grau de reprovação ou evasão, oito não conseguiram terminar o curso.

4.2.3 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 de risco dos alunos em curso. Em uma fase anterior, o serviço *Forecasting* realiza a antecipação 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. Para formar grupos equilibrados, o sistema garante que cada grupo contenha uma mistura de estudantes de baixo, médio e alto riscos.

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. 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, conforme Figura 24.

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.

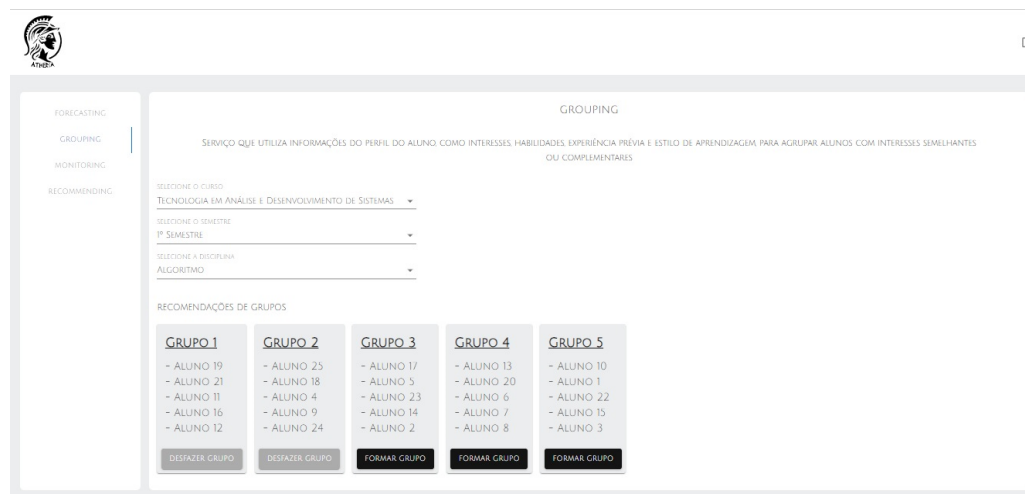


Figura 24: Resultado da Formação de grupos de estudos.

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. 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.

5 Considerações Finais

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, o Athena, é 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.

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

O modelo foi validado através de uma ontologia e de dois serviços inteligentes como instrumentos de avaliação. O primeiro serviço destina-se a auxiliar os instrutores da EaD 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.

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 identificação de reprovação e evasão, assim como na formação de grupos de estudo.

O modelo pode contribuir 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 diferencial científico do Athena reside na aplicação de dados contextuais, como acessos, interações em fóruns, *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 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.

O desenvolvimento do Athena está limitado à escolha das informações que compõem os históricos de contextos dos alunos, a ausência de contribuições de profissionais da área da educação para a elaboração das perguntas e respostas sobre EaD junto ao ambiente virtual e para a definição das questões de competências da ontologia. Com base nos resultados obtidos, é possível listar novas oportunidades e trabalhos futuros: 1) avaliar a OntoAthena com especialistas em EaD; 2) avaliar o modelo em um cenário com uma quantidade maior de dados; 3) desenvolver e validar outros serviços inteligentes e, 4) integrar o Athena no ambiente virtual *moodle* ou outros ambientes virtuais de aprendizagem.

Agradecimentos

Os autores agradecem à Universidade do Vale do Rio dos Sinos (Unisinos) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio ao desenvolvimento desse trabalho. Os autores reconhecem especialmente o apoio do Programa de Pós-Graduação em Computação Aplicada (PPGCA) e do Laboratório de Computação Móvel (Mobilab) da Unisinos.

Referências

- Allmendinger, G., Lombreglia, R. (2005). Four strategies for the age of smart services. *Harvard Business Review*. ISSN:00178012, 83(10), 131-145. <https://hbr.org/2005/10/four-strategies-for-the-age-of-smart-services>. [GS Search]
- Almeida Maia, M. D. S. de, Silva, D. G. (2020). Práticas pedagógicas em ambientes virtuais de aprendizagem: usos e abusos. *EmRede - Revista de Educação a Distância*, [S.l.], 7(1), 81–95. Disponível em: <https://www.aunirede.org.br/revista/index.php/emrede/article/view/555>. <https://doi.org/10.53628/emrede.v7i1.555>. [GS Search]
- Almeida Neto, F. A. D. (2017). Um Framework para Criação de Serviços Inteligentes em Ambientes Flexíveis na Web. Universidade Federal do Amazonas (216 páginas). Disponível em: <https://tede.ufam.edu.br/handle/tede/6755?mode=full>. [GS Search]
- 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>. [GS Search]
- 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, 13(1), 1–15. <https://doi.org/10.21307/ijssis-2020-035>. [GS Search]
- Anjos, R. A. V. (2015). Referencial Pedagógico Para Análise de Ambientes Virtuais de Aprendizagem. Disponível em: <http://ri.ufmt.br/handle/1/74>. [GS Search]
- Aranda, J.A.S., Bavaresco, R.S., de Carvalho, J.V. et al. A computational model for adaptive recording of vital signs through context histories. *J Ambient Intell Human Comput* 14, 16047–16061 (2023). <https://doi.org/10.1007/s12652-021-03126-8>. [GS Search]

- 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. <https://doi:10.46328/ijres.v6i4.1022>. [GS Search]
- Beverungen, D., Müller, O., Matzner, M. et al. (2019) Conceptualizing smart service systems. *Electron Markets* 29, 7–18. <https://doi.org/10.1007/s12525-017-0270-5>. [GS Search]
- Bezerra, C., Freitas, F., Santana da Silva, F. (2013). CQChecker: A Tool to Check the Satisfaction of Description Logic Competency Questions on Ontologies. Conference: X Encontro Nacional de Inteligência Artificial e Computacional (ENIAC). At: Fortaleza. Disponível em: <https://sbic.org.br/lnlm/publicacoes/vol12-no2/vol12-no2-art4/> [GS Search]
- Campos, A., Hollerweger, L., Santos, G., Farias, A. F., Behar, P. A. (2017) Mapeamento de Soluções tecnológicas em Sistemas de Recomendação Educacionais em âmbito brasileiro. *Informática na Educação: teoria & prática*, Porto Alegre, 20(3), 79-96. <https://seer.ufrgs.br/index.php/InfEducTeoriaPratica/article/view/79624>. [GS Search]
- 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. <https://doi.org/10.26599/TST.2019.9010014>. [GS Search]
- 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, 987-1003. <https://doi.org/10.1007/s10115-019-01374-x>. [GS Search]
- Costa, M. A. B., Guedes, P. da S., & Guerra, R. S. (2021). Desafios da educação a distância on-line. *Revista Ibero-Americana De Humanidades, Ciências e Educação*, 7(9), 766–776. <https://doi.org/10.51891/rease.v7i9.2279>. [GS Search]
- 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, 333-342. <https://doi.org/10.1109/ICSME.2019.00051>. [GS Search]
- Dias, R. S. (2017) Caracterização do learning analytics na educação a distância. *Anais do Seminário de Pesquisa e Inovação Tecnológica - SEPIT*, [S. l.], 1(1). Disponível em: <https://periodicos.iftm.edu.br/index.php/sepit/article/view/312>. [GS Search]
- 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, 85, 1–6. <https://doi.org/10.1145/3167486.3167574>. [GS Search]
- Flach, L. (2022) 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*. Disponível em: <https://repositorio.ufsc.br/handle/123456789/238320> [GS Search]
- 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: <https://doi.org/10.1016/j.infsof.2020.106497>. [GS Search]
- Freitas, F. A. da S., Vasconcelos, F. F. X., Peixoto, S. A., Hassan, M. M., Dewan, M. A. A., Albuquerque, V. H. C. de, Filho, P. P. R. (2020). IoT System for School Dropout Prediction Using Machine Learning Techniques Based on Socioeconomic Data. *Electronics*, 9(10):1613. <https://doi.org/10.3390/electronics9101613>. [GS Search]
- 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>. [GS Search]
- 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. <https://doi.org/10.1088/1757-899X/928/3/032019>. [GS Search]
- 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>. [GS Search]
- Heckler, W. F; Feijó, L.P.; Carvalho, J. C.; Barbosa, L. J. V. (2023). Thoth: An intelligent model for assisting individuals with suicidal ideation, *Expert Systems with Applications*, Volume 233, 120918, ISSN 0957-4174, DOI: <https://doi.org/10.1016/j.eswa.2023.120918>. [GS Search]
- Iatrellis, O., Savvas, I. K., Fitsilis, P., Gerogiannis, V. C. (2021). A two-phase machine learning approach for predicting student outcomes. *Education and Information Technologies* 26(1), 69–88. <https://doi.org/10.1007/s10639-020-10260-x>. [GS Search]
- Kim, W., Kim, J. (2020). Individualized AI Tutor Based on Developmental Learning Networks, in *IEEE Access*, 8, 27927-27937. <https://doi.org/10.1109/ACCESS.2020.2972167>. [GS Search]
- 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. https://doi.org/10.1007/978-3-030-69380-0_12. [GS Search]
- Koldewey, C., Meyer, M., Stockbrügger, P., Dumitrescu, R., Gausemeier, J. (2020). Framework and Functionality Patterns for Smart Service Innovation, *Procedia CIRP*, ISSN 2212-8271, 91, 851-857. <https://doi.org/10.1016/j.procir.2020.02.244>. [GS Search]
- Larentis A. V. *Salus: um modelo para assistência educacional ubíqua em doenças crônicas não transmissíveis*. Tese. Universidade do Vale do Rio dos Sinos – UNISINOS. São Leopoldo, Rs. 2022. Disponível em: <https://repositorio.jesuita.org.br/> [GS Search]
- 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>. [GS Search]
- 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>. [GS Search]
- 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>. [GS Search]
- Martini, B. G.; Helfer, G. A.; Barbosa, J. L. V.; Espinosa Modolo, 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>. [GS Search]
- Noy, N. & McGuinness, D. (2001). *Ontology Development 101: A Guide to Creating Your First Ontology*. Knowledge Systems Laboratory. 32. Disponível: [Ontology Development 101: A Guide to Creating Your First Ontology](#) [GS Search]
- Rodrigues, F. C.; Filippetto, A. S.; Lima, R. K. D.; Heckler, W. F.; Barbosa, J. L. V. (2022). Kairós: using context histories for predictions and recommendations in projects time management. *International Journal of Agile Systems and Management (IJASM)*, Vol. 15, No. 1, 2022. DOI: <https://doi.org/10.1504/IJASM.2022.124168>. [GS Search]
- Silva, L. M. da; Barbosa, J. L. V.; Rigo, S. J. Análise de Dados e Serviços Inteligentes Aplicados na Educação à Distância: um mapeamento sistemático. *Revista Brasileira de Informática na Educação*, [S. l.], v. 29, p. 331–357, 2021. DOI: 10.5753/rbie.2021.29.0.331. Disponível em: <https://journals-sol.sbc.org.br/index.php/rbie/article/view/2983>. [GS Search]
- Silva, Lidia M, da; Dias, Lucas; Barbosa, Jorge; Rigo, Sandro; Anjos, Julio Geyer, Claudio Leithardt, Valderi. (2022). Learning analytics and collaborative groups of learners in distance education. Doi: <https://doi.org/10.15388/infedu.2022.05>. Disponível em: <https://infedu.vu.lt/journal/INFEDU/article/695/info>. [GS Search]
- 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>. [GS Search]
- Web Protégé. Disponível em: <https://protege.stanford.edu/>. [GS Search]
- Wiedemann, T.; Barbosa, J.; Matter, V.; Gonçales, L.; Nesi, L.; Farias, 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>. [GS Search]
- 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. <https://doi.org/10.1145/3386723.3387890>. [GS Search]

Apêndice A: Comparativo dos trabalhos relacionados.

Referência	Qual serviço inteligente	Considera grupos / atividades de colaboração	Considera contextos	Modelo, Sistema ou Arquitetura	Suporta serviços genéricos	Qual técnica / tecnologia foi utilizada	Tem ontologia
(KOTSIANTIS et al., 2010)	Previsão do desempenho	Não	Não	Modelo	Não	Combinação de uma versão incremental do <i>Naive Bayes</i> , os algoritmos 1-NN e <i>WINNOWER</i> utilizam a metodologia de votação.	Não
(CHANG et al. 2010)	Recomendação de conteúdos de aprendizagem.	Não	Não	Modelo	Não	Redes de Petri comportamentais de aprendizagem.	Não
(ZORRILA et al., 2010)	Sistema de tomada de decisão.	Não	Não	Modelo	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	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	Não	Técnicas de sistema de recomendação com métodos tradicionais de regressão, como regressão logística e linear.	Não
(GRAF et al., 2011)	Sistema de consultas analíticas simples e complexas sobre o comportamento dos alunos.	Não	Não	Sistema	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	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 <i>web</i> que pode ajudar os alunos a encontrar um caminho de aprendizagem em um sistema de <i>e-learning</i> .	Não	Não	Sistema	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	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	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	Não	Técnicas de aprendizado de máquina: seletor de atributos, algoritmo de árvore de decisão.	Não

Referência	Qual serviço inteligente	Considera grupos / atividades de colaboração	Considera contextos	Modelo, Sistema ou Arquitetura	Suporta serviços genéricos	Qual técnica / tecnologia foi utilizada	Tem ontologia
(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	Não	<i>Moodle, EvalCourse, Eclipse IDE.</i>	Não
(DIMOPOULOS et al. 2013)	Ferramenta de avaliação, chamada Rubrica Enriquecida de análise de Aprendizagem.	Não	Não	Sistema	Não	<i>Pugin Moodle.</i>	Não
(MANHÃES et al., 2014)	<i>WAVE</i> : uma arquitetura para prever a evasão em cursos de graduação.	Não	Não	Modelo	Não	Técnicas de classificação: <i>Naïve Bayes, Multilayer Perceptron, Support Vector Machine</i> com <i>kernel</i> polinomial (SVM1) e <i>kernel</i> RBF (SVM2) e <i>Decision Table</i> .	Não
(YANG et al., 2014)	Método de predição de estilos de aprendizagem.	Não	Não	Modelo	Sim	Técnica de reconhecimento de padrões.	Não
(LARA et al., 2014)	Sistema de Mineração de Dados Educacionais.	Não	Não	Modelo	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	Não	<i>IMS 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	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	Não	<i>Apache Hadoop, 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	Não	Tecnologia da <i>web</i> semântica.	Sim
(VENUGOPALAN et al. 2016)	Sistema de recomendação baseado em conteúdo.	Não	Não	Sistema	Não	.NET e sistema ASP.	Sim
(EL FOUKI et al., 2017)	Sistema de tomada de decisão.	Não	Não	Modelo	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 <i>web</i> .	Não	Não	Modelo	Não	Técnicas de mineração de dados.	Não

Referência	Qual serviço inteligente	Considera grupos / atividades de colaboração	Considera contextos	Modelo, Sistema ou Arquitetura	Suporta serviços genéricos	Qual técnica / tecnologia foi utilizada	Tem ontologia
(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	Não	<i>Rapid Application Development.</i>	Não
(OMAR; ABDESSELAM, 2017)	Classificação de usuários na plataforma sem classes previamente conhecidas.	Não	Não	Modelo	Não	Algoritmos de agrupamento.	Não
(OKUBO et al., 2017)	Método para prever notas finais de alunos.	Não	Não	Modelo	Não	Rede Neural Recorrente.	Não
(CHAFFAI et al., 2017)	Arquitetura da infraestrutura de <i>pipeline</i> ETL escalável para análise exploratória dos dados dos alunos.	Não	Não	Arquitetura	Não	<i>Hadoop e Spark.</i>	Não
(ROS et al., 2017)	Análise exploratória de dados.	Não	Não	Modelo	Não	Algoritmo PCA (<i>Principal Component Analysis</i>).	Não
(HUSSAIN et al., 2018)	Modelo preditivo de resultado ou comportamento com base em dados de registros no <i>Moodle</i> .	Não	Não	Modelo	Não	Técnica estatística de <i>Machine Learning</i> .	Não
(OLIVÉ et al., 2018)	Modelos de previsão de mineração de dados educacionais.	Não	Não	Modelo	Sim	API12 do <i>Moodle Analytics</i> , <i>back-end</i> de <i>Machine Learning</i> .	Não
(QU et al., 2018)	Estrutura de previsão de desempenho do aluno.	Não	Não	Modelo	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	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	Não	Alocação de <i>Dirichlet</i> Latente.	Não
(SPATIOTIS et al., 2018)	Plataforma para classificação de opinião.	Não	Não	Arquitetura	Não	Técnicas de mineração de textos.	Não
(DAHDOUH et al., 2018)	Sistema de aprendizagem <i>online</i> .	Não	Não	Sistema	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	Não	Algoritmo <i>Naive Bayesiano</i> .	Sim
(CHANAA; FADDOULI, 2018)	Modelo personalizado de recomendação.	Não	Sim	Modelo	Não	Algoritmo de rede neural LSTM.	Não

Referência	Qual serviço inteligente	Considera grupos / atividades de colaboração	Considera contextos	Modelo, Sistema ou Arquitetura	Suporta serviços genéricos	Qual técnica / tecnologia foi utilizada	Tem ontologia
(ISLAM et al., 2019)	Mineração de dados para prever comportamentos dos alunos.	Não	Não	Modelo	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	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	Não	<i>Deep Neural Networks</i> .	Não
(HUANG et al., 2019)	Estrutura de aprendizado de reforço profundo para recomendação de exercícios.	Não	Não	Sistema	Não	Redes Q de Exercícios diferentes para o agente para gerar recomendações seguindo a propriedade de <i>Markov</i> .	Não
(WANG et al., 2019)	Sistema inteligente de assistente de ensino.	Não	Não	Modelo	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	Não	<i>Resource Description Framework (RDF)</i> . <i>JAVA</i> .	Sim
(IQBAL et al., 2019)	Algoritmo, o <i>Kernel Context Recommender System</i> .	Não	Não	Modelo	Não	Técnica de aprendizagem de estrutura.	Não
(DAHDOUH et al., 2019)	Sistema de recomendação inteligente aplicado em um ambiente de aprendizagem <i>online</i> .	Não	Não	Sistema	Não	Tecnologias e técnicas de <i>Big Data</i> , <i>Spark Framework</i> , <i>Hadoop</i> .	Não
(ALTAF et al., 2019)	Previsão do desempenho.	Não	Não	Modelo	Não	Rede Neural.	Não
(RUANGVANI CH et al. 2019)	Sistema de análise de aprendizagem como uma ferramenta para apoiar a aprendizagem dos alunos.	Não	Não	Sistema	Não	Ciclo de vida de desenvolvimento de sistemas.	Não
(UZIR et al., 2020)	Metodologia de análise de aprendizado.	Não	Não	Modelo	Não	<i>Cluster</i> hierárquico aglomerativo, análise epistêmica de redes e mineração de processos.	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	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 <i>online</i> dos alunos.	Não	Não	Modelo	Não	Algoritmo <i>Expectation-Maximization (EM)</i> adaptado para tarefas de mineração de processos, pacote <i>pMineR</i> .	Não
(CHEN et al., 2020a)	Recomendação Adaptativa com base no <i>Online Learning Style</i> .	Sim	Não	Modelo	Não	Algoritmo <i>Apriori</i> , <i>-Kmeans</i> .	Não

Referência	Qual serviço inteligente	Considera grupos / atividades de colaboração	Considera contextos	Modelo, Sistema ou Arquitetura	Suporta serviços genéricos	Qual técnica / tecnologia foi utilizada	Tem ontologia
(CHEN et al., 2020b)	Modelo de previsão em fases para prever alunos em risco em diferentes semestres.	Não	Não	Modelo	Não	Algoritmos <i>K-means</i> .	Não
(KIM; KIM, 2020)	Tutor individualizado de Inteligência Artificial que sugere conteúdos de aprendizagem.	Não	Não	Modelo	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	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	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	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	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	Não	<i>Felder-Silverman Learning Style Model</i> , <i>Fuzzy C Means</i> .	Não
(ULLAH et al., 2020)	Modelo IoT baseado em SDN (Rede definida por <i>software</i>) para a interação dos alunos.	Não	Não	Modelo	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 <i>e-learners</i> .	Não	Não	Modelo	Não	Questionários VARK, <i>Chatbot</i> , <i>Naïve Bayes</i> , N48 e <i>Canopy</i> .	Não
(SHI et al., 2020)	Modelo de recomendação de caminho de aprendizagem qualificado e personalizado para melhorar as experiências de aprendizagem.	Não	Não	Modelo	Não	Estrutura de grafo de conhecimento multidimensional.	Não

Referência	Qual serviço inteligente	Considera grupos / atividades de colaboração	Considera contextos	Modelo, Sistema ou Arquitetura	Suporta serviços genéricos	Qual técnica / tecnologia foi utilizada	Tem ontologia
(LIN et al., 2020)	Estrutura de recomendação complementar para calouros sob restrições ou requisitos, com base em padrões orientados a metas.	Não	Não	Sistema	Não	<i>MATLAB</i> 2015b (<i>Corell</i> 2.54, <i>Win</i> 7)	Não
(NIKNAM; THULASIRAM AN, 2020)	Sistema de recomendação de caminhos de aprendizagem.	Não	Não	Sistema	Não	Teoria de aprendizagem significativa de <i>Ausubel</i> e algoritmo de otimização de colônia de formigas <i>Fuzzy</i> Algoritmo <i>C-Mean</i> .	Não
(VILLEGAS-CH et al., 2020)	Arquitetura para a integração de um <i>chatbot</i> com inteligência artificial em um campus inteligente para melhorar o aprendizado através de recomendação de atividades.	Não	Não	Arquitetura	Não	<i>Chatbot</i> , 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	Não	<i>Plugins</i> do ambiente virtual <i>Moodle</i> .	Não
(ANGELINE et al., (2020)	Análise discriminante para medir o desempenho dos alunos.	Não	Não	Modelo	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	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	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
(BARLYBAYE V et al., 2020)	Sistema inteligente para avaliar os níveis de competências profissionais dos alunos em <i>e-learning</i> .	Não	Não	Modelo	Não	Relações binárias <i>fuzzy</i> , método <i>Mamdani</i> , <i>Matlab</i> .	Não
(HAN; XU, 2021)	Plataforma de educação inteligente com base em aprendizagem profunda e detecção de imagens.	Não	Não	Modelo	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	Não	Técnicas de aprendizado supervisionado e não supervisionado, algoritmo <i>K-Means</i> .	Não

Referência	Qual serviço inteligente	Considera grupos / atividades de colaboração	Considera contextos	Modelo, Sistema ou Arquitetura	Suporta serviços genéricos	Qual técnica / tecnologia foi utilizada	Tem 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	Não	Conjunto de classificadores de aprendizado de máquina, como KNN, rede neural recorrente em camadas, <i>Naïve Bayes</i> e rede neural artificial.	Não
(MAËLOUL; BAHOU, 2021)	Sistema de recomendação que se baseia fundamentalmente em uma técnica de aprendizagem digital.	Não	Não	Modelo	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	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	Não	Sensor <i>Kinect</i> , <i>Web Server</i> , <i>Api (Node JS)</i> , <i>Database (MongoDB)</i> , <i>.NET Framework</i> .	Não

Apêndice B: Comparativo dos trabalhos relacionados com Ontologias.

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 <i>tags HTML</i> 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; DAUDI; AJHOUN (2019)	Recursos educacionais para <i>MOOCs</i> , <i>OERs</i> , plataformas de <i>e-learning</i> .	Não mencionado	Não	Não	Não	Não	Distância Euclidiana, uso <i>dataset</i> 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
BOUREKKACHE et al. (2019)	Estilos de aprendizagem e perfil do aluno.	Não mencionado	Regras de adaptação	SPARQL	Não	Não	Não
GRIVOKOSTOPOULOU et al. (2019)	Genérica.	Não mencionado	Regras da <i>Web Rule Language</i> .	SPARQL	Não	Não	Regra para responder uma questão de pesquisa.

Referência	Domínio	Metodologia	Regras	Consultas	Reuso	Contexto	Avaliação
MOHEMAD et al. (2020)	Educação especial (dislexia, discalculia, disgrafia) em sistemas de e-learning.	Define três passos: especificação, conceitualização, formalização e implementação	Regras da <i>Web Rule Language</i> .	SPARQL	Não	Não	Não
BOLOCK; ABDENNADHER; HERBERT (2021)	Estado psicológico de estudantes durante 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 e-learning.	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

Apêndice C: Resumo dos artigos de autoria dos autores.

Referência	Assunto	Resumo
ANDRADE; RIGO; BARBOSA (2022).	Mapeamento sistemático sobre metodologia ativa, mineração de dados educacionais e análise de aprendizagem.	O trabalho apresenta um mapeamento sistemático de métodos de Mineração de Dados Educacionais e Análise de Aprendizagem, além da aplicação de Metodologias Ativas para reduzir a evasão.
ARANDA; BAVARESCO; et al. (2023).	Um modelo computacional para registro adaptativo de sinais vitais por meio de históricos de contextos.	O trabalho apresenta um modelo adaptativo e sensível ao contexto para coleta de sinais vitais, que permite análises personalizadas da saúde e otimiza recursos computacionais ao reduzir o consumo de energia e a quantidade de dados coletados.
FILIPPETTO; LIMA; BARBOSA (2021).	Modelo de predição de risco para gerenciamento de projetos de software baseado em análise de similaridade de históricos de contexto.	O trabalho propõe um modelo computacional que utiliza históricos de contexto para prever e recomendar riscos, ajudando a reduzir falhas e a apoiar equipes na identificação e monitoramento de riscos ao longo do ciclo de vida dos projetos.
GARCIA MARTINS; NESI; SILVA PEREIRA; BARBOSA (2021).	Um Modelo para Análise Multitemporal Baseado em Contextos Históricos.	O artigo apresenta um modelo de análise multitemporal baseado em contextos históricos, testado com dados reais de uma subestação de energia e de atletas de futsal. Os resultados mostraram alta precisão na criação de perfis e na predição de contextos.
HECKLER; DE CARVALHO; BARBOSA (2020).	Uma revisão sistemática da literatura sobre aprendizado de máquina para identificação de ideação suicida.	O artigo realiza uma revisão sistemática sobre o uso de aprendizado de máquina na identificação da ideação suicida, analisando 54 estudos. A pesquisa destaca técnicas, dados, dispositivos e aplicabilidade, além de propor taxonomias sobre abordagens utilizadas e desafios da área.
HECKLER; FEIJÓ; CARVALHO; BARBOSA (2023).	Um modelo inteligente para auxiliar indivíduos com ideação suicida.	O estudo apresenta um modelo inteligente que utiliza dados sensoriais, psicológicos e sociodemográficos para identificar precocemente o risco de ideação suicida e oferecer atendimento personalizado, avaliado por meio de um protótipo com coleta de dados de três pacientes e técnicas de ampliação de dados.
LARENTIS (2022).	Um modelo para assistência educacional ubíqua em doenças crônicas não transmissíveis.	A tese apresenta um modelo computacional que usa históricos de contextos para fornecer assistência educacional ubíqua na prevenção e acompanhamento das DCNTs, adaptando-se aos recursos disponíveis e personalizando serviços.
LARENTIS; NETO; BARBOSA; BARBOSA; LEITHARDT; CORREIA (2021).	Ontologia baseada em raciocínio para Assistência Educacional em Doenças Crônicas Não Transmissíveis	Este artigo propõe uma ontologia para representar o conhecimento da assistência educacional em DCNTs, visando apoiar práticas e sistemas focados na prevenção e monitoramento dessas doenças.
LIMA; FILIPPETTO; HECKLER; BARBOSA; LEITHARDT (2022).	Engenharia de requisitos ubíqua por meio de recomendações baseadas em históricos de contexto.	O artigo apresenta um modelo computacional que recomenda requisitos reutilizáveis a partir da análise de históricos de contexto e similaridade entre projetos.

Referência	Assunto	Resumo
MACHADO; TAVARES; MARTINS; BARBOSA; GONZÁLEZ; LEITHARDT (2021).	Inteligência Ambiental baseada em IoT para auxiliar pessoas com doença de Alzheimer através de históricos de contexto.	Este artigo apresenta um modelo computacional baseado em ontologia que utiliza dados fisiológicos de aplicações IoT para identificar comportamentos de risco em pacientes com Alzheimer.
MARTINI; HELFER; BARBOSA; ESPINOSA; MODOLO; SILVA; FIGUEIREDO; MENDES; SILVA; LEITHARDT (2021.)	Um modelo para serviços inteligentes na agricultura interna com base em histórias de contexto.	O artigo apresenta um modelo computacional para agricultura indoor que fornece previsões e recomendações baseadas em históricos de contexto, com resultados precisos e alta aceitação por agricultores.
RODRIGUES; FILIPPETTO; LIMA; HECKLER; BARBOSA (2022).	Modelo computacional usando históricos de contexto para previsões e recomendações na gestão do tempo de projetos.	O artigo apresenta um modelo computacional que utiliza históricos de contexto para prever atrasos e oferecer recomendações proativas em cronogramas de projetos, mostrando alta precisão e eficácia na gestão de tarefas.
SILVA et al. (2022)	Mapeamento Sistemático sobre Análise de Aprendizagem e Grupos Colaborativos	O artigo apresenta os resultados de um estudo de mapeamento sistemático com o objetivo de identificar como a mineração de dados educacionais, a análise de aprendizagem e os grupos colaborativos têm sido aplicados em ambientes de educação a distância.
SILVA, BARBOSA e RIGO (2021)	Mapeamento Sistemático sobre análise de dados e Serviços Inteligentes	O artigo apresenta os resultados de um mapeamento sistemático da literatura que visa identificar como a Learning Analytics (LA) e os serviços inteligentes vêm sendo aplicados em ambientes de educação à distância (EAD).
VIELITZ; MARTINS; BARBOSA; OLIVEIRA; DIAS; WOLF (2019).	Estrutura para gerenciar históricos de contexto dinâmicos e hierárquicos.	O artigo apresenta um framework que gerencia informações contextuais dinâmicas e hierárquicas em ambientes físicos, destacando-se por sua capacidade de reorganizar entidades e armazenar contextos variáveis, comprovada em aplicações de monitoramento de movimentos e energia.
WIEDEMANN; BARBOSA; MATTER; GONÇALES; NESI; FARIAS; RIGO (2021).	Estrutura para análise de similaridade de históricos de contexto.	O artigo apresenta um framework extensível para análise de similaridade de históricos de contexto, que oferece recomendações, classificações e predições, demonstrando eficácia em duas aplicações avaliadas.