

UNIVERSIDADE FEDERAL DE PELOTAS
Centro de Desenvolvimento Tecnológico
Programa de Pós-Graduação em Computação



Dissertação

**Sistema de Recomendação de Matrículas a partir do Perfil e do Progresso dos
Estudantes no Contexto de Campus Inteligente**

Fabricio Gonzales Scaglioni

Pelotas, 2021

Fabricio Gonzales Scaglioni

**Sistema de Recomendação de Matrículas a partir do Perfil e do Progresso dos
Estudantes no Contexto de Campus Inteligente**

Dissertação apresentada ao Programa de Pós-Graduação em Computação do Centro de Desenvolvimento Tecnológico da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Júlio Carlos Balzano de Mattos
Coorientador: Prof. Dr. Marilton Sanchotene de Aguiar

Pelotas, 2021

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação na Publicação

S277s Scaglioni, Fabricio Gonzales

Sistema de recomendação de matrículas a partir do perfil e do progresso dos estudantes no contexto de campus inteligente / Fabricio Gonzales Scaglioni ; Júlio Carlos Balzano de Mattos, orientador ; Marilton Sanchotene de Aguiar, coorientador. — Pelotas, 2021.

85 f. : il.

Dissertação (Mestrado) — Programa de Pós-Graduação em Computação, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, 2021.

1. Campus inteligente. 2. Sistema de recomendação. 3. Sistema de recomendação de matrículas. I. Mattos, Júlio Carlos Balzano de, orient. II. Aguiar, Marilton Sanchotene de, coorient. III. Título.

CDD : 005

Fabrizio Gonzales Scaglioni

**Sistema de Recomendação de Matrículas a partir do Perfil e do Progresso dos
Estudantes no Contexto de Campus Inteligente**

Dissertação aprovada, como requisito parcial, para obtenção do grau de Mestre em Ciência da Computação, Programa de Pós-Graduação em Computação, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas.

Data da Defesa: 13 de outubro de 2021

Banca Examinadora:

Prof. Dr. Júlio Carlos Balzano de Mattos (orientador)

Doutor em Computação pela Universidade Federal do Rio Grande do Sul.

Prof. Dr. Marilton Sanchotene de Aguiar (coorientador)

Doutor em Computação pela Universidade Federal do Rio Grande do Sul.

Prof. Dr. Antônio Maurício Medeiros Alves

Doutor em Educação pela Universidade Federal de Pelotas.

Prof. Dra. Larissa Astrogildo de Freitas

Doutora em Ciência da Computação pela Pontifícia Universidade Católica do Rio Grande do Sul.

Prof. Dr. Tiago Thompsen Primo

Doutor em Computação pela Universidade Federal do Rio Grande do Sul.

AGRADECIMENTOS

Agradeço aos meus orientadores, os professores Júlio Carlos Balzano de Mattos e Marilton Sanchotene de Aguiar por toda dedicação e suporte durante o desenvolvimento deste trabalho.

Agradeço também a minha esposa Roberta, pela paciência, companheirismo e apoio para poder superar mais esta etapa da minha jornada acadêmica.

Agradeço ainda a todos aqueles que de alguma forma contribuíram para a realização deste trabalho.

Qualquer tecnologia suficientemente avançada é indistinguível da magia.

— ARTHUR C. CLARKE

RESUMO

SCAGLIONI, Fabricio Gonzales. **Sistema de Recomendação de Matrículas a partir do Perfil e do Progresso dos Estudantes no Contexto de Campus Inteligente.** Orientador: Júlio Carlos Balzano de Mattos. 2021. 85 f. Dissertação (Mestrado em Ciência da Computação) – Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, Pelotas, 2021.

Nas últimas décadas muitos avanços tecnológicos foram atingidos e, com eles, surgiram conceitos de prédios e cidades inteligentes. Concomitantemente surge o conceito de campus inteligente, entendido como a utilização dos conceitos de prédios e cidades inteligentes em um campus universitário. Contudo, não se pode esquecer que o mais importante em um campus universitário é sua comunidade. Sistemas de recomendação têm sido utilizados em um amplo espectro de aplicações. Não é difícil encontrar recomendadores para livros, filmes, músicas e campanhas publicitárias. Focado na comunidade e nos processos acadêmicos executados diariamente, este trabalho visa auxiliar os alunos de graduação no momento da rematrícula através de sistemas de recomendação, os quais direcionam a escolha das disciplinas para aquelas que melhor se adéquam ao momento acadêmico do aluno. Para o desenvolvimento do recomendador foram utilizados algoritmos de recomendação que executam as tarefas de analisar o histórico do aluno, avaliar os pré-requisitos e as equivalências cursadas e recomendar as disciplinas, sendo posteriormente classificadas e selecionadas para então gerar a lista final de recomendações. Como estudo de caso foi utilizado o Curso de Ciência da Computação da UFPel. As recomendações foram geradas para o primeiro semestre do ano de 2019 e comparadas com as disciplinas solicitadas, matriculadas e aprovadas. Foi desenvolvido ainda uma funcionalidade de booster para impulsionar as recomendações de um período específico do currículo do curso. Após a realização dos testes e comparação com o que foi solicitado e cursado pelo aluno chegou-se a acertos de mais de 60%.

Palavras-chave: Campus Inteligente. Sistema de Recomendação. Sistema de Recomendação de Matrículas.

ABSTRACT

SCAGLIONI, Fabricio Gonzales. **Ensemble Recommender System for College Enrollment based on Student Profile and Progress in the Smart Campus Context**. Advisor: Júlio Carlos Balzano de Mattos. 2021. 85 f. Dissertation (Masters in Computer Science) – Technology Development Center, Federal University of Pelotas, Pelotas, 2021.

In recent decades, we have achieved many technological advances and, with them, concepts of smart buildings and cities have emerged. Concomitantly, the concept of smart campus appears, understood as the use of the concepts of smart buildings and cities in a university campus. However, do not forget that the most important thing on a university campus is its community. Therefore, we have used recommender systems in a broad spectrum of applications. It is not hard to find recommenders for books, movies, music, and advertising campaigns. We focused on the community and academic processes performed daily, and this work aims to assist undergraduate students at the time of re-enrollment through recommendation systems, which direct the choice of subjects to those that best suit the student's academic moment. To develop the recommender system, we used algorithms that analyze the student's history, evaluate the prerequisites and equivalences attended and recommend the subjects, which are later classified and selected to generate the final list of recommendations. We used as a case study the Computer Science Course at UFPel. The recommendations were generated for the first semester of 2019 and compared with the requested, registered, and approved subjects. In addition, we developed a booster feature to reinforce recommendations for a specific period of the course curriculum. After performing the tests and comparing the students' requested and taken, we reached more than 60% of correct answers.

Keywords: Smart Campus. Recommender System. Recommender System for College Enrollment.

LISTA DE FIGURAS

Figura 1	Principais áreas de atuação e tecnologias para Campus Inteligente. Fonte: (FERNÁNDEZ-CARAMÉS; FRAGA-LAMAS, 2019).	19
Figura 2	Macroprocesso de Solicitação de Matrícula.	38
Figura 3	Programa de solicitação de matrícula atual.	39
Figura 4	Fluxograma do Funcionamento do Recomendador.	41
Figura 5	Distribuição dos alunos pelo curso de Ciência da Computação.	46
Figura 6	Número de disciplinas obrigatórias por versão do curso.	47
Figura 7	Média de solicitações de matrículas por aluno.	48
Figura 8	Média de disciplinas cursadas por período.	48
Figura 9	Histórico de disciplinas dispensadas.	49
Figura 10	Histórico de disciplinas (Aprovadas, Dispensadas, Total).	50
Figura 11	Diferentes configurações de <i>Boost</i> utilizados nos experimentos.	58
Figura 12	Proposta de integração com o sistema Cobalto.	66

LISTA DE TABELAS

Tabela 1	Análise dos Trabalhos Relacionados.	35
Tabela 2	Exemplo de uma tabela de votação (Classificação)	43
Tabela 3	Exemplo de uma tabela de votação (Votação)	43
Tabela 4	Exemplo de uma tabela de votação (Resultado)	43
Tabela 5	Quantidade de disciplinas do currículo (versão 9) do curso de Ciência da Computação.	46
Tabela 6	Alunos selecionados para o experimento.	51
Tabela 7	Disciplinas que ainda faltam ser cursadas para os alunos A, B, C, D e E.	52
Tabela 8	Disciplinas recomendadas para os alunos A, B, C, D e E.	54
Tabela 9	Disciplinas solicitadas pelos alunos A, B, C, D e E.	54
Tabela 10	Disciplinas cursadas pelos alunos A, B, C, D e E.	55
Tabela 11	Análise dos Resultados para os alunos A, B, C, D e E.	56
Tabela 12	Estatísticas das recomendações	57
Tabela 13	N.º recomendações vs. Acertos sem utilização de <i>boost</i>	59
Tabela 14	Recomendações utilizando <i>boost</i> linear decrescente – Fig. 11a.	59
Tabela 15	Recomendações utilizando <i>boost</i> exponencial decrescente – Fig. 11b.	59
Tabela 16	Recomendações utilizando <i>boost</i> linear crescente – Fig. 11c.	59
Tabela 17	Recomendações utilizando <i>boost</i> exponencial crescente – Fig. 11d.	60
Tabela 18	Recomendações utilizando <i>boost</i> constante (50%) – Fig. 11e.	60
Tabela 19	Comparação dos percentuais de acertos nas solicitações de matrícula com diferentes configurações de <i>boost</i>	60
Tabela 20	Comparação dos acertos nas disciplinas cursadas com diferentes configurações de <i>boost</i>	61
Tabela 21	Comparação dos acertos nas disciplinas aprovadas com diferentes configurações de <i>boost</i>	61
Tabela 22	Avaliação dos algoritmos	62
Tabela 23	Grade Curricular do Curso de Ciência da Computação (versão 9)	74
Tabela 24	Distância Contextual dos Alunos do Curso de Ciência da Computação Com Matrícula em 2019/2	75

LISTA DE ABREVIATURAS E SIGLAS

CI	Campus Inteligente
DC	Distância Contextual
IA	Inteligência Artificial
ID	Identificador
IES	Instituição de Ensino Superior
IoT	Internet das Coisas
PLN	Processamento de Linguagem Natural
SGD	Gradiente Estocástico de Descida
SR	Sistemas De Recomendação
UFPeI	Universidade Federal de Pelotas

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Organização do Texto	17
2	REFERENCIAL TEÓRICO	18
2.1	Cidades e Campus Inteligentes	18
2.2	Sistemas de Recomendação	19
2.3	Algoritmos de Recomendação	21
2.3.1	Algoritmos Básicos	21
2.3.2	Algoritmos inspirados em k-NN	22
2.3.3	Algoritmos Baseados em Fatoração de Matriz	23
2.3.4	Slope One	25
2.3.5	Co-clustering	25
2.4	Trabalhos Relacionados	26
2.4.1	<i>Smart Campus</i>	26
2.4.2	Sistemas de Recomendação no Contexto de <i>Smart Campus</i> e de Recomendação de Disciplinas	32
2.5	Análise dos Trabalhos Relacionados	35
3	ABORDAGEM PROPOSTA	37
3.1	Contextualização	37
3.2	O Recomendador de Disciplinas Proposto	40
3.2.1	Definição do Número Máximo de Recomendações	42
3.2.2	Booster	42
3.2.3	Sistema de Votação	42
3.2.4	Considerações Gerais	43
3.3	Distância Contextual	44
4	EXPERIMENTOS E RESULTADOS	45
4.1	Caracterização do Estudo de Caso	45
4.2	Experimentos	49
4.2.1	Experimentos e Resultados Individuais	51
4.2.2	Experimentos e Resultados Gerais	56
4.3	Avaliação dos Algoritmos de Recomendação Utilizados	62
5	CONCLUSÕES E TRABALHOS FUTUROS	63
5.1	Trabalhos Futuros	64
	REFERÊNCIAS	67

APÊNDICE A	GRADE CURRICULAR DO CURSO DE CIÊNCIA DA COMPUTAÇÃO (VERSÃO 9)	74
APÊNDICE B	DISTÂNCIA CONTEXTUAL DOS ALUNOS DO CURSO DE CIÊNCIA DA COMPUTAÇÃO - REFERÊNCIA SEMESTRE 2019/2	75

1 INTRODUÇÃO

O avanço tecnológico nas últimas décadas permitiu o uso de tecnologias no dia a dia das indústrias, residências, prédios e até mesmo das cidades. Atualmente existem Prédios Inteligentes (do inglês, *Smart Buildings*) sendo construções que interagem com sensores IoT (acrônimo de Internet das Coisas, do inglês *Internet of Things*) através de conexões sem fio e coletam dados. A partir desses dados, é possível realizar uma infinidade de atividades trazendo benefício aos proprietários, ocupantes e ao meio ambiente.

Tem-se ainda, Cidades Inteligentes (do inglês, *Smart Cities*) que incorporam uma série de dispositivos eletrônicos para coletar dados e usá-los para gerir recursos de forma eficiente como, por exemplo, monitorar sistemas de tráfego e de transporte, qualidade ambiental da cidade, sistemas de vigilância, de energia elétrica e muitos outros. Cidades inteligentes são uma perspectiva do desenvolvimento urbano que integram várias soluções de tecnologias da informação e comunicação para gerenciar o patrimônio de uma cidade, criar um ambiente sustentável, melhorar a qualidade de vida e aumentar a eficiência e valor econômico (AHLGREN; HIDEELL; NGAI, 2016).

Por fim, ainda mais atual é a ideia de Campus Inteligente (do inglês, *Smart Campus*). Porém, apesar do esforço que existe para gerar um conceito, não se chegou a uma definição compartilhada do que são esses ambientes. Segundo Alghamdi; Shetty (2016), o Campus Inteligente é aquele que utiliza os recursos de forma eficiente, fornece serviços de alta qualidade para a comunidade do campus, enquanto o custo operacional é reduzido. Além disso, pode trazer uma série de benefícios, como ambiente interativo e criativo para alunos e professores, gerenciamento de energia inteligente, sistema de vigilância eficaz e com avisos de incidentes em tempo real, controle de estacionamento com eficiência e também o gerenciamento do controle de acesso.

O Campus Inteligente possui muitas semelhanças com uma Cidade Inteligente. Porém, muitos trabalhos relacionados tratam um campus apenas como uma cidade em escala menor e, com a pesquisa realizada para esse trabalho, identificou-se que os processos acadêmicos notadamente não estão recebendo a atenção necessária dentro desse conceito. Desse modo, a definição de Campus Inteligente não deve ser

formulada a partir da aplicação de tecnologias já existentes nas cidades ou prédios inteligentes, mas pela soma das tecnologias e estratégias inteligentes que auxiliem nos processos acadêmicos e de ensino e aprendizagem. Os quais nesse caso funcionam de forma interativa entre o discente e a instituição, ao realizar a matrícula e retirar um documento, por exemplo.

Neste contexto, segundo relatório do Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP), entre 2008 e 2018, as matrículas na educação superior aumentaram 44,6%, a média de crescimento anual no período foi de 3,8% e, em relação a 2017, a variação foi de 1,9% (SAMPAIO et al., 2019). Esta crescente busca pela educação em instituições de ensino superior torna o atendimento aos candidatos e aos próprios alunos um grande desafio. O grande volume de atendimentos e também a quantidade reduzida de funcionários das instituições pode causar atendimentos que nem sempre correspondem com à qualidade esperada. Sendo assim, este trabalho tem como foco principal buscar tecnologias utilizadas em campus inteligentes que auxiliem no atendimento dos envolvidos com a instituição.

Corriqueiramente as Instituições de Ensino Superior passam por várias adversidades. Dois mil e vinte, e dois mil e vinte e um foram anos acadêmicos atípicos, nos quais as instituições tiveram que se adaptar à pandemia do coronavírus. Não somente as atividades de aula foram adaptadas mas também muitos processos tiveram de ser automatizados para evitar o contato entre os membros da comunidade acadêmica. A digitalização dos processos é o primeiro passo, porém espera-se que esta digitalização do processo venha sempre acompanhada de melhorias que ao final resultem numa transformação digital tornando o processo mais “inteligente”.

Nesse ponto, diretamente ligada ao campus inteligente tem-se a Inteligência Artificial, a qual está cada vez mais sendo utilizada em todos os setores da sociedade, desde sistemas bancários, atendimento de empresas, telecomunicações até o campus universitário (MARR, 2019; STONE, 2019; NEELAKANTAN, 2020). Das diversas formas que a IA pode ser utilizada, destacam-se os sistemas de recomendação e os atendentes virtuais (*chatbots*). Os Sistemas de Recomendação (SR) podem ser definidos como programas que tentam recomendar os itens mais adequados (produtos ou serviços) para usuários específicos (indivíduos ou empresas), prevendo o interesse de um usuário em um item com base nas informações relacionadas sobre os itens, os usuários e as interações entre eles.

Nas universidades, sejam elas brasileiras ou estrangeiras, os currículos dos cursos de graduação são organizados em componentes curriculares dispostos em períodos letivos (normalmente semestrais ou anuais). Em cada início de período os discentes necessitam realizar o processo de matrícula nos componentes curriculares, o que significa selecionar os componentes desejados pelo aluno ou até determinados pela instituição, para o período que está por iniciar.

Atualmente na Universidade Federal de Pelotas (UFPel), os cursos ofertados em sua maioria não são modulares. Isso quer dizer que os alunos desses cursos podem cursar componentes curriculares de forma um pouco mais flexível que em um curso modular, onde é necessário realizar a matrícula em um bloco de componentes curriculares previamente estabelecido. Assim, desde que respeite os pré-requisitos do currículo, o aluno pode cursar os componentes da forma que achar melhor. Diversos fatores podem influir para os discentes não cursarem o currículo de forma modular: reprovações, dificuldade de cursar todas as disciplinas recomendadas (seja por fatores econômicos ou outros) ou até mesmo por estar procurando outro caminho de aprendizado segundo as suas necessidades.

Essa flexibilidade do discente se matricular no componente que deseja pode ser positiva, pois permite que alunos que reprovam ou não conseguem cursar o número adequado de componentes no semestre permaneçam ligados ao curso. Contudo, esta flexibilidade também acaba causando algumas dificuldades para os coordenadores do curso como, por exemplo, o aluno seleciona mais disciplinas do que consegue gerenciar, na intenção de adiantar o término do curso e disso decorrem reprovações, o que vai em sentido contrário ao seu objetivo. Outro problema recorrente nesse modelo é o elevado número de reprovações nos semestres iniciais que conseqüentemente pode desmotivar estes alunos.

Coordenadores experientes conhecem o currículo do curso muito bem. Além de conseguirem classificar as disciplinas conforme seu grau de dificuldade, estes coordenadores, através de uma análise do histórico, conseguem auxiliar os alunos a selecionarem as que melhor se encaixam em seu perfil, assim como o número adequado. Porém, quando o aluno não tem contato com o coordenador ou este é inexperiente, como o aluno poderia se beneficiar deste auxílio?

Nesta situação pode-se perceber que um sistema de recomendação que realize a análise do histórico do aluno e que identifique a dificuldade e a quantidade de disciplinas que o estudante consegue gerenciar, pode ser de grande ajuda para o aluno. A recomendação de matrícula automatizada é a tentativa de trazer o conhecimento de um coordenador experiente sem a necessidade de uma relação direta entre coordenador e aluno.

Em suma, o objetivo deste trabalho é propor um sistema combinado de recomendação através de ferramentas de software e técnicas de inteligência artificial, sugerindo aos discentes componentes curriculares para a matrícula. Pretende-se que este sistema auxilie o aluno em sua jornada acadêmica indicando as disciplinas que melhor se encaixem ao seu perfil e limitando o número de recomendações de modo que o volume de trabalho não extrapole a capacidade de aprendizado. Esse sistema irá considerar o número de aprovações e reprovações do aluno e a dificuldade da disciplina. O trabalho apresenta o recomendador proposto e utiliza o curso de Ciência da

Computação da UFPel como estudo de caso.

1.1 Organização do Texto

Este trabalho está organizado como segue. No Capítulo 2 apresenta o referencial teórico levantado no trabalho, assim como os conceitos utilizados e os trabalhos relacionados encontrados na literatura. No Capítulo 3 é apresentada a proposta desenvolvida neste trabalho. Já no Capítulo 4 os experimentos são apresentados e os resultados obtidos para estudo de caso são discutidos. No Capítulo 5 são apresentadas as considerações finais do trabalho e as perspectivas futuras. Por fim são listamos alguns trabalhos que durante o desenvolvimento deste foram surgindo como ideias.

2 REFERENCIAL TEÓRICO

Neste Capítulo são apresentados os principais conceitos utilizados neste trabalho. Será apresentado um estudo introdutório sobre cidades e campus inteligente, sistemas recomendadores e seus algoritmos, e também serão apresentados trabalhos relacionados com a abordagem proposta.

2.1 Cidades e Campus Inteligentes

Cidades Inteligentes (do inglês, *Smart Cities*) são uma perspectiva do desenvolvimento urbano que integram várias soluções de TIC para gerenciar o patrimônio de uma cidade, criar um ambiente sustentável, melhorar a qualidade de vida e aumentar a eficiência e valor econômico (AHLGREN; HIDEELL; NGAI, 2016).

Campus Inteligente é aquele que utiliza os recursos de forma eficiente, fornece serviços de alta qualidade para a comunidade do campus, enquanto o custo operacional é reduzido. Além disso, usufruir de um campus inteligente pode trazer uma série de benefícios como um ambiente interativo e criativo para alunos e professores, o gerenciamento de energia de forma inteligente, sistemas de vigilância eficazes e com avisos de incidentes em tempo real, controle de estacionamento de forma eficiente, além do gerenciamento do controle de acesso ao campus.

A Figura 1 apresenta as principais áreas de atuação e tecnologias para Campus Inteligente (FERNÁNDEZ-CARAMÉS; FRAGA-LAMAS, 2019). O círculo mais interno apresenta o grande campo de aplicação de Campus Inteligente. O círculo intermediário apresenta as principais tecnologias envolvidas como IoT, realidade aumentada, robótica e UAV, *Cloud* e *Edge Computing*, entre outras. Por fim, no círculo mais externo são apresentados os campos de aplicação como segurança, objetos inteligentes, gerenciamento de água e lixo, ferramentas inteligentes, entre outras.

Campus Inteligente possui muitas semelhanças com uma cidade inteligente. Percebe-se que em alguns trabalhos relacionados os autores tratam o campus apenas como a cidade em escala menor. Na pesquisa realizada para este trabalho identificou-se que os processos acadêmicos foram negligenciados neste conceito.

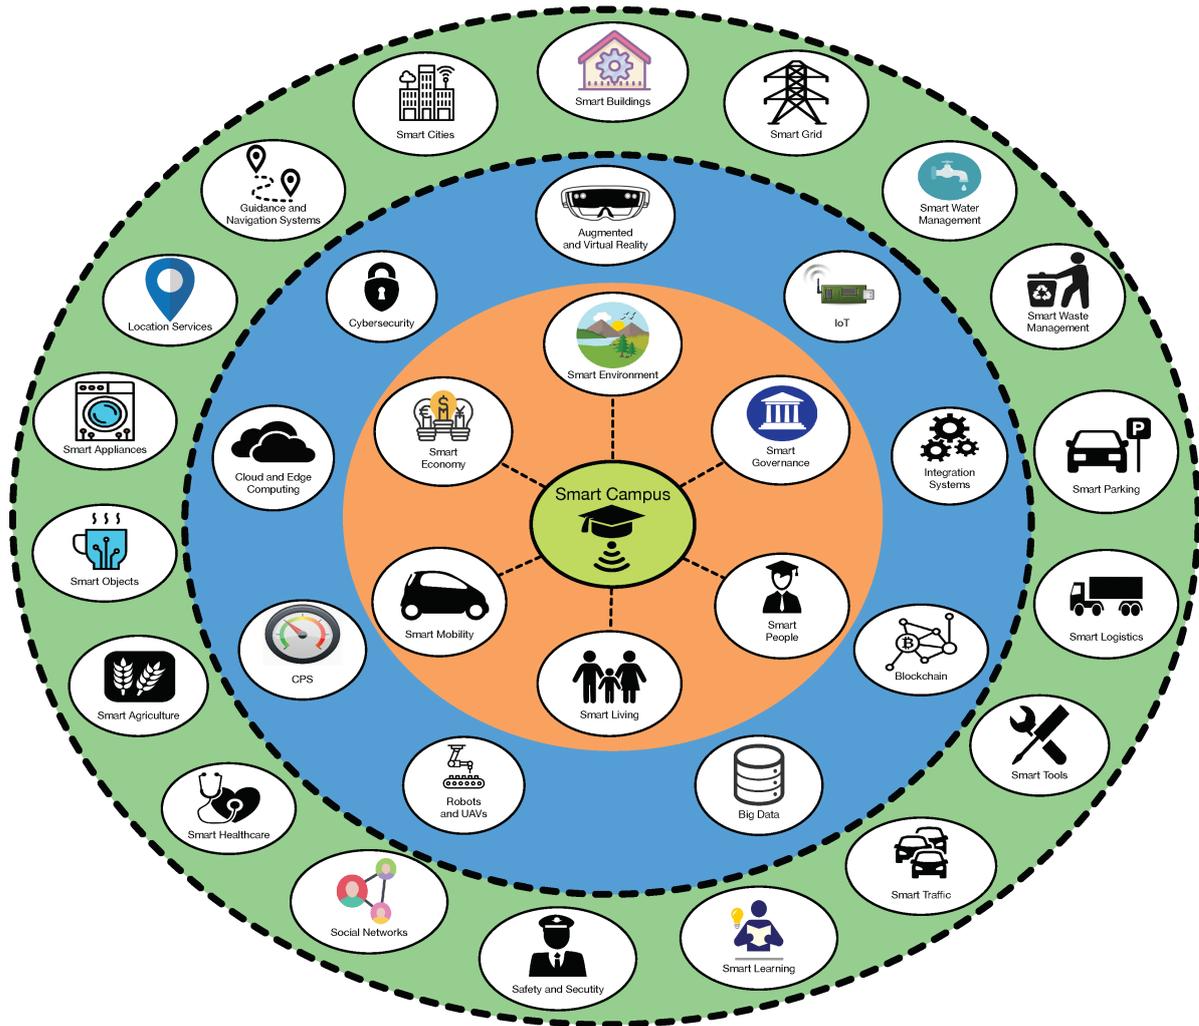


Figura 1 – Principais áreas de atuação e tecnologias para Campus Inteligente. Fonte: (FERNÁNDEZ-CARAMÉS; FRAGA-LAMAS, 2019).

Então, a definição de Campus Inteligente não deve ser formulada a partir da aplicação de tecnologias já existentes nas cidades ou prédios inteligentes, mas pela soma das tecnologias e estratégias inteligentes que auxiliem nos processos acadêmicos e de ensino e aprendizagem.

2.2 Sistemas de Recomendação

A IA, às vezes chamada de inteligência de máquina, é a inteligência demonstrada por máquinas, em contraste com a inteligência natural exibida por humanos e outros animais. Na ciência da computação, a pesquisa em IA é definida como o estudo de “agentes inteligentes”: qualquer dispositivo que perceba seu ambiente e realize ações que maximizem sua chance de atingir seus objetivos com sucesso. Coloquialmente, o termo inteligência artificial é aplicado quando uma máquina imita funções cognitivas que os humanos associam a outras mentes humanas, como “aprendizado” e “resolu-

ção de problemas” (WARWICK, 2011).

O aprendizado de máquina ensina os dispositivos computacionais a fazerem o que é natural para humanos e animais: aprender com a experiência. Os algoritmos de aprendizado de máquina usam técnicas e métodos computacionais para extrair as informações e aprender diretamente dos dados, sem depender das equações predefinidas como modelo (SILVA et al., 2019). Eles ainda tentam melhorar, de forma adaptativa, seu desempenho à medida que o número de amostras disponíveis para o aprendizado aumenta. Os algoritmos de aprendizado de máquina encontram padrões naturais no conjunto de dados que geram conhecimento e ajudam os administradores a tomarem melhores decisões e a efetuarem previsões, podendo ser empregados também em algumas etapas de processamento pelos agentes inteligentes. Eles são usados diariamente na tomada de decisões críticas de diagnóstico médico, na negociação de ações, na previsão de carga de energia, entre outras tarefas. Na internet, os sites de mídia contam com o aprendizado de máquina para selecionar, entre milhões de opções, as mais adequadas para recomendar músicas ou filmes. Já no e-commerce, são utilizados para se obter informações sobre o comportamento de compra dos clientes.

Somando-se a isso, têm-se os Sistemas de Recomendação, ferramentas de software e técnicas que fornecem sugestões de itens que podem ser usados pelo usuário. As sugestões estão relacionadas a vários processos de tomada de decisão, como quais itens comprar, que música ouvir ou quais notícias online ler (RICCI et al., 2011). Eles surgem para solucionar o problema de sobrecarga de informações na Internet, tornando-se uma excelente ferramenta para quase qualquer tipo de serviço online (POLATIDIS; GEORGIADIS, 2013).

Esses programas são elaborados para sugerir itens aos usuários, filtrando apenas a partir de uma gama ampla ou descentralizada de opções com base nas alternativas que consideram mais relevantes para o objetivo proposto. Essa ideia é gerada por um processo social natural: quando nos deparamos com uma situação em que precisamos fazer uma escolha e não temos autocompreensão suficiente sobre as alternativas, geralmente buscamos a resposta com a ajuda de outras pessoas, seja perguntando para os amigos mais experientes ou observando as opiniões dos outros. Outros podem buscar análise profissional e crítica de questões relacionadas (RESNICKPAUL; R., 1997).

Segundo Balabanović; Shoham (1997) os sistemas de recomendação basicamente são classificados em filtragem baseada em conteúdo e filtragem colaborativa.

A Filtragem Baseada em Conteúdo utiliza características semelhantes entre objetos para indicar a um usuário itens que ele ainda não viu. O item pode ser um livro, um filme, uma música etc. Basicamente qualquer item que tenha características semelhantes pode ser recomendado dessa forma. Grandes empresas estão utilizando esse tipo de filtragem para oferecer aos seus usuários novos itens baseados em con-

teúdo já visto.

Na filtragem colaborativa, o método para realização da filtragem é baseado na classificação do conteúdo. Quando um usuário X classifica o item Y com uma nota Z, o sistema se utiliza dessas variáveis para identificar usuário que tenham o mesmo gosto de X para recomendar novos itens que podem agradar o usuário X.

Em seu trabalho Burke (2002) apresenta diversas maneiras de como realizar a combinação de resultados para melhorar os sistemas de recomendação. Este conjunto de técnicas denomina-se hibridização. Entre os métodos apresentados por Burke (2002) estão os métodos aleatório, balanceado, de permuta, mesclado, de combinação de características, de cascata, de aumento de características e o método de níveis.

2.3 Algoritmos de Recomendação

Nesta Seção é apresentado um resumo dos principais algoritmos de recomendação que são utilizados neste trabalho.

2.3.1 Algoritmos Básicos

Normal Predictor é um algoritmo que prevê uma classificação aleatória com base na distribuição do conjunto de treinamento, sendo considerada normal. A previsão \hat{r}_{ui} é gerada a partir de uma distribuição normal $\mathcal{N}(\hat{\mu}, \hat{\sigma}^2)$, onde $\hat{\mu}$ e $\hat{\sigma}$ são estimados a partir dos dados de treinamento usando a Estimativa de Máxima Verossimilhança:

$$\hat{\mu} = \frac{1}{|R_{train}|} \sum_{r_{ui} \in R_{train}} r_{ui} \quad (1)$$

$$\hat{\sigma} = \sqrt{\sum_{r_{ui} \in R_{train}} \frac{(r_{ui} - \hat{\mu})^2}{|R_{train}|}}$$

BaselineOnly é um algoritmo que prevê a estimativa de linha de base para determinado usuário e item.

$$\hat{r}_{ui} = b_{ui} = \mu + b_u + b_i \quad (2)$$

Mais detalhes sobre a implementação do algoritmo podem ser encontrados em (KOREN, 2010).

2.3.2 Algoritmos inspirados em k-NN

O **KNN Basic** é um algoritmo básico de filtragem colaborativa. A previsão \hat{r}_{ui} é definida como:

$$\hat{r}_{ui} = \frac{\sum_{v \in N_i^k(u)} \text{sim}(u, v) \cdot r_{vi}}{\sum_{v \in N_i^k(u)} \text{sim}(u, v)} \quad (3)$$

ou

$$\hat{r}_{ui} = \frac{\sum_{j \in N_u^k(i)} \text{sim}(i, j) \cdot r_{uj}}{\sum_{j \in N_u^k(i)} \text{sim}(i, j)} \quad (4)$$

dependendo do campo `user_based` do parâmetro `sim_options`.

O **KNN With Means** também é um algoritmo básico de filtragem colaborativa, considerando as avaliações médias de cada usuário. A previsão \hat{r}_{ui} é definida como:

$$\hat{r}_{ui} = \mu_u + \frac{\sum_{v \in N_i^k(u)} \text{sim}(u, v) \cdot (r_{vi} - \mu_v)}{\sum_{v \in N_i^k(u)} \text{sim}(u, v)} \quad (5)$$

ou

$$\hat{r}_{ui} = \mu_i + \frac{\sum_{j \in N_u^k(i)} \text{sim}(i, j) \cdot (r_{uj} - \mu_j)}{\sum_{j \in N_u^k(i)} \text{sim}(i, j)} \quad (6)$$

dependendo do campo `user_based` do parâmetro `sim_options`.

O **KNN With Z-Score** é um algoritmo básico de filtragem colaborativa, levando em consideração a normalização do z-score de cada usuário. A previsão \hat{r}_{ui} é definida como:

$$\hat{r}_{ui} = \mu_u + \sigma_u \frac{\sum_{v \in N_i^k(u)} \text{sim}(u, v) \cdot (r_{vi} - \mu_v) / \sigma_v}{\sum_{v \in N_i^k(u)} \text{sim}(u, v)} \quad (7)$$

ou

$$\hat{r}_{ui} = \mu_i + \sigma_i \frac{\sum_{j \in N_u^k(i)} \text{sim}(i, j) \cdot (r_{uj} - \mu_j) / \sigma_j}{\sum_{j \in N_u^k(i)} \text{sim}(i, j)} \quad (8)$$

dependendo do campo `user_based` do parâmetro `sim_options`.

O **KNN BaseLine**, um algoritmo básico de filtragem colaborativa, considera uma

classificação de linha de base. A previsão \hat{r}_{ui} é definida como:

$$\hat{r}_{ui} = b_{ui} + \frac{\sum_{v \in N_i^k(u)} \text{sim}(u, v) \cdot (r_{vi} - b_{vi})}{\sum_{v \in N_i^k(u)} \text{sim}(u, v)} \quad (9)$$

ou

$$\hat{r}_{ui} = b_{ui} + \frac{\sum_{j \in N_u^k(i)} \text{sim}(i, j) \cdot (r_{uj} - b_{uj})}{\sum_{j \in N_u^k(i)} \text{sim}(i, j)} \quad (10)$$

dependendo do campo `user_based` do parâmetro `sim_options`. Para obter as melhores previsões, a medida de similaridade `pearson_baseline` deve ser utilizada.

2.3.3 Algoritmos Baseados em Fatoração de Matriz

O **algoritmo SVD** foi popularizado por Simon Funk durante o Prêmio Netflix. Segundo Salakhutdinov; Mnih (2007 apud Hug, 2020), quando as linhas de base não são usadas, o algoritmo é equivalente à Fatoração da Matriz Probabilística.

A previsão \hat{r}_{ui} é definida como

$$\hat{r}_{ui} = \mu + b_u + b_i + q_i^T p_u \quad (11)$$

Se o usuário u for desconhecido, a tendência b_u e os fatores p_u são considerados zero. O mesmo se aplica ao item i com b_i e q_i . Para obter detalhes, consulte (KOREN; BELL; VOLINSKY, 2009; RICCI et al., 2011).

Para estimar todo o desconhecido, minimiza-se o seguinte erro quadrático regularizado:

$$\sum_{r_{ui} \in R_{train}} (r_{ui} - \hat{r}_{ui})^2 + \lambda (b_i^2 + b_u^2 + \|q_i\|^2 + \|p_u\|^2) \quad (12)$$

A minimização é realizada por uma descida gradiente estocástica (SGD):

$$\begin{aligned} b_u &\leftarrow b_u + \gamma(e_{ui} - \lambda b_u) \\ b_i &\leftarrow b_i + \gamma(e_{ui} - \lambda b_i) \\ p_u &\leftarrow p_u + \gamma(e_{ui} \cdot q_i - \lambda p_u) \\ q_i &\leftarrow q_i + \gamma(e_{ui} \cdot p_u - \lambda q_i) \end{aligned}$$

onde $e_{ui} = r_{ui} - \hat{r}_{ui}$.

Essas etapas são executadas em todas as classificações do conjunto e repetidas `n_epochs` vezes. As linhas de base são inicializadas em 0. Os fatores de usuário e item são inicializados aleatoriamente de acordo com uma distribuição normal, que

pode ser ajustada usando os parâmetros `init_mean` e `init_std_dev`.

Tem-se controle sobre a taxa de aprendizado γ e o termo de regularização λ . Ambos podem diferir para cada categoria de parâmetro. Por padrão, as taxas de aprendizado são definidas como 0,005 e os termos de regularização são definidos como 0,02.

O **algoritmo SVD++** é uma extensão do SVD considerando as classificações implícitas. A previsão \hat{r}_{ui} é definida como:

$$\hat{r}_{ui} = \mu + b_u + b_i + q_i^T \left(p_u + |I_u|^{-\frac{1}{2}} \sum_{j \in I_u} y_j \right) \quad (13)$$

onde os termos y_j são um novo conjunto de fatores de item que capturam classificações implícitas. Aqui, uma classificação implícita descreve que um usuário avaliou um item j , independentemente do valor da classificação.

Se o usuário u for desconhecido, a tendência b_u e os fatores p_u são considerados zero. O mesmo se aplica ao item i com b_i , q_i e y_i . Para obter detalhes, consulte (KOREN; BELL; VOLINSKY, 2009; RICCI et al., 2011).

Assim como para SVD, os parâmetros são aprendidos usando um SGD no objetivo de erro quadrático regularizado. As linhas de base são inicializadas em 0. Os fatores de usuário e item são inicializados aleatoriamente de acordo com uma distribuição normal, que pode ser ajustada usando os parâmetros `init_mean` e `init_std_dev`.

Tem-se controle sobre a taxa de aprendizado γ e o termo de regularização λ . Ambos podem diferir para cada categoria de parâmetro. Por padrão, as taxas de aprendizado são definidas como 0,005 e os termos de regularização são definidos como 0,02.

O **algoritmo NMF** é um algoritmo de filtragem colaborativa baseado na Fatoração de Matrizes Não Negativas. Este algoritmo é muito semelhante ao SVD.

A previsão \hat{r}_{ui} é definida como:

$$\hat{r}_{ui} = q_i^T p_u \quad (14)$$

onde os fatores do usuário e do item são mantidos positivos. Nossa implementação segue aquela sugerida em Luo et al. (2014), sendo equivalente a Zhang et al. (2006) em sua forma não regularizada. Ambos são aplicações diretas de NMF para matrizes densas (LEE; SEUNG, 2001).

O procedimento de otimização é um SGD com uma escolha específica do tamanho do degrau que garante a não negatividade dos fatores, desde que seus valores iniciais também sejam positivos.

Em cada etapa do procedimento SGD, os fatores f ou o usuário u e o item i são atualizados da seguinte forma:

$$p_{uf} \leftarrow p_{uf} \cdot \frac{\sum_{i \in I_u} q_{if} \cdot r_{ui}}{\sum_{i \in I_u} q_{if} \cdot \hat{r}_{ui} + \lambda_u |I_u| p_{uf}}$$

$$q_{if} \leftarrow q_{if} \cdot \frac{\sum_{u \in U_i} p_{uf} \cdot r_{ui}}{\sum_{u \in U_i} p_{uf} \cdot \hat{r}_{ui} + \lambda_i |U_i| q_{if}}$$

onde λ_u e λ_i são parâmetros de regularização.

Este algoritmo é altamente dependente dos valores iniciais. Fatores de usuário e item são inicializados uniformemente entre `init_low` e `init_high`. Uma versão tendenciosa está disponível definindo o parâmetro `tendencioso` como `True`. Neste caso, a previsão é definida como:

$$\hat{r}_{ui} = \mu + b_u + b_i + q_i^T p_u \quad (15)$$

ainda garantindo fatores positivos. As linhas de base são otimizadas da mesma maneira que no algoritmo SVD. Embora produza melhor precisão, a versão tendenciosa parece altamente propensa a *overfitting*.

2.3.4 Slope One

O Slope One é um algoritmo de filtragem colaborativa simples, porém preciso. Esta é uma implementação direta do algoritmo SlopeOne (LEMIRE; MACLACHLAN, 2005). A previsão \hat{r}_{ui} é definida como:

$$\hat{r}_{ui} = \mu_u + \frac{1}{|R_i(u)|} \sum_{j \in R_i(u)} \text{dev}(i, j) \quad (16)$$

onde $R_i(u)$ é o conjunto de itens relevantes, ou seja, o conjunto de itens j avaliados por u que também têm pelo menos um usuário comum com i . $\text{dev}(i, j)$ é definido como a diferença média entre as avaliações de i e as de j :

$$\text{dev}(i, j) = \frac{1}{|U_{ij}|} \sum_{u \in U_{ij}} r_{ui} - r_{uj} \quad (17)$$

2.3.5 Co-clustering

Co-Clustering é um algoritmo de filtragem colaborativa apresentado em George; Merugu (2005). Basicamente, os usuários e itens são atribuídos a alguns clusters C_u , C_i e alguns co-clusters C_{ui} . A previsão \hat{r}_{ui} é definida como:

$$\hat{r}_{ui} = \overline{C_{ui}} + (\mu_u - \overline{C_u}) + (\mu_i - \overline{C_i}) \quad (18)$$

onde $\overline{C_{ui}}$ é a classificação média de C_{ui} co-cluster, $\overline{C_u}$ é a classificação média de aglomerado u de e $\overline{C_i}$ é a classificação média de conjunto i 's.

Se o usuário for desconhecido, a previsão é $\hat{r}_{ui} = \mu_i$. Se o item for desconhecido, a previsão é $\hat{r}_{ui} = \mu_u$. Se o usuário e o item forem desconhecidos, a previsão é $\hat{r}_{ui} = \mu$. Os clusters são atribuídos usando um método de otimização direto, muito parecido com o k-means (HUG, 2015).

2.4 Trabalhos Relacionados

Como já dito, este trabalho possui como um dos seus primeiros objetivos estudar o assunto de campus inteligente e suas aplicações. Após este primeiro momento, perceberemos que para o desenvolvimento do trabalho, precisaríamos de referências sobre sistemas de recomendação no contexto de campus inteligente e recomendação de componentes curriculares. Logo, para melhor organizar as referências, dividimos esta Seção em três seções que tratam de *Smart Campus* e sistemas de recomendação no contexto de *Smart Campus*.

2.4.1 *Smart Campus*

Yu et al. (2011), no decorrer do artigo, apresentam três aplicativos. O primeiro, um aplicativo para encontrar um local disponível para o aluno estudar e colegas para discutir sobre algum tópico de alguma disciplina. O segundo foi desenvolvido para que o aluno possa realizar um questionamento à comunidade acadêmica e obter uma resposta. No exemplo apresentado, quando o aluno pergunta através do aplicativo se a quadra de basquete está ocupada, a solicitação vai para o servidor sendo transmitida para a comunidade como uma tarefa que pode ser respondida com uma foto ou com uma descrição. O terceiro é um aplicativo para compartilhamento de arquivos entre professores e seus alunos. Utilizando o *bluetooth* do celular, o professor pode enviar para os alunos arquivos como apresentações, textos e imagens. Os autores finalizam afirmando que o campus é um ambiente social e que muita interação social acontece. Por este motivo, eles propõem a construção de um campus inteligente que traga mais conveniência para as interações sociais através das redes sociais móveis.

Chou; Chanlin (2012) expõe um sistema de apresentação do campus utilizando tecnologia de realidade aumentada. Para o desenvolvimento do sistema utilizaram o *framework* Layar bem como outras ferramentas necessárias para a construção dos modelos 3D e edição das imagens em 2D. Para avaliação do sistema utilizaram um questionário respondido pelos usuários. Além dos comentários positivos, os alunos ainda deram sugestões para melhoria do sistema.

No trabalho de Cañ (2015), surge um novo conceito chamado Universidade Inteligente (do inglês, *Smart University*), que pode ser comparado ao campus inteligente.

Também foram apresentados alguns sensores e locais que podem ser transformados em inteligentes utilizando sensores. Em suas considerações finais o trabalho conclui que cada vez mais teremos objetos inteligentes conectados no panorama da IoT, de modo que nenhum campus deve ficar de fora da nova onda de modernidade se quiser criar espaços mais seguros e eficientes para todos os atores neste ambiente. O modelo de universidade inteligente pode ser reutilizado em parte ou em sua totalidade também em outros domínios, tanto no campo educacional quanto em outras áreas.

Em Torres-sospedra et al. (2015) o foco principal é no conceito de mobilidade inteligente. Para o estudo de caso os autores utilizam principalmente dois aplicativos Android, o SmartUJI APP e o SmartUJI AR. O primeiro aplicativo mostra o mapa do campus com informações relevantes sobre este. O aplicativo permite ainda que o usuário realize busca por prédios, salas de aula, funcionários. O segundo aplicativo utiliza-se de realidade aumentada para que o usuário possa passear pelo campus e visualizar informações sobre o espaço em que ele está. O artigo também apresenta os conceitos de cidade inteligente e universidade inteligente, bem como uma lista de serviços utilizados tanto em cidades inteligentes como em universidades inteligentes. Esta lista de atividades sobrepostas demonstra haver mais similaridades do que diferenças entre os ambientes inteligentes. Os autores concluem o artigo afirmando que o sistema de posicionamento interno por eles desenvolvido, após passar por uma avaliação real, mostrou resultados positivos em relação à precisão e um erro médio de posicionamento inferior a quatro metros. Segundo os relatórios de experiência, os usuários confirmaram a utilidade dos aplicativos para melhorar a mobilidade.

Kane; Mishra; Dutta (2016) descrevem o desenvolvimento de um campus inteligente utilizando tecnologias de IoT. A pesquisa é conduzida focando na educação, estacionamento e salas inteligentes. A educação inteligente é conduzida através de sistemas de *e-learning* e salas de aulas virtuais. Quanto ao estacionamento inteligente, o sistema de estacionamento é responsável por informar se existem vagas disponíveis, bem como se o local está lotado. As salas inteligentes utilizam sensores como PIR (*Passive Infrared Sensor*), RFID (*Radio-Frequency IDentification*) e câmeras. Nessa aplicação, as salas informam se estão ocupadas ou não e, em caso de ocupação, a quantidade de alunos presentes. A conclusão que os autores apresentam é de que a tecnologia IoT pode ser aplicada em qualquer campo, uma delas o campus inteligente. Por fim, destacam que o trabalho dedicou-se apenas ao estacionamento inteligente, salas inteligentes e educação inteligente.

Segundo Sun; Zhou; Li (2017) recentemente muitas pesquisas tem sido feitas sobre cidades inteligentes. Na University of Science and Technology of China (USTC), desde 2012 vem sendo desenvolvido um projeto prático chamado SMART CAMPUS. Este projeto faz a análise de dados do comportamento humano para desenvolver sistemas para o campus inteligente e úteis para os estudantes, empregando métodos de

visualização de dados de última geração para produzir gráficos estatísticos intuitivos que fornecem aos alunos, individualmente, conselhos abrangentes e significativos sobre seu estudo, saúde e relações sociais. Utilizando conjuntos de dados do campus, bem como dados de redes sociais, analisaram a relevância entre os conjuntos de dados heterogêneos e em seguida, construíram um sistema de recomendação inteligente para recomendar livros e amigos aos alunos. Os autores destacam que o conjunto de dados de rastreamento de atividades diárias, como dados de negócios do cartão eletrônico do campus, dados de uso de Wi-Fi, dados de e-mails escolares e check-ins ou status de redes sociais, juntamente com dados de detecção móvel pode ajudar a propositura de métodos inovadores para análise do comportamento humano. A novidade do projeto, refletida no objetivo, consiste na construção de um campus inteligente baseado na análise de conjuntos de dados do campus para fornecer mais serviços de humanização e capacidade para os alunos.

Abuarqoub et al. (2017) focam em como se aproveitar das tecnologias de IoT para criar um campus inteligente. Também identifica os benefícios-chave e motivação por trás do desenvolvimento de um campus habilitado para IoT, propiciando uma visão geral das aplicações de um campus inteligente. Finalmente, considera os desafios de implementar um campus inteligente. Um campus inteligente pode ser realizado usando um ambiente de computação preparado para IoT para estabelecer uma infraestrutura por aplicação, criar e fornecer serviços de valor agregado por meio da detecção cooperativa de entidades ambientais como seres humanos, espaços, máquinas, etc. Neste artigo, os autores consideraram os desafios vitais do projeto que impedem o desenvolvimento de um campus inteligente preparado para IoT. Identificaram interoperabilidade, processamento de informações, integração de sistemas e comunicação eficiente, confiável, de alta velocidade como os principais fatores que impedem a ampla adoção da IoT para disponibilizar o campus inteligente. Este artigo dá um passo em direção a uma visão estruturada dos campi inteligentes como um paradigma de computação para aplicativos de IoT. A discussão apresentada é apoiada e referenciada com inúmeros bancos de testes de aplicativos para campus já implementados com IoT, em domínios tópicos como redes renováveis e inteligentes, gerenciamento de resíduos, água e espaços de aprendizado, entre outros. Resumiram as descobertas preliminares dos estudos de caso e implementações revisados. Por fim, discutiram soluções para enfrentar os desafios identificados neste domínio. As soluções discutidas já podem ser usadas em infraestruturas avançadas de IoT.

Apesar dos próximos autores não apresentarem seu trabalho como diretamente relacionado ao campus inteligente, resolvemos trazer este trabalho, porque trata de técnicas de sensoriamento que podem ser utilizadas em qualquer contexto, inclusive no campus inteligente. Alvarez-campana et al. (2017) apresentam serviços de uma plataforma de IoT para cidades inteligentes, implantados na escola de engenharia da

Universidade Politécnica de Madri em Moncloa, dando ênfase especial nos desafios tecnológicos encontrados e nas soluções adotadas, assim como nas funcionalidades, serviços e potencialidades que a plataforma oferece. A plataforma oferece dois serviços pilotos, monitoramento de fluxo de pessoas com base em Wi-Fi, rastreamento e monitoramento ambiental, incluindo os seguintes parâmetros: temperatura, umidade, luz, ruído, concentração de CO e concentração de NO₂. O artigo descreve os principais desafios encontrados e as decisões de design e implementação que foram tomadas em cada uma das principais camadas da plataforma, a camada de detecção, a camada de rede e comunicação de dados e a camada de aplicação. Além disso, o documento também apresenta as principais funcionalidades que a plataforma oferece atualmente, principalmente relacionadas à análise visual através de um painel na Web que garante acesso onipresente e discute seu potencial através de alguns casos de uso selecionados.

Bates; Friday (2017) apresentam algumas lições ligadas ao seu estudo de caso, na criação de uma plataforma para transformar o campus em “inteligente”. O objetivo do trabalho é compartilhar os desafios que eles vivenciaram para ajudar outros tecnólogos das cidades inteligentes. Ainda comunicam que os desenvolvedores de IoT enfrentarão barreiras técnicas e organizacionais envolvendo integração financeira complexa ou regras institucionais. A plataforma apresentada é um sistema para monitoramento do consumo de energia no campus da Lancaster University.

Dixit; Kulkarni (2017) descreveram um novo conceito chamado *Smart University*, fornecendo uma visão abrangente do cenário da IoT e avaliando quais as tecnologias necessárias para habilitar seu uso, assim como a rede de sensores. Os autores propõem um sistema para controlar temperatura e luzes das salas de aula, afirmando que o controle manual é complicado porque os humanos podem cometer erros e esquecer de desligar os aparelhos quando não estiverem em uso e, nesse caso, esses sistemas são úteis para aumentar a eficiência de energia. O sistema pode ser visto como um futuro de inteligência artificial. Este é um sistema poderoso e confiável. Ele cumpre o objetivo de economizar energia e ajuda a alcançar o uso eficiente dos recursos energéticos. Com a ajuda da IoT, pode-se monitorar as informações de qualquer lugar do mundo. Portanto, a pesquisa possibilitou tornar o sistema energeticamente eficiente, econômico e automatizado. Este sistema está dando um passo à frente em direção à meta de aumentar o avanço tecnológico e a cidade inteligente.

Landahl (2017) apresenta a proposta de uma plataforma para dispositivos móveis para acompanhar, em tempo real, as informações coletadas por dispositivos IoT. A plataforma que tem o nome de CampusInfo, é um aplicativo Android que conta com os seguintes recursos: monitoramento da temperatura, consumo de água, informações sobre o campus, notificações, contatos de emergência e a lista de produtos da cafeteria. Vários recursos, como o sistema de informações do campus baseado em

aplicativo Android, o monitoramento de temperatura e água inteligente, estão atualmente integrados em uma única plataforma. Esses recursos do campus inteligente são conectados em rede e comunicados por meio da IoT, permitindo que os dados sejam acessados de qualquer lugar remotamente com a garantia da entrega rápida e confiável de dados em tempo real. Além disso, todos os acessos a dados são autenticados, fornecendo credenciais de login autorizadas, para garantir a troca segura de dados. Este trabalho pode ser estendido adicionando mais recursos ao aplicativo Android e facilitando o controle de vários dispositivos por meio do aplicativo móvel e análise de previsão da demanda de água no futuro a partir dos dados anteriores.

Gahlaut (2017) apresenta um sistema de campus inteligente que tem a função de capturar e gravar imagens e enviar esses dados para telefones celulares. O sistema proposto é mais confiável e protege os lados do transmissor e do receptor em relação ao sistema existente. Está inscrito nos lados do receptor; portanto, torna acessível apenas à pessoa autorizada para visualizar todos os detalhes. No caso de atividades como crime, queda de idosos, roubo em residências e campus, as ações necessárias podem ser tomadas em curto espaço de tempo. O trabalho futuro proposto para este sistema é que ele detectará a atividade comportamental e utilizará o reconhecimento de face de pessoas presentes exatamente na área de vigilância, para que o receptor possa receber informações corretas e precisas.

No trabalho de Sultan (2017), foi explorado o campus inteligente com IoT, nas literaturas existentes e em diferentes aplicações. Em seguida, foi explorado o estado atual de um campus universitário em Bangladesh, a Universidade de Ciência e Tecnologia Hajee Mohammad Danesh (HSTU). Finalmente, foi investigada a possibilidade e a oportunidade de aplicar sala de aula, laboratório, biblioteca e edifícios inteligentes habilitados para IoT para o contexto do HSTU. Recomendações necessárias foram sugeridas para aproveitar as funcionalidades do campus universitário inteligente da HSTU. Os autores concluem dizendo que o ambiente de ensino-aprendizagem com IoT é muito mais envolvente, tanto para professores quanto para estudantes como observado na literatura. No entanto, tanto conceitos de IoT, protocolos de comunicação e aplicativos estão em estágio de desenvolvimento. A lista de itens que poderiam ser melhorados para melhorar o ambiente de ensino é ilimitada, mas a implementação depende de tecnologia de ponta e isso facilmente pode ser estimado com um alto custo de implementação. Os autores deste artigo tentaram propor um modelo incremental teórico, de etapa, de incremento mínimo sobre como incorporar inteligência em objetos, sendo o tema central da IoT. No entanto, é óbvio que surgiriam muitas questões sobre a implementação de um sistema desse tipo, sendo a principal preocupação dos trabalhos futuros dos autores.

No artigo de Zhamanov et al. (2017), além de apresentar os conceitos sobre IoT e sala de aula invertida, as aplicações da IoT para campus inteligente e algumas re-

ferências, também apresentam o caso de uso onde foi implementado a sala de aula inteligente. Para a implementação do modelo, os autores criaram vídeos para uma disciplina e aplicaram o modelo de sala de aula invertida com o objetivo de tornar o processo de aprendizado mais simples. Na conclusão do artigo os autores mencionam que a implementação de tecnologias de IoT ajudam os instrutores, estudantes e administração a automatizar o processo de aprendizagem, e a sala de aula invertida com IoT é um bom exemplo disso. Contudo, não foi possível constatar pelo apresentado que a aplicação se encaixe no contexto de IoT nem ao menos em *smart campus*.

De Pietro et al. (2018) abordam a questão de como o campus inteligente pode organizar e planejar eventos e atividades para os alunos, explorando as TICs. A solução proposta é baseada em um sistema de recomendação de grupo das atividades sociais dos alunos, permitindo que eles expressem suas preferências através de pedidos completos. Um novo método de agregação (chamado Avg-Pos) é proposto para produzir a ordem de preferência global em relação a todos os membros do grupo. Estudo experimental realizado com dados reais obtidos de alunos da Universidade Lille (França) aponta os resultados promissores sobre a eficácia do sistema de recomendação proposto.

Rao et al. (2018) apresentam neste artigo um sistema de campus inteligente baseado em IoT. Na metodologia proposta os autores utilizam várias categorias de sensores. Alguns sensores listados no artigo são o sensor de umidade, sensor ultrassônico, câmeras, sensor de infravermelho entre outros. As funcionalidades apresentadas pelo artigo são um sistema de iluminação pública inteligente, estacionamento inteligente, automação inteligente, jardinagem inteligente, qualidade do ar inteligente, monitoramento de ruídos, sistema de monitoramento do clima, biblioteca inteligente, cantina inteligente e escritório inteligente. Os autores afirmam que não conseguiram implementar todos os serviços e demonstram apenas um sistema básico para controle de ventiladores, luzes, nível da iluminação pública e nível de ruídos.

Gaglio et al. (2019) apresentam um assistente virtual que explora a tecnologia do Watson (IBM) para apoiar estudantes e funcionários de um campus inteligente da Universidade de Palermo. O assistente virtual proposto foi projetado para ajudar estudantes da Universidade de Palermo a se movimentar no campus (por exemplo, localizando facilmente prédios, salas de aula e outros pontos de interesse relevantes) e responder a algumas perguntas comuns sobre bolsas de estudo, impostos, matrículas, entre outros. Além disso, os recursos do assistente virtual podem ser ampliados ainda mais, permitindo que ele interaja com outros sistemas inteligentes, de modo a executar tarefas mais complexas, como identificar um ponto livre em um estacionamento ou sugerir uma sala de aula com uma certa temperatura conforme os dados provenientes de Dispositivos de IoT.

2.4.2 Sistemas de Recomendação no Contexto de *Smart Campus* e de Recomendação de Disciplinas

O artigo de Bydžovská (2016) está focado em recomendar um plano de inscrição no curso utilizando técnicas de mineração de dados. As recomendações consideram disciplinas eletivas e opcionais, respeitando as habilidades, conhecimento, interesse e tempo livre (grade de horários) do aluno. Como conclusão os autores apresentaram uma versão piloto do recomendador que lembra os alunos de seus deveres, adverte sobre cursos difíceis e recomenda cursos potencialmente benéficos. Afirma que o sistema ajuda os estudantes no processo de inscrição no início de cada semestre.

Sun; Zhang (2018) propõem integrar a pesquisa em sistemas de diálogo e sistemas de recomendação em uma nova e unificada estrutura de aprendizado por reforço profundo para criar um agente personalizado de recomendação de conversação. Utilizando técnicas de aprendizado por reforço, os autores demonstram que a eficiência do agente de conversação pode aumentar consideravelmente utilizando os dados do usuário não apenas da sessão atual, mas de todo seu histórico de relacionamento com *e-commerce*.

Villegas-ch; Arias-navarrete; Palacios-pacheco (2020) apresentam o conceito de “educação personalizada” além dos já conhecidos *smart campus* e *chatbot*. O objetivo é fazer com que o aluno deixe de ser um mero espectador, sendo o ator principal na sua educação. Neste caso o *chatbot*, utilizando técnicas de IA, é utilizado para recomendar atividades para os alunos.

O'mahony; Smyth (2007) apresentam um sistema de recomendação de disciplina para a matrícula online da University College Dublin (UCD). Apresentam os fatores que influenciam as escolhas dos alunos e propõem soluções. Realizaram uma avaliação empírica utilizando dados históricos de matrículas de alunos e mostraram que um desempenho promissor é alcançado com o projeto. O currículo da UCD foi atualizado e agora é modular por semestres e baseado em créditos. Enquanto isso flexibiliza as escolhas do aluno, traz uma dificuldade de escolha de quais disciplinas cursar. Quando o algoritmo colaborativo foi avaliado utilizando dados históricos de matrículas, o desempenho foi considerado encorajador em termos de cobertura. O algoritmo seria implantado no próximo ano acadêmico. E aguardam que o *feedback* dos alunos possa ajudar a desenvolver recursos mais avançados para o próximo período de solicitação de matrícula.

Vialardi et al. (2011) comenta que uma das principais contribuições de seu trabalho é a utilização de dois atributos sintéticos para melhorar a relevância das recomendações feitas. O primeiro atributo estima a dificuldade inerente a um determinado curso. O segundo atributo, denominado potencial, é uma medida da competência de um aluno para um determinado curso com base nas notas obtidas em cursos relacionados.

Uslu; Ozturan; Uslu (2016) relatam as dificuldades que os alunos encontram para organizar as disciplinas eletivas que irão cursar durante o semestre. Conforme o número de disciplinas cresce o problema também aumenta e esse tipo de problema desperta interesse de pesquisadores no campo de otimização. Foi desenvolvido para os alunos uma plataforma online chamada *Mecanin* para ajudar a preparar os horários, considerando a preferência por professores e os conflitos de horários. Essa plataforma possui um sistema de recomendação baseado em filtragem colaborativa. De 2010 a 2014 entre 700 e 1400 alunos utilizaram o sistema e os algoritmos foram testados neste conjunto de dados. Após a execução dos experimentos os autores observam que a plataforma desenvolvida é suficientemente responsiva para sugerir uma grade de horários para os estudantes, baseado na avaliação das disciplinas e nos conflitos de horário. Eles apresentam diversas variantes e comparações com o algoritmo proposto e observam que o método baseado em similaridade, supera todos os outros métodos.

Lin et al. (2018) apresentam o conceito de educação inteligente e afirmam que no passado vários algoritmos e métodos foram propostos para lidar com o problema de recomendação de disciplinas, porém nenhum deles foi projetada para lidar com os requisitos da educação inteligente. Escrevem sobre os sistemas de recomendação e os métodos utilizados para a seleção de disciplinas e que basicamente eles podem ser categorizados em três grupos diferentes, os colaborativos, baseados em conteúdo e baseados em conhecimento. O método escolhido para o desenvolvimento do recomendador foi o SLIM (*Sparse Linear Method*). Após o processo de coleta de dados, foram realizados experimentos de comparação entre métodos de última geração e o método proposto. Os resultados experimentais da taxa de acerto e da média recíproca de classificação de acertos, mostram que o método proposto supera os outros métodos.

Fernandez-garcia et al. (2020) falam da importância do ensino superior e da relação direta entre a educação e a desigualdade no continente europeu. Relata que o número de alunos do curso de ciência da computação aumentou, assim como a demanda por esses profissionais. E diz ainda que medidas devem ser tomadas para evitar a evasão dos alunos, principalmente no primeiro ano do curso. As principais inovações propostas no artigo são a da criação de uma estratégia que aproveite ao máximo pequenos conjuntos de dados para inferir conhecimento, na forma de sistemas de apoio à decisão para auxiliar os alunos na escolha das disciplinas mais adequadas. Usando sistemas de recomendação os autores pretendem auxiliar os alunos na escolha das melhores disciplinas para aumentar o número de alunos graduados no curso. Propõe ainda uma abordagem que utiliza técnicas de mineração de dados. Os autores concluem lembrando que o trabalho não focou apenas em previsões mas também em ajudar os alunos a terem melhores resultados.

Vuong et al. (2019) começam relatando que cada vez mais universidades adotam o sistema de créditos para realizar a avaliação do progresso do aluno no curso. Relatam que no Vietnã os alunos podem ganhar créditos por concluírem as disciplinas selecionadas. Portanto a seleção correta das disciplinas é uma decisão importante. Infelizmente, os estudantes geralmente ficam confusos e não sabem quais disciplinas optativas escolher. Isso se deve ao fato de não conhecer as habilidades necessárias para cursar a disciplina ou então não sabem o quão útil a disciplina será para sua carreira após a graduação além de desconhecerem os limites máximos e mínimos de créditos da universidade. A proposta do trabalho é um sistema de recomendação e personalização para a educação, que utiliza filtragem colaborativa, recomendações baseadas em conteúdo e outras diversas técnicas. Segundo os autores os experimentos produziram resultados ótimos, alcançaram a melhor pontuação RMSE de 1,669, que utiliza a proposta de abordagem híbrida. Para tarefa de recomendação de caminho de estudo, alcançaram 0,790 para a pontuação SMC.

Shah; Shah; Banerjee (2017) relatam a influência dos colegas nas escolhas dos estudantes e o peso que estas escolhas tem no futuro, nos objetivos e na motivação do aluno. Um sistema de recomendação que tenha acesso a vários parâmetros sobre o aluno tem chance de dar sugestões muito melhores. Neste artigo os autores apresentam uma abordagem de aprendizado de máquina para prever o desempenho do aluno em várias disciplinas. O autor utiliza técnicas de fatoração de matriz de baixa classificação além de propõe uma técnica de regularização para resolver o problema de sobre-ajuste durante a aprendizagem. Os resultados dos experimentos realizados sugerem que a proposta de regularização na aprendizagem melhora a precisão de predição e o tempo de processamento. A comparação baseada no erro de previsão, taxa de aprendizado e tempo de processamento do método proposto com o método de regularização existente apresenta melhoras significativas.

Maphosa; Doorsamy; Paul (2020) relatam os desafios que os estudantes enfrentam ao escolher suas disciplinas eletivas e informam que as instituições de ensino superior contratam conselheiros para ajudar nessa tarefa. Este artigo tem o foco de examinar o escopo e sistemas de recomendação que auxiliam os estudantes na escolha de disciplinas eletivas. Para realizar o trabalho os autores utilizaram uma revisão sistemática da literatura sobre o corpus de sistemas de recomendação para a escolha de disciplinas eletivas publicada entre 2010 e 2019. Dos 16.981 artigos de pesquisa inicialmente identificados, apenas 24 abordaram sistemas de recomendação para a escolha de disciplinas eletivas e foram incluídos na análise final. Esses artigos mostram que várias abordagens de sistemas de recomendação e algoritmos de mineração de dados são usados para realizar a tarefa de recomendar disciplinas eletivas. Este estudo contribui para o corpo da literatura sobre sistemas de recomendação, em particular aqueles aplicados para auxiliar os alunos na escolha de disciplinas eletivas

No total são apresentados 29 (vinte e nove) trabalhos relacionados. Deste total, 17 (dezessete) trabalhos são direcionados a campus inteligente. E destes, cerca de 59%, estão ligados a tópicos do grupo Infraestrutura. Como comentado na Seção 2.1, os trabalhos na área de *Smart Campus* são muito focados em aplicações também utilizadas em *Smart Cities* e não tanto em aplicações em processos acadêmicos e de ensino-aprendizagem.

Os trabalhos reunidos no grupo de Interface propõem diferentes abordagens de comunicação ou novas experiências para os usuários do *Smart Campus*. Por fim, os do grupo Recomendador são trabalhos que propõem soluções de técnicas de recomendação no contexto de *Smart Campus* e recomendação de disciplinas. O'mahony; Smyth (2007), Vialardi et al. (2011) e Bydžovská (2016) estão relacionados com este trabalho no aspecto de recomendação de disciplinas, mas não estão ligados diretamente ao conceito de *Smart Campus*. Este trabalho e o de Villegas-ch; Arias-navarrete; Palacios-pacheco (2020) são os únicos da lista que estão diretamente relacionados a *Smart Campus* e recomendação de disciplinas. Villegas-ch; Arias-navarrete; Palacios-pacheco (2020) utiliza um sistema de *chatbot* onde o aluno precisa se autenticar no sistema para que este então passe a fazer recomendações. Em nossa proposta os componentes curriculares que serão recomendados estarão inseridos do processo de rematricula, não sendo necessário o acesso a outros sistemas.

3 ABORDAGEM PROPOSTA

Este Capítulo apresenta a proposta do trabalho, a qual consiste em um sistema de recomendação de disciplinas. Neste Capítulo é realizada a contextualização do processo atual de matrículas e o detalhamento do sistema de recomendação proposto.

3.1 Contextualização

Em grande parte das universidades brasileiras, e até do mundo, os currículos dos cursos de graduação são organizados em períodos letivos semestrais ou anuais. Isto quer dizer que o aluno cursa em cada período letivo (semestral ou anual) um conjunto de componentes curriculares indicado na sequência estabelecida no projeto pedagógico de cada curso. A cada início de período (semestre ou ano) os alunos têm de realizar alguns processos ligados à sua vida acadêmica. Um deles é o processo de solicitar as componentes curriculares que querem cursar no período que está para iniciar.

Na Universidade Federal de Pelotas, o processo de Matrícula é regulado no Capítulo I do Regulamento do Ensino de Graduação na UFPel (UFPEL, 2018). Este processo de matrícula na UFPel é constituído de três fases:

Rematrícula: os discentes devem fazer a solicitação de matrícula no Sistema Acadêmico, no período estabelecido no calendário acadêmico. Após a solicitação de matrícula online é realizado o processamento de matrícula automatizado que considera uma ordem de matrícula em componentes curriculares que possuem mais solicitações de matrícula que vagas disponíveis;

Correção de Matrícula: a correção de matrícula é a possibilidade de inclusão ou exclusão de componentes curriculares após o processamento de matrícula, sendo destinada aos discentes que necessitam de ajustes no resultado de sua solicitação de matrícula ou que não tenham solicitado a matrícula online. Atualmente a solicitação de matrícula ocorre online e o processamento é pelos Colegiados de Curso;

Matrícula Especial: é permitido ao discente cursar componentes curriculares em outros cursos, na modalidade de matrícula especial, desde que haja disponibilidade de vagas a cada período letivo. Atualmente o processo de solicitação de matrícula especial é realizado online e para ser efetivado deve possuir o aval do Colegiado do Curso que oferta o componente curricular pretendido e do Colegiado do Curso de origem do aluno.

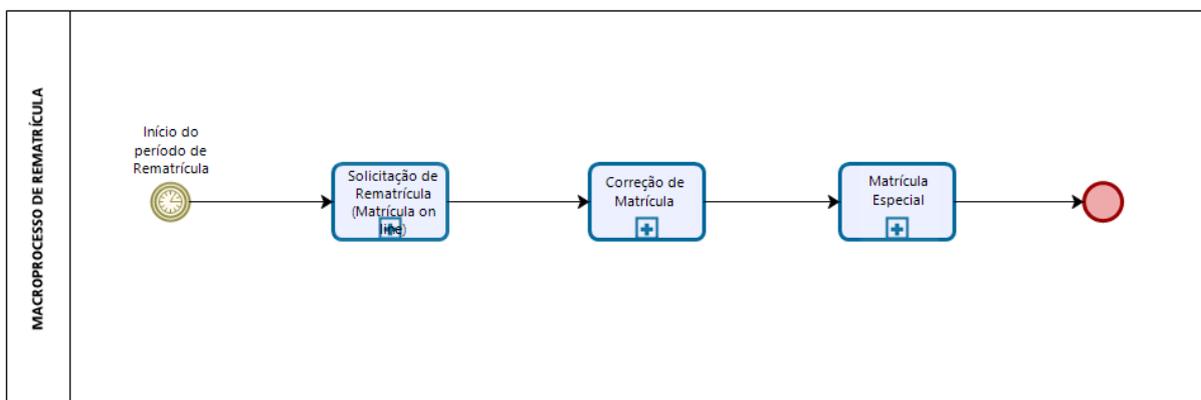


Figura 2 – Macroprocesso de Solicitação de Matrícula.

Na Figura 2 pode-se observar o macroprocesso de matrícula que deve ser realizado em cada novo período letivo. Atualmente na UFPel este procedimento é realizado de forma online e manual. Quando o período para solicitação de disciplinas para a rematrícula está aberto, o discente acessa o sistema acadêmico da Universidade (Cobalto) e solicita as disciplinas ofertadas. No Cobalto é apresentado para o aluno uma lista de todas as ofertas do semestre para o respectivo curso. A partir dessa listagem o aluno escolhe as disciplinas que acredita ser as melhores opções para ele e salva sua solicitação. Caso não haja conflitos de horários entre as atividades escolhidas ou quebra de pré-requisitos a solicitação é salva. Após esse momento, é realizado o processamento da matrícula, onde as solicitações de matrículas são processadas e disponibilizadas para o aluno.

O programa do sistema Cobalto atualmente apresenta no processo de rematrícula todas as ofertas de disciplinas que o aluno pode cursar. Ele apresenta as disciplinas obrigatórias organizadas por semestre, as optativas e as do Banco Universal (disciplinas ofertadas para todos os cursos). Um dos problemas é a imensa lista de disciplinas. A Figura 3 apresenta o programa atual de solicitação de matrícula do Cobalto.

Disciplinas **Grade de Horários Preliminar**

Curso: 16104034 - 100 - Agronomia (GRADUAÇÃO)

Lista de disciplinas

Turma	Solicitações/IV	Horário	Horário
7º Semestre			
01200016 - MANEJO INTEGRADO DE DOENÇAS DE PLANTAS			
M1	0 / 55	SEG (08:00-08:50)	SEG (08:50-09:40) SEG (09:00-10:50)
M2	0 / 55	QUI (08:00-08:50)	QUI (08:50-09:40) QUI (09:00-10:50)
8º Semestre			
01180029 - EXTENSÃO E DESENVOLVIMENTO RURAL			
M1	0 / 55	SEX (14:00-14:50)	SEX (14:50-15:40) SEX (15:50-16:40)
M2	0 / 50	TER (14:00-14:50)	TER (14:50-15:40) TER (15:50-16:40)
01180036 - TRABALHO DE CONCLUSÃO DE CURSO I			

Figura 3 – Programa de solicitação de matrícula atual.

Além do grande número de disciplinas apresentadas, a solicitação de matrícula é um processo totalmente baseado no discente. Na forma online não existe um “aconselhamento” para os alunos a não ser a própria disposição das disciplinas nos períodos do curso. Atualmente, em grande parte dos cursos os alunos não percorrem as disciplinas de forma padronizada (em bloco), seja por reprovar em alguma como também por não cursar o número de disciplinas recomendadas por semestre. Para estes alunos o aconselhamento por parte da coordenação do curso pode ser essencial, pois considerará quais disciplinas são mais relevantes para o aluno cursar em um dado semestre, o grau de dificuldade e a capacidade do aluno em relação ao seu histórico.

A recomendação de matrícula automatizada é a tentativa de trazer o conhecimento de um coordenador experiente sem a necessidade de uma relação direta entre um coordenador e o aluno, além de considerar as características do próprio aluno. O

sistema de Recomendação de Matrícula proposto neste trabalho é aplicado apenas na Rematrícula, contudo, pode ser normalmente aplicado ao processo de Correção de Matrícula.

3.2 O Recomendador de Disciplinas Proposto

O Recomendador de Disciplinas proposto objetiva propiciar um sistema de recomendação que auxiliará o aluno em sua jornada acadêmica sugerindo as disciplinas que melhor se encaixam ao seu perfil considerando o índice de aprovações e a dificuldade, e limitará o número de recomendações para que o volume de trabalho não ultrapasse a capacidade de aprendizado.

Para o desenvolvimento do recomendador de disciplinas utilizou-se o *Surprise*, uma biblioteca para uso do Sci-Kit, em Python, para construir e analisar sistemas de recomendação que lidam com dados de classificação explícitos (HUG, 2021). Dessa biblioteca foram utilizados os algoritmos detalhados na Seção 2.3. SciKits (abreviação de SciPy Toolkits) são pacotes complementares para o SciPy, hospedados e desenvolvidos separados e independentes da distribuição principal do SciPy. Todos os SciKits são licenciados sob licenças aprovadas pela *Open Source Initiative* (OSI) (SCIPY DEVELOPERS, 2021).

Na Figura 4, pode-se ver a representação do fluxo de atividades do recomendador. O sistema de recomendações funciona da seguinte forma: para começar o processo de recomendações precisa-se carregar as informações dos alunos, das matrículas, do currículo do curso (disciplinas que compõem o currículo) e das turmas ofertadas.

Para cada aluno, carregam-se as respectivas solicitações de matrícula. Para realizar as recomendações, é feito o ajuste do número máximo e mínimo de recomendações para cada aluno; a validação das disciplinas cursadas, aprovadas, equivalentes e dispensadas; e, verificação do que ainda falta cursar.

O ajuste do número de recomendações é o cálculo realizado tendo como base o número de aprovações que o aluno alcança em cada semestre. Para isso é calculada a média das aprovações e este valor é utilizado para limitar o número máximo de recomendações.

A validação das disciplinas cursada é uma análise do currículo do aluno. Neste procedimento são removidas do currículo do curso as disciplinas não obrigatórias, assim como as disciplinas já aprovadas pelo aluno e as que foram cursadas por alguma equivalência. Deste processo resulta a lista das disciplinas que o recomendador pode ofertar para o aluno.

Para cada algoritmo, é necessário carregar as configurações, realizar a recomendação, selecionar as com maior peso e armazenar na lista de recomendações. Se o *booster* for utilizado, aplica-se o *boost* na lista de recomendações e a listagem final é

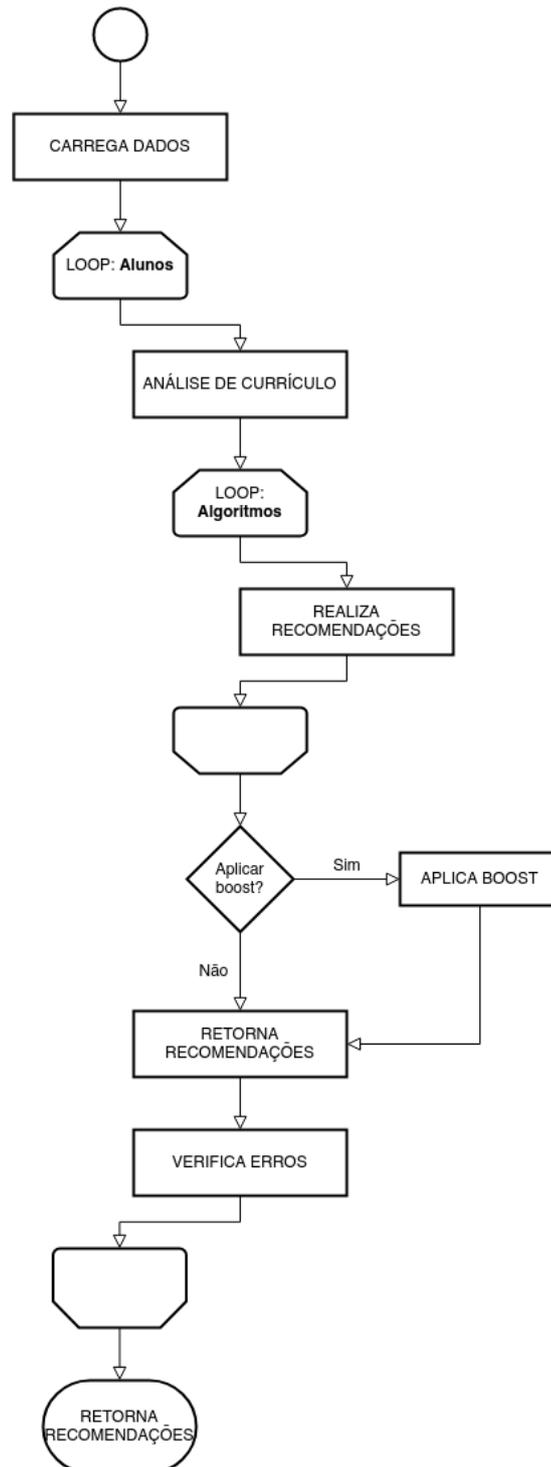


Figura 4 – Fluxograma do Funcionamento do Recomendador.

retornada.

Como é possível ser observado na Figura 4, no passo **LOOP: Algoritmos**, todos os algoritmos têm a oportunidade de gerar as recomendações. A lista de recomendações de cada algoritmo é armazenada. Após a realização das recomendações as listas são comparadas. Logo, as disciplinas com melhor classificação, em cada lista, são selecionadas para serem recomendadas.

3.2.1 Definição do Número Máximo de Recomendações

O número máximo de recomendações (NMR) foi calculado para cada aluno considerando a média de disciplinas que o aluno costuma aprovar, conforme a equação que segue:

$$NMR = (NDA + NDD)/NSC \quad (19)$$

onde NDA é o número de disciplinas em que o aluno foi aprovado; NDD é o número de disciplinas dispensadas; e, NSC é o número total de semestres no curso.

O número de recomendações é importante, pois, caso contrário, podem ser recomendados um número de disciplinas maior do que o estudante é capaz de realizar, o que não é desejado. Desta forma, este número é baseado no próprio histórico de aprovações do aluno.

3.2.2 Booster

O recomendador poderá recomendar, de acordo com seus algoritmos, disciplinas que estão mais à frente do curso em detrimento das disciplinas dos semestres iniciais, que podem ter menor peso na recomendação.

O *booster* é uma funcionalidade pensada para dar mais poder ao coordenador do curso, ajustando a preferência pela recomendação de disciplinas que ficaram para trás, contornando esse problema. Quando a função de recomendação for utilizada em conjunto com o *booster*, o recomendador pode ajustar o peso da recomendação da disciplina para o semestre onde a disciplina deve ser cursada. A configuração do *booster* é feita por um vetor de valores passados ao recomendador, onde cada posição do vetor corresponde a um semestre do curso. Esta funcionalidade pode ser configurada pelo Coordenador do Curso.

Por exemplo, no currículo atual, o curso de Ciência da Computação é composto de 8 semestres. Para dar prioridade às disciplinas do primeiro e segundo semestre, a configuração passada ao recomendador poderia ser algo como $[0.9, 0.8, 0, 0, 0, 0, 0, 0]$. Na configuração citada, as disciplinas do primeiro e segundo semestre receberiam um impulso na sua recomendação de 90% e 80%, respectivamente.

3.2.3 Sistema de Votação

Para a seleção das disciplinas que serão recomendadas utilizou-se um processo de votação. Após a seleção de um aluno, cada algoritmo realiza suas recomendações. Após a conclusão do processo de recomendação realiza-se uma análise das disciplinas que foram mais recomendadas (“votadas”) pelos onze algoritmos utilizados. Então, estas são selecionadas como as melhores recomendações.

Como citado no início deste Capítulo, o sistema de recomendação aqui proposto,

realiza uma análise do currículo do aluno, removendo as disciplinas já aprovadas, dispensadas e cursadas em alguma equivalência. Após realizar esta operação, as disciplinas que permaneceram na lista do currículo são classificadas por cada um dos algoritmos. Na Tabela 2 podemos ver um exemplo de como é feita a classificação. Nas primeiras colunas é possível observar as características das disciplinas do currículo e a partir da terceira coluna temos os algoritmos e a classificação de cada disciplina pelo algoritmo. A partir dessa Tabela e com a utilização do número máximo de recomendações (definido na Seção 3.2.1), as disciplinas melhor classificadas por cada algoritmo são filtradas e contadas como um voto, conforme demonstrado na Tabela 3. Após a contagem dos votos, um aluno que tenha duas recomendações como seu número máximo de recomendações, resultaria em algo como o apresentado na Tabela 4.

Tabela 2 – Exemplo de uma tabela de votação (Classificação)

Código	Disciplina	BaselineOnly	CoClustering	...	SVD	SVDpp
22000196	INTRODUÇÃO À CIÊNCIA DA COMPUTAÇÃO	0,91	0,83	...	0,30	0,26
22000207	LABORATÓRIO DE COMPUTAÇÃO	0,34	0,45	...	0,63	0,29
22000224	LÓGICA PARA COMPUTAÇÃO	0,10	0,15	...	0,89	0,14

22000186	COMPUTAÇÃO E SOCIEDADE	0,97	0,10	...	0,23	0,08
22000255	PROCESSAMENTO DIGITAL DE IMAGENS	0,10	0,09	...	0,60	0,10
22000306	TRABALHO DE CONCLUSÃO DE CURSO II	0,62	0,60	...	0,92	0,18

Tabela 3 – Exemplo de uma tabela de votação (Votação)

Código	Disciplina	BaselineOnly	CoClustering	...	SVD	SVDpp
22000196	INTRODUÇÃO À CIÊNCIA DA COMPUTAÇÃO	S	S	...	N	S
22000207	LABORATÓRIO DE COMPUTAÇÃO	N	S	...	S	S
22000224	LÓGICA PARA COMPUTAÇÃO	N	N	...	S	N

22000186	COMPUTAÇÃO E SOCIEDADE	S	N	...	N	N
22000255	PROCESSAMENTO DIGITAL DE IMAGENS	N	N	...	N	N
22000306	TRABALHO DE CONCLUSÃO DE CURSO II	S	S	...	S	S

Tabela 4 – Exemplo de uma tabela de votação (Resultado)

Código	Disciplina	BaselineOnly	CoClustering	...	SVD	SVDpp	Top
22000186	COMPUTAÇÃO E SOCIEDADE	S	S	...	S	S	11
22000306	TRABALHO DE CONCLUSÃO DE CURSO II	S	S	...	S	S	11
22000224	LÓGICA PARA COMPUTAÇÃO	S	N	...	S	S	10

3.2.4 Considerações Gerais

Um dos problemas corriqueiros dos sistemas de recomendação é o de partida a frio (*cold-start*). Este problema ocorre quando há um novo usuário ou um novo item. Como o usuário ainda não classificou nenhum item, é difícil recomendar, pois, ainda não se sabe nada sobre este usuário (SARNOBAT; KALOLA, 2019).

Contudo, em nossa proposta esse problema não ocorre porque se utilizam as seguintes correspondências: o aluno é correspondente a um usuário, a disciplina cur-

sada corresponde ao item e a nota final da disciplina é utilizada como a classificação do item. Quando o aluno ingressa na universidade ele é matriculado nas disciplinas do primeiro semestre do curso, não havendo a necessidade de recomendações. Consequentemente, a partir da primeira rodada de recomendações o aluno, no caso usuário, já tem itens classificados, as disciplinas cursadas e as notas do semestre.

3.3 Distância Contextual

A **Distância Contextual** (*DC*) foi criada como uma forma de identificar ou avaliar se um aluno está no estágio que deveria estar no curso ou está ficando atrasado/adiantado em relação ao seu currículo. O objetivo da *DC* não é mostrar o quanto do curso o aluno concluiu. Visto que um aluno no início do curso pode ter a mesma *DC* que um aluno que está para finalizar o curso. Esta forma, chamada Distância Contextual (*DC*), estabelecida pela seguinte equação:

$$DC = \frac{TOA - TOS}{TOC} * 100 \quad (20)$$

onde: *TOA* é o total de disciplinas obrigatórias que o aluno aprovou ou foi dispensado; *TOS* é o somatório do número de disciplinas até o número de semestres que correspondem ao tempo do aluno no curso; e, *TOC* é o número de disciplinas que os alunos devem cursar obrigatoriamente para concluírem o curso.

Por exemplo, se o aluno estiver no curso há 3 semestres, ele deveria ter cursado 16 disciplinas obrigatórias (5 disciplinas do 1.º período + 5 disciplinas do 2.º período + 6 disciplinas do 3.º período). Se ele cursou as 16 obrigatórias, $DC = \frac{16 - 16}{41} * 100 = 0$, ou seja, ele está ajustado ao terceiro semestre. Caso não tenha aprovado em nada, $DC = \frac{0 - 16}{41} * 100 = -39,02$, um atraso de 39% do total do curso.

4 EXPERIMENTOS E RESULTADOS

Este Capítulo consiste nos experimentos e resultados realizados com o recomendador proposto. O Capítulo apresenta inicialmente uma caracterização do estudo de caso utilizado: o curso de graduação em Ciência da Computação da UFPel. Após, são apresentados os diversos experimentos realizados e seus resultados.

4.1 Caracterização do Estudo de Caso

O presente trabalho utilizou como estudo de caso os dados do curso de Ciência da Computação da UFPel, registrados no Sistema Cobalto. A partir de 2001, o nome do curso é Ciência da Computação, pois inicialmente tinha o nome de Bacharelado em Informática. O curso foi aprovado pelo Conselho Universitário da UFPel em 1992 e iniciou as atividades em 07/03/1994.

O currículo do curso de Ciência da Computação da UFPel compreende um conjunto de disciplinas obrigatórias, disciplinas optativas e atividades complementares. O curso de Ciência da Computação é integral (com aula em dois turnos) estruturado em 3200 horas em 8 semestres. Além disso, o curso possui um regime letivo semestral. Atualmente, no semestre 2021/1, o curso de Ciência da Computação possui 386 alunos matriculados.

Para conhecer melhor as características do curso que este trabalho utiliza como estudo de caso foi necessária a extração de algumas informações. Desta forma, esta Seção apresenta algumas análises feitas sobre o curso da Ciência da Computação.

Foi realizada uma análise geral do curso com intuito de determinar a distribuição de alunos pelo curso, considerando a situação dos alunos por semestre. Como resultado, foi obtido o gráfico apresentado na Figura 5. Observa-se que uma grande parte dos alunos está aglomerada no início do gráfico, o que é esperado, pois a cada novo semestre novos alunos ingressam no curso e essa quantidade vai caindo conforme o tempo vai passando. Observa-se ainda que, a partir do oitavo semestre, começam a surgir as primeiras indicações de alunos formados, o que também é esperado, pois o curso tem um ou mais currículos com oito semestres. O fato curioso nesta Figura é a

quantidade de períodos que os alunos permanecem no curso após o final esperado.

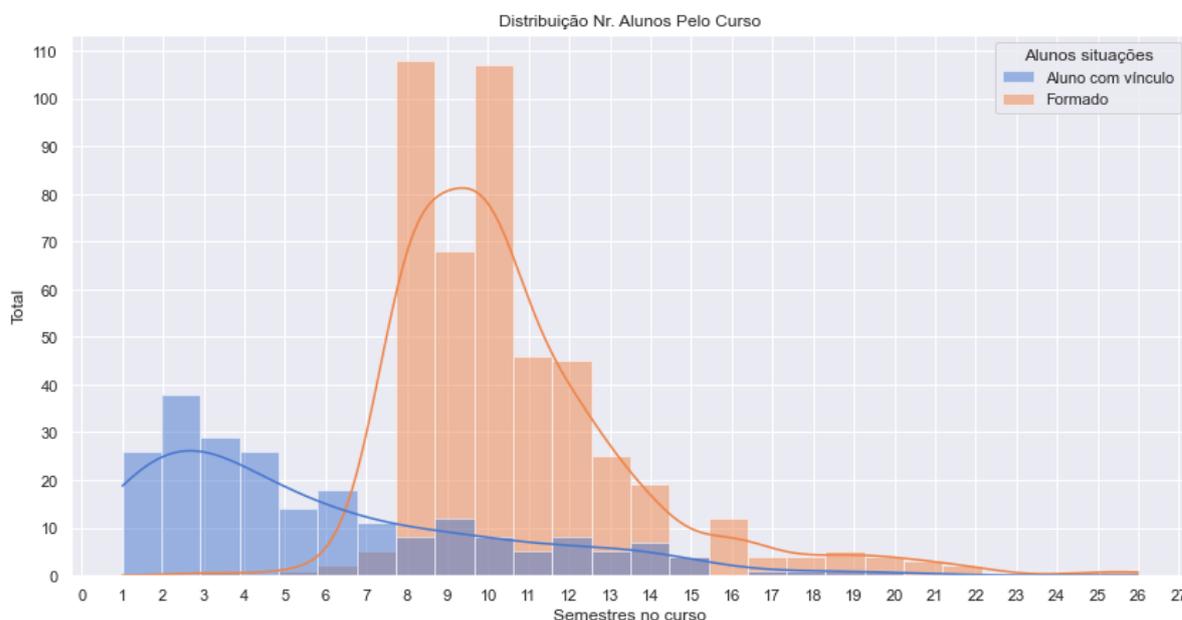


Figura 5 – Distribuição dos alunos pelo curso de Ciência da Computação.

O curso da computação não é modularizado, isso significa que o aluno pode cursar as disciplinas da forma que achar melhor desde que respeitados os pré-requisitos. Entretanto, no cadastro do currículo do curso, que tem como base o projeto pedagógico, cada disciplina está indicada no período ideal para o aluno cursar aquela disciplina.

A grade curricular do curso de Ciência da Computação é apresentada no Apêndice A. Neste Apêndice são apresentadas as disciplinas obrigatórias organizadas por semestre (código, nome da disciplina, número de créditos total, carga horárias e pré-requisitos). De forma resumida, a Tabela 5 apresenta a quantidade de disciplinas obrigatórias e o número de atividades curriculares com pré-requisitos conforme o semestre. Pode-se afirmar que a quantidade de pré-requisitos influencia diretamente na recomendação de disciplinas.

Tabela 5 – Quantidade de disciplinas do currículo (versão 9) do curso de Ciência da Computação.

Período	Disciplinas obrigatórias	Disciplinas com pré-requisitos
1	5	0
2	5	2
3	6	5
4	6	4
5	6	4
6	5	5
7	5	5
8	3	1
Total	41	26

Na UFPel, cada curso pode ter mais de uma versão, que muda a cada vez que o curso sofre uma alteração de currículo, por exemplo, quando um componente curricu-

lar é removido ou adicionado. Isso acontece para manter a compatibilidade dos alunos que ingressaram em um determinado currículo.

A Figura 6 apresenta as 3 últimas versões do curso da computação (versões 7, 8 e 9). No eixo vertical do gráfico pode-se observar o número de disciplinas do currículo, no eixo horizontal pode-se observar o número de semestres que o currículo possui. Nesta mesma Figura pode-se observar que às duas últimas versões do curso têm oito semestres e a versão número sete tem nove semestres. Já em relação ao número de disciplinas por semestre pode-se observar que o número não passa de seis disciplinas para a última versão do currículo e fica entre cinco e seis disciplinas com exceção no último semestre (três disciplinas).

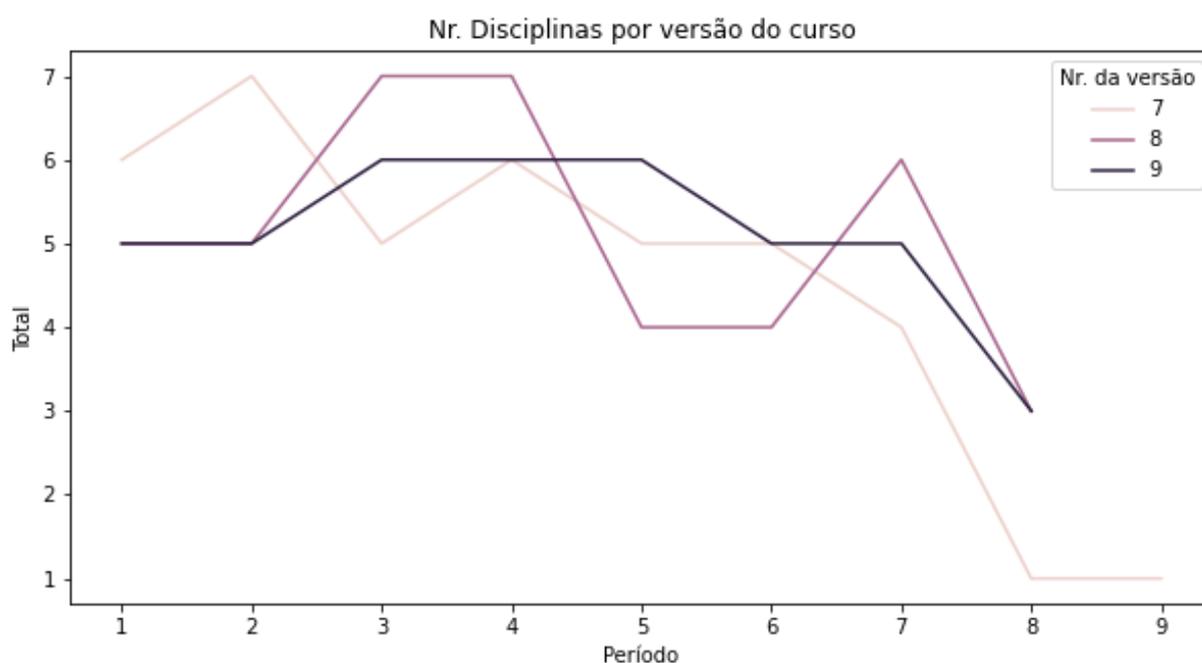


Figura 6 – Número de disciplinas obrigatórias por versão do curso.

Outra análise importante foi o número de solicitações de matrículas que os alunos realizaram. O objetivo desta análise era investigar qual o número médio de disciplinas que os alunos solicitavam. A Figura 7 apresenta no eixo vertical a média de cada um dos itens do gráfico.

O item *Solicitou* é o indicador do número médio de disciplinas que os alunos solicitaram. O item *Conseguiu* é o indicador do número médio de disciplinas que os alunos foram matriculados. O item *Não Conseguiu* é o indicador do número médio de disciplinas que os alunos não conseguiram matrícula.

No eixo horizontal observa-se o período em que ocorreu a solicitação de matrícula. Cabe observar que o eixo horizontal apresenta seus valores no formato ANO-MÊS (período que ocorreu a solicitação de matrícula) de modo que no ano de 2017 houve uma solicitação, 2018 e 2019 com duas solicitações, 2020 com três solicitações e

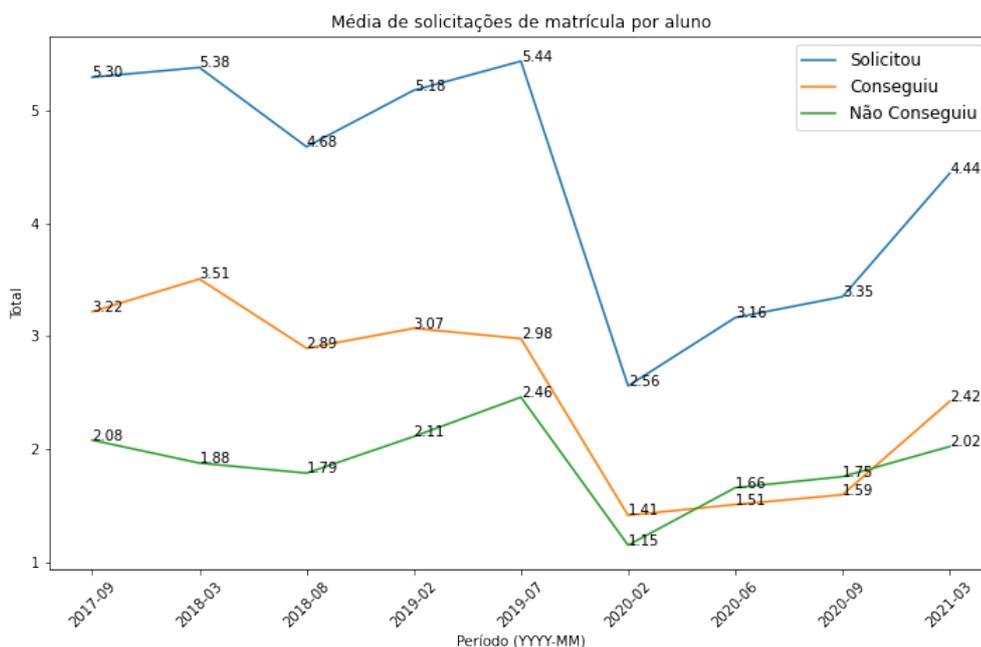


Figura 7 – Média de solicitações de matrículas por aluno.

2021 com uma solicitação. Os números baixos de solicitações de matrículas nos anos de 2020 e 2021 são decorrentes dos problemas causados nas ofertas pela pandemia de Coronavírus. Já dos anos de 2017 a 2019 pode-se observar que a média de solicitações fica ao redor de 5 e o número de solicitações efetivadas (“Conseguiu”) são em torno de 3.

Avaliou-se ainda a média de disciplinas cursadas no curso. Na Figura 8, no eixo vertical temos a média de disciplinas cursadas, enquanto no eixo horizontal temos o período da média, período este que está apresentado no formato ANO-SEMESTRE. Pode-se observar ainda uma queda acentuada no ano de 2020, o que demonstra o forte impacto que a pandemia de COVID-19 teve sobre o curso.



Figura 8 – Média de disciplinas cursadas por período.

As disciplinas dispensadas são aquelas que o aluno já cursou uma disciplina equivalente na própria instituição ou em outra IES. Neste trabalho consideramos estas disciplinas como aprovadas, pois não há a necessidade do aluno cursá-la novamente. Então, resolveu-se conduzir a análise dos dados e gerou-se o gráfico apresentado na Figura 9. Nesta Figura o eixo vertical apresenta o número de disciplinas dispensadas no período, apresentado no eixo horizontal. O período está representado no formato ANO-SEMESTRE. Observamos ainda nesta mesma Figura um grande número de disciplinas dispensadas. Uma possível explicação para esse índice pode ser atribuída a uma troca de versão do curso, ou seja, quando disciplinas são adicionadas, removidas ou alteradas no currículo do curso, alguns alunos são trocados de versão. Contudo, para que possam concluir o curso, as disciplinas cursadas na versão anterior são considerados concluídas por dispensa o que contribui para os níveis apresentados na Figura.

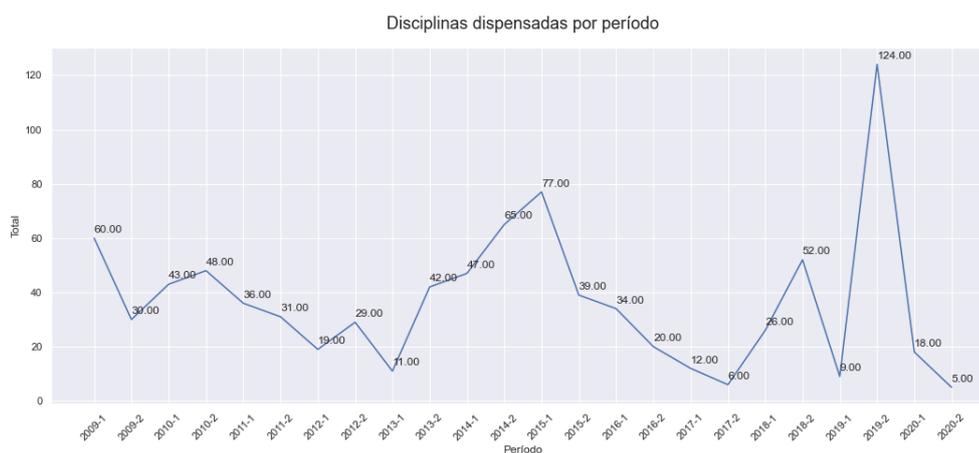


Figura 9 – Histórico de disciplinas dispensadas.

Além das análises já realizadas, ainda se considerou necessária a visualização do panorama das disciplinas. O gráfico apresentado na Figura 10 foi criado. Nele foi traçado o número das disciplinas aprovadas e das disciplinas dispensadas, foco deste estudo. Também consta neste gráfico o indicador TOT o qual é composto por todas as outras situações possíveis da matrícula, quais sejam: aprovado/utilizada para dispensa, cancelado, cursando, frequente, infrequente, mobilidade acadêmica, reprovado, trancado e trancamento de disciplina.

4.2 Experimentos

Esta Seção apresenta os experimentos realizados e seus resultados, divididos em dois grupos. A Seção 4.2.1 apresenta os experimentos para cinco discentes selecionados com o objetivo de apresentar o funcionamento do sistema de recomendação proposto de forma didática. Já a Seção 4.2.2 apresenta os resultados gerais do sis-

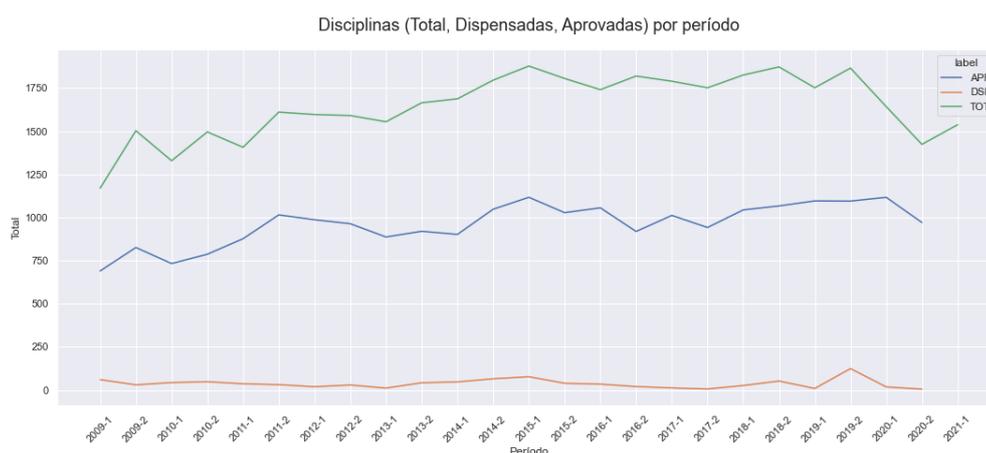


Figura 10 – Histórico de disciplinas (Aprovadas, Dispensadas, Total).

tema de recomendação proposto. Além disso, apresenta os resultados para diferentes configurações de *boost* e uma comparação para estas diferentes configurações.

Para os experimentos foram utilizados dados do semestre 2019/1. Neste período específico, obtiveram-se os dados das solicitações de matrículas, das matrículas realizadas e das ofertas que ocorreram neste período. Cabe salientar que os registros de solicitação de matrícula não são armazenados por longo tempo. Também se descartou utilizar os dados acadêmicos de 2020/1 e 2020/2 por se tratarem de semestres atípicos no funcionamento da instituição.

Ressalta-se que na implementação do sistema de recomendação desse trabalho, não foram considerados os horários de turmas ofertadas. Como resultado, o número total de erros deverá ser menor, quando essa informação for utilizada.

Para realizar os experimentos individuais e resultados de forma individual (considerando determinados alunos) realizou-se a seleção de um conjunto de cinco alunos. Para esta seleção utilizou-se como critério a distância contextual (DC) apresentada na Seção 3.3. Após calcular a DC para todos os alunos, classificou-se em ordem crescente e dividiu-se os alunos em 5 grupos conforme a distância contextual. Os grupos foram criados respeitando os seguintes limites:

- Alunos que tiveram DC acima de 50;
- Alunos que tiveram DC entre 0 e 50;
- Alunos que tiveram DC igual a 0;
- Alunos que tiveram DC entre 0 e -50;
- Alunos que tiveram DC abaixo de -50.

Após realizada a organização por grupos, um aluno de cada grupo foi sorteado para fazer parte dos exemplos aqui expostos.

A metodologia para execução dos experimentos e coleta dos resultados foi realizada da seguinte forma:

1. Para cada aluno foi executado o sistema de recomendação de disciplinas conforme funcionamento descrito na Seção 3.2;
2. Foi realizada a comparação das disciplinas recomendadas com as disciplinas realmente solicitadas pelo aluno;
3. Também foi realizada a comparação das disciplinas recomendadas com as disciplinas matriculadas (realmente cursadas) pelo aluno;
4. Por fim, foi realizada a comparação das disciplinas recomendadas com as disciplinas aprovadas pelo aluno ao final do semestre.

As seções subsequentes apresentarão os experimentos e resultados obtidos a partir desta metodologia.

4.2.1 Experimentos e Resultados Individuais

Esta Seção apresenta os experimentos para cinco discentes selecionados com o objetivo de exemplificar o funcionamento do sistema de recomendação proposto de forma didática.

Os perfis dos estudantes selecionados para este experimento são apresentados na Tabela 6. A Tabela apresenta o semestre do aluno no curso, e a média geral dos alunos e a Distância Contextual (DC) que foi utilizada para seleção dos alunos. Por fim, a Tabela apresenta o número máximo de recomendações obtido pelo sistema de recomendação proposto através da definição da Seção 3.2.1. O número máximo de recomendações apresentado na tabela está fracionado, porém, quando ele é utilizado para limitar as recomendações ele é arredondado para o número inteiro mais próximo.

Tabela 6 – Alunos selecionados para o experimento.

Aluno	Sem. no Curso	Média	N.º Máximo de recomendações	DC
A	2	6,80	24,50	85,37
B	5	7,19	4,00	2,44
C	15	7,48	3,07	0,00
D	11	7,39	2,27	-41,46
E	9	7,04	1,78	-56,10

Na Tabela 7 pode-se observar as disciplinas obrigatórias que ainda restavam para os alunos cursarem. Nesta Tabela têm-se as informações sobre a disciplina, tais como: o código da disciplina e o nome. Ainda, é importante ressaltar a coluna Pré-requisitos, nela está contida a lista dos códigos das disciplinas que os alunos ainda precisavam cursar.

Tabela 7 – Disciplinas que ainda faltam ser cursadas para os alunos A, B, C, D e E.

Aluno	Cód. Atividade	Nome	Erro	Pré-requisitos
A	22000187	COMPUTAÇÃO GRÁFICA	5,627	[11100005 22000297]
A	22000272	INTROD PROCESSAMENTO PARALELO E DISTRIBUÍDO	9999,000	[22000270]
A	22000306	TRABALHO DE CONCLUSÃO DE CURSO II	8,158	[22000305]
A	22000270	SISTEMAS OPERACIONAIS	7,465	[22000182 22000297]
B	22000297	ALGORITMOS E ESTRUTURAS DE DADOS I	5,623	[22000296]
B	11100005	ÁLGEBRA LINEAR E GEOMETRIA ANALÍTICA	1,559	[]
B	22000182	ARQUITETURA E ORGANIZAÇÃO DE COMPUTADORES II	9999,000	[22000181]
B	22000205	TEORIA DA COMPUTAÇÃO	6,138	[22000197]
B	22000298	ESTATÍSTICA BÁSICA PARA COMPUTAÇÃO	9999,000	[11100059]
B	22000299	ALGORITMOS E ESTRUTURAS DE DADOS II	9999,000	[22000297]
B	22000300	ALGORITMOS E ESTRUTURAS DE DADOS III	9999,000	[22000299]
B	22000301	FUNDAMENTOS DE INTELIGÊNCIA ARTIFICIAL	8,229	[]
B	22000302	PROJETO DE BANCO DE DADOS	6,805	[]
B	22000187	COMPUTAÇÃO GRÁFICA	9999,000	[11100005 22000297]
B	22000189	ENGENHARIA DE SOFTWARE I	9999,000	[22000201]
B	22000268	CÁLCULO NUMÉRICO COMPUTACIONAL	9999,000	[22000296 11100059]
B	22000272	INTROD PROCESSAMENTO PARALELO E DISTRIBUÍDO	9999,000	[22000270]
B	22000303	PROJETO DE COMPILADORES	6,565	[22000197]
B	22000304	DESENVOLVIMENTO DE SOFTWARES	9999,000	[22000201]
B	22000305	TRABALHO DE CONCLUSÃO DE CURSO I	7,827	[22000199]
B	22000186	COMPUTAÇÃO E SOCIEDADE	8,183	[]
B	22000306	TRABALHO DE CONCLUSÃO DE CURSO II	9999,000	[22000305]
B	22000273	REDES DE COMPUTADORES	9999,000	[22000270]
B	22000270	SISTEMAS OPERACIONAIS	9999,000	[22000182 22000297]
B	22000174	ENGENHARIA DE SOFTWARE II	9999,000	[22000189]
B	11100059	CÁLCULO 2	2,951	[11100058]
B	22000181	ARQUITETURA E ORGANIZAÇÃO DE COMPUTADORES I	5,451	[22000211]
B	22000188	CONCEITOS DE LINGUAGENS DE PROGRAMAÇÃO	9999,000	[22000201]
B	22000237	PROGRAMAÇÃO DE SISTEMAS	9999,000	[22000181 22000296]
B	22000203	SEMÂNTICA FORMAL	9999,000	[22000197 22000188]
B	22000201	PROGRAMAÇÃO ORIENTADA A OBJETOS	5,075	[22000296]
B	22000255	PROCESSAMENTO DIGITAL DE IMAGENS	5,212	[]
C	22000298	ESTATÍSTICA BÁSICA PARA COMPUTAÇÃO	3,941	[11100059]
C	22000187	COMPUTAÇÃO GRÁFICA	4,816	[11100005 22000297]
C	22000272	INTROD PROCESSAMENTO PARALELO E DISTRIBUÍDO	7,395	[22000270]
C	22000306	TRABALHO DE CONCLUSÃO DE CURSO II	8,384	[22000305]
C	22000273	REDES DE COMPUTADORES	5,885	[22000270]
D	22000298	ESTATÍSTICA BÁSICA PARA COMPUTAÇÃO	3,722	[11100059]
D	22000299	ALGORITMOS E ESTRUTURAS DE DADOS II	8,620	[22000297]
D	22000300	ALGORITMOS E ESTRUTURAS DE DADOS III	9999,000	[22000299]
D	22000302	PROJETO DE BANCO DE DADOS	4,907	[]
D	22000187	COMPUTAÇÃO GRÁFICA	5,315	[11100005 22000297]
D	22000189	ENGENHARIA DE SOFTWARE I	4,644	[22000201]
D	22000268	CÁLCULO NUMÉRICO COMPUTACIONAL	4,709	[22000296 11100059]
D	22000272	INTROD PROCESSAMENTO PARALELO E DISTRIBUÍDO	9999,000	[22000270]
D	22000303	PROJETO DE COMPILADORES	4,763	[22000197]
D	22000304	DESENVOLVIMENTO DE SOFTWARES	6,586	[22000201]
D	22000305	TRABALHO DE CONCLUSÃO DE CURSO I	7,541	[22000199]
D	22000186	COMPUTAÇÃO E SOCIEDADE	5,072	[]
D	22000306	TRABALHO DE CONCLUSÃO DE CURSO II	9999,000	[22000305]
D	22000273	REDES DE COMPUTADORES	9999,000	[22000270]
D	22000270	SISTEMAS OPERACIONAIS	5,539	[22000182 22000297]
D	22000174	ENGENHARIA DE SOFTWARE II	9999,000	[22000189]
D	22000188	CONCEITOS DE LINGUAGENS DE PROGRAMAÇÃO	7,645	[22000201]
D	22000203	SEMÂNTICA FORMAL	9999,000	[22000197 22000188]
D	22000255	PROCESSAMENTO DIGITAL DE IMAGENS	5,592	[]
E	22000297	ALGORITMOS E ESTRUTURAS DE DADOS I	2,535	[22000296]
E	11100005	ÁLGEBRA LINEAR E GEOMETRIA ANALÍTICA	0,313	[]
E	22000182	ARQUITETURA E ORGANIZAÇÃO DE COMPUTADORES II	2,946	[22000181]
E	22000205	TEORIA DA COMPUTAÇÃO	4,867	[22000197]
E	22000298	ESTATÍSTICA BÁSICA PARA COMPUTAÇÃO	9999,000	[11100059]
E	22000299	ALGORITMOS E ESTRUTURAS DE DADOS II	9999,000	[22000297]
E	22000300	ALGORITMOS E ESTRUTURAS DE DADOS III	9999,000	[22000299]
E	22000301	FUNDAMENTOS DE INTELIGÊNCIA ARTIFICIAL	9,484	[]
E	22000302	PROJETO DE BANCO DE DADOS	4,710	[]
E	22000187	COMPUTAÇÃO GRÁFICA	9999,000	[11100005 22000297]
E	22000189	ENGENHARIA DE SOFTWARE I	9999,000	[22000201]
E	22000268	CÁLCULO NUMÉRICO COMPUTACIONAL	9999,000	[22000296 11100059]
E	22000272	INTROD PROCESSAMENTO PARALELO E DISTRIBUÍDO	9999,000	[22000270]
E	22000303	PROJETO DE COMPILADORES	6,055	[22000197]
E	22000304	DESENVOLVIMENTO DE SOFTWARES	9999,000	[22000201]
E	22000305	TRABALHO DE CONCLUSÃO DE CURSO I	8,204	[22000199]
E	22000186	COMPUTAÇÃO E SOCIEDADE	7,031	[]
E	22000306	TRABALHO DE CONCLUSÃO DE CURSO II	9999,000	[22000305]
E	22000273	REDES DE COMPUTADORES	9999,000	[22000270]
E	22000270	SISTEMAS OPERACIONAIS	9999,000	[22000182 22000297]
E	22000174	ENGENHARIA DE SOFTWARE II	9999,000	[22000189]
E	11100059	CÁLCULO 2	0,897	[11100058]
E	22000188	CONCEITOS DE LINGUAGENS DE PROGRAMAÇÃO	9999,000	[22000201]
E	22000237	PROGRAMAÇÃO DE SISTEMAS	7,341	[22000181 22000296]
E	22000203	SEMÂNTICA FORMAL	9999,000	[22000197 22000188]
E	22000201	PROGRAMAÇÃO ORIENTADA A OBJETOS	2,415	[22000296]
E	22000255	PROCESSAMENTO DIGITAL DE IMAGENS	4,940	[]

Sobre os alunos selecionados, pode-se tecer as seguintes observações:

Aluno A: possui uma característica interessante: apesar de estar no segundo semestre do curso, o número de recomendações é extremamente elevado. Isso ocorre porque o discente reingressou no curso e já possui um grande número de disciplinas aprovadas/dispensadas, muito embora esteja no segundo semestre. O DC tem valor positivo indicando que o aluno está adiantado no curso em relação ao que deveria ter cursado;

Aluno B: está no curso há 4 semestres e sua DC é 0, o que indica que o aluno está onde era esperado que estivesse;

Aluno C: apesar deste aluno estar no curso pelo mesmo número de semestres do Aluno B, ele tem sua DC negativa, indicando que cursou menos atividades do que deveria ter cursado até seu momento curricular;

Aluno D: este aluno tem o mesmo atraso indicado no Aluno C, com o diferencial de que já está há 13 semestres no curso. Apesar de apresentar uma média menor que o Aluno C, a distância entre o que cursou e o que deveria ter cursado é a mesma;

Aluno E: apresenta uma DC negativa e bem elevada, indicando que está bem atrás do que deveria estar. Por estar bem atrasado e ter uma média baixa, o número de recomendações para este aluno também é reduzido.

Na Tabela 8, têm-se as recomendações que o sistema recomendador gerou para cada um dos alunos. Nessa Tabela a coluna *Top* contém a informação do número de votos dados pelos algoritmos de recomendação. Na Tabela 8 também observa-se que o valor contido na coluna *top*, para o aluno A é 11. Isto indica que todos os algoritmos recomendaram esta disciplina. Já na linha onde o nome da disciplina é **ÁLGEBRA LINEAR E GEOMETRIA ANALÍTICA**, do aluno B, 10 algoritmos votaram nessa disciplina. O sistema de recomendação seleciona as disciplinas mais votadas até o número máximo de disciplinas recomendadas, calculado para cada aluno.

Com objetivo de comparar o sistema de recomendação proposto com o que aconteceu na realidade, foram analisados dados das disciplinas realmente solicitadas e cursadas no semestre pelos alunos.

Na Tabela 9 pode-se visualizar as disciplinas que os alunos selecionados escolheram no período de solicitação de matrículas. Nessa Tabela, além das informações das disciplinas solicitadas têm-se as colunas *Matriculado* e *Erro*. A coluna *Matriculado* indica que após o processamento da matrícula o aluno foi matriculado na disciplina. A coluna *Erro* indica qual erro ocorreu no processamento da solicitação de matrícula que impediu o aluno de cursar a disciplina solicitada. Entre os erros possíveis, o mais comum é a falta de vaga na turma.

Tabela 8 – Disciplinas recomendadas para os alunos A, B, C, D e E.

Aluno	Cód. Atividade	Atividade Curricular	Top
A	22000187	COMPUTAÇÃO GRÁFICA	11
A	22000270	SISTEMAS OPERACIONAIS	11
A	22000272	INTROD PROCESSAMENTO PARALELO E DISTRIBUÍDO	11
A	22000306	TRABALHO DE CONCLUSÃO DE CURSO II	11
B	11100005	ÁLGEBRA LINEAR E GEOMETRIA ANALÍTICA	11
B	11100059	CÁLCULO 2	11
B	22000201	PROGRAMAÇÃO ORIENTADA A OBJETOS	9
B	22000181	ARQUITETURA E ORGANIZAÇÃO DE COMPUTADORES I	7
C	22000187	COMPUTAÇÃO GRÁFICA	11
C	22000272	INTROD PROCESSAMENTO PARALELO E DISTRIBUÍDO	11
C	22000273	REDES DE COMPUTADORES	11
C	22000298	ESTATÍSTICA BÁSICA PARA COMPUTAÇÃO	11
D	22000298	ESTATÍSTICA BÁSICA PARA COMPUTAÇÃO	11
D	22000187	COMPUTAÇÃO GRÁFICA	9
D	22000189	ENGENHARIA DE SOFTWARE I	7
E	11100059	CÁLCULO 2	10
E	11100005	ÁLGEBRA LINEAR E GEOMETRIA ANALÍTICA	9

Tabela 9 – Disciplinas solicitadas pelos alunos A, B, C, D e E.

Aluno	Cód. Matrícula	Atividade Curricular	Matriculado	Erro
A	22000227	TÓPICOS ESPECIAIS EM COMPUTAÇÃO II	S	
A	22000187	COMPUTAÇÃO GRÁFICA	S	
A	22000306	TRABALHO DE CONCLUSÃO DE CURSO II	S	
A	22000270	SISTEMAS OPERACIONAIS	S	
B	22000297	ALGORITMOS E ESTRUTURAS DE DADOS I	N	Não há vagas na turma
B	22000181	ARQUITETURA E ORGANIZAÇÃO DE COMPUTADORES I	N	Não há vagas na turma
B	11100005	ÁLGEBRA LINEAR E GEOMETRIA ANALÍTICA	S	
B	22000205	TEORIA DA COMPUTAÇÃO	S	
B	22000201	PROGRAMAÇÃO ORIENTADA A OBJETOS	S	
B	11100059	CÁLCULO 2	N	Não há vagas na turma
C	22000319	PROJETOS EM COMPUTAÇÃO I	N	Não há vagas na turma
C	22000272	INTROD PROCESSAMENTO PARALELO E DISTRIBUÍDO	N	Não há vagas na turma
C	22000273	REDES DE COMPUTADORES	S	
C	22000306	TRABALHO DE CONCLUSÃO DE CURSO II	S	
C	22000187	COMPUTAÇÃO GRÁFICA	N	Não há vagas na turma
C	22000298	ESTATÍSTICA BÁSICA PARA COMPUTAÇÃO	S	
D	22000298	ESTATÍSTICA BÁSICA PARA COMPUTAÇÃO	S	
D	22000188	CONCEITOS DE LINGUAGENS DE PROGRAMAÇÃO	S	
D	22000299	ALGORITMOS E ESTRUTURAS DE DADOS II	N	Não há vagas na turma
D	22000302	PROJETO DE BANCO DE DADOS	N	Não há vagas na turma
E	11100059	CÁLCULO 2	S	
E	22000205	TEORIA DA COMPUTAÇÃO	N	Não há vagas na turma
E	11100005	ÁLGEBRA LINEAR E GEOMETRIA ANALÍTICA	N	Não há vagas na turma
E	22000201	PROGRAMAÇÃO ORIENTADA A OBJETOS	N	Não há vagas na turma
E	22000227	TÓPICOS ESPECIAIS EM COMPUTAÇÃO II	N	Não há vagas na turma
E	22000297	ALGORITMOS E ESTRUTURAS DE DADOS I	N	Não há vagas na turma

Na Tabela 10, estão listadas as disciplinas que os alunos cursaram no semestre analisado. Essa informação é importante porque após a solicitação de matrícula online, o aluno pode fazer uma nova solicitação através do processo de correção de matrícula ou da matrícula especial.

Tabela 10 – Disciplinas cursadas pelos alunos A, B, C, D e E.

Aluno	Cód. Matrícula	Atividade Curricular	Situação da matrícula
A	22000187	COMPUTAÇÃO GRÁFICA	Aprovado
A	22000272	INTROD PROCESSAMENTO PARALELO E DISTRIBUÍDO	Aprovado
A	22000306	TRABALHO DE CONCLUSÃO DE CURSO II	Reprovado
A	22000270	SISTEMAS OPERACIONAIS	Dispensado
B	11100005	ÁLGEBRA LINEAR E GEOMETRIA ANALÍTICA	Aprovado
B	22000205	TEORIA DA COMPUTAÇÃO	Infrequente
B	11100059	CÁLCULO 2	Aprovado
B	22000181	ARQUITETURA E ORGANIZAÇÃO DE COMPUTADORES I	Aprovado
B	22000201	PROGRAMAÇÃO ORIENTADA A OBJETOS	Aprovado
C	22000298	ESTATÍSTICA BÁSICA PARA COMPUTAÇÃO	Aprovado
C	22000187	COMPUTAÇÃO GRÁFICA	Aprovado
C	22000272	INTROD PROCESSAMENTO PARALELO E DISTRIBUÍDO	Infrequente
C	22000306	TRABALHO DE CONCLUSÃO DE CURSO II	Reprovado
C	22000273	REDES DE COMPUTADORES	Aprovado
D	22000298	ESTATÍSTICA BÁSICA PARA COMPUTAÇÃO	Infrequente
D	22000188	CONCEITOS DE LINGUAGENS DE PROGRAMAÇÃO	Infrequente
E	22000297	ALGORITMOS E ESTRUTURAS DE DADOS I	Reprovado
E	22000182	ARQUITETURA E ORGANIZAÇÃO DE COMPUTADORES II	Reprovado
E	22000186	COMPUTAÇÃO E SOCIEDADE	Aprovado
E	11100059	CÁLCULO 2	Reprovado
E	22000201	PROGRAMAÇÃO ORIENTADA A OBJETOS	Reprovado

Além dos dados da disciplina, cabe destacar a coluna Situação da matrícula, a qual demonstra a situação da matrícula em cada disciplina ao final do semestre. Dentre as situações possíveis, vale destacar as mais frequentes, quais sejam: Aprovado, Reprovado, Infrequente e Trancamento.

A Tabela 11 apresenta os resultados consolidados para os experimentos individualizados dos alunos A, B, C, D e E. Nesta Tabela consta o resumo das recomendações. Cada linha corresponde a um item avaliado. As colunas representam os alunos (A,B,C,D e E). Observa-se que o Nr. Recomendadas muda conforme o aluno, o que demonstra que o SR está se adaptando ao usuário que está sendo avaliado.

Na sequência, tem-se o Nr. Solicitadas que é uma contagem das disciplinas que o aluno solicitou no período analisado. O Nr. Cursadas representa as disciplinas que o aluno cursou. Estes dois valores são utilizados para critérios de comparação. Os itens Acertou nas (solicitações, cursadas, aprovadas), representam os acertos do que foi recomendado, conforme os itens avaliados. Os itens Errou nas (solicitações, cursadas, aprovadas) são o oposto do Acertou. Estes itens representam o que foi recomendado, porém, não estava na lista do item avaliado. Por fim, os valores apresentados para os itens Recomendado vs. Solicitado, Recomendado vs. Cursado, Recomendado vs. Aprovadas são os índices de acerto das disciplinas recomendadas pelo sistema em relação às disciplinas realmente solicitadas, matriculadas e aprovadas.

Tabela 11 – Análise dos Resultados para os alunos A, B, C, D e E.

Item	A	B	C	D	E
Nr. Recomendadas	4	4	4	3	2
Nr. Solicitadas	4	6	6	4	6
Nr. Cursadas	4	5	5	2	5
Nr. Aprovadas	2	4	3	0	1
Acertou nas solicitações	3	4	4	1	2
Acertou nas cursadas	4	4	4	1	1
Acertou nas aprovadas	2	4	3	0	0
Errou nas cursadas	0	1	1	1	4
Errou nas solicitações	1	2	2	3	4
Errou nas aprovadas	0	0	0	0	1
Recomendado vs. Solicitado	0,75	1,00	1,00	0,33	1,00
Recomendado vs. Cursado	1,00	1,00	1,00	0,33	0,50
Recomendado vs. Aprovadas	0,50	1,00	0,75	0,00	0,00

Um resultado importante a observar, apesar dos alunos-alvo do estudo de caso terem sido selecionados aleatoriamente, é que o número de disciplinas recomendadas foi igual ao número de disciplinas solicitadas. Para os alunos selecionados, o índice de acerto das disciplinas recomendadas em relação às disciplinas solicitadas possui índice superior a 67%, atingindo em dois alunos acertos de 100%. Já em relação às disciplinas cursadas também foram atingidos índices satisfatórios, com exceção do aluno E que não cursou nenhuma disciplina no semestre. Por fim, o índice que compara as disciplinas recomendadas com as aprovadas apresenta resultados com índices menores, contudo ainda relevantes, considerando que neste caso depende do rendimento do aluno.

4.2.2 Experimentos e Resultados Gerais

Nesta Seção são apresentados os resultados obtidos pelo sistema de recomendação proposto. Como já mencionado, foram utilizados dados do semestre 2019/1. Os experimentos foram realizados a partir dos dados de 304 discentes que somaram um total de **1606** solicitações de matrícula em disciplinas.

Para apresentação dos resultados foi utilizado o agrupamento do número de recomendações produzidas pelo SR. Além disso, serão apresentados os resultados utilizando a técnica de *boost* descrita na Seção 3.2.2. Para os testes realizados, utilizou-se cinco variações de estratégias de *boosting*, a saber:

B1 – Boost linear decrescente: o *boosting* linear crescente foi pensando em valorizar (dar mais peso) nas disciplinas dos semestres iniciais;

B2 – Boost exponencial decrescente: este *boosting* também foi utilizado para dar mais peso as disciplinas iniciais do curso, porém de forma exponencial;

B3 – Boost linear crescente: é o oposto do *boosting* linear crescente e valoriza disciplinas dos semestres mais a frente do curso;

B4 – Boost exponencial crescente: este *boosting* também concede maior peso as disciplinas mais a frente do curso, porém de forma exponencial; e,

B5 – Boost constante 50%: este *boosting* foi utilizado para verificar a sua diferença em relação à não utilizar *boosting*.

A partir das configurações de *boost* determinadas (Figura 11) são apresentados os resultados obtidos pelo recomendador quando o sistema de *boost* é utilizado e também sem *boosting*.

Antes de apresentar os resultados um destaque importante que deve ser feito é que as tabelas a seguir tem o número máximo de recomendações limitados em seis. Isso decorre devido ao fato do curso ter em sua versão nove, o máximo de seis disciplinas obrigatórias por semestre. Quando o número máximo de recomendações ultrapassa o limite, esse passa a ser seis. Na Tabela 12 podemos ver alguns dados sobre as recomendações. São apresentadas as colunas N.º Máx que representa o número máximo de recomendações, a coluna Tam que contem a quantidade de recomendações feitas quando o número máximo de recomendações é o indicado na coluna N.º Máx e por fim a coluna Rep. total que indica o quando a coluna Tam. representa no volume total de recomendações.

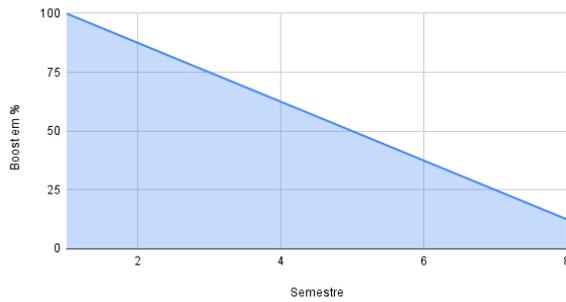
Tabela 12 – Estatísticas das recomendações

Recomendações		
N.º Máx.	Tam	Rep. total
1	4	1,32%
2	82	26,97%
3	54	17,76%
4	51	16,78%
5	31	10,20%
6	82	26,97%
	304	100%

A Tabela 13 apresenta os resultados sem *boosting*, enquanto as Tabelas 14, 15, 16, 17 e 18 apresentam os resultados com *boosting* nas diferentes configurações.

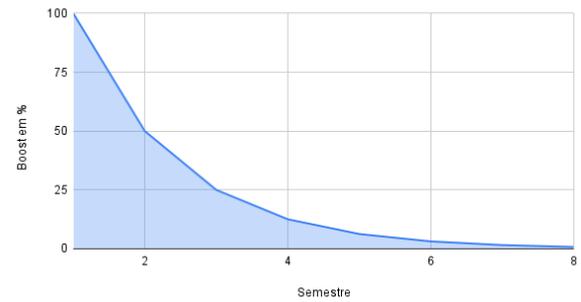
Para observar as variações nas recomendações, as Tabelas foram organizadas com as seguintes colunas: N.º Recomendações, Solicitações, Coursadas e Aprovadas. Na coluna do N.º Recomendações são apresentados os números de recomendações realizadas pelo SR. Já os valores contidos nas colunas Solicitações, Coursadas

Boost em % versus Semestre (Teste 1)



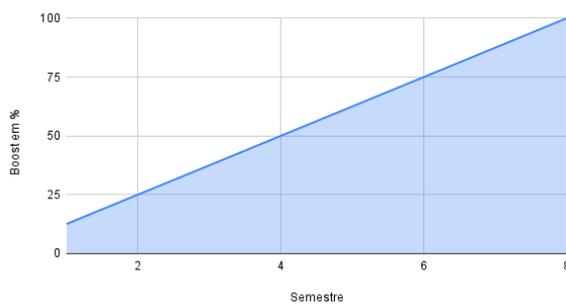
(a) Boost linear decrescente

Boost em % versus Semestre (Teste 2)



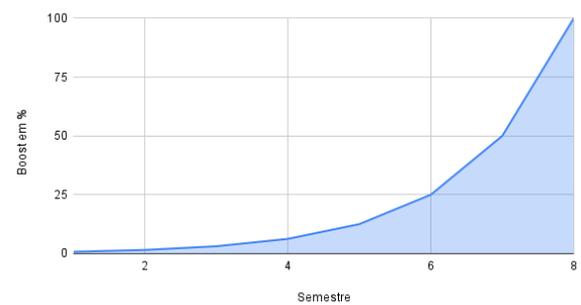
(b) Boost exponencial decrescente

Boost em % versus Semestre (Teste 3)



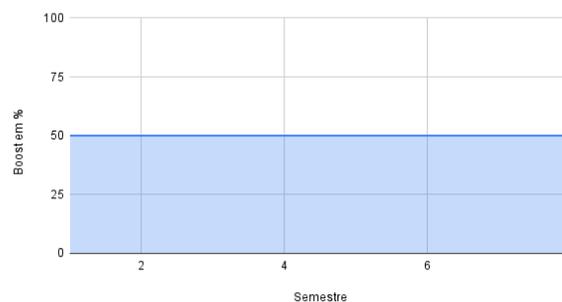
(c) Boost linear crescente

Boost em % versus Semestre (Teste 4)



(d) Boost exponencial crescente

Boost em % versus Semestre (Teste 5)



(e) Boost constante 50%

Figura 11 – Diferentes configurações de *Boost* utilizados nos experimentos.

e Aprovadas são o valor médio calculado a partir das informações de Acertou nas solicitações, Acertou nas cursadas e Acertou nas aprovadas.

Por exemplo, a Tabela 13 apresenta os resultados para as recomendações sem *boosting* quando o SR recomendou uma disciplina, a média de de acerto das recomendações vs. solicitações foi de 0,750.

Tabela 13 – N.º recomendações vs. Acertos sem utilização de *boost*.

N.º Recomendações	Solicitações	Cursadas	Aprovadas
1	0,750	1,000	0,250
2	0,878	0,695	0,183
3	1,833	1,426	0,593
4	2,549	2,471	1,275
5	3,000	2,903	2,226
6	3,220	3,183	2,707

Tabela 14 – Recomendações utilizando *boost* linear decrescente – Fig. 11a.

N.º Recomendações	Solicitações	Cursadas	Aprovadas
1	0,750	1,000	0,250
2	0,902	0,780	0,195
3	1,852	1,481	0,593
4	2,549	2,412	1,235
5	3,065	2,935	2,226
6	3,256	3,232	2,744

Tabela 15 – Recomendações utilizando *boost* exponencial decrescente – Fig. 11b.

N.º Recomendações	Solicitações	Cursadas	Aprovadas
1	0,750	1,000	0,250
2	0,890	0,805	0,220
3	1,833	1,444	0,574
4	2,549	2,471	1,275
5	3,065	2,968	2,226
6	3,256	3,232	2,732

Tabela 16 – Recomendações utilizando *boost* linear crescente – Fig. 11c.

N.º Recomendações	Solicitações	Cursadas	Aprovadas
1	0,750	1,000	0,250
2	0,878	0,720	0,183
3	1,778	1,407	0,519
4	2,569	2,471	1,255
5	3,032	2,903	2,226
6	3,256	3,244	2,756

Com intuito de facilitar a comparação entre as recomendações geradas pelo SR e as disciplinas realmente solicitadas, cursadas e aprovadas dos discentes, são apresentadas as Tabelas 19, 20 e 21.

Tabela 17 – Recomendações utilizando *boost* exponencial crescente – Fig. 11d.

N.º Recomendações	Solicitações	Cursadas	Aprovadas
1	0,750	1,000	0,250
2	0,878	0,720	0,207
3	1,778	1,389	0,519
4	2,549	2,471	1,275
5	2,903	2,806	2,129
6	3,280	3,256	2,768

Tabela 18 – Recomendações utilizando *boost* constante (50%) – Fig. 11e.

N.º Recomendações	Solicitações	Cursadas	Aprovadas
1	0,750	1,000	0,250
2	0,927	0,780	0,195
3	1,833	1,426	0,593
4	2,588	2,510	1,275
5	3,065	2,935	2,258
6	3,256	3,232	2,756

Tabela 19 – Comparação dos percentuais de acertos nas solicitações de matrícula com diferentes configurações de *boost*.

Acertos nas solicitações de matrícula						
N.º Recomendações	B1	B2	B3	B4	B5	SB
1	75,00%	75,00%	75,00%	75,00%	75,00%	75,00%
2	45,12%	44,51%	43,90%	43,90%	46,34%	43,90%
3	61,73%	61,11%	59,26%	59,26%	61,11%	61,11%
4	63,73%	63,73%	64,22%	63,73%	64,71%	63,73%
5	61,29%	61,29%	60,65%	58,06%	61,29%	60,00%
6	54,27%	54,27%	54,27%	54,67%	54,27%	53,66%

Na Tabela 19 são apresentados os percentuais de acertos nas solicitações de matrículas com diferentes configurações de *boost*. Pode-se observar que, quando o número de recomendações é 1, a configuração do *boost* é irrelevante. Todos os testes apresentaram o mesmo resultado. Isso ocorre porque quando o SR recomenda apenas uma disciplina, o aluno normalmente está no final do curso, tornando, portanto, o sistema de *boost* irrelevante. É possível ainda observar que a utilização do *booster* não modifica significativamente o resultado das recomendações, quando comparado aos testes que não o utilizam. Os maiores índices de acerto das disciplinas recomendadas em relação as disciplinas solicitadas são: 75,00%, 43,90%, 61,11%, 63,73%, 60,00% e 53,66%, respectivamente para uma, duas, três, quatro, cinco e seis disciplinas recomendadas. Os índices podem ser considerados bons, pois está se recomendando disciplinas e comparando com as escolhas realizadas pelos alunos (que

poderiam não ser as melhores).

Os resultados comparativos utilizando diferentes configurações em relação às disciplinas recomendadas e cursadas é apresentado na Tabela 20. Assim como na Tabela 19, pode-se observar o mesmo padrão de resultado, ou seja: quando apenas uma recomendação é feita, o sistema de boost é irrelevante, do mesmo modo que o resultado das recomendações não se modifica significativamente. Os maiores índices de acerto das disciplinas recomendadas em relação as disciplinas cursadas são: 100,00%, 43,90%, 51,85%, 63,24%, 56,13% e 48,58%, respectivamente para uma, duas, três, quatro, cinco e seis disciplinas recomendadas.

Tabela 20 – Comparação dos acertos nas disciplinas cursadas com diferentes configurações de boost.

Acertos nas disciplinas cursadas						
N.º Recomendações	B1	B2	B3	B4	B5	SB
1	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
2	39,02%	40,24%	35,98%	35,98%	39,02%	34,76%
3	49,38%	48,15%	46,91%	46,30%	47,53%	47,53%
4	60,29%	61,76%	61,76%	61,76%	62,75%	61,76%
5	58,71%	59,35%	58,06%	56,13%	58,71%	58,06%
6	53,86%	53,86%	54,07%	54,27%	53,86%	53,05%

Por fim, a Tabela 21 apresenta os resultados da comparação das disciplinas recomendadas e aprovadas. Os dados novamente demonstram que quando apenas uma recomendação é realizada o sistema de booster não é efetivo. Percebe-se ainda que o percentual de acerto é muito baixo quando duas recomendações são realizadas. O índice de acerto baixa de 48,78%(SB) na Tabela 19 para 5,49%(SB). Os maiores índices de acerto das disciplinas recomendadas em relação as disciplinas aprovadas são: 25,00%, 7,32%, 18,52%, 31,37%, 40,65% e 40,45%, respectivamente para uma, duas, três, quatro, cinco e seis disciplinas recomendadas. Estes índices mesmo são baixos claramente por considerarem a aprovação das disciplinas por parte dos alunos.

Tabela 21 – Comparação dos acertos nas disciplinas aprovadas com diferentes configurações de boost.

Acertos nas disciplinas aprovadas						
N.º Recomendações	B1	B2	B3	B4	B5	SB
1	25,00%	25,00%	25,00%	25,00%	25,00%	25,00%
2	9,76%	10,98%	9,15%	10,37%	9,76%	9,15%
3	19,75%	19,14%	17,28%	17,28%	19,75%	19,75%
4	30,88%	31,86%	31,37%	31,86%	31,86%	31,86%
5	44,52%	44,52%	44,52%	42,58%	45,16%	44,52%
6	45,73%	45,53%	45,93%	46,14%	45,93%	45,12%

A comparação com as disciplinas matriculadas, aprovadas e até mesmo solicitadas é uma métrica para o sistema de recomendação proposto. Contudo, não pode ser considerado um mecanismo de comparação definitivo. Muitas vezes os alunos podem solicitar e cursar disciplinas que não são as mais apropriadas segundo o cronograma curricular.

4.3 Avaliação dos Algoritmos de Recomendação Utilizados

Para realizar a avaliação dos algoritmos selecionados utilizaram-se medidas de avaliação de erros como: a RMSE (*root mean squared error*), que é a medida que calcula a raiz quadrática média dos erros entre valores observados e predições; e, o MAE (*mean absolute error*), que calcula o erro absoluto médio dos erros entre valores observados e predições. Após rodar os testes, obteve-se a Tabela 22, apresentando para cada algoritmo as métricas de erro e o tempo para realizar o treinamento do algoritmo.

Tabela 22 – Avaliação dos algoritmos

Algoritmo	RMSE	MAE	Tempo
BaselineOnly	2,000	1,550	0:00:02
CoClustering	2,008	1,534	0:00:08
KNNBaseline	2,027	1,485	0:00:37
KNNBasic	2,082	1,512	0:00:32
KNNWithMeans	2,008	1,494	0:00:31
KNNWithZScore	2,012	1,478	0:00:19
NMF	2,274	1,901	0:00:21
NormalPredictor	3,542	2,835	0:00:01
SlopeOne	1,857	1,398	0:00:06
SVD	2,045	1,496	0:00:16
SVDpp	2,056	1,496	0:01:41

Em relação aos algoritmos de recomendação utilizados se pode perceber que o SlopeOne obteve as menores taxas de erro para o conjunto de dados experimentado, assim como o tempo de execução ficou entre os 3 melhores tempos. Contudo, resolveu-se utilizar todo o conjunto de algoritmos apresentados, visto que todos tiveram um bom desempenho e a cada vez que o *benchmark* entre eles era executado, as variações eram mínimas e poderiam colocar outro algoritmo em primeiro lugar. Logo, a utilização do conjunto permitiu a criação da funcionalidade de votação apresentada na Seção 3.2.3.

5 CONCLUSÕES E TRABALHOS FUTUROS

O conceito de Campus Inteligente traz uma perspectiva de uso e integração de várias soluções de TIC a fim de propiciar o desenvolvimento do ambiente universitário nos mais diversos setores. O uso da Inteligência Artificial está diretamente ligado às soluções de campus inteligente como, por exemplo, o uso de sistemas de recomendação (SR).

Este trabalho apresentou um sistema combinado de recomendação de disciplinas no processo de matrícula no contexto de Campus Inteligente. O desenvolvimento do recomendador utilizou técnicas de sistemas de recomendação combinadas com filtragem colaborativa. Como estudo de caso para os experimentos e resultados foram utilizados dados do Curso de Ciência da Computação da Universidade Federal de Pelotas. Para comparação de resultados foi usada a matrícula do primeiro semestre do ano de 2019. Os dados foram extraídos do sistema integrado de gestão da UFPel (Cobalto).

A abordagem de recomendação proposta baseia-se em um sistema combinado de vários algoritmos largamente utilizados. Além disso, o sistema realiza a definição do número máximo de recomendações para cada aluno relacionado com o seu perfil. Foram desenvolvidos ainda um sistema de *booster* que permite dar peso diferentes nas recomendações e um sistema de votação utilizando os diferentes algoritmos.

Em relação aos experimentos e resultados, foi realizada uma análise individualizada com alunos selecionados com objetivo de demonstrar o uso do sistema de recomendação. Foram executados experimentos com todo o conjunto de dados (304 discentes solicitantes de matrícula) com e sem as diferentes configurações de *boosting*. Os resultados obtidos demonstraram que a utilização de um sistema de *boost* não se justifica quando a recomendação é de apenas uma disciplina. Quando a recomendação é de duas ou mais disciplinas, dependendo da configuração do boost e da situação do aluno no curso, é possível obter um pequeno ganho de desempenho. Quando comparadas as disciplinas solicitadas e cursadas com as recomendações feitas para mais de uma disciplina o percentual de acerto atinge mais de 60% para alguns grupos de disciplinas.

Por fim, este trabalho mostrou que o campus inteligente é um local no qual é possível aplicar os mais diversos tipos de tecnologias, entre elas, os sistemas de recomendação. Igualmente, vale destacar que os processos acadêmicos além de fazerem parte do campus inteligente podem ser melhorados com o uso de novas metodologias e tecnologias.

Pelo dito, é possível concluir que este trabalho atingiu os objetivos propostos, uma vez que: o sistema de recomendação de disciplinas consegue recomendar de forma eficiente as disciplinas mais relevantes; o recomendador consegue ofertar disciplinas em quantidade que não extrapole a capacidade de aprendizado do aluno e o mecanismo apresenta configurações parametrizáveis para se ajustar a especificidades de outros cursos.

5.1 Trabalhos Futuros

Considerando a perspectiva de trabalhos futuros, a primeira oportunidade que se vislumbra é aprofundar os experimentos do recomendador. Pode-se analisar os resultados com maior propriedade pensando em grupos de alunos. Por exemplo, o *boost* não apresentou vantagens na média, porém para alunos no início as recomendações podem fazer diferença. Outra oportunidade é realizar uma análise em mais cursos. Algumas questões se encontram em aberto como o uso de *boost* e deve-se realizar uma análise em relação à flexibilidade dos currículos. Pode-se afirmar que currículos com poucos pré-requisitos podem ter mais contribuição do recomendador, pois abre um maior leque de possibilidades. Também deve-se avaliar o uso do recomendador em cursos que tenham muitos pré-requisitos para haver o contraponto da comparação anterior.

Atualmente, como já foi comentado, o recomendador não considera o horário da turma em que a disciplina é ministrada. Uma análise poderia ser feita incluindo essa validação do horário para checar qual o impacto desta restrição de colisão de horários na análise de erros do recomendador. Esta modificação inclusive poderia melhorar os resultados apresentados neste trabalho.

O mecanismo atual apresenta configurações parametrizáveis para serem ajustadas de acordo com as especificidades de outros cursos. Estas configurações no futuro poderiam até ser definidas pelo Coordenador do Curso.

O recomendador proposto foi testado apenas no processo de solicitação de **rematrícula** e não nos processos de **correção de matrícula** e **matrícula especial**. Contudo, o sistema poderia com poucas modificações integrar o processo de **correção de matrícula** sendo que para isso deveria apenas considerar na recomendação as disciplinas que o aluno já conseguiu matrícula no processo de **rematrícula**.

Já a matrícula especial é o momento em que o aluno pode escolher quase qualquer

disciplina que queira fazer. A lista de disciplinas é muito variada, causando grande confusão na hora da escolha. O recomendador pode ser útil neste caso, utilizando a recomendação por similaridade dos itens. O aluno pode escolher uma ou mais disciplinas que tenha gostado de cursar e com base nessa informação o recomendador pode sugerir disciplinas que sejam similares as escolhidas. Para a realização do filtro o nome e a ementa da disciplina podem ser utilizados.

Outra aplicação do uso de recomendadores poderia ser para solicitação de disciplinas optativas, já que o foco deste trabalho foi apenas nas disciplinas obrigatórias. Seria muito interessante ajustar o recomendador para indicar qual o melhor período para cursar uma disciplina optativa. Atualmente as disciplinas optativas não possuem nenhuma indicação do período em que ela deva ser cursada. Entretanto, o percurso e rendimento dos próprios discentes podem fornecer a ideia de qual seria o melhor momento para o aluno cursar determinada atividade.

Pretende-se realizar a integração do sistema de recomendação proposto no Sistema Integrado de Gestão da UFPel, o sistema Cobalto. Como alternativa a esta aplicação apresentada na Figura 3, propõe-se que as disciplinas ofertadas para o semestre, continuem sendo exibidas em uma listagem para o aluno. O diferencial é que com base no rendimento do aluno o sistema de recomendação possa avaliar quais as disciplinas que ele tem a maior chance de ter um rendimento melhor.

Nesta proposta, essas disciplinas ficariam marcadas na listagem com um destaque e um aviso ao usuário é apresentado informando que tais disciplinas são recomendações. Se o discente decidir que as recomendações são de seu interesse ele pode selecionar as disciplinas. Na possibilidade de o aluno não selecionar as recomendações, essa atitude gera uma ocorrência para o sistema de recomendação que será avaliada na próxima rodada da solicitação da matrícula. Além de avisar a Coordenação do Curso que o sistema recomendou uma disciplina para o aluno e ele não aceitou a recomendação.

A Figura 12 apresenta a sugestão da tela para integração do sistema de recomendação com o sistema Cobalto. Na tela de solicitação de matrícula seria adicionada uma guia com o título **Recomendações** onde seriam listadas todas as recomendações para o aluno.

Por fim, na linha de uso de recomendadores, uma outra possibilidade para uso do recomendador seria no momento da oferta das disciplinas por parte do coordenador do curso. Nesse momento o coordenador deve decidir quais disciplinas e quantas vagas para cada turma serão ofertadas. Com o auxílio de um recomendador, o coordenador poderia realizar a análise da situação atual do curso e receber a recomendação de quais disciplinas e quantidade de vagas necessárias para atender a demanda do curso.

The screenshot displays the COBALTO system interface for UFPEL. The header includes the COBALTO logo (SISTEMA INTEGRADO DE GESTÃO), the UFPEL logo, and user navigation options like 'Mensagens' (14), 'Perfil', and 'Sair'. A navigation menu on the left lists various services such as 'Aluno', 'Cadastros', 'Consultas', 'Biblioteca', and 'Acesso livre'. The main content area shows a breadcrumb trail: 'Compras > Contratação > Gerenciador > Ciência da Computação'. A yellow message bar at the top of the main area says 'Escolha a(s) disciplina(s) desejada(s) e clique em Salvar'. Below this, there are tabs for 'Recomendações', 'Disciplinas', and 'Grade de Horários Preliminar'. The 'Recomendações' tab is active, showing a table of course recommendations.

Lista de disciplinas			
Turma	Solicitações	Horários	Crédi
RECOMENDAÇÕES			
22000187 - COMPUTAÇÃO GRÁFICA			
<input type="checkbox"/>	T1	0 / 5	QUI (14:20-15:10) QUI (15:10-16:00)
22000189 - ENGENHARIA DE SOFTWARE I			
<input type="checkbox"/>	T1	0 / 15	QUA (14:20-15:10) QUA (15:10-16:00)
22000272 - INTROD PROCESSAMENTO PARALELO E DISTRIBUÍDO			
<input type="checkbox"/>	M1	0 / 5	SEX (15:10-16:00) SEX (16:00-16:50)
22000273 - REDES DE COMPUTADORES			
<input type="checkbox"/>	T1	0 / 5	QUA (16:00-16:50) QUA (17:10-18:00)
22000186 - COMPUTAÇÃO E SOCIEDADE			
<input type="checkbox"/>	T1	0 / 60	QUI (14:20-15:10) QUI (15:10-16:00) QUI (16:00-16:50)

Figura 12 – Proposta de integração com o sistema Cobalto.

REFERÊNCIAS

ABUARQOUB, A. et al. A Survey on Internet of Things Enabled Smart Campus Applications. **Proceedings of the International Conference on Future Networks and Distributed Systems**, New York, NY, US, v.17, 2017.

AHLGREN, B.; HIDEELL, M.; NGAI, E. C. Internet of Things for Smart Cities: Interoperability and Open Data. **IEEE Internet Computing**, New York, NY, US, v.20, n.6, p.52–56, 2016.

ALGHAMDI, A.; SHETTY, S. Survey Toward a Smart Campus Using the Internet of Things. In: IEEE 4TH INTERNATIONAL CONFERENCE ON FUTURE INTERNET OF THINGS AND CLOUD (FICLOUD), 2016., 2016. **Anais...** IEEE, 2016. p.235–239.

ALVAREZ-CAMPANA, M. et al. Smart CEI Moncloa: An IoT-based Platform for People Flow and Environmental Monitoring on a Smart University Campus. **Sensors**, Basel, Switzerland, v.17, n.12, p.2856, dec 2017.

BALABANOVIĆ, M.; SHOHAM, Y. Fab: content-based, collaborative recommendation. **Communications of the ACM**, New York, NY, US, v.40, n.3, p.66–72, mar 1997.

BATES, O.; FRIDAY, A. Beyond Data in the Smart City: Repurposing Existing Campus IoT. **IEEE Pervasive Computing**, New York, NY, US, v.16, n.2, p.54–60, apr 2017.

BURKE, R. Hybrid Recommender Systems: Survey and Experiments. **User Modeling and User-Adapted Interaction 2002 12:4**, New York, NY, US, v.12, p.331–370, 2002.

BYDŽOVSKÁ, H. Course enrollment recommender system. **Proceedings of the 9th International Conference on Educational Data Mining, EDM 2016**, Raleigh, NC, USA, n.x, p.312–317, 2016.

CAȚĂ, M. Smart university, a new concept in the Internet of Things. **2015 14th RoEdu-Net International Conference - Networking in Education and Research, RoEduNet NER 2015 - Proceedings**, Craiova, Romania, p.195–197, 2015.

CHOU, T.-L.; CHANLIN, L.-J. Augmented Reality Smartphone Environment Orientation Application: A Case Study of the Fu-Jen University Mobile Campus Touring System. **Procedia - Social and Behavioral Sciences**, Barcelona, Spain, v.46, p.410–416, 2012.

De Pietro, G.; GALLO, L.; HOWLETT, R. J.; JAIN, L. C. (Ed.). **Intelligent Interactive Multimedia Systems and Services 2017**. Cham: Springer International Publishing, 2018. (Smart Innovation, Systems and Technologies, v.76).

DIXIT, S. K.; KULKARNI, S. M. Smart Campus System using IoT. **International Journal of Advance Research in Science and Engineering**, India, v.6, n.8, p.1658–1665, 2017.

FERNANDEZ-GARCIA, A. J. et al. Creating a Recommender System to Support Higher Education Students in the Subject Enrollment Decision. **IEEE Access**, New York, NY, US, v.8, p.189069–189088, 2020.

FERNÁNDEZ-CARAMÉS, T. M.; FRAGA-LAMAS, P. Towards Next Generation Teaching, Learning, and Context-Aware Applications for Higher Education: A Review on Blockchain, IoT, Fog and Edge Computing Enabled Smart Campuses and Universities. **Applied Sciences 2019, Vol. 9, Page 4479**, Basel, Switzerland, v.9, p.4479, 10 2019.

GAGLIO, S.; Lo Re, G.; MORANA, M.; RUOCCO, C. Smart assistance for students and people living in a campus. In: IEEE INTERNATIONAL CONFERENCE ON SMART COMPUTING, SMARTCOMP 2019, 2019., 2019. **Proceedings...** Institute of Electrical and Electronics Engineers Inc., 2019. p.132–137.

GAHLAUT, S. IoT based smart campus. In: INTERNATIONAL CONFERENCE ON INNOVATIONS IN CONTROL, COMMUNICATION AND INFORMATION SYSTEMS (ICICCI), 2017. **Proceedings...** IEEE, 2017. p.1–4.

GEORGE, T.; MERUGU, S. A Scalable Collaborative Filtering Framework Based on Co-Clustering. In: FIFTH IEEE INTERNATIONAL CONFERENCE ON DATA MINING (ICDM'05), 2005. **Proceedings...** IEEE, 2005. p.625–628.

HUG, N. **Co-clustering – Surprise 1 documentation**. (Accessed on 09/20/2021), https://surprise.readthedocs.io/en/stable/co_clustering.html.

HUG, N. Surprise: A Python library for recommender systems. **Journal of Open Source Software**, New York, NY, US, v.5, n.52, p.2174, aug 2020.

HUG, N. **Surprise – A Python scikit for recommender systems**. (Accessed on 09/20/2021), <http://surpriselib.com/>.

KANE, S. N.; MISHRA, A.; DUTTA, A. K. International Conference on Recent Trends in Physics 2016 (ICRTP2016). **Journal of Physics: Conference Series**, Bristol, United Kingdom, v.755, p.011001, Oct. 2016.

KOREN, Y. Factor in the Neighbors: Scalable and Accurate Collaborative Filtering. **ACM Trans. Knowl. Discov. Data**, New York, NY, US, v.4, n.1, Jan. 2010.

KOREN, Y.; BELL, R.; VOLINSKY, C. Matrix factorization techniques for recommender systems. **Computer**, New York, NY, US, v.42, p.30–37, 8 2009.

LANDAHL, G. **Smart & Connected Campus**. Stockholm, Sweden: Stockholm Stads, 2017. 16p. Disponível em: <<http://international.stockholm.se/globalassets/ovriga-bilder-och-filer/smart-city/brochure-smart-and-connected.pdf>>. Acesso em: 2021-07-15.

LEE, D.; SEUNG, H. S. Algorithms for Non-negative Matrix Factorization. In: **ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS**, 2001. **Anais...** MIT Press, 2001. v.13.

LEMIRE, D.; MACLACHLAN, A. Slope one predictors for online rating-based collaborative filtering. **Proceedings**, Newport Beach, CA, US, p.471–475, 2005.

LIN, J.; PU, H.; LI, Y.; LIAN, J. Intelligent Recommendation System for Course Selection in Smart Education. **Procedia Computer Science**, Mapo-gu, Seoul, KR, v.129, p.449–453, 2018.

LUO, X.; ZHOU, M.; XIA, Y.; ZHU, Q. An efficient non-negative matrix-factorization-based approach to collaborative filtering for recommender systems. **IEEE Transactions on Industrial Informatics**, New York, NY, US, v.10, p.1273–1284, 5 2014.

MAPHOSA, M.; DOORSAMY, W.; PAUL, B. A Review of Recommender Systems for Choosing Elective Courses. **International Journal of Advanced Computer Science and Applications**, West Yorkshire, UK, v.11, n.9, p.287–295, 2020.

MARR, B. **The 10 Best Examples Of How AI Is Already Used In Our Everyday Life**. Disponível em: <<https://www.forbes.com/sites/bernardmarr/2019/12/16/the-10-best-examples-of-how-ai-is-already-used-in-our-everyday-life/>>. Acesso em: 2021-07-12.

NEELAKANTAN, S. **Successful AI Examples in Higher Education That Can Inspire Our Future | EdTech Magazine**. Disponível em: <<https://edtechmagazine.com/higher/article/2020/01/successful-ai-examples-higher-education-can-inspire-our-future>>. Acesso em: 2021-07-12.

O'MAHONY, M. P.; SMYTH, B. A recommender system for on-line course enrolment: an initial study. In: ACM CONFERENCE ON RECOMMENDER SYSTEMS - RECSYS '07, 2007., 2007, New York, NY, US. **Proceedings...** ACM Press, 2007. n.January, p.133.

POLATIDIS, N.; GEORGIADIS, C. K. Recommender Systems. **International Journal of E-Entrepreneurship and Innovation**, Thessaloniki, Greece, v.4, n.4, p.32–46, oct 2013.

RAO, M. et al. An IoT Based Smart Campus System. **International Journal of Scientific & Engineering Research**, India, v.9, n.4, p.146–151, 2018.

RESNICKPAUL; R., V. Recommender systems. **Communications of the ACM**, New York, NY, US, v.40, p.56–58, 3 1997.

RICCI, F.; ROKACH, L.; SHAPIRA, B.; KANTOR, P. B. (Ed.). **Recommender Systems Handbook**. Boston, MA: Springer US, 2011.

SALAKHUTDINOV, R.; MNIH, A. Probabilistic Matrix Factorization. In: INTERNATIONAL CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS, 20., 2007, Red Hook, NY, USA. **Proceedings...** Curran Associates Inc., 2007. p.1257–1264. (NIPS'07).

SAMPAIO, C. E. M. et al. **CENSO DA EDUCAÇÃO SUPERIOR 2018**. Brasília, DF, Brazil: Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira, 2019.

SARNOBAT, A.; KALOLA, D. A Survey on Recommender Systems. **International Journal of Scientific and Research Publications (IJSRP)**, India, v.9, p.p9356, 9 2019.

SciPy Developers. **SciKits – SciPy.org**. (Accessed on 09/20/2021), <https://www.scipy.org/scikits.html>.

SHAH, D.; SHAH, P.; BANERJEE, A. Similarity based regularization for online matrix-factorization problem: An application to course recommender systems. In: TENCON 2017 - 2017 IEEE REGION 10 CONFERENCE, 2017, New York, NY, US. **Anais...** IEEE, 2017. v.2017-Decem, p.1874–1879.

SHARMA, K.; SURYAKANTHI, T. Smart System: IoT for University. In: INTERNATIONAL CONFERENCE ON GREEN COMPUTING AND INTERNET OF THINGS (ICG-CIOT), 2015., 2015. **Anais...** IEEE, 2015. p.1586–1593.

SILVA, F. M. da; LENZ, M. L.; FREITAS, P. H. C.; SANTOS, S. C. B. dos. **Inteligência artificial**. Brazil: Grupo A, 2019. 223–224p.

STONE, A. **AI and Smart Campuses Are Among Higher Ed Tech to Watch in 2020 | EdTech Magazine**. Disponível em: <<https://edtechmagazine.com/higher/article/2019/12/ai-and-smart-campus-are-among-higher-ed-tech-watch-2020-1>>. Acesso em: 2021-07-12.

SULTAN, M. N. Smart Campus Using IoT with Bangladesh Perspective: A Possibility and Limitation. **International Journal for Research in Applied Science and Engineering Technology**, Dinajpur, Bangladesh, v.V, n.VIII, p.1681–1690, aug 2017.

SUN, G.; ZHOU, Y.; LI, J. Build Smart Campus Using Human Behavioral Data. In: INTL IEEE CONFERENCES ON UBIQUITOUS INTELLIGENCE & COMPUTING, ADVANCED AND TRUSTED COMPUTING, SCALABLE COMPUTING AND COMMUNICATIONS, CLOUD AND BIG DATA COMPUTING, INTERNET OF PEOPLE, AND SMART WORLD CONGRESS (UIC/ATC/SCALCOM/CBDCOM/IOP/SMARTWORLD), 1., 2017. **Proceedings...** IEEE, 2017. p.133–136.

SUN, Y.; ZHANG, Y. Conversational recommender system. In: INTERNATIONAL ACM SIGIR CONFERENCE ON RESEARCH AND DEVELOPMENT IN INFORMATION RETRIEVAL, SIGIR 2018, 41., 2018. **Anais...** ACM, 2018. p.235–244.

TORRES-SOSPEDRA, J. et al. Enhancing integrated indoor/outdoor mobility in a smart campus. **International Journal of Geographical Information Science**, London, UK, v.29, n.11, p.1955–1968, nov 2015.

UFPEL. **Regulamento do Ensino de Graduação na UFPel**. (Accessed on 09/20/2021), https://wp.ufpel.edu.br/pre/files/2018/10/SEI_Resolucao-29.2018-Regulamento-Ensino-de-Graduacao-I.pdf.

USLU, S.; OZTURAN, C.; USLU, M. F. Course scheduler and recommendation system for students. In: IEEE 10TH INTERNATIONAL CONFERENCE ON APPLICATION OF INFORMATION AND COMMUNICATION TECHNOLOGIES (AICT), 2016., 2016, Baku, Azerbaijan. **Anais...** IEEE, 2016. p.1–6.

VIALARDI, C. et al. A data mining approach to guide students through the enrollment process based on academic performance. **User Modeling and User-Adapted Interaction**, New York, NY, US, v.21, n.1-2, p.217–248, apr 2011.

VILLEGAS-CH, W.; ARIAS-NAVARRETE, A.; PALACIOS-PACHECO, X. Proposal of an Architecture for the Integration of a Chatbot with Artificial Intelligence in a Smart Campus for the Improvement of Learning. **Sustainability**, Basel, Switzerland, v.12, n.4, p.1500, feb 2020.

VUONG, T.-H.-Y. et al. A Personalized Course Recommender System for Undergraduate Students. **International Journal of Learning and Teaching**, United States, v.5, n.3, p.181–190, 2019.

WARWICK, K. **Artificial Intelligence: The Basics**. New York, NY, US: Routledge, 2011. 1–184p.

YU, Z. et al. Towards a smart campus with mobile social networking. **Proceedings - 2011 IEEE International Conferences on Internet of Things and Cyber, Physical and Social Computing, iThings/CPSCoM 2011**, New York, NY, US, p.162–169, 2011.

ZHAMANOV, A.; SAKHIYEVA, Z.; SULIYEV, R.; KALDYKULOVA, Z. IoT smart campus review and implementation of IoT applications into education process of university. In: INTERNATIONAL CONFERENCE ON ELECTRONICS, COMPUTER AND COMPUTATION (ICECCO), 2017., 2017. **Anais...** IEEE, 2017. v.2018-Janua, p.1–4.

ZHANG, S.; WANG, W.; FORD, J.; MAKEDON, F. Learning from incomplete ratings using non-negative matrix factorization. **Proceedings**, Philadelphia, PA, US, v.2006, p.549–553, 2006.

Apêndices

APÊNDICE A – Grade Curricular do Curso de Ciência da Computação (versão 9)

Tabela 23 – Grade Curricular do Curso de Ciência da Computação (versão 9)

Cód. Atividade	Nome	Creditos	Carga Horária	Pré-requisito
1º Semestre - DISCIPLINAS OBRIGATORIAS				
22000196	INTRODUÇÃO A CIÊNCIA DA COMPUTAÇÃO	4	60	
22000207	LABORATÓRIO DE COMPUTAÇÃO	2	30	
22000224	LÓGICA PARA COMPUTAÇÃO	4	60	
22000293	SISTEMAS DISCRETOS	4	60	
22000294	ALGORITMOS E PROGRAMAÇÃO	4	60	
2º Semestre - DISCIPLINAS OBRIGATORIAS				
11100058	CÁLCULO 1	4	60	
22000199	METODOLOGIA CIENTÍFICA PARA COMPUTAÇÃO	4	60	
22000211	TÉCNICAS DIGITAIS	4	60	22000196
22000295	ANÁLISE COMBINATÓRIA E TEORIA DOS GRAFOS	4	60	
22000296	PROGRAMAÇÃO DE COMPUTADORES	4	60	22000294
3º Semestre - DISCIPLINAS OBRIGATORIAS				
6560017	SOCIOLOGIA	2	30	
11100059	CÁLCULO 2	4	60	11100058
22000181	ARQUITETURA E ORGANIZAÇÃO DE COMPUTADORES I	4	60	22000211
22000197	LINGUAGENS FORMAIS	4	60	22000293
22000201	PROGRAMAÇÃO ORIENTADA A OBJETOS	4	60	22000296
22000297	ALGORITMOS E ESTRUTURAS DE DADOS I	4	60	22000296
4º Semestre - DISCIPLINAS OBRIGATORIAS				
6730016	EPISTEMOLOGIA	2	30	
11100005	ÁLGEBRA LINEAR E GEOMETRIA ANALÍTICA	6	90	
22000182	ARQUITETURA E ORGANIZAÇÃO DE COMPUTADORES II	4	60	22000181
22000205	TEORIA DA COMPUTAÇÃO	4	60	22000197
22000298	ESTATÍSTICA BÁSICA PARA COMPUTAÇÃO	4	60	11100059
22000299	ALGORITMOS E ESTRUTURAS DE DADOS II	4	60	22000297
5º Semestre - DISCIPLINAS OBRIGATORIAS				
22000188	CONCEITOS DE LINGUAGENS DE PROGRAMAÇÃO	4	60	22000201
22000237	PROGRAMAÇÃO DE SISTEMAS	4	60	22000181, 220003
22000270	SISTEMAS OPERACIONAIS	4	60	22000182, 220003
22000300	ALGORITMOS E ESTRUTURAS DE DADOS III	4	60	22000299
22000301	FUNDAMENTOS DE INTELIGÊNCIA ARTIFICIAL	4	60	
22000302	PROJETO DE BANCO DE DADOS	4	60	
6º Semestre - DISCIPLINAS OBRIGATORIAS				
22000187	COMPUTAÇÃO GRÁFICA	4	60	11100005, 220003
22000189	ENGENHARIA DE SOFTWARE I	4	60	22000201
22000203	SEMÂNTICA FORMAL	4	60	22000197, 2200019
22000268	CÁLCULO NUMÉRICO COMPUTACIONAL	4	60	22000296, 11100006
22000273	REDES DE COMPUTADORES	4	60	22000270
7º Semestre - DISCIPLINAS OBRIGATORIAS				
22000174	ENGENHARIA DE SOFTWARE II	4	60	22000189
22000272	INTROD PROCESSAMENTO PARALELO E DISTRIBUÍDO	4	60	22000270
22000303	PROJETO DE COMPILADORES	4	60	22000197
22000304	DESENVOLVIMENTO DE SOFTWARES	4	60	22000201
22000305	TRABALHO DE CONCLUSÃO DE CURSO I	8	120	22000199
8º Semestre - DISCIPLINAS OBRIGATORIAS				
22000186	COMPUTAÇÃO E SOCIEDADE	4	60	
22000255	PROCESSAMENTO DIGITAL DE IMAGENS	4	60	
22000306	TRABALHO DE CONCLUSÃO DE CURSO II	8	120	22000305
ATIVIDADES COMPLEMENTARES				
22000175	ATIVIDADES COMPLEMENTARES	320	320	
DISCIPLINAS OPTATIVAS				
11100060	CÁLCULO 3	6	90	
20000084	LÍNGUA BRASILEIRA DE SINAIS I (LIBRAS I)	4	60	
22000176	INFORMÁTICA INDUSTRIAL	4	60	
22000193	GERÊNCIA DE PROJETOS	4	60	
22000210	PROJETOS EM COMPUTAÇÃO IV	4	60	
22000227	TÓPICOS ESPECIAIS EM COMPUTAÇÃO II	4	60	
22000228	TÓPICOS ESPECIAIS EM COMPUTAÇÃO III	2	30	
22000229	TÓPICOS ESPECIAIS EM COMPUTAÇÃO IV	4	60	
22000231	SISTEMAS EMBARCADOS	4	60	
22000240	CONCEPÇÃO DE CIRCUITOS INTEGRADOS	4	60	
22000241	INTERAÇÃO HUMANO-COMPUTADOR	4	60	
22000242	TÓPICOS ESPECIAIS EM COMPUTAÇÃO I	2	30	
22000253	SISTEMAS DE INFORMAÇÃO	4	60	
22000254	PROJETOS EM COMPUTAÇÃO II	4	60	
22000264	PROJETOS EM COMPUTAÇÃO III	4	60	
22000269	SISTEMAS DIGITAIS AVANÇADOS	4	60	
22000278	FERRAMENTAS DE CAD	4	60	
22000279	MICROCONTROLADORES	4	60	
22000282	ROBÓTICA	4	60	
22000283	SISTEMAS DE TEMPO REAL	4	60	
22000307	BANCO DE DADOS AVANÇADO	4	60	
22000308	ARQUITETURA E ORGANIZAÇÃO COMPUT. AVANÇADOS	4	60	
22000309	COMUNICAÇÃO DE DADOS	4	60	
22000310	AVALIAÇÃO DE DESEMPENHO DE SISTEMAS	4	60	
22000311	SEGURANÇA DE COMPUTADORES	4	60	
22000312	INTELIGÊNCIA ARTIFICIAL AVANÇADA	4	60	
22000313	COMPILADORES AVANÇADO	4	60	
22000314	FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL	4	60	
22000315	COMPUTAÇÃO FLEXÍVEL	4	60	
22000316	WEB SEMÂNTICA E ONTOLOGIAS	4	60	
22000317	ESPECIFICAÇÃO E VERIFICAÇÃO DE SISTEMAS	4	60	
22000318	SISTEMAS DISTRIBUÍDOS E UBIQUOS	4	60	
22000319	PROJETOS EM COMPUTAÇÃO I	4	60	
22000346	TÓPICOS ESPECIAIS EM COMPUTAÇÃO V	2	30	
22000347	TÓPICOS ESPECIAIS EM COMPUTAÇÃO VI	2	30	
22000348	TÓPICOS ESPECIAIS EM COMPUTAÇÃO VII	4	60	
22000349	TÓPICOS ESPECIAIS EM COMPUTAÇÃO VIII	4	60	
22000350	TÓPICOS ESPECIAIS EM COMPUTAÇÃO IX	4	60	
22000351	TÓPICOS ESPECIAIS EM COMPUTAÇÃO X	4	60	

APÊNDICE B – Distância Contextual dos Alunos do Curso de Ciência da Computação - referência semestre 2019/2

Tabela 24 – Distância Contextual dos Alunos do Curso de Ciência da Computação Com Matrícula em 2019/2

Matrícula	Distância Contextual	Semestres no Curso	Ingresso
1	2	1	2019/2
2	-7,32	1	2019/2
3	-4,88	1	2019/2
4	-4,88	1	2019/2
5	12,2	1	2019/2
6	34,15	1	2019/2
7	36,59	1	2019/2
8	51,22	1	2019/2
9	70,73	1	2019/2
10	0	1	2019/2
11	-12,2	1	2019/2
12	-2,44	1	2019/2
13	0	1	2019/2
14	-12,2	1	2019/2
15	-9,76	1	2019/2
16	-7,32	1	2019/2
17	-4,88	1	2019/2
18	-9,76	1	2019/2
19	-12,2	1	2019/2
20	0	1	2019/2
21	7,32	1	2019/2
22	-12,2	1	2019/2
23	0	1	2019/2
24	-12,2	1	2019/2
25	0	1	2019/2
26	0	1	2019/2
27	-4,88	1	2019/2

Continua na próxima página

Tabela 24 – continuação da página anterior

Matrícula	Distância contextual	Semestres no curso	Ingresso
28	-4,88	1	2019/2
29	-9,76	1	2019/2
30	-2,44	1	2019/2
31	-12,2	1	2019/2
32	0	1	2019/2
33	0	1	2019/2
34	0	1	2019/2
35	-9,76	1	2019/2
36	0	1	2019/2
37	-4,88	1	2019/2
38	-7,32	1	2019/2
39	-12,2	1	2019/2
40	-12,2	1	2019/2
41	0	1	2019/2
42	-2,44	1	2019/2
43	0	1	2019/2
44	2,44	1	2019/2
45	-2,44	1	2019/2
46	-12,2	1	2019/2
47	-2,44	1	2019/2
48	0	1	2019/2
49	-2,44	1	2019/2
50	-2,44	1	2019/2
51	-4,88	1	2019/2
52	-7,32	1	2019/2
53	0	1	2019/2
54	0	1	2019/2
55	-4,88	1	2019/2
56	-21,95	2	2019/1
57	-12,2	2	2019/1
58	-7,32	2	2019/1
59	0	2	2019/1
60	-2,44	2	2019/1
61	73,17	2	2019/1
62	0	2	2019/1
63	-24,39	2	2019/1

Continua na próxima página

Tabela 24 – continuação da página anterior

Matrícula	Distância contextual	Semestres no curso	Ingresso
64	-9,76	2	2019/1
65	4,88	2	2019/1
66	-4,88	2	2019/1
67	-24,39	2	2019/1
68	-4,88	2	2019/1
69	-4,88	2	2019/1
70	-21,95	2	2019/1
71	0	2	2019/1
72	0	2	2019/1
73	-2,44	2	2019/1
74	-2,44	2	2019/1
75	0	2	2019/1
76	-2,44	2	2019/1
77	0	2	2019/1
78	0	2	2019/1
79	0	2	2019/1
80	-12,2	2	2019/1
81	0	2	2019/1
82	-2,44	2	2019/1
83	0	2	2019/1
84	-19,51	2	2019/1
85	0	2	2019/1
86	0	2	2019/1
87	-14,63	2	2019/1
88	0	2	2019/1
89	-12,2	2	2019/1
90	0	2	2019/1
91	0	2	2019/1
92	-26,83	3	2018/2
93	-4,88	3	2018/2
94	-17,07	3	2018/2
95	60,98	3	2018/2
96	-4,88	3	2018/2
97	12,2	3	2018/2
98	-24,39	3	2018/2
99	-4,88	3	2018/2

Continua na próxima página

Tabela 24 – continuação da página anterior

Matrícula	Distância contextual	Semestres no curso	Ingresso
100	-29,27	3	2018/2
101	-19,51	3	2018/2
102	-9,76	3	2018/2
103	-4,88	3	2018/2
104	-17,07	3	2018/2
105	-17,07	3	2018/2
106	-21,95	3	2018/2
107	-19,51	3	2018/2
108	-29,27	3	2018/2
109	-14,63	3	2018/2
110	-2,44	3	2018/2
111	-9,76	3	2018/2
112	-34,15	3	2018/2
113	-12,2	3	2018/2
114	-7,32	3	2018/2
115	-24,39	3	2018/2
116	26,83	3	2018/2
117	-7,32	3	2018/2
118	-2,44	3	2018/2
119	-26,83	3	2018/2
120	-26,83	3	2018/2
121	-4,88	3	2018/2
122	-31,71	3	2018/2
123	-24,39	3	2018/2
124	4,88	3	2018/2
125	-2,44	3	2018/2
126	-39,02	3	2018/2
127	-26,83	3	2018/2
128	-29,27	3	2018/2
129	0	3	2018/2
130	-9,76	3	2018/2
131	-2,44	3	2018/2
132	-36,59	3	2018/2
133	-34,15	3	2018/2
134	-7,32	3	2018/2
135	-7,32	3	2018/2

Continua na próxima página

Tabela 24 – continuação da página anterior

Matrícula	Distância contextual	Semestres no curso	Ingresso
136	2,44	3	2018/2
137	-14,63	4	2018/1
138	-14,63	4	2018/1
139	-31,71	4	2018/1
140	-39,02	4	2018/1
141	0	4	2018/1
142	-12,2	4	2018/1
143	-2,44	4	2018/1
144	-2,44	4	2018/1
145	-34,15	4	2018/1
146	-7,32	4	2018/1
147	-24,39	4	2018/1
148	-34,15	4	2018/1
149	-12,2	4	2018/1
150	-34,15	4	2018/1
151	-4,88	4	2018/1
152	0	4	2018/1
153	-12,2	4	2018/1
154	0	4	2018/1
155	2,44	4	2018/1
156	-2,44	4	2018/1
157	-21,95	4	2018/1
158	0	4	2018/1
159	-9,76	4	2018/1
160	-9,76	4	2018/1
161	-21,95	4	2018/1
162	-9,76	4	2018/1
163	0	4	2018/1
164	0	4	2018/1
165	-7,32	4	2018/1
166	0	4	2018/1
167	0	4	2018/1
168	0	5	2017/2
169	-21,95	5	2017/2
170	-34,15	5	2017/2
171	-41,46	5	2017/2

Continua na próxima página

Tabela 24 – continuação da página anterior

Matrícula	Distância contextual	Semestres no curso	Ingresso
172	-43,9	5	2017/2
173	-24,39	5	2017/2
174	-12,2	5	2017/2
175	-31,71	5	2017/2
176	-7,32	5	2017/2
177	-29,27	5	2017/2
178	-36,59	5	2017/2
179	-12,2	5	2017/2
180	-14,63	5	2017/2
181	-36,59	5	2017/2
182	-26,83	5	2017/2
183	-31,71	5	2017/2
184	-60,98	5	2017/2
185	-46,34	5	2017/2
186	-29,27	5	2017/2
187	-21,95	5	2017/2
188	-24,39	5	2017/2
189	-19,51	5	2017/2
190	-41,46	5	2017/2
191	-19,51	5	2017/2
192	-51,22	5	2017/2
193	-19,51	5	2017/2
194	-7,32	5	2017/2
195	0	5	2017/2
196	-39,02	6	2017/1
197	-48,78	6	2017/1
198	-46,34	6	2017/1
199	-36,59	6	2017/1
200	-17,07	6	2017/1
201	-51,22	6	2017/1
202	-53,66	6	2017/1
203	-60,98	6	2017/1
204	-19,51	6	2017/1
205	-12,2	6	2017/1
206	-2,44	6	2017/1
207	-29,27	6	2017/1

Continua na próxima página

Tabela 24 – continuação da página anterior

Matrícula	Distância contextual	Semestres no curso	Ingresso
208	-7,32	6	2017/1
209	-2,44	6	2017/1
210	2,44	6	2017/1
211	-46,34	6	2017/1
212	-26,83	6	2017/1
213	-14,63	6	2017/1
214	-24,39	6	2017/1
215	-48,78	6	2017/1
216	-46,34	6	2017/1
217	-21,95	6	2017/1
218	-51,22	6	2017/1
219	2,44	6	2017/1
220	-4,88	6	2017/1
221	-43,9	6	2017/1
222	0	6	2017/1
223	-19,51	6	2017/1
224	-21,95	7	2016/2
225	-36,59	7	2016/2
226	-14,63	7	2016/2
227	-21,95	7	2016/2
228	-58,54	7	2016/2
229	-31,71	7	2016/2
230	-92,68	7	2016/2
231	-65,85	7	2016/2
232	-68,29	7	2016/2
233	-24,39	7	2016/2
234	-24,39	7	2016/2
235	-73,17	7	2016/2
236	-43,9	7	2016/2
237	-19,51	7	2016/2
238	-4,88	7	2016/2
239	-58,54	7	2016/2
240	-12,2	7	2016/2
241	-48,78	7	2016/2
242	-7,32	7	2016/2
243	-68,29	7	2016/2

Continua na próxima página

Tabela 24 – continuação da página anterior

Matrícula	Distância contextual	Semestres no curso	Ingresso
244	-73,17	7	2016/2
245	-39,02	8	2016/1
246	-43,9	8	2016/1
247	-60,98	8	2016/1
248	-7,32	8	2016/1
249	-82,93	8	2016/1
250	0	8	2016/1
251	-78,05	8	2016/1
252	-87,8	8	2016/1
253	0	8	2016/1
254	0	8	2016/1
255	-21,95	8	2016/1
256	-51,22	8	2016/1
257	-34,15	8	2016/1
258	-36,59	8	2016/1
259	0	8	2016/1
260	-12,2	8	2016/1
261	-9,76	8	2016/1
262	-31,71	8	2016/1
263	-75,61	8	2016/1
264	-68,29	8	2016/1
265	-80,49	9	2015/2
266	-19,51	9	2015/2
267	-48,78	9	2015/2
268	0	9	2015/2
269	-2,44	9	2015/2
270	-65,85	9	2015/2
271	0	9	2015/2
272	-60,98	9	2015/2
273	-60,98	9	2015/2
274	-31,71	9	2015/2
275	-2,44	9	2015/2
276	-7,32	9	2015/2
277	-63,41	9	2015/2
278	-63,41	9	2015/2
279	-34,15	9	2015/2

Continua na próxima página

Tabela 24 – continuação da página anterior

Matrícula	Distância contextual	Semestres no curso	Ingresso
280	-70,73	9	2015/2
281	-24,39	9	2015/2
282	-63,41	9	2015/2
283	-90,24	9	2015/2
284	-9,76	9	2015/2
285	-51,22	9	2015/2
286	-82,93	9	2015/2
287	-65,85	9	2015/2
288	-68,29	10	2015/1
289	-87,8	10	2015/1
290	-58,54	10	2015/1
291	-2,44	10	2015/1
292	-2,44	10	2015/1
293	0	10	2015/1
294	-51,22	10	2015/1
295	-26,83	10	2015/1
296	0	10	2015/1
297	-51,22	10	2015/1
298	-39,02	10	2015/1
299	-4,88	10	2015/1
300	-21,95	10	2015/1
301	-14,63	10	2015/1
302	0	11	2014/2
303	-19,51	11	2014/2
304	-51,22	11	2014/2
305	-51,22	11	2014/2
306	-9,76	11	2014/2
307	-7,32	11	2014/2
308	-7,32	11	2014/2
309	-2,44	11	2014/2
310	-24,39	11	2014/2
311	-56,1	11	2014/2
312	0	11	2014/2
313	-78,05	11	2014/2
314	-58,54	11	2014/2
315	-80,49	11	2014/2

Continua na próxima página

Tabela 24 – continuação da página anterior

Matrícula	Distância contextual	Semestres no curso	Ingresso
316	-65,85	11	2014/2
317	-46,34	11	2014/2
318	0	12	2014/1
319	-53,66	12	2014/1
320	-48,78	12	2014/1
321	-7,32	12	2014/1
322	-31,71	12	2014/1
323	-2,44	12	2014/1
324	-14,63	12	2014/1
325	-36,59	12	2014/1
326	-63,41	12	2014/1
327	-4,88	12	2014/1
328	0	12	2014/1
329	-4,88	12	2014/1
330	-60,98	13	2013/2
331	-73,17	13	2013/2
332	-43,9	13	2013/2
333	-17,07	13	2013/2
334	-4,88	13	2013/2
335	-2,44	13	2013/2
336	-2,44	13	2013/2
337	-17,07	13	2013/2
338	-7,32	13	2013/2
339	-51,22	13	2013/2
340	-53,66	14	2013/1
341	-9,76	14	2013/1
342	-17,07	14	2013/1
343	-2,44	14	2013/1
344	-4,88	14	2013/1
345	-41,46	14	2013/1
346	-60,98	15	2012/2
347	-12,2	15	2012/2
348	-56,1	15	2012/2
349	-34,15	15	2012/2
350	-4,88	15	2012/2
351	-21,95	15	2012/2

Continua na próxima página

Tabela 24 – continuação da página anterior

Matrícula	Distância contextual	Semestres no curso	Ingresso
352	-58,54	15	2012/2
353	-4,88	16	2012/1
354	-12,2	16	2012/1
355	0	16	2012/1
356	-2,44	16	2012/1
357	-2,44	16	2012/1
358	-34,15	16	2012/1
359	-46,34	17	2011/2
360	0	17	2011/2
361	0	17	2011/2
362	-43,9	17	2011/2
363	0	18	2011/1
364	-36,59	18	2011/1
365	0	18	2011/1
366	-56,1	19	2010/2
367	-19,51	19	2010/2
368	0	19	2010/2
369	0	19	2010/2
370	-2,44	20	2010/1
371	-14,63	20	2010/1
372	-7,32	21	2009/2
373	0	22	2009/1