

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
INSTITUTO DE CIÊNCIAS EXATAS
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

Sistema de Recomendação de Licenças de Software

Andressa Augusta Ferrugini de Oliveira

JUIZ DE FORA
JULHO, 2024

Sistema de Recomendação de Licenças de Software

ANDRESSA AUGUSTA FERRUGINI DE OLIVEIRA

Universidade Federal de Juiz de Fora

Instituto de Ciências Exatas

Departamento de Ciência da Computação

Bacharelado em Ciência da Computação

Orientador: Victor Ströele de Andrade Menezes

JUIZ DE FORA

JULHO, 2024

SISTEMA DE RECOMENDAÇÃO DE LICENÇAS DE SOFTWARE

Andressa Augusta Ferrugini de Oliveira

MONOGRAFIA SUBMETIDA AO CORPO DOCENTE DO INSTITUTO DE CIÊNCIAS EXATAS DA UNIVERSIDADE FEDERAL DE JUIZ DE FORA, COMO PARTE INTEGRANTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE BACHAREL EM CIÊNCIA DA COMPUTAÇÃO.

Aprovada por:

Victor Ströele de Andrade Menezes
Doutor em Engenharia de Sistemas e Computação (COPPE/UFRJ)

Regina Maria Maciel Braga Villela
Doutora em Engenharia de Sistemas e Computação (COPPE/UFRJ)

Pedro Henrique Dias Valle
Doutor em Ciências da Computação e Matemática Computacional (USP)

JUIZ DE FORA
10 DE JULHO, 2024

Resumo

A crescente dependência da tecnologia resultou em um aumento significativo na quantidade de dados gerados diariamente, tornando os sistemas de recomendação essenciais para ajudar os usuários a filtrar informações relevantes. No contexto organizacional, o licenciamento de software frequentemente se mostra um processo ineficiente e dispendioso, levando ao desperdício de recursos financeiros.

Este trabalho propõe então o desenvolvimento de um Sistema de Recomendação de Licenças de Software, que utiliza dados de uso e informações sobre licenças existentes para reduzir custos e garantir conformidade.

Focado nas licenças do Microsoft 365, o sistema aplica programação linear para otimizar a recomendação de licenças com base nas necessidades e comportamentos dos usuários. Essa abordagem permite selecionar os planos mais adequados, considerando as funcionalidades utilizadas e o custo associado. Além disso, a transparência no processo de otimização proporciona uma visão clara das decisões tomadas, facilitando a alocação de recursos e contribuindo para a economia com licenças de software.

Palavras-chave: Sistema de Recomendação, Licenciamento de Software, Microsoft 365, Programação Linear, Problemas de Otimização, Otimização de Gastos, Conformidade de Licenças, Inteligência de negócios.

Abstract

The growing dependence on technology has led to a significant increase in the amount of data generated daily, making recommendation systems essential for helping users filter relevant information. In the organizational context, software licensing often proves to be an inefficient and costly process, resulting in wasted financial resources.

This work proposes the development of a Software License Recommendation System that utilizes usage data and information about existing licenses to reduce costs and ensure compliance.

Focusing on Microsoft 365 licenses, the system employs linear programming to optimize license recommendations based on users' needs and behaviors. This approach allows for the selection of the most suitable plans, considering the functionalities used and the associated costs. Furthermore, the transparency in the optimization process provides a clear view of the decisions made, facilitating resource allocation and contributing to cost savings in software licensing.

Keywords: Recommendation System, Software Licensing, Microsoft 365, Linear Programming, Optimization Problems, Cost Optimization, License Compliance, Business Intelligence.

Agradecimentos

O desenvolvimento deste trabalho de conclusão de curso contou com a ajuda de diversas pessoas, às quais agradeço:

Ao meu orientador, professor Victor, que me acompanhou ao longo de meses com imensa empatia, oferecendo todo o apoio e auxílio necessários para a elaboração deste projeto. Sua paciência e compreensão foram inestimáveis, especialmente durante os momentos em que enfrentei problemas pessoais. Sou profundamente grata por todo o suporte que ele me proporcionou nessa trajetória.

Aos meus professores de curso, cuja dedicação e ensinamentos tornaram possível a conclusão deste trabalho. Agradeço por cada lição, orientação e inspiração ao longo dessa jornada acadêmica.

Aos meus colegas de curso, que compartilharam essa jornada acadêmica comigo, meu sincero agradecimento. Juntos enfrentamos desafios, celebramos conquistas e construímos memórias inesquecíveis. A colaboração, a troca de ideias e o apoio mútuo foram fundamentais para o sucesso dessa trajetória. Sou grata por cada momento e por toda a amizade e parceria ao longo desses anos.

Aos meus pais e à minha família, minha eterna gratidão. Obrigada pelo amor incondicional, pelo apoio inabalável e por acreditarem em mim em todos os momentos. Suas palavras de encorajamento e sua presença constante foram essenciais para que eu pudesse superar os desafios e alcançar este sonho. Este trabalho é tanto meu quanto de vocês.

Aos meus gestores e colegas de trabalho, minha profunda gratidão. Obrigada por toda a colaboração e apoio que tornaram este trabalho possível. Suas orientações, incentivos e a flexibilidade para conciliar minhas responsabilidades foram fundamentais para que eu pudesse alcançar este objetivo. Agradeço por contribuírem de maneira tão significativa para esta conquista.

Aos meus amigos, minha sincera gratidão. Obrigada por estarem ao meu lado durante essa jornada, oferecendo apoio, compreensão e momentos de descontração.

E, por último, a mim, por não ter desistido em meio a tantos obstáculos. Finalizar uma graduação é, sem dúvida, uma conquista memorável, mas fazê-la enquanto enfrento um processo de cura torna essa realização ainda mais significativa. Agradeço a mim mesma por ter encontrado força e resiliência para superar os desafios e alcançar esta vitória pessoal e acadêmica.

“Quando penso que cheguei ao meu limite, descobro que tenho forças para ir além”.

Ayrton Senna

Conteúdo

Lista de Figuras	8
Lista de Tabelas	9
Lista de Abreviações	10
1 Introdução	11
1.1 Apresentação do Tema	11
1.2 Contextualização	11
1.3 Descrição do problema	12
1.4 Justificativa/Motivação	13
1.5 Objetivos	14
1.5.1 Objetivo geral	14
1.5.2 Objetivos específicos	15
1.5.3 Organização do Texto	16
2 Fundamentação Teórica	18
2.1 Introdução	18
2.2 Sistemas de Recomendação	18
2.2.1 Sistemas de Recomendação com Filtragem Baseada em Conhecimento	19
2.2.2 Sistemas de Recomendação Híbridos	20
2.2.3 Transparência em Sistemas de Recomendação	20
2.3 Programação Linear	21
2.3.1 Particularidades da Formulação Matemática de um PPL	22
2.3.2 Métodos de Resolução de PPL	23
2.3.3 Programação Linear Inteira	23
2.4 Conclusão	24
3 Revisão Bibliográfica	25
3.1 Introdução	25
3.2 Constrained contextual bandit algorithm for limited-budget recommenda- tion system	25
3.3 A Recommendation System for Predicting Risks across Multiple Business Process Instances	26
3.4 Recommendation Systems with Complex Constraints: A Course Recom- mendation Perspective	27
3.5 Development of Organic Material Recommendation System for Organic Rice Using Linear Programming	29
3.6 Recommender systems for the conference paper assignment problem	30
3.7 Practical Design of Performant Recommender Systems using Large-scale Linear Programming-based Global Inference	31
3.8 Considerações Finais do Capítulo	32

4	Material e Métodos	37
4.1	Extração dos dados	38
4.2	Pré-Processamento dos dados	39
4.3	Construção do modelo de recomendação	40
4.3.1	PuLP	40
4.3.2	Obtendo a descrição do problema	40
4.3.3	Variáveis de Decisão	41
4.3.4	Função Objetivo	42
4.3.5	Restrições	42
4.3.6	Solucionando o problema e analisando os resultados	44
4.3.7	Resultados	45
5	Considerações Finais e Trabalhos Futuros	51
	Bibliografia	53

Lista de Figuras

4.1	Quantidade de Licenças Atual X Recomendada	46
4.2	Potencial de Economia por Licença	47
4.3	Licenças por Usuário	47
4.4	Potencial de Economia por Licença	49
4.5	Visão Geral de Custos	49

Lista de Tabelas

1.1	Previsão de gastos mundiais com TI (milhões de dólares americanos) . .	12
3.1	Comparação Trabalhos Relacionados	33
4.1	Comparação de características entre diferentes planos Microsoft	39

Lista de Abreviações

DCC Departamento de Ciência da Computação

UFJF Universidade Federal de Juiz de Fora

SR Sistema de Recomendação

1 Introdução

1.1 Apresentação do Tema

Nas últimas décadas a tecnologia vem se tornando cada vez mais indispensável na vida das pessoas, principalmente devido à praticidade e comodidade que traz. Tarefas que antes demandavam tempo e deslocamento agora podem ser realizadas de forma rápida por qualquer dispositivo conectado à internet, como, por exemplo, ir ao banco pagar contas ou fazer compras.

O volume de dados e informações geradas é proporcional ao aumento do uso da internet. Segundo a ESPM (2021), atualmente geramos cerca de 2,5 quintilhões de dados diariamente.

Em resposta a grande quantidade de informação disponível, surgem os sistemas de recomendação, que são uma subcategoria de sistemas de filtragem e combinam várias técnicas computacionais para selecionar itens personalizados com base nos interesses dos usuários e conforme o contexto no qual estão inseridos (SINGH et al., 2021).

Diversos segmentos como plataformas de streaming (Netflix, Spotify), *e-commerces* (Amazon), redes sociais (Facebook) e buscadores (Google), utilizam deste recurso para proporcionar uma boa experiência de navegação aos usuários e ao mesmo tempo aumentar suas conversões.

1.2 Contextualização

Atualmente, existem milhares de softwares corporativos, de diversos fabricantes. Uma pesquisa da consultoria Gartner (2024) prevê que os gastos mundiais com tecnologia da informação crescerão 6.8% em 2024, totalizando quase 5 trilhões de dólares, sendo deste valor mais de 20% provenientes de softwares, um crescimento de 12,7% comparado ao ano anterior, o maior de todos os crescimentos dentro desse mercado. A Tabela 1.1 traz mais

informações acerca das previsões realizadas pela Gartner com relação a gastos mundiais com TI.

Tabela 1.1: Previsão de gastos mundiais com TI (milhões de dólares americanos)

	Gastos em 2023	Crescimento em 2023 (%)	Gastos em 2024	Crescimento em 2024 (%)
Sistemas de Data Center	243.063	7.1	261.332	7.5
Dispositivos	699.791	-8.7	732.287	4.6
Softwares	913.334	12.4	1.029.421	12.7
Serviços de TI	1.381.832	5.8	1.501.365	8.7
Serviços de Comunicações	1.440.827	1.5	1.473.314	2.3
Total	4.678.847	3.3	4.997.718	6.8

O aumento expressivo dos gastos mundiais com TI se deve em parte ao avanço da pandemia da COVID-19. Uma pesquisa realizada pela IBM (2020) (*International Business Machines*) explica como a crise sanitária mudou drasticamente as prioridades das empresas, acelerando em 59% a transformação digital nas organizações pesquisadas.

A necessidade de estruturar o trabalho remoto, refazer cadeias de suprimentos e absorver mudanças na fabricação, fez com que a adaptabilidade se tornasse uma competência empresarial obrigatória. A pandemia rompeu barreiras, principalmente em relação à implementação de soluções tecnológicas, aumentando a dependência de plataformas de tecnologia nas organizações (IBM, 2020).

Na pesquisa feita pela IBM (2020) 55% dos entrevistados disseram que a pandemia resultou em mudanças permanentes em suas estratégias organizacionais e 64% reconheceram uma mudança para atividades de negócios mais baseadas em nuvem.

1.3 Descrição do problema

Embora a transformação digital acelerada pela pandemia tenha possibilitado a continuidade dos negócios, um estudo encomendado pela Microsoft e recentemente divulgado pela *The Economist Intelligence Unit* (EIU) (MICROSOFT; GROUP, 2021), revelou lacunas de qualificação, privacidade, segurança e conformidade à medida que as organizações aplicam novas tecnologias.

O cenário e os desafios agora são outros. O segmento de softwares corporativos teve um crescimento muito expressivo nos últimos 2 anos. Entretanto, a compra de software nem sempre é simples. Ainda na sua aquisição, as empresas se deparam com inúmeros tipos de licenciamento, diversos recursos, diversos fabricantes, cada um com suas políticas e contratos. Mesmo após a compra, existem outros pontos como: atribuição e distribuição de licenças, implantação, treinamento dos usuários, manutenção e renovação, até o descarte do software.

A partir destas informações, questionamentos se tornam pertinentes: Todo esse valor gasto com softwares é realmente necessário? Os usuários correspondentes utilizam todos os recursos licenciados? Todos os usuários da organização estão cobertos pelas licenças?

Daws (2021) afirma que 20% dos gastos com licenciamento de software são com softwares que não serão utilizados. Segundo ele, há várias explicações para isso, como, por exemplo, a dificuldade das organizações de se manterem atualizadas com as mudanças nos termos de licenciamento e nos acordos comerciais, visto a quantidade de possibilidades e fornecedores. Uma pesquisa feita por ele verificou que uma empresa lida em média com 15 fornecedores e 76% delas afirmam que teriam mais poder de negociação se tivessem melhor conhecimento e experiência.

1.4 Justificativa/Motivação

Diante do cenário apresentado, se torna necessário que as equipes responsáveis pelo licenciamento nas organizações entendam quais recursos seus colaboradores precisam para escolher um plano de valor mínimo que satisfaça essas necessidades. Assim, é necessário entender quais recursos possuem, onde e quanto estão sendo utilizados, para conseguirem remanejar essas licenças, de forma a cobrir todo o parque da empresa, eliminando o desperdício e reduzindo custos com licenciamentos.

Atualmente, já existem programas para inventariar computadores, como por exemplo o *Snow Inventory Agent*¹. Essas aplicações, uma vez instaladas na máquina con-

¹<https://docs.snowsoftware.com/snow-inventory-agents-and-oracle-scanners/en/index-en.html>

seguem monitorar instalações de software e medir sua utilização. Fornecendo às empresas a inteligência detalhada para responder perguntas de utilização de software, podendo auxiliar no processo de licenciamento. Por exemplo, se um colaborador utiliza e precisa dos recursos A e B, não há necessidade de oferecer a ele um plano que contenha os recursos A, B, C, D e E, afinal, os 3 últimos acabariam inutilizados.

Cada licença possui um valor, e esses valores variam de acordo com os recursos contemplados. Quando observada a diferença para um funcionário em particular, pode parecer irrelevante, mas não se pode esquecer que em empresas de grande porte, essa diferença deve ser multiplicada por centenas de funcionários. A contratação da licença de melhor custo benefício neste caso, pode gerar uma economia considerável.

Além disso, os fabricantes de software fazem verificações nas empresas com o objetivo de entender se a mesma está usando o software de sua propriedade de acordo com os termos acordados em contrato, as chamadas auditorias de software. Estar com o parque em desconformidade nesta situação, podem incorrer em multas, danos reputacionais e perdas financeiras. Muitas organizações acabam optando por licenciar em excesso para evitar problemas em futuras auditorias, já que não têm conhecimento pleno de quais ativos possuem, nem de quais precisam.

O fato é que não é interessante licenciar a mais nem a menos. Mas como chegar no conjunto de licenças necessárias para tantos funcionários e em meio a tantas possibilidades de licenças?

1.5 Objetivos

1.5.1 Objetivo geral

O objetivo deste trabalho é o desenvolvimento de um Sistema de Recomendação de licenças de software que seja transparente, fornecendo explicações claras sobre o motivo pelo qual cada recomendação é feita. Isso permite que as organizações entendam completamente as decisões sugeridas pelo sistema, promovendo uma tomada de decisão informada e eficiente. Esse sistema deve ser capaz de analisar os dados de medição do Agente

(dados de utilização de software pelo usuário) e as informações das licenças existentes e gerar recomendações baseadas no conhecimento destas duas bases de dados, visando suprir as necessidades do usuário com o menor custo possível. Dessa forma, objetiva-se otimizar os gastos com softwares corporativos, para que as empresas consigam investir de forma inteligente em ferramentas que sejam realmente necessárias e usá-las em todo o seu potencial.

1.5.2 Objetivos específicos

O desenvolvimento deste sistema de recomendação de licenças para Microsoft 365 visa alcançar diversos objetivos específicos. Primeiramente, busca-se aumentar a transparência nas recomendações. Para isso, o sistema deve proporcionar aos usuários uma visão clara e detalhada das razões por trás de cada recomendação, apresentando informações sobre as necessidades específicas de cada usuário. Essa abordagem garante que, ao analisar as recomendações, os usuários possam entender o porquê de cada sugestão, aumentando assim a confiança nas recomendações oferecidas.

Além disso, o sistema deve fornecer informações relevantes e ações resultantes do processo de recomendação. Essas serão apresentadas de forma organizada e intuitiva através de um *dashboard*, facilitando a compreensão e a tomada de decisões pelos usuários.

Por fim, o sistema será adaptado ao contexto específico do Microsoft 365. Isso significa desenvolver o sistema de recomendação considerando as várias funcionalidades e recursos desta suíte de produtos, que é amplamente utilizada em empresas de todo o mundo. De forma complementar, o Microsoft 365 oferece uma API robusta que facilita a extração de dados essenciais para a geração das recomendações. A implementação deverá garantir que o sistema opere no modelo SaaS (Software as a Service) utilizado pelo Microsoft 365, atendendo às necessidades de licenciamento de software de diferentes organizações.

A implementação desses objetivos visa criar um sistema de recomendação confiável e útil para a otimização do licenciamento de software nas organizações, garantindo que as decisões de licenciamento sejam bem informadas e transparentes.

1.5.3 Organização do Texto

Este trabalho está estruturado em 5 capítulos, que abordam diferentes aspectos do desenvolvimento e aplicação do sistema de recomendação de licenças de software. A seguir, uma breve descrição do conteúdo de cada capítulo:

- **Capítulo 1 - Introdução:** Apresenta o tema, contexto e descrição do problema, a justificativa para o estudo, bem como os objetivos geral e específicos do trabalho.
- **Capítulo 2 - Fundamentação Teórica:** Discute os conceitos e teorias relevantes para o entendimento do tema, abordando sistemas de recomendação, programação linear e a importância da transparência nas recomendações.
- **Capítulo 3 - Revisão Bibliográfica:** Revisa as principais publicações e pesquisas relacionadas ao assunto do trabalho, destacando trabalhos que influenciaram o desenvolvimento da solução proposta.
- **Capítulo 4 - Materiais e Métodos:** Detalha o processo metodológico utilizado no trabalho, dividido nas seguintes seções:
 - **Extração dos Dados:** Explica como os dados foram obtidos e quais fontes foram utilizadas.
 - **Pré-processamento dos Dados:** Descreve as etapas de limpeza e transformação dos dados para garantir sua qualidade.
 - **Construção do Modelo de Recomendação:** Descreve a implementação do modelo, organizado nas seguintes subseções:
 - * **Pulp:** Introdução à ferramenta utilizada para resolver o modelo de otimização.
 - * **Obtendo a Descrição do Problema:** Definição clara do problema de recomendação.
 - * **Variáveis de Decisão:** Apresenta as variáveis do modelo.
 - * **Função Objetivo:** Explica a função que orienta a otimização.

-
- * **Restrições:** Define as limitações impostas ao modelo.
 - * **Solucionando o Problema e Analisando os Resultados:** Explica como o problema foi resolvido com as ferramentas escolhidas e discute a análise dos resultados obtidos após a solução do problema.
 - * **Resultados:** Apresenta os resultados obtidos com o sistema de recomendação e avalia sua eficácia em comparação com os objetivos estabelecidos.
-
- **Capítulo 5 - Considerações Finais e Trabalhos Futuros:** Resume as principais conclusões do trabalho, discute suas limitações e sugere melhorias e direções para estudos futuros.

2 Fundamentação Teórica

2.1 Introdução

O objetivo deste trabalho é o desenvolvimento de um sistema de recomendação de licenças de software baseado nas informações de uso de software pelo usuário. Antes de qualquer coisa é necessário entender como funciona um sistema de recomendação, quais os tipos de abordagens já existentes e como são implementados, para então trazer ao contexto do problema e definir os próximos passos.

Além disso, é fundamental reconhecer o papel da transparência na geração de recomendações e identificar as informações pertinentes para os usuários. Essas informações não devem se limitar apenas à transparência das recomendações, mas também devem ser incorporadas nas visualizações dos relatórios, com o objetivo de fornecer *insights* de negócios confiáveis para aqueles que solicitam as recomendações.

Para gerar as recomendações de forma eficaz, os dados devem ser limpos e transformados adequadamente antes de serem aplicados em um modelo a ser construído. Além disso, é fundamental compreender em que contexto específico este trabalho se insere, a fim de determinar o modelo mais apropriado a ser desenvolvido. Esta contextualização é imprescindível para a efetividade do sistema proposto.

2.2 Sistemas de Recomendação

Um sistema de recomendação busca recomendar itens de todos os tipos para um indivíduo de acordo com características do item e o usuário em questão.

Existem diversas técnicas de geração de recomendações. Singh et al. (2021) traz seis das principais abordagens de recomendação: recomendação baseada em conteúdo, por filtragem colaborativa, demográfica, baseada em conhecimento, híbrida e sensível ao contexto.

Resumidamente, a técnica de recomendação baseada em conteúdo tem foco nas propriedades dos itens, recomendando produtos de acordo com a similaridade com itens positivamente avaliados. Já a recomendação baseada em filtragem colaborativa tenta prever os interesses de um usuário baseado nas avaliações feitas por usuários semelhantes. O sistema de recomendação demográfica por outro lado, leva em conta o perfil demográfico do usuário como idade, sexo, ocupação e localidade para agrupar, recomendando itens semelhantes para usuários de mesmo grupo demográfico. Na filtragem baseada em conhecimento, as recomendações são feitas apoiadas em um domínio de conhecimento específico, levando em consideração as necessidades e preferências do indivíduo. A recomendação híbrida consiste em combinar mais de um tipo de abordagem em um mesmo sistema, a fim de melhorar a precisão das recomendações. Por fim, a recomendação sensível ao contexto, explora o contexto no qual o usuário está inserido para fazer recomendações mais adequadas ao momento, local e dispositivo utilizado.

2.2.1 Sistemas de Recomendação com Filtragem Baseada em Conhecimento

Os Sistemas de Recomendação com Filtragem Baseada em Conhecimento fornecem recomendações com base no conhecimento de um domínio. Diferente de como acontece em outros SRs, as recomendações são geradas a um usuário de acordo com o seu perfil, de forma que o comportamento dos outros usuários não tem um papel importante na determinação da recomendação, podendo nem ser levado em consideração (BOURAGA et al., 2014).

Bouraga et al. (2014) afirma que um sistema de recomendação baseado em conhecimento precisa de uma base de conhecimento e um perfil de usuário. A construção da base de conhecimento pode ser uma tarefa complicada e exigir um conhecimento considerável do domínio, ela precisa estar alinhada à estratégia da recomendação. É imprescindível possuir as preferências do usuário, afinal esse tipo de sistema fornece uma recomendação personalizada. Essas informações podem ser coletadas de forma explícita, através de questionários respondidos pelos usuários por exemplo, ou de forma implícita,

neste caso, é feita uma análise do comportamento do usuário ao longo do tempo.

2.2.2 Sistemas de Recomendação Híbridos

Burke (2002) traz um estudo sobre a combinação das técnicas de recomendação, afim de melhorar seus resultados e diminuir as desvantagens de qualquer técnica individual, as chamadas recomendações híbridas.

Alguns métodos de combinação existentes são: Ponderado, onde uma pontuação de um item recomendado é calculada a partir dos resultados de todas as técnicas de recomendação disponíveis presentes no sistema; Comutação, o sistema usa critérios para alternar entre as técnicas de recomendação; Misto, as recomendações de mais de uma técnica são apresentadas juntas; Cascata, uma técnica é aplicada aos dados e então o resultado se torna entrada de outra técnica de recomendação, visando melhorar o resultado da recomendação; Aumento de recursos, onde uma técnica é empregada para produzir a classificação de um item e essa informação é então incorporada ao processamento da próxima técnica de recomendação; entre outros.

2.2.3 Transparência em Sistemas de Recomendação

A transparência em sistemas de recomendação têm se tornado uma competência obrigatória. Vorm e Miller (2018) afirmam que sistemas que não conseguem explicar seu raciocínio aos usuários finais podem perder confiança e não conseguir a aceitação.

Segundo Afridi (2019), quando um sistema de recomendação é mais transparente, a confiança aumenta entre os usuários. Para ele os principais atributos de sistemas de recomendação são transparência e confiança, sendo a transparência necessária para aumentar a confiança no sistema como um todo.

Kizilcec (2016) testou três níveis de transparência em sistemas e observou que os usuários tendem a confiar mais no sistema à medida que ele se torna mais transparente. No entanto, essa confiança pode diminuir quando o volume de informações fornecidas é excessivo. O estudo concluiu que a transparência deve ser implementada de forma equilibrada, oferecendo apenas as informações necessárias para ajudar os usuários

a compreenderem as recomendações apresentadas.

Verbert et al. (2013) trazem um estudo sobre explorar a transparência dos sistemas através do uso de técnicas de visualização de informação e o quanto isso pode ajudar na compreensão do usuário sobre o raciocínio por trás das recomendações, a fim de aumentar a relevância e significado percebidos e apoiar a exploração e o envolvimento do usuário no processo de recomendação.

2.3 Programação Linear

Problemas de otimização são problemas matemáticos que visam encontrar a melhor solução para uma função objetivo, sujeita a um conjunto de restrições. Essa melhor solução é geralmente definida como aquela que maximiza ou minimiza qualquer medida relevante para o problema em questão. Após a definição de um problema, é necessário construir um modelo matemático que represente o mesmo (HILLIER; LIEBERMAN, 2015).

Problemas de otimização são encontrados em diversas áreas, como engenharia, economia, ciência da computação, logística, finanças e muitas outras. A resolução eficiente desses problemas pode levar a significativas melhorias em termos de lucro, eficiência, produtividade e outros indicadores importantes (HILLIER; LIEBERMAN, 2015).

Existem diferentes tipos de problemas de otimização, classificados de acordo com diversas características:

1. **Função Objetivo:** A função que define o que se deseja otimizar, pode ser de maximização e minimização, linear ou não linear (HILLIER; LIEBERMAN, 2015).
2. **Variáveis de decisão:** As quantidades que se deseja determinar para otimizar a função objetivo. As variáveis podem ser contínuas (podem assumir qualquer valor dentro de um intervalo real) ou discretas (podem assumir apenas valores específicos, como números inteiros ou binários) (WINSTON, 2004).
3. **Restrições:** São as condições que limitam as soluções possíveis do problema. Na maioria das situações, apenas determinados valores das variáveis de decisão são

possíveis. As restrições podem ser expressas por equações ou desigualdades lineares das variáveis ou por funções não lineares das variáveis (WINSTON, 2004).

Em matemática, um problema de programação linear é um problema de otimização onde tanto a função-objetivo quanto as restrições do problema são todas lineares, isto é, possuem grau 1 (PRADO, 2016).

Portanto, para representar um problema de programação linear (PPL) também usamos um sistema de equações e expressões matemáticas relacionadas que descrevem a essência do problema.

2.3.1 Particularidades da Formulação Matemática de um PPL

Função Objetivo:

- Representada por uma **equação linear** que define o que se deseja otimizar.
- Coeficientes da função objetivo indicam a importância de cada variável na otimização.

Variáveis de decisão:

- Podem ser contínuas (podem assumir qualquer valor dentro de um intervalo real) ou discretas (podem assumir apenas valores específicos).
- Representadas por letras minúsculas.

Restrições:

- Expressas por **equações ou desigualdades lineares** das variáveis.
- Limites que as variáveis devem atender para que a solução seja viável.
- Podem representar recursos disponíveis, limites de produção, etc.

2.3.2 Métodos de Resolução de PPL

1. Método Gráfico: Adequado para problemas com poucas variáveis (até duas). Envolve a representação gráfica das restrições e da função objetivo para encontrar o ponto ideal.
2. Método Simplex: Algoritmo iterativo que busca a solução ideal passo a passo. Utilizado para problemas com um grande número de variáveis.
3. Método do Ponto Interior: Algoritmo mais recente que busca a solução ideal de forma mais eficiente que o método simplex. Útil para problemas com grandes dimensões e restrições complexas.
4. Software para Resolução de PPL: Diversos softwares disponíveis para auxiliar na resolução de PPLs, como o LINGO, o GAMS e o Excel Solver. Facilitam a modelagem e resolução de problemas complexos.

2.3.3 Programação Linear Inteira

Um problema de programação linear em que algumas ou todas as variáveis devem ser números inteiros não negativos, incluindo problemas que envolvam escolhas que possam ser representadas por variáveis binárias tipo zero-um, são chamados de problemas de programação linear inteira ou simplesmente programação inteira. Um problema passível de solução por programação inteira deve apresentar as seguintes características:

- função objetivo linear;
- restrições lineares;
- variáveis positivas;
- algumas (ou todas) variáveis inteiras.

2.4 Conclusão

Este capítulo apresentou uma revisão abrangente da literatura sobre sistemas de recomendação e programação linear, elementos-chave para a construção do sistema proposto neste trabalho de conclusão de curso. Exploramos os diferentes tipos de sistemas de recomendação, utilizando esse entendimento para selecionar a abordagem mais pertinente ao problema em questão, levando em conta as características dos dados disponíveis e os objetivos do sistema, identificamos que a filtragem baseada em conhecimento é a estratégia mais apropriada. Além disso, discutimos a importância da transparência nos sistemas de recomendação, destacando a necessidade de clareza, confiabilidade e explicações adequadas das recomendações aos usuários. Também apresentamos os conceitos fundamentais da programação linear e inteira, com destaque para sua aplicação na otimização do processo de recomendação, buscando otimizar ao máximo o custo de licenciamento, ao mesmo tempo garantimos a satisfação de todas as restrições.

3 Revisão Bibliográfica

3.1 Introdução

Neste capítulo, são apresentados alguns trabalhos relacionados ao trabalho proposto, além de uma comparação entre eles. A seleção dos artigos foi realizada por meio de uma busca sistematizada em bases de dados científicas, utilizando palavras-chave relevantes como "sistema de recomendação", "otimização com restrições", e "programação linear". Foram incluídos artigos focando em trabalhos que abordam a recomendação com restrições e otimização. Cada artigo propõe uma abordagem diferente e utiliza técnicas específicas.

A comparação entre esses artigos nos permitirá identificar pontos fortes e fracos de cada abordagem, bem como destacar as contribuições individuais de cada trabalho. Além disso, essa análise comparativa ajudará a entender as tendências e os desafios enfrentados nessas áreas de estudo, além de fornecer *insights* valiosos para futuras pesquisas.

3.2 Constrained contextual bandit algorithm for limited-budget recommendation system

Zhao e Yang (2024) propõem um novo algoritmo de bandit contextual planejado para sistemas de recomendação com orçamento limitado. O algoritmo, denominado "CB-Constrained", leva em consideração restrições de orçamento ao selecionar itens para recomendar, otimizando o retorno esperado sob a condição de que o orçamento seja respeitado.

Os autores demonstram através de experimentos em larga escala que o CB-Constrained supera significativamente outros algoritmos de bandit contextual em termos de retorno esperado, mesmo sob restrições de orçamento apertadas. O algoritmo também se mostra robusto a diferentes tipos de restrições e eficiente em termos computacionais.

O algoritmo CB-Constrained se destaca por sua capacidade de otimizar o re-

torno esperado mesmo em cenários com restrições de orçamento. Este atributo o torna uma opção promissora para situações onde os recursos são limitados, mas ainda se deseja maximizar o retorno. Além disso, os resultados dos experimentos revelam a superioridade do CB-Constrained em comparação com outros algoritmos similares, destacando sua eficácia na prática. Sua robustez a diferentes tipos de restrições, como as relacionadas ao orçamento e à diversidade, reforça ainda mais sua viabilidade em uma variedade de contextos de aplicação. Adicionalmente, sua eficiência computacional permite sua utilização em larga escala, o que é crucial para aplicações que exigem processamento rápido e eficaz.

Em suma, o artigo de Zhao e Yang (2024) apresenta o CB-Constrained como um algoritmo promissor para sistemas de recomendação com restrições de orçamento. Embora os resultados dos experimentos sejam promissores, a falta de detalhes sobre sua implementação e a limitada avaliação em cenários reais sugerem que ainda há desafios a serem superados antes de sua aplicação prática generalizada.

3.3 A Recommendation System for Predicting Risks across Multiple Business Process Instances

Conforti et al. (2015) propõem um sistema de recomendação inovador para prever e mitigar riscos em múltiplas instâncias de processos de negócios. O sistema se destaca pela combinação de duas técnicas:

1. Previsão de Riscos: Emprega técnicas de *machine learning* para analisar *logs* de processos passados e identificar padrões que indicam o risco de falhas em instâncias em execução.
2. Otimização de Recursos: Utiliza programação linear inteira para calcular a atribuição ideal de recursos às tarefas a serem executadas, a fim de lidar com a complexa interação entre riscos relativos a diferentes instâncias.

A técnica de programação linear inteira na abordagem proposta pelos autores,

permite que o sistema considere múltiplas instâncias: otimização na alocação de recursos considerando os riscos de falhas em todas as instâncias de processo em execução simultaneamente. Além de conseguir minimizar riscos coletivamente, pois prioriza a redução do risco geral do sistema, ao invés de apenas o risco de uma única instância. Tudo isso lidando com interdependências, pois leva em consideração as interdependências entre as instâncias de processo, otimizando a alocação de recursos de forma holística.

A combinação de *machine learning* e programação linear inteira demonstra resultados promissores para a previsão precisa de riscos, já que o sistema prevê riscos com alta precisão, possibilitando a tomada de decisões preventivas. Para a redução de falhas, as recomendações geradas contribuem para a redução significativa da ocorrência de falhas nos processos; bem como para a otimização de recursos, pois garante a alocação eficiente dos recursos disponíveis, minimizando custos e maximizando a produtividade.

O sistema de recomendação proposto por Conforti et al. (2015) se destaca pela inovação na utilização da programação linear inteira para otimizar a alocação de recursos e mitigar riscos em múltiplas instâncias de processos de negócios. A abordagem holística e a alta precisão do sistema o tornam uma ferramenta valiosa para empresas que buscam aprimorar a eficiência e reduzir perdas em seus processos.

3.4 Recommendation Systems with Complex Constraints: A Course Recommendation Perspective

Parameswaran, Venetis e Garcia-Molina (2011) propõem o CourseRank, um sistema de recomendação para cursos em ambientes de ensino superior. O diferencial do CourseRank reside na combinação estratégica de tecnologias avançadas, como modelagem de restrições, otimização e *machine learning*, para lidar com as complexas restrições presentes na recomendação de cursos. A programação linear, em particular, desempenha um papel determinante na otimização das recomendações, garantindo que atendam às necessidades de cada aluno e otimizem o aprendizado.

A proposta de Parameswaran, Venetis e Garcia-Molina (2011) combina as se-

guintes estratégias:

- **Modelagem de Restrições:** O CourseRank utiliza técnicas de modelagem de restrições para representar as complexas regras que governam a seleção de cursos, como pré-requisitos, co-requisitos e carga horária máxima dos alunos. Essa modelagem permite que o sistema leve em consideração todas as restrições relevantes na geração das recomendações.
- **Otimização:** A programação linear entra em cena na etapa de otimização, onde o CourseRank busca encontrar a combinação de cursos que maximiza o aprendizado e a satisfação dos alunos, respeitando todas as restrições modeladas. Essa técnica garante que as recomendações sejam viáveis e atendam às necessidades de cada aluno.
- *Machine Learning:* O CourseRank incorpora técnicas de *machine learning* para personalizar as recomendações de acordo com as preferências e histórico acadêmico de cada aluno. Essa combinação de técnicas garante que as recomendações sejam relevantes e interessantes para cada aluno, otimizando o engajamento e o aprendizado.

A programação linear desempenha um papel crucial no CourseRank, proporcionando recomendações que maximizam tanto o aprendizado quanto a satisfação dos alunos ao escolherem seus cursos. Além de garantir a viabilidade das recomendações, ao assegurar que atendam a todas as restrições modeladas, como pré-requisitos, co-requisitos e carga horária máxima dos alunos. A eficiência computacional da programação linear também permite que o CourseRank opere de maneira rápida e escalável, mesmo com grandes conjuntos de dados.

A implementação do sistema em instituições de ensino pode contribuir para melhorar a experiência dos alunos, otimizar a seleção de cursos e aumentar o engajamento no processo de ensino-aprendizagem.

3.5 Development of Organic Material Recommendation System for Organic Rice Using Linear Programming

Em seu artigo, Lee et al. (2019) propõem um sistema de recomendação de materiais orgânicos para o cultivo de arroz orgânico utilizando programação linear. O sistema visa auxiliar agricultores na escolha dos materiais orgânicos mais adequados para suas necessidades, considerando fatores como tipo de solo, clima, pragas e doenças, e disponibilidade de recursos. O sistema utiliza um modelo de programação linear para otimizar a seleção de materiais orgânicos, maximizando a produtividade e a rentabilidade do cultivo de arroz orgânico.

Os autores demonstram através de experimentos com dados reais que o sistema de recomendação proposto é capaz de identificar os materiais orgânicos mais adequados para cada tipo de solo, clima e conjunto de condições. O sistema também se mostra eficaz na otimização da produtividade e da rentabilidade do cultivo de arroz orgânico.

Embora o sistema apresente várias vantagens, como a base científica sólida proporcionada pela programação linear e sua potencial aplicabilidade em outras culturas, como frutas e hortaliças, há desafios significativos a serem considerados. A precisão do sistema está diretamente ligada à disponibilidade e qualidade dos dados históricos de cultivo de arroz orgânico, podendo comprometer sua eficácia em cenários onde tais informações são escassas ou imprecisas. Além disso, a avaliação do sistema em larga escala com diferentes agricultores e em diferentes regiões ainda é necessária para confirmar sua efetividade em cenários reais.

3.6 Recommender systems for the conference paper assignment problem

Conry, Koren e Ramakrishnan (2009) propõem um sistema de recomendação baseado em programação linear para otimizar a atribuição de trabalhos submetidos a conferências científicas. O objetivo é auxiliar comitês de programa na seleção dos revisores mais adequados para cada trabalho, considerando diversos fatores como expertise, disponibilidade, conflitos de interesse e afinidade entre o trabalho e o revisor.

Os autores demonstram através de experimentos computacionais que o sistema de recomendação proposto, utilizando PL, supera métodos tradicionais de atribuição manual em diversos aspectos, tais como: (i) Eficiência: a PL reduz significativamente o tempo necessário para a tarefa de atribuição de trabalhos, automatizando o processo e liberando tempo para os membros do comitê de programa se concentrarem em outras atividades importantes; (ii) Qualidade das revisões: a seleção otimizada de revisores com base na PL leva a revisões de maior qualidade, com feedbacks mais precisos, completos e construtivos para os autores; (iii) Equidade na Distribuição de Trabalhos: garante uma distribuição mais justa e equilibrada da carga de trabalho entre os revisores, evitando que alguns sejam sobrecarregados enquanto outros ficam com poucos trabalhos.

Além de possibilitar lidar com grandes volumes de trabalhos submetidos e comitês de programa com diversos membros, diminuindo a influência de fatores subjetivos e potenciais vieses na seleção de revisores.

Porém a precisão do sistema depende da qualidade dos dados disponíveis, como perfis de autores, áreas de *expertise* e histórico de revisões. Além disso, alguns desafios precisam ser considerados como: o sistema não considera as preferências individuais dos revisores ou as características específicas de cada trabalho, além de poder cometer erros, levando à atribuição de revisores inadequados para alguns trabalhos. A implementação e o uso eficaz exigem treinamento e manutenção constantes.

A PL é um componente fundamental do sistema de recomendação proposto pelos autores. Ela atua na otimização da atribuição de trabalhos, buscando a solução que

maximizar a afinidade entre artigos e revisores, considerando diversas restrições como disponibilidade dos revisores, conflitos de interesse e carga de trabalho. A PL permite explorar o espaço de atribuições de forma eficiente, identificando combinações ótimas que podem não ser óbvias para a seleção manual.

3.7 Practical Design of Performant Recommender Systems using Large-scale Linear Programming-based Global Inference

Gupta et al. (2023) propõem um novo método de inferência global para sistemas de recomendação de grande escala, baseado em programação linear (PL). O objetivo é superar as limitações de métodos tradicionais de inferência local, como o método de fatoração de matriz, que não conseguem capturar as complexas interações entre usuários e itens em grandes conjuntos de dados.

O método proposto pela equipe de Gupta utiliza PL para realizar inferência global, capturando as complexas relações entre usuários e itens em um único modelo. Isso permite que o sistema faça recomendações mais precisas e relevantes para cada usuário, mesmo em conjuntos de dados extremamente grandes. Além disso, o modelo proposto é flexível e permite a incorporação de diversos fatores na inferência, como características dos usuários, características dos itens e informações contextuais, aprimorando ainda mais a qualidade das recomendações.

Os resultados do estudo demonstram que a inferência global baseada em PL supera os métodos tradicionais em diversos cenários de avaliação, alcançando maior precisão nas recomendações. O modelo também se mostra eficiente em lidar com grandes conjuntos de dados, sem comprometer a precisão. A interpretabilidade dos resultados é outro ponto positivo, pois a PL permite entender as razões por trás das recomendações geradas.

Embora o método proposto apresente grande potencial, é importante conside-

rar alguns desafios para sua implementação prática. A complexidade computacional da PL em grande escala exige recursos computacionais significativos para treinamento e inferência. A qualidade dos dados de usuários e itens também é importante para a precisão do modelo, necessitando de dados limpos, completos e com informações relevantes. Por fim, a falta de uma implementação aberta do modelo dificulta a replicação dos resultados e a adoção por outros pesquisadores e desenvolvedores.

Apesar dos desafios, o estudo de Gupta et al. (2021) apresenta um método inovador de inferência global para sistemas de recomendação de grande volume, com potencial para superar as limitações de métodos tradicionais e oferecer maior precisão, eficiência, flexibilidade e interpretabilidade. A combinação de inferência global com PL abre caminho para o desenvolvimento de sistemas de recomendação mais eficazes e personalizados em diversos domínios.

3.8 Considerações Finais do Capítulo

Tabela 3.1: Comparação Trabalhos Relacionados

Artigo	Tipo de Estudo	Objetivo	Tecnologias	Resultados Encontrados	Testes Realizados	Público do Teste
Zhao e Yang (2024)	Algoritmo	Sistema de recomendação com orçamento limitado para maximizar a satisfação do usuário	Aprendizado por Reforço, Algoritmo Bandido Contextual, Otimização Constrita	Maior satisfação do usuário com menor orçamento.	Simulação	Usuários de um sistema de recomendação.
Conforti et al. (2015)	Sistema de Recomendação	Sistema de recomendação para prever riscos em instâncias de processos de negócio	Aprendizado de Máquina Supervisionado, Programação Linear Inteira	Melhor previsão de riscos, redução de perdas financeiras e otimização de recursos	Dados reais de processos de negócio	Empresas que utilizam processos de negócio.

Continua na próxima página

Tabela 3.1 – Continuação da página anterior

Artigo	Tipo de Estudo	Objetivo	Tecnologias	Resultados Encontrados	Testes Realizados	Público do Teste
Parames-Venettis e Garcia-Molina (2011)	Sistema de Recomendação	Sistema de recomendação de cursos com restrições complexas	Programação Linear, Otimização Combinatória	Cursos mais adequados para cada aluno, considerando restrições complexas	Simulação	Alunos de uma instituição de ensino
Lee et al. (2019)	Sistema de Recomendação	Sistema de recomendação de material orgânico para arroz orgânico usando programação linear	Programação Linear	Sistema de recomendação eficiente para material orgânico para arroz orgânico	Dados reais de produção de arroz orgânico	Agricultores que produzem arroz orgânico
Conry, Korten e Ramakrishnan (2009)	Sistema de Recomendação	Sistema de recomendação para atribuição de trabalhos em conferências	Programação Linear, Algoritmos Genéticos	Atribuição de trabalhos mais eficiente e justa	Dados reais de conferências	Comitês de programa de conferências

Continua na próxima página

Tabela 3.1 – Continuação da página anterior

Artigo	Tipo de Estudo	Objetivo	Tecnologias	Resultados Encontrados	Testes Realizados	Público do Teste
Gupta et al. (2023)	Sistema de Recomendação	Sistema de recomendação de alto desempenho com inferência global baseada em programação linear em grande escala	Programação Linear em Grande Escala, Processamento Distribuído	Maior precisão e relevância das recomendações em grandes conjuntos de dados	Dados reais de sistemas de recomendação	Empresas que utilizam sistemas de recomendação.

Neste capítulo, foram explorados 6 artigos que abordam diferentes aspectos dos sistemas de recomendação, com o objetivo de mapear as tendências e desafios nessa área em constante evolução. Através da análise comparativa detalhada, presente na tabela 3.1, é possível identificar as nuances de cada abordagem, seus pontos fortes e limitações, além das contribuições significativas para a resolução de problemas reais em diversos setores.

Os artigos demonstram a diversidade de técnicas e métodos empregados na construção de sistemas de recomendação eficazes: desde o aprendizado de máquina e mineração de dados até técnicas de otimização matemática e algoritmos genéticos. Cada abordagem se destaca em diferentes cenários de aplicação, evidenciando a necessidade de uma seleção criteriosa da metodologia mais adequada para cada problema específico.

É importante destacar os avanços significativos em áreas específicas, como: Orçamento

Limitado, Restrições Complexas e Desenvolvimento de Sistemas de Recomendação de Alto Desempenho com programação linear em grande escala, envolvendo tecnologias como processamento distribuído.

Apesar dos avanços, ainda existem desafios a serem superados, como:

- **Falta de Validação Aprofundada:** Alguns dos artigos apresentam resultados promissores, mas carecem de validação em cenários reais e com conjuntos de dados maiores e mais diversificados.
- **Personalização e Relevância:** A personalização das recomendações e a garantia de que elas sejam relevantes para as necessidades e preferências dos usuários ainda representam desafios a serem enfrentados.
- **Transparência e Explicabilidade:** A necessidade de sistemas de recomendação transparentes e explicáveis, que permitam aos usuários entender os motivos por trás das sugestões recebidas, é importante para a construção da confiança e da aceitação desses sistemas.

Em síntese, a análise dos artigos relacionados demonstra um panorama promissor para o futuro dos sistemas de recomendação, com potencial para revolucionar diversos setores da sociedade. Acredita-se que o trabalho proposto neste estudo contribui para o avanço dessa área, ao propor uma nova abordagem para a recomendação de licenças de software, considerando as necessidades do usuário e otimizando o seu custo.

4 Material e Métodos

O desenvolvimento de um Sistema de Recomendação requer a execução de várias etapas fundamentais. O primeiro passo foi identificar as perguntas que o sistema deveria responder, quem seriam os usuários da solução e quais medidas seriam necessárias para transformar os dados em informações valiosas. Para isso, foi realizado um levantamento inicial junto a um grupo empresarial composto por organizações de diversos setores, que serviu como estudo de caso para este projeto, a fim de identificar esses requisitos iniciais.

O levantamento foi conduzido por meio de reuniões periódicas com um representante de governança de TI do grupo e sua equipe. O objetivo inicial dessas reuniões era compreender as necessidades da empresa em relação à governança de licenças de software, identificar os principais desafios enfrentados e determinar quais entregas trariam maior valor. Esse processo permitiu definir os objetivos específicos do sistema de recomendação. Desde o início, houve uma preocupação em diferenciar o que era uma particularidade do cliente e o que representava uma necessidade mais ampla, a fim de desenvolver um sistema aplicável a várias organizações.

Com base nessas discussões, concluímos que o sistema de recomendação deveria fornecer informações sobre o valor total do licenciamento recomendado, a economia gerada e as inconformidades identificadas, além de garantir um nível adequado de transparência para que os usuários confiem nos resultados do sistema. Para atender a esses requisitos, as seguintes etapas foram executadas: Extração dos Dados, Pré-Processamento dos Dados, Construção do Modelo de Recomendação e Análise dos Resultados. Essas etapas são detalhadas nas subseções seguintes.

Durante todas as fases do desenvolvimento, foi mantida uma comunicação constante com o cliente para obter feedbacks e validações, com o objetivo de garantir que o sistema final fosse de fato útil e atendesse às suas necessidades.

4.1 Extração dos dados

Na primeira etapa foi iniciada a extração dos dados necessários. As duas principais bases de dados do sistema são basicamente informações de uso de software dos usuários e informações das licenças a serem recomendadas, bem como seus valores e produtos inclusos.

Para compor a primeira base, foram extraídos dados de duas fontes diferentes: Primeiro, foi realizada uma conexão com a Microsoft Graph, uma API Web RESTful que permite acesso à recursos do serviço Microsoft Cloud, e requisitados os dados que seriam importantes para contribuir na construção da recomendação como: licenças atribuídas, últimos logins e datas de uso e quantidade utilizada. Em seguida, obtivemos relatórios de inventário e medição através de um agente instalado nos computadores dos colaboradores, de forma a obter mais informações de uso de softwares por usuários como tempo de uso por execução, último uso, etc. No caso dessa empresa que utilizamos como estudo de caso, o agente utilizado foi o Snow Software (SNOW, 2024).

Para construir a segunda base, de licenças a serem recomendadas, utilizamos materiais do fabricante ² e seu próprio site para criar um mapeamento de licenças, funcionalidades e valores. Na tabela 4.1 é possível ver um exemplo reduzido do mapeamento construído. As funcionalidades listadas na Tabela ?? foram as mais relevantes para gerar as recomendações, pois conseguimos obter dados suficientes de uso das mesmas para correlacioná-las com as licenças estudadas. Existem outras funcionalidades que seriam interessantes levar em consideração, como por exemplo o Windows, entretanto, não foi possível extrair informações suficientes para definir uso ou desuso pelo usuário, portanto, não foi incluída na análise.

²<https://m365maps.com/>

Tabela 4.1: Comparação de características entre diferentes planos Microsoft

Feature	Office 365 E1	Office 365 E3	Office 365 E5	Microsoft 365 F1	Microsoft 365 F3	Microsoft 365 E3	Microsoft 365 E5
Delve	✓	✓	✓		✓	✓	✓
Exchange On-line	Plan 1	Plan 2	Plan 2	Calendar	Kiosk	Plan 2	Plan 2
Exchange On-line Archiving	50 GB	1.5 TB	1.5 TB		1.5 TB	1.5 TB	1.5 TB
Microsoft 365 Apps		Enterprise	Enterprise			Enterprise	Enterprise
Microsoft Forms	✓	✓	✓	Consume	✓	✓	✓
Microsoft Teams	✓	✓	✓	✓	✓	✓	✓
Microsoft To Do	✓	✓	✓		✓	✓	✓
Microsoft Whiteboard	✓	✓	✓		✓	✓	✓
Office for the Web	✓	✓	✓	Read	✓	✓	✓
OneDrive for Business	Plan 1	Plan 2	Plan 2	Kiosk	Kiosk	Plan 2	Plan 2
Power BI Pro						✓	✓
SharePoint Online	Plan 1	Plan 2	Plan 2	Kiosk	Kiosk	Plan 2	Plan 2

4.2 Pré-Processamento dos dados

Com os arquivos em mãos, iniciou-se a etapa de pré-processamento dos dados. Inicialmente, integramos as informações das diversas fontes, agrupando os dados por usuário para consolidar todas as informações de uso. Em seguida, foram aplicadas técnicas de anonimização para proteger dados sensíveis. O processo incluiu uma filtragem criteriosa dos dados extraídos, para manter somente os relevantes para responder às necessidades específicas do sistema de recomendação.

Durante o processo de limpeza e transformação dos dados, cada etapa foi projetada para garantir a qualidade e a integridade dos dados, fatores essenciais para gerar recomendações precisas e confiáveis. Isso incluiu, por exemplo, a normalização de formatos e unidades de medida, como a conversão de capacidades de armazenamento para bytes, permitindo uma análise consistente e precisa das necessidades de cada usuário.

Além disso, foram aplicadas técnicas de validação e correção, assegurando que os dados estivessem livres de inconsistências e prontos para serem utilizados pelo sistema de recomendação.

4.3 Construção do modelo de recomendação

Com as bases de dados prontas para alimentar o modelo de recomendação, foi iniciada a etapa de implementação deste modelo. O modelo escolhido foi de recomendação a partir do conhecimento do usuário e utilizamos de programação linear inteira para gerar a recomendação, já que esta permite descrever as restrições as quais o problema está sujeito, gerando assim somente recomendações de licenças que atendam completamente à todas as necessidades de software por parte dos usuários.

4.3.1 PuLP

Para resolver o problema abordado neste trabalho, utilizamos a programação linear inteira por meio do software PuLP ³, um software de código aberto gratuito escrito em Python.

É usado para descrever problemas de otimização como modelos matemáticos, permitindo então, chamar qualquer um dos vários solucionadores de PL externos como CBC, GLPK, CPLEX, Gurobi, etc., para resolver este modelo e então usar comandos python para manipular e exibir a solução.

Junto ao PuLP utilizamos o CBC (COIN-OR Branch and Cut), que é um solucionador de programação inteira mista de código aberto.

4.3.2 Obtendo a descrição do problema

É necessário chegar à uma descrição do modelo mais rigorosa para então formularmos o mesmo. Para isso, várias conversas com o cliente foram necessárias para entender os pormenores do problema, suas especificidades. Considerando os requisitos definidos pelo cliente junto aos dados obtidos, entendendo as limitações, para fechar de fato o escopo

³<https://pypi.org/project/PuLP/>

do projeto e restrições contempladas.

Dados do problema

- *Pessoas*: funcionários da organização que necessitam de utilização de software e carecem de licenciamento.
- *Produtos*: lista de licenças de Microsoft 365 a serem recomendadas pelo software.
- *Custo por produto*: mapeamento do valor mensal de cada licença.
- *Funcionalidades*: listagem de todas as funcionalidades presentes nos produtos.
- *Funcionalidades por produto*: mapeamento de cada produto para as funcionalidades que ele inclui.
- *Necessidades*: mapeamento das necessidades de cada pessoa em relação a cada item/funcionalidade analisada.

4.3.3 Variáveis de Decisão

$x_{p,prod}$ - Onde p representa o funcionário para o qual a decisão está sendo tomada e $prod$ representa o produto Microsoft 365 em questão.

Ao contrário de variáveis contínuas que podem assumir qualquer valor numérico, $x_{p,prod}$ é uma variável binária. Isso significa que ela só pode ter dois valores possíveis:

0: Indica que o plano $prod$ não é recomendado para o funcionário p .

1: Indica que o plano $prod$ é recomendado para o funcionário p .

O modelo de otimização linear busca minimizar o custo total, considerando as necessidades de cada funcionário e as restrições de orçamento. Para alcançar esse objetivo, o modelo ajusta os valores de $x_{p,prod}$ para 1 ou 0, criando combinações de planos que atendam às necessidades de cada funcionário com o menor custo possível.

Exemplo Prático: Imagine o funcionário A e os planos Microsoft 365 X e Y . Se o modelo definir $x_{A,X}$ como 1, isso significa que o plano X é recomendado para o funcionário A . Já se $x_{A,Y}$ for 0, indica que o plano Y não é recomendado para ele.

4.3.4 Função Objetivo

$$\text{Min} \sum_{p \in \text{pessoas}} \sum_{prod \in \text{produtos}} x_{p,prod} \cdot \text{custo_produtos}_{prod}$$

A função objetivo do problema estudado busca minimizar o custo total da solução, ou seja, o valor total gasto em licenças do Microsoft 365 para todos os funcionários. Ela faz isso somando o custo de cada plano multiplicado pela variável de decisão $x_{p,prod}$ que representa a existência de recomendação para a pessoa e produto em questão. É feita uma dupla iteração em pessoas e produtos que garante que todos os planos sejam considerados para cada funcionário. Para cada combinação p e $prod$, a função objetivo multiplica o valor de $x_{p,prod}$ pelo custo do plano $prod$ e adiciona o resultado à soma total.

Se $x_{p,prod}$ for 0, significa que o plano $prod$ não é recomendado para o funcionário p , e seu custo não é considerado na soma.

Se $x_{p,prod}$ for 1, significa que o plano $prod$ é recomendado para o funcionário p , e seu custo é adicionado à soma total, contribuindo para o cálculo do custo total da solução.

4.3.5 Restrições

$$R1_{p,item} : \sum_{prod \in \text{produtos}} x_{p,prod} \cdot \text{produtos_itens}_{prod,item} \geq \text{necessidades}_{p,item}, \quad (4.1)$$

$$\forall p \in \text{pessoas}, \forall item \in \text{itens}$$

Esta restrição envolve as seguintes variáveis e parâmetros:

- $x_{p,prod}$: Variável de decisão que indica se o produto $prod$ é alocado para a pessoa p .
- $\text{produtos_itens}_{prod,item}$: Quantidade da funcionalidade $item$ presente no produto $prod$.
- $\text{necessidades}_{p,item}$: Necessidade da pessoa p para a funcionalidade $item$.

Descrição da Restrição

A restrição diz que, para uma pessoa p e uma funcionalidade $item$, a soma da quantidade da funcionalidade $item$ contida em todos os produtos $prod$ alocados para essa pessoa deve

ser maior ou igual à necessidade da pessoa p para a funcionalidade item.

Passo a Passo da Restrição

1. Iteração sobre os Produtos:

- A expressão $\sum_{\text{prod} \in \text{produtos}}$ indica que estamos somando para todos os produtos prod disponíveis.

2. Quantidade do Item no Produto:

- $x_{p,\text{prod}} \cdot \text{produtos_itens}_{\text{prod,item}}$ representa a quantidade da funcionalidade item contida no produto prod alocado para a pessoa p .

3. Soma das Quantidades:

- A soma $\sum_{\text{prod} \in \text{produtos}} x_{p,\text{prod}} \cdot \text{produtos_itens}_{\text{prod,item}}$ calcula a quantidade total da funcionalidade item obtida a partir de todos os produtos prod alocados para a pessoa p .

4. Satisfação da Necessidade:

- A restrição $\geq \text{necessidades}_{p,\text{item}}$ garante que essa quantidade total seja pelo menos igual à necessidade da pessoa p para a funcionalidade item.

Implicação da Restrição

Esta restrição assegura que as necessidades mínimas de cada pessoa para cada item sejam atendidas pela alocação dos produtos. É uma forma de garantir que a solução do problema de programação linear inteira satisfaz os requisitos básicos de cada pessoa, em termos de itens específicos que eles necessitam. Isso significa que nenhum funcionário terá suas necessidades de itens essenciais do Microsoft 365 não atendidas pela solução otimizada.

Permitindo que o modelo de otimização selecione planos que atendam às necessidades de todos os funcionários, evitando desperdício de recursos e garantindo o melhor uso das licenças disponíveis.

4.3.6 Solucionando o problema e analisando os resultados

Após a formulação do problema matemático, o próximo passo foi chamar o solver escolhido e passar o problema formulado para ele. O solver então aplica técnicas de programação linear para encontrar a solução ideal.

Uma etapa essencial que se seguiu foi a validação da solução do programa matemático. Esse processo envolveu uma análise minuciosa dos planos recomendados para garantir que eles realmente faziam sentido e atendiam a todas as necessidades dos usuários com o menor custo possível. Os seguintes pontos foram considerados durante a validação:

- **Verificação de Adequação:** Cada plano recomendado foi revisado para assegurar que correspondia às necessidades específicas dos usuários. Isso incluía verificar se as funcionalidades necessárias estavam presentes nas licenças sugeridas.
- **Análise de Custo-Benefício:** Avaliamos se os custos associados às licenças recomendadas eram os melhores, comparando com as outras alternativas possíveis.
- **Conformidade com Termos de Licenciamento:** Garantimos que todas as recomendações estavam em conformidade com os termos e condições de licenciamento, evitando riscos legais e financeiros.

Para garantir a transparência do processo e facilitar a compreensão das decisões tomadas, carregamos também as informações detalhadas de cada usuário junto às recomendações de planos. Isso incluiu dados sobre os padrões de uso do software e as necessidades específicas de cada funcionário. A transparência foi um fator crucial para:

- **Facilitar a Compreensão das Recomendações:** Ao fornecer uma visão clara das razões por trás de cada recomendação, os usuários e gestores puderam entender melhor como as decisões foram tomadas.
- **Apoiar a Tomada de Decisão:** Com informações detalhadas e justificadas, os gestores puderam tomar decisões mais informadas e confiantes sobre a implementação das recomendações.

Dessa forma, o processo de validação e análise dos resultados não apenas garantiu a precisão e a eficácia das recomendações, mas também promoveu a confiança dos usuários e gestores na solução proposta.

4.3.7 Resultados

Após a validação e análise das soluções obtidas através do modelo de programação linear, esta seção apresenta os resultados detalhados, destacando as principais recomendações apontadas pelo modelo e *insights* obtidos. Os resultados foram exportados para o Power BI para criação de um *dashboard* interativo, que facilita a visualização e análise dos dados por parte dos gestores.

Resultados do Modelo de Otimização

Os resultados do modelo de otimização destacam-se por sua capacidade de reduzir custos e melhorar a alocação de licenças. A seguir, destacam-se os resultados por custo e adequação das licenças às necessidades dos usuários.

1. Redução de Custos

- (a) O modelo indicou uma redução média de 46% nos gastos com licenças de software.
- (b) Economias totais projetadas foram de R\$371.093,89, destacando a eficácia do modelo em otimizar os recursos financeiros.

2. Adequação das Licenças

- (a) A análise revelou que as licenças recomendadas atendiam perfeitamente às necessidades dos usuários, com uma taxa de adequação de 100%.
- (b) A diminuição na subutilização de licenças, isso é, casos em que as licenças recomendadas possuem menor custo comparado às licenças atuais, foi de 19.8%, mostrando uma melhoria significativa na eficiência de uso.

Visualização dos Dados no Power BI

Para proporcionar uma análise detalhada e interativa dos resultados, os dados foram exportados para o Power BI, onde um dashboard foi criado. O dashboard inclui várias visualizações que permitem uma compreensão profunda dos resultados:

Visão Geral dos Custos

- Gráfico de barras mostrando a quantidade de licenças atribuídas e recomendadas (figura 4.1).

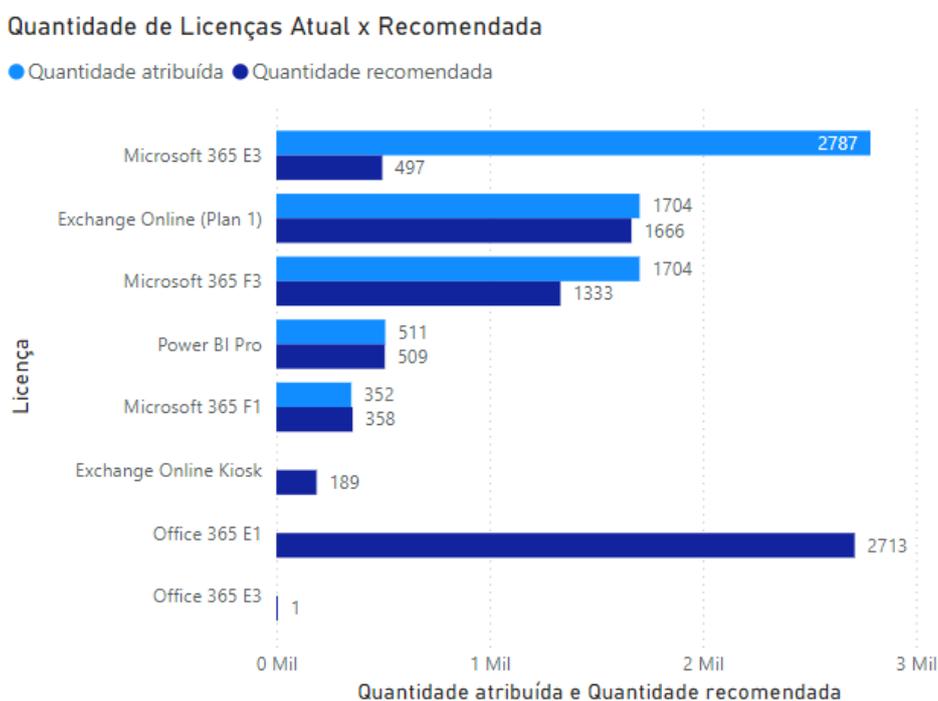


Figura 4.1: Quantidade de Licenças Atual X Recomendada

- Gráfico de linhas exibindo o potencial de economia de cada licença, destacando as licenças com maior potencial de redução de custos e que devem ter análise prioritizada (figura 4.2).

Detalhamento por Usuário

- Tabela com os IDs dos usuários, licenças atuais, recomendadas e a transparência correspondente (figura 4.3).

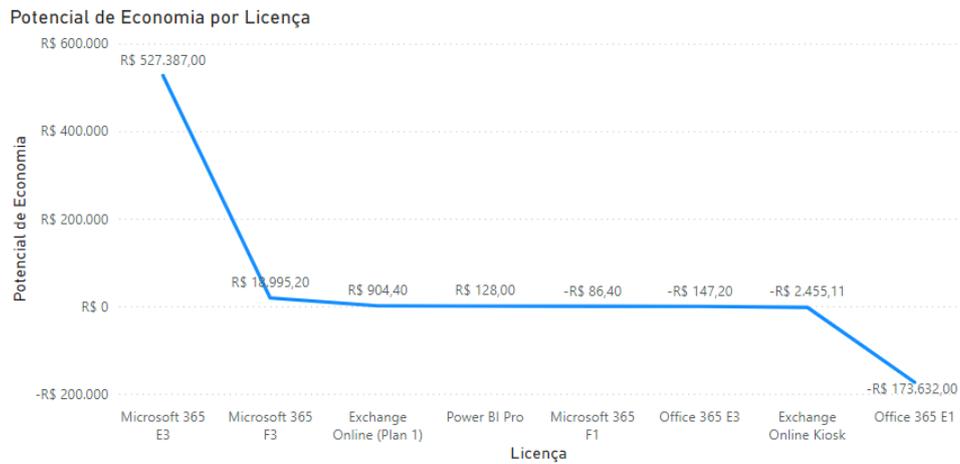


Figura 4.2: Potencial de Economia por Licença

Id Usuário	Departamento	Empresa						
63539	Setor Y	Empresa 2						
<table border="1"> <thead> <tr> <th>Licença Atual</th> <th>Licença Recomendada</th> <th>Transparência</th> </tr> </thead> <tbody> <tr> <td>Microsoft 365 E3</td> <td>Microsoft 365 E3</td> <td>Usuário Utiliza: 70.16GB de StorageUsedByteMailbox, 95.81GB de StorageUsedByteOneDrive, Azure Active Directory Premium Plan 1, Office for the web, Microsoft 365 Apps for Enterprise, Microsoft Teams</td> </tr> </tbody> </table>			Licença Atual	Licença Recomendada	Transparência	Microsoft 365 E3	Microsoft 365 E3	Usuário Utiliza: 70.16GB de StorageUsedByteMailbox, 95.81GB de StorageUsedByteOneDrive, Azure Active Directory Premium Plan 1, Office for the web, Microsoft 365 Apps for Enterprise, Microsoft Teams
Licença Atual	Licença Recomendada	Transparência						
Microsoft 365 E3	Microsoft 365 E3	Usuário Utiliza: 70.16GB de StorageUsedByteMailbox, 95.81GB de StorageUsedByteOneDrive, Azure Active Directory Premium Plan 1, Office for the web, Microsoft 365 Apps for Enterprise, Microsoft Teams						
65984	Setor Y	Empresa 2						
<table border="1"> <thead> <tr> <th>Licença Atual</th> <th>Licença Recomendada</th> <th>Transparência</th> </tr> </thead> <tbody> <tr> <td>Microsoft 365 F1</td> <td>Microsoft 365 F3</td> <td>Usuário Utiliza: 1.08GB de StorageUsedByteMailbox, Office for the web, 0.97GB de StorageUsedByteOneDrive, Azure Active Directory Premium Plan 1</td> </tr> </tbody> </table>			Licença Atual	Licença Recomendada	Transparência	Microsoft 365 F1	Microsoft 365 F3	Usuário Utiliza: 1.08GB de StorageUsedByteMailbox, Office for the web, 0.97GB de StorageUsedByteOneDrive, Azure Active Directory Premium Plan 1
Licença Atual	Licença Recomendada	Transparência						
Microsoft 365 F1	Microsoft 365 F3	Usuário Utiliza: 1.08GB de StorageUsedByteMailbox, Office for the web, 0.97GB de StorageUsedByteOneDrive, Azure Active Directory Premium Plan 1						
66251	Setor X	Empresa 2						
<table border="1"> <thead> <tr> <th>Licença Atual</th> <th>Licença Recomendada</th> <th>Transparência</th> </tr> </thead> <tbody> <tr> <td>Microsoft 365 F3</td> <td>Microsoft 365 F1</td> <td>Usuário Utiliza: Azure Active Directory Premium Plan 1</td> </tr> </tbody> </table>			Licença Atual	Licença Recomendada	Transparência	Microsoft 365 F3	Microsoft 365 F1	Usuário Utiliza: Azure Active Directory Premium Plan 1
Licença Atual	Licença Recomendada	Transparência						
Microsoft 365 F3	Microsoft 365 F1	Usuário Utiliza: Azure Active Directory Premium Plan 1						
67854	Setor X	Empresa 2						
<table border="1"> <thead> <tr> <th>Licença Atual</th> <th>Licença Recomendada</th> <th>Transparência</th> </tr> </thead> <tbody> <tr> <td>Microsoft 365 F1</td> <td></td> <td>Usuário não necessita de licenciamento.</td> </tr> </tbody> </table>			Licença Atual	Licença Recomendada	Transparência	Microsoft 365 F1		Usuário não necessita de licenciamento.
Licença Atual	Licença Recomendada	Transparência						
Microsoft 365 F1		Usuário não necessita de licenciamento.						

Figura 4.3: Licenças por Usuário

Podemos encontrar 4 cenários na recomendação: *Compliance*, *Downgrade*, *Upgrade* e *Unassign*

- *Compliance*: Acontece quando o usuário está em conformidade, o que significa que a licença que possui atualmente atende e cobre as funcionalidades que ele usa.
- *Downgrade*: Quando o usuário possui uma licença robusta demais para o que necessita. Neste caso, a recomendação é para uma licença menos avançada que ainda atenda às necessidades do usuário, resultando em uma possível economia de custos.
- *Upgrade*: Ocorre quando a licença atual do usuário não cobre todas as funcionalidades necessárias para suas atividades. Nesse caso, o usuário utiliza ferramentas às quais não tem direito, ficando em desconformidade com o fabricante. A recomendação aqui é para uma licença mais avançada, que forneça todos os recursos necessários.
- *Unassign*: Este cenário ocorre quando a licença atual não é mais necessária para o usuário, seja porque ele não utiliza mais as funcionalidades oferecidas pela licença ou porque as suas necessidades mudaram completamente. Neste caso, a recomendação é desatribuir a licença, liberando-a para outro usuário ou para ser cancelada.

Resumo de Licenças

- Visualização em tabela por tipo de licença mostrando quantidade atribuída, custos atuais, quantidade recomendada, custos após otimização e economia gerada (figura 4.4).

Indicadores de Custo

- Cartões com o custo total inicial, custo após otimização e economia esperada (figura 4.5).

Licença	Qtt atribuída	Custos atuais	Qtt recomendada	Custos após otimização	Saving
Exchange Online (Plan 1)	1704	40.555,20	1666	39.650,80	R\$ 904,40
Exchange Online Kiosk			189	2.455,11	-R\$ 2.455,11
Microsoft 365 E3	2787	641.846,10	497	114.459,10	R\$ 527.387,00
Microsoft 365 F1	352	5.068,80	358	5.155,20	-R\$ 86,40
Microsoft 365 F3	1704	87.244,80	1333	68.249,60	R\$ 18.995,20
Office 365 E1			2713	173.632,00	-R\$ 173.632,00
Office 365 E3			1	147,20	-R\$ 147,20
Power BI Pro	511	32.704,00	509	32.576,00	R\$ 128,00
Total	7058	807.418,90	7266	436.325,01	R\$ 371.093,89

Figura 4.4: Potencial de Economia por Licença

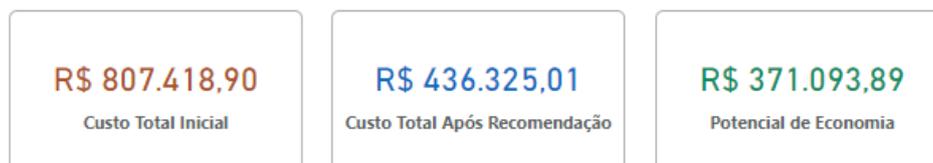


Figura 4.5: Visão Geral de Custos

Análise dos Principais Resultados

A análise dos resultados apresentados no dashboard do Power BI revela insights importantes:

Eficiência na Alocação de Licenças

- Visualizações indicam uma melhoria significativa na alocação de licenças, reduzindo a subutilização e otimizando o uso.
- A eficiência operacional aumentou, resultando em um uso mais racional dos recursos.

Impacto Financeiro Positivo

- A economia projetada evidencia uma estratégia viável para otimização de custos, especialmente na renovação de contratos com o Fabricante, contribuindo para a sustentabilidade financeira das organizações.

Tomada de Decisão Informada

- A transparência do processo de otimização, visualizada no dashboard, permite que os gestores tomem decisões mais informadas.
- A clareza nas recomendações facilita a aceitação e implementação das mudanças necessárias.

Discussão dos Resultados

Os resultados obtidos através do modelo de otimização e sua visualização no Power BI demonstram a eficácia da abordagem proposta para a recomendação de licenças de software. A redução de custos, a adequação das licenças às necessidades dos usuários e a garantia de conformidade sublinham a relevância e aplicabilidade deste sistema em ambientes corporativos. Este trabalho não apenas contribui para a otimização de recursos financeiros, mas também promove a eficiência operacional e a tomada de decisão informada.

O código desenvolvido oferece uma ferramenta prática para recomendar planos do Microsoft 365, considerando as necessidades individuais dos funcionários e minimizando o custo total. A combinação de otimização linear e descrição transparente das necessidades dos funcionários faz dessa ferramenta uma solução eficiente para otimizar os custos de licenciamento.

Com a visualização detalhada dos resultados no Power BI, as organizações podem tomar decisões informadas, promovendo a eficiência operacional e a sustentabilidade financeira. Este sistema facilita a gestão de licenças e potencializa a economia de custos, tornando-se um recurso valioso para empresas que utilizam o Microsoft 365.

5 Considerações Finais e Trabalhos Futuros

O gerenciamento de ativos de software tem se destacado como uma competência essencial nas empresas modernas, visando reduzir custos com licenciamento, mitigar riscos legais associados ao uso de software e aumentar a eficiência operacional.

Neste contexto, este trabalho concentrou-se no desenvolvimento de um sistema de recomendação personalizado para licenças do Microsoft 365, utilizando dados de uso de software dos usuários para otimizar a escolha de licenciamento. Os resultados obtidos através do modelo de otimização e sua visualização no Power BI demonstraram claramente a eficácia dessa abordagem. A redução de custos, a adequação das licenças às necessidades individuais dos usuários e a garantia de conformidade destacam a relevância e aplicabilidade deste sistema em ambientes corporativos.

O presente trabalho não apenas contribui para a otimização de recursos financeiros, mas também promove a eficiência operacional e a tomada de decisão informada, posicionando-se como uma ferramenta valiosa para empresas que buscam maximizar o valor de seus investimentos em tecnologia.

No entanto, durante a implementação, algumas limitações foram identificadas. Por exemplo, a granularidade das informações extraídas pelo agente de medição proporciona uma boa visão do uso de softwares pelos funcionários, mas para alguns produtos específicos seria vantajoso obter dados mais detalhados. Além disso, para que o processo de recomendação seja bem-sucedido, é de suma importância que todos os dispositivos e servidores da empresa estejam corretamente inventariados, pois somente assim é possível obter dados precisos de hosts que estão no ambiente de inventário.

Como trabalhos futuros, sugere-se a implementação de funcionalidades que permitam aos usuários personalizar as recomendações de licenciamento de acordo com suas necessidades específicas. Isso poderia incluir uma interface intuitiva onde os administradores possam definir critérios e preferências para a recomendação de licenças, como funcionalidades específicas a serem analisadas e regras de negócio a serem aplicadas.

Para a parte de transparência, seria interessante utilizar a proveniência de dados para melhorar a explicabilidade do sistema. A proveniência permite rastrear a origem e as transformações dos dados utilizados para gerar as recomendações, o que possibilitaria aos usuários entenderem melhor como as sugestões foram geradas, aumentando a confiança e a adoção da ferramenta.

Além disso, seria benéfico desenvolver um módulo dedicado exclusivamente à realocação de usuários entre as licenças já existentes na empresa. Isso permitiria que o sistema fosse utilizado não apenas durante períodos de renovação contratual, mas também como uma ferramenta contínua para otimizar a utilização das licenças existentes. Essa abordagem não só maximiza a eficiência operacional, mas também reduz potencialmente os custos ao evitar a compra desnecessária de novas licenças.

Outro aspecto importante seria a expansão da capacidade do sistema para integrar novas plataformas de software além do Microsoft 365, adaptando-se às necessidades variadas de diferentes ambientes corporativos. Isso poderia incluir a análise e recomendação de licenças para outras soluções de software usadas pelas empresas, proporcionando uma solução abrangente para o gerenciamento de ativos de software.

Essas melhorias não apenas aprimorariam a funcionalidade do sistema atual, mas também o posicionariam como uma ferramenta versátil e essencial para a gestão eficiente de recursos tecnológicos nas organizações.

Bibliografia

- AFRIDI, A. H. Transparency for beyond-accuracy experiences: A novel user interface for recommender systems. *Procedia Computer Science*, v. 151, p. 335–344, 2019. ISSN 1877-0509. The 10th International Conference on Ambient Systems, Networks and Technologies (ANT 2019) / The 2nd International Conference on Emerging Data and Industry 4.0 (EDI40 2019) / Affiliated Workshops. Disponível em: [⟨https://www.sciencedirect.com/science/article/pii/S1877050919305095⟩](https://www.sciencedirect.com/science/article/pii/S1877050919305095).
- BOURAGA, S. et al. Knowledge-based recommendation systems: A survey. *Int. J. Intell. Inf. Technol.*, v. 10, p. 1–19, 2014.
- BURKE, R. Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, v. 12, 11 2002.
- CONFORTI, R. et al. A recommendation system for predicting risks across multiple business process instances. *Decision Support Systems*, v. 69, p. 1–19, 2015. ISSN 0167-9236. Disponível em: [⟨https://www.sciencedirect.com/science/article/pii/S0167923614002516⟩](https://www.sciencedirect.com/science/article/pii/S0167923614002516).
- CONRY, D.; KOREN, Y.; RAMAKRISHNAN, N. Recommender systems for the conference paper assignment problem. In: *Proceedings of the Third ACM Conference on Recommender Systems*. New York, NY, USA: Association for Computing Machinery, 2009. (RecSys '09), p. 357–360. ISBN 9781605584355. Disponível em: [⟨https://doi.org/10.1145/1639714.1639787⟩](https://doi.org/10.1145/1639714.1639787).
- DAWS, H. Is software licensing costing you £2 million? *ITProPortal*, 2021. Disponível em: [⟨https://www.itproportal.com/features/is-software-licensing-costing-you-pound2-million/⟩](https://www.itproportal.com/features/is-software-licensing-costing-you-pound2-million/).
- ESPM. Big data: tudo o que você precisa saber sobre o assunto. *Propmark*, 07 2021. Disponível em: [⟨https://propmark.com.br/big-data-tudo-o-que-voce-precisa-saber-sobre-o-assunto/⟩](https://propmark.com.br/big-data-tudo-o-que-voce-precisa-saber-sobre-o-assunto/).
- GARTNER. Gartner forecasts worldwide it spending to grow 6.8 % in 2024. 2024. Disponível em: [⟨https://www.gartner.com/en/newsroom/press-releases/01-17-2024-gartner-forecasts-worldwide-it-spending-to-grow-six-point-eight-percent-in-2024#:~:text=Worldwide%20IT%20spending%20is%20expected,quarter's%20forecast%20of%208%25%20growth.⟩](https://www.gartner.com/en/newsroom/press-releases/01-17-2024-gartner-forecasts-worldwide-it-spending-to-grow-six-point-eight-percent-in-2024#:~:text=Worldwide%20IT%20spending%20is%20expected,quarter's%20forecast%20of%208%25%20growth.)
- GUPTA, A. et al. Practical design of performant recommender systems using large-scale linear programming-based global inference. In: *Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. New York, NY, USA: Association for Computing Machinery, 2023. (KDD '23), p. 5781–5782. ISBN 9798400701030. Disponível em: [⟨https://doi.org/10.1145/3580305.3599183⟩](https://doi.org/10.1145/3580305.3599183).
- HILLIER, F. S.; LIEBERMAN, G. J. *Introduction to operations research*. [S.l.]: McGraw-Hill, 2015.

IBM. Covid-19 and the future of business. 2020. Disponível em: <https://www.ibm.com/thought-leadership/institute-business-value/report/covid-19-future-business#>.

KIZILCEC, R. F. How much information? effects of transparency on trust in an algorithmic interface. In: *Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems*. New York, NY, USA: Association for Computing Machinery, 2016. (CHI '16), p. 2390–2395. ISBN 9781450333627. Disponível em: <https://doi.org/10.1145/2858036.2858402>.

LEE, C.-R. et al. Development of organic material recommendation system for organic rice using linear programming. *Journal of Korean Society of Agricultural Engineers*, v. 61, n. 2, p. 121–130, 2019.

MICROSOFT; GROUP, T. E. Transformation imperative. 2021. Disponível em: <https://transformationimperative.economist.com/executive-summary/>.

PARAMESWARAN, A.; VENETIS, P.; GARCIA-MOLINA, H. Recommendation systems with complex constraints: A course recommendation perspective. *ACM Trans. Inf. Syst.*, Association for Computing Machinery, New York, NY, USA, v. 29, n. 4, dec 2011. ISSN 1046-8188. Disponível em: <https://doi.org/10.1145/2037661.2037665>.

PRADO, D. *Programação linear*. [S.l.]: Falconi Editora, 2016. v. 1.

SINGH, P. et al. Recommender systems: An overview, research trends, and future directions. *International Journal of Business and Systems Research*, v. 15, p. 14–52, 01 2021.

SNOW. *Snow Inventory Agents and Oracle Scanners*. 2024. <https://docs.snowsoftware.com/snow-inventory-agents-and-oracle-scanners/en/index-en.html>. Acessado em: Junho 2, 2024.

VERBERT, K. et al. Visualizing recommendations to support exploration, transparency and controllability. In: . [S.l.: s.n.], 2013. p. 351–362. ISBN 9781450319652.

VORM, E.; MILLER, A. Assessing the value of transparency in recommender systems: An end-user perspective. In: . [S.l.: s.n.], 2018.

WINSTON, W. L. *Operations research: applications and algorithm*. [S.l.]: Thomson Learning, Inc., 2004.

ZHAO, Y.; YANG, L. Constrained contextual bandit algorithm for limited-budget recommendation system. *Engineering Applications of Artificial Intelligence*, v. 128, p. 107558, 2024. ISSN 0952-1976. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0952197623017426>.