



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

RICARDO ERALDO DE SANTANA

**FAVORECENDO A APRENDIZAGEM COLABORATIVA EM PBL: uma
Solução Automatizada para Formação de Equipes de Estudantes Baseada em
Semântica de Grupos**

Recife

2025

RICARDO ERALDO DE SANTANA

**FAVORECENDO A APRENDIZAGEM COLABORATIVA EM PBL: uma
Solução Automatizada para Formação de Equipes de Estudantes Baseada em
Semântica de Grupos**

Dissertação de Mestrado apresentada ao
Programa de Pós-graduação em Ciência da
Computação do Centro de Informática da
Universidade Federal de Pernambuco,
como requisito parcial para obtenção do
título de Mestre em Ciência da Computação.
Área de Concentração: Engenharia de
Software e Sistemas

Orientadora: Profa. Dra. Simone Cristiane dos Santos Lima

Recife

2025

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Santana, Ricardo Eraldo de.

Favorecendo a aprendizagem colaborativa em PBL: uma solução automatizada para formação de equipes de estudantes baseada em semântica de grupos / Ricardo Eraldo de Santana. - Recife, 2025.
126f.: il.

Dissertação (Mestrado)- Universidade Federal de Pernambuco, Centro de Informática, Programa de Pós-Graduação em Ciência da Computação, 2025.

Orientação: Simone Cristiane dos Santos Lima.

1. Ensino Superior de Computação; 2. PBL; 3. Aprendizagem colaborativa; 4. Formação de equipes; 5. Web Semântica. I. Lima, Simone Cristiane dos Santos. II. Título.

UFPE-Biblioteca Central

Ricardo Eraldo de Santana

“Favorecendo a Aprendizagem Colaborativa em PBL: uma Solução Automatizada para Formação de Equipes de Estudantes Baseada em Semântica de Grupos”

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Ciência da Computação do Centro de Informática da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de Mestre em Ciência da Computação.

Aprovada em: 18/06/2025.

BANCA EXAMINADORA

Profa. Dra. Jessyka Flavyanne Ferreira Vilela
Centro de Informática / UFPE

Prof. Dr. Daniel Schneider
Instituto Tércio Pacitti de Aplicações e Pesquisas
Computacionais / UFRJ

Profa. Dra. Simone Cristiane dos Santos Lima
Centro de Informática / UFPE
(orientadora)

Dedico este trabalho, primeiramente, a Deus, por me conceder força, sabedoria e perseverança ao longo desta jornada. À minha esposa, pelo amor, apoio incondicional e compreensão nos momentos mais desafiadores. Aos meus pais, pelo exemplo de dedicação, pelos valores transmitidos e por sempre acreditarem em mim. E a toda minha família, pelo carinho, incentivo e presença constante, que foram fundamentais para a realização desta conquista.

AGRADECIMENTOS

Agradeço, primeiramente, a **Deus**, por me conceder saúde, sabedoria e forças nos momentos mais difíceis, guiando cada passo dessa caminhada.

À minha esposa **Kaliny**, pelo amor, paciência, incentivo constante e por estar ao meu lado em todos os momentos — nos bons e especialmente nos desafiadores. Nada disso teria o mesmo significado sem você.

Aos meus pais, **Josefa e Eraldo**, por todo o amor, educação, valores e por acreditarem em mim desde sempre. Vocês são minha base e minha inspiração diária.

À minha família e amigos, pelo apoio emocional, palavras de encorajamento e por celebrarem cada pequena vitória comigo ao longo dessa trajetória.

À minha professora e orientadora **Simone Santos**, minha gratidão por todo o apoio, paciência e dedicação ao longo desta caminhada. Sua orientação firme, mas sempre generosa, foi essencial para o amadurecimento deste trabalho e para o meu crescimento pessoal e acadêmico. Obrigado por me guiar com sabedoria e por acreditar no meu potencial, mesmo nos momentos em que eu duvidei.

Aos integrantes do **NEXT Research Group**, em especial àqueles com quem tive o privilégio de conviver mais de perto durante essa jornada (**Davi Maia, André Ribeiro, Pedro Falcão, Esdras Bispo Jr. e Thaise Neri**), obrigado pelas trocas, colaborações e companheirismo. Cada contribuição foi essencial para que esta pesquisa se concretizasse.

Agradeço aos professores **Jessyka Vilela** e **Daniel Schneider** pela participação na banca e pelas excelentes contribuições.

Ao corpo docente e técnico do CIn, pelo acolhimento, suporte e pela excelência que fazem dessa instituição um lugar de aprendizado e crescimento excepcionais.

E, finalmente, a todos que, de forma direta ou indireta, contribuíram para a conclusão desta etapa da minha vida: meu sincero e profundo agradecimento.

Muito obrigado!

RESUMO

O PBL (*Problem-Based Learning*) é um modelo pedagógico que promove o desenvolvimento de competências profissionais (conhecimentos, habilidades e atitudes) para resolução de problemas por meio da aprendizagem colaborativa alcançada no trabalho em equipes. Esse modelo tem se mostrado bastante adequado ao ensino superior de computação, considerando que soluções tecnológicas para problemas complexos são desenvolvidas por equipes de profissionais de tecnologia com conhecimentos e habilidades diversas e complementares. Nesse contexto, a formação efetiva de equipes é essencial para o sucesso do PBL, pois pode potencializar o aprendizado e o desenvolvimento dos estudantes. A formação de equipes utilizando o PBL envolve esforço e observação de diversos aspectos, o que torna o agrupamento manual custoso na formatação de equipes equilibradas. Além disso, tanto o instrutor quanto o estudante podem participar do processo de decisão de agrupamento, considerando as restrições definidas pelo instrutor e a satisfação do estudante com as recomendações feitas, em geral, associadas a afinidades com seus colegas. Nesse sentido, ao utilizar uma abordagem automatizada que considere esses critérios, atributos dos estudantes e afinidades, é possível agilizar o processo de estruturação de equipes balanceadas entre si e aumentar o potencial de sucesso. Motivado por esse propósito, este estudo considera a seguinte questão de pesquisa: QP) No contexto do ensino superior de computação com PBL, como equipes balanceadas podem ser formadas automaticamente, considerando critérios, atributos e afinidades pré-definidos entre seus membros? Para responder essa questão, este estudo propõe uma solução automatizada para formação de equipes de estudantes utilizando o método DSR (*Design Science Research*) aplicado em ciclos evolutivos. Esta solução considera múltiplos atributos dos indivíduos envolvidos, critérios do organizador para divisão das equipes e afinidades entre seus membros, usando uma estrutura semântica para formação de equipes. Protótipos do sistema foram criados e avaliados ao longo dos ciclos de DSR para avaliar a proposta, demonstrando conformidade com as restrições definidas e indicação de equipes balanceadas. Os resultados obtidos indicaram correlações positivas entre o balanceamento das restrições e o desempenho das equipes, reforçando a relevância da solução automatizada para a formação de equipes mais eficazes no contexto do PBL.

Palavras-chave: Ensino Superior de Computação, PBL, Aprendizagem Colaborativa, Formação de Equipes, Web Semântica.

ABSTRACT

PBL (Problem-Based Learning) is a pedagogical model that promotes the development of professional competencies (knowledge, skills, and attitudes) for problem-solving through collaborative learning achieved in team-based work. This model has proven to be highly suitable for higher education in computing, considering that technological solutions to complex problems are developed by teams of technology professionals with diverse and complementary knowledge and skills. In this context, effective team formation is essential for the success of PBL, as it can enhance student learning and development. Team formation using PBL involves effort and observation of various aspects, making manual grouping inefficient in creating balanced groups. Furthermore, both the instructor and the student can participate in the grouping decision-making process, considering the constraints defined by the instructor and the student's satisfaction with the recommendations, which are generally associated with affinities with their peers. In this regard, by using an automated approach that considers these criteria, student attributes, and affinities, it is possible to streamline the process of structuring balanced teams and mitigate the formation of teams with low potential for success. Motivated by this purpose, this study addresses the following research question: RQ) In the context of higher education in computing with PBL, how can balanced teams be automatically formed, considering predefined criteria, attributes, and affinities among their members? To answer this question, this study proposes an automated solution for forming student teams using the DSR (Design Science Research) method applied in evolutionary cycles. This solution considers multiple attributes of the individuals involved, organizer-defined criteria for team division, and affinities among members, using a semantic structure for team formation. System prototypes were created and evaluated throughout DSR cycles to assess the proposal, demonstrating compliance with the defined constraints and indicating balanced teams. The results obtained showed positive correlations between the balancing of constraints and group performance, reinforcing the relevance of the automated solution for creating more effective teams in the context of PBL.

Keywords: Computing Higher Education, PBL, Collaborative Learning, Group Formation, Web-semantics.

LISTA DE FIGURAS

Figura 1 - Distribuição de gênero por curso de TI em 2021 no Brasil	34
Figura 2 - Esquema metodológico	45
Figura 3 - Processo de Formação de Equipes.....	60
Figura 4 - Interface do xPBL Teams	67
Figura 5 - Impressão de PDF da formação das equipes.....	68
Figura 6 - Impressão em CSV de cada equipe	68
Figura 7 – Funcionalidade de upload.....	71
Figura 8 – Configuração de parâmetros	71
Figura 9 – Exemplo Formação de Equipes.....	72
Figura 10 - Desempenho: Resultado (Turma 1)	96
Figura 11 - Desempenho: Processo (Turma 1).....	96
Figura 12 - Desempenho: Satisfação do Cliente (Turma 1).....	97
Figura 13 - Desempenho: Resultado (Turma 2)	98
Figura 14 - Desempenho: Processo (Turma 2).....	99
Figura 15 - Desempenho: Satisfação do Cliente (Turma 2).....	100
Figura 16 - Desempenho: Resultado (Turma 3)	101
Figura 17 - Desempenho: Processo (Turma 3).....	102
Figura 18 - Desempenho: Satisfação do Cliente (Turma 3).....	103

LISTA DE TABELA E QUADROS

Tabela 1 - Perfil dos estudantes da 1 ^a turma.....	78
Tabela 2 - Perfil da Turma 2	84
Tabela 3 - Perfil da Turma 3	89
Tabela 4 - Coeficiente de Spearman: Turma 1 - Resultado.....	105
Tabela 5 - Coeficiente de Spearman: Turma 2 - Resultado.....	105
Tabela 6 - Coeficiente de Spearman: Turma 3 - Resultado.....	106
Tabela 7 - Coeficiente de Spearman: Turma 1 - Processo	107
Tabela 8 - Coeficiente de Spearman: Turma 2 - Processo	108
Tabela 9 - Coeficiente de Spearman: Turma 3 - Processo	108
Tabela 10 - Coeficiente de Spearman: Turma 1 - Satisfação do cliente	110
Tabela 11 - Coeficiente de Spearman: Turma 2 - Satisfação do cliente	110
Tabela 12 - Coeficiente de Spearman: Turma 3 - Satisfação do cliente	111
Quadro 1 - Comparativo De Estudos Relacionados	39
Quadro 2 - Critérios para Formação de Equipes	59
Quadro 3 - Requisitos Funcionais e Não Funcionais do xPBL Teams	62
Quadro 4 - Formato do Arquivo CSV de Entrada para o xPBL Teams	69
Quadro 5 - Dados dos estudantes da Turma 1	76
Quadro 6 - Verificação da satisfação das restrições no Ciclo 1.....	79
Quadro 7 - Dados dos estudantes da Turma 2	80
Quadro 8 - Verificação da satisfação das restrições no Ciclo 2.....	85
Quadro 9 - Dados dos estudantes da Turma 3	87
Quadro 10 - Verificação da satisfação das restrições no Ciclo 3	90

LISTA DE SIGLAS

CIN Centro de Informática

DSR *Design Science Research*

N.E.X.T. *iNnovative Educational eXperience in Technology*

PBL *Problem-Based Learning*

SUMÁRIO

1 INTRODUÇÃO	16
1.1 CONTEXTO.....	16
1.2 MOTIVAÇÃO	18
1.3 JUSTIFICATIVA	20
1.4 OBJETIVOS DA PESQUISA.....	21
1.5 ORGANIZAÇÃO DO TRABALHO	23
2. PRINCIPAIS REFERENCIAIS TEÓRICOS	25
2.1 PBL NO ENSINO DE COMPUTAÇÃO.....	25
2.2 FORMAÇÃO DE EQUIPES EM AMBIENTES PBL	27
2.3 DIMENSÕES NA FORMAÇÃO DE EQUIPES	28
2.3.1 Dimensão: Tamanho da equipe	29
2.3.2 Dimensão: Personalidade	30
2.3.3 Dimensão: Experiência profissional	32
2.3.4 Dimensão: Gênero	33
2.3.5 Dimensão: Afinidade	36
2.4 TRABALHOS RELACIONADOS	37
3. METODOLOGIA.....	43
3.1. DEFINIÇÃO DO PROBLEMA	45
3.1.1 Atividade 1: Identificação do problema	45
3.1.2 Atividade 2: Revisão não sistemática da literatura.....	45
3.1.3 Atividade 3: Levantamento de requisitos	46
3.1.4 Atividade 4: Delimitação do problema.....	46
3.1.5 Atividade 5: Definição dos objetivos da pesquisa	47
3.2. CICLOS DSR.....	47

3.2.1 Ciclo DSR 1: Ciclo de concepção e algoritmo inicial.....	49
3.2.2 Ciclo DSR 2: Ciclo de evolução do algoritmo.....	51
3.2.3 Ciclo DSR 3: Ciclo de interface da solução.....	54
3.3. RESULTADOS DA PESQUISA.....	56
3.3.1 Análise de Dados	56
3.3.2 Resultados e Discussões.....	57
3.3.3 Conclusões	57
4. xPBL TEAMS: UMA SOLUÇÃO DE FORMAÇÃO DE EQUIPES	58
4.1 CONCEPÇÃO E FUNDAMENTAÇÃO	58
4.2 REQUISITOS DA SOLUÇÃO.....	62
4.3 ARQUITETURA DA SOLUÇÃO.....	64
4.3.1 Tecnologias Empregadas	65
4.4 INTERFACE E OPERACIONALIZAÇÃO DO xPBL TEAMS	66
4.4.1 Visão Geral da Interface Gráfica (Streamlit)	66
4.4.2 Principais Funcionalidades e Telas.....	68
4.4.3 Exemplo Prático de Utilização (Passo a Passo)	73
5. RESULTADOS E DISCUSSÕES	75
5.1 EXPERIMENTOS DE FORMAÇÃO DE EQUIPES.....	75
5.1.1 Ciclo DSR 1	75
5.1.2 Ciclo DSR 2	80
5.1.3 Ciclo DSR 3	86
5.2 ANÁLISE ESTATÍSTICA DA INFLUÊNCIA DA FORMAÇÃO DE EQUIPES NO DESEMPENHO DOS ESTUDANTES.....	92
5.2.1 Método Estatístico Utilizado: Correlação de Spearman	92
5.2.2 Os gráficos de desempenhos	94
5.2.3 Relação entre o Balanceamento dos Times e o Desempenho Apresentado	

.....	103
5.3. DISCUSSÕES DOS RESULTADOS ENCONTRADOS	112
6. CONCLUSÕES	116
6.1 LIMITAÇÕES E AMEAÇAS À VALIDADE.....	117
6.2 CONTRIBUIÇÕES DA PESQUISA	119
6.3 IMPLICAÇÕES DO TRABALHO.....	120
6.4 TRABALHOS FUTUROS	121
REFERÊNCIAS	123

1 INTRODUÇÃO

Este capítulo apresenta as características gerais do tema desta pesquisa, seu contexto, motivação, justificativa e objetivos, evidenciando a importância e necessidade da automatização do processo de formação de equipes no modelo PBL dentro da educação em computação.

1.1 CONTEXTO

O *Problem-Based Learning* (PBL) é um modelo de ensino que, ao contrário do modelo tradicional, tem como princípio norteador a apresentação de problemas práticos e contextualizados da vida real para fomentar o processo de aprendizagem (BARROWS, 1996). Seu principal objetivo é deslocar o estudante de uma postura passiva para um papel mais protagonista no processo educativo. Nessa perspectiva, o professor assume o papel de mediador, criando um ambiente propício à descoberta, à investigação e à construção do conhecimento por parte dos estudantes (SEI PLATAFORMA EDUCACIONAL, 2019).

Embora tenha suas origens na área da Medicina, o PBL rapidamente se expandiu para outros campos do conhecimento, como a Administração e a Computação (SOUZA, 2010). Isso se deve ao fato de que o método não se restringe a conteúdos específicos, mas sim à forma como o conhecimento é construído (BARROWS, 1996).

A formação de profissionais na área da computação, como os cursos de Ciência da Computação, Engenharia de Software ou Sistemas de Informação, precisa estar alinhada às exigências do mercado de trabalho, onde a atuação em equipe é não apenas comum, mas essencial. Projetos de software, desenvolvimento de sistemas e soluções tecnológicas, em geral, são frequentemente construídos por equipes multidisciplinares, nas quais, a colaboração entre diferentes especialistas contribui para a qualidade, eficiência e inovação dos produtos desenvolvidos (SALAS; COOKE; ROSEN, 2008). Trabalhar de forma colaborativa permite a divisão inteligente de tarefas, o compartilhamento de conhecimentos e a construção conjunta de soluções mais robustas. Por isso, disciplinas práticas nesses cursos devem adotar metodologias que incentivem o trabalho em equipe e a aprendizagem entre pares.

Nesse cenário, o uso do PBL tem se mostrado eficaz, ao proporcionar um

ambiente de aprendizagem ativa, centrado no estudante, em que o conhecimento é construído por meio da resolução de problemas contextualizados e da interação entre os colegas, simulando as dinâmicas reais do mercado de trabalho (SAVERY & DUFFY, 1995).

Além dos benefícios teóricos e comportamentais promovidos pelo PBL, experiências práticas de sua aplicação também evidenciam resultados positivos em contextos educacionais diversos. Em um relato de experiência da Universidade de São Paulo (USP), apresentado por Estevão Filho e Ribeiro (2009), o modelo foi implementado com um sistema de avaliação que combinava autoavaliação, avaliação pelos pares e pelo professor, por meio de provas e apresentações. Essa abordagem foi bem recebida pela maioria dos estudantes, que ressaltaram aspectos positivos como a diversidade dos instrumentos de avaliação e sua capacidade de abranger diferentes dimensões do aprendizado, desde seminários e conceitos teóricos até habilidades práticas, como o trabalho em equipe. Além disso, os estudantes demonstraram confiança na própria responsabilidade e competência para avaliar seu desempenho e o dos colegas, o que fortalece o senso de autonomia e corresponsabilidade. Outro ponto relevante foi o uso da avaliação como ferramenta de retroalimentação, contribuindo para o aprimoramento não apenas da aprendizagem individual, mas também da metodologia de ensino e da disciplina como um todo. Esses dados evidenciam que o PBL promove uma aprendizagem mais ampla, crítica e colaborativa, com impacto positivo na formação discente.

Outro aspecto relevante do PBL é sua contribuição para a redução da evasão escolar. Por ser uma abordagem prática, que conecta teoria e aplicação real, o PBL aumenta o engajamento dos estudantes e facilita a identificação precoce de afinidade (ou não) com a área profissional escolhida (RIBEIRO, 2008). Assim, o estudante tem mais subsídios para reavaliar sua trajetória acadêmica antes de comprometer tempo e recursos com uma formação que não atende às suas expectativas ou habilidades.

Um dos pilares fundamentais do PBL é o trabalho em equipe. A aprendizagem colaborativa é central nesse modelo, pois a resolução de problemas complexos geralmente exige a articulação de diferentes saberes, perspectivas e experiências. A formação de equipes no PBL não é apenas uma questão organizacional, mas sim uma dimensão pedagógica essencial (FONTEIJN; DOLMANS, 2019). A dinâmica de grupo contribui não apenas para o avanço cognitivo dos indivíduos, mas também para o desenvolvimento de habilidades sociais e emocionais, como empatia, comunicação,

liderança e resolução de conflitos.

Fonteijn e Dolmans (2019) destacam que o desempenho de um time em contextos baseados em PBL depende de fatores diversos, que vão além das capacidades cognitivas dos estudantes. Aspectos como o tamanho da equipe, a diversidade de perfis, as experiências prévias e as habilidades interpessoais influenciam diretamente a sua efetividade. A pressão positiva entre os membros também se mostra um elemento motivador importante, uma vez que o sucesso individual está diretamente ligado ao sucesso coletivo. Nesse modelo, “para um estudante ter sucesso, o grupo deve ter sucesso” (FONTEIJN; DOLMANS, 2019, p. 199).

Desse modo, a formação de equipes torna-se uma etapa estratégica no processo de ensino-aprendizagem por PBL. A adequada composição das equipes pode ser decisiva para o alcance dos objetivos educacionais, reforçando a importância do olhar atento do professor, não apenas para os conteúdos trabalhados, mas também para as relações que se estabelecem entre os estudantes (FONTEIJN & DOLMANS, 2019).

Em síntese, o uso do PBL na educação em computação representa uma oportunidade de alinhar o ensino superior às demandas contemporâneas, tanto no aspecto técnico, quanto no desenvolvimento de competências humanas. A ênfase na resolução de problemas reais, no uso de tecnologias digitais e no trabalho colaborativo torna essa abordagem especialmente adequada para formar profissionais preparados para os desafios da sociedade digital. Nesse contexto, a formação de equipes é um aspecto fundamental para o sucesso do PBL.

1.2 MOTIVAÇÃO

Segundo Fonteijn e Dolmans (2019), as pequenas equipes, bem como o trabalho realizado nelas, são parte fundamental do PBL, uma vez que essas equipes são o núcleo onde as atividades de resolução de problemas são realizadas e seu foco principal é a aprendizagem do estudante. Nessas interações, os estudantes desenvolvem, individualmente e em equipes, conhecimentos, habilidades e atitudes, como habilidades socioemocionais e qualidades motivacionais, além de sua expertise técnica e do networking proporcionado nessas interações.

Para desenvolver esse conjunto de atributos, é essencial que a formação das

equipes em contextos de PBL seja conduzida de forma rigorosa e bem estruturada, contemplando diversas dimensões. É importante conhecer cada uma delas, bem como sua aderência ao processo de formação de equipes em PBL.

No processo de formação de equipes, especialmente em contextos educacionais como o do PBL, é fundamental considerar diversas dimensões que influenciam diretamente o desempenho, a colaboração e os resultados obtidos pelos grupos. Fatores como o tamanho da equipe, a personalidade dos membros, a experiência prévia com trabalho em grupo, as habilidades cognitivas, as preferências de trabalho, a diversidade sociocultural e a afinidade entre os participantes devem ser cuidadosamente analisados para a constituição de equipes equilibradas e eficazes. Essas dimensões serão detalhadas no Capítulo 2, Seção 2.3.

Diante de tantas variáveis que podem influenciar para o sucesso da equipe (FONTEIJN; DOLMANS, 2019), a formação de equipes utilizando o PBL envolve esforço e observação de diversos aspectos, o que torna o agrupamento manual muito trabalhoso e possivelmente ineficiente na construção de equipes equilibradas (Ounnas, 2010). Além disso, Ounnas sugere ainda que o instrutor e o estudante podem participar do processo de decisão de agrupamento, considerando as restrições definidas pelo instrutor e a satisfação do estudante com as recomendações feitas.

A formação de equipes balanceadas em contextos de PBL requer atenção tanto à heterogeneidade dentro das equipes quanto à homogeneidade entre elas. Conforme defendido por Wang et al. (2007), grupos eficazes devem apresentar diversidade interna, com diferentes estilos de pensamento e perfis psicológicos, ao mesmo tempo em que se busca um equilíbrio global entre os grupos formados, promovendo justiça e equidade. Essa configuração favorece a complementaridade nas equipes e enriquece o ambiente de aprendizagem colaborativa.

Entretanto, considerar múltiplas variáveis, como estilos cognitivos, habilidades e perfis de personalidade, torna o processo de formação manual altamente complexo, especialmente em turmas grandes. Wang et al. (2007) destacam que quanto mais variáveis são consideradas, mais difícil se torna realizar esse agrupamento de forma precisa e eficiente. Nesse sentido, a automação se mostra uma solução viável e necessária, pois os algoritmos podem lidar com múltiplos critérios simultaneamente, otimizando a criação de grupos平衡ados com maior rapidez e menor carga de trabalho para o docente.

Segundo Wang et al. (2007), quando esses critérios são negligenciados, há um

risco real de formação de equipes com baixo potencial de colaboração e desempenho.

Apesar de Webb (1989) destacar os desafios enfrentados por grupos excessivamente heterogêneos, que podem sofrer com diferenças extremas entre os membros, prejudicando a cooperação e a dinâmica interna. Diversos outros trabalhos vão de encontro a essa proposta.

Moreno, Ovalle e Vicari (2012), afirmam que o ideal é formar grupos o mais semelhantes possível entre si (inter-homogêneos), maximizando as diferenças individuais dos alunos dentro desses grupos (intra-heterogêneos).

Com base na tese de Ounnas (2010), a heterogeneidade é apresentada como um fator importante e benéfico na aprendizagem colaborativa e cooperativa. Citando pesquisas da área, o trabalho destaca que a formação de grupos heterogêneos pode promover resultados sociais positivos, como a melhoria das relações entre colegas, o aumento da tolerância e a promoção da compreensão intercultural, além de benefícios acadêmicos como a tutoria entre alunos. Essa abordagem pode ser implementada com base em diversos critérios, como proficiência, etnia ou gênero.

Assim, a abordagem de balanceamento de equipes baseada na heterogeneidade entre seus membros foi a adotada no presente trabalho, no qual critérios como perfis de personalidade, experiência profissional e afinidades foram considerados para criar grupos equilibrados, promovendo equipes suficientemente diversas para fomentar múltiplas perspectivas, mas também coesas para garantir uma dinâmica interna colaborativa e produtiva.

Nesse sentido, ao utilizar uma abordagem automatizada que considere esses critérios e possibilidades de formação de equipes, é possível agilizar o processo de estruturação e aumentar o potencial de sucesso.

1.3 JUSTIFICATIVA

A formação de equipes é uma etapa essencial em ambientes de aprendizagem colaborativa, especialmente no PBL, onde a qualidade das interações entre os membros influencia diretamente o desenvolvimento da aprendizagem. No entanto, atribuir manualmente os integrantes aos grupos pode ser um processo altamente complexo e demorado. Na disciplina de Sistemas de Gestão Empresarial (SGE), onde foi aplicada a solução desenvolvida neste trabalho, a professora responsável pela disciplina frequentemente gastava entre 2 e 3 horas para formar equipes utilizando

todos os critérios necessários, como diversidade de perfis, experiência profissional, afinidades e preferências de trabalho dos estudantes. Esse esforço prolongado não apenas consumia tempo valioso da docente, mas também aumentava o risco de escolhas subjetivas ou inconsistentes, comprometendo o balanceamento dos grupos e, consequentemente, o potencial de sucesso das equipes.

Diversos estudos propuseram algoritmos para apoiar a formação de equipes em contextos educacionais (Ounnas, 2010; Wang et al., 2007; Moreno, Ovalle e Vicari, 2012). Trabalhos como os de Reis et al. (2020), Isotani et al. (2009), Ounnas (2010) e Chen e Kuo (2019), incorporam aspectos como traços de personalidade, habilidades, interesses e papéis de aprendizagem na composição dos grupos. Ainda que relevantes, essas abordagens não atendem plenamente às particularidades do PBL ou não oferecem flexibilidade suficiente para adaptação a diferentes domínios e objetivos pedagógicos.

Diante desse cenário, torna-se evidente a necessidade de automatização com base em critérios pedagógicos consistentes. Uma solução automatizada pode não apenas reduzir o tempo e o esforço demandados pelo organizador das equipes, mas também garantir maior precisão na aplicação dos critérios, promovendo equipes mais equilibradas e alinhadas com os princípios do PBL. Além disso, uma abordagem automatizada deve permitir ao professor definir múltiplos critérios de agrupamento e ajustar seus níveis de prioridade conforme as necessidades específicas da turma. Tal solução visa aumentar a eficácia das interações colaborativas, potencializar os resultados da aprendizagem e otimizar o processo de formação de equipes no contexto do PBL.

1.4 OBJETIVOS DA PESQUISA

A formação de equipes utilizando o modelo PBL requer esforço e atenção a múltiplos aspectos, como diversidade de perfis, afinidades entre os participantes e experiência profissional, o que torna o agrupamento manual um processo altamente complexo e demandante de tempo e dedicação para garantir a criação de grupos equilibrados e eficazes. Além disso, Ounnas (2010) sugere que o instrutor e o estudante podem participar do processo de decisão de agrupamento, considerando as restrições definidas pelo instrutor e a satisfação do discente com as recomendações feitas. Ao utilizar uma abordagem automatizada que considere esses

critérios e possibilidades de formação de equipes, é possível tornar o processo de estruturação mais ágil e facilitar a obtenção de equipes com baixo potencial de sucesso.

Nesse sentido, este estudo foi motivado pela seguinte questão central de pesquisa:

QP) No contexto do ensino superior de computação com PBL, como equipes balanceadas podem ser formadas automaticamente, considerando critérios, atributos e afinidades pré-definidos entre seus membros?

O objetivo geral da pesquisa é propor uma solução automatizada para a formação de equipes balanceadas no ensino superior de computação com PBL, considerando critérios, atributos e afinidades pré-definidos entre seus membros. A necessidade desta solução surge da dificuldade e demora do agrupamento manual em formar grupos equilibrados, dado o esforço e a observação de diversos aspectos que o modelo PBL exige.

Para alcançar esse objetivo geral, a pesquisa se concentra em quatro objetivos específicos:

- OE1: reduzir a dificuldade e o tempo na formação de equipes, automatizando o processo de seleção e agrupamento dos estudantes. O sistema proposto busca otimizar o processo, eliminando a necessidade de procedimentos manuais trabalhosos, permitindo que o professor se concentre em outros aspectos importantes do ensino.
- OE2: Desenvolver um sistema que incorpore critérios e atributos específicos para a formação de equipes, permitindo a participação tanto do instrutor quanto do estudante no processo de decisão de agrupamento. O sistema deve atender às restrições definidas pelo instrutor e levar em conta a satisfação do estudante com as recomendações feitas, promovendo um ambiente de colaboração positivo e equilibrado em termos de habilidades e características. A personalização dos critérios, como personalidade (MBTI) (MYERS & BRIGGS FOUNDATION, 2021), gênero, experiência profissional e afinidades, possibilita a criação de grupos mais heterogêneos e com maior potencial de sucesso.
- OE3: Analisar o sistema desenvolvido quanto ao cumprimento dos critérios de restrição e ao desempenho das equipes, por meio de uma abordagem quantitativa referente à correlação entre o nível de atendimento aos requisitos e os resultados obtidos em três dimensões coletivas: Resultado, Processo e

Satisfação do Cliente.

A pesquisa se baseia na premissa de que a formação de equipes eficazes é crucial para o sucesso do PBL, uma vez que grupos bem estruturados podem melhorar o aprendizado dos estudantes e o desenvolvimento de habilidades importantes. A solução automatizada proposta busca, portanto, otimizar esse processo, contribuindo para a eficácia da abordagem de ensino.

1.5 ORGANIZAÇÃO DO TRABALHO

O trabalho é dividido em seis capítulos distribuídos conforme descrito a seguir.

O Capítulo 2, "Principais Referenciais Teóricos", aborda a importância de práticas essenciais para a aplicação do PBL no ensino de computação, com ênfase na formação de equipes e no papel da automação. O texto mostra como o PBL não só conecta teoria e prática, mas também ajuda os estudantes a desenvolverem habilidades valiosas para sua vida profissional. Além disso, reforça que equipes bem estruturadas fazem toda a diferença, destacando como a diversidade, as afinidades entre os membros e um bom equilíbrio são fundamentais para o sucesso. A automação surge como uma aliada nesse processo, tornando a formação de equipes mais ágil, personalizada e eficiente. Por fim, o capítulo traz exemplos e reflexões de estudos acadêmicos, evidenciando como a tecnologia pode fortalecer a colaboração e enriquecer o aprendizado dos estudantes.

O Capítulo 3 apresenta a metodologia adotada para o desenvolvimento do estudo, fundamentada no método *Design Science Research* (DSR) (Weringa, 2014). Essa abordagem combina características qualitativas e exploratórias, utilizando dados reais de turmas de computação do ensino superior para avaliar a solução proposta. O processo é detalhado em etapas bem definidas, desde o levantamento de literatura e análise de modelos existentes até o desenvolvimento e avaliação de algoritmos. A metodologia busca, de forma estruturada e iterativa, identificar desafios, propor melhorias e criar uma solução eficiente para a formação de equipes no contexto do PBL. Além disso, a pesquisa considera tanto as melhores práticas quanto as limitações dos modelos atuais, utilizando dados concretos para alinhar teoria e prática, garantindo relevância e aplicabilidade ao contexto educacional.

O Capítulo 4 apresenta o sistema proposto, chamado de *xPBL Teams*, uma solução projetada para automatizar a formação de equipes em ambientes

educacionais baseados no modelo PBL. Inicialmente, descreve-se o modelo conceitual, fundamentado em referências do estado da arte e em abordagens discutidas no Capítulo 2. Esse modelo considera aspectos como diversidade, afinidades entre os participantes e equilíbrio nas habilidades, com o objetivo de maximizar o desempenho das equipes. Em seguida, detalha-se a implementação do sistema, explicando os algoritmos e as tecnologias utilizadas para garantir a eficácia da solução.

O Capítulo 5 concentra-se nos resultados e discussões, apresentando um panorama abrangente sobre a eficácia da solução apresentada. Inicialmente, descrevem-se os experimentos realizados para formar equipes, destacando os critérios e métricas adotados para avaliação. Por fim, o capítulo promove uma discussão detalhada sobre os resultados encontrados, considerando tanto os benefícios quanto os desafios identificados durante a aplicação prática da solução.

Por fim, o Capítulo 6 descreve as Conclusões, retomando a questão central e os objetivos da pesquisa. O texto reafirma a relevância do *xPBL Teams* como uma ferramenta inovadora para o contexto educacional e destaca suas contribuições para a otimização da formação de equipes. Também são discutidas as limitações da pesquisa, como dependências de dados e possíveis vieses nos critérios utilizados, bem como as ameaças à validade dos resultados. O capítulo conclui apresentando perspectivas para trabalhos futuros, incluindo melhorias na ferramenta, novos testes em contextos variados e a integração de funcionalidades adicionais.

2. PRINCIPAIS REFERENCIAIS TEÓRICOS

Este capítulo visa apresentar os principais referenciais teóricos que fundamentam a presente discussão, abrangendo o PBL no ensino de computação, a formação de equipes, as soluções de automação aplicáveis a este contexto e, por fim, os trabalhos relacionados que envolvem a temática.

2.1 PBL NO ENSINO DE COMPUTAÇÃO

O PBL é um modelo de ensino construtivista centrado no estudante, que promove a construção do conhecimento por meio da resolução de problemas contextualizados (SAVERY & DUFFY, 1995). Originado na década de 1960 na área médica, o PBL foi posteriormente adaptado para diversas disciplinas, incluindo a computação, devido à sua eficácia em desenvolver competências essenciais como pensamento crítico, autonomia e trabalho em equipe (SOUSA, 2010).

No contexto do ensino de computação, o PBL tem se mostrado uma estratégia eficaz para o ensino de algoritmos e conteúdos computacionais. Segundo Souza (2010), a aplicação do PBL em disciplinas introdutórias de computação permitiu aos estudantes desenvolver competências relacionadas à resolução de problemas complexos, integrando teoria e prática de forma mais contextualizada. De maneira semelhante, De Oliveira et al. (2014) relatam que, ao utilizar PBL no ensino de algoritmos e técnicas de programação em cursos de engenharia, foi possível proporcionar uma aprendizagem mais significativa, estimulando a autonomia, o raciocínio lógico e a interdisciplinaridade. No entanto, sua aplicação apresenta desafios específicos que devem ser considerados. Um dos principais desafios é a complexidade dos problemas abordados, que frequentemente exigem que os estudantes lidem com cenários abertos, multidimensionais e altamente técnicos, demandando habilidades avançadas de abstração e análise. Em um estudo conduzido por Suciu, Motogna e Molnar (2023), os autores mostram que, em cursos baseados em projetos no ensino de computação, estudantes enfrentam dificuldades técnicas recorrentes ao lidar com tecnologias novas e problemas abertos, muitas vezes escolhidos por eles mesmos, o que exige autonomia, raciocínio lógico e tomada de decisão. Além disso, o ritmo de trabalho em equipes pode variar significativamente entre os grupos, dificultando o alinhamento de prazos e entregas, especialmente em

turmas grandes, cenário também evidenciado no estudo, que identificou desafios relacionados à sincronização de agendas, organização da equipe e gestão de tempo.

Outro desafio está relacionado ao critério de balanceamento dos times. Na computação, a diversidade de habilidades, como programação, modelagem e gestão de projetos, é essencial para a construção de soluções robustas. Contudo, formar equipes equilibradas que integrem diferentes perfis e níveis de experiência pode ser uma tarefa demorada e sujeita a inconsistências quando realizada manualmente (OUNNAS, DAVIS & MILLARD, 2014).

Além disso, a área de computação possui particularidades que tornam o PBL ainda mais desafiador. Por exemplo, muitos estudantes têm pouca experiência prática prévia e precisam aplicar conceitos teóricos em contextos reais, o que pode gerar dificuldades na transição entre o aprendizado teórico e a prática (BOWMAN et al., 2019). A rápida evolução tecnológica também exige que os problemas propostos estejam atualizados e reflitam as demandas do mercado, o que exige esforço adicional dos docentes na elaboração de atividades.

Apesar desses desafios, o PBL continua sendo uma estratégia eficaz na formação de profissionais mais preparados para os desafios do mercado de trabalho, justamente por promover uma aprendizagem que integra teoria e prática. Conforme destacam Santos et al. (2020), o PBL contribui significativamente para o desenvolvimento de competências essenciais ao exercício profissional, como a capacidade de trabalhar em equipe, resolver problemas complexos, aprender de forma autônoma e agir com ética e respeito à diversidade de perspectivas. Essas habilidades são cada vez mais valorizadas em contextos organizacionais dinâmicos e multidisciplinares, especialmente na área de tecnologia.

Além de contribuir para o desenvolvimento de competências técnicas e interpessoais, o PBL também favorece a interdisciplinaridade e a aplicação prática dos conhecimentos adquiridos. Ao colocar os estudantes diante de problemas reais e abertos, a metodologia possibilita que eles compreendam melhor a relevância dos conteúdos estudados, promovendo uma aprendizagem mais contextualizada e significativa. O PBL oferece um ambiente no qual os estudantes são incentivados a atuar de forma ativa e colaborativa, desenvolvendo habilidades como a aprendizagem autodirigida, a resolução de problemas e o trabalho em equipe (SANTOS et al., 2020). Esse engajamento, por sua vez, contribui diretamente para o aumento da motivação e para uma formação mais alinhada com os desafios da prática profissional na área

de computação.

2.2 FORMAÇÃO DE EQUIPES EM AMBIENTES PBL

O trabalho em equipe é uma das competências centrais desenvolvidas por meio do PBL, especialmente no ensino de Computação. Ao enfrentar desafios complexos e contextualizados, os estudantes precisam colaborar, comunicar-se de forma eficaz e tomar decisões coletivas, habilidades fundamentais para sua futura atuação profissional. Coelho e Guedes (2020), ao realizarem um mapeamento sistemático sobre o uso do PBL no ensino de programação, identificaram que a grande maioria dos estudos enfatiza a relevância do trabalho colaborativo para o sucesso da metodologia. Segundo os autores, o PBL cria um ambiente propício para que os estudantes aprendam não apenas os conteúdos técnicos, mas também desenvolvam competências interpessoais essenciais, como cooperação, escuta ativa e negociação de ideias, capacidades indispensáveis para profissionais da área de tecnologia que atuam em equipes multidisciplinares.

A formação de equipes é um aspecto crucial na implementação eficaz do PBL. A composição adequada dos grupos pode influenciar significativamente o desempenho dos estudantes e a qualidade das soluções desenvolvidas. Além disso, a dinâmica de trabalho em equipe no contexto do PBL contribui para o desenvolvimento de competências socioemocionais, como comunicação, empatia e liderança, que são fundamentais para o sucesso profissional na área de computação.

No entanto, a composição da equipe não se resume apenas ao número de participantes, mas também à diversidade de habilidades e perfis dos integrantes. Como destacam Ferreira et al. (2020), em um grupo homogêneo, espera-se que todos os membros compartilhem os mesmos pontos fortes e fracos, o que acaba por potencializar tanto as qualidades quanto as limitações do grupo. Esse padrão pode limitar a capacidade de enfrentamento de desafios durante a resolução de problemas, uma vez que a falta de diversidade nas habilidades pode dificultar a superação de dificuldades. Em contraste, uma equipe heterogênea oferece uma variedade maior de habilidades e fraquezas, o que permite uma abordagem mais eficaz para lidar com os problemas que surgem ao longo do processo de aprendizagem. Essa diversidade favorece o desenvolvimento de soluções mais criativas e completas, pois os membros do grupo podem complementar uns aos outros, utilizando suas forças em áreas

específicas e compensando as fraquezas de outros, o que é particularmente importante no contexto do modelo PBL, onde a colaboração e a troca de conhecimentos são essenciais.

Contudo, montar equipes com essas características ideais pode ser um desafio para os professores. A formação manual de equipes pode ser desafiadora para os docentes, especialmente em turmas numerosas, devido à complexidade em equilibrar as habilidades, personalidades e preferências dos estudantes. Segundo Felder e Brent (2004), a tarefa de formar equipes eficazes exige tempo e atenção aos detalhes, pois envolve não apenas a distribuição equitativa das habilidades dos membros, mas também a consideração de fatores como compatibilidade de trabalho e motivação. Além disso, Ounnas, Davis e Millard (2014) destacam que, em ambientes de grande escala, essa tarefa pode ser ainda mais complicada pela falta de ferramentas adequadas para garantir a composição ideal dos grupos. Assim, a formação manual de equipes, em contextos de alta demanda, pode tornar-se um processo demorado e propenso a erros, o que pode impactar a qualidade da experiência de aprendizagem.

Nesse cenário, o uso de métodos automatizados ou semiautomatizados para apoiar a formação de equipes pode representar uma solução promissora para otimizar a aprendizagem colaborativa. Essas ferramentas podem considerar diversos critérios, como habilidades técnicas, estilos de aprendizagem e preferências dos estudantes, para formar grupos equilibrados e eficazes (OUNNAS; DAVIS; MILLARD, 2014).

2.3 DIMENSÕES NA FORMAÇÃO DE EQUIPES

No processo de formação de equipes, especialmente em contextos educacionais como o PBL, é fundamental considerar diversas dimensões que influenciam diretamente o desempenho, a colaboração e os resultados obtidos pelas equipes. Fatores como o tamanho da equipe, a personalidade dos membros, a experiência prévia com trabalho em grupo, as habilidades cognitivas, as preferências de trabalho, a diversidade sociocultural e a afinidade entre os participantes devem ser cuidadosamente analisados para a constituição de equipes equilibradas e eficazes. A seguir, são explorados essas dimensões e seus impactos na dinâmica e produtividade das equipes.

2.3.1 Dimensão: Tamanho da equipe

Segundo Fonteijn & Dolmans (2019), o tamanho ideal dos grupos em contextos PBL é uma questão crucial, pois impacta diretamente a eficácia das interações e o desenvolvimento das habilidades colaborativas dos estudantes.

Embora o valor exato do tamanho ideal possa variar conforme o contexto, autores como Fonteijn & Dolmans (2019) recomendam a formação de equipes com 5 a 6 estudantes, a depender também do número total de estudantes por turma, o que geralmente resulta em 4 a 6 equipes por classe. Esse número parece oferecer um equilíbrio entre a diversidade de perspectivas e a capacidade de coordenação entre os membros. Grupos menores favorecem uma participação mais ativa e uma comunicação mais fluida, permitindo que todos os membros contribuam de maneira significativa para a resolução dos problemas propostos. Além disso, a interação em grupos de tamanho reduzido tende a ser mais focada, o que favorece a aprendizagem autodirigida, com cada membro se sentindo mais responsável e engajado no processo. Os autores pontuam, por outro lado, que grupos muito grandes, embora ofereçam uma maior variedade de habilidades e conhecimentos, frequentemente enfrentam desafios relacionados à organização do trabalho, com dificuldades na distribuição de tarefas e na gestão do tempo.

A coordenação em grupos grandes pode se tornar um processo mais complexo, aumentando a possibilidade de que alguns membros se tornem passivos ou menos envolvidos nas discussões e soluções propostas. Dessa forma, grupos maiores tendem a apresentar maiores custos operacionais, não apenas em termos de tempo de coordenação, mas também pela necessidade de um número maior de tutores para garantir que cada estudante receba a devida atenção.

Portanto, o valor do tamanho ideal do grupo em PBL deve considerar um equilíbrio entre a diversidade de habilidades, a participação equitativa e a viabilidade operacional. Grupos com seis participantes tendem a ser uma escolha eficiente, pois oferecem um bom nível de colaboração sem sobrecarregar o processo de gestão e a coordenação das atividades, mas essa escolha pode variar dependendo dos recursos disponíveis e do contexto específico de cada curso (Fonteijn & Dolmans, 2019).

2.3.2 Dimensão: Personalidade

Outra característica essencial da formação de equipes é a personalidade. Estudos de Driskell et al. (2006), Holen et al. (2015) e Ferreira et al. (2020) apresentam uma preferência pela diversidade de personalidades em equipes PBL, argumentando que, ao combinar diferentes perfis, cada membro pode contribuir com aspectos distintos que enriquecem o trabalho coletivo, como comunicação, organização, criatividade, agilidade e proatividade.

Driskell et al. (2006), em sua pesquisa sobre a eficácia das equipes, destacam que equipes compostas por indivíduos com diferentes traços de personalidade tendem a ser mais bem-sucedidas em situações que exigem colaboração. Eles argumentam que, enquanto algumas pessoas podem ser mais comunicativas e outras mais organizadas, a interação entre essas diferenças favorece o desempenho geral da equipe. Assim, no contexto do PBL, a diversidade de personalidades é vista como uma vantagem, pois cada membro tem a oportunidade de contribuir de maneira única para a solução dos problemas propostos.

Holen et al. (2015), ao investigar as preferências de estudantes de medicina dentro do contexto PBL, apontam que a personalidade e a cultura desempenham um papel significativo nas dinâmicas de grupo. Eles observam que estudantes com diferentes perfis de personalidade trazem abordagens variadas para a resolução de problemas, o que, por sua vez, melhora o aprendizado coletivo. A formação de equipes heterogêneas, segundo o estudo, facilita a troca de ideias e a reflexão crítica, elementos essenciais para o sucesso no PBL.

Por fim, Ferreira et al. (2020) exploram o uso de detecção automática de traços de personalidade para formar equipes de colaboração mais eficientes. O estudo propõe que a personalização das equipes com base nas características individuais de cada estudante pode melhorar a interação e a produtividade nas equipes. Eles defendem que a combinação de diferentes traços de personalidade pode resultar em equipes mais equilibradas e com maior capacidade de resolver problemas de maneira colaborativa, o que é especialmente relevante para modelos como o PBL.

Esses estudos convergem para a ideia de que equipes compostas por indivíduos com diferentes perfis de personalidade não só se complementam, mas também são mais eficazes ao trabalharem juntos em tarefas complexas, como as propostas pelo PBL.

Para compreender e explorar essa diversidade de perfis nas equipes, diferentes abordagens teóricas sobre personalidade têm sido consideradas como ferramentas de apoio à formação de equipes mais eficazes. Entre elas, destacam-se o Myers-Briggs Type Indicator (MBTI) e o modelo de temperamentos de Keirsey.

O MBTI é um instrumento de avaliação baseado na tipologia psicológica de Carl Jung, desenvolvido por Isabel Briggs Myers e Katharine Cook Briggs, que visa identificar as preferências cognitivas e comportamentais dos indivíduos. O modelo classifica os indivíduos em 16 tipos de personalidade com base em quatro dicotomias principais, que representam pares de opostos nas formas como as pessoas percebem o mundo e tomam decisões. A primeira dicotomia, Extroversão–Introversão (E–I), descreve onde os indivíduos tendem a focar sua energia: os extrovertidos direcionam sua atenção para o mundo externo e buscam interação social, enquanto os introvertidos preferem a introspecção e atividades solitárias. A segunda dicotomia, Sensação–Intuição (S–N), refere-se à maneira como as pessoas processam informações: os sensoriais tendem a focar em detalhes e informações concretas, enquanto os intuitivos são mais atraídos por padrões, possibilidades e abstrações. A terceira dicotomia, Pensamento–Sentimento (T–F), indica como as pessoas tomam decisões: os pensadores preferem decisões baseadas em lógica e objetividade, enquanto os sentimentais consideram mais os sentimentos e as necessidades dos outros. A última dicotomia, Julgamento–Percepção (J–P), descreve a abordagem em relação ao mundo externo: os julgadores preferem organização, planejamento e estrutura, enquanto os perceptivos são mais flexíveis, espontâneos e adaptáveis. Essas quatro dicotomias geram 16 tipos de personalidade diferentes, permitindo uma análise detalhada das preferências e comportamentos individuais (MYERS & BRIGGS FOUNDATION, 2021).

O modelo de temperamentos de Keirsey (KEIRSEY, s.d.) agrupa os 16 tipos de personalidade do MBTI em quatro grandes perfis (Guardião, Idealista, Artesão e Racional) com base em padrões de comportamento observáveis e estilos de comunicação. Cada temperamento é composto por um conjunto de tipos MBTI que compartilham características semelhantes de funcionamento e interação. Os que se enquadram no perfil Guardião incluem os tipos ESTJ, ESFJ, ISTJ e ISFJ, caracterizados por sua organização, responsabilidade e foco na estabilidade e na segurança. Os Idealistas englobam os tipos ENFJ, INFJ, ENFP e INFP, conhecidos por sua empatia, visão idealista e interesse no desenvolvimento humano. Os Artesãos

são compostos pelos tipos ESTP, ESFP, ISTP e ISFP, que se destacam pela espontaneidade, criatividade e habilidade prática em resolver problemas. Por fim, os Racionais reúnem os tipos ENTJ, INTJ, ENTP e INTP, caracterizados pela lógica, racionalidade e foco em inovação e resolução de problemas complexos. Essa categorização permite uma compreensão mais clara de como as preferências individuais do MBTI se manifestam nas interações sociais e no comportamento cotidiano.

Alguns estudos empíricos, como o de Yilmaz e O'Connor (2015), demonstram a aplicabilidade desses modelos em contextos profissionais. Os autores aplicaram o Keirsey Temperament Sorter II (KTS-II) em 382 profissionais de software, identificando que a compreensão dos temperamentos contribuiu para melhorar a comunicação e a gestão de conflitos nas equipes. Além disso, a análise fatorial exploratória realizada no estudo indicou uma estrutura de fatores coerente com os constructos propostos, sugerindo uma validade construtiva satisfatória para o KTS-II. Por isso, ambos os modelos continuam amplamente utilizados em contextos organizacionais, educacionais e de desenvolvimento pessoal, apesar do MBTI ser frequentemente criticado pela comunidade acadêmica por sua falta de validade preditiva, confiabilidade psicométrica e fundamentos empíricos limitados (PITTENGER, 2005; BOYLE, 1995), fragilidades estas, que se aplicam também ao modelo de temperamentos de Keirsey, uma vez que ele é derivado diretamente da estrutura tipológica do MBTI.

2.3.3 Dimensão: Experiência profissional

A experiência profissional é uma característica importante no processo, pois a partir de suas experiências anteriores os membros da equipe podem identificar melhores formas de resolver problemas e realizar atividades, desempenhar papéis como instrutores e mentores, além de fortalecer e desenvolver habilidades como autorregulação e autodireção (HENRY et al., 2012).

No contexto dos cursos de computação, a experiência profissional dos estudantes pode influenciar significativamente o desempenho das equipes. A experiência profissional prévia facilita a aplicação desses conceitos em projetos de PBL, pois de acordo com Bowman et al. (2019), estudantes que já trabalharam em projetos de software trazem conhecimentos práticos que complementam a teoria

aprendida em sala de aula. Esses indivíduos, ao compartilharem suas vivências, atuam como mediadores do conhecimento, promovendo uma troca de aprendizagem que beneficia tanto os colegas com menos experiência quanto os próprios estudantes experientes.

No mercado de trabalho, a combinação de profissionais com diferentes níveis de experiência pode contribuir positivamente para o desempenho das equipes. Enquanto os mais experientes tendem a compartilhar conhecimentos técnicos e práticos, os que estão iniciando na área podem oferecer ideias novas e diferentes pontos de vista. Essa troca de experiências favorece tanto o aprendizado mútuo quanto a busca por soluções criativas nos projetos.

2.3.4 Dimensão: Gênero

A diversidade de gênero é uma dimensão essencial a ser considerada na formação de equipes em ambientes educacionais colaborativos, como os propostos pelo modelo PBL. Em particular, no contexto da computação, uma área historicamente marcada pela desigualdade de gênero, a inclusão de critérios que promovam maior equilíbrio entre estudantes do sexo feminino e masculino é essencial para mitigar assimetrias estruturais e estimular ambientes de aprendizagem mais equitativos e eficazes (CHERYAN, 2017).

Segundo dados da UNESCO (2017), mulheres representavam apenas cerca de 30% dos estudantes nas áreas de ciências, tecnologia, engenharia e matemática no ensino superior em nível global. No Brasil, a discrepância de gênero nos cursos da área de Tecnologia da Informação (TI) é particularmente acentuada quando comparada às demais áreas do ensino superior. Enquanto as mulheres representam 60,7% dos matriculados no conjunto dos cursos de graduação, sua presença em cursos de TI é expressivamente menor, ocupando apenas 16,5% das vagas (INSTITUTO SEMESP, 2023). A Figura 1 mostra a disparidade na distribuição das vagas em cursos de TI, por cargo, entre os gêneros no ano de 2021.

Figura 1 - Distribuição de gênero por curso de TI em 2021 no Brasil



Fonte: Instituto Semesp (2021)

Essa desvantagem numérica impacta diretamente a dinâmica das equipes de trabalho e pode levar a processos de invisibilização da participação feminina, perpetuando estereótipos de competência e afetando negativamente o engajamento e a confiança das estudantes (MOSS-RACUSIN et al., 2012).

Diante desse cenário, a formação de equipes heterogêneas em termos de gênero no contexto do PBL demanda decisões pedagógicas criteriosas, que considerem tanto a promoção da equidade quanto a dinâmica interpessoal das equipes. Idealmente, busca-se que cada equipe seja composta de maneira equilibrada quanto ao gênero, favorecendo a diversidade e a inclusão. No entanto, reconhecendo que, em cursos de computação, a presença feminina ainda é significativamente menor, torna-se necessário adotar estratégias que mitiguem possíveis assimetrias. Nesse contexto, duas alternativas são geralmente consideradas: alocar as estudantes de modo que nenhuma fique isolada em uma equipe predominantemente masculina ou distribuí-las entre as equipes de forma que, sempre que possível, todas as equipes contem com ao menos uma integrante do gênero feminino. Ambas as abordagens têm implicações importantes para o engajamento, o conforto e o desempenho das estudantes, exigindo uma análise cuidadosa por parte dos docentes no momento da formação das equipes.

A primeira estratégia consiste em distribuir as estudantes de forma que, sempre que possível, nenhuma delas permaneça sozinha em uma equipe, com o objetivo de

equilibrar internamente a proporção de gênero e criar um ambiente mais acolhedor e psicologicamente seguro. Essa configuração pode estimular maior participação, engajamento e protagonismo das estudantes, reduzindo sua exposição a microagressões, isolamento e estigmas de competência (CHERYAN et al., 2017; MOSS-RACUSIN et al., 2012). Também favorece a construção de confiança e proporciona espaço para que suas vozes sejam ouvidas com liberdade, fortalecendo o senso de pertencimento e promovendo uma experiência de aprendizagem mais equitativa, em consonância com os princípios construtivistas do PBL.

Contudo, essa estratégia apresenta limitações. Ao concentrar mais de uma estudante em determinadas equipes para evitar que fiquem isoladas, aumenta-se a probabilidade de que outras equipes sejam formadas exclusivamente por estudantes do gênero masculino, o que pode reduzir a diversidade de gênero nesses grupos e limitar o intercâmbio de diferentes perspectivas. A ausência de mulheres nesses times pode reforçar visões homogêneas e dificultar a construção de competências sociais, como empatia e escuta ativa, que são fundamentais no trabalho colaborativo. Além disso, essa separação pode reforçar uma percepção de diferenciação entre os gêneros, criando um efeito de guetização e afastando os estudantes de interações mistas que refletem o ambiente profissional real da área de tecnologia.

A segunda alternativa é a distribuição equilibrada das alunas entre os grupos, de forma que cada equipe conte com pelo menos uma mulher. Essa configuração promove o enriquecimento cognitivo e social, e possibilita que todos os estudantes se beneficiem da convivência com perspectivas diversas, já que contribui para desconstruir estereótipos de gênero e estimula relações mais igualitárias (CHERYAN et al., 2017).

Entretanto, essa estratégia também implica desafios. Inseridas isoladamente em grupos majoritariamente masculinos, as alunas podem enfrentar processos de invisibilização, sobrecarga simbólica e pressões para representar todo um gênero. Estudos mostram que essas situações geram estresse adicional e podem inibir o engajamento das estudantes, comprometendo seu aprendizado e o desempenho coletivo da equipe (WHITE & MASSIHA, 2016; MOSS-RACUSIN et al., 2012). Quando são minoria absoluta, há o risco de que sua presença se torne meramente simbólica, sem uma participação efetiva ou valorizada nas decisões do grupo.

Portanto, qualquer que seja a estratégia de alocação adotada, ela deve vir acompanhada de ações complementares de suporte institucional e pedagógico. Isso

inclui a mediação docente atenta às dinâmicas de gênero, a construção de um ambiente de respeito mútuo e o estímulo explícito à escuta e valorização das contribuições femininas. Apenas dessa forma será possível transformar a presença feminina em participação significativa e garantir que a diversidade de gênero atue como elemento qualitativo na aprendizagem colaborativa.

2.3.5 Dimensão: Afinidade

Por fim, algo importante a considerar ao pensar em PBL e na formação de equipes é que a maioria das atividades dessa abordagem são realizadas de forma colaborativa. As habilidades construídas nesse processo, como comunicação, negociação, resolução de conflitos e pensamento crítico, emergem dos relacionamentos interpessoais estabelecidos entre os membros da equipe. Portanto, a maneira como essas equipes são constituídas pode influenciar diretamente a qualidade da experiência de aprendizagem.

Um aspecto relevante nesse processo é a familiaridade entre os integrantes da equipe. O estudo de Gruenfeld et al. (1996) demonstrou que equipes compostas por membros que já se conheciam previamente apresentaram maior conforto ao trabalhar em conjunto, maior abertura para expressar discordâncias e foram avaliados como mais eficazes do que grupos compostos exclusivamente por desconhecidos. A familiaridade promove um ambiente psicologicamente mais seguro, no qual os estudantes se sentem mais à vontade para participar ativamente, questionar ideias e propor soluções. Além disso, os autores observaram que, mesmo em comparação com grupos mistos (compostos por membros conhecidos e desconhecidos), as equipes totalmente familiares tenderam a apresentar melhores percepções de desempenho, ainda que as diferenças nem sempre fossem estatisticamente significativas. Esses resultados sugerem que a afinidade prévia entre os participantes pode atenuar os efeitos negativos da insegurança social e favorecer a expressão de ideias divergentes, algo fundamental em processos baseados em investigação e construção coletiva de conhecimento.

Contudo, é importante reconhecer que a familiaridade não garante, por si só, diversidade de perspectivas, elemento igualmente essencial em contextos de PBL. O mesmo estudo indica que, embora equipes de desconhecidos tendam a enfrentar mais desconforto na interação inicial, eles podem contribuir com uma maior

diversidade de opiniões e estratégias cognitivas, especialmente quando todos os membros têm acesso às mesmas informações. Assim, ao formar equipes em PBL, é recomendável buscar um equilíbrio entre familiaridade interpessoal e diversidade de atributos. A escolha estratégica das equipes, portanto, deve considerar tanto a afinidade social quanto a composição heterogênea de perfis, conhecimentos e experiências, a fim de potencializar os benefícios pedagógicos do trabalho em equipe.

2.4 TRABALHOS RELACIONADOS

Um sistema de formação de equipes adequado ao modelo PBL precisa atender a diversos diferenciais que são específicos dessa abordagem educacional, os quais outros modelos de formação de equipes não necessariamente precisam considerar. Seguem os principais diferenciais:

- Diversidade de Perfis para Resolução de Problemas:

O modelo PBL é centrado na resolução de problemas reais e complexos, exigindo equipes heterogêneas para maximizar a troca de ideias e perspectivas. Um sistema para PBL precisa considerar diversidade de perfis cognitivos e comportamentais (como os identificados por modelos como MBTI e Keirsey) para garantir que cada equipe tenha membros com diferentes formas de abordar e solucionar problemas. Isso é essencial para promover criatividade e complementaridade no trabalho, diferentemente de outros modelos que podem focar apenas em habilidades técnicas ou interesses semelhantes.

- Afinidades e Relações Interpessoais:

No PBL, as atividades são altamente colaborativas e dependem de uma dinâmica de grupo saudável. Um sistema voltado para PBL deve incluir critérios para identificar e considerar afinidades interpessoais, promovendo grupos onde os membros já tenham algum nível de familiaridade ou facilidade de interação, o que pode ajudar a minimizar conflitos e facilitar a comunicação.

- Distribuição Equitativa de Experiência Profissional:

O PBL frequentemente busca integrar estudantes com diferentes níveis de experiência, onde os mais experientes podem atuar como mentores e os menos experientes podem contribuir com novas perspectivas. Um sistema para PBL deve

garantir que as equipes tenham pelo menos um membro com experiência prática, o que não é um requisito comum em outros modelos de formação de equipes.

- **Promoção de Competências Socioemocionais:**

Além do desenvolvimento técnico, o PBL visa aprimorar competências como liderança, empatia, comunicação e negociação. Um sistema adequado deve considerar a composição dos perfis das equipes para estimular o desenvolvimento dessas habilidades, o que não é necessariamente uma prioridade em outros modelos voltados apenas para resultados técnicos ou acadêmicos.

- **Flexibilidade para Adaptação ao Contexto Educacional:**

O PBL pode ser aplicado em diferentes disciplinas e contextos educacionais, exigindo que o sistema tenha flexibilidade para ajustar os critérios de formação conforme as necessidades específicas da turma, como diversidade de gênero, preferências de trabalho e nível de maturidade acadêmica. Outros modelos podem ser menos adaptáveis e mais genéricos em sua lógica de formação.

- **Equilíbrio entre Heterogeneidade Interna e Homogeneidade Externa:**

No PBL, é importante que cada equipe seja internamente heterogênea (diversidade de perfis) e que o conjunto das equipes seja homogêneo em termos de potencial de desempenho. Um sistema para PBL deve equilibrar esses dois aspectos, enquanto outros modelos podem focar apenas em um dos dois.

- **Consideração de Preferências dos Estudantes:**

Para alinhar expectativas e aumentar a motivação, um sistema voltado para PBL deve incluir preferências individuais dos estudantes, como atividades preferenciais (programação, modelagem, gestão) e escolha de colegas com quem desejam trabalhar. Essa personalização não é essencial em outros modelos de formação de equipes mais rígidos.

Esses diferenciais tornam um sistema de formação de equipes para PBL mais complexo e especializado, garantindo que as equipes sejam equilibradas tanto tecnicamente quanto socioemocionalmente, alinhadas aos princípios do modelo PBL e às demandas educacionais.

A crescente complexidade na formação de equipes equilibradas e a sua influência sobre o sucesso da equipe em ambientes PBL impulsionaram o desenvolvimento de soluções automatizadas para apoiar essa tarefa. Vários autores (Ounnas, 2010; Wang et al., 2007; Moreno, Ovalle e Vicari, 2012) desenvolveram algoritmos computacionais que podem realizar esses agrupamentos de maneira mais eficiente.

No presente estudo, propõe-se uma solução baseada na formação de grupos semânticos para apoiar a criação de equipes colaborativas com alto potencial de sucesso no contexto PBL.

O Quadro 1 apresenta trabalhos relacionados ao estudo atual a partir de uma revisão não sistemática da literatura. Esses estudos foram coletados utilizando as bases de dados Scopus e Google Scholar. Os trabalhos identificados revelaram-se pertinentes para fundamentar o escopo da solução proposta, evidenciando convergências conceituais com os objetivos desta pesquisa. As abordagens analisadas demonstraram-se suficientemente robustas para subsidiar o desenvolvimento da proposta, ao mesmo tempo em que suscitaron reflexões críticas acerca de suas limitações e divergências metodológicas.

Quadro 1 - Comparativo De Estudos Relacionados

Refs.	Características	Proposta	Contexto	Critérios de Formação
Reis et al. (2020)	Algoritmo de formação de grupos usando traços de personalidade	Formação de grupos	Estudantes de Ensino Superior em Computação	Contexto, atividades de aprendizagem, estrutura do grupo e personalidade
Ounnas (2010)	Sistema de formação de grupos baseado em ontologia	Formação de grupos	Estudantes de Ensino Superior em Estatística e Computação	Tamanho da equipe, interesses e habilidades pessoais
Isotani et al. (2009)	Algoritmo de formação de grupos baseado	Formação de grupos	Estudantes de Ensino Superior	Conhecimento, habilidades, papéis de aprendizagem e

	em ontologia			preferências do professor
Chen e Kuo (2019)	Esquema de formação de grupos baseado em algoritmo genético	Formação de grupos	Estudantes do Ensino Fundamental e Médio	Níveis de conhecimento, papéis de aprendizagem e interações em redes sociais
Atual	Solução baseada na formação de grupos semânticos	Formação de grupos	Estudantes de Ensino Superior em Computação baseado em PBL	Contexto, tamanho da equipe, personalidade, diversidade (gênero, faixa etária e experiência profissional), preferências dos estudantes e afinidades.

Fonte: Elaborado pelo autor (2025)

Reis et al. (2020) propõe uma abordagem teórica para a formação de equipes, que considera a personalidade como um fator relevante na colaboração entre membros. O artigo apresenta um algoritmo para formar equipes que apoiam novas funções de aprendizagem, denominadas funções de Aprendizagem Colaborativa Afetiva, com base na relação entre teorias de aprendizagem colaborativa e traços de personalidade dos estudantes. A avaliação consistiu em uma série de experimentos com estudantes universitários, onde as equipes foram formadas com base em critérios de personalidade e avaliadas quanto ao desempenho e à satisfação dos membros. Os resultados indicaram que a abordagem baseada na personalidade pode melhorar a eficácia da colaboração e aumentar a satisfação dos membros da equipe. O estudo conclui que formar equipes com base nas características de personalidade pode ser uma abordagem promissora para aprimorar a colaboração e o desempenho da equipe em ambientes de aprendizagem colaborativa. O estudo aponta a personalidade como uma característica crítica para a formação de equipes; isso se alinha ao presente estudo, pois também utiliza essa característica para focar em ambientes de aprendizagem colaborativa. Apesar disso, não considera diversos fatores relevantes ao contexto PBL, como experiência profissional, preferências e gênero. Também não

considera o tamanho da equipe.

Ounnas (2010) apresenta um sistema que utiliza ontologias para representar o conhecimento sobre os estudantes e suas características, permitindo que o sistema selecione automaticamente os membros da equipe com base em suas habilidades, conhecimentos e interesses. Além disso, o sistema permite que os professores personalizem os critérios de formação de equipes para atender às necessidades específicas de sua turma. A autora concluiu que considerar a diversidade das características dos estudantes pode ajudar a tornar a formação de equipes em ambientes educacionais mais eficiente e personalizada. O trabalho está alinhado com o presente estudo no que diz respeito à personalização de atributos pelo professor, além de aproveitar os interesses e habilidades do estudante. Apesar disso, não utiliza os perfis MBTI e Keirsey como classificação de personalidades, além de considerar apenas notas nas disciplinas e não experiência profissional, característica relevante no PBL, já que sua base é trabalhar com problemas reais ou que pelo menos o simule.

Isotani et al. (2009) apresenta uma abordagem baseada em ontologia para a formação de equipes em ambientes educacionais com base em teorias pedagógicas. Os autores propõem uma abordagem teórica para a formação de equipes com base em um conjunto de teorias pedagógicas representadas por meio de uma ontologia que utiliza um modelo de referência para formar equipes heterogêneas em algumas dimensões e homogêneas em outras com base em critérios específicos. O trabalho é interessante e se alinha ao presente estudo no uso dos interesses e habilidades dos estudantes. Apesar disso, não considera o tamanho da equipe, gênero e personalidade.

Chen e Kuo (2019) apresenta uma estrutura para a formação de equipes baseada em um algoritmo (GAGFS-PF) que considera níveis de conhecimento e papéis de aprendizagem e tipos de interações em redes sociais. O estudo considera três esquemas de treinamento: completamente aleatório, treinamento com auto seleção e calibrado por entrevistas. Os resultados mostraram que o algoritmo funciona para formar equipes aleatórias com auto seleção. Embora necessário e alinhado ao contexto deste estudo em relação à abordagem PBL, o estudo não levou em consideração o contexto do ensino superior em computação; além disso, a forma como utilizou a parte atitudinal foi por meio de redes sociais e não da personalidade.

Diante das lacunas identificadas, pode-se concluir que há a necessidade de desenvolvimento de um algoritmo de formação de equipes que considere os critérios

de restrição definidos como relevantes pelo organizador da atividade, levando em conta o nível de prioridade que cada um tem sobre os demais, tornando possível a flexibilização desses níveis para se adequar a vários domínios, e que seja voltado para a abordagem PBL, visto o grande impacto que todo esse processo inicial de agrupamento pode ter sobre o desenvolvimento da aprendizagem de cada indivíduo da equipe.

A pesquisa atual é um estudo de caso que apresenta um processo automatizado para formar equipes de PBL no ensino superior em um curso de Sistemas de Gestão Empresarial (SGE). O modelo abrange desde os procedimentos de coleta de dados dos estudantes até a distribuição das equipes de acordo com critérios definidos e avaliação. O algoritmo foi modelado utilizando as dimensões de avaliação: perfil de personalidade e comportamento (Perfis MBTI e Keirsey), dados demográficos (faixa etária e experiência profissional), habilidades técnicas (programação, modelagem, gerenciamento) e afinidades, além de considerar o tamanho da equipe. Essas dimensões foram formuladas com base nos princípios do PBL e previamente apresentadas. Embora o algoritmo tenha sido implementado com base nessas dimensões, os critérios de restrição podem ser personalizados para atender ao propósito do organizador.

3. METODOLOGIA

Este capítulo apresenta a estrutura metodológica adotada na pesquisa, com base na abordagem *Design Science Research* (DSR). São descritos os ciclos evolutivos realizados, bem como o fluxo geral de desenvolvimento, que envolveu etapas de Definição do problema, Ciclos DSR e Resultados da pesquisa. O foco está na organização do processo metodológico e na forma como ele foi conduzido ao longo da pesquisa.

A metodologia DSR surgiu no campo dos Sistemas de Informação e da Engenharia de Software como uma abordagem voltada para a resolução de problemas complexos por meio da construção de artefatos inovadores. Seu surgimento está relacionado ao fortalecimento de uma visão pragmática na ciência da computação e nas ciências aplicadas, que buscava equilibrar a produção de conhecimento teórico com a criação de soluções práticas e úteis. (HEVNER et al., 2010)

A base conceitual do DSR começou a ser estruturada nos anos 1990, mas ganhou maior destaque com os trabalhos de Hevner et al. (2004), que formalizaram seu uso no contexto da pesquisa em Sistemas de Informação, e com a sistematização proposta por Wieringa (2014), voltada especificamente para engenharia de software e desenvolvimento de sistemas. A proposta central era responder a uma lacuna nas metodologias científicas tradicionais, que muitas vezes não contemplavam adequadamente a criação de artefatos tecnológicos como uma forma válida de contribuição científica.

O DSR se consolidou em um contexto em que a academia buscava maior relevância prática e impacto social, especialmente nas áreas de tecnologia, onde os pesquisadores não apenas observam fenômenos, mas também projetam e constroem soluções. O método parte do princípio de que resolver problemas reais por meio do design de artefatos (como algoritmos, modelos, métodos ou sistemas) é uma forma legítima de geração de conhecimento, desde que os artefatos sejam avaliados de forma rigorosa e os aprendizados sistematizados.

O processo no DSR é iterativo e cílico, geralmente composto por quatro etapas principais: investigação do problema, design da solução, implementação e avaliação. Cada ciclo permite o refinamento progressivo do artefato, com base em testes, feedbacks e melhorias sucessivas. O objetivo é tanto desenvolver soluções eficazes

quanto gerar conhecimento generalizável sobre o problema e sobre o processo de design adotado.

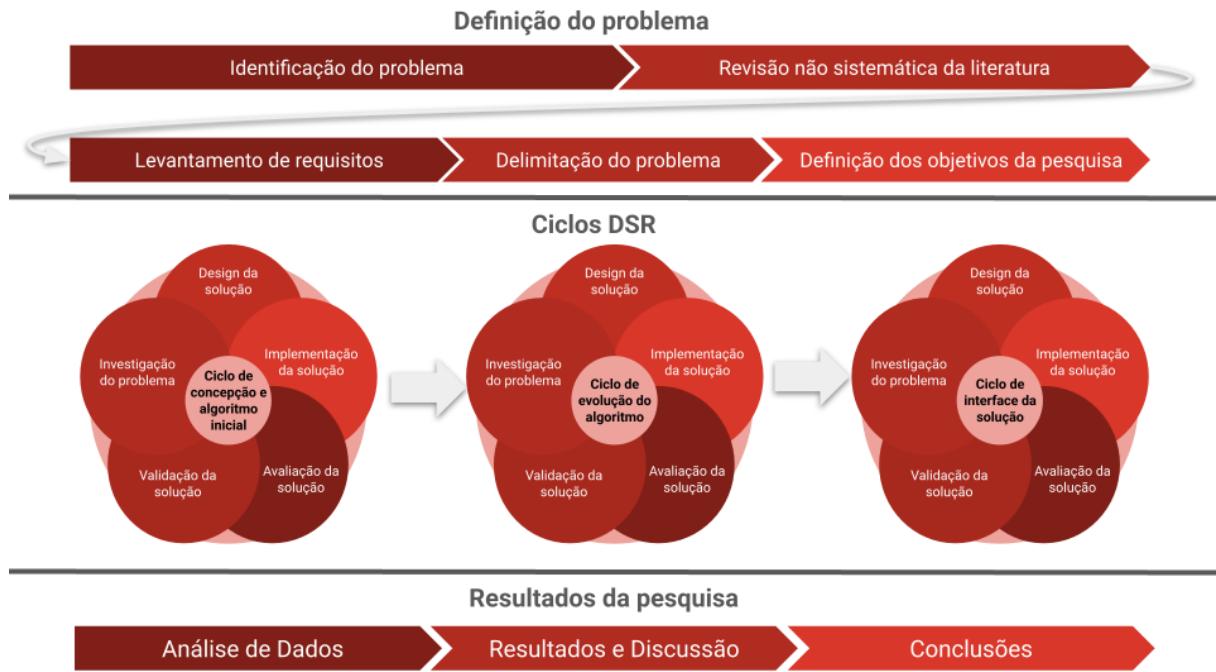
Nesta pesquisa, a abordagem DSR foi escolhida por sua capacidade de estruturar o desenvolvimento e a evolução de artefatos de forma iterativa e incremental. Essa característica foi essencial para a criação de um sistema computacional de formação automatizada de equipes, permitindo que o processo fosse conduzido a partir da observação de um problema real no contexto educacional. O método DSR viabilizou a aplicação de ciclos evolutivos, nos quais o artefato foi continuamente testado, refinado e aprimorado com base em dados empíricos e feedbacks dos usuários.

Além disso, a metodologia permitiu a produção de diferentes artefatos ao longo da pesquisa, cada um contribuindo para a solução proposta: (1) um algoritmo inicial para formação de equipes, que serviu como base funcional para os ciclos subsequentes; (2) versões refinadas do algoritmo, incorporando critérios como personalidade, afinidades, gênero e experiência profissional; e (3) uma interface gráfica desenvolvida na plataforma Streamlit, que tornou o sistema acessível e fácil de usar para os professores, permitindo a entrada de dados via planilhas e a configuração personalizada dos critérios de agrupamento.

Essa abordagem incremental e sistemática garantiu que cada artefato fosse validado e ajustado conforme os resultados dos testes e as necessidades específicas do contexto educacional, assegurando maior precisão, eficiência e aplicabilidade prática da solução automatizada. Dessa forma, o DSR demonstrou ser a metodologia ideal para conduzir este trabalho, integrando teoria e prática para resolver o problema identificado e contribuir com inovação na área educacional.

A Figura 2 apresenta o esquema da metodologia utilizada, que envolveu etapas de Definição do problema, Ciclos DSR (design e implementação da solução) e Resultados da pesquisa.

Figura 2 - Esquema metodológico



Fonte: Elaborado pelo autor (2025)

3.1. DEFINIÇÃO DO PROBLEMA

A primeira etapa do fluxo DSR é a Definição do problema que, por sua vez, é dividido em cinco atividades. Cada uma delas é descrita a seguir.

3.1.1 Atividade 1: Identificação do problema

Nesta fase inicial, o problema foi observado durante a atuação como tutor em uma disciplina de SGE, organizada com base na abordagem PBL, aliado às experiências de debates e reflexões vividas pelo autor junto ao grupo de pesquisa NEXT. Identificou-se que o processo de formação de equipes era moroso e exigente para a professora da disciplina, além de propenso à criação de grupos desequilibrados devido à dificuldade de considerar múltiplos critérios manualmente. Essa percepção prática foi o ponto de partida para o desenvolvimento da pesquisa.

3.1.2 Atividade 2: Revisão não sistemática da literatura

Foi conduzida uma revisão não sistemática da literatura com o objetivo de

explorar as abordagens existentes e avaliar as metodologias aplicadas, destacando seus pontos fortes e limitações. Esse processo forneceu uma base teórica preliminar, essencial para fundamentar a escolha dos critérios utilizados na formação de equipes e reforçar a necessidade de personalização das restrições aplicadas. Além disso, a revisão permitiu identificar aspectos relevantes relacionados à composição de grupos, ao equilíbrio entre os integrantes e aos critérios de afinidade e atributos, contribuindo para uma compreensão mais aprofundada das variáveis associadas ao problema estudado e orientando os próximos passos da pesquisa.

3.1.3 Atividade 3: Levantamento de requisitos

Nessa atividade, o foco foi compreender o processo manual de formação de equipes adotado pela professora, com o objetivo de identificar suas intenções pedagógicas e os critérios utilizados na organização das equipes. Por meio da análise de dados de turmas anteriores e de diálogos com a docente, buscou-se conhecer em detalhes como as equipes eram formadas, quais atributos eram considerados prioritários (como habilidades, preferências e afinidades) e de que forma essas escolhas se alinhavam aos objetivos do PBL. Além disso, foi analisado o percurso avaliativo aplicado na disciplina, permitindo compreender previamente como a formação dos grupos impactava nas etapas de avaliação da disciplina ao longo do período letivo para modelar também a avaliação da solução.

Esse mapeamento inicial foi fundamental para o levantamento dos requisitos da solução, garantindo que sua implementação respeitasse a lógica pedagógica e avaliativa da disciplina.

3.1.4 Atividade 4: Delimitação do problema

Após a revisão da literatura e o levantamento dos requisitos, foi realizada a delimitação do problema. Esta atividade envolveu a especificação dos contextos em que o algoritmo seria aplicado, considerando as particularidades do ensino superior em cursos de Sistemas de Gestão Empresarial e a abordagem do PBL.

Essa delimitação permitiu focar o escopo da pesquisa e facilitar a identificação de soluções viáveis para o contexto educacional estudado.

3.1.5 Atividade 5: Definição dos objetivos da pesquisa

A partir da delimitação do problema, formulou-se a questão de pesquisa que cerceou com clareza o problema a ser investigado, orientando todo o desenvolvimento do estudo.

Nessa atividade, definiu-se, por conseguinte, o objetivo geral da pesquisa que é propor uma solução automatizada para a formação de equipes balanceadas no ensino superior de computação com PBL, considerando critérios, atributos e afinidades pré-definidos entre seus membros. Em seguida, foram estabelecidos também os objetivos específicos cujas descrições encontram-se na seção de Introdução dessa presente pesquisa.

Esses objetivos orientaram a concepção da solução, visando a automatização da formação de equipes equilibrados, respeitando os critérios inicialmente definidos, mas também passíveis de adaptação conforme o contexto da turma.

A abordagem DSR permitiu que o processo de design da solução fosse baseado na investigação empírica do problema, garantindo que o algoritmo desenvolvido atendesse aos critérios específicos de formação de equipes para o PBL. Após a definição do problema, a pesquisa avançou para os ciclos de DSR, nos quais cada ciclo contribuiu para a evolução do algoritmo inicial, culminando em um sistema com interface amigável e eficiente.

3.2. CICLOS DSR

Para o desenvolvimento da solução proposta, foram conduzidos três ciclos iterativos DSR, cada um com objetivos específicos e complementares. Esses ciclos seguiram uma estrutura metodológica comum composta por cinco fases (investigação do problema, design da solução, implementação, avaliação e validação) permitindo uma evolução progressiva da proposta. O primeiro ciclo teve como foco a concepção e implementação de um algoritmo inicial. Esta versão serviu como base para os ciclos subsequentes, onde melhorias e refinamentos foram feitos para desenvolver um sistema com interface amigável e eficiente. O segundo concentrou-se na evolução e refinamento do algoritmo com base nos feedbacks e testes; e o terceiro abordou o desenvolvimento de uma interface amigável, visando facilitar o uso do sistema por parte dos professores. A seguir, são apresentados os detalhes de cada um desses

ciclos.

Embora cada ciclo tenha suas particularidades, todas as iterações seguiram a mesma estrutura metodológica. A seguir, apresenta-se um resumo do que se espera em cada uma dessas fases:

- **Fase 1: Investigação do problema**

Esta fase é iniciada a cada novo período da disciplina de SGE e consiste na coleta dos dados dos estudantes e na análise do perfil da turma. A investigação busca compreender as características do grupo e identificar os principais desafios para a formação de equipes equilibradas e heterogêneas, servindo como base para o design da solução.

- **Fase 2: Design da solução**

Com base na análise do perfil da turma, são definidos os critérios de restrição e suas prioridades, os quais guiarão o funcionamento do algoritmo de formação das equipes. Além disso, é nesta fase que se idealiza a lógica do algoritmo, com base nos dados coletados, para que ele distribua os estudantes entre as equipes de forma equilibrada. Também são previstas regras para o comportamento do algoritmo em cenários mais complexos, nos quais há conflitos ou sobreposição entre os critérios. Esta fase busca adaptar a solução às características específicas da turma, respeitando tanto os objetivos pedagógicos quanto às limitações operacionais do contexto.

- **Fase 3: Implementação da solução**

Nesta fase, é feita a programação do algoritmo, incorporando as melhorias identificadas em ciclos anteriores. Também é nesta etapa que ocorre a aplicação prática da solução, com a formação das equipes a partir dos dados da turma e dos critérios previamente definidos.

Em termos gerais, a implementação da solução consistiu na etapa de construção e aprimoramento do código computacional do algoritmo de agrupamento PBL. O algoritmo foi desenvolvido com a linguagem de programação Python utilizando a biblioteca Pandas para manipulação de dados. A lógica do algoritmo foi estruturada em torno da personalização de prioridades e critérios específicos, como perfil de personalidade, gênero,

experiência, preferência, faixa etária e afinidades. A seleção e distribuição dos alunos em grupos foram implementadas equipe por equipe, buscando formar equipes equilibradas e otimizar a heterogeneidade dos grupos. O código utilizou estruturas de controle para filtrar e alocar alunos com base nesses critérios, mantendo flexibilidade ao permitir a escolha personalizada de perfis de personalidade prioritários.

- **Fase 4: Avaliação da solução**

Após a implementação, realiza-se a verificação da eficácia da solução, analisando se os critérios de restrição foram atendidos. A avaliação pode incluir tanto a análise técnica dos resultados quanto o retorno de professores e estudantes, e serve para identificar ajustes e melhorias que serão incorporados no ciclo seguinte.

- **Fase 5: Validação da solução**

Por fim, a fase de validação verifica se a solução atende plenamente aos objetivos propostos. Caso a validação aponte limitações ou oportunidades de melhoria, um novo ciclo é iniciado. Se os critérios forem plenamente atendidos, o processo segue para a etapa final do DSR, voltada à consolidação dos resultados da pesquisa.

3.2.1 Ciclo DSR 1: Ciclo de concepção e algoritmo inicial

No primeiro ciclo do processo baseado na metodologia DSR, foi desenvolvido o protótipo inicial do algoritmo, com o objetivo de estabelecer a base funcional do sistema proposto e validar a viabilidade técnica da solução. Este trabalho foi conduzido no período letivo de 2022.2 e contou com o uso do Jupyter, uma interface de desenvolvimento interativa e gratuita amplamente utilizada nas áreas de ciência de dados, machine learning e programação em Python.

O Jupyter permite a criação de notebooks que integram código executável, visualizações e textos explicativos, facilitando tanto o desenvolvimento quanto a documentação do processo de construção do algoritmo (JUPYTER, 2015).

3.2.1.1 Fase 1: Investigação do problema

A investigação do problema no Ciclo 1 ocorreu durante o período de 2022.2, após a formação manual das equipes pelos professores. Como a pesquisa teve início apenas no decorrer do semestre, não foi possível utilizar o algoritmo para formar as equipes daquela turma. Ainda assim, a planilha com os dados dos estudantes foi aproveitada para a análise do perfil da turma e serviu como base para a concepção da primeira versão do algoritmo. A coleta de dados, no entanto, apresentou falhas: o campo de preferência por atividade (programar (P), modelar (M) ou gerenciar (G)) permitia múltiplas marcações, o que contrariava o objetivo de obter apenas uma preferência clara por estudante.

Nessa primeira versão do algoritmo, optou-se por não considerar a restrição de afinidades entre os estudantes por estar em uma versão muito inicial ainda. Assim, foi estabelecida uma lista com quatro critérios de restrição a serem considerados nesse ciclo. No capítulo 5, são apresentados mais detalhes sobre os critérios de restrição adotados.

3.2.1.2 Fase 2: Design da solução

Com base nos dados disponíveis, foi desenhada a primeira proposta da solução. Esta versão inicial consistiu na definição dos critérios de restrição (perfil de personalidade, gênero, experiência, preferência de atividade, faixa etária) e de suas prioridades, mesmo sem o uso prático imediato do algoritmo para formar as equipes. A ausência das afinidades e a inconsistência na coleta das preferências limitaram a abrangência dos critérios utilizados neste ciclo. A estrutura lógica do algoritmo foi concebida a partir desses insumos e adaptada para refletir as condições reais da turma.

3.2.1.3 Fase 3: Implementação da solução

A implementação da solução consistiu na programação da primeira versão do algoritmo, utilizando a linguagem Python e a biblioteca Pandas para o tratamento dos dados. O foco principal esteve na construção de uma base funcional capaz de processar os dados coletados e gerar uma sugestão de distribuição dos estudantes

conforme os critérios definidos. Como a aplicação do algoritmo não foi possível na turma de 2022.2, sua implementação serviu como um protótipo inicial, cuja funcionalidade e lógica interna foram testadas com os dados disponíveis.

3.2.1.4 Fase 4: Avaliação da solução

A avaliação, neste ciclo, ocorreu de forma limitada, dado que o algoritmo não foi efetivamente utilizado na formação das equipes. A análise concentrou-se na verificação da consistência dos critérios processados pelo código e na identificação de fragilidades no processo de coleta de dados, especialmente quanto à ausência das afinidades e à ambiguidade na indicação de preferências. Essas limitações impediram uma avaliação mais robusta do desempenho do algoritmo, mas forneceram insumos importantes para os ajustes do próximo ciclo. Os detalhes das avaliações serão apresentados no Capítulo 5.

3.2.1.5 Fase 5: Validação da solução

A validação, neste primeiro ciclo, teve caráter preliminar. O artefato foi considerado funcional do ponto de vista técnico, mas sua aplicabilidade prática ainda não havia sido testada em um cenário real de formação de equipes. As inconsistências na coleta de dados apontaram para a necessidade de ajustes no instrumento de entrada, como a limitação de uma única resposta por atributo, com exceção do campo de afinidades.

No primeiro ciclo, o foco foi a concepção e implementação de um protótipo inicial do algoritmo. Apesar de limitado, este ciclo foi essencial como prova de conceito, demonstrando a viabilidade técnica da proposta e estabelecendo as bases funcionais do sistema. Os resultados obtidos neste ciclo permitiram identificar fragilidades no processo de coleta de dados e na lógica inicial do algoritmo, orientando ajustes necessários para os ciclos seguintes.

3.2.2 Ciclo DSR 2: Ciclo de evolução do algoritmo

No segundo ciclo do processo conduzido sob a metodologia DSR, realizado no período de 2023.1, o foco foi na melhoria do algoritmo inicial. Os aprimoramentos

foram orientados pelos feedbacks obtidos durante a fase anterior, com ajustes nas funcionalidades e aumento da eficiência do sistema. Para este ciclo, utilizou-se o Google Colab, uma plataforma baseada na nuvem que permite o desenvolvimento e execução de notebooks Python sem a necessidade de instalação local. O Google Colab oferece a vantagem de integrar-se ao Google Drive, facilitando o acesso e o salvamento de arquivos diretamente na nuvem, além de possibilitar o trabalho colaborativo de forma prática e acessível.

3.2.2.1 Fase 1: Investigação do problema

Foram realizados esclarecimentos no processo de preenchimento da planilha de dados, pois inconsistências nos dados impactam negativamente no desempenho do algoritmo.

Ao realizar o levantamento dos perfis, constatou-se tratar de uma turma majoritariamente jovem, masculina, com boa experiência profissional, perfil comportamental voltado ao planejamento e execução (guardião e artesão), e com preferência por atividades técnicas como modelagem e programação, com menor inclinação para funções de gestão.

Considerando essas fortalezas e principalmente limitações, avançou-se para a próxima fase que é o Design da solução adequada para o ciclo.

3.2.2.2 Fase 2: Design da solução

No Ciclo 2, os critérios de formação das equipes foram definidos com base no perfil da turma, buscando promover diversidade e equilíbrio. Cada equipe foi composta por uma combinação de diferentes perfis comportamentais, com a exigência de que houvesse pelo menos um estudante com perfil idealista ou racional, por serem menos frequentes e contribuírem com características analíticas e cooperativas. Houve também a distribuição equilibrada das estudantes, bem como a inclusão de ao menos um integrante com experiência profissional em cada grupo. As afinidades identificadas nas interações entre os alunos foram consideradas para estimular o engajamento e a colaboração.

3.2.2.3 Fase 3: Implementação da solução

A implementação do algoritmo com esses critérios foi realizada na plataforma Google Colab, que permitiu testar e ajustar o sistema com facilidade e integração aos dados armazenados no Google Drive. A vantagem dessa ferramenta sobre a do ciclo anterior é a facilidade de acesso, pois é uma plataforma online, com controle de versionamento e acesso ao Google Drive e fácil compartilhamento de código.

3.2.2.4 Fase 4: Avaliação da solução

Nessa fase ocorreu a avaliação da solução gerada para essa turma durante o Ciclo 3. A professora da disciplina mostrou-se bem interessada no algoritmo que, nessa fase, ainda não possuía uma interface que permitia o seu uso independente do autor, portanto, essa é a principal sugestão de melhoria para o ciclo seguinte, já que o sistema se mostrou eficaz na formação de equipes equilibradas, das quais apenas uma não atingiu todos os critérios de restrição propostos previamente pela docente.

3.2.2.5 Fase 5: Validação da solução

Para encerrar o Ciclo 2, foi realizada uma análise reflexiva acerca da adequação da solução para uso geral e a resposta é que o algoritmo ainda não estava preparado para ser utilizado, portanto foi iniciado o terceiro ciclo a fim de finalizar, principalmente a sua interface e torná-la mais amigável até para facilitar sua aceitação entre os usuários.

No segundo ciclo, o algoritmo foi aprimorado para incorporar critérios mais sofisticados, como diversidade de perfis comportamentais, afinidades e experiência profissional. Este ciclo foi crucial para validar a capacidade do sistema de formar equipes equilibradas e heterogêneas, atendendo a restrições pedagógicas mais complexas. Os resultados obtidos consolidaram o algoritmo como um componente funcional robusto, destacando sua eficiência em atender à maioria dos critérios propostos.

3.2.3 Ciclo DSR 3: Ciclo de interface da solução

No terceiro ciclo do processo orientado pela metodologia DSR, desenvolvido no período de 2023.2, o objetivo principal foi a criação de uma interface amigável e intuitiva, visando facilitar o uso do sistema por parte dos professores e, consequentemente, aumentar a aceitação da solução final. Diferentemente dos ciclos anteriores, que se concentraram no desenvolvimento do algoritmo, nesta etapa foi construída uma interface capaz de receber dados por meio de planilhas no formato CSV e retornar a formação de equipes com base nos critérios previamente selecionados pelo organizador, além de fornecer um detalhamento tanto da turma como um todo, antes da distribuição, quanto do perfil de cada equipe formada. Para isso, utilizou-se a plataforma Streamlit, uma ferramenta que permite transformar scripts Python em aplicações web interativas de forma rápida e simplificada. Essa mudança representou um avanço significativo, ao aproximar a solução de um produto utilizável no contexto real de aplicação.

3.2.3.1 Fase 1: Investigação do problema

Com base nos entraves encontrados no levantamento de dados dos ciclos anteriores, gerando sobrecarga do algoritmo e perda de tempo dos envolvidos, o ciclo 3 foi iniciado com alterações na planilha de coleta de dados.

Nos campos Faixa etária, Perfil MBTI e Preferência dos estudantes foram inseridas validações para mitigar interpretações ambíguas pelo sistema. Além disso, a célula correspondente ao Perfil Keirsey ficou bloqueada para os estudantes, pois estava atrelada ao Perfil MBTI, ou seja, o estudante selecionava seu perfil MBTI e automaticamente o Perfil Keirsey era indicado. Outra melhoria nesse sentido, foi usar um ID para o estudante indicar suas afinidades através de uma chave única numérica. São pequenos ajustes que promoveram uma fluidez significativa no processamento das informações.

A Turma 3 é composta majoritariamente por estudantes jovens e do sexo masculino, com pouca experiência profissional. Destaca-se pelo alto número de estudantes com perfil racional, o que indica uma tendência a pensar de forma lógica e estratégica. Em relação às preferências, há uma clara inclinação para tarefas técnicas como programação e modelagem, enquanto a gestão é menos procurada.

Na fase seguinte, o design da solução baseado neste perfil será apresentado.

3.2.3.2 Fase 2: Design da solução

Na fase de design da solução do terceiro ciclo, foram definidos os elementos essenciais para adaptar o sistema ao perfil específico da Turma 3. A primeira etapa consistiu na escolha da tecnologia, sendo adotada a plataforma Streamlit para o desenvolvimento da interface gráfica. Essa decisão considerou a necessidade de oferecer uma experiência mais acessível e interativa para os usuários finais, no caso, os professores responsáveis pela formação das equipes.

No Ciclo 3, a formação das equipes considerou critérios voltados à diversidade e equilíbrio entre os membros. Foram combinados diferentes perfis comportamentais e distribuídos, de forma equitativa, os perfis mais raros, artesão e idealista, garantindo ao menos um por equipe. Também foi assegurada a presença de estudantes do sexo feminino e de ao menos um membro com experiência profissional em cada grupo. Além disso, afinidades observadas nas interações entre os alunos foram levadas em conta para favorecer a colaboração.

A proposta de solução incorporará as melhorias identificadas no ciclo anterior e será detalhada no Capítulo 4.

3.2.3.3 Fase 3: Implementação da solução

Através da plataforma Streamlit foi possível construir uma interface de comunicação simples entre o usuário e o algoritmo. O sistema não apenas informa as equipes formadas, mas também dá detalhes das características de cada uma, através da análise de seus perfis.

Também é possível visualizar as informações individuais dos estudantes antes mesmo da formação das equipes. A linguagem usada foi Python.

A implementação da solução incluirá as melhorias identificadas no ciclo anterior e será detalhada no Capítulo 4.

3.2.3.4 Fase 4: Avaliação da solução

Em relação a solução apresentada pelo autor para formação de equipes no

ciclo 3, as equipes formadas mostraram-se bastante heterogêneas entre seus integrantes e semelhantes entre si, isso é confirmado na satisfação de restrições, das quais cinco das seis equipes tiveram todos os critérios de restrição satisfeitos.

Ademais, com a nova interface, o sistema tornou-se atrativo e de fácil utilização. Avaliações mais objetivas, considerando o modelo de correlação de Spearman da solução e o desempenho dos estudantes serão discutidas no Capítulo 5.

3.2.3.5 Fase 5: Validação da solução

Com base no cumprimento dos objetivos programados para o sistema nesta pesquisa, o autor confirma a solução e avança para a etapa final do método DSR, que é a apresentação dos Resultados da Pesquisa.

No terceiro ciclo, o objetivo principal foi desenvolver uma interface gráfica amigável utilizando a plataforma Streamlit, tornando o sistema acessível para professores. Este ciclo foi essencial para transformar o artefato em um produto utilizável, permitindo a entrada de dados por planilhas CSV e a configuração personalizada dos critérios de formação. Os resultados deste ciclo demonstraram a capacidade do sistema de atender plenamente aos objetivos da pesquisa, consolidando-o como uma solução prática e eficiente para o contexto educacional.

3.3. RESULTADOS DA PESQUISA

A última etapa do Fluxo DSR são os resultados da Pesquisa. Esta etapa é composta por três atividades: Análise de dados, Resultados e Discussões e Conclusões. Veja a seguir, de modo geral e sucinto, as propostas de cada uma.

3.3.1 Análise de Dados

Nesta etapa, procedeu-se à coleta, organização e sistematização dos dados gerados a partir da utilização da interface final de formação de equipes. Foram considerados os dados de entrada (como perfis comportamentais, experiência profissional, gênero e afinidades dos estudantes) e os dados de saída (as composições de equipe geradas pelo sistema). A análise teve como objetivo verificar a conformidade entre os critérios previamente definidos e os resultados produzidos,

além de preparar os dados necessários para a avaliação quantitativa da ferramenta, com destaque para o cálculo da correlação de Spearman, utilizada como técnica estatística para medir a aderência entre critérios e formações realizadas.

3.3.2 Resultados e Discussões

A atividade de avaliação da ferramenta foi conduzida com base na aplicação da correlação de Spearman, que permitiu aferir o grau de correspondência entre os critérios estabelecidos (como equilíbrio de perfis, diversidade de gênero, experiência profissional e afinidades interpessoais) e as composições formadas pelo sistema. Os resultados obtidos indicaram correlações significativas, o que evidencia que os critérios definidos foram, em grande medida, respeitados pelo algoritmo. A partir desses dados, foram discutidas as implicações práticas dos resultados, as contribuições da ferramenta para o processo de formação de equipes em contextos educacionais e as limitações observadas, especialmente em relação à variabilidade dos perfis disponíveis e à subjetividade presente em alguns critérios, como afinidade interpessoal.

3.3.3 Conclusões

A última etapa do processo teve como finalidade sintetizar os principais achados da pesquisa, à luz dos resultados obtidos e das discussões realizadas. Constatou-se que a solução desenvolvida ao longo dos três ciclos do DSR demonstrou viabilidade técnica e aderência pedagógica, cumprindo os objetivos propostos. A aplicação da correlação de Spearman revelou-se um recurso metodológico eficaz para validar a funcionalidade do sistema e sua capacidade de aplicar os critérios definidos de maneira objetiva. A pesquisa contribui para a área de tecnologias educacionais ao propor uma ferramenta flexível, personalizável e de fácil aplicação para a formação de equipes em sala de aula. Recomenda-se, como continuidade, a ampliação da aplicação da solução em outros contextos e disciplinas, bem como o refinamento dos critérios de formação com base em novos indicadores pedagógicos.

4. xPBL TEAMS: UMA SOLUÇÃO DE FORMAÇÃO DE EQUIPES

Este capítulo apresenta em detalhe a solução xPBL Teams, uma proposta de ferramenta computacional desenvolvida para automatizar e otimizar a formação de equipes de estudantes em ambientes PBL. O objetivo central deste capítulo é descrever minuciosamente a concepção, a arquitetura, as funcionalidades e o mecanismo de formação de equipes implementado no xPBL Teams. A introdução da solução xPBL Teams, portanto, não apenas descreve um artefato técnico, mas a posiciona como uma resposta direta a um desafio pedagógico significativo no ensino de computação que utiliza o PBL, estabelecendo uma ligação explícita entre as dificuldades da formação manual e os benefícios da abordagem automatizada proposta.

4.1 CONCEPÇÃO E FUNDAMENTAÇÃO

A concepção da ferramenta xPBL Teams partiu da necessidade premente de superar as limitações inerentes ao processo manual de formação de equipes em contextos de PBL.

Em concordância com a definição de Moreno, Ovalle e Vicari (2012) sobre grupos balanceados, buscou-se um modelo de formação de equipes que fosse o mais diversificado possível, combinando perfis semelhantes entre si, de modo que a probabilidade de sucesso para cada equipe fosse equivalente.

Com base na experiência com outras turmas, a equipe pedagógica determinou um conjunto inicial de restrições que foi estabelecido antes da interação com os estudantes, fundamentado nos perfis historicamente mais comuns na disciplina. Esses critérios são apresentados e justificados no Quadro 2.

Quadro 2 - Critérios para Formação de Equipes

Critério de Formação	Justificativa	Referência
1. Mistura de personalidades MBTI	Grupos com personalidades diversas possuem variedade de habilidades e perspectivas, favorecendo a criatividade e produtividade.	Montequín et al., 2010
2. Personalidades MBTI minoritárias distribuídas nas equipes	Representatividade evita marginalização e valoriza perspectivas únicas.	Montequín et al. (2010)
3. Gênero minoritário distribuído nas equipes	Importante para evitar marginalização e promover diversidade.	Michailidou e Economides (2008)
4. Pelo menos um membro com experiência profissional	Traz conhecimento prático e capacidade de mentoria para os demais membros.	Fonteijn e Dolmans (2019); Henry et al. (2012)
5. Afinidades entre os colegas de turma indicadas pelos estudantes a partir da sua prévia interação	Afinidades prévias favorecem a colaboração mais fluida e produtiva.	Ardaiz-Villanueva et al. (2011)

Fonte: Elaborado pelo autor (2025)

A Figura 3 ilustra o processo de formação de equipes proposto. Na primeira interação com a turma, os estudantes são apresentados ao PBL, e seus perfis e afinidades são levantados. Inicialmente, os estudantes preenchem um formulário online que lhes permite classificar seu tipo de personalidade com base nos perfis MBTI (Myers-Briggs Type Indicator). Com seu perfil MBTI, os estudantes são direcionados a preencher uma planilha com dados relacionados aos critérios selecionados pelo professor, que neste caso incluem nome, faixa etária, gênero, perfil Keirsey

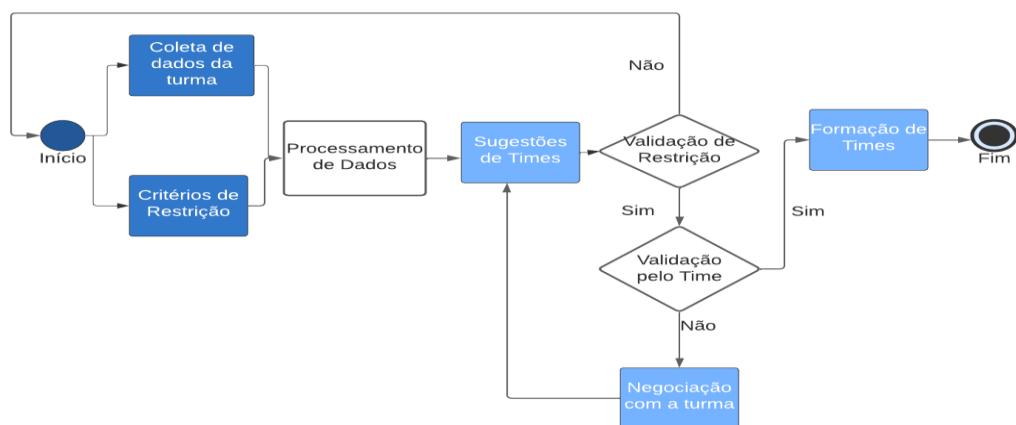
(convertido do MBTI), tempo de experiência, atividade preferencial (Programação - P, Modelagem - M ou Gerenciamento - G) e afinidades (participantes com quem desejam trabalhar). O perfil Keirsey é utilizado para facilitar a compreensão das habilidades com base nas duas dimensões: comunicação e ação (KOBUSINGYE, 2006).

Após os estudantes preencherem os dois formulários, ocorre a preparação dos dados na etapa 1 do ciclo. Com base nos dados obtidos, os ajustes necessários são feitos nos critérios de restrição preestabelecidos para adaptá-los à realidade de cada turma. Por exemplo, se não houver mulheres matriculadas em uma turma, a restrição 3 perde o sentido e será removida da lista.

Na etapa 2, design da solução, define-se como o algoritmo se comporta em casos mais complexos e a ordem de prioridade entre os critérios. O algoritmo adotado para a formação de equipes opera em um ambiente desenvolvido em Python, utilizando a biblioteca Pandas para manipulação de dados. A lógica do algoritmo foi estruturada em torno da personalização de prioridades e critérios específicos, como perfil de personalidade, gênero, experiência, preferência, faixa etária e afinidades.

Na etapa 3, a seleção e distribuição dos estudantes em grupos é implementada equipe por equipe. À medida que um grupo é formado utilizando as restrições propostas, todos os grupos são formados seguindo os mesmos critérios. O código utiliza estruturas de controle para filtrar e alojar estudantes com base nesses critérios. O algoritmo mantém a flexibilidade ao permitir a escolha personalizada da prioridade dos perfis de personalidade. Adicionalmente, a abordagem técnica emprega a manipulação de estruturas de dados como listas e dicionários para armazenar e gerenciar as informações dos estudantes.

Figura 3 - Processo de Formação de Equipes



Fonte: Elaborado pelo autor (2025)

Finalmente, a distribuição de estudantes sugerida pelo algoritmo é realizada, buscando formar equipes balanceadas, otimizando a heterogeneidade dos grupos formados. As restrições são verificadas após a primeira sugestão das equipes para garantir a satisfação. Se alguma restrição não for atendida, o processo é reiniciado. Se todas as restrições forem atendidas e não houver objeção de nenhum membro, as equipes são finalizadas; caso contrário, inicia-se o processo de negociação com o grupo.

A negociação ocorre após a formação inicial das equipes ser apresentada aos estudantes, permitindo que eles analisem a composição dos grupos e sugiram pequenas modificações. Esse momento é importante para atender ao critério de afinidade, especialmente quando ele possui alta prioridade na parametrização definida pelo organizador. Durante essa etapa, os estudantes podem indicar preferências específicas, como trabalhar com colegas com quem possuem maior afinidade ou ajustar a composição com base em suas próprias percepções de colaboração.

O organizador avalia essas sugestões considerando o impacto das alterações propostas sobre o balanceamento geral das equipes. Caso as mudanças não comprometam significativamente os critérios de formação prioritários, como diversidade de perfis ou inclusão de experiência profissional, elas podem ser implementadas. Essa flexibilidade contribui para aumentar a satisfação dos estudantes com a formação das equipes, sem comprometer os objetivos pedagógicos do modelo PBL.

No contexto do ciclo DSR, essa etapa de negociação está inserida na “Fase 4: Avaliação da Solução” e ocorre manualmente. É nesse momento que o organizador verifica se os critérios de restrição foram atendidos e realiza os ajustes necessários, incluindo as sugestões dos estudantes, para garantir que as equipes estejam alinhadas tanto aos critérios definidos quanto às expectativas dos participantes. Essa abordagem promove um ambiente mais participativo e colaborativo, reforçando o engajamento dos estudantes no processo.

Muitas das dificuldades encontradas no processamento dos dados coletados surgiram desde o momento da coleta; portanto, esta etapa do ciclo é definitiva para o resultado satisfatório do sistema.

A coleta de dados para a formação automatizada de grupos PBL foi realizada por meio de uma planilha do Google Sheets compartilhada com os estudantes e

professores do curso. Essa ferramenta proporcionou acesso fácil e intuitivo aos dados, facilitando a contribuição dos estudantes.

Para garantir a qualidade dos dados coletados, diversas medidas foram implementadas. Inicialmente, foram fornecidas instruções claras e objetivas sobre o preenchimento de cada campo da planilha, visando minimizar erros e inconsistências.

Além disso, a planilha foi configurada com validação automática para determinados campos para evitar a entrada de dados inválidos. Após a conclusão da coleta de dados, a equipe de ensino revisou manualmente os dados para identificar e corrigir possíveis erros ou inconsistências.

A segurança dos dados coletados foi uma preocupação central durante todo o processo. Para garantir a proteção das informações, diversas medidas foram implementadas. Primeiramente, a planilha do Google Sheets foi configurada com permissões de acesso restritas, permitindo apenas a visualização e edição pelos estudantes e pela equipe docente. Além disso, a planilha foi armazenada em um ambiente seguro, acessível exclusivamente aos membros da equipe de pesquisa. Todo o processo de coleta e armazenamento de dados foi conduzido em conformidade com os padrões éticos de pesquisa, garantindo o respeito aos direitos dos participantes.

4.2 REQUISITOS DA SOLUÇÃO

Com base na problemática identificada, nos objetivos da pesquisa e nas bases teóricas para a formação de equipes, foram definidos os Requisitos Funcionais (RF) e Requisitos Não Funcionais (RNF) para a solução xPBL Teams. O Quadro 3 apresenta um resumo destes requisitos.

Quadro 3 - Requisitos Funcionais e Não Funcionais do xPBL Teams

ID do Requisito	Tipo	Descrição Detalhada	Prioridade	Justificativa / Origem
RF01	Funcional	Permitir o upload de dados dos estudantes através de um arquivo em formato CSV, contendo informações como perfil, preferências e afinidades.	Essencial	Necessidade de entrada de dados para o algoritmo
RF02	Funcional	Permitir ao instrutor configurar os parâmetros	Essencial	Flexibilidade para o instrutor adaptar a

		para a formação de equipes, como o número de equipes desejado e a prioridade dos critérios de formação.		formação ao contexto da turma (OE2)
RF03	Funcional	Executar o algoritmo de agrupamento para distribuir os estudantes em equipes com base nos dados de entrada e nos parâmetros configurados.	Essencial	Núcleo da solução automatizada (OE1)
RF04	Funcional	Apresentar as equipes formadas de maneira clara e comprehensível para o instrutor.	Essencial	Saída principal da ferramenta
RF05	Funcional	Fornecer visualizações ou relatórios sobre as características da turma e das equipes formadas (distribuição de perfis, gênero, experiência).	Desejável	Permite ao instrutor analisar as características individuais e coletivas da turma
RF06	Funcional	Permitir a participação do estudante no processo de decisão, através da consideração de afinidades e de um processo de negociação pós-formação.	Essencial	Valorização da autonomia do estudante (OE2)
RNF01	Não Funcional	Usabilidade: A interface do sistema deve ser intuitiva e de fácil utilização para instrutores com diferentes níveis de proficiência tecnológica.	Essencial	Aumentar a probabilidade de adoção e uso efetivo da ferramenta.
RNF02	Não Funcional	Flexibilidade: O sistema deve ser adaptável para considerar diferentes conjuntos de critérios e prioridades, conforme as necessidades da disciplina.	Essencial	Atender a diversos contextos de PBL e objetivos pedagógicos
RNF03	Não Funcional	Desempenho: O algoritmo de formação de equipes deve ser capaz de processar os dados e gerar os resultados de maneira ágil ¹ , atendendo às necessidades práticas do organizador, mesmo para	Essencial	Viabilidade prática da solução.

¹ O termo "tempo hábil" foi definido empiricamente através da experiência dos stakeholders envolvidos. No caso do sistema proposto, considera-se como "tempo hábil" um tempo de processamento de até 1 minuto para gerar os resultados da formação das equipes.

		turmas de tamanho moderado ² .		
RNF04	Não Funcional	Segurança dos Dados: As informações dos estudantes devem ser tratadas com confidencialidade e segurança.	Essencial	Conformidade com princípios éticos e de proteção de dados.
RNF05	Não Funcional	Manutenibilidade: O código da solução deve ser organizado e documentado para facilitar futuras modificações e evoluções.	Desejável	Sustentabilidade da solução a longo prazo.

Fonte: Elaborado pelo autor (2025)

A formalização destes requisitos numa tabela permite uma compreensão clara e concisa do que o sistema xPBL Teams se propõe a fazer e sob quais condições de qualidade, servindo como um referencial para o design e a avaliação subsequente da ferramenta. A coluna "Justificativa/Origem" visa conectar diretamente cada requisito aos problemas identificados na formação manual de equipes ou aos objetivos específicos da pesquisa delineados anteriormente.

4.3 ARQUITETURA DA SOLUÇÃO

A arquitetura do xPBL Teams foi concebida para ser modular, facilitando o desenvolvimento, a manutenção e a potencial expansão futura. Os principais componentes da arquitetura são:

1. **Módulo de Entrada de Dados:** Responsável por receber as informações dos estudantes. Atualmente, isto é realizado através do upload de um arquivo em formato CSV (*Comma-Separated Values*) contendo os perfis, preferências e afinidades dos alunos. Este módulo realiza validações básicas no formato do arquivo.
2. **Módulo de Configuração de Parâmetros:** Consiste na interface gráfica

² No contexto deste trabalho, considera-se como turmas de tamanho moderado aquelas que possuem entre 25 e 40 estudantes. Esse intervalo foi definido com base na prática educacional da professora responsável. Turmas acima de 40 estudantes são classificadas como grandes.

(desenvolvida em Streamlit) que permite ao instrutor definir os parâmetros para a formação das equipes. Estes parâmetros incluem o número desejado de equipes, a seleção dos critérios de formação (personalidade, gênero, experiência, afinidade) e a atribuição de prioridades a esses critérios.

3. **Módulo de Processamento (Motor do Algoritmo):** Este é o núcleo da solução, onde o algoritmo de formação de equipes é executado. Implementado em Python e utilizando a biblioteca Pandas para manipulação de dados, este módulo aplica a lógica de agrupamento com base nos dados de entrada e nos parâmetros configurados pelo instrutor para distribuir os estudantes pelas equipes.
4. **Módulo de Saída e Visualização:** Também parte da interface Streamlit, este componente é responsável por apresentar os resultados da formação das equipes ao instrutor. Isto inclui a listagem dos membros de cada equipe, bem como informações e estatísticas sobre o balanceamento alcançado em relação aos critérios definidos.

O fluxo de dados inicia-se com o instrutor fornecendo os dados dos estudantes (via CSV) e configurando os parâmetros na interface Streamlit. Essas informações são passadas para o módulo de processamento em Python/Pandas, que executa o algoritmo. As equipes resultantes são então retornadas à interface Streamlit para visualização pelo instrutor.

4.3.1 Tecnologias Empregadas

A seleção das tecnologias para o desenvolvimento do xPBL Teams foi pautada pela adequação aos requisitos do projeto, pela familiaridade da equipe de desenvolvimento e pela disponibilidade de bibliotecas robustas para as tarefas necessárias. As principais tecnologias utilizadas foram:

- **Python:** Escolhida como a linguagem de programação principal para o desenvolvimento do backend e da lógica do algoritmo de formação de equipes. A sua vasta gama de bibliotecas para análise de dados, a sua sintaxe clara e a sua popularidade na comunidade científica e de desenvolvimento de software tornaram-na uma escolha natural.

- **Pandas:** Uma biblioteca Python fundamental para a manipulação e análise de dados. Foi utilizada extensivamente para carregar, limpar, transformar e processar os dados dos estudantes (provenientes do arquivo CSV) de forma eficiente, antes e durante a execução do algoritmo de agrupamento.
- **Streamlit:** Um framework Python de código aberto utilizada para criar e compartilhar aplicações web interativas para projetos de ciência de dados e machine learning com rapidez e facilidade. Foi a tecnologia escolhida no Ciclo DSR 3 para desenvolver a interface gráfica do xPBL Teams, permitindo que instrutores interajam com a ferramenta através de um navegador web sem necessidade de conhecimentos de programação. A escolha do Streamlit reflete uma priorização da usabilidade e da acessibilidade para o utilizador final, o que é crucial para a adoção da ferramenta no contexto educacional. A transição de um foco puramente algorítmico nos ciclos iniciais para um foco na experiência do utilizador no ciclo final, facilitada pelo Streamlit, representa um passo importante para aumentar o impacto prático da solução.

A combinação destas tecnologias permitiu o desenvolvimento de uma solução que é, ao mesmo tempo, robusta na sua capacidade de processamento de dados e formação de equipes, e acessível aos instrutores através de uma interface web intuitiva.

4.4 INTERFACE E OPERACIONALIZAÇÃO DO xPBL TEAMS

A interface do xPBL Teams foi desenvolvida com a ferramenta Streamlit, visando proporcionar uma experiência de utilização intuitiva e acessível para os instrutores. Esta seção descreve a visão geral da interface gráfica, as suas principais funcionalidades e telas, e apresenta um exemplo prático de utilização. A aplicação está disponível em <https://pbltteamformer-cin-ufpe.streamlit.app/>.

4.4.1 Visão Geral da Interface Gráfica (Streamlit)

A aplicação xPBL Teams, acessível via navegador web, apresenta uma interface limpa e direta, característica das aplicações construídas com Streamlit. O layout é tipicamente de uma única página focada na funcionalidade principal: a

formação de equipes. A Figura 4 demonstra uma abordagem minimalista, com elementos de formulário padrão como botões de upload, campos de seleção e caixas de texto para entrada de parâmetros, e áreas de exibição para os resultados.

A escolha do Streamlit no Ciclo DSR 3 foi motivada pela sua capacidade de transformar rapidamente scripts Python complexos em aplicações web interativas, sem exigir um extenso desenvolvimento front-end. Isto permitiu concentrar esforços na lógica do algoritmo e na usabilidade da ferramenta para o público-alvo: instrutores que podem não ter profundo conhecimento técnico em programação, mas que necessitam de uma ferramenta eficaz para gerir a formação de equipes. A simplicidade aparente da interface esconde a complexidade do algoritmo de agrupamento e dos múltiplos critérios de formação, tornando a ferramenta acessível.

Figura 4 - Interface do xPBL Teams

The screenshot shows the Streamlit interface for the xPBL Teams application. At the top, there's a header with the app name and a 'Share' button. Below the header, there's a section for uploading a CSV file, with a placeholder 'Drag and drop file here' and a 'Browse files' button. There's also a checkbox for 'Mostrar layout do csv (separados por ;)'. A 'Número de Grupos' input field shows the value '1'. Below these, there are two dropdown menus for selecting priorities: 'Escolha a prioridade dos critérios' and 'Escolha os perfis keirsey prioritários da turma', both currently set to 'Choose an option'. At the bottom, there are two buttons: 'Ver Perfil da Turma' and 'Formar Times'.

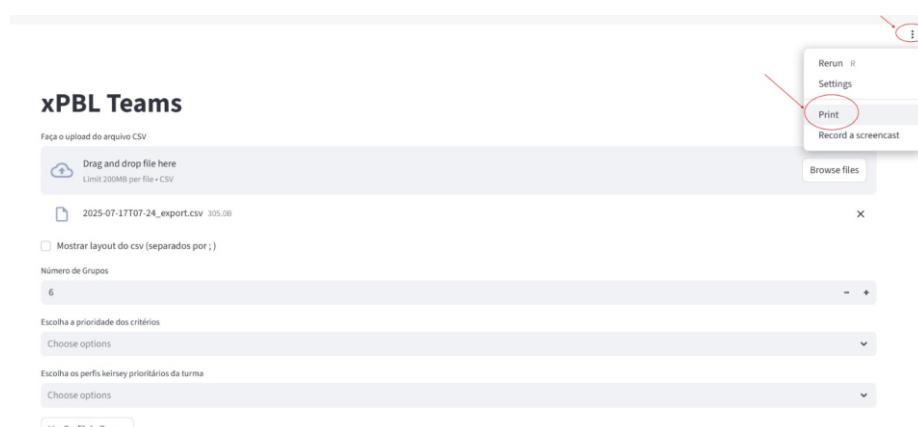
Fonte: Elaborado pelo autor (2025)

Nesta versão, o organizador insere os dados dos estudantes no sistema por meio de um arquivo CSV, cujo modelo está detalhado no Quadro 4. A interface do sistema também informa que o formato correto do arquivo deve ser CSV e que o tamanho máximo permitido é de 200 MB, garantindo praticidade no processo de configuração inicial. Após carregar o arquivo, o organizador pode visualizar o perfil geral da turma clicando na opção "Ver perfil da turma". Essa funcionalidade permite identificar, de forma clara, os perfis Keirsey minoritários, auxiliando na definição da ordem de prioridade para o campo "Escolha os perfis Keirsey prioritários da turma".

Com os critérios e suas respectivas prioridades definidos, as equipes podem ser geradas ao clicar na opção "Formar times". Caso não haja pessoas com um determinado critério prioritário para alocação em uma equipe, o algoritmo automaticamente segue para o próximo critério, garantindo o máximo possível de balanceamento. Ao final do processo, os estudantes remanescentes são alocados na equipe com menos integrantes, garantindo que todas as equipes sejam formadas de maneira eficiente.

O sistema gera e exibe na tela a formação das equipes, permite ao organizador imprimir a formação dos times em PDF (ver Figura 5) e baixar cada equipe individualmente em CSV (ver Figura 6). Essas funcionalidades foram desenvolvidas utilizando a plataforma Streamlit, proporcionando maior flexibilidade e praticidade na gestão e exportação das equipes geradas.

Figura 5 - Impressão de PDF da formação das equipes



Fonte: Elaborado pelo autor (2025)

Figura 6 - Impressão em CSV de cada equipe

The screenshot shows a table titled 'Time 1' with the following data:

	id	aluno	faixa_etaria	genero	email	perfil_mitsi	perfil_keirsey	experiencia	preferencia	afinidades
0	10	ALUNO 10	B - 21 a 25	M	[redacted]@cin.ufpe.br	ISTJ	Guardião	2,0	Programar	None
1	12	ALUNO 12	A - 18 a 20	F	[redacted]@cin.ufpe.br	ESFP	Artesão	0,3	Gerenciar	1,13
2	5	ALUNO 05	None	M	None	None	None	0	None	None

In the top right corner of the table, there's a button 'Download as CSV' which is circled in red. A red arrow points from the caption to this button.

Fonte: Elaborado pelo autor (2025)

4.4.2 Principais Funcionalidades e Telas

A operacionalização do xPBL Teams envolve algumas telas e funcionalidades chave, que guiam o instrutor através do processo de formação de equipes:

1. Tela Inicial e Upload de Dados:

- **Funcionalidade:** Permitir que o instrutor carregue os dados dos estudantes.
- **Interface:** Apresenta um botão ou uma área de "arrastar e soltar" para o upload de um arquivo em formato CSV. Instruções sobre o formato do arquivo e o tamanho máximo permitido são geralmente fornecidas.
- **Formato do Arquivo CSV:** É crucial que o arquivo CSV siga um formato específico para que o sistema possa processar os dados corretamente. Com base nos dados coletados durante os ciclos DSR e nas necessidades do algoritmo, o Quadro 4 detalha o formato esperado.

Quadro 4 - Formato do Arquivo CSV de Entrada para o xPBL Teams

Nome da Coluna no CSV	Descrição do Dado	Tipo de Dado (Exemplo)	Exemplo de Valor	Observações
ID Aluno	Identificador único do estudante	Numérico	12	Essencial para referências, especialmente para o critério de afinidades.
Nome Completo	Nome completo do estudante	Texto	João Silva	Para identificação nas equipes formadas.
Gênero	Gênero do estudante	Categórico (M, F)	F	Usado para o critério de diversidade de gênero.
Perfil MBTI	Perfil MBTI do estudante	Texto (4 letras)	ISTJ	Usado para o critério de personalidade.

Perfil Keirsey	Perfil Keirsey (derivado do MBTI)	Categórico (Guardião, Idealista, Artesão, Racional)	Guardião	Usado para o critério de personalidade.
Experiencia Profissional	Tempo de experiência profissional do estudante	Numérico	3 anos	Usado para o critério de experiência.
Preferência	Preferência do estudante por tipo de atividade no projeto (Programar/ Modelar/ Gestão)	Categórico (P, M, G)	P	Usado para diversificar habilidades ou interesses dentro das equipes.
Afinidades	IDs dos colegas	Texto (IDs numéricos/ alfanuméricos)	12,15	Usado para o critério de afinidade. Requer que os IDs correspondam aos ID_Aluno.
Faixa Etária	Faixa etária do estudante	Categórico (A: 18-20, B: 21-25, C: >25)	B	Pode ser usado como um critério adicional de diversidade

Fonte: Elaborado pelo autor (2025)

Figura 7 – Funcionalidade de upload

xPBL Teams

Faça o upload do arquivo CSV

+ Drag and drop file here
Limit 200MB per file • CSV

Mostrar layout do csv (separados por ;)

	id	aluno	faixa_etaria	genero	email	perfil_mbti	perfil_keirsey	experiencia	preferencia	afinidades
0	1	João Silva	A, B ou C	M	joao.silva@example.com	INTJ	Racional	2,0	T, G, M ou P	Lista de ids
1	2	Maria Souza	A, B ou C	F	maria.souza@example.com	ENFJ	Idealista	3,5	T, G, M ou P	Lista de ids

Fonte: Elaborado pelo autor (2025)

2. Configuração de Parâmetros:

- **Funcionalidade:** Permitir ao instrutor definir como as equipes serão formadas.
- **Interface:** Apresenta campos para:
 - Inserir o número de equipes desejado.
 - Selecionar os critérios de formação a serem ativados ("Personalidade", "Gênero", "Experiência", "Afinidade"...).
 - Definir a ordem de prioridade dos critérios selecionados (usando uma lista ordenável ou atribuindo pesos).
 - Especificar parâmetros adicionais para certos critérios, como quais perfis Keirsey devem ser distribuídos prioritariamente entre as equipes.

Figura 8 – Configuração de parâmetros

xPBL Teams

Faça o upload do arquivo CSV

+ Drag and drop file here
Limit 200MB per file • CSV

SGE_2025.1_dados_anonimizados.csv 1.0KB X

Mostrar layout do csv (separados por ;)

Número de Grupos

3 - +

Escolha a prioridade dos critérios

perfil_keirsey
 genero
 experiencia
 preferencia
 faixa_etaria
 afinidades

Desenvolvido por Ricardo Santana com a colaboração do Grupo [NEXT](#) © 2024 - v21112024



Fonte: Elaborado pelo autor (2025)

3. Tela de Geração e Visualização de Equipes:

- **Funcionalidade:** Executar o algoritmo e apresentar as equipes resultantes.
- **Interface:**
 - Um botão "Formar Equipes" para iniciar o processo de formação.
 - Após o processamento, as equipes formadas são exibidas, geralmente numa tabela ou lista, mostrando os nomes (ou IDs) dos estudantes alocados a cada equipe.

Figura 9 – Exemplo Formação de Equipes

xPBL Teams

Faça o upload do arquivo CSV

Drag and drop file here
Limit 200MB per file • CSV

Browse files

SGE_2025.1_dados_anonimizados.csv 1.0KB

Mostrar layout do csv (separados por ;)

Número de Grupos: 3

Escolha a prioridade dos critérios: genero, experiencia, afinidades, faixa_etaria, perfil_keirsey, preferencia

Escolha os perfis keirsey prioritários da turma: racional, idealista, artesão

Ver Perfil da Turma

Formar Times

Time 1

	id	aluno	faixa_etaria	genero	email	perfil_mbti	perfil_keirsey	experiencia	preferencia	afinidades	afim
0	2	ALUNO 02	B - 21 a 25	F	Amspb@cin.ufpe.br	ENFP	Idealista	3,0	Gerenciar	11	None
1	1	ALUNO 01	B - 21 a 25	M	avcl@cin.ufpe.br	ISTJ	Guardião	5,0	Modelar/Analisar	12,13	None
2	11	ALUNO 11	B - 21 a 25	M	mcsm@cin.ufpe.br	ENFJ	Idealista	5,0	Gerenciar	2	*
3	5	ALUNO 05	None	M	None	None	None	0	None	None	None
4	8	ALUNO 08	C - Mais de 25	M	lfa2@cin.ufpe.br	INTP	Racional	6,0	Modelar/Analisar	None	None

Perfil do Time 1

Pessoas em cada faixa_etaria (A, B ou C):

	Faixa Etária	Contagem
0	B - 21 a 25	3
1	C - Mais de 25	1

Pessoas de cada gênero:

	Gênero	Contagem
0	M	4
1	F	1

Time 2

	id	aluno	faixa_etaria	genero	email	perfil_mbti	perfil_keirsey	experiencia	preferencia	afinidades
0	6	ALUNO 06	C - Mais de 25	F	jrm0@cin.ufpe.br	ISTJ	Guardião	6,0	Programar	None
1	3	ALUNO 03	C - Mais de 25	M	bsc2@cin.ufpe.br	ESFP	Artesão	0,5	Gerenciar	15
2	7	ALUNO 07	None	M	None	None	None	0	None	None
3	10	ALUNO 10	B - 21 a 25	M	lgn@cin.ufpe.br	ISTJ	Guardião	2,0	Programar	None
4	13	ALUNO 13	B - 21 a 25	M	mop2@cin.ufpe.br	ESTP	Artesão	1	Programar	1,0,12

Perfil do Time 2

Pessoas em cada faixa_etaria (A, B ou C):

	Faixa Etária	Contagem
0	C - Mais de 25	2
1	B - 21 a 25	2

Pessoas de cada gênero:

	Gênero	Contagem
0	M	4
1	F	1

Time 3

Perfis

Pessoas em cada faixa_etaria (A, B ou C):

Pessoas de cada gênero:

	Faixa Etária	Contagem
0	C - Mais de 25	2
1	A - 18 a 20	1

Fonte: Elaborado pelo autor (2025)

4.4.3 Exemplo Prático de Utilização (Passo a Passo)

Para ilustrar a operacionalização do xPBL Teams, segue um exemplo prático:

- Preparação dos Dados:** A Professora Ana, que leciona uma disciplina de Engenharia de Software com PBL para 30 estudantes, coleta os dados de seus alunos (ID, Nome, Gênero, Perfil Keirsey, Experiência Profissional em anos, Preferência de Atividade P/M/G, e até 3 IDs de colegas com quem gostariam de trabalhar). Ela organiza estes dados num arquivo turma_es_2024.csv.
- Upload do Arquivo:** A Professora Ana acessa à aplicação xPBL Teams no seu navegador. Na tela inicial, ela clica no botão "Carregar CSV" e seleciona o

arquivo turma_es_2024.csv.

3. Configuração dos Parâmetros:

- Ela deseja formar 6 equipes (resultando em 5 membros por equipe). Ela insere "6" no campo "Número de Equipes".
- Ela ativa os seguintes critérios: "Perfil Keirsey", "Gênero", "Experiência Profissional" e "Afinidades".
- Ela define as prioridades.

4. Ela especifica que os perfis "Racional" e "Idealista", minoritários na sua turma, devem ter prioridade na distribuição para garantir que não fiquem concentrados em poucas equipes.

5. Geração das Equipes: A Professora Ana clica no botão "Formar Equipes". O sistema processa os dados por alguns segundos.

6. Análise dos Resultados:

- A tela de resultados exibe as 6 equipes formadas, com a lista de estudantes em cada uma.
- Ela verifica os detalhes dos perfis das equipes. Observa que 5 das 6 equipes têm pelo menos uma aluna. A sexta equipe não tem, mas a turma tem apenas 5 alunas no total. Todas as equipes têm pelo menos um estudante com alguma experiência. A distribuição dos perfis Keirsey parece razoável, com uma mistura em cada equipe e os perfis Racional/Idealista bem distribuídos. Algumas afinidades foram atendidas.

Este exemplo ilustra como o xPBL Teams pode ser utilizado de forma interativa e flexível, apoiando o instrutor na complexa tarefa de formar equipes eficazes para o PBL.

5. RESULTADOS E DISCUSSÕES

Este capítulo apresenta os resultados obtidos com a aplicação da solução automatizada de formação de equipes ao longo dos três ciclos de desenvolvimento, realizados em turmas distintas da disciplina de Sistemas de Gestão Empresarial (SGE). Inicialmente, são descritos os experimentos de formação de equipes em cada ciclo, incluindo os dados coletados dos estudantes, os critérios utilizados, as restrições aplicadas e a verificação do atendimento a essas restrições. Em seguida, realiza-se uma análise estatística da influência do balanceamento das equipes no desempenho dos grupos, com base em três dimensões avaliativas: resultado, processo e satisfação do cliente. São apresentados gráficos comparativos para cada turma, além dos coeficientes de correlação de Spearman, que ajudam a interpretar os efeitos do agrupamento automatizado no contexto do PBL. Por fim, o capítulo discute os principais achados da pesquisa, destacando os avanços obtidos, as limitações observadas e sugestões de melhorias para versões futuras do sistema.

5.1 EXPERIMENTOS DE FORMAÇÃO DE EQUIPES

Nesta seção, serão apresentados os resultados do sistema para os três ciclos aplicados. Os ciclos 1, 2 e 3 foram aplicados em três turmas da disciplina de Sistemas de Gestão Empresarial (SGE). A forma como os dados foram coletados influenciou significativamente os resultados obtidos.

5.1.1 Ciclo DSR 1

A formação das equipes no Ciclo 1 foi realizada manualmente, porém, mesmo após a conclusão do curso, os dados desses estudantes foram utilizados para realizar a primeira iteração do algoritmo.

Esta turma tinha 28 estudantes. Como o período letivo desta turma já havia terminado, foi necessário trabalhar exclusivamente com os dados registrados na planilha que eles preencheram, resultando em muitas imprecisões.

Inicialmente, cada estudante preencheu um formulário com suas características individuais, o que possibilitou a geração de seu perfil MBTI. Em seguida, foi verificada a correspondência entre esse perfil e o perfil Keirsey, resultando na identificação de

ambas as classificações de personalidade. Posteriormente, os dados referentes aos atributos individuais de cada estudante foram registrados em uma planilha, na qual informaram sua faixa etária (as faixas etárias foram separadas em intervalos: A - 18 a 20 anos; B - 21 a 25 anos; C - acima de 25 anos), perfis MBTI e Keirsey, experiência profissional, preferências de trabalho e afinidades com os colegas. No entanto, como a planilha não contava com validações de dados, alguns campos ficaram em branco, conforme ilustrado no Quadro 5.

Quadro 5 - Dados dos estudantes da Turma 1

ID	Faixa Etária	Perfil MBTI	Perfil Keirsey	Experiência de trabalho	Preferência do estudante	Afinidades
Estudante 1	B	ISFJ	Idealista		P	
Estudante 2			artesão			
Estudante 3	A	ISTP	artesão	0	P ou M	7, 13 e 12
Estudante 4	C	ISTJ	Guardião	0	M ou P	15.
Estudante 5	B	ISTJ	Racional	2 anos	P	20, 21 e 23.
Estudante 6						
Estudante 7	A	INFJ	Idealista	0	M ou P	3, 12 e 13.
Estudante 8						
Estudante 9	B	ESFP	Artesão	2a1m	G	
Estudante 10	A	INTJ	Racional	1a 9m	M ou P	17, 18, 22, 24, 26 e 27.
Estudante 11	B	ISTJ	guardião	0	M ou P	18, 25, 26 e 28.
Estudante 12	A	ENTP	Racional	1a	G ou M	3, 7 e 13.
Estudante 13	A	ISFJ	Guardião	1a	G ou M	3, 7 e 12.
Estudante 14	A	INFP	idealista	1a3m	P	2.
Estudante 15	A	ENFP	idealista	0	M	4.

Estudante	16	C	INTJ	Racional	1a	P	
Estudante	17	A	ISTJ	Guardião	0	G ou P	10, 12, 18, 22, 24, 26 e 28.
Estudante	18	C	ESTJ	Guardião	7a	G ou P	11, 25, 26 e 28.
Estudante	20	B	ISTP	artesão	1a+-	G ou P	5, 21 e 23.
Estudante	21	B	INFJ	Idealista	3a	M	5, 20 e 23.
Estudante	22	A	ESTJ	Guardião	0	G ou P	10, 11, 12, 17, 18, 25, 26 e 28.
Estudante	23		INFP	Idealista	0	G ou P	
Estudante	24	A	ISTJ	Guardião	0	G ou P	10, 11, 17, 22, 25, 26 e 28.
Estudante	25	A	ENTJ	racional	0	G	11, 18, 26 e 28.
Estudante	26	B	ESFP	Artesão	2a	G ou P	11, 18, 25 e 28.
Estudante	27	C	INFJ	Idealista	8a	G ou P	10, 17, 20.
Estudante	28	A	ENFP	idealista	1a	G ou M	11, 18, 25 e 26.

Fonte: Elaborado pelo autor (2025)

Os dados da Tabela 1 mostram o perfil dos alunos desta turma agrupados por categoria. Através dela é possível traçar o perfil geral da turma.

Tabela 1 - Perfil dos estudantes da 1^a turma

			TOTAL
Gênero	M	25	28
	F	3	
Faixa de Idade	A	12	24
	B	7	
	C	5	
Perfil Keirsey	Artesão	5	26
	Guardião	8	
	Idealista	8	
	Racional	5	
Experiência Profissional	Sem Experiência	10	25
	Com Experiência	15	
O que você mais gosta de fazer? (P)rogramar, (M)odelar ou (G)erenciar?	P	17	Não se aplica
	M	11	
	G	13	

Fonte: Elaborado pelo autor (2025)

Alguns alunos deixaram em branco alguns campos da planilha de coleta de dados, dificultando, assim, encaixá-los no grupo conforme seu perfil. Devido a isto, tais estudantes foram distribuídos aleatoriamente ou considerando apenas os critérios informados.

Neste ciclo não foram consideradas as afinidades dos estudantes, existindo um

menor número de “Artesãos” e Perfis “Racionais” e uma classe majoritariamente masculina, portanto, após a coleta dos dados, o conjunto de restrições foi o seguinte:

1. Cada equipe é composta por uma mistura de perfis;
2. Um "Artesão" ou "Racional" por equipe.
3. Membros femininos distribuídos pelas equipes;
4. Pelo menos um membro da equipe com alguma experiência profissional;

A primeira distribuição foi obtida após a implementação do algoritmo de formação de equipes, conforme mostrado no Quadro 6.

Quadro 6 - Verificação da satisfação das restrições no Ciclo 1

	Critério 1	Critério 2	Critério 3	Critério 4
Time 1	✓	✓	✓	✓
Time 2	✓	✓	✓	✓
Time 3	✓	✓	✓	✓
Time 4	✓	✓	✓	✓
Time 5	✓	✓	✓	✓

Fonte: Elaborado pelo autor (2025)

Todas as equipes apresentaram uma mistura de perfis relacionados a praticamente todos os critérios possíveis; no entanto, um ponto de melhoria seria adicionar a faixa etária como um dos fatores de variação do perfil dentro da equipe. Embora algumas equipes não tivessem mulheres, três representantes femininas foram distribuídas em diferentes grupos.

Algumas melhorias foram realizadas, como a melhoria do formulário de coleta de dados, que foi considerado para ajuste no Ciclo 2. Além disso, o Ciclo 2 melhorou a questão de considerar as afinidades dos estudantes.

5.1.2 Ciclo DSR 2

Para coletar os dados dos 38 alunos da segunda turma, utilizou-se novamente uma planilha, mas desta vez forneceu-se instruções mais detalhadas sobre como preenchê-la, buscando garantir maior clareza e consistência nas respostas.

A última questão abordava o critério de afinidade, permitindo que os alunos digitassem os nomes de colegas com os quais gostariam de trabalhar. Nesse ciclo, o critério de afinidade foi efetivamente considerado no algoritmo, de modo que cada equipe fosse formada com pelo menos dois integrantes que apresentassem afinidade mútua. No entanto, como o campo era preenchido em formato de texto livre (string), surgiram dificuldades na interpretação automática dos dados devido a erros de digitação, nomes homônimos e ausência de sobrenomes, o que exigiu atenção adicional no tratamento dessas informações.

Com exceção dessas dificuldades específicas no campo de afinidade, a planilha foi bem preenchida por todos os alunos, e nenhum participante ficou de fora do processo de alocação.

O Quadro 7 mostra as características individuais dos estudantes da Turma 2, assim como no primeiro ciclo as afinidades só estão em formato de ID para preservar a identidade dos estudantes, embora eles tenham preenchido nominalmente o que gerou as dificuldades supracitadas.

Quadro 7 - Dados dos estudantes da Turma 2

ID	Faixa Etária	Perfil MBTI	Perfil Keirsey	Experiência profissional	Preferência dos estudantes. (G)erenciar, (M)odelar ou (P)rogramar?	Afinidade
Estudante 1	C	ISTP	Artesão	3 meses	M	30, 33, 6, 31
Estudante 2	B	ESFJ	Guardião	4 meses	G	11, 3, 15, 18, 14, 9, 6, 7, 8, 10, 5, 17, 22, 33

Estudante 3	A	ESFJ	Guardião	20 meses	M	15, 18, 11, 5, 14, 9, 17, 7, 12, 2, 33, 6, 30, 1
Estudante 4	B	ISTP	Artesão	4 meses	P	9, 17, 6, 35, 3, 5, 10, 22, 12, 13
Estudante 5	A	INFJ	Idealista	2 meses	P	2, 3, 11, 12, 4, 9, 14, 17, 18, 7
Estudante 6	B	ESTJ	Guardião	0 meses	P	9, 7, 2, 15, 18, 35, 4, 10, 22, 12, 16, 1
Estudante 7	A	ISFJ	Guardião	1 ano	P	9, 7, 2, 15, 18, 35, 4, 10, 22, 12, 16, 8, 14, 3, 11, 5
Estudante 8	A	ISFJ	Guardião	0 meses	P	9, 7, 2, 15, 18, 6, 35, 4, 10, 22, 12, 16, 8, 14, 3, 11, 5
Estudante 9	A	ISFP	Artesão	0	P	10, 22, 12
Estudante 10	B	ISFJ	Guardião	0 meses	P	14, 18, 2, 15, 8, 7, 17, 4, 11, 3, 12, 10, 6, 22
Estudante 11	B	ISFP	Artesão	8 meses	P	13, 32, 30
Estudante 12	A	ESFJ	Guardião	0 meses	P	3, 2, 5, 12
						5, 4, 11, 3, 2, 17, 14, 15, 9,

							10, 22, 6, 8, 35
							10, 12, 17, 24, 22, 32, 4,
Estudante	13	B	INFP	Idealista	0	G	35, 36
							9, 18, 2, 15, 3, 11, 5, 12,
Estudante	14	A	INFJ	Idealista	0	M	7, 35, 4
							14, 2, 3, 18, 9, 11, 5, 12
Estudante	15	B	INFP	Idealista	1 ano	P	
							21, 20, 38, 29, 25, 19,
Estudante	16	B	ESFP	Artesão	2 meses	M	33
							10, 4, 6, 9, 13, 7, 2, 3, 11, 22, 5, 35,
Estudante	17	A	ESFJ	Guardião	4 meses	P	12, 18
							5, 4, 11, 3, 2, 17, 14, 9, 10, 22, 6, 8, 35,
Estudante	18	A	ENTP	Racional	2 anos	G	12, 13, 7
Estudante	19	A	INTP	Racional	0	M	20
							19, 33, 29,
Estudante	20	B	ESFJ	Guardião	0	G	21, 16
							16, 29, 25,
Estudante	21	B	ISTP	Artesão	3 meses	P	20, 17
							35, 6, 4, 17, 13, 7, 8, 12,
Estudante	22	A	ISFJ	Guardião	0	P	18, 2, 15
Estudante	23	B	ESTP	Artesão	9 meses	P	25, 38, 36,

							34
Estudante 24	B	ISFJ	Guardião	2 anos	G	17, 31	13, 32, 35,
Estudante 25	A	INFJ	Idealista	0	P	16	23, 38, 21, 34, 29, 20,
Estudante 26	B	ESTJ	Guardião	13 meses	P	27	
Estudante 27	B	ISFJ	Guardião	5 meses	P	26, 28, 29	
Estudante 28	B	ISTP	Artesão	0	P	26, 25, 27	
Estudante 29	B	ISTJ	Guardião	0 meses	G	20, 21, 16	26, 25, 28,
Estudante 30	C	INFP	Idealista	65 meses	G	1, 31, 3	
Estudante 31	C	ESTJ	Guardião	41 meses	G	1, 30, 24	
Estudante 32	B	ENTJ	Racional	6 meses	M	13, 24, 32	
Estudante 33	B	INFP	Idealista	0	M	12, 14, 18	1, 2, 3, 29, 17, 20, 21,
Estudante 34	A	ISTJ	Guardião	3 meses	P	38	25, 34, 23,
Estudante 35	A	ESTP	Artesão	2 anos	G	3, 32, 24, 36	10, 6, 4, 17, 13, 7, 8, 12, 18, 2, 15, 14,
Estudante 36	B	ENFP	Idealista	18 meses	G	13, 32	
Estudante 37	A	ISTP	Artesão	0	M	20, 19	
Estudante 38	A	ISTJ	Guardião	9 meses	P	25, 34, 23	

Fonte: Elaborado pelo autor (2025)

Na Tabela 2, observa-se esses dados agrupados por categoria. Dessa vez, é possível, ao agrupá-los dessa forma, contabilizar o total de alunos na categoria

preferência do estudante, já que, nesse ciclo o preenchimento do campo preferência dos estudantes foi cuidadosamente orientado, permitindo que o estudante indique apenas uma das três preferências, não sobrepondo os subconjuntos P, M e G, evitando problemas de interpretação para o algoritmo.

Tabela 2 - Perfil da Turma 2

			TOTAL
Gênero	M	30	38
	F	8	
Faixa de Idade	A	16	38
	B	19	
	C	3	
Perfil Keirsey	Artesão	10	38
	Guardião	17	
	Idealista	8	
	Racional	3	
Experiência Profissional	Sem Experiência	10	38
	Com Experiência	28	
O que você mais gosta de fazer? (P)rogramar, (M)odelar ou (G)erenciar?	P	20	38
	M	8	
	G	10	

Fonte: Elaborado pelo autor (2025)

Nesta turma, o número de mulheres ainda era bem inferior à metade dos estudantes, embora esse número tenha aumentado proporcionalmente para mais de 26% da turma, em comparação com 12% na turma anterior. Portanto, distribuir as mulheres entre os grupos continua sendo uma meta neste ciclo.

Outro tópico que merece atenção é o perfil de Keirsey. A minoria era "Idealista" ou "Racional", então esses são os perfis mais raros e que devem ser distribuídos prioritariamente nas equipes.

Portanto, o conjunto de restrições finais para esta classe foi:

1. Cada equipe é composta por uma mistura de perfis;
2. Um "idealista" ou "racionalista" por equipe;
3. Membros femininos distribuídos pelas equipes;
4. Pelo menos um membro da equipe com alguma experiência profissional;
5. Afinidades identificadas a partir da interação dos estudantes.

O Quadro 8 apresenta a avaliação da distribuição das equipes sob a perspectiva do atendimento às restrições estabelecidas.

Quadro 8 - Verificação da satisfação das restrições no Ciclo 2

	Critério 1	Critério 2	Critério 3	Critério 4	Critério 5
Time 1	✓	✓	✓	✓	✓
Time 2	✓	✓	✓	✓	✓
Time 3	✓	✓	✓	✓	✓
Time 4	✓	✓	✓	✓	✓
Time 5	X	X	✓	✓	✓
Time 6	✓	✓	✓	✓	✓

Fonte: Elaborado pelo autor (2025)

Em todos os grupos houve pelo menos uma pessoa cuja afinidade foi atendida, entretanto, este é um ponto de melhoria do algoritmo, pois houve diversas

incompatibilidades devido a erros de ortografia, formatação ou ambiguidades na digitação dos nomes.

Como demonstrado, os critérios 1 e 2 não foram atendidos na Equipe 5, pois a composição da equipe não incluía um perfil Idealista ou Racional, além da faixa etária do tipo C e pessoas com preferência por Modelagem (M). Portanto, a equipe também violou o critério 1 (mistura de perfis).

Assim, melhorando a distribuição de perfis entre os grupos também foram necessários para o ciclo seguinte.

5.1.3 Ciclo DSR 3

O Quadro 9 mostra os dados individuais dos estudantes da Turma 3. Os dados foram coletados através de uma planilha, igualmente os ciclos anteriores, embora desta vez alguns campos que anteriormente causaram ambiguidades foram corrigidos, gerando, assim, um conjunto de dados mais confiável para a formulação dos critérios de restrições desse ciclo.

Para esse ciclo foram realizadas algumas validações na planilha que coleta os dados dos estudantes, visto aos significativos entraves proporcionados por deficiências nesse processo. A partir desse ciclo, o perfil Keirsey já foi inserido automaticamente na planilha ao preencher o MBTI, evitando erros na correspondência entre os dois perfis de personalidade. Uma outra novidade foi a identificação de cada estudante com um ID, mitigando as possibilidades de más interpretações desse quesito pelo sistema como ocorreu no ciclo 2, bem como a inserção de validações que permitiram aos estudantes indicar apenas uma única resposta por questão nos critérios de restrição, com exceção da última (afinidade), o que ajudou a minimizar ambiguidades.

Quadro 9 - Dados dos estudantes da Turma 3

ID	Faixa Etária	Perfil MBTI	Perfil Keirsey	Experiência de trabalho (em anos)	Preferência do estudante. (G)erenciar, (M)ostrar ou (P)rogramar?	Afinidades (IDs dos colegas separados por vírgula)	
Estudante 1	1	A	ENFP	idealista	0	M	31, 6, 9, 21, 23, 7
Estudante 2	2	A	INTP	racional	0	P	4, 8, 15
Estudante 3	3	A	ESTP	artesão	2	P	
Estudante 4	4	A	ISTP	artesão	1	M	2, 15, 16, 26, 32
Estudante 5	5	B	ESFJ	guardião	0	G	7, 8, 11, 17, 18, 19, 22, 33, 34
Estudante 6	6	A	INTP	racional	0	P	9, 31, 1
Estudante 7	7	A	ENFP	idealista	0	P	
Estudante 8	8	A	ISTJ	guardião	0	G	19, 22, 17, 18, 2, 5, 26, 15
Estudante 9	9	A	INFJ	idealista	0	P	31, 23, 21, 1, 6, 24, 36
Estudante 10	10	A	ISTJ	guardião	1	M	1, 17, 21, 23, 31, 25, 36
Estudante 11	11	A	ISTJ	guardião	0	P	5, 18, 19, 28, 33
Estudante 12	12	B	INFJ	idealista	0	P	
Estudante 13	13	A	INTP	racional	0	P	
Estudante 14	14	A	ISTJ	guardião	0	P	
Estudante 15	15	A	INTP	racional	0	P	2, 3, 4, 8, 13, 26, 29, 35
Estudante 16	16	A	ISTJ	guardião	0	P	4, 7, 13

Estudante 17	A	ISTJ	guardião	0	P	22,18, 8, 19, 34, 5, 32
Estudante 18	B	ESFJ	guardião	3	M	19,5,9,32,22
Estudante 19	C	INTJ	racional	0	P	18, 8, 22, 17, 5, 32
Estudante 20	A	INTP	racional	1	M	
Estudante 21	A	ESTP	artesão	3	G	1,9,10,23,31
Estudante 22	C	ENFJ	idealista	0	P	19,32,17,5,18,8
Estudante 23	A	INTP	racional	0	M	1,9,21,31, 10
Estudante 24	A	ENTJ	racional	0	G	30, 36
Estudante 25	B	ENFP	idealista	1,5	G	10
Estudante 26	A	INFJ	idealista	2	M	3, 8, 13, 15, 29, 35
Estudante 27	B	ESFP	artesão	2	G	28
Estudante 28	B	ENTJ	racional	0		
Estudante 29	A	INTJ	racional	0	M	3, 13, 15, 26, 35
Estudante 30	A	ESTP	artesão	0	M	36, 24
Estudante 31	A	ISTJ	guardião	0	P	1, 6, 9, 10, 21, 23
Estudante 32	B	ENTP	racional	0	P	18, 19, 22, 4, 17
Estudante 33	A	INTP	racional	0	M	5. 11
Estudante 34	C	ISTP	artesão	0	M	1, 2, 5, 17, 18, 19, 22, 23, 26, 32
Estudante 35	A	INTJ	racional	0	M	3, 13, 15, 26, 29
Estudante 36	A	ENFJ	idealista	0	P	30, 24, 23, 21, 10, 1, 9

Fonte: Elaborado pelo autor (2025)

A turma 3 tinha 36 estudantes, predominantemente do sexo masculino; a grande maioria é muito jovem e não tem experiência profissional, como mostra a Tabela 3.

Tabela 3 - Perfil da Turma 3

			TOTAL
Gênero	M	27	36
	F	9	
Faixa de Idade	A	26	36
	B	7	
	C	3	
Perfil Keirsey	Artesão	6	36
	Guardião	9	
	Idealista	8	
	Racional	13	
Experiência Profissional	Sem Experiência	27	36
	Com Experiência	9	
O que você mais gosta de fazer? (P)rogramar, (M)odelar ou (G)erenciar?	P	17	35
	M	12	
	G	6	

Fonte: Elaborado pelo autor (2025)

Um dos estudantes não indicou sua preferência técnica, pois o preenchimento

deste item não era obrigatório. Isso constitui uma pendência a ser corrigida no processo.

Nesta classe, obteve-se uma minoria de perfis “Artesão” e “Idealista”, portanto, analisando as características específicas da classe, formulou-se o conjunto final de restrições neste caso:

1. Cada equipe é composta por uma mistura de perfis;
2. Um "artesão" ou "idealista" por equipe;
3. Membros femininos distribuídos pelas equipes;
4. Pelo menos um membro da equipe com alguma experiência profissional;
5. Afinidades identificadas a partir da interação dos estudantes.

Assim como no ciclo anterior, a identificação de afinidades foi problemática, então decidiu-se pedir aos estudantes que selecionassem os IDs dos colegas em vez do nome do participante.

Em relação ao atendimento das restrições no Ciclo 3, o Quadro 10 apresenta o atendimento ou não de cada restrição em cada equipe.

Quadro 10 - Verificação da satisfação das restrições no Ciclo 3

	Critério 1	Critério 2	Critério 3	Critério 4	Critério 5
Time 1	✓	✓	✓	✓	✓
Time 2	✓	✓	✓	✓	✓
Time 3	✓	✓	✓	✓	✓
Time 4	✓	✓	✓	✓	✓
Time 5	✓	✓	✓	✓	✓
Time 6	X	✓	✓	X	✓

Fonte: Elaborado pelo autor (2025)

Na maioria das equipes, os critérios foram atendidos, incluindo afinidade. Como a equipe 6 foi a última a ser formada e essa equipe tinha pouquíssimas pessoas com

experiência e propensas à gestão, o algoritmo ficou sem opções para atender aos critérios 1 e 4. Além desses pontos de melhoria, a interface precisava ser melhorada após a aplicação do Ciclo 3. Vale acrescentar que ao final da implementação de cada ciclo, o professor abre uma rodada de negociação com os estudantes para considerar as possibilidades de atender a mais solicitações dos estudantes; portanto, o resultado é diferente daquele gerado pelo algoritmo.

A não satisfação de alguns critérios em determinadas equipes pode ser explicada por uma combinação de fatores relacionados às características das turmas e às condições específicas do contexto de aplicação. O sistema foi desenvolvido para otimizar a formação de equipes com base em múltiplos critérios, como mistura de perfis, inclusão de perfis específicos (como "Idealista" ou "Racional"), distribuição de estudantes com experiência profissional e consideração de afinidades. No entanto, alguns aspectos influenciaram o cumprimento pleno dessas restrições.

Um dos fatores que podem ter contribuído é a baixa diversidade de perfis em algumas turmas. Por exemplo, na Turma 3, a predominância de estudantes com perfil "Racional" e a escassez de perfis "Idealista" e "Artesão" limitaram as opções disponíveis para satisfazer o critério de mistura de perfis. Da mesma forma, o número reduzido de estudantes com experiência profissional em algumas turmas dificultou o atendimento ao critério que exigia pelo menos um membro experiente por equipe, especialmente nas últimas equipes formadas.

Além disso, a ordem de formação das equipes pode ter influenciado os resultados. Em cenários onde os últimos grupos foram formados com os estudantes restantes, as opções disponíveis já eram mais restritas, o que pode ter comprometido o cumprimento de alguns critérios. Isso foi observado na Turma 2, onde a equipe 5 não satisfez os critérios relacionados à mistura de perfis e inclusão de um estudante "Idealista" ou "Racional".

Embora o sistema tenha apresentado resultados positivos na maior parte das equipes, é possível que o algoritmo tenha enfrentado limitações ao lidar com situações de conflito entre restrições e características insuficientes dos estudantes. No entanto, essas limitações refletem os desafios inerentes ao processo de formação de equipes em cenários reais, especialmente em turmas com perfis menos diversificados.

Dessa forma, os resultados evidenciam que o sistema gerado oferece uma solução robusta para a formação de equipes, mesmo em contextos desafiadores. Para aprimorar ainda mais sua eficácia, recomenda-se considerar ajustes futuros, como a

implementação de mecanismos para reavaliação e ajuste dos grupos após a formação inicial e o uso de validações automáticas na coleta de dados para garantir maior consistência nas informações utilizadas. Essas medidas podem ampliar ainda mais a capacidade do sistema de atender aos critérios de forma eficiente e adaptável em diferentes contextos educacionais.

5.2 ANÁLISE ESTATÍSTICA DA INFLUÊNCIA DA FORMAÇÃO DE EQUIPES NO DESEMPENHO DOS ESTUDANTES

Esta seção tem como objetivo principal investigar, por meio de métodos estatísticos, se a forma como as equipes foram originalmente formadas (manual ou automaticamente) possui relação com o desempenho final dos grupos em atividades baseadas no PBL. A análise é realizada com base nos dados obtidos em três turmas distintas e utiliza um processo de classificação do desempenho das equipes fundamentado nas dimensões Resultado, Processo e Satisfação do Cliente. Esse modelo de avaliação foi desenvolvido por Santos (2016), no âmbito da dimensão do estudante do PBL-SEE (Problem-Based Learning Student Evaluation Extension), que contempla cinco aspectos para a avaliação da aprendizagem em ambientes baseados em projetos.

5.2.1 Método Estatístico Utilizado: Correlação de Spearman

Para investigar a possível influência da formação inicial dos times sobre o desempenho obtido nas atividades realizadas com base no PBL, adotou-se como método estatístico a **correlação de Spearman**, também conhecida como **coeficiente de correlação de postos de Spearman** (ρ ou rho). Essa técnica estatística permite avaliar a **associação monotônica** entre duas variáveis, ou seja, a tendência de que os valores de uma variável aumentem ou diminuam de maneira consistente conforme os valores da outra variam.

A correlação de Spearman é especialmente apropriada para **dados ordinais** ou para situações nas quais a relação entre as variáveis não pode ser assumida como linear, o que a diferencia da correlação de Pearson. Além disso, por ser um método **não paramétrico**, Spearman não exige que os dados sigam uma distribuição normal, característica que o torna ideal para contextos educacionais, onde frequentemente há

heterogeneidade de comportamento, variações no desempenho e outliers.

→ Fundamentação estatística

O coeficiente de Spearman é calculado com base na ordenação dos valores das duas variáveis em análise. No presente estudo, as variáveis observadas são:

- **Atendimento aos critérios de restrição:** Cada equipe recebeu uma pontuação proporcional à quantidade de critérios atendidos (0,2 por critério), variando de 0,0 a 1,0.
- **Desempenho médio do grupo:** obtido a partir das avaliações aplicadas ao longo das etapas do projeto, podendo ser analisado de forma global ou por dimensão (Processo, Resultado, Satisfação).

Após ordenar os valores de ambas as variáveis e calcular a diferença entre os ranks (d_i) de cada par, aplica-se a seguinte fórmula:

$$\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2-1)}, \text{ os quais:}$$

- n representa o número de observações (grupos),
- d_i é a diferença entre os ranks de cada par de variáveis.

O valor de ρ varia entre -1 e 1:

- $\rho = 1$ indica uma **correlação positiva perfeita** (à medida que uma variável aumenta, a outra também aumenta),
- $\rho = -1$ indica uma **correlação negativa perfeita** (à medida que uma variável aumenta, a outra diminui),
- $\rho \approx 0$ indica ausência de correlação monotônica.

→ Aplicação na presente pesquisa

O uso da correlação de Spearman nesta pesquisa visa **avaliar se existe uma tendência geral de melhor desempenho por parte dos grupos formados automaticamente**, em comparação com os formados manualmente. Como o

desempenho dos grupos pode ser influenciado por múltiplos fatores, e os dados não seguem uma distribuição padronizada, a robustez da Spearman frente a esses aspectos torna sua aplicação particularmente valiosa.

Além disso, ao utilizar rankings em vez dos valores absolutos, minimiza-se o impacto de variações sutis ou pontuais nos dados — o que é especialmente importante ao lidar com amostras reduzidas, como é o caso das turmas analisadas. A escolha por essa abordagem contribui para uma análise mais confiável e sensível às relações de tendência entre os grupos, mesmo com um número limitado de observações.

A correlação de Spearman, portanto, é utilizada aqui como um **instrumento complementar à análise descritiva**, contribuindo para a identificação de padrões de associação entre a configuração dos times e os resultados obtidos, em cada uma das três dimensões de avaliação adotadas no projeto: Processo, Resultado e Satisfação do cliente.

5.2.2 Os gráficos de desempenhos

Esta seção apresenta os gráficos de desempenho das três turmas envolvidas na pesquisa, os quais avaliam as equipes ao longo das etapas do projeto com base no modelo PBL-SEE (*Problem-Based Learning – Student Evaluation Extension*), desenvolvido por Santos (2016). Este modelo propõe uma avaliação autêntica da aprendizagem em ambientes baseados em PBL, estruturada na perspectiva do estudante, composta por cinco dimensões: Conteúdo, Processo, Resultado, Performance e Satisfação do Cliente. Cada um desses aspectos está associado a objetivos educacionais específicos e é avaliado por diferentes agentes, conforme detalhado a seguir:

- **Conteúdo:** avalia o domínio de conceitos e fundamentos teóricos adquiridos pelos estudantes. Essa dimensão é avaliada pelos professores, por meio de instrumentos como provas, relatórios ou atividades escritas.
- **Processo:** examina a condução do trabalho em equipe, incluindo clareza na organização, planejamento, divisão de tarefas e estratégias adotadas. A avaliação é realizada por professores e tutores, com base em critérios observacionais e registros das atividades do grupo.
- **Resultado:** considera a qualidade dos artefatos produzidos pelas equipes,

avaliando critérios como completude, aderência aos requisitos, qualidade técnica e inovação. Assim como o processo, é avaliado por professores e tutores, geralmente ao final de cada entrega parcial ou final.

- **Performance:** trata do comportamento individual dos estudantes no ambiente de equipe, avaliando aspectos como iniciativa, colaboração, liderança e responsabilidade. Esta dimensão é avaliada por meio de autoavaliação, avaliação por pares e avaliação dos tutores, e tem foco na atuação de cada membro individualmente, mesmo que no contexto do trabalho coletivo.
- **Satisfação do Cliente:** mede a percepção do cliente (real ou simulado) sobre o produto entregue pela equipe, considerando aspectos como utilidade, usabilidade, qualidade percebida e atendimento às expectativas. Esta avaliação é realizada diretamente pelo cliente, com base em critérios previamente definidos e registrados em instrumentos estruturados.

Embora o modelo compreenda essas cinco dimensões, nesta análise foram consideradas apenas aquelas voltadas à avaliação coletiva das equipes (Processo, Resultado e Satisfação do Cliente). As dimensões Conteúdo e Performance foram excluídas por se tratar de avaliações de natureza individual, cujo foco incide sobre o desempenho específico de cada estudante, não representando diretamente o desempenho da equipe enquanto unidade de trabalho.

A partir da consolidação dos dados dessas três dimensões, foram elaborados gráficos que possibilitaram a visualização da evolução das equipes ao longo do tempo, permitindo identificar padrões de melhoria, estabilidade ou oscilação. Esses dados serviram também como base para a aplicação da correlação de Spearman, utilizada com o objetivo de verificar a aderência entre os critérios adotados para a formação das equipes e os resultados obtidos em cada dimensão analisada.

5.2.2.1 Desempenho - Turma 1

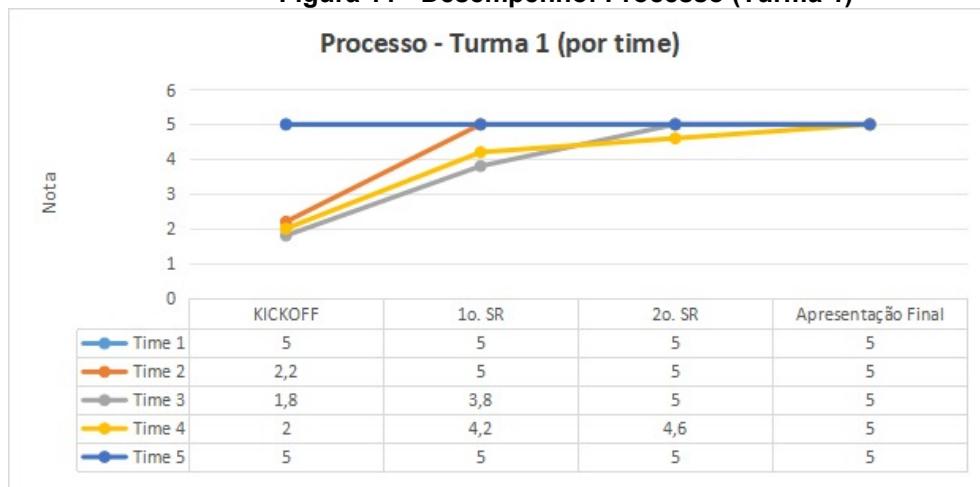
Na dimensão **Resultado**, observa-se um padrão de **crescimento consistente** ao longo das etapas.

Figura 10 - Desempenho: Resultado (Turma 1)

Fonte: Elaborado pelo autor (2025)

O **Time 1**, por exemplo, manteve notas altas desde o início, com leve crescimento até alcançar o máximo (5,0) na apresentação final. O **Time 2** também apresentou evolução, saindo de 4,2 no Kickoff para atingir o máximo na etapa final. O **Time 3** iniciou com desempenho elevado (5,0) e manteve estabilidade, com ligeiras variações. O destaque vai para o **Time 5**, que iniciou com a nota mais baixa (3,4) e teve crescimento progressivo ao longo do projeto, alcançando 5,0 na apresentação final. Isso sugere um processo de amadurecimento e desenvolvimento contínuo das equipes, possivelmente impulsionado pelo trabalho colaborativo e pelos feedbacks.

A dimensão **Processo** revela dados interessantes sobre a **dinâmica de funcionamento interno** dos grupos.

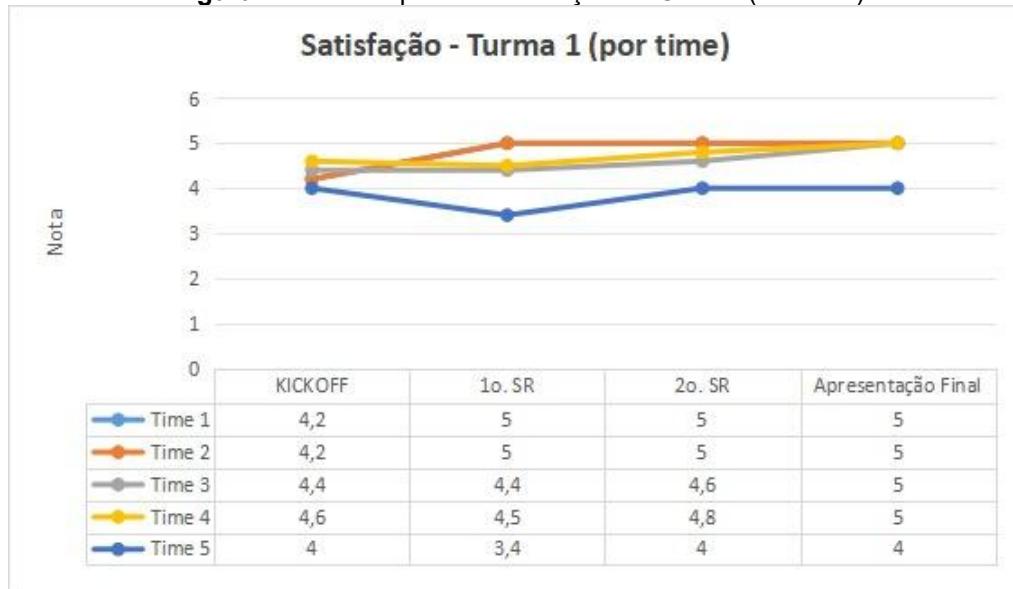
Figura 11 - Desempenho: Processo (Turma 1)

Fonte: Elaborado pelo autor (2025)

Os **Times 1 e 5** mantiveram um padrão alto e estável desde o início, com nota máxima em todas as etapas, indicando grupos bem organizados e com boa cooperação interna. Já os **Times 2, 3 e 4** começaram com notas bastante baixas, especialmente o **Time 3** (1,8 no Kickoff), o que indica dificuldades iniciais na organização do grupo, divisão de tarefas ou comunicação. No entanto, todos esses grupos demonstraram **melhora significativa** até a apresentação final, chegando ao patamar máximo (5,0). Isso mostra que, mesmo com desafios iniciais, os grupos foram capazes de se ajustar ao longo do projeto, o que pode ser atribuído ao acompanhamento pedagógico e à natureza iterativa do PBL.

Na dimensão **Satisfação do Cliente**, que avalia a percepção de valor do produto entregue, o desempenho dos grupos foi majoritariamente **elevado e estável**.

Figura 12 - Desempenho: Satisfação do Cliente (Turma 1)



Fonte: Elaborado pelo autor (2025)

Os **Times 1, 2 e 4** se destacaram por atingirem a nota máxima ao final do projeto, com trajetórias consistentes. O **Time 3** também manteve um padrão alto, com notas próximas do máximo em todas as etapas. O único grupo que demonstrou instabilidade foi o **Time 5**, que começou com uma boa avaliação (4,0), sofreu uma queda no primeiro SR (3,4), e depois se recuperou parcialmente, mas não atingiu a nota máxima. Essa variação pode indicar alguma dificuldade pontual na entrega ou na comunicação do valor da solução desenvolvida, mesmo tendo alcançado melhora nos critérios de Resultado e Processo.

De forma geral, os gráficos de desempenho da Turma 1 evidenciam o potencial do PBL para promover **melhoria progressiva dos grupos**, especialmente quando há acompanhamento contínuo e oportunidades de revisão e ajuste. A evolução positiva nas três dimensões para a maioria dos grupos sugere que, mesmo em cenários com desafios iniciais, o trabalho colaborativo, aliado a uma estrutura de avaliação por etapas, favorece o crescimento e a aprendizagem. A relação entre o balanceamento inicial dos grupos e essa trajetória de melhoria também se reflete nas análises anteriores por correlação, reforçando a importância de formar equipes bem distribuídas para maximizar o desempenho coletivo.

5.2.2.2 Desempenho - Turma 2

Na dimensão **Resultado**, todos os grupos apresentam uma trajetória **positiva ou estável**, com **melhora gradual nas notas** ao longo das quatro etapas avaliadas.

Figura 13 - Desempenho: Resultado (Turma 2)

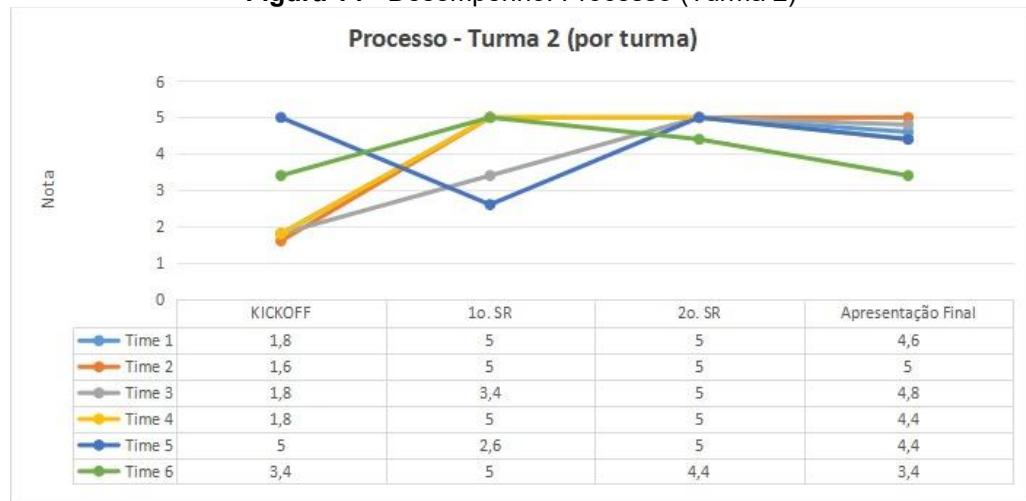


Fonte: Elaborado pelo autor (2025)

Destaca-se o **Time 3**, que iniciou com 4,6 no Kickoff e alcançou a nota máxima (5,0) já no 2º Status Report (SR), mantendo-a na apresentação final. O **Time 2**, que teve o menor valor inicial (1,4), mostrou uma **evolução expressiva**, atingindo 4,6 na segunda revisão e finalizando com 4,0. Isso demonstra uma curva de aprendizado e aprimoramento significativa. O **Time 5** também evoluiu de forma contínua, indo de 2,6 até 5,0, o que indica que os mecanismos do PBL, como feedbacks iterativos e reorganização interna, foram eficazes em impulsionar o desempenho.

Na dimensão **Processo**, o comportamento dos grupos foi **mais variado**.

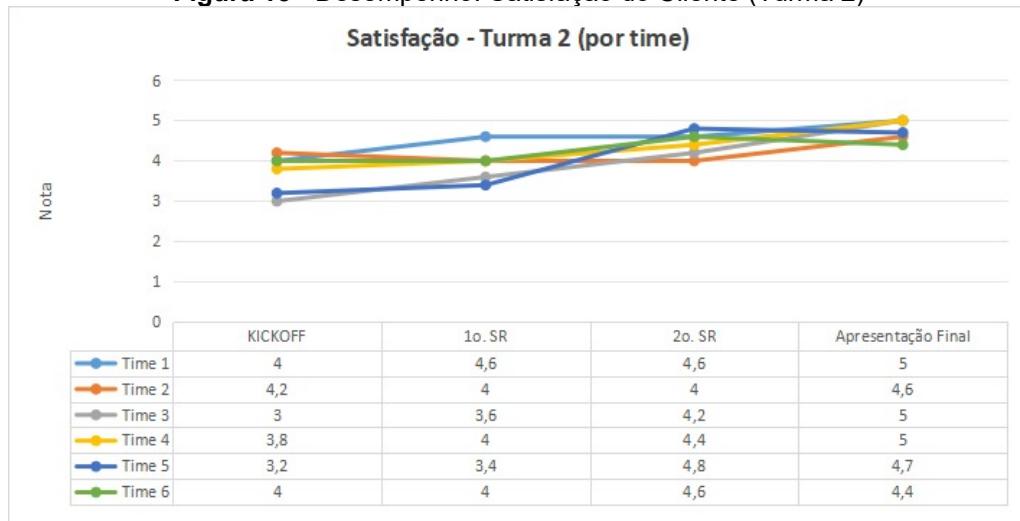
Figura 14 - Desempenho: Processo (Turma 2)



Fonte: Elaborado pelo autor (2025)

Os **Times 1, 2, 3 e 4** começaram com notas baixas (entre 1,6 e 1,8), indicando possíveis dificuldades iniciais com relação à dinâmica de grupo, comunicação ou organização interna. No entanto, esses grupos apresentaram melhorias substanciais já no primeiro Status Report, com destaque para os **Times 1 e 2**, que saltaram de valores baixos diretamente para a nota máxima (5,0). O **Time 5** chama atenção por um comportamento atípico: começou com nota máxima (5,0), caiu para 2,6 na 1ª SR, e depois voltou a subir — o que pode indicar **instabilidades internas temporárias**. Já o **Time 6**, apesar de iniciar com uma nota mediana (3,4), não manteve uma trajetória ascendente, apresentando oscilação e finalizando com uma das notas mais baixas (3,4), sugerindo dificuldades persistentes na organização e execução dos trabalhos.

Quanto à **Satisfação do Cliente**, a maioria dos grupos apresenta uma **evolução coerente com os resultados obtidos** nas demais dimensões.

Figura 15 - Desempenho: Satisfação do Cliente (Turma 2)

Fonte: Elaborado pelo autor (2025)

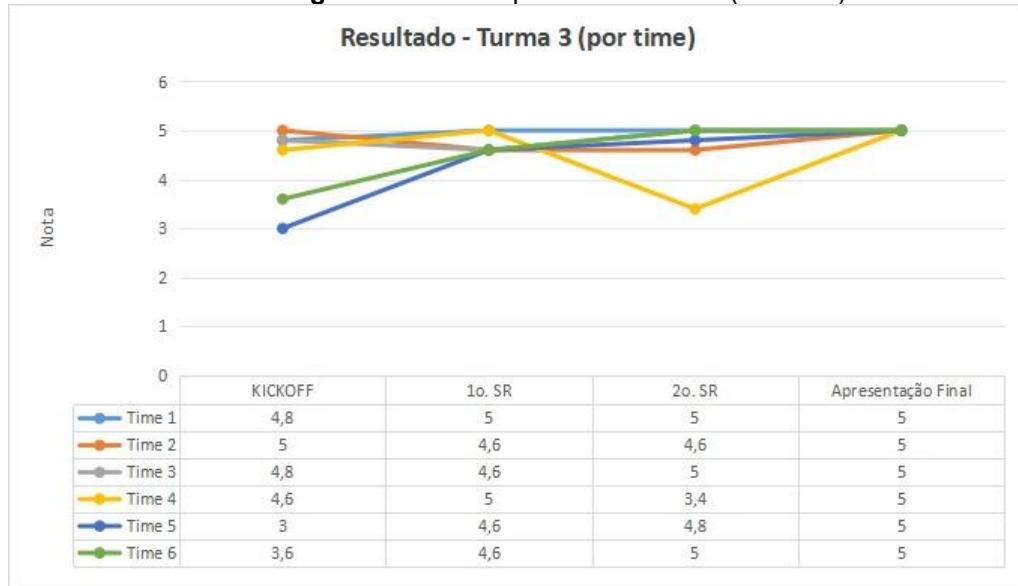
O **Time 1** manteve uma trajetória linear crescente, culminando na nota máxima, o que indica um alinhamento consistente entre o produto entregue e as expectativas do cliente. O **Time 3**, embora tenha iniciado com uma nota relativamente baixa (3,0), avançou significativamente até alcançar a nota 5,0 na etapa final — reforçando que seu alto desempenho técnico foi percebido positivamente pelos stakeholders. Os **Times 4 e 5** também mostraram crescimento contínuo, embora com uma leve queda final no Time 5 (4,7), que pode estar associada a ajustes de escopo ou expectativas na entrega final. O **Time 6**, por outro lado, manteve uma avaliação mais constante ao longo do projeto, terminando com uma leve queda, de 4,6 para 4,4.

Em síntese, os dados da Turma 2 indicam que a aplicação do PBL, somada à formação automatizada de equipes, contribuiu para **melhorias claras e contínuas** nas três dimensões avaliadas. A maioria das equipes partiu de notas medianas ou baixas e alcançou um desempenho elevado ao final do projeto, o que demonstra **efetividade do processo iterativo e do trabalho colaborativo**. A análise também reforça que o equilíbrio interno dos times pode não ser percebido imediatamente nos resultados, mas tende a se refletir positivamente ao longo do tempo, à medida que os grupos amadurecem em suas dinâmicas. Em especial, o forte crescimento observado em grupos como o Time 2 e Time 3 serve como evidência concreta do potencial de evolução de times inicialmente menos performáticos.

5.2.2.3 Desempenho - Turma 3

Na dimensão Resultado, observa-se uma tendência de estabilização em patamares elevados, com a maioria dos grupos apresentando melhorias ou manutenção de um bom desempenho ao longo das etapas.

Figura 16 - Desempenho: Resultado (Turma 3)

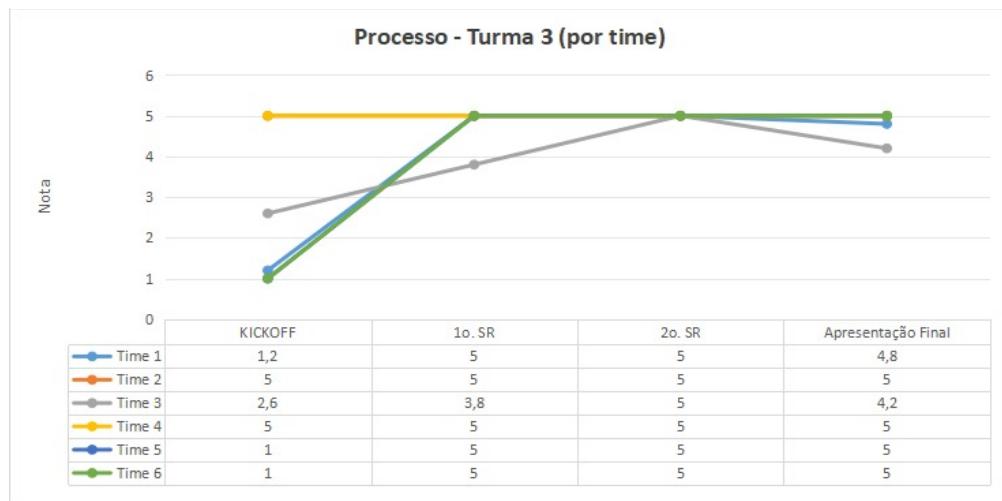


Fonte: Elaborado pelo autor (2025)

Os **Times 1, 2 e 3**, por exemplo, iniciaram com notas próximas de 5,0 e mantiveram esse padrão até a apresentação final, demonstrando consistência na entrega de resultados. O **Time 4**, embora tenha mantido notas altas nas primeiras etapas, apresentou uma queda acentuada no segundo Status Report (3,4), seguida de recuperação na entrega final, o que pode refletir um problema pontual que foi corrigido com sucesso. Já os **Times 5 e 6** partiram de notas mais baixas (3,0 e 3,6, respectivamente) e alcançaram nota máxima, evidenciando um processo de crescimento sólido.

Em relação à dimensão **Processo**, o comportamento dos grupos é bastante interessante.

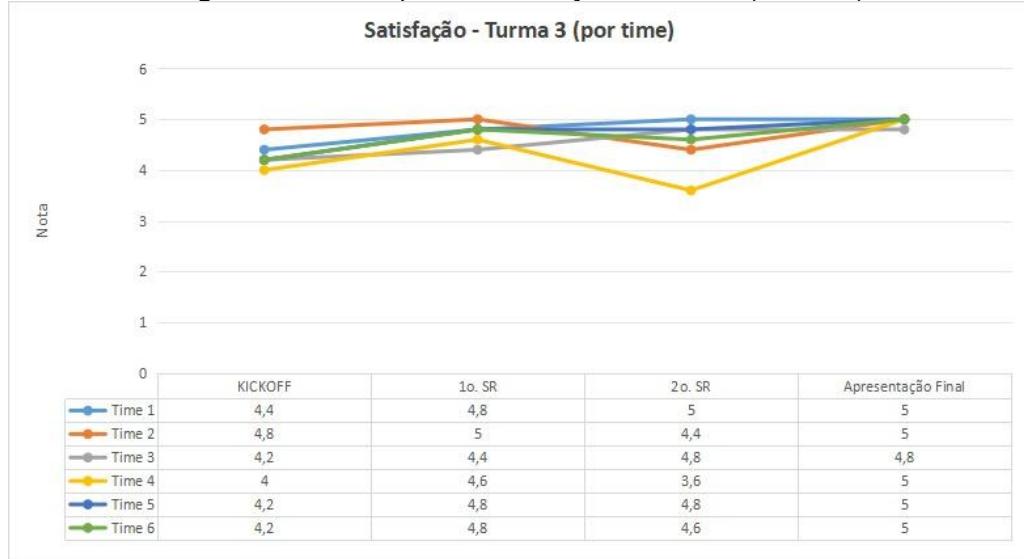
Figura 17 - Desempenho: Processo (Turma 3)



Fonte: Elaborado pelo autor (2025)

Os **Times 1, 5 e 6** iniciaram com notas extremamente baixas (entre 1,0 e 1,2), indicando sérias dificuldades na organização, divisão de tarefas ou cooperação inicial. Contudo, todos esses grupos **atingiram nota máxima nas etapas seguintes**, o que sugere um avanço notável em termos de maturidade do grupo e engajamento com os princípios do PBL. O **Time 3** teve uma evolução progressiva e consistente, embora tenha encerrado com uma leve queda (de 5,0 para 4,2), o que pode indicar pequenos desvios ou dificuldades de última hora. Os **Times 2 e 4**, por sua vez, mantiveram desempenho excelente durante todo o processo, demonstrando uma dinâmica de grupo estável e produtiva desde o início.

Na dimensão **Satisfação do Cliente**, os dados refletem uma **percepção geralmente positiva dos stakeholders** quanto ao produto e à interação com os times. Todos os grupos terminaram o projeto com notas altas (entre 4,8 e 5,0), o que indica sucesso na entrega de valor.

Figura 18 - Desempenho: Satisfação do Cliente (Turma 3)

Fonte: Elaborado pelo autor (2025)

O **Time 1** é um bom exemplo de consistência, mantendo avaliações entre 4,4 e 5,0 ao longo do tempo. O **Time 2** apresenta uma oscilação, caindo de 5,0 para 4,4 no segundo Status Report, mas finalizando com nota máxima. Situação semelhante ocorre com o **Time 4**, cuja queda mais acentuada na 2^a SR (3,6) pode sugerir uma entrega abaixo das expectativas momentaneamente, porém revertida na etapa final. Os **Times 5 e 6** mantêm uma trajetória de crescimento progressivo, reforçando a ideia de que o projeto foi bem conduzido e conseguiu alinhar desenvolvimento técnico à satisfação do cliente.

Em resumo, a análise dos desempenhos nas três turmas demonstra que, no geral, os grupos evoluíram positivamente ao longo do projeto, com melhorias nas dimensões de Processo, Resultado e Satisfação do Cliente. A formação automatizada dos times contribuiu para um ambiente de trabalho equilibrado, favorecendo tanto o desenvolvimento técnico quanto a colaboração. Os dados indicam que, mesmo grupos com início difícil conseguiram alcançar altos desempenhos, evidenciando a efetividade da metodologia adotada.

5.2.3 Relação entre o Balanceamento dos Times e o Desempenho Apresentado

A relação entre o balanceamento dos times e o desempenho apresentado em pode ser observada a partir da correlação entre os rankings das restrições e o de desempenho médio dos grupos, por dimensão. A análise é conduzida por meio da

correlação de Spearman, que é amplamente utilizada para avaliar a força e a direção da associação entre duas variáveis ordinais ou para dados não paramétricos (Hays, 1994). A correlação de Spearman é especialmente útil quando se deseja medir o grau de concordância entre duas variáveis classificadas, sem exigir que os dados sigam uma distribuição normal.

A interpretação da correlação de Spearman segue a escala de Cohen (1988), que classifica a magnitude dos coeficientes da seguinte maneira:

- $|0| \text{ a } |0,1|$: Correlação muito fraca ou praticamente inexistente
- $|0,1| \text{ a } |0,3|$: Correlação fraca
- $|0,3| \text{ a } |0,5|$: Correlação moderada
- $|0,5| \text{ a } |0,7|$: Correlação forte
- $|0,7| \text{ a } |1|$: Correlação muito forte

5.2.3.1 Dimensão: Resultado

A seguir, é mostrado o coeficiente de Spearman que indicam o grau de associação entre o nível de satisfação das restrições de cada equipe (em percentual) e desempenho médio da dimensão Resultado (por equipe).

A **dimensão Resultado** refere-se ao desempenho final dos grupos em relação ao produto entregue — isto é, o quanto as equipes foram eficazes na solução do problema proposto dentro da metodologia PBL adotada. Essa dimensão considera critérios como qualidade técnica, completude, inovação e aderência às especificações do projeto. O objetivo aqui é entender se há uma relação entre o **balanceamento das restrições** e o desempenho médio final desses grupos na dimensão Resultado.

Utilizando a **correlação de Spearman (ρ)** para avaliar essa relação em cada turma, foram encontrados os seguintes valores:

- Turma 1: $\rho = 0,5$
- Turma 2: $\rho = 0,54286$
- Turma 3: $\rho = 0,37143$

Tabela 4 - Coeficiente de Spearman: Turma 1 - Resultado

Resultado - TIME 1						
Time	restrições	média desempenho	Rank restrições	Rank desempenho	d	d^2
Time 1	1	4,85	3	4	-1	1
Time 2	1	4,55	3	3	0	0
Time 3	1	4,9	3	5	-2	4
Time 4	1	4,5	3	2	1	1
Time 5	1	4,05	3	1	2	4
ρ						0,5

Fonte: Elaborado pelo autor (2025)

Na **Turma 1**, o valor de $\rho = 0,5$ indica uma **correlação moderada** entre o balanceamento e o desempenho. Isso sugere que times com uma distribuição mais equilibrada de restrições tendem a obter melhores resultados na entrega final, possivelmente por conseguirem se organizar de maneira mais eficaz e colaborar de forma mais fluida, sem que as dificuldades estejam excessivamente concentradas em um único grupo.

Tabela 5 - Coeficiente de Spearman: Turma 2 - Resultado

Resultado - TURMA 2						
Time	restrições	média desempenho	Rank restrições	Rank desempenho	d	d^2
Time 1	1	4,525	4	3	1	1
Time 2	1	3,55	4	1	3	9
Time 3	1	4,85	4	6	-2	4
Time 4	1	4,75	4	5	-1	1
Time 5	0,6	4,025	1	2	-1	1
Time 6	1	4,65	4	4	0	0
ρ						0,542857

Fonte: Elaborado pelo autor (2025)

Já na **Turma 2**, o valor de $\rho = 0,54286$ aponta para uma **correlação moderadamente forte**, sendo o mais alto entre as três turmas. Esse dado reforça a hipótese de que o balanceamento tem influência significativa na performance dos times, sugerindo que, quando as restrições são distribuídas de forma mais justa entre os grupos, há uma tendência maior de alcançar bons resultados.

Tabela 6 - Coeficiente de Spearman: Turma 3 - Resultado

Resultado - TURMA 3						
Time	restrições	média desempenho	Rank restrições	Rank desempenho	d	d^2
Time 1	1	4,95	4	6	-2	4
Time 2	1	4,8	4	4	0	0
Time 3	1	4,85	4	5	-1	1
Time 4	1	4,5	4	2	2	4
Time 5	1	4,35	4	1	3	9
Time 6	0,6	4,55	1	3	-2	4
ρ						0,371428

Fonte: Elaborado pelo autor (2025)

Na **Turma 3**, o valor de $\rho = 0,37143$ ainda indica uma **correlação positiva**, embora de intensidade **moderada a fraca**. Isso demonstra que, mesmo com uma associação mais suave, existe um padrão em que grupos mais balanceados tendem a ter desempenhos melhores, mas que outros fatores contextuais, como a complexidade do problema, a interação entre membros ou o nível de engajamento, também podem ter influenciado significativamente os resultados.

A consistência de correlações **positivas em todas as turmas** sugere que o balanceamento dos grupos, mesmo não sendo o único fator, desempenha um papel relevante na performance final dos times. A **Turma 2**, com o maior coeficiente, reforça essa tendência e destaca o potencial de estratégias automáticas de formação de equipes para melhorar os resultados no PBL. Já as variações de intensidade entre as turmas mostram que o efeito do balanceamento pode ser sensível ao contexto e à dinâmica interna dos grupos, sendo importante considerar outras variáveis que

impactam o desempenho coletivo.

5.2.3.2 Dimensão: Processo

A **dimensão Processo** avalia a maneira como os grupos executam suas tarefas e colaboram no decorrer do trabalho, refletindo a qualidade do processo de resolução de problemas. A correlação de Spearman, como já mencionado, é utilizada para analisar a associação entre o balanceamento das restrições dos times e o desempenho médio dos grupos no processo.

Tabela 7 - Coeficiente de Spearman: Turma 1 - Processo

Processo - TIME 1						
Time	restrições	média desempenho	Rank restrições	Rank desempenho	d	d^2
Time 1	1	5	3	4,5	-1,5	2,25
Time 2	1	4,3	3	3	0	0
Time 3	1	3,9	3	1	2	4
Time 4	1	3,95	3	2	1	1
Time 5	1	5	3	4,5	-1,5	2,25
ρ						0,525

Fonte: Elaborado pelo autor (2025)

Na **Turma 1**, a correlação de $\rho = 0,525$ indica uma **correlação moderada a forte**. Isso sugere que um bom balanceamento das restrições tem um impacto positivo no desempenho do processo. Os times com restrições bem distribuídas apresentam uma execução mais eficiente das tarefas, mostrando uma colaboração mais eficaz e uma organização melhor no processo de resolução dos problemas. O equilíbrio das restrições, nesse caso, parece ser um fator importante para o sucesso do trabalho colaborativo.

Tabela 8 - Coeficiente de Spearman: Turma 2 - Processo

Processo - TIME 2						
Time	restrições	média desempenho	Rank restrições	Rank desempenho	d	d^2
Time 1	1	4,1	4	4	0	0
Time 2	1	4,15	4	5	-1	1
Time 3	1	3,75	4	1	3	9
Time 4	1	4,05	4	2,5	1,5	2,25
Time 5	0,6	4,25	1	6	-5	25
Time 6	1	4,05	4	2,5	1,5	2,25
ρ						-0,128571

Fonte: Elaborado pelo autor (2025)

Já na **Turma 2**: A correlação de $\rho = -0,12857$ indica uma **correlação muito fraca e negativa**. Esse valor sugere que o balanceamento das restrições não tem uma relação clara com o desempenho do processo na turma 2. Pode-se inferir que, na turma 2, outros fatores além do balanceamento das restrições influenciam mais fortemente o desempenho do processo, como a dinâmica interna do grupo, a complexidade das tarefas ou até mesmo características individuais dos membros dos times.

Tabela 9 - Coeficiente de Spearman: Turma 3 - Processo

Processo - TIME 3						
Time	restrições	média desempenho	Rank restrições	Rank desempenho	d	d^2
Time 1	1	4	4	3	1	1
Time 2	1	5	4	5,5	-1,5	2,25
Time 3	1	3,9	4	1	3	9
Time 4	1	5	4	5,5	-1,5	2,25

Time 5	1	4	4	3	1	1
Time 6	0,6	4	1	3	-2	4
ρ						0,44285

Fonte: Elaborado pelo autor (2025)

A correlação de $\rho = 0,44286$ na **Turma 3** indica uma **correlação moderada**.

Embora não seja tão forte quanto na turma 1, ainda sugere que um balanceamento adequado das restrições tem um impacto positivo no desempenho do processo. Nesse caso, os grupos com melhor distribuição de dificuldades têm um desempenho mais eficaz na execução das atividades, mas o efeito não é tão claro ou consistente quanto na turma 1.

Esses resultados mostram que, em algumas turmas, o balanceamento das restrições tem um impacto positivo no desempenho do processo, enquanto, em outras, o efeito é menos pronunciado ou até mesmo negativo. A **Turma 1** e a **Turma 3** apresentaram correlações positivas moderadas, indicando que o equilíbrio nas restrições contribui para uma execução mais eficiente das tarefas. Já a **Turma 2** apresentou uma correlação negativa muito fraca, sugerindo que o balanceamento das restrições não desempenhou um papel importante no desempenho do processo de resolução de problemas, o que pode indicar a presença de outros fatores que influenciam mais diretamente essa dimensão.

Essas variações podem ser explicadas por uma série de fatores, como a complexidade das tarefas atribuídas, a diversidade dos membros dos grupos, a forma como as restrições foram distribuídas e outros elementos contextuais que podem afetar a dinâmica e a eficácia do trabalho em equipe. Uma análise mais profunda desses fatores pode fornecer insights sobre como otimizar o balanceamento dos times para maximizar o desempenho no processo de aprendizagem.

5.2.3.3 Dimensão: Satisfação do cliente

A **dimensão Satisfação do Cliente**, no contexto do PBL, refere-se à percepção de qualidade e efetividade do produto entregue pelos grupos, o que pode envolver tanto a opinião dos próprios estudantes sobre o resultado do trabalho quanto a avaliação de professores ou stakeholders fictícios. A ideia é verificar se o

balanceamento dos times influencia na capacidade do grupo de gerar soluções que atendam aos objetivos propostos, sejam relevantes e causem boa impressão ao “cliente”.

Para isso, a correlação de Spearman (ρ) foi novamente utilizada para avaliar a associação entre o ranking das restrições impostas a cada time e o ranking do desempenho na dimensão satisfação. Os valores obtidos foram os seguintes:

Tabela 10 - Coeficiente de Spearman: Turma 1 - Satisfação do cliente

Satisfação - TIME 1						
Time	restrições	média desempenho	Rank restrições	Rank desempenho	d	d^2
Time 1	1	4,8	3	3,5	-0,5	0,25
Time 2	1	4,8	3	3,5	-0,5	0,25
Time 3	1	4,6	3	2	1	1
Time 4	1	4,725	3	5	-2	4
Time 5	1	3,85	3	1	2	4
ρ						0,525

Fonte: Elaborado pelo autor (2025)

A **Turma 1**, com correlação de **0,525**, apresenta uma **relação moderada a forte** entre o balanceamento das restrições e o desempenho em satisfação do cliente. Isso sugere que grupos mais equilibrados quanto às restrições tiveram mais sucesso em entregar produtos satisfatórios, possivelmente por conseguirem trabalhar de forma mais coesa e com melhor divisão de tarefas.

Tabela 11 - Coeficiente de Spearman: Turma 2 - Satisfação do cliente

Satisfação - TIME 2						
Time	restrições	média desempenho	Rank restrições	Rank desempenho	d	d^2
Time 1	1	4,55	4	6	-2	4
Time 2	1	4,2	4	3	1	1
Time 3	1	3,95	4	1	3	9

Time 4	1	4,3	4	5	-1	1
Time 5	0,6	4,025	1	2	-1	1
Time 6	1	4,25	4	4	0	0
ρ						0,542857 1429

Fonte: Elaborado pelo autor (2025)

Na **Turma 2**, o valor de $\rho = 0,54286$ indica uma **correlação forte**, sendo ligeiramente superior ao da turma 1. Isso reforça a ideia de que, para essa turma, o balanceamento das restrições foi um fator importante para o sucesso dos grupos, especialmente no que diz respeito à entrega de um resultado final que atendesse aos critérios estabelecidos.

Tabela 12 - Coeficiente de Spearman: Turma 3 - Satisfação do cliente

Satisfação - TIME 3						
Time	restrições	média desempenho	Rank restrições	Rank desempenho	d	d^2
Time 1	1	4,8	4	5,5	-1,5	2,25
Time 2	1	4,8	4	5,5	-1,5	2,25
Time 3	1	4,55	4	2	2	4
Time 4	1	4,3	4	1	3	9
Time 5	1	4,7	4	4	0	0
Time 6	0,6	4,65	1	3	-2	4
ρ						0,385714 2857

Fonte: Elaborado pelo autor (2025)

Já a **Turma 3**, com $\rho = 0,38571$, apresenta uma **correlação moderada**. Embora o valor seja um pouco menor que nas outras turmas, ainda há uma associação positiva entre balanceamento e satisfação, sugerindo que grupos mais equilibrados tendem a alcançar melhores resultados também sob a ótica da satisfação

do cliente. No entanto, o impacto é um pouco menos evidente, o que pode indicar maior variabilidade nas influências externas ou na percepção dos avaliadores.

Em todas as turmas, foi observada uma **correlação positiva** entre o balanceamento dos times e o desempenho na dimensão Satisfação do Cliente, com valores variando entre **moderado e forte**. Esses resultados reforçam a hipótese de que a formação de equipes equilibradas, com distribuição adequada de restrições e potencialidades, pode contribuir significativamente para a geração de soluções mais eficazes e bem avaliadas.

As diferenças entre as turmas, ainda que pequenas, também indicam que o contexto de cada aplicação, como o tema dos projetos, a dinâmica dos grupos e a metodologia de avaliação, pode influenciar essa relação, mas o padrão geral se mantém consistente: **times mais balanceados tendem a entregar resultados mais satisfatórios**. Essa constatação fortalece a proposta de utilizar ferramentas automatizadas para formação de equipes equilibradas, como a discutida no artigo base da pesquisa.

5.3. DISCUSSÕES DOS RESULTADOS ENCONTRADOS

A formação automatizada de grupos pode impactar significativamente as habilidades interpessoais dos estudantes. Ao serem agrupados com base em critérios como idade, experiência profissional, preferências de atividade e afinidades, os estudantes podem desenvolver competências socioemocionais, como comunicação, trabalho em equipe e resolução de conflitos. A diversidade dentro dos grupos também promove a empatia e a compreensão de diferentes perspectivas, o que é essencial para o desenvolvimento de habilidades interpessoais.

A formação automatizada de equipes demonstrou um impacto positivo na construção de grupos mais equilibrados e coerentes com os critérios pedagógicos definidos para o desenvolvimento de projetos em ambiente PBL. No Quadro 6, Quadro 8 e Quadro 10, referentes respectivamente aos Ciclos 1, 2 e 3, evidenciam o grau de atendimento às restrições estipuladas, tais como diversidade de perfis, presença de membros com experiência profissional, distribuição de gêneros e consideração das afinidades entre os alunos.

Contudo, é necessário fazer ressalvas especialmente em relação ao Ciclo 1. Nesse caso, a formação dos grupos foi realizada manualmente, com posterior

aplicação do algoritmo apenas como simulação. Além disso, foram considerados apenas quatro critérios de restrição, e muitos estudantes deixaram de preencher corretamente a planilha de dados, o que levou à distribuição aleatória de alguns integrantes. O critério de afinidade também não foi utilizado, o que limitou ainda mais a coerência dos agrupamentos gerados nesse ciclo. Esses fatores comprometem a comparação direta com os ciclos posteriores, nos quais o sistema foi de fato aplicado.

Nos Ciclos 2 e 3, com melhorias significativas no processo de coleta de dados e um conjunto mais robusto de critérios, o sistema mostrou-se mais eficiente. No Ciclo 2, apenas uma equipe (Time 5) não atendeu plenamente aos critérios. Já no Ciclo 3, apenas o Time 6 apresentou falhas pontuais no balanceamento, reflexo das restrições combinadas a um conjunto de alunos com perfis menos diversos disponíveis no final da alocação.

Apesar dessas falhas pontuais, o sistema proposto apresenta ganhos operacionais relevantes, como a redução do tempo demandado por professores para formar os grupos e a minimização do esforço cognitivo envolvido no processo. Além disso, promove maior imparcialidade na distribuição e permite ajustes mais fáceis a partir da parametrização das restrições. Esses aspectos contribuem para tornar a ferramenta uma solução promissora e escalável no contexto de disciplinas baseadas em metodologias ativas, como o PBL.

Quadro 11 - Resumo das correlações encontradas

Dimensão	Turma 1 (ρ)	Turma 2 (ρ)	Turma 3 (ρ)
Resultado	0,5 (Mod.)	0,54 (Mod.-Forte)	0,37 (Mod.)
Processo	0,52 (Mod.-Forte)	-0,12 (Fraca Neg.)	0,44 (Mod.)
Satisfação	0,52 (Mod.-Forte)	0,54 (Forte)	0,38 (Mod.)

Fonte: Elaborado pelo autor (2025)

Em relação aos resultados obtidos nas três dimensões analisadas (**Processo, Resultado e Satisfação do Cliente**), observe o Quadro 11, é possível observar um padrão consistente de **correlações positivas** entre o **balanceamento das restrições**

dos times e o desempenho dos grupos. Embora a intensidade dessa correlação varie entre turmas e dimensões, os dados indicam que grupos mais equilibrados tendem a apresentar melhores desempenhos, especialmente nas dimensões **Resultado e Satisfação**, cujos coeficientes de Spearman se mantiveram, em sua maioria, em níveis moderados a fortes. Esse padrão reforça a relevância do uso de soluções automatizadas para a **formação de equipes balanceadas**, como a proposta no artigo base deste trabalho, pois tais ferramentas contribuem para uma distribuição mais justa de restrições, o que parece favorecer o desempenho coletivo.

No entanto, em cada turma, uma dimensão apresentou um resultado destoante, o que pode indicar desafios específicos relacionados às características gerais das turmas e ao processo de distribuição dos estudantes nas equipes.

Na Turma 2, a dimensão Processo apresentou uma correlação negativa e fraca ($\rho = -0,12$), sendo o pior resultado entre todas as turmas e dimensões. Esse dado contrasta com os resultados positivos obtidos nas dimensões Resultado e Satisfação. Apesar de a Turma 2 ter maior diversidade de perfis e uma proporção significativa de estudantes com experiência profissional, é possível que fatores relacionados à alocação dos estudantes tenham prejudicado a dinâmica interna dos grupos. Problemas na coleta de afinidades, como ambiguidades e erros de digitação, podem ter dificultado o uso eficaz desse critério pelo algoritmo, resultando na formação de equipes com relações interpessoais menos coesas. Além disso, a equipe 5 não satisfez critérios importantes, como mistura de perfis e inclusão de pelo menos um perfil "Idealista" ou "Racional", o que pode ter impactado negativamente a organização e colaboração interna. Instabilidades iniciais e oscilações no desempenho de alguns grupos também podem ter contribuído para o resultado negativo na dimensão Processo.

Na Turma 3, a dimensão Resultado apresentou uma correlação moderada ($\rho = 0,37$), sendo a mais baixa entre todas as turmas nessa dimensão. A composição homogênea da turma, com predominância de perfis "Racional" e estudantes jovens com pouca experiência profissional, pode ter limitado a capacidade das equipes de produzir resultados inovadores e completos. A baixa diversidade de perfis pode ter reduzido a complementaridade entre os membros, impactando negativamente a qualidade técnica e criativa dos produtos entregues. Além disso, a falta de experiência prática pode ter dificultado a aplicação de conceitos teóricos em contextos reais, prejudicando o desempenho das equipes nessa dimensão.

Ainda na Turma 3, a dimensão Satisfação também apresentou a correlação mais baixa ($\rho = 0,38$), sugerindo que os produtos entregues não atenderam plenamente às expectativas dos clientes reais. As razões para esse resultado podem ser similares às da dimensão Resultado, incluindo a falta de diversidade de perfis e a escassez de experiência prática entre os estudantes. A homogeneidade das equipes pode ter limitado a inovação e a relevância das soluções apresentadas, impactando negativamente a percepção de qualidade pelos avaliadores.

Embora as características gerais das turmas ofereçam insights importantes sobre os resultados obtidos, elas não são suficientes para concluir definitivamente a influência da distribuição de equipes no desempenho dos estudantes. Outros fatores, como o engajamento dos participantes, a complexidade das tarefas propostas e o acompanhamento pedagógico, também podem ter desempenhado papéis significativos na obtenção dos resultados.

Para concluir a influência da distribuição de equipes, medidas adicionais podem ser tomadas em futuras pesquisas. Sugere-se realizar uma análise mais subjetiva da visão dos estudantes sobre a alocação de equipes ao longo de toda a disciplina, permitindo compreender como eles percebem a dinâmica dos grupos e o impacto das formações na colaboração e aprendizado; essa avaliação poderá ser integrada com os dados de desempenho para oferecer uma perspectiva mais abrangente e profunda dos resultados obtidos. Além disso, o controle de variáveis externas, como o suporte pedagógico e a complexidade das tarefas, ajudaria a isolar os efeitos do balanceamento. Novos fatores avaliativos também poderiam ser considerados, como o desenvolvimento de competências socioemocionais (liderança, comunicação e resolução de conflitos), a motivação dos estudantes e a eficiência do trabalho colaborativo.

Essas medidas permitirão uma análise mais robusta, ajudando a compreender melhor a influência do balanceamento das equipes na formação de grupos colaborativos e no desempenho dos estudantes, e otimizando as soluções propostas para aplicação em contextos educacionais futuros.

6. CONCLUSÕES

A pesquisa apresentada neste trabalho partiu de uma problemática bastante prática e recorrente no contexto do ensino superior em computação: a formação de equipes equilibradas dentro do PBL. A questão central investigada foi como equipes balanceadas podem ser formadas automaticamente, considerando critérios, atributos e afinidades pré-definidos entre seus membros, no contexto do ensino superior de computação com PBL? A motivação para essa questão veio da experiência do autor como tutor PBL vivenciando as dificuldades da formação manual de grupos em disciplinas baseadas na metodologia. O objetivo principal da pesquisa, portanto, foi propor uma solução automatizada, baseada em critérios diversos, que pudesse auxiliar o docente na formação de equipes mais equilibradas e potencialmente mais colaborativos.

A abordagem adotada utilizou o método DSR, aplicado em ciclos evolutivos. A cada ciclo, novos dados foram coletados, restrições ajustadas e o algoritmo aprimorado com base nos resultados anteriores. A solução proposta considera diversos atributos, como perfis de personalidade (com base no MBTI), experiência profissional, gênero, afinidades entre estudantes e preferências técnicas. Essa multiplicidade de critérios foi fundamental para garantir que os grupos formados fossem heterogêneos internamente e homogêneos entre si, de modo a favorecer a aprendizagem colaborativa, um dos pilares do PBL.

Dessa forma, os objetivos específicos traçados no início deste trabalho foram progressivamente atendidos ao longo do desenvolvimento da solução:

- OE1 – Reduzir a dificuldade e o tempo na formação de equipes: O sistema desenvolvido automatizou com sucesso o processo de agrupamento dos estudantes, substituindo práticas manuais demoradas e facilitando a atuação do professor, que pôde concentrar seus esforços em aspectos pedagógicos mais relevantes.
- OE2 – Desenvolver um sistema que incorpore critérios e atributos específicos para a formação de equipes permitindo a participação do instrutor e do estudante no processo de decisão de agrupamento: A ferramenta implementada demonstrou capacidade de lidar com múltiplos critérios definidos pelo instrutor, como personalidade, gênero, experiência profissional e afinidades, possibilitando a criação de grupos mais equilibrados e alinhados

aos princípios da heterogeneidade produtiva e colaborativa. Além disso, a solução favoreceu a atuação conjunta de professores e estudantes no processo de formação das equipes, por meio da coleta de preferências e da parametrização de critérios, promovendo um ambiente mais participativo, inclusivo e propício ao engajamento coletivo.

- OE3 – Analisar o sistema quanto ao cumprimento dos critérios e desempenho das equipes: A avaliação quantitativa realizada evidenciou que o sistema atende satisfatoriamente às restrições impostas pelo instrutor. Foi possível identificar uma correlação positiva entre o grau de atendimento aos requisitos e os resultados obtidos pelas equipes nas três dimensões coletivas analisadas: Resultado, Processo e Satisfação do Cliente. Embora a intensidade dessas correlações tenha variado entre turmas, os dados reforçam o potencial da solução automatizada como uma ferramenta eficaz para a formação de equipes com maior desempenho coletivo. Além disso, os achados indicam que o impacto do balanceamento pode ser influenciado por fatores contextuais, como a complexidade das tarefas, o engajamento dos participantes e a maturidade da turma quanto ao trabalho em equipe, elementos que reforçam a necessidade de uma abordagem integrada de gestão de grupos no PBL. Além disso, percepções superficiais e pontuais dos estudantes observadas pelo tutor da disciplina indicam a aceitação da solução, demonstrando que o sistema contribui efetivamente para a formação de equipes mais equilibradas e produtivas.

6.1 LIMITAÇÕES E AMEAÇAS À VALIDADE

Apesar dos avanços obtidos com a proposta apresentada, esta pesquisa enfrentou algumas limitações e identificou ameaças à validade que merecem ser consideradas em interpretações e futuras aplicações.

Uma das principais limitações observadas refere-se à complexidade envolvida na coleta, padronização e consistência dos dados fornecidos pelos estudantes, especialmente durante os ciclos iniciais de aplicação. A ausência de mecanismos automáticos de validação nos formulários e a utilização de campos abertos, como a digitação livre de nomes para indicar afinidades, resultaram em inconsistências que impactaram a precisão do agrupamento. Esses entraves foram sendo

progressivamente corrigidos ao longo do desenvolvimento, com a introdução de validações automáticas e melhorias na estrutura dos formulários.

Outra limitação diz respeito à escala da aplicação: o sistema foi testado em um número relativamente restrito de turmas. Isso limita, neste estágio, a generalização dos resultados para outros contextos educacionais. A ampliação do uso da solução em diferentes instituições, perfis de estudantes e disciplinas será essencial para validar sua robustez e adaptabilidade.

No que se refere à usabilidade, a interface inicial do sistema, embora funcional, apresentou baixa intuição para alguns usuários durante os primeiros ciclos, especialmente entre docentes e organizadores com menor familiaridade tecnológica.

A avaliação da usabilidade nos primeiros ciclos revelou uma limitação importante: a ausência de uma interface que permitisse a utilização do algoritmo por usuários comuns, sem necessidade de acesso ao código. Nos dois primeiros ciclos, o sistema dependia diretamente da presença do desenvolvedor para alimentar o algoritmo com os dados do perfil da turma, o que exigia conhecimento técnico e dificultava a autonomia dos professores e organizadores no uso da solução.

Essa dificuldade foi identificada como um ponto crítico na avaliação informal feita pelos próprios usuários, que relataram a necessidade de uma ferramenta mais acessível e intuitiva. Como resposta a essas observações, o terceiro ciclo DSR incluiu o desenvolvimento de uma interface gráfica amigável utilizando a plataforma Streamlit, permitindo que qualquer organizador pudesse carregar os dados, configurar os critérios e gerar as equipes de forma independente e prática. Essa evolução na usabilidade eliminou a dependência do desenvolvedor e ampliou significativamente o potencial de adoção do sistema em contextos educacionais.

Adicionalmente, reconhece-se que fatores contextuais, como o grau de engajamento dos estudantes, a complexidade das tarefas propostas e a maturidade da turma quanto ao trabalho em equipe, podem ter influenciado os resultados observados, representando potenciais ameaças à validade interna. Esses elementos não foram isolados ou controlados rigorosamente, o que pode ter impactado a força das correlações entre o balanceamento das equipes e os desempenhos coletivos.

Apesar dessas limitações, o uso da metodologia DSR foi decisivo para o aprimoramento contínuo do artefato, assegurando que cada ciclo contribuísse para o refinamento da solução com base em evidências empíricas e feedbacks dos usuários. Futuras melhorias poderão contemplar a ampliação dos critérios de agrupamento, a

incorporação de dados em tempo real e o desenvolvimento de painéis de análise para o acompanhamento dinâmico das equipes, aumentando ainda mais a eficácia e a aplicabilidade do sistema.

Foram utilizadas ferramentas de IA, como o ChatGPT, como apoio pontual na reescrita de trechos, na organização de ideias e na sugestão de estruturas textuais. Todas as decisões relacionadas ao conteúdo, análises e interpretações foram conduzidas pelo autor, com base nos dados coletados e no referencial teórico adotado. O uso da IA teve caráter complementar, com o objetivo de aprimorar a clareza, coesão e qualidade da redação final do trabalho.

6.2 CONTRIBUIÇÕES DA PESQUISA

Esta pesquisa resultou no desenvolvimento de um sistema funcional para formação automatizada de equipes, capaz de considerar múltiplos critérios definidos por professores e estudantes, como perfis de personalidade (MBTI e Keirsey), experiência profissional, afinidades, gênero e preferências técnicas. O sistema resolve um problema recorrente em ambientes educacionais que utilizam metodologias ativas, como o PBL, ao reduzir o tempo, a complexidade e os conflitos envolvidos na composição de grupos de trabalho.

Uma das principais contribuições práticas do trabalho é a entrega de um artefato funcional, testado em sala de aula, que pode ser imediatamente utilizado por outros docentes, instituições e pesquisadores interessados em melhorar a gestão de equipes. Além disso, o sistema foi projetado com estrutura adaptável, o que facilita sua customização para diferentes contextos, sejam eles acadêmicos ou corporativos, presenciais ou remotos.

O sistema está disponível publicamente no seguinte endereço: <https://pblteamformer-cin-ufpe.streamlit.app/>. Interessados podem acessar livremente e utilizar a ferramenta.

Além da construção e validação do sistema, parte dos resultados desta pesquisa foi reconhecida e publicada na conferência internacional Frontiers in Education (FIE) 2024, um dos eventos mais relevantes na área de ensino de engenharia e tecnologia, com o artigo intitulado "*Favoring Collaborative Learning in PBL: An Automated Solution for Semantic Group Formation.*" (Santana; Santos; Maia, 2024). O FIE possui Qualis A3 na CAPES, o que reforça a relevância científica e a

qualidade metodológica do trabalho apresentado.

Com isso, esta pesquisa contribui de forma significativa não apenas para a solução de um problema real no contexto da educação, mas também para a comunidade científica, ao oferecer um modelo replicável, dados de avaliação e uma aplicação concreta da metodologia DSR voltada à inovação educacional.

6.3 IMPLICAÇÕES DO TRABALHO

Este trabalho apresenta implicações significativas tanto para o contexto educacional quanto para o desenvolvimento de tecnologias aplicadas à aprendizagem colaborativa. No âmbito educacional, a solução proposta contribui para a otimização do processo de formação de equipes em metodologias baseadas no PBL, reduzindo o tempo e a complexidade envolvidos nessa tarefa. Ao automatizar a formação de grupos com base em critérios pedagógicos consistentes, como perfis de personalidade, afinidades e experiência profissional, o sistema favorece a criação de equipes mais equilibradas, aumentando o potencial de sucesso das interações colaborativas e, consequentemente, os resultados de aprendizagem.

Além disso, o trabalho evidencia a relevância da abordagem Design Science Research (DSR) para a criação de artefatos inovadores no contexto educacional. A metodologia utilizada permitiu o desenvolvimento incremental e sistemático de um sistema funcional, validado em diferentes turmas e adaptável a diversos cenários. Isso reforça a aplicabilidade do DSR em projetos que demandam refinamento contínuo e integração entre teoria e prática.

As implicações tecnológicas também são relevantes, especialmente no que diz respeito à utilização de ferramentas como Python, Pandas e Streamlit para o desenvolvimento de sistemas interativos e acessíveis. A solução final, com sua interface gráfica intuitiva, demonstra como tecnologias modernas podem ser aplicadas para atender às necessidades de docentes e facilitar o uso de sistemas automatizados em ambientes educacionais.

Por fim, a solução proposta serve como ponto de partida para futuras investigações e aplicações. As limitações identificadas, como a dificuldade em atender todas as restrições em contextos de baixa diversidade, indicam caminhos para aprimoramentos, como a integração com plataformas acadêmicas institucionais, o

desenvolvimento de funcionalidades para negociações pós-processamento e a análise do impacto das equipes balanceadas em variáveis como desempenho acadêmico e desenvolvimento de soft skills.

Portanto, este trabalho não apenas contribui para a resolução de um problema prático no ensino de computação, mas também abre espaço para novas pesquisas e inovações na área de tecnologias educacionais, consolidando-se como uma referência para docentes, instituições e pesquisadores interessados em melhorar a gestão de equipes em ambientes de aprendizagem colaborativa.

6.4 TRABALHOS FUTUROS

Com base nos resultados alcançados e nas potencialidades do sistema desenvolvido, diversas frentes podem ser exploradas em pesquisas futuras, destacando-se as seguintes:

- Ampliação dos ciclos de aplicação e validação empírica do sistema em diferentes instituições, cursos e contextos educacionais, visando fortalecer a generalização dos resultados e refinar os critérios de formação de equipes.
- Integração do sistema com plataformas acadêmicas institucionais, possibilitando o carregamento automático de dados dos estudantes, autenticação via sistemas de login e validação cruzada das informações inseridas, o que aumentaria a confiabilidade e a escalabilidade da solução.
- Desenvolvimento de funcionalidades de arquivamento histórico e versionamento de equipes, permitindo o acompanhamento das formações e facilitando análises comparativas entre semestres ou disciplinas.
- Inclusão de um módulo de entrada de dados diretamente na própria ferramenta³, eliminando a necessidade de utilização de arquivos CSV para o carregamento de informações, além de permitir o cadastro dos docentes e estudantes com níveis diferentes de acesso ao sistema. Esse módulo poderia

³ Essa funcionalidade não foi implementada na versão atual devido à decisão de manter o algoritmo simples e leve, sem necessidade de investimentos em banco de dados ou manutenções frequentes. A intenção foi desenvolver uma solução prática e acessível, que pudesse ser utilizada de forma direta e rápida, sem exigir recursos adicionais ou infraestrutura mais complexa. Esse conceito de simplicidade garantiu que o sistema fosse funcional e adaptável ao contexto educacional, alinhando-se aos objetivos iniciais do trabalho.

tornar o sistema ainda mais prático e intuitivo para o organizador, permitindo o preenchimento e validação dos dados dos estudantes diretamente na interface.

- Criação de um módulo de negociação pós-processamento, que permita ao professor ou à própria equipe realizar ajustes finos nas sugestões de agrupamento geradas pelo sistema, com base em feedbacks ou situações específicas da turma.
- Análise do impacto das equipes balanceadas nas dimensões individuais de avaliação do modelo PBL-SEE (Conteúdo e Performance) a fim de investigar se há alguma relação entre os critérios utilizados na formação das equipes e o desempenho individual dos seus integrantes. Outra abordagem pode ser explorar a influência da solução no engajamento, desenvolvimento de soft skills e satisfação dos estudantes, abrindo espaço para estudos interdisciplinares com outras áreas.
- Realização de uma comparação entre os times formados pela ferramenta automatizada e os times gerados manualmente em períodos anteriores, utilizando as mesmas dimensões de avaliação aplicadas na dissertação: Resultado, Processo e Satisfação do Cliente. Essa análise permitiria investigar se as equipes formadas pelo sistema automatizado apresentam desempenhos equivalentes, superiores ou inferiores aos dos grupos criados manualmente, trazendo uma perspectiva mais ampla sobre a eficácia da solução proposta.
- Implementação de uma funcionalidade que permita ao instrutor adicionar novos critérios de formação de equipes diretamente na ferramenta. Essa funcionalidade ampliaria a flexibilidade do sistema, possibilitando que o organizador adapte os critérios às necessidades específicas da turma ou da disciplina, indo além dos parâmetros já estabelecidos, como personalidade, gênero, experiência profissional e afinidades. Com essa melhoria, o sistema poderia ser utilizado em uma variedade ainda maior de contextos educacionais, atendendo a demandas personalizadas e promovendo formações de equipes mais alinhadas aos objetivos pedagógicos de cada aplicação. Essa evolução contribuiria para tornar a ferramenta mais robusta e adaptável a diferentes cenários.

Essas possibilidades demonstram o potencial da solução proposta como ponto de partida para diversas investigações aplicadas, voltadas à melhoria da aprendizagem colaborativa mediada por tecnologia no ensino superior.

REFERÊNCIAS

- Ardaiz-Villanueva, O., Nicuesa-Chacón, X., Brene-Artazcoz, O., de Acedo Lizarraga, MLS, & de Acedo Baquedano, MTS (2011). Avaliação de ferramentas de computador para geração de ideias e formação de equipes em aprendizagem baseada em projetos. *Computadores e Educação*, 56(3), 700-711.
- BARROWS, Howard S. Aprendizagem baseada em problemas na medicina e além: uma breve visão geral. *Novas direções para o ensino e a aprendizagem*, v. 1996, n. 68, p. 3-12, 1996.
- BOYLE, Gregory J. Myers-Briggs type indicator (MBTI): some psychometric limitations. *Australian Psychologist*, v. 30, n. 1, p. 71-74, 1995.
- BOWMAN, Nicholas A. et al. How prior programming experience affects students' pair programming experiences and outcomes. In: *Proceedings of the 2019 ACM Conference on innovation and technology in computer science education*. 2019. p. 170-175.
- Chen, CM, & Kuo, CH (2019). Um esquema de formação de grupo otimizado para promover a aprendizagem colaborativa baseada em problemas. *Computadores e Educação*, 133, 94-115.
- CHERYAN, S. et al. Why are some STEM fields more gender balanced than others? *Psychological Bulletin*, v. 143, n. 1, p. 1–35, 2017. Disponível em: <https://doi.org/10.1037/bul0000052>.
- COELHO, M. da C.; GUEDES, A. M. A. Aprendizagem Baseada em Problemas aplicada à Programação de Computadores: Um Mapeamento Sistemático. *RENOTE*, v. 18, n. 1, 2020. DOI: 10.22456/1679-1916.110298.
- Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences* (2^a ed.). Lawrence Erlbaum Associates.
- DE OLIVEIRA, Alexandre Manicoba et al. Algoritmos e técnicas de programação com uma abordagem de aprendizagem baseada em problemas para cursos de engenharia. In: *5º Congresso Científico da Semana Nacional de Ciência e Tecnologia no IFSP*. 2014.
- DE SANTANA, Ricardo E.; DOS SANTOS, Simone C.; MAIA, Davi J. Mendes. Favoring Collaborative Learning in PBL: An Automated Solution for Semantic Group Formation. In: *2024 IEEE Frontiers in Education Conference (FIE)*. IEEE, 2024. p. 1-8. DOI: 10.1109/FIE61694.2024.10893355.
- DOS SANTOS, Simone C. PBL-SEE: An authentic assessment model for PBL-based software engineering education. *IEEE Transactions on Education*, v. 60, n. 2, p. 120-126, 2016.
- Driskell, JE, Goodwin, GF, Salas, E., & O'Shea, PG (2006). O que faz um bom

jogador de equipe? Personalidade e eficácia da equipe. *Dinâmica de grupo: teoria, pesquisa e prática*, 10(4), 249.

ENCONTRO NACIONAL DO CONPEDI/UFSC, 23., 2014, Santa Catarina. Problem-based learning (PBL) aplicado aos cursos de graduação em direito. Florianópolis: Researchgate, 2014. 17 p. Disponível em: <<http://www.publicadireito.com.br/artigos/?cod=abdac3c2c521741e>>. Acesso em: 10 jun. 2019.

JUPYTER. Project Jupyter. © 2015. Disponível em: <https://jupyter.org>. Acesso em: abr., 2025.

ESCRIVÃO FILHO, Edmundo; RIBEIRO, Luis Roberto de Camargo. Aprendendo com PBL: aprendizagem baseada em problemas: relato de uma experiência em cursos de engenharia da EESC-USP. *Revista Minerva*, v. 6, n. 1, p. 23-30, 2009.

FELDER, R. M.; BRENT, R. Turning student groups into effective teams. *Journal of Engineering Education*, v. 94, n. 1, p. 57–61, 2004.

Ferreira, TB, Buiar, JA, Fernandes, MA, Pimentel, AR, & Oliveira, LS (2020). Regras para formação de grupos de colaboração usando detecção automática de traços de personalidade. *Revista Brasileira de Informática na Educação*, 28, 273-296.

FONTEIJN, Herco TH; DOLMANS, Diana HJM. Group work and group dynamics in PBL. *The Wiley handbook of problem-based learning*, p. 199-220, 2019.

GRUENFELD, Deborah H. et al. Group composition and decision making: How member familiarity and information distribution affect process and performance. *Organizational behavior and human decision processes*, v. 67, n. 1, p. 1-15, 1996.

Hays, W. L. (1994). *Statistics for the Social Sciences* (4^a ed.). Holt, Rinehart, and Winston.

Henry, HR, Tawfik, AA, Jonassen, DH, Winholtz, RA, & Khanna, S. (2012). “Eu sei que isso deveria ser mais parecido com o mundo real, mas...”: percepções dos alunos sobre uma implementação de PBL em um curso de graduação em ciência dos materiais. *Interdisciplinary Journal of Problem-based Learning*, 6(1), 43-81.

HEVNER, Alan R. et al. Design science in information systems research. *MIS quarterly*, p. 75-105, 2004.

HEVNER, Alan et al. Design science research in information systems. *Design research in information systems: theory and practice*, p. 9-22, 2010.

Holen, A., Manandhar, K., Pant, DS, Karmacharya, BM, Olson, L. M., & Koju, R. (2015). Preferências de estudantes de medicina para aprendizagem baseada em problemas em relação à cultura e personalidade: um estudo multicultural. *Revista internacional de educação médica*, 6, 84.

INSTITUTO SEMESP. Mapa do ensino Superior no Brasil 2023. 2023.

Isotani, S., Inaba, A., Ikeda, M., & Mizoguchi, R. (2009). Uma abordagem de engenharia de ontologia para a realização da formação de grupos orientada por teoria. International Journal of Computer-Supported Collaborative Learning, 4, 445-478.

KEIRSEY. Temperament Overview. [S. I.], [s. d.]. Disponível em: <https://keirsey.com/temperament-overview/>. Acesso em: 12 abril 2025.

Kobusingye, C. (2006). O papel da personalidade no desenvolvimento de equipes de alto desempenho estudo de caso: faculdade de educação: Kampala Universidade Internacional (Tese de doutorado, Universidade Internacional de Kampala, Faculdade de Economia e Gestão).

Michailidou, A., & Economides, A. (2008). Gênero e diversidade em equipes virtuais colaborativas. Em Aprendizagem colaborativa apoiada por computador: melhores práticas e princípios para instrutores (pp. 199-224). IGI Global.

Montequin, VR, Balsera, JV, Fernández, JMM e Juiz, JDC (2010, abril). Usando o Myers-Briggs Type Indicator (MBTI) para avaliar o sucesso de grupos de alunos em aprendizagem baseada em projetos. In International Conference on Computer Supported Education (Vol. 2, pp. 156-160). SCITEPRESS.

MOSS-RACUSIN, C. A. et al. Science faculty's subtle gender biases favor male students. Proceedings of the National Academy of Sciences, v. 109, n. 41, p. 16474–16479, 2012. Disponível em: <https://doi.org/10.1073/pnas.1211286109>.

Myers & Briggs Foundation. (2021). MBTI Basics. <https://www.myersbriggs.org/my-mbti-personality-type/mbti-basics/>. Acesso em: 12 abril 2025.

MORENO, Julián; OVALLE, Demetrio A.; VICARI, Rosa M. A genetic algorithm approach for group formation in collaborative learning considering multiple student characteristics. Computers & Education, v. 58, n. 1, p. 560-569, 2012.

OUNNAS, A.; DAVIS, H. C.; MILLARD, D. E. A framework for recommending student teams: Thinking in terms of groups. International Journal of Artificial Intelligence in Education, v. 24, n. 1, p. 1–26, 2014.

OUNNAS, Asma. Enhancing the automation of forming groups for education with semantics. 2010. Tese (Doutorado) – University of Southampton, School of Electronics and Computer Science.

Pittenger, D. J. (2005). Cautionary comments regarding the Myers-Briggs Type Indicator. Consulting Psychology Journal: Practice and Research, 57(3), 210–221.

Reis, R. C. D., Lyra, K. T., Reis, C. D. G., Penteado, B. E., & Isotani, S. (2020). The use of personality traits to enhance theory-driven group formation. Revista Brasileira de Informática na Educação-RBIE, 28, 796-818.

RIBEIRO, L. R. C.. APRENDIZAGEM BASEADA EM PROBLEMAS (PBL) NA

EDUCAÇÃO EM ENGENHARIA. Revista de Ensino de Engenharia, Brasília, v. 27, n. 2, p.23-32, jan. 2008.

SAVERY, John R.; DUFFY, Thomas M. Problem based learning: an instructional model and its constructivist framework. *Educational Technology*, v. 35, n. 5, p. 31–38, set./out. 1995. Disponível em: <<https://www.jstor.org/stable/44428296>>. Acesso em: 2 abr.2025.

SALAS, Eduardo; COOKE, Nancy J.; ROSEN, Michael A. On teams, teamwork, and team performance: Discoveries and developments. *Human Factors*, v. 50, n. 3, p. 540–547, 2008. DOI: <https://doi.org/10.1518/001872008X288457>

SEI PLATAFORMA EDUCACIONAL. PBL: Problem Based Learning. Disponível em: <<https://sei.inf.br/produtos/pbl-problem-based-learning/>>. Acesso em: 12 jun. 2024.

SOUSA, S. de O. Aprendizagem Baseada em Problemas (PBL – Problem-Based Learning): Estratégia para o Ensino e Aprendizagem de Algoritmos e Conteúdos Computacionais. 2010. Dissertação (Mestrado em Educação) – Universidade Estadual Paulista, Faculdade de Ciências e Tecnologia, Presidente Prudente, 2010.

S. C. dos Santos, P. B. S. Reis, J. F. S. Reis e F. Tavares, "Duas Décadas de PBL no Ensino de Computação: Um Estudo de Mapeamento Sistemático", em *IEEE Transactions on Education*, vol. 64, nº 3, pp. 233-244, agosto de 2021, doi: 10.1109/TE.2020.3033416.

SUCIU, Dan Mircea; MOTOGNA, Simona; MOLNAR, Arthur-Jozsef. Transitioning a project-based course between onsite and online. An experience report. *Journal of Systems and Software*, v. 206, p. 111828, 2023.

UNESCO. Cracking the code: Girls' and women's education in science, technology, engineering and mathematics (STEM). Paris: UNESCO, 2017. Disponível em: <https://unesdoc.unesco.org/ark:/48223/pf0000253479>. Acesso em abr. 2025.

WANG, Dai-Yi; LIN, Sunny SJ; SUN, Chuen-Tsai. DIANA: A computer-supported heterogeneous grouping system for teachers to conduct successful small learning groups. *Computers in Human Behavior*, v. 23, n. 4, p. 1997-2010, 2007.

WIERINGA, Roel J. Design science methodology for information systems and software engineering. Berlin: Springer, 2014.

WHITE, Jeffry L.; MASSIHA, G. H. The retention of women in science, technology, engineering, and mathematics: A framework for persistence. *International Journal of Evaluation and Research in Education*, v. 5, n. 1, p. 1-8, 2016.