

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA DE PRODUÇÃO**

**Modelo preditivo de Aprendizagem Ativa em Engenharia
baseado na Modelagem de Equações Estruturais com
Mínimos Quadrados Parciais (PLS-SEM)**

Leovani Marcial Guimarães

Itajubá, abril de 2021

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA DE PRODUÇÃO**

Leovani Marcial Guimarães

**Modelo preditivo de Aprendizagem Ativa em Engenharia
baseado na Modelagem de Equações Estruturais com
Mínimos Quadrados Parciais (PLS-SEM)**

Tese submetida ao Programa de Pós- Graduação em Engenharia de Produção como parte dos requisitos para obtenção do Título de Doutor em Ciências em Engenharia de Produção.

Área de concentração: Engenharia de Produção

Orientador: Prof. Dr. Renato da Silva Lima

Itajubá, abril de 2021

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA DE PRODUÇÃO**

Leovani Marcial Guimarães

**Modelo preditivo de Aprendizagem Ativa em Engenharia
baseado na Modelagem de Equações Estruturais com
Mínimos Quadrados Parciais (PLS-SEM)**

Tese submetida ao Programa de Pós- Graduação em Engenharia de Produção como parte dos requisitos para obtenção do Título de Doutor em Ciências em Engenharia de Produção.

Banca Examinadora

Prof. Dr. Renato da Silva Lima, UNIFEI (orientador).

Prof. Dr. Fabiano Leal, UNIFEI.

Prof. Dr. Pedro Paulo Balestrassi, UNIFEI.

Prof. Dr. Rui Manuel de Sá Pereira de Lima, UMINHO.

Prof. Dr. Carlos Nazareth Motta Marins, INATEL.

Itajubá, abril de 2021

DEDICATÓRIA

Deus, à minha família e a todos que me ajudaram e me deram apoio nesta conquista.

AGRADECIMENTOS

A Deus por todas oportunidades, desafios e pessoas que colocou em minha trajetória.

À minha família, em especial minha esposa e minha filha pelo apoio, suporte e amor, em todos os momentos, para a concretização deste trabalho e pela paciência durante minha ausência, mesmo que fisicamente presente.

A todos os professores que me ajudaram e contribuíram com este trabalho. Em especial ao meu orientador Prof. Dr. Renato da Silva Lima, por me acolher no seu grupo de pesquisa Logtrans e acreditar em mim.

Aos professores da Universidade Federal de Itajubá (UNIFEI) e do Instituto Nacional de Telecomunicações (INATEL) que participaram direta ou indiretamente neste projeto e também aos colegas do grupo de pesquisa Logtrans que estiveram sempre dispostos a me ajudar, contribuindo para a melhoria deste trabalho.

EPÍGRAFE

“A persistência é a mais curta trajetória para o êxito”. (Charles Chaplin)

RESUMO

As Diretrizes Curriculares Nacionais (DCN) dos Cursos de Graduação em Engenharia de 2019 apresentaram novas demandas pedagógicas, sendo uma delas a aplicação de Aprendizagem Ativa (AA). A pesquisa científica sobre AA aplicada aos cursos de Engenharia tem crescido de forma relevante nos últimos anos e seus resultados tem revelado desafios e oportunidades para novos estudos. Instrumentos de observação em sala de aula projetados para os ambientes de AA surgiram e têm apoiado pesquisas para avaliação dos comportamentos e atitudes que caracterizam tais ambientes. Entretanto, observou-se a falta de previsibilidade para as Instituições de Ensino Superior (IES) de Engenharia quanto aos ganhos de aprendizagem ao aplicar as técnicas ativas dentro de um processo desafiador de mudança de práticas de ensino. Neste contexto, o objetivo desta tese foi propor um modelo matemático preditivo que demonstrasse a relação entre a aprendizagem dos alunos (medido pelas suas notas) e a aplicação ou não das técnicas de AA em sala de aula (medido pelo nível de atividade capturado por um protocolo de observação). Para atingir esse objetivo, uma rígida sistemática metodológica foi estabelecida, utilizando-se de pesquisa experimental controlada em uma IES de Engenharia ao longo de três anos, em duas dimensões de análise. A primeira, intraclasse, utilizou um projeto de amostras pareadas para gerar as bases de observações e graus de desempenho e demonstrar a provável relação causa-efeito em dois níveis de um fator, além de permitir a avaliação qualitativa da abordagem de AA de cada disciplina. A segunda, interclasse, envolveu amostras independentes de turmas em semestres subsequentes e utilizou a Modelagem de Equações Estruturais por Mínimos Quadrados Parciais - PLS-SEM para testar e identificar o melhor modelo preditivo para a aprendizagem em função da aplicação da AA. Os resultados intraclasse demonstraram uma relação positiva de causa-efeito, onde o desempenho acadêmico médio global foi 14% melhor na avaliação pós AA, comparado com a primeira, sem a aplicação de técnicas de AA, representando 40% do desvio padrão das notas. Além disto, a análise individual do desempenho em cada uma das disciplinas revelou as estratégias de maior e menor sucesso e permitiu recomendar aquelas estratégias mais viáveis de AA para grupos específicos de disciplinas. Na dimensão interclasse, a melhoria foi de 10% e o modelo preditivo PLS-SEM foi validado positivamente por diversos índices de desempenho, demonstrando uma relação positiva significativa e não linear entre os constructos latentes, com capacidade entre moderada e alta de predição de alvos de aprendizagem ($Q^2 > 0,344$), a partir dos níveis de AA. Na demonstração da relevância preditiva, a curva ajustada da relação permitiu, a partir de um escore médio entre 0 e 35,97 no nível de aderência AA (NAA) prever um escore médio de Aprendizagem (AP) entre 45,89 e 74,90, na escala de graus de desempenho. Os coeficientes β foram positivos e significativos, com valores $p < 0,01$. A sistemática metodológica e os resultados obtidos pretendem ser as principais contribuições desta pesquisa para a literatura e para a discussão latente da eficácia de métodos ativos de aprendizagem na Educação em Engenharia.

Palavras Chave: Aprendizagem Ativa, Educação em Engenharia, Protocolos de Observação em Sala de Aula, Modelagem de Equações Estruturais, Mínimos Quadrados Parciais, PLS-SEM.

ABSTRACT

The Brazilian National Curriculum Guidelines (DCN) of the Undergraduate Engineering Courses of 2019 presented new pedagogical demands, one of them being the application of Active Learning (AL). Scientific studies on AL applied to Engineering courses has grown significantly in recent years and its results uncovered challenges and opportunities for future research. Classroom observation instruments designed for AL environments have emerged and have supported research to objectively assess the behaviors and attitudes that characterize such environments. However, there was a lack of predictability for Engineering Higher Education Institutions (EHEIs) regarding learning gains when applying AL techniques within a challenging process of changing teaching practices. In this context, the objective of this thesis was to propose a predictive mathematical model that demonstrates the relationship between the students' degree of learning and the application or not of AL techniques in the classroom (measured by the level of activity captured by an observation protocol). To achieve this objective, a strict and systematic methodological process was established, using controlled experimental research in an EHEI over three years, in two dimensions of analysis. The first one, intraclass, used a repeated measures experimental design to demonstrate the probable cause-effect relationship in a two-level one-factor approach. In addition, it allowed a qualitative analysis of AA application in individual courses. The second, interclass, involved independent class samples in subsequent semesters and used Partial Least Squares Structural Equation Modeling to test and identify the best predictive model for learning based on the application of AL. The intraclass results demonstrated, in a positive cause-effect relationship, that the global average academic performance was 14% better in the post-AL assessment, compared to the first, without the application of AL techniques, representing 40% of the standard deviation of the grades. In addition, the individual analysis of performance in each of the courses revealed the most and least successful strategies and allowed to recommend those most viable AL strategies for specific groups of courses. In the interclass dimension, the improvement was 10% and the PLS-SEM predictive model was positively validated by several performance indexes, demonstrating a significant and non-linear positive relationship between the latent constructs, with a moderate to high relevance for learning prediction ($Q^2 > 0.344$). In the demonstration of the predictive relevance, the best-fitting curve of the relationship allowed, from an average score between 0 and 35.97 in the level of AL adherence (NAA) to predict an average Learning score (AP) between 45.89 and 74.90 on the scale of performance degrees. β coefficients were positive and significant, with p values < 0.01 . The systematic methodological design and the results obtained are intended to be the main contributions of this research to the literature and to the latent discussion of the effectiveness of active learning methods in Engineering Education.

Keywords: Active Learning, Engineering Education, Classroom Observation Protocols, Structural Equation Modeling, Partial Least Squares, PLS-SEM.

LISTA DE FIGURAS

Figura 1 - Exemplo de modelo de trajetórias SEM	22
Figura 2 - Taxonomia de Bloom.....	34
Figura 3 - Mapas Conceituais.....	44
Figura 4 - Evolução dos COP's de EE/STEM em ambientes de aprendizagem ativa.....	55
Figura 5 - Modelo básico SEM.....	62
Figura 6 - A Teoria SEM e o diagrama de trajetórias.....	65
Figura 7 - Modelo PLS-SEM de Fator e Compósito (<i>Mixed Model</i>).....	74
Figura 8 - Exemplo de Modelo PSL-SEM - Aplicação	78
Figura 9 - Classificação da Pesquisa nesta tese	94
Figura 10 - Dimensões da abrangência da pesquisa	100
Figura 11 - Framework do planejamento dos experimentos Intraclasse.....	101
Figura 12 - Framework do planejamento dos experimentos Interclasse.....	105
Figura 13 - Protocolo PORE – adaptado do COPUS - na plataforma PGOR.....	109
Figura 14 - Tela com lista parcial de observações.....	111
Figura 15 - Solução de Problemas de Pesquisa por Modelagem.....	115
Figura 16 - Modelo Conceitual.....	117
Figura 17 - Diagrama de trajetórias - Especificação genérica da tese	120
Figura 18 - Menu de Cálculos do SmartPLS® 3.0.....	121
Figura 19 - Teste de normalidade para a distribuição das diferenças.....	126
Figura 20 - Diferenças entre as médias globais das amostras	127
Figura 21 - Análise Global Aula Tradicional x Ativa - % Média de Tempo Ativo	129
Figura 22 - Percepção dos professores I	133
Figura 23 - Percepção dos professores II.....	133
Figura 24 - Percepção dos professores III.....	134
Figura 25 - Percepção dos professores IV.....	134
Figura 26 - Resumo de resultados do <i>screening</i> de arranjos.....	140
Figura 27 - Modelo preditivo inicial da Aprendizagem.....	143
Figura 28 - Modelo preditivo final da Aprendizagem	152
Figura 29 - Relação da Aprendizagem com nível de AA – Melhor Ajuste	153

LISTA DE QUADROS

Quadro 1 - Aspectos e Lacunas da literatura.....	28
Quadro 2 - Resumo da proposição de valor dos COP's	56
Quadro 3 - Simbologia da SEM	61
Quadro 4 - Algoritmo Básico da PLS-SEM.....	70
Quadro 5 - Framework do processo de pesquisa	95
Quadro 6 - Elementos COPUS versus PORE.....	112
Quadro 7 - Opções de Codificação das variáveis	117

LISTA DE TABELAS

Tabela 1 - Publicações por base de dados e critério de busca	27
Tabela 2 - Tamanho de amostra mínimo sugerido em um modelo PLS-SEM.....	70
Tabela 3 - Alguns índices recentes recomendados em PLS-SEM.....	89
Tabela 4 - Resumo do planejamento geral dos experimentos	108
Tabela 5 - Exemplo de relatório de graus de desempenho.....	114
Tabela 6 - Critérios para avaliação e validação dos modelos de Medição e Estrutural.....	122
Tabela 7 - Corte parcial das amostras de graus de desempenho	125
Tabela 8 - Resultado individual de disciplinas e técnicas de AA aplicadas	130
Tabela 9 - Estratégias de AA propostas a partir da pesquisa	137
Tabela 10 - Resultados da análise preliminar da modelagem	141
Tabela 11 - Corte parcial da tabela de observações no arranjo 184 D1-D4.....	142
Tabela 12 - Ajuste global do modelo.....	144
Tabela 13 - Validação dos modelos de medição reflexivos	145
Tabela 14 - Corte parcial dos erros padrão dos indicadores	146
Tabela 15 - Análise de resíduos.....	146
Tabela 16 - Validação do modelo estrutural	147
Tabela 17 - Validação de robustez do modelo	149

LISTA DE EQUAÇÕES

(1) - Parte estrutural do modelo SEM.....	63
(2) - Parte endógena do modelo SEM.....	64
(3) - Parte exógena do modelo SEM.....	64
(4) - Medição exógena 1.....	65
(5) - Medição exógena 2.....	65
(6) - Medição exógena 3.....	65
(7) - Medição exógena 4.....	66
(8) - Medição exógena 5.....	66
(9) - Medição exógena 6.....	66
(10) - Medição endógena 1.....	66
(11) - Medição endógena 2.....	66
(12) - Medição endógena 3.....	66
(13) - Medição endógena 4.....	66
(14) - Equação estrutural 1.....	66
(15) - Equação estrutural 2.....	66
(16) - Confiabilidade composta.....	79
(17) - AVE.....	80
(18) - HTMT.....	81
(19) - VIF.....	82
(20) - Tamanho do efeito.....	86
(21) - Especificação do modelo reflexivo exógeno.....	119
(22) - Especificação do modelo reflexivo endógeno.....	119
(23) - Especificação do modelo estrutural.....	119

LISTA DE ABREVIATURAS E SIGLAS

3DCOS	<i>Three Dimension Classroom Observation System</i>
AA	<i>Aprendizagem Ativa</i>
ACS	<i>American Chemical Society</i>
AL	<i>Active Learning</i>
ALCOT	<i>Active Learning Classroom Observation Tool</i>
ALIT	<i>Active-Learning Inventory Tool</i>
ANOVA	<i>Analysis of Variance</i>
aRTOP	<i>altered Reformed Teaching Observation Protocol</i>
ASPECT	<i>Assessing Student Perspective of Engagement in Class Tool</i>
AVE	<i>Average Variance Extracted</i>
BERI	<i>Behavioral Engagement Related to Instruction</i>
BOSS	<i>Behavior Observation of Students in Schools</i>
CAPES	<i>Coordenação de Aperfeiçoamento de Pessoal de Nível Superior</i>
CB	<i>Covariance-Based</i>
CB-SEM	<i>Covariance Based Structural Equation Modeling</i>
CCCO	<i>Community College Classroom Observation</i>
CDAT	<i>Classroom Discourse Analysis Tool</i>
CDOP	<i>Classroom Discourse Observation Protocol</i>
CIEOP	<i>Classroom Interactive Engagement Observation Protocol</i>
CLASS	<i>Classroom Assessment Scoring System</i>
CLOP	<i>Cooperative Learning Observation Protocol</i>
CM	<i>Conceptual Maps</i>
COP	<i>Classroom Observation Protocol</i>
COPEd	<i>Classroom Observation Protocol for Engineering Design</i>
COPUS	<i>Classroom Observation Protocol for Undergraduate STEM</i>
COSPERM	<i>Code for Students' Performance Measures</i>
DART	<i>Decibel Analysis for Research in Teaching</i>
DCN	<i>Diretrizes Curriculares Nacionais</i>
DRM	<i>Design Research Methodology</i>
DOAJ	<i>Directory of Open Access Journals</i>
EE	<i>Educação em Engenharia</i>
EJEE	<i>European Journal of Engineering Education</i>
ELCOT	<i>Engineering Learning Classroom Observation Tool</i>
EQUIP	<i>Electronic Quality of Inquiry Protocol</i>
ERIC	<i>Education Resources Information Center</i>
ETBC	<i>Effective Team Behavior Checklist</i>
FIMIX	<i>Finite Mixture</i>
GL	<i>Graus de Liberdade</i>
HTMT	<i>HeteroTrait_MonoTrait</i>
IEEE	<i>Institute of Electrical and Electronic Engineering</i>

IES	Instituição de Ensino Superior
IOP	<i>Inquiry-Based Observation Protocol</i>
ISIOP	<i>Inquiring into Science Instruction Observation Protocol</i>
ISOCS	<i>Inquiry Science Observation Coding Sheet</i>
JITT	<i>Just In Time Teaching</i>
JSTOR	<i>Journal Storage</i>
KTOP	<i>Korean Teaching Observation Protocol</i>
LAMM	<i>Learner Activity Monitoring Matrix</i>
LISREL	<i>Linear Structural Relations</i>
LV	<i>Latent Variable</i>
MAE	<i>Mean Absolute Error</i>
MCOP²	<i>Mathematics Classroom Observation Protocol for Practices</i>
MGA	<i>Multi Group Analysis</i>
MIST	<i>Measurement Instrument for Scientific Teaching</i>
MV	<i>Manifest Variable</i>
OPAL	<i>Observation Protocol for Active Learning</i>
PBL	<i>Problem Based Learning</i>
PGOR	Plataforma Geral de Observação e Reflexão
PjBL	<i>Project Based Learning</i>
PLS	<i>Partial Least Square</i>
PLS-SEM	<i>Partial Least Square Structural Equation Modeling</i>
POA	Protocolo de Observação de Aula
POGIL	<i>Process Oriented Guided Inquiry Learning</i>
PORE	Protocolo de Observação e Reflexão em Engenharia
PORTAAL	<i>Practical Observation Rubric To Assess Active Learning</i>
PSI	<i>Principles of Scientific Inquiry</i>
PULSE	<i>Protocol Base Utility to Log Student Engagement</i>
QAP	<i>Question and Answer Protocol</i>
RMSE	<i>Root Mean Square Error</i>
RTOP	<i>Reformed Teaching Observation Protocol</i>
SACS	<i>Student Actions Coding Sheet</i>
SBE	<i>Students' Behavioral Engagement</i>
SCAEI	<i>Student Class Activity and Engagement Instrument</i>
SCIELO	<i>Scientific Electronic Library Online</i>
SD	<i>Standard Deviation</i>
SEM	<i>Structural Equation Modeling</i>
SIOI	<i>Scholastic Inquiry Observation Instrument</i>
SMOP	<i>Science Management Observation Protocol</i>
SPB	<i>Student's Participatory Behavior</i>
SSM	<i>Soft System Methodology</i>
STEM	<i>Science, Technology, Engineering and Mathematics</i>
STIR	<i>Science Teacher Inquiry Rubric</i>
StRIP	<i>Student Response to Instructional Practices</i>

TBL	<i>Team Based Learning</i>
TDOP	<i>Teaching Dimensions Observation Protocol</i>
TPI	<i>Teaching Practices Inventory</i>
TPS	<i>Think Pair Share</i>
VIF	<i>Variance Inflation Factor</i>
VOS	<i>VaNTH (from Vanderbilt University - USA) Observation System</i>

SUMÁRIO

1. INTRODUÇÃO.....	18
1.1. Contextualização	18
1.2. Delimitações da pesquisa.....	24
1.2.1. Objeto de estudo	24
1.2.2. Limitações	25
1.3. Justificativas.....	26
1.3.1. Originalidade	26
1.3.2. Lacunas e Perguntas de Pesquisa.....	28
1.3.3. Hipóteses associadas	29
1.4. Objetivos.....	30
1.4.1. Objetivo geral	30
1.4.2. Objetivos específicos	31
1.5. Estrutura da tese	31
2. FUNDAMENTAÇÃO TEÓRICA.....	32
2.1. Critérios de inclusão e abrangência da bibliografia	32
2.2. Técnicas de Aprendizagem Ativa	33
2.2.1. Aprendizagem baseada em problemas - PBL (<i>Problem Based Learning</i>)	36
2.2.2. Aprendizagem baseada em Projetos - PjBL (<i>Project Based Learning</i>).....	39
2.2.3. Aprendizagem baseada em equipes - TBL (<i>Team Based Learning</i>)	41
2.2.4. Instrução por Pares (<i>Peer Instruction</i>) e Aula invertida	42
2.2.5. Ensino no tempo certo - JITT (<i>Just-in-Time Teaching</i>).....	43
2.2.6. Caso de Ensino (Estudo de Caso).....	43
2.2.7. Mapas Conceituais	44
2.2.8. <i>Design Thinking</i>	46
2.2.9. POGIL - <i>Process Oriented Guided Inquiry Learning</i>	47
2.3.1. Questões Recíprocas	49
2.3.2. Entrevista de 3 passos	49
2.3.3. Procedimento de Pausa	50
2.3.4. Advogado do diabo.....	50
2.3.5. Plataforma de jogos (<i>Gamification</i>).....	50
2.3.6. <i>Think_Pair_Share</i>	51
2.3.7. <i>Clicker Question</i> (Sistema de Perguntas e Respostas).....	52
2.4. Protocolos de Observação em Sala de Aula	52
2.5. Modelagem de Equações Estruturais	59

2.5.1.	Fundamentos.....	59
2.5.2.	Simbologia e Terminologia SEM.....	61
2.5.3.	A formulação do modelo geral da SEM.....	63
2.5.4.	Estimação de modelos de trajetória na variante PLS-SEM.....	67
2.5.5.	A formulação do modelo PLS-SEM.....	72
2.5.6.	Etapas para aplicação da abordagem PLS-SEM.....	76
3.	MÉTODO DE PESQUISA	90
3.1.	Classificação da pesquisa científica	90
3.2.	Etapas e procedimentos da Tese	94
3.3.	Experimentação e desenvolvimento da pesquisa	99
3.3.1.	Introdução.....	99
3.3.2.	Delineamento dos Experimentos em Sala de Aula.....	106
3.3.3.	Pesquisa Quantitativa - Aderência à AA.....	111
3.3.4.	Pesquisa Quantitativa - Graus de desempenho.....	113
3.3.5.	Modelagem e Simulação	114
4.	RESULTADOS E DISCUSSÃO.....	124
4.1.	Análise estatística na dimensão intraclasse	124
4.1.1.	Experimento com amostras pareadas.....	124
4.1.1.1.	Avaliação da influência de outros fatores.....	127
4.1.2.	Análise global intraclasse – perfil e estratégias de AA.....	128
4.2.	Os efeitos das estratégias de AA em disciplinas individuais.....	130
4.3.	Implementação, análise e validação do modelo PLS-SEM.....	138
4.3.1.	Análise de interações e escolha do arranjo de dados	139
4.3.2.	Análise Preliminar	140
4.3.3.	Modelagem, avaliação e ajuste do arranjo 184 D1-D4.....	142
4.3.3.1.	Ajuste global do modelo.....	144
4.3.3.2.	Validação dos modelos de medição reflexivos.....	144
4.3.3.3.	Validação do modelo estrutural	147
4.3.3.4.	Validação de robustez do modelo	149
4.3.3.5.	<i>Best fitting curve</i> do modelo preditivo de Aprendizagem.....	152
5.	CONCLUSÃO E CONSIDERAÇÕES FINAIS.....	155
5.1.	Conclusão	155
5.2.	Limitações e oportunidades para futuras pesquisas	160

1. INTRODUÇÃO

1.1. Contextualização

Em alguns dos debates a respeito do perfil do engenheiro para o século XXI, Escrivão Filho e Ribeiro (2009) e Casale (2013) expõem que o processo de educação atual, que se encontra no foco dessa discussão para muitas nações, está em estado de esgotamento funcional e que a rápida obsolescência do grande volume de conhecimento passado aos alunos motiva essa discussão. Os autores avaliaram que na Educação em Engenharia (EE) há predominância dos currículos tradicionais, com pouca interdisciplinaridade e integração tardia. Os currículos ainda são organizados em sequência, das disciplinas de ciências básicas rumo às ciências aplicadas e depois as práticas, tais como estágios. Há uma discussão na comunidade acadêmica se a metodologia tradicional ainda promove a aprendizagem teórica e prática, bem como se estimula o desenvolvimento de outros tipos de conhecimentos importantes na visão acadêmica, profissional e social. Entretanto, mesmo quando há aceitações das insuficiências encontradas nos modelos convencionais, as instituições de ensino superior em Engenharia encontram-se em um sério dilema: como trabalhar as habilidades e atitudes de aprendizagens contínuas e independentes para toda a vida com a obrigação de ensinar um volume de conhecimentos técnicos e científicos crescentes, sem inchar os currículos e nem acrescentar anos a mais na escolarização formal.

As mais recentes Diretrizes Curriculares Nacionais (DCN) dos Cursos de Graduação em Engenharia, de 2019, trouxeram novos conceitos atuais, em comparação com a versão anterior do documento, de 2002. Dentre estes conceitos, constaram a) formação baseada por competências; b) o foco na prática; c) a aprendizagem ativa e; d) uma maior flexibilidade na constituição do currículo. O uso da Aprendizagem Ativa (AA) como um novo conjunto de métodos ou técnicas de aprendizagem, foi, portanto, previsto no novo texto. A intenção foi promover uma educação mais centrada no aluno e o desenvolvimento da autonomia dos alunos na aprendizagem (auto aprendizagem) também surge como forma de aprendizado contínuo na carreira dos futuros profissionais (MEC, 2019).

A metodologia tradicional de aprendizagem está baseada nas aulas expositivas, onde o professor é o centro das atenções. Em uma definição sucinta do método tradicional, pode-se dizer que é onde “... há contínua exposição do conteúdo pelo professor (BLIGH, 2000;

FREEMAN *et al.*, 2014, p4). Neste contexto, a atividade do aluno foi assumida como sendo limitada a ouvir, tomar notas e/ou fazer perguntas aleatórias e ocasionais ao instrutor, individualmente. As respostas ao desafio de colocar o aluno no centro das atenções têm sido formuladas através do uso de técnicas instrucionais de aprendizagem ativa. Uma definição sucinta de Aprendizagem Ativa (AA) é qualquer coisa que envolva os alunos a fazer as coisas e pensar sobre as coisas que eles estão fazendo (BONWELL; EISON, 1991). Freeman *et al.* (2014) demonstraram que a aprendizagem ativa melhora o desempenho dos estudantes em Ciências, Tecnologia, Engenharia e Matemática (sigla STEM no idioma Inglês), disciplinas centrais nos programas de graduação em Engenharia. Os autores realizaram uma meta-análise para avaliar a efetividade dos métodos de aprendizagem ativa (perguntar) versus aprendizagem tradicional baseada em aulas expositivas (dizer o que fazer), em cursos superiores e aulas de disciplinas STEM. Eles graduaram 225 fontes de pesquisa publicadas e não publicadas sobre estudos que compararam lado a lado os dois métodos genéricos. Sintetizando suas conclusões na forma estatística, os alunos sujeitos aos métodos de aprendizagem ativa obtiveram uma melhora de desempenho quantificada, em média, como quase a metade do desvio padrão das notas das avaliações. A relevância do tema pode também ser observada nas pesquisas relacionadas ao projeto de transformação da educação nos Estados Unidos da América e diversas discussões e novos projetos de pesquisa em metodologias ativas em outros países do mundo (BOWDEN; D’ALESSANDRO, 2011; CHANG *et al.*, 2014; CHEN; LOOI, 2011; LUND *et al.*, 2015; MUÑOZ *et al.*, 2013).

As estratégias de obtenção dos dados de sala de aula que permitem avaliar o nível de aderência à aprendizagem ativa passam pela utilização de técnicas sistemáticas de medição objetiva, comumente chamadas de instrumentos ou protocolos de observação em sala de aula, do inglês COP – *Classroom Observation Protocols*. Por exemplo, Smith *et al.* (2013) desenvolveram um instrumento chamado COPUS – *Classroom Observation Protocol for Undergraduate STEM*, para uso em um intenso processo de observação. Os autores incluíram 263 cursos de STEM em 28 grandes universidades americanas com forte enfoque em pesquisa e sugeriram um conjunto de perfis de cursos classificados dentro de uma escala de uso da aprendizagem ativa. O estudo destes pesquisadores utilizou um método empírico para realizar uma confiável e válida caracterização das práticas instrucionais, produzindo uma análise comparativa dos perfis mais comuns das mesmas. Em parte da revisão de literatura desta tese, o autor pesquisou os protocolos existentes a partir de fontes em 23 bancos de dados globais de 2000 a 2020 para uma revisão sistemática. A pesquisa descobriu as abordagens e aplicações de 68 protocolos de

observação avaliados em várias dimensões e permitiu sugestões para futuros estudos de EE, inclusive nesta pesquisa. Os autores revelaram como as estratégias de observação no ambiente de aprendizagem ativa incorporaram a EE alavancada por aplicações em STEM com 82% do total e a tendência crescente dessas aplicações, com 62% ocorrendo nos últimos 6 anos. A escolha do protocolo-base para esta tese e a sua adaptação levou em consideração tal revisão de literatura e um robusto histórico positivo de testes de validade e confiabilidade, bem como amplo número de aplicações em ambientes de aprendizagem ativa de EE e STEM (DAHER *et al.*, 2018; LEWIN *et al.*, 2016; SANDERS; SPIEGEL; SHERER, 2018)

As pesquisas nestes temas sugerem que a aprendizagem ativa pode melhorar o desempenho dos alunos em cursos de Engenharia de uma IES local, que há diversas técnicas ativas de aprendizagem disponíveis para tal desafio. Além disto, há métodos válidos e confiáveis para medir os comportamentos em sala de aula que demonstrem a aderência à AA e também formas de obter a avaliação de desempenho associada. Dessa forma, a Aprendizagem Ativa (AA) associada à Educação em Engenharia, os instrumentos de observação em sala de aula (COP) adequados e disponíveis para medição e o desempenho acadêmico resultante dos alunos formam um contexto favorável para realizar essa pesquisa.

Quando se utiliza certos tipos de conceitos teóricos mais abstratos, tais como os comportamentos dentro de uma sala de aula, com complexas interações entre alunos e professores-alunos, ou ainda o nível de aprendizagem dos alunos (o quanto eles aprenderam), na maior parte das vezes não é possível medi-los diretamente. A maioria das pesquisas em Educação concentra-se em variáveis que não são diretamente observáveis (SCHREIBER *et al.*, 2006). Pode-se citar como exemplos conceitos abstratos tais como extroversão, atitudes e a própria aprendizagem, conceito central tratado nesta pesquisa. Esses conceitos teóricos podem ser representados por constructos operacionalizados por variáveis que são geralmente chamadas de **variáveis latentes**. Os dados que são utilizados para medir indiretamente essas variáveis latentes, em geral, não seguem as premissas de normalidade previstas para os métodos paramétricos de análise estatística. É comum investigar a estrutura e o efeito de variáveis não mensuráveis diretamente através da análise de dados de diferenças interindividuais relacionando estatisticamente a covariação entre as variáveis observáveis e mensuráveis e as variáveis latentes. Isso é feito, por exemplo, nos modelos de análise fatorial (BORSBOOM; MELLENBERGH; VAN HEERDEN, 2003).

Aplicando-se a abordagem de uma variável latente para uma sala de aula com múltiplos eventos (atividades e comportamentos) ocorrendo com o instrutor, com cada aluno, entre alunos e entre instrutor e alunos, existe um grau ou nível de atividade não observável diretamente. Esta variável representaria o quanto de aprendizagem ativa (AA) está sendo utilizada em cada período de aula de acordo com a estratégia de aprendizagem implementada pelo instrutor. Embora esse nível de AA não possa ser medido diretamente, a proporção do tempo total da aula gasto com os diversos eventos de aprendizagem pode ser medida com protocolos de observação em sala de aula que possuam as características pertinentes a esse objetivo. Então, é possível supor que podemos medir indiretamente um constructo relativo ao conceito - atividade comportamental em sala de aula - operacionalizando uma variável latente “**nível de aderência à aprendizagem ativa**” a ser medida indiretamente pelas proporções do tempo total de aula alocadas para os diversos eventos de aprendizagem projetados no protocolo de observação. Esta medição formaria um vetor de indicadores manifestos do **nível de aderência à AA**, em uma escala contínua.

A aplicação das metodologias ativas ou tradicionais na sala de aula em certa proporção do tempo de aula (**o nível de aderência à AA**) pode causar graus diferentes de uma variável também latente tal como a **Aprendizagem**, que mesmo não podendo ser medida diretamente, pode ser avaliada através de suas **notas ou graus de desempenho** em uma escala contínua. Esta variável comporia um vetor de indicadores manifestos (as notas) para avaliar a aprendizagem. Se existir uma relação significativa entre estas variáveis, com um efeito relevante para os objetivos da pesquisa e cuja evidência de causa-efeito possa ser fundamentada pela teoria, pode-se desenvolver um modelo com viés preditivo entre elas. Tal modelo demonstraria essa relação causal do nível de AA para os graus de desempenho e permitiria exercitar alvos de aprendizagem a partir de níveis de AA. Um método que tem sido utilizado para esse tipo de tarefa é chamado SEM (*Structural Equation Modeling*) ou Modelagem de Equações Estruturais, e no caso específico desta tese, a vertente PLS-SEM (Modelagem de Equações Estruturais por Mínimos Quadrados Parciais). Esta vertente possui a capacidade de avaliar modelos de medição das variáveis latentes com dados em geral não paramétricos e não normais com premissas menos restritivas, enquanto também testando relações entre as próprias variáveis latentes (BABIN; HAIR JR.; BOLES, 2008).

A Modelagem de Equações Estruturais (SEM - *Structural Equation Modeling*) é um método de análise de dados multivariada de segunda geração o qual é frequentemente usado em pesquisas

de ciências comportamentais porque pode testar modelos causais lineares e não lineares com suporte teórico (HAENLEIN; KAPLAN, 2007). Os modelos de equações estruturais podem ser representados por um subconjunto de modelos gráficos chamados de *path diagram* ou diagrama de trajetórias. Cada modelo SEM está associado a um diagrama que representa a estrutura causal do modelo e a forma das equações. Há uma seta direcionada de uma variável independente *A* para uma variável dependente e eventualmente outra seta da variável independente *B* para a mesma variável dependente (ou seja, *A* e *B* são preditoras da variável dependente). Além disto, há setas que conectam as variáveis manifestas ou mensuráveis (indicadores) às variáveis latentes em ambos os sentidos. Se as setas se dirigem do indicador para a variável latente quer dizer que o indicador causa aquela variável latente, se no sentido contrário, a variável latente causa o indicador. Ainda podem haver outros elementos, tais como os termos de erro, coeficientes e pesos de regressão, conforme o modelo. Nos diagramas de trajetória, variáveis latentes independentes ou exógenas e variáveis latentes dependentes ou endógenas são colocadas em elipses e variáveis medidas (indicadores) são colocadas em retângulos. Os modelos que relacionam as variáveis latentes com seus indicadores são chamados de modelos de medição ou externos. O modelo que relaciona as variáveis latentes entre si é chamado de modelo estrutural ou interno. A Figura 1 ilustra de forma simplificada um modelo de trajetórias que representa a modelagem de equações estruturais (SEM) para uma situação genérica.

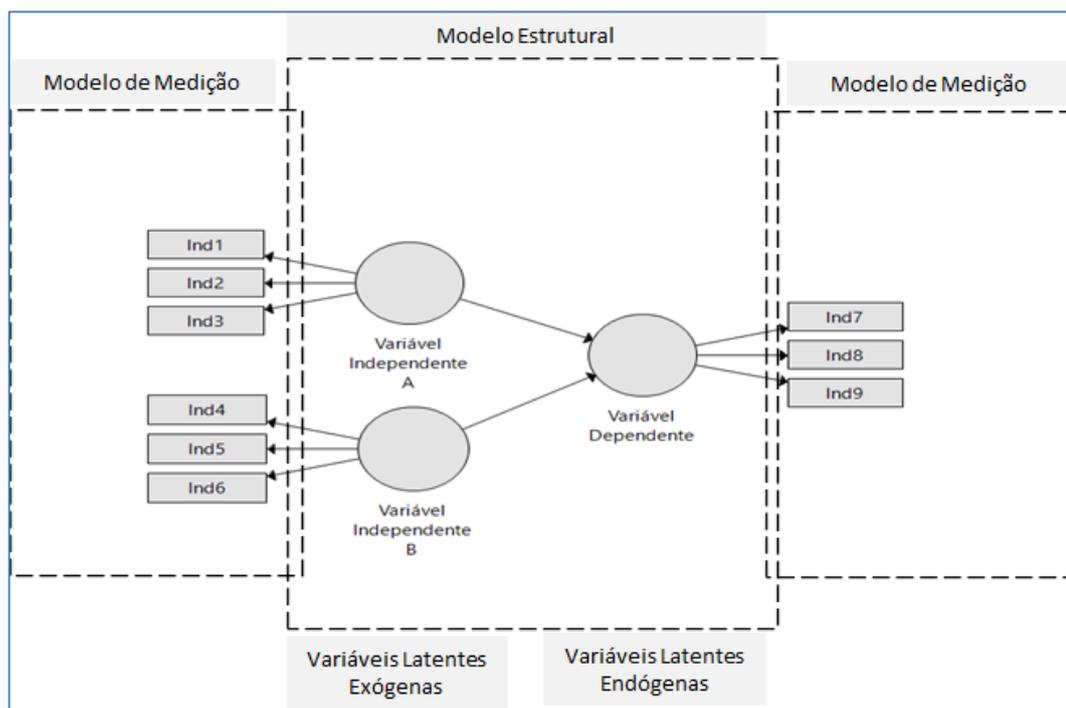


Figura 1 - Exemplo de modelo de trajetórias SEM

Embora a inicial aplicação do método SEM adotou a abordagem baseada em covariância (CB-SEM), pesquisadores também podem escolher a técnica de mínimos quadrados parciais, baseado na variância (PLS-SEM). A abordagem PLS-SEM (*Partial Least Square SEM*) é uma abordagem de modelagem causal que visa maximizar a explicação da variância dos constructos (variáveis) latentes dependentes. Essa abordagem é distinta do objetivo primário da CB-SEM qual seja de reproduzir a matriz de covariância teórica, sem manter o foco na variância explicada. Originalmente desenvolvido pelo economista sueco Herman Wold (WOLD, 1975), o PLS-SEM é uma técnica baseada em uma abordagem iterativa que maximiza a variância explicada de constructos ou variáveis latentes endógenas. Para isto, estima os parâmetros de um conjunto de equações em um modelo de equações estruturais combinando análise de componentes principais com análise de trajetória (*path analysis*) baseada em regressão (WOLD, 1975, 1980). Um dos principais motivos da atratividade do PLS-SEM é que o método permite aos pesquisadores estimar modelos muito complexos com muitos constructos e variáveis indicadoras, especialmente quando a predição é o objetivo da análise. Além disso, o PLS-SEM geralmente permite mais flexibilidade em termos de requisitos de dados e a especificação de relacionamentos entre constructos e variáveis indicadoras. Outro motivo é a acessibilidade de softwares com interface gráfica tais como o SmartPLS® (RINGLE; WENDE; BECKER, 2015) e o WarpPLS® (KOCK, 2020a), que facilitam os cálculos para o pesquisador.

Portanto, esta tese propõe um modelo preditivo da Aprendizagem em Engenharia medida pelos graus de desempenho de alunos em uma IES específica, a partir do nível de AA observado em sala de aula (aderência), com e sem aprendizagem ativa. Para isto, utilizou-se de um protocolo de observação em sala de aula e uma vertente de segunda geração da SEM - a PLS-SEM (Modelagem de Equações Estruturais por Mínimos Quadrados Parciais) para modelagem. Espera-se que os resultados contribuam para o desenvolvimento da aprendizagem ativa na Educação em Engenharia em busca de um melhor desempenho acadêmico e os pesquisadores possam usar os resultados deste estudo como base para iniciar outros estudos relacionados nesta área do conhecimento. A fundamentação teórica e a sistemática metodológica apresentadas possibilitaram delinear experimentos para medir, analisar e demonstrar as associações entre os constructos latentes, as variáveis manifestas relevantes e seus efeitos.

1.2. Delimitações da pesquisa

1.2.1. Objeto de estudo

A escolha da Instituição de Ensino Superior (IES) levou em conta a existência de um número representativo de cursos de Engenharia e na qual se pudesse planejar os experimentos em uma amostragem o mais representativa possível de aulas e disciplinas dos diversos cursos. Além disto, elencou-se uma equipe de professores que desejasse aprender novos métodos e participar da pesquisa, tendo suas aulas filmadas e gravadas. Uma IES particular da região sul de Minas Gerais globalmente conhecida como INATEL - Instituto Nacional de Telecomunicações foi abordada e sua diretoria concordou em apoiar o projeto, sendo essa IES o alvo desse estudo (participante). A IES é relevante na sua área de atuação em Engenharia e alta tecnologia, com 56 anos de existência (no momento da defesa desta tese) e possui 7 cursos de Engenharia (Produção, Computação, Controle e Automação, Telecomunicações, Elétrica, Software e Biomédica). Com foco apenas nas aulas teóricas, onde técnicas de aprendizagem ativa pudessem ser pela primeira vez experimentadas, um total de (6) classes ou turmas, em cinco (5) disciplinas para as quais os experimentos pudessem ser ampliados nos semestres seguintes, foram selecionadas. Uma 6ª. disciplina foi elencada, mas houve dificuldades operacionais para execução do plano experimental no 1S2019 e as filmagens foram replanejadas e reiniciadas no 1S2020. No entanto, devido ao evento da pandemia de COVID-19, o processo foi interrompido e a disciplina foi retirada da amostra.

As disciplinas englobaram áreas do grupo STEM, quais sejam Ciências, Tecnologia, Matemática e Engenharia, abordando duas dimensões de abrangência: 1) a primeira, intraclasse, dentro do semestre com medições nos mesmos sujeitos (aulas e alunos) de forma a prover mais poder estatístico para as comparações de médias e; 2) a segunda, interclasse, com medições em sujeitos independentes em turmas de semestres subsequentes para a etapa de modelagem. As disciplinas foram ministradas por cinco (5) professores experientes, dos quais 2 com pós-doutorado, 1 com doutorado, 1 com mestrado e 1 especialista. Os cursos de Engenharia oferecidos por esta IES no período da pesquisa possuem, em média, um total de 4000 horas de carga horária mínima, sendo que 1941,4 horas são aulas teóricas ministradas em 10 semestres. As 6 classes (turmas) amostradas inicialmente na dimensão intraclasse, com cargas horárias teóricas variando de 40 horas-aula a 80 horas-aula por semestre, somaram 296 horas-aula, o que corresponde a uma amostra para observações igual a aproximadamente 14% da média total

de horas-aula de um curso de engenharia nesta IES. Na dimensão interclasse, quatro disciplinas foram mantidas, somando 184 horas-aulas ou 9% da carga teórica. Assim, o objeto de estudo da pesquisa incorpora as aulas ministradas e as notas parciais das disciplinas supra mencionadas, exclusivas da IES selecionada, tal que permitissem analisar as relações de causa e efeito entre o nível de aderência à AA e a Aprendizagem.

1.2.2. Limitações

As consideráveis assimetria e curtose das distribuições de frequência das variáveis manifestas do modelo de medição reduziram a possibilidade de uso de ferramentas estatísticas paramétricas com maior poder de estimação na modelagem. Associado a este fato, o tamanho amostral e o resultante poder dos testes estatísticos e do modelo de equações estruturais foi outra questão relevante. Diversas fontes com diferentes recomendações sobre o tamanho amostral foram apresentadas, com foco no número de observações realizadas para a modelagem PLS-SEM. A obtenção das amostras de aulas para esse estudo buscou atender tais premissas utilizando a técnica de amostra por *cluster*, mas foi limitada pela disponibilidade de tempo (os cursos são semestrais) e recursos (disponibilidade de cursos e professores, filmagens, técnicos, etc.). A formatação das observações em planilhas especiais para atender os requisitos dos softwares de modelagem permitiu compor arranjos de dados onde os critérios mínimos foram atendidos (MIKESKA et al., 2019). Nesta tese, os **arranjos** são definidos como formas de construir as matrizes de dados adequadas para a interpretação dos softwares de apoio, utilizando alternativas de indicadores quais sejam individuais, médias globais ou médias de subgrupos, além do tratamento de valores ausentes, em busca de maior qualidade no modelo final a ser proposto. No entanto, as análises de heterogeneidade, que utilizam segmentação dos dados, resultam em subamostras de menor tamanho de possíveis subgrupos, as quais podem não atender todas as premissas para os diversos testes e avaliações.

Por fim, mesmo com todo o esforço e dedicação empenhados na pesquisa desta tese, não se pretende sugerir técnicas e modelos que respondam a todas as abordagens de Aprendizagem Ativa na Educação em Engenharia e sua relação com o desempenho dos alunos. Não se almeja reduzir a complexidade de uma sala de aula a uma tabela de indicadores e um modelo único de equações estruturais, mas prover uma proposta inovadora no seu escopo específico da EE. Ainda que com limitações e lacunas, buscou-se inspirar outros pesquisadores dessa área a

avançar rumo a novas pesquisas que possibilitem a melhoria da qualidade da Educação em Engenharia no Brasil. O estudo limita-se a agregar valor para a extensão da teoria e do estado da arte na busca de melhor desempenho acadêmico associado à aprendizagem ativa na Educação em Engenharia e à eficácia das técnicas instrucionais utilizadas.

1.3. Justificativas

Esta seção apresenta as motivações para esta pesquisa e a problematização, gerando as perguntas de pesquisa a serem respondidas e as hipóteses a serem avaliadas.

1.3.1. Originalidade

De forma inovadora, esta tese pretende demonstrar através de um modelo matemático preditivo a obtenção de alvos de aprendizagem (desempenho dos alunos) medidos pelas notas, a partir de níveis de atividade dentro das salas de aula (aderência às técnicas de AA) medidos por um instrumento de observação, utilizando-se de experimentos controlados para avaliar o efeito das metodologias de AA sobre a aprendizagem. A abordagem científica se baseia em pesquisa experimental com uma rígida sistemática metodológica e em métodos estatísticos pertinentes, tais como experimentos com medidas pareadas e modelagem de equações estruturais PLS-SEM. A sistemática metodológica e os resultados são as principais contribuições desta pesquisa para a literatura e para discussão latente da eficácia de métodos ativos de aprendizagem na Educação em Engenharia.

Outros trabalhos associados ao tema da pesquisa foram buscados para validar o quesito de originalidade. A Tabela 1 reporta da esquerda para a direita o número de artigos por base de pesquisa, mostrando a escassez de trabalhos em temas mais avançados que utilizam algum tipo de modelagem SEM nos temas de aprendizagem ativa em Engenharia. O software MS Excel® foi utilizado para tabular os dados sobre as publicações, sem limite de datas e tipos.

Tabela 1 - Publicações por base de dados e critério de busca

Research Database	Classroom Observation	AND Protocol or Instrument	AND Active or Inquiry-based Learning	AND Engineering	AND Structural Equation Modeling (SEM)	AND Learning Model or Prediction	AND PLS or Path Analysis
ACS Publications	32	13	6	3	0	0	0
Cambridge - iDiscover	13811	773	226	110	5	0	0
DOAJ	250	8	4	1	0	0	0
Emerald Insight	647	159	16	6	0	0	0
ERIC	4916	241	10	2	0	0	0
Gale Academic Onefile	6673	937	122	64	1	1	0
IEEE Explore	32	5	3	2	0	0	0
Inforns	4	2	0	0	0	0	0
JSTOR - Journal Storage	3760	365	41	20	1	0	0
Mendeley	2419	131	23	12	0	0	0
PsychInfo	7	2	1	0	0	0	0
PubPsych	327	13	0	0	0	0	0
Scielo	34	4	0	0	0	0	0
Google Scholar	92600	40900	9870	3580	11	8	1
Science Direct	1759	817	55	7	1	1	1
Science Open	359	14	6	5	1	0	0
Scopus	8431	2095	132	127	10	0	0
Springer Link	15	8	1	0	0	0	0
Bases CAPES	10308	1373	165	79	3	0	0
Wiley Online Library	2070	1185	95	48	8	0	0

As publicações no tema, já aplicados os critérios de seleção dos protocolos e com a modelagem por equações estruturais (SEM) associada, somam 41 trabalhos. Contudo, nenhuma fonte envolveu a modelagem da Aprendizagem através de Aderência à AA medida por protocolos de observação e utilizando PLS-SEM aplicados à Educação em Engenharia. Assim, no enfoque específico dessa pesquisa, não foram encontradas referências de trabalhos brasileiros ou internacionais publicados. As duas fontes destacadas em células hachuradas na última coluna à direita da Tabela 1, após o último filtro que associou Modelagem de Equações Estruturais à aprendizagem ativa em EE/STEM, são dois artigos, um acessado no Google Scholar e outro no Science Direct. Os autores são, respectivamente, (BORDA *et al.*, 2020; CAMPBELL *et al.*, 2017).

Borda *et al.* (2020) utilizaram-se do método *Survey* em um programa de desenvolvimento de professores com o objetivo final de melhorar o aprendizado dos alunos em cursos de Ciência,

Tecnologia, Engenharia e Matemática (STEM) com pedagogias inclusivas e centradas no aluno. Os dados da pesquisa foram combinados com os dados dos vídeos da sala de aula, entrevistas do corpo docente e questionários de estudantes. As fontes de dados foram combinadas para gerar quatro temas gerais para caracterizar o projeto e orientar projetos futuros. Os relacionamentos foram analisados utilizando a técnica de Modelagem de Equações Estruturais, sendo uma abordagem inovadora, mas distinta dos alvos perseguidos nesta tese. Campbell *et al.* (2017) utilizaram avaliadores externos para entender padrões de práticas pedagógicas incorporados em grupos heterogêneos de cursos, obtendo dados quantitativos de 587 cursos em nove instituições, para entender os padrões de práticas de ensino. Apesar da abordagem do aspecto latente das salas de aula, o estudo utilizou “clusters” para agrupar os padrões observados tais como aprendizagem ativa, palestras tradicionais e palestras ativas, entre outras. Mas a menção ao SEM só foi identificada na bibliografia, o que fez o artigo ser selecionado pelos mecanismos de busca, indicando, portanto, um tema comum, mas nenhuma relação direta com o alvo dessa tese.

1.3.2. Lacunas e Perguntas de Pesquisa

A partir da análise sobre a literatura disponível nas bases pesquisadas, o Quadro 1 ilustra algumas das lacunas não preenchidas em outros trabalhos.

Quadro 1 - Aspectos e Lacunas da literatura

Aspecto	Lacuna
Aprendizagem	A Aprendizagem é comumente associada aos graus de desempenho, mas falta uma abordagem estatística que a considere como uma variável latente associada numa relação de causa e efeito com as técnicas de aprendizagem ativa, observadas em salas de aula de cursos em Engenharia.
Protocolos de observação	Os dados qualitativos ou quantitativos dos protocolos de observação em sala de aula não são abordados como indicadores reflexivos ou formativos de modelos de equações estruturais. Dados internos de salas de aula são alternativamente coletados por pesquisas subjetivas com alunos e professores.
Avaliação de cursos e instituições	Falta uma metodologia de avaliação e orientação em cursos superiores de Engenharia considerando a eficácia do uso de metodologias ativas em relação aos graus de desempenho.
Metas objetivas de aprendizagem	Não há um modelo que permita estimar uma meta de aprendizagem e prever o quanto de AA e qual tipo de AA é possível implementar para atingi-la na Educação em Engenharia.

Mesmo não pretendendo preencher todas as lacunas plenamente, esta tese busca atender um alvo original, ou seja, explorar estatisticamente os experimentos nas aulas da IES participante, analisando as relações de causa e efeito entre os níveis de ocupação do tempo de aula medidos através da observação e os graus de desempenho dos alunos, com e sem os métodos ativos.

As seguintes perguntas de pesquisa (PP) são propostas:

- 1) A implementação de uma ou mais técnicas de aprendizagem ativa nos cursos de Engenharia da Instituição de Ensino Superior (IES) participante, melhorou o desempenho acadêmico dos alunos comparado com o desempenho a partir dos métodos tradicionais?
- 2) É possível obter um modelo com desempenho preditivo adequado para a Aprendizagem (medida pelas notas dos alunos), a partir de um nível de aderência à AA (medido pelos protocolos de observação), numa relação de causa-efeito?
- 3) Quais técnicas de aprendizagem ativa funcionaram e/ou funcionariam melhor de forma a aumentar a confiança na predição do modelo e em qual perfil de aulas ou grupos de disciplinas elas são recomendadas?

1.3.3. Hipóteses associadas

As hipóteses de pesquisas permitem testar a realidade e minimizam eventuais distorções causadas por preferências do pesquisador. A comprovação ou rejeição embasam-se em resultados advindos de dados e evidências (MARTINS; THEÓPHILO, 2009). As hipóteses associadas às perguntas 1 e 2, que tratam de abordagem quantitativa, bem como os critérios de teste são:

H1.1: O desempenho acadêmico na IES participante melhorou no nível global após a implementação de técnicas ativas de aprendizagem.

Para testar esta hipótese do desempenho global um experimento de medidas pareadas, com os mesmos sujeitos para maximização do poder estatístico, será utilizado. O teste estatístico para esta hipótese é o teste *t*-pareado.

H1.2: O desempenho acadêmico na IES participante melhorou no nível das disciplinas após a implementação de técnicas ativas de aprendizagem.

Para testar estas hipóteses individuais, o mesmo experimento de medidas pareadas, com os mesmos sujeitos para maximização do poder estatístico, será utilizado. No entanto o tamanho das amostras e os graus de desempenho são individuais, por disciplina. O teste estatístico para esta hipótese é o teste *t*-pareado.

H2: A Aprendizagem como variável dependente da variável preditora, qual seja o nível de aderência à AA, em uma relação positiva de causa-efeito, pode ser prevista em um modelo com poder preditivo significativo usando técnicas de PLS-SEM.

Para testar esta hipótese da relação causal, os constructos relativos à Aprendizagem e à Aderência à AA serão operacionalizados por duas variáveis latentes medidas por indicadores de desempenho (notas) e níveis de ocupação do tempo de aula (protocolo de observação). Esta configuração permitirá especificar e testar um modelo de equações estruturais PLS-SEM com foco no poder preditivo e validá-lo de acordo com as melhores práticas da literatura. Neste caso de análise multivariável, a estimação de pesos externos, cargas fatoriais externas, coeficientes de trajetória e parâmetros de localização do modelo será obtida através de algoritmos que utilizam por exemplo cálculos simultâneos de correlação e regressão.

1.4. Objetivos

1.4.1. Objetivo geral

O objetivo geral desta tese é propor um modelo matemático preditivo que permite buscar alvos de aprendizagem (desempenho dos alunos) medidos pelas notas, a partir de níveis de atividade dentro das salas de aula (aderência às técnicas de AA) medidos por um instrumento de observação, utilizando-se de experimentos controlados para avaliar o efeito das metodologias de AA sobre a aprendizagem.

1.4.2. Objetivos específicos

- Propor um protocolo de observação para Engenharia no ambiente de aprendizagem ativa a partir da adaptação das alternativas pertinentes, válidas e confiáveis disponíveis em ampla revisão da literatura.
- Identificação das técnicas mais eficazes para cada curso e/ou disciplina dentro dos cursos de engenharia, em especial voltadas ao escopo de STEM.
- Apresentar uma aplicação inovadora de projetos experimentais com amostras pareadas e alto poder estatístico.
- Apresentar uma rígida sistemática metodológica que permita replicar o experimento em outras IES de Engenharia.
- Utilizar a vertente PLS-SEM para criar experimentos, especificar modelos e modelar constructos típicos da área de Educação em Engenharia (EE)

O resultado final deve disponibilizar uma ferramenta eficaz para analisar cursos e instituições e criar referências de comparação dentro dos cursos, entre cursos e entre instituições de ensino, bem como recomendar níveis de AA e estratégias de AA, baseados em um modelo preditivo de aprendizagem.

1.5. Estrutura da tese

Este documento está dividido em cinco capítulos. O Capítulo 1 apresenta uma introdução do trabalho a partir do contexto, justificativas e objetivos relacionados às perguntas de pesquisa. Descreve também as hipóteses, o objeto de pesquisa e as limitações ao mesmo tempo que informa e explica a estrutura do texto da tese, proporcionando uma visão geral do que foi realizado ao longo da pesquisa. A fundamentação teórica é mostrada no Capítulo 2, abordando as técnicas ativas de aprendizagem em Engenharia, os protocolos de observação em sala de aula e a metodologia PLS-SEM, além de outras referências teóricas complementares. No Capítulo 3 é mostrada a classificação desta pesquisa científica, o método e também os detalhes da condução sistemática dos experimentos, utilizando o método escolhido para o trabalho. O Capítulo 4 traz resultados obtidos pelo pesquisador e seu orientador e as discussões sobre seus efeitos e contribuições para a literatura. No Capítulo 5, são apresentadas a Conclusão e as Recomendações para futuros trabalhos.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Critérios de inclusão e abrangência da bibliografia

Para obter as fontes bibliográficas que apresentassem a fundamentação teórica necessária, três pilares da pesquisa foram abordados: 1) a aprendizagem ativa e suas aplicações na Educação em Engenharia; 2) os protocolos de observação em sala de aula e suas aplicações em ambientes de aprendizagem ativa e; 3) a modelagem de equações estruturais por mínimos quadrados parciais (PLS-SEM) e suas aplicações gerais a específicas em áreas sociais e humanas, incluindo educação superior. Para atingir o objetivo de maior abrangência nas pesquisas em bases de dados acadêmicos, foram utilizadas palavras e expressões-chave. Tais termos incluíram nomes das técnicas de aprendizagem ativa, elementos e eventos de protocolos de observação em sala de aula em ambientes ativos e outros relacionados à modelagem de equações estruturais em suas diversas abordagens estatísticas. Foram acessadas até 19 bases de dados tais como *ACS Publications, Cambridge – iDiscover, DOAJ, Emerald Insight, ERIC, Gale Academic Onefile, IEEE Explore, Informa, JSTOR - Journal Storage, Mendeley, PsychInfo, PubPsych, Scielo, Google Scholar, Science Direct, Science Open, Springer Link, Bases CAPES (bases Scopus, etc.), Wiley Online Library*. Como critério, todos os tipos de documentos (por exemplo, artigos de periódicos, livros, capítulos de livros, dissertações e teses, artigos de conferências, estudos de caso, etc.) nos idiomas inglês, espanhol ou português foram considerados.

Ao final do processo de qualificação, um conjunto de 48 fontes principais foi selecionado para fundamentar a teoria de aprendizagem ativa. Ainda, 44 fontes com diversas aplicações foram selecionadas para estudo aprofundado dos protocolos de observação, sendo 40 delas associadas ao ambiente de aprendizagem ativa na EE ou EE alavancado por STEM. No pilar da Modelagem de Equações Estruturais (SEM) e na abordagem PLS-SEM uma base inicial de 41 artigos foram lidos e através da citação cruzada, a abrangência das fontes cresceu de forma relevante para 89 fontes que serviram de base para a fundamentação teórica neste tema. Os dados coletados no processo de pesquisa foram completamente registrados em planilhas do MS®Excel. Os arquivos reais formatados em Adobe Acrobat® .pdf foram adicionados ao conjunto de dados e gerenciados pelo pacote de software Mendeley®.

2.2. Técnicas de Aprendizagem Ativa

A base científica para o que chamamos de aprendizagem ativa repousa na teoria construtivista, a qual propõe que o sujeito constrói o conhecimento e aprende através da interação com o meio. As diversas formas de aprendizagem ativa possuem princípios muito semelhantes às teorias de Ausubel, Bruner, Dewey, Piaget, Rogers, entre outros (DOCHY *et al.*, 2003). A pedagogia dos métodos ativos é cientificamente bem enquadrada na crença fundamental que o aprendizado mais efetivo necessita de envolvimento ativo do aluno, uso do conhecimento baseado no contexto e propósito básico bem definido.

O que é a aprendizagem ativa (AA)? Até o presente, a maioria dos educadores ainda confia mais na compreensão intuitiva do que definições exatas de AA. Apesar da ausência de formulação explícita, existe uma ampla gama de descrições geralmente aceitas de características típicas de AA. Nesse contexto, adaptado de diversos autores, AA é entendida como:

- Qualquer coisa que envolva os alunos a fazer as coisas e pensar sobre as coisas que eles estão fazendo (BONWELL; EISON, 1991). Essa descrição pode ser ampliada, fornecendo uma lista explícita do que os alunos fazem;
- Aprendizagem ativa envolve o fornecimento de oportunidades para os alunos, de forma significativa, falar e ouvir, escrever, ler e refletir sobre o conteúdo, ideias, questões e preocupações de um assunto acadêmico (MEYERS; JONES, 1993);
- A aprendizagem ativa visa aumentar a participação dos alunos, ou aumentar a interatividade, com o propósito de afetar positivamente a aprendizagem e as atitudes dos alunos (GORDON *et al.*, 2015);
- A Aprendizagem ativa pode ser definida como qualquer atividade relacionada ao curso na qual todos os alunos em uma classe são chamados a praticar, fazer ao invés de simplesmente assistir, ouvir o professor e fazer anotações (FELDER; BRENT, 2016).
- Aprendizagem Ativa é um termo que enquadra um conjunto de abordagens que visam envolver os estudantes no processo de ensino e de aprendizagem, a partir de experiências significativas que permitam aos estudantes compreender a relevância do que aprendem e para quê. Um ambiente de aprendizagem ativa é, assim, caracterizado pelo envolvimento do estudante, através do seu entusiasmo, ação e reflexão sobre o seu próprio processo de aprendizagem (LIMA; MESQUITA, 2021).

De acordo com essas definições, perguntas retóricas (estimular a reflexão do indivíduo) feitas durante a palestra ou perguntas respondidas por vários alunos em primeira mão não podem ser consideradas como AA.

Villarini (2004) afirma que aprendizagem ativa possui as seguintes características:

- É significativa para o aluno (motivação);
- O aluno está ativo e reflexivo;
- Requer colaboração mútua entre os alunos;
- Está associada ao mundo real, ou seja, ajuda a desenvolver competências ou habilidades cognitivas superiores que permanecem mesmo com o passar do tempo.

A aplicação das metodologias ativas busca atingir patamares mais altos na taxonomia dos objetivos de aprendizagem (BLOOM, 1956), cujo modelo é mostrado na Figura 2:

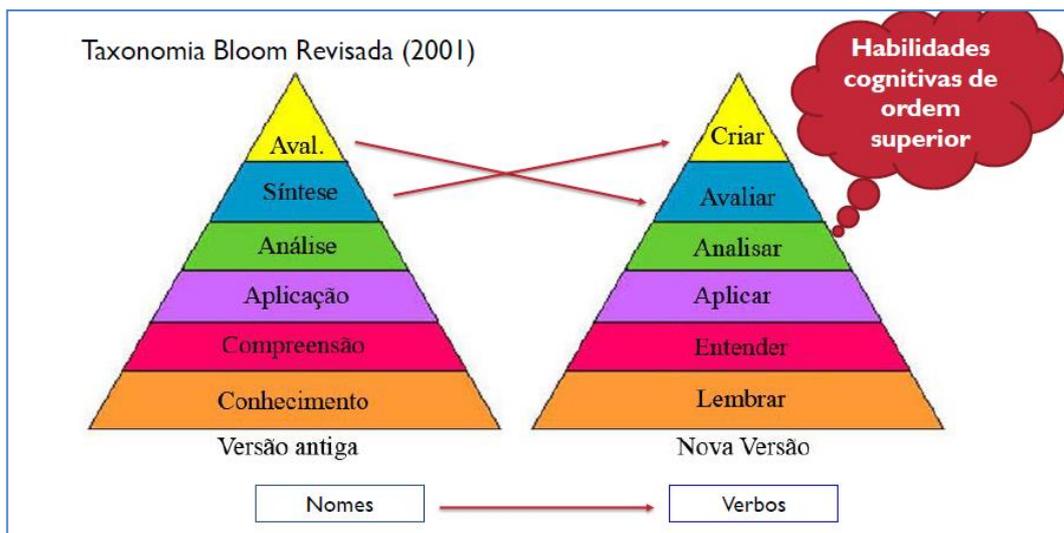


Figura 2 - Taxonomia de Bloom

As habilidades no domínio cognitivo tratam de conhecimento, compreensão e o pensar sobre um problema ou fato. Habilidades + Conhecimentos + Atitudes = Competências. A AA ajuda a focar no desenvolvimento de competências ao invés de apenas em conteúdo. Os objetivos de aprendizagem de Bloom foram assim definidos objetivamente:

- Lembrar: memorizar fatos específicos, padrões de procedimento e conceitos.

- Entender: imprimir significado, traduzir, interpretar problemas, instruções e os extrapolar.
- Aplicar: utilizar o aprendizado em novas situações.
- Analisar: dividir em partes, identificar elementos, relações e princípios de organização.
- Avaliar: estabelecer padrões e realizar julgamentos com base em critérios defensáveis.
- Criar: Articular as partes num todo.

O termo “competência” associado ao modelo de Bloom tem sido amplamente discutido na literatura e sua aplicação no campo da Educação em Engenharia tem englobado a visão global do engenheiro competente, por exemplo a) Em Walther *et al.* (2011), os autores pesquisaram as influências que contribuem para a formação profissional de estudantes de engenharia e as competências resultantes; b) Em Klein-Gardner e Walker (2011), os autores definem a competência do engenheiro em várias dimensões tais como 1) capacidade e estilo de comunicação; 2) conhecimento da cultura, costumes, comportamento social e padrão de pensamento de grupos; 3) conhecimento de tecnologia, sistema de educação e prática comercial; 4) capacidade de trabalhar em projetos com equipes multiculturais presencialmente e à distância; e 5) integrar-se a este universo diverso e amplo. Segundo Borrego e Bernhard (2011), as pesquisas em educação em engenharia tem se ampliado como um campo de investigação conectado internacionalmente, com o objetivo de melhorar a preparação e o treinamento de engenheiros, sendo fundamental para resolver os principais desafios de engenharia na atualidade, em diversos ramos de conhecimento.

Pesquisas realizadas para determinar em quais tipos de atividades de aprendizagem alunos de um curso de engenharia de uma universidade americana absorveriam mais conhecimentos, através de testes e escores controlados, mostraram que os melhores resultados se deram nas atividades construtivistas e interativas, enquanto os piores, se deram nas atividades apenas ativas e puramente passivas (MENEKSE *et al.*, 2013). Muñoz *et al.* (2013) pesquisaram a aprendizagem ativa em um curso de computação de quatro anos na Escola de Engenharia da *Universidad Católica de la Santísima Concepción*, Chile e relataram a mudança do projeto do curso (currículo), adicionando novas disciplinas com pedagogia ativa. O resultado foi avaliado por pesquisas com os alunos e revelou melhora do seu grau de compreensão de seus desafios profissionais e de sua motivação, bem como satisfação ampliada com as metodologias de aprendizagem ativas. A rede informal *Active Learning in Engineering Education* (ALE) tem

promovido o uso da AA em Engenharia desde 2001, criando oportunidades para profissionais e pesquisadores de educação em engenharia aprenderem de forma colaborativa como promover a aprendizagem de estudantes de engenharia. O próprio termo AA foi discutido em um análise de artigos de um jornal europeu dedicado à educação em engenharia (*European Journal of Engineering Education*) e mostrou que as diferentes abordagens de AA estão alinhadas com as diferentes abordagens que foram encontradas nestes periódicos (LIMA; ANDERSSON; SAALMAN, 2017). Entretanto, mesmo com os benefícios potenciais, os instrutores relutam em mudar suas abordagens de ensino por vários motivos, incluindo o medo da resistência do aluno à aprendizagem ativa. Esta resistência foi estudada por Tharayil *et al.* (2018) e demonstrou que certas estratégias do instrutor podem influenciar positivamente as respostas dos alunos à aprendizagem ativa tais como as estratégias de explicação e facilitação. As estratégias de explicação consistem em: (a) explicar o propósito, (b) explicar as expectativas do curso e (c) explicar as expectativas da atividade. As estratégias de facilitação incluem: (a) abordar os não participantes, (b) assumir uma atitude encorajadora, (c) avaliar a participação, (d) andar pela sala, (e) fazer perguntas, (f) desenvolver uma rotina, (g) projetar atividades para participação e (h) usar etapas incrementais. Shekhar *et al.* (2015) desenvolveram um instrumento de observação em sala de aula especificamente voltado para observar as respostas dos alunos e os focos de resistência às metodologias de AA.

São diversas as metodologias ou técnicas utilizadas dentro da aprendizagem ativa. Pode-se destacar as mais conhecidas, a maioria delas adequadas para uso na Educação em Engenharia (EE), dentro do escopo deste trabalho, a partir das subseções seguintes.

2.2.1. Aprendizagem baseada em problemas - PBL (*Problem Based Learning*)

Segundo Tynjälä (1999), o *Problem-Based Learning* (PBL), como é conhecido mundialmente, é um método de ensino-aprendizagem caracterizado pela aplicação de problemas da vida real. O PBL instiga as habilidades de solução de problemas e a aquisição de conceitos fundamentais da área de conhecimento em questão, além do desenvolvimento do pensamento crítico. Junto com outras técnicas educacionais baseadas no construtivismo, o PBL busca responder a vários dilemas inseridos na educação profissional contemporânea. Dentre eles o aumento gradativo do volume de informações científicas e tecnológicas que devem ser transmitidos aos alunos durante a graduação ou a pós graduação e a sua rápida obsolescência proporcionada pela mesma

evolução. Ainda sobre a educação superior, o PBL parece satisfazer alguns aspectos que a literatura recomenda como uma formação que promova, além do domínio do conhecimento técnico, também o desenvolvimento de habilidades e atitudes profissionais e sociais, ou seja, que integre a teoria com a prática e a academia com o trabalho (GUIMARÃES; CERQUEIRA; NORONHA, 2016).

As pesquisas realizadas por Barron e Darling-hammond (2008) mostram que o PBL envolve essencialmente as seguintes situações:

- Estudantes assimilando conhecimentos para enfrentar problemas reais que seriam resolvidos no mundo real.
- Aumento do controle do próprio aluno sobre o seu aprendizado.
- Professores servindo como tutores e facilitadores da investigação e das reflexões sobre o problema.
- Estudantes usualmente, mas não sempre, trabalhando em pares ou grupos.

A teoria do PBL não é nova e a maioria dos estudos nesta revisão indicou que o PBL é uma metodologia potencial que aborda níveis mais altos de metas de aprendizado dos alunos e afeta positivamente suas percepções. De acordo com Boud e Feletti (1997) o PBL teve sua origem e evoluiu a partir de currículos inovadores em ciências da saúde, introduzidos na América do Norte por volta de 1970. Savery (2006) definiu o PBL como uma abordagem centrada no aluno que oferece aos alunos mais controle sobre a investigação que estão realizando. O PBL é capaz de integrar teoria, prática, conhecimento e habilidades, permitindo que os alunos encontrem uma solução viável para uma situação problemática. Hmelo-silver (2004) descreveu o PBL como um método baseado em estudantes que aprendem através da resolução de problemas complexos que não têm uma única resposta correta. Os alunos trabalham em grupos colaborativos e identificam o que precisam aprender para resolver um problema, promovendo o aprendizado autodirigido. Há a aplicação de novos conhecimentos e a reflexão sobre o processo, alinhados aos objetivos de aprendizagem comuns em cursos diversos, tais como os de Engenharia, alinhados com futuros papéis profissionais. Outras características do PBL também estão bem alinhadas com as demandas globais da EE (GUIMARÃES; CERQUEIRA; NORONHA, 2016), tais como:

- o aluno procura oportunidades para adquirir conhecimento organizando seu tempo;

- o aluno é encorajado a discutir suas dificuldades com as pessoas envolvidas na disseminação do conhecimento e com outras pessoas quando necessário;
- o instrutor deixa de ser o transmissor do conhecimento e começa a orientar e motivar os alunos a descobrir o conhecimento como ator principal.

De acordo com Barrows (1986) e Norman and Schmidt (1992), o PBL promove vários objetivos de aprendizagem. Ele ajuda os alunos a construir uma base de conhecimento extensa e flexível, desenvolver habilidades efetivas de resolução de problemas, tornar-se colaboradores efetivos, desenvolver habilidades de aprendizado autodirigidas e motivar-se intrinsecamente para aprender. Um típico ciclo de aprendizagem do PBL é (HMELO-SILVER, 2004):

1. Identificação do cenário do problema.
2. Definir o problema analisando os fatos decorrentes do cenário.
3. Formulação de hipóteses sobre possíveis soluções com o conhecimento existente.
4. Identifique novas necessidades de aprendizagem.
5. Realização da pesquisa em busca de novos conhecimentos, autodirigidos.
6. Aplicação de novas hipóteses geradoras de conhecimento e seleção da melhor solução.
7. Avaliação, abstração e reflexão sobre o processo de aprendizagem.

Na aplicação da técnica do PBL, os instrutores são mentores dos alunos, tornando-se participantes ativos no processo de ensino e educação (FRUCHTER, 1999). Conforme desejado pelos objetivos de aprendizagem do curso, a mudança do papel do instrutor faz com que os alunos aumentem o uso de ferramentas e técnicas para articular, refletir e desenvolver seus processos cognitivos (percepção, memória, aprendizado e consciência). Como metodologia ativa de aprendizado, o PBL é relativamente bem implantado em muitas disciplinas de Ciência, Tecnologia, Engenharia e Matemática (STEM), em geral (ZOLIN; FRUCHTER; LEVITT, 2003). Em uma aplicação específica de EE, o PBL foi associado às iniciativas de CDIO (*Conceive-Design-Implement-Operate*), quando os alunos cursaram a disciplina de Laboratórios de Engenharia I com a implementação da metodologia. Segundo os autores, os alunos obtiveram um conjunto de habilidades éticas, sociais e técnicas, como trabalho em equipe, pesquisa, comunicação inter e intragrupo e redação de relatórios, úteis para o restante do curso e seu futuro profissional (MAGALHAES *et al.*, 2018). O uso do PBL para soluções de problemas de média e alta complexidade por parte dos alunos os fazem trabalhar no

desenvolvimento de diferentes habilidades. O modelo de ensino se transforma em um modelo de aprendizado significativo e autônomo, no qual os alunos estão conscientes de seu compromisso com esse processo de aprendizado (LACUESTA; PALACIOS; FERNÁNDEZ, 2009). Um estudo sobre uma mudança de currículo, introduzindo o uso do PBL na disciplina Logística & Transporte, parte do curso de engenharia de produção da UNIFEI, apresentou todas as etapas de projeto e implementação do método e das aulas, bem com uma pesquisa válida e confiável em duas fases cobrindo os conceitos do curso e objetivos de aprendizagem modelados pela Análise Fatorial, e, indo além para fornecer o impacto do processo PBL e adaptações devido à pandemia COVID-19. Os resultados demonstraram uma percepção positiva da metodologia PBL para 91% dos alunos (GUIMARÃES; LIMA, 2021).

2.2.2. Aprendizagem baseada em Projetos - PjBL (*Project Based Learning*)

Esta metodologia de aprendizagem é uma abordagem educativa fundamentada nos processos de investigação (dos termos em inglês *enquiry* ou *inquiry*) para gerar produtos inovadores, sistemas e soluções. A Aprendizagem Baseada em Projetos (ABPj) tem uma base ampla e antiga originada nas ideias de John Dewey e William H. Kilpatrick, ambos do início do século XX. A ABPj utiliza os conceitos pedagógicos das técnicas de aprendizagem ativa para a elaboração de problemas apresentados na forma de projetos (GÓMEZ PUENTE; VAN EIJCK; JOCHEMS, 2011). Os autores desenvolveram um modelo com as dimensões e características relevantes na aplicação do PjBL no ensino da Engenharia, resumido a seguir.

- **Característica do Projeto:** Não há uma única solução e não são fornecidas especificações: a pesquisa e os questionamentos contribuirão para se chegar a uma especificação completamente desenvolvida pelos alunos, os quais devem buscar alternativas e soluções.
 - **Experimentação / experiências práticas:** Os alunos conduzem experimentos e aprendem a partir das repetições. A reflexão é encorajada com base na experiência.
 - **Ambientes de aprendizado autênticos e baseados na vida real:** O professor assume o papel de um cliente e, ao mesmo tempo, de um consultor. Já os alunos

são a equipe de projetos de uma empresa, gerenciando os processos como se fossem especialistas.

- Multidisciplinaridade: Integração do conteúdo com diferentes disciplinas.
- Métodos de avaliação:
 - Avaliação formativa: Apresentações ou relatórios semanais, pontos de checagem intermediários com base nas entregas parciais.
 - Avaliação somativa: Avaliação de pares e autoavaliação, envolvimento de representantes da indústria na avaliação, exames.
- Contexto Social: Aprendizagem colaborativa.
 - Trabalho em equipe, comunicação entre pares, motivação por meio da competição.
- Papel do professor: Treinamento em tarefa, processo e autoavaliação.
 - O professor deve desafiar os alunos fazendo perguntas e esclarecendo conceitos por meio de questionários online antes da aula, além de avaliar as entregas parciais e estimular a avaliação do processo e a autorreflexão.

Em uma análise bibliométrica abordando as aplicações de PjBL em EE Reis, Barbalho e Zanette (2017) destacaram os benefícios do uso da abordagem de projetos para o aprendizado em engenharia, mostrando uma maior absorção de conteúdo técnico pelos alunos e o desenvolvimento de habilidades multidisciplinares. A análise bibliométrica revelou os periódicos mais relevantes no assunto, autores e os artigos e palavras-chave mais citados. Em outra abordagem de PjBL aplicada à EE, avaliou-se as percepções dos alunos quanto à aplicação da metodologia. Neste estudo, os alunos apreciaram positivamente a experiência, com o aspecto da apresentação oral recebendo o menor índice de satisfação. Não houve diferença significativa nas classificações entre nenhum agrupamento demográfico, sugerindo que todos os alunos puderam participar e experimentar essencialmente da mesma maneira (PALMER; HALL, 2011). Aplicações mais recentes de PjBL em tópicos mais avançados, por exemplo em projetos de prototipagem em realidade virtual e 3D, demonstraram uma comunicação mais eficaz, aumento das habilidades de resolução de problemas e melhorou os resultados da aprendizagem (HALABI, 2020). A aplicação dos princípios da aprendizagem baseada em projetos em cursos engenharia, usando uma abordagem denominada PLE (*Project Led Education*) foi também discutida em Lima et al., (2007), Fernandes, Flores e Lima (2012) e Fernandes et al. (2014), onde os autores demonstraram através de pesquisas e grupos focais com os alunos, a importância

dada aos processos e resultados de aprendizagem, no contexto dos cursos de engenharia em questão.

De Graaff e Kolmos (2007) argumentam que há princípios básicos comuns entre o PjBL e PBL e que mesmo com as diferenças, as técnicas podem ser integradas. Os autores destacam que, na maioria dos casos, a distinção é baseada no entendimento de que a aprendizagem baseada em problemas é definida por problemas abertos e mal estruturados que fornecem um contexto para a aprendizagem. Em contraste, a aprendizagem baseada em projetos é interpretada em termos de uma atribuição ou tarefa que os alunos têm que atuar. Um projeto era definido como uma tarefa complexa que requer mais recursos do que uma única pessoa é capaz de entregar, o que implica que um projeto é mais do que apenas uma tarefa ou uma atribuição. Na verdade, os problemas complexos que desencadeiam o processo de aprendizagem no PjBL são mais autênticos do que a maioria dos casos artificiais usados em PBL. A questão é que não é apenas o "problema" que decide o processo de aprendizagem. Muito depende do contexto em que a atribuição é apresentada aos alunos.

2.2.3. Aprendizagem baseada em equipes - TBL (*Team Based Learning*)

Muitas técnicas utilizam o trabalho em equipes e o TBL traz uma configuração específica. Em um curso utilizando TBL, os alunos são organizados em grupos permanentes pelo período completo do curso. O conteúdo do curso é organizado em unidades principais tipicamente de 5 a 7. Antes de qualquer aula presencial os alunos devem estudar o material indicado porque a aula começa com um processo para medir e assegurar a preparação prévia dos alunos (RAP - *Readiness Assurance Process*) que é um teste curto, com as principais ideias do material estudado. Primeiro os alunos o completam individualmente e depois fazem o mesmo teste em equipe, buscando consenso nas respostas. Os alunos recebem imediato feedback no teste de equipe e tem a oportunidade de apelar em algum resultado divergente. Como passo final do RAP, há uma rápida e específica exposição pelo tutor buscando eliminar conceitos errados e esclarecer as apelações. Finalizado o RAP, a maior parte do tempo da aula é gasto em atividades e tarefas que requerem prática dos conceitos e conteúdo do curso (MICHAELSEN; SWEET, 2008). Algumas premissas do TBL foram incorporadas por outras metodologias, sendo que estudos apontaram o uso do TBL em EE associado a estas metodologias como por exemplo em (DOUGLAS; CHIU, 2013; KAVANAGH; CROSTHWAITE, 2007; REQUIES *et al.*, 2018).

2.2.4. Instrução por Pares (*Peer Instruction*) e Aula invertida

De acordo com Mazur (1997) e Mazur e Watkins (2009), o objetivo básico da Instrução por Pares (*Peer Instruction*) é explorar a interação entre os estudantes durante as aulas expositivas e focar a sua atenção nos conceitos. As aulas consistem de uma série de apresentações curtas sobre pontos chave do material de aula, cada uma seguida de um teste conceitual. Eles respondem individualmente em um certo tempo e depois é dado a eles mais tempo para discutir as respostas entre si, fazendo-os pensar nos argumentos que estão sendo desenvolvidos; e também dá a eles e ao professor um meio de avaliar a sua compreensão do conceito. O formato genérico seria:

- Proposição da questão.
- Tempo para os alunos pensarem.
- Alunos anotam sua resposta individual.
- Alunos discutem e convencem seus colegas (*peer instruction*).
- Alunos anotam respostas finais.
- Feedback para o professor: registro das respostas.
- Explicação pelo professor da resposta certa.

A metodologia *Peer Instruction* funciona de forma mais completa se adicionarmos uma técnica complementar da aprendizagem ativa que é chamada de ***Flipped Class (Aula invertida)***. Nesta técnica o material da aula é disponibilizado um período antes da aula em questão, suficiente para os alunos consultarem e estudarem. Normalmente acompanha um teste conceitual logo no início da aula para assegurar ao professor a visão correta de quanto os alunos entenderam e lhe permitir prosseguir a aula com ou sem explicações adicionais de cada ponto chave. A prática da aula invertida tem sido experimentada no ensino de engenharia e a literatura relatou maior satisfação e aumento do desempenho dos alunos comparado ao método tradicional, por exemplo em (PREVALLA; UZUNBOYLU, 2019). Um projeto longitudinal de métodos mistos foi empregado para medir a mudança de atitudes e a auto eficácia do alcance da educação em estudantes de engenharia através de instrução por pares e tanto os professores quanto os engenheiros descreveram qualitativamente os benefícios decorrentes do modelo de aprendizagem (FOGG-ROGERS; LEWIS; EDMONDS, 2017). Adicionalmente, o uso de tecnologia da informação tem possibilitado que o material e os testes sejam tratados eletronicamente e disponibilizados de forma virtual, de forma que o acesso seja online e as

respostas aos testes conceituais sejam através de aplicativos denominados *Clickers*, onde os alunos efetivamente teclam as respostas em dispositivos individuais, que podem até ser os próprios celulares, eletronicamente.

2.2.5. Ensino no tempo certo - JITT (*Just-in-Time Teaching*)

Esta metodologia foi criada pelo professor Gregory M. Novak e seus colaboradores com o objetivo de melhorar o ensino dentro da sala de aula usando a tecnologia (NOVAK, 1999). A essência do *Just-in-time Teaching* é o envolvimento ativo dos alunos, incentivando ao estudo prévio, buscando sempre informações sobre o próximo assunto que será discutido em sala, sempre instigando os alunos a estudar e pensar sobre o que estão estudando. Envia-se o material eletronicamente e perguntas breves sobre o assunto que será o discutido na próxima aula presencial, com um prazo estabelecido. Na aula presencial o professor apresenta o material preparado para aquela aula, coleta algumas respostas dos alunos de forma anônima e provoca um debate sobre as respostas apresentadas. O professor, dinamicamente, ajusta o enfoque das suas aulas baseado nas respostas dos alunos e pode também resolver os problemas de conceitos errados, promovendo a interação entre os alunos. Esta metodologia pode trabalhar complementada pela instrução por pares (*Peer Instruction*) ((MAZUR; WATKINS, 2009).

2.2.6. Caso de Ensino (Estudo de Caso)

Os casos de ensino costumam ser comumente utilizados nos programas de educação para administração e negócios, pois possibilitam que os estudantes aprendam por meio da aplicação e da adaptação dos conceitos teóricos às situações específicas descritas. Casos de ensino são uma descrição o mais próxima possível de uma situação real com objetivos de aprendizagem, comumente envolvendo um problema, uma decisão ou uma oportunidade vivenciada por um profissional, gerente ou executivo de uma organização (CHRISTENSEN; CARLILE, 2009). Através dos casos, o aluno pode vivenciar situações similares às que são encontradas nas organizações empresariais, ainda que sem correr os riscos e exposições que estão relacionados às decisões a serem tomadas no mundo real (WANG; WANG, 2011). Os estudos de caso também têm sido usados associados a outras técnicas, para narrar as experiências em

implementações de metodologias ativas diversas na EE (BARAK, 2013; TEIXEIRA *et al.*, 2015; VIJAYAN; MORK; GISKE, 2019).

2.2.7. Mapas Conceituais

A proposição dos *Conceptual Maps* (CM) ou mapas conceituais (MC) é formada por dois conceitos unidos por um termo de ligação que expressa claramente a relação conceitual, como mostra a Figura 3.

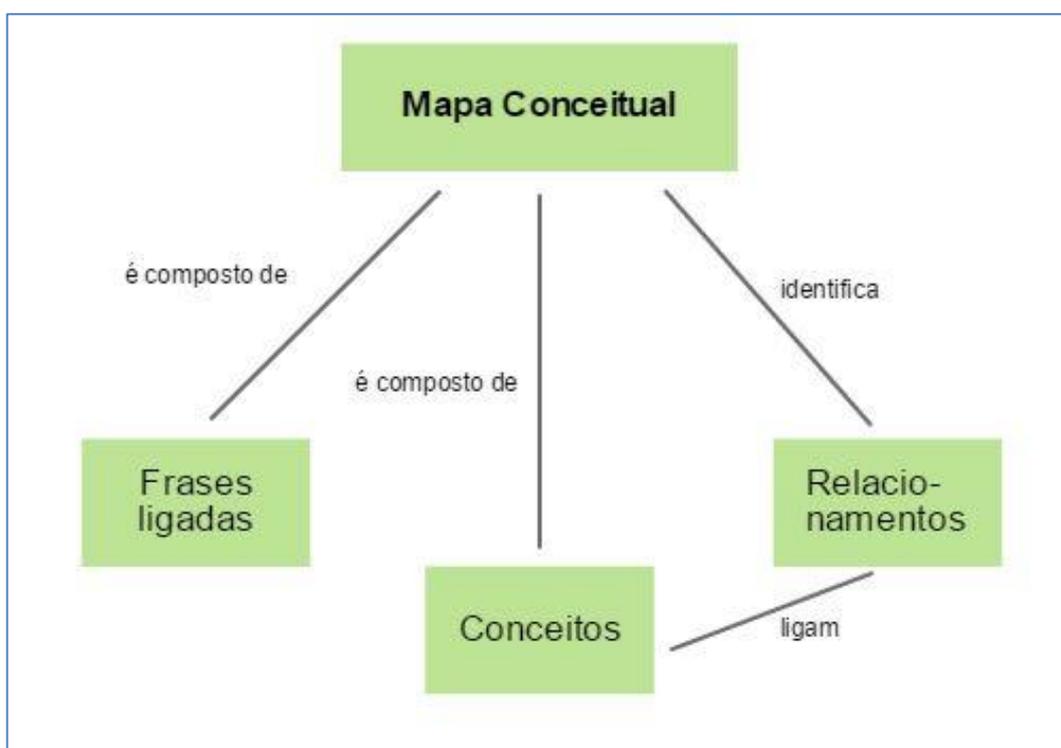


Figura 3 - Mapas Conceituais

Novak e Cañas (2006) propõem os seguintes passos para criação dos MC:

- 1) Identifique os conceitos pertinentes: Defina quais são os conceitos mais importantes sobre o tema. Selecione esses conceitos e faça uma lista. Esses conceitos devem ser compostos, preferencialmente, por uma única palavra (use, no máximo 2 ou 3 palavras para designar um conceito).

- 2) Ordene os conceitos selecionados: Organize a lista de conceitos do seu grupo colocando na parte superior da lista os conceitos mais amplos e gerais, deixando na parte inferior da lista os conceitos mais específicos.
- 3) Organize os conceitos do seu Mapa Conceitual (MC): Comece o seu MC colocando os conceitos mais gerais na parte superior.
- 4) Incorpore outros conceitos: Agora, selecione outros 2, 3 ou 4 sub-conceitos para adicionar embaixo dos conceitos gerais.
- 5) Ligue os conceitos com Conexões Explicativas: Faça linhas entre os conceitos unindo-os 2 a 2. Sobre essa linha escreva 1 ou poucas palavras que definam uma relação entre os conceitos. Essa conexão deve criar sentido, formando uma unidade semântica.
- 6) Revise e altere seu mapa: Esse momento é muito valioso, pois vai acelerar seu aprendizado: quanto mais você tentar melhorar seu mapa, mais você aprenderá sobre o assunto em questão.
- 7) Verifique possíveis ligações cruzadas: Após refletir sobre seu MC você pode achar importante ligar conceitos que estão em diferentes partes do mapa.
- 8) Incorpore exemplos específicos a alguns conceitos: Adicione exemplos específicos a alguns conceitos do seu mapa para que você consiga relacioná-lo com partes específicas do seu tema de interesse.
- 9) Entenda seu MC: É possível elaborar diferentes mapas para o mesmo conjunto de conceitos. Por isso, não se preocupe em buscar a “resposta certa”, pois ela não existe.
- 10) Identifique a pergunta que seu MC responde: Todo MC tenta responder uma pergunta (pergunta focal) por meio de proposições que relacionam conceitos.

Os mapas conceituais, também chamados de mapas mentais, foram apresentados juntamente com outras metodologias de aprendizagem ativa para melhorar as habilidades interpessoais e habilidades de aprendizagem ao longo da vida dos alunos de engenharia. Os benefícios foram demonstrados por uma grande melhoria em seus resultados acadêmicos, histórico de colocação e interesses em pesquisa (ASOK *et al.*, 2017). Outros estudos do uso de mapas conceituais aplicados na EE podem ser obtidos por exemplo em (ELLIS; RUDNITSKY; SILVERSTEIN, 2004; MARTÍNEZ *et al.*, 2013).

2.2.8. *Design Thinking*

Segundo Brown (2008) o *Design Thinking* é um modelo de pensamento. A técnica promove a crença que podemos fazer a diferença, desenvolvendo um processo intencional para chegar ao novo, a soluções criativas, e criar impacto positivo. Ele faz com que você acredite em sua própria criatividade e no propósito de transformar desafios em oportunidades. Serve para desenhar desde novos espaços, processos, sistemas e até novos currículos. O processo de design é o que coloca o *Design Thinking* em ação: É uma abordagem estruturada para gerar e aprimorar ideias.

Cinco fases ajudam em seu desenvolvimento, desde identificaram desafio até encontrar e construir a solução.

- 1) Descoberta: Entenda o desafio; prepare a pesquisa; reúna inspirações.
- 2) Interpretação: Conte histórias; procure por significados; estruture oportunidades.
- 3) Ideação: Gere ideias; refine ideias.
- 4) Experimentação: Faça protótipos; obtenha feedback.
- 5) Evolução: Acompanhe o aprendizado; Avance.

A experiência de exploração do pensamento criativo, como base para o uso do *Design Thinking* na EE pode ser exemplificada no estudo de (DOPPELT, 2009). Os resultados do estudo demonstraram vários níveis de habilidade de pensamento criativo e evidências para documentação de alto nível dos projetos foram encontradas nas avaliações dos alunos. Por outro lado, o autor identificou que havia um longo processo de aprendizagem quanto a documentação do trabalho em equipe e a autorreflexão dos alunos. Em um estudo transnacional aplicado na EE e empregando *Design Thinking*, um programa de inovação social foi bem-sucedido ao fornecer uma rica experiência de aprendizado aos estudantes de engenharia participantes no sudeste asiático, desenvolvendo suas habilidades de resolução de problemas e habilidades interpessoais (MATSUSHITA *et al.*, 2016).

2.2.9. POGIL - *Process Oriented Guided Inquiry Learning*

De acordo com Eberlein *et al.* (2008), POGIL ou Aprendizagem Orientada por Processos de Indagação Guiada, como o PBL, foi projetada para substituir palestras na sala de aula e, assim, envolver os alunos na discussão do material do curso, em vez de apenas ouvir sobre isso. Os alunos trabalham em equipes auto gerenciadas durante a aula em materiais especialmente projetados. Essas atividades consistem em uma série de perguntas cuidadosamente elaboradas (a “indagação guiada”) que geralmente seguem a abordagem de “ciclo de aprendizagem” de três fases, que inclui uma fase de exploração, uma fase de invenção conceitual e uma fase de aplicação. Na fase de “exploração”, os alunos examinam um “modelo”, procuram padrões dentro dele e tentam extrair significado dele. O modelo consiste em qualquer combinação de imagens, tabelas, equações, gráficos, textos em prosa ou outros tipos de informação. Muitas vezes, as perguntas levam os alunos a testar hipóteses ou explicar os padrões e relacionamentos encontrados no modelo.

Em seguida, na fase de “invenção de conceito” (ou “introdução de termo”), surge um conceito ou relacionamento específico e um termo pode ser introduzido para descrever o conceito ou relacionamento recentemente desenvolvido. Alternativamente, em vez de ser inventado, o conceito pode ser mais desenvolvido ou generalizado durante essa fase. Nesse caso, a fase é chamada de “formação de conceito” em vez de “invenção conceitual”. Por fim, a fase de “aplicação” dá aos alunos a oportunidade de estender e aplicar o conceito a novas situações, aumentando sua compreensão do conceito. A sequência de perguntas nos materiais do POGIL é cuidadosamente planejada para ajudar os alunos a progredir adequadamente durante as fases, guiá-los em direção a conclusões apropriadas e desenvolver as habilidades desejadas no processo, como resolução de problemas, raciocínio dedutivo, comunicação e autoavaliação. Exemplos de materiais POGIL podem ser encontrados no site POGIL (<https://www.pogil.org>).

No POGIL, o instrutor serve como um facilitador para ajudar os grupos no processo de aprendizagem e não responde a perguntas que os alunos devem ser capazes de responder por conta própria. Aos alunos são atribuídos papéis específicos, como gerente, gravador, refletor, técnico e apresentador. A facilitação planejada pelo instrutor e os papéis que os alunos desempenham permitem o desenvolvimento de habilidades de processo além do que é abordado dentro da própria atividade. De certa forma, isso é semelhante à abordagem de aprendizagem

baseada em equipe (TBL). A abordagem POGIL tem sido usada com sucesso em todas as áreas típicas da graduação em química, assim como biologia, física, matemática, ciência da computação, engenharia, ciência ambiental, educação e no ensino médio (predominantemente em química e biologia). Abordagens POGIL também podem ser usadas para desenvolver experimentos de laboratório. Embora o POGIL tenha sido usado mais extensivamente em classes pequenas, ele foi adaptado para classes tão grandes quanto várias centenas com muito sucesso. Os elementos essenciais para a implementação do POGIL são o uso de pequenos grupos auto gerenciados de estudantes; o papel do instrutor como facilitador; o uso de atividades especialmente projetadas que geralmente seguem o paradigma do ciclo de aprendizagem; e a ênfase no desenvolvimento de habilidades de processo, além de dominar o conteúdo do curso. Em uma aplicação do POGIL em ciência da computação os autores destacam os diferenciais da metodologia em relação a outras pedagogias de aprendizagem ativa e fornecem antecedentes sobre a eficácia do POGIL. Foram fornecidas diversas recomendações sobre como facilitar e desenvolver as atividades do POGIL bem como as citações de avaliações de alunos e a melhoria do aprendizado em programação (HU; SHEPHERD, 2013).

A experiência em cursos de engenharia foi narrada por exemplo em Douglas e Chiu (2009), onde os autores descrevem a implementação e o teste do POGIL como uma aprendizagem pedagógica ativa, baseada em equipe. Em vez de participar de palestras tradicionais, os alunos trabalharam em equipe para preencher planilhas que os orientaram no processo de aprendizado. O papel do instrutor nesta aula foi atuar como facilitador do aprendizado. Os alunos envolvidos ativamente no processamento das informações tiveram a oportunidade de utilizar e desenvolver habilidades importantes, como trabalho em equipe, comunicação e pensamento crítico. A avaliação dessa abordagem foi realizada usando dados qualitativos formais e informais. Os dados revelaram elementos importantes de implementação que são necessários para melhorar o aprendizado dos alunos ao usar essa abordagem, por exemplo, a principal expectativa dos alunos é que eles esperam ser “ensinados” por um especialista. Portanto, é importante que o feedback apropriado seja fornecido para que os alunos sintam que o instrutor faz parte de seu aprendizado. Dar justificativas e iniciar uma discussão em toda a classe sobre a implementação do POGIL os ajudará a entender seu próprio aprendizado e aumentarão a consciência de serem aprendizes ativos (DOUGLAS; CHIU, 2013).

2.3. Outras Técnicas de AA complementares

São ainda mais diversas as técnicas complementares que podem ser utilizadas isoladamente ou conjuntamente com as técnicas instrucionais que foram elencadas anteriormente, sempre dependendo da disciplina, do contexto e da infraestrutura disponível. Seguem alguns exemplos disponibilizados na literatura tais como em Gleason *et al.* (2011).

2.3.1. Questões Recíprocas

Criação de um diálogo aberto no qual os alunos assumem o papel do instrutor e geram suas próprias questões sobre um tópico, sessão de leitura ou aula. Por exemplo, as perguntas a) Pode o aprendizado em uma disciplina apoiar os alunos individualmente no desenvolvimento e na construção de uma narrativa pessoal de si mesmos? b) Como a busca de uma narrativa pessoal de si mesmo pode influenciar a abordagem individual de um aluno para uma disciplina? As perguntas recíprocas colocadas visam revisitar a agenda do aprendizado / ensino do conhecimento de conteúdo, colocando uma ênfase adicional no papel de aprender uma disciplina para o desenvolvimento da identidade ((LEVRINI *et al.*, 2015).

2.3.2. Entrevista de 3 passos

A técnica da entrevista em três etapas foi implementada como uma atividade de aprendizagem ativa para vários tópicos em engenharia e STEM . Nas 3 etapas da entrevista há participação igual e individual e responsabilidade pela escuta, porque na terceira etapa cada aluno compartilha o que ouviu nos primeiros dois passos e interage em pares. A técnica encoraja os alunos a desenvolverem habilidades de ouvir ativamente a) colocando perguntas conceituais um pro outro; b) dividindo seus pensamentos e c) tomando notas ((KURUNDAWADE; KAVALE, 2018).

2.3.3. Procedimento de Pausa

Encaixa procedimentos de pausa durante as aulas tradicionais (palestra) para enriquecer a compreensão dos alunos sobre o material e os recursos de ensino. O uso do procedimento de pausa em pesquisas em educação superior indicaram resultados surpreendentes, por exemplo em uma aula de contabilidade, quando o instrutor fez duas pausas de oito minutos durante cada aula de noventa minutos, obteve-se maior desempenho e satisfação dos alunos em comparação com o grupo de controle, onde o procedimento de pausa não foi empregado (CHOWDHURY, 2016). A incorporação de pausas estratégicas durante as aulas contribuiu para o desempenho geral da classe.

2.3.4. Advogado do diabo

O instrutor atuando como mentor solicita que um ou mais alunos tomem o lado oposto de um argumento predominante ou ponto de vista sendo discutido durante a aula. O mentor pode atuar como advogado do diabo sendo parte integrante das discussões e atos da equipe para trazer o foco da equipe para os aspectos que requerem resolução. Ele não necessariamente oferece as respostas diretas, mas incentiva a equipe a chegar a uma solução correta (KAVANAGH; CROSTHWAITE, 2007).

2.3.5. Plataforma de jogos (*Gamification*)

A incorporação de jogos na educação em engenharia tem crescido nos últimos anos. A academia tem buscado desenvolver novas metodologias e ferramentas para produzir, aplicar e usar jogos digitais e técnicas de gamificação (*gamification*) na indústria contemporânea e apresentar evidências científicas sobre o valor e benefícios derivados dessa tecnologia. Em uma revisão de literatura sobre a gamificação na EE, Markopoulos *et al.* (2015) sugerem os seguintes elementos para jogos em engenharia: a) Conquistas: representações virtuais ou mesmo físicas de ter realizado algo no contexto dado ao usuário pelo jogo; b) Níveis: fazem parte de um sistema no qual o jogo é dividido em estágios distintos de dificuldade variável, geralmente crescente; c) Progressão: é um mecanismo que mede a porcentagem de sucesso do usuário no

que diz respeito à conclusão de um nível. Geralmente é granular e assume a forma de pontos; d) Missões ou desafios: tipo específico de competição dentro de um nível; e) Status: maneira complexa de expressar o nível de conhecimento que o usuário possui ou foi alcançado no domínio do jogo ou na classificação de um jogador; f) Colaboração: desejo do usuário de colaborar com outros usuários para resolver um problema específico; g) Aversão à perda: influência do comportamento do usuário, não pelo potencial de resultados positivos, mas evitando resultados negativos; h) Quadros de líderes: são componentes agregados de feedback usados para calcular as conquistas que o usuário acumulou, bem como seu status. Eles podem ser baseados em fatores agregados, como a contagem geral, a contagem periódica ou a contagem de espaço, ou seja, focado em um nível específico. Eles aumentam a motivação ajudando os usuários comparar-se a outros usuários. Aplicações de gamificação em EE foram também estudadas por exemplo em (LIN; MIAO; SUN, 2011; MEHTA *et al.*, 2017; USKOV; SEKAR, 2014).

2.3.6. *Think_Pair_Share*

É uma técnica de aprendizagem colaborativa, onde os alunos atuam juntos para resolver um problema ou responder uma pergunta sobre um assunto abordado pelo instrutor. os alunos devem a) pensar individualmente sobre o tópico ou resposta à pergunta (1 a 2 minutos); b) discutir com um colega próximo de forma a maximizar a participação, atenção e engajamento (3 a 5 minutos); c) dividir a solução ou resposta com os colegas de classe. Esta técnica de aprendizado cooperativo incentiva a participação individual e é aplicável a todos os níveis e tamanhos de classe. Na atividade de pensar em compartilhar, os alunos reservam um minuto para refletir sobre a lição anterior, depois para discuti-la com um ou mais de seus colegas e finalmente para compartilhá-la com a classe como parte de uma discussão formal. É durante essa discussão formal que o instrutor deve esclarecer conceitos errôneos. No entanto, os alunos precisam de um histórico no assunto para conversar de maneira significativa. Assim, um exercício de "pensar em compartilhar" é útil em situações em que os alunos podem identificar e relacionar o que já sabem com os outros. Então a preparação é a chave. O *Think-pair-share* é útil também para o instrutor, pois permite organizar o conteúdo e rastrear os alunos sobre onde eles são melhores piores relativo ao tópico discutido na aula, economiza tempo para que ele possa passar para outros tópicos e ajuda a tornar a aula mais interativa (WIGGINS; MCTIGHE, 2005).

2.3.7. Clicker Question (Sistema de Perguntas e Respostas)

O termo "*clicker question*", em muitas aplicações também conhecido como sistema de perguntas e respostas em sala de aula, é um setup de hardware e software que facilita as atividades de ensino. É comumente utilizado em conjunto com o *Peer Instruction* (BRUFF, 2009; MAZUR; WATKINS, 2009). Uma sequência do processo seria como a seguir:

1. O instrutor posta uma questão de múltipla escolha para os alunos via projetor de slides.
2. Cada aluno submete uma resposta para a questão usando seu *smartphone*, *notepad* ou *notebook* (o *clicker*) que se comunica por uma rede local, *internet* ou outro dispositivo conectado com o computador do instrutor.
3. O software no computador do instrutor ou plataforma na rede local ou internet coleta as respostas dos alunos e produz um gráfico de barras mostrando quantos alunos escolheram cada uma das possíveis respostas.
4. O instrutor realiza escolhas instrucionais dinâmicas (*on-the-fly*) em resposta ao gráfico de barras, por exemplo, liderando os alunos para discussões de mérito de cada opção de resposta ou pedindo aos alunos que discutam a questão e as opções em pequenos grupos.

Muitos instrutores veem as questões de múltipla escolha como para testar a memória dos alunos para os fatos, mas elas podem servir vários outros propósitos na sala de aula, tais como avaliação de habilidades de alta ordem. As questões servem não só para avaliar os alunos, mas para engajá-los e podem ser bem distintas daquelas que aparecem em provas ou exames (BRUFF, 2009). Esta abordagem é particularmente adotada para grandes turmas e podem ser facilitadas por uma variedade de ferramentas, por exemplo: *Poll Everywhere* (<https://www.poll everywhere.com/>); *TopHat* (<https://tophat.com/>); *TurningPoint* (<https://www.turningtechnologies.com/turningpoint/>).

2.4. Protocolos de Observação em Sala de Aula

As observações em sala de aula tem sido usadas na Educação como uma estratégia importante para abordar vários objetivos, tais como avaliar o desempenho do professor e as técnicas de ensino (HAEP; BEHNKE; STEINS, 2016). A complexidade dos dados observados está

impulsionando novas abordagens para uma análise mais profunda dos comportamentos no ambiente da sala de aula com vários instrumentos ou protocolos de medição (ERDMANN; STAINS, 2019).

As observações podem ser qualitativas ou quantitativas e os protocolos podem assumir muitas formas de registro de dados, como a forma de uma pesquisa com escalas, um padrão de comportamento ou evento com um registro de tempo de duração ou mesmo um formulário eletrônico com som audível da sala de aula (FREY, 2016; SMITH *et al.*, 2013). As disciplinas de graduação STEM (Ciência, Tecnologia, Engenharia e Matemática) são partes críticas do currículo de Educação em Engenharia (EE) e as aplicações de protocolos STEM podem ser adaptadas para apoiar novos experimentos no contexto de EE. A presente fundamentação demonstrou que, com pequenas adaptações, os protocolos de observação em sala de aula de EE, se não projetados especificamente para EE, podem ser alavancados pelos protocolos STEM de graduação desenvolvidos com várias abordagens diferentes (em termos de proposição de valor, forma, processo de coleta de dados, tecnologia, etc.). Eles mostraram uma estratégia central comum: os protocolos abordam o que os alunos estão fazendo, o que os instrutores estão fazendo, as interações entre professores e alunos, a reflexão sobre os dados da observação e, eventualmente, o nível de envolvimento dos alunos no ambiente da sala de aula (HARRIS; COX, 2003; SMITH *et al.*, 2013; STEARNS *et al.*, 2012; VAN AMBURGH *et al.*, 2007).

Além disso, a literatura relacionada à EE e à STEM tem trazido novos experimentos que discutem ambientes tradicionais de palestras versus ambientes de aprendizagem ativa, bem como o uso de metodologias de aprendizagem ativa e seu impacto no desempenho dos alunos. Isto tem reforçando a implantação mais ampla de metodologias educacionais de aprendizagem ativa (por exemplo, FREEMAN *et al.*, 2014; DEMONBRUN *et al.*, 2016; LEFEBVRE; PRAKASH, 2018).

Seguindo a tendência das abordagens de aprendizagem ativa, houve novos desenvolvimentos de estratégias de observação em sala de aula que cumprem o tipo de atividades de aprendizagem que são introduzidas no ambiente ativo para EE (DEMONBRUN *et al.*, 2016; SMITH *et al.*, 2013; TOLNAY *et al.*, 2017). Tais estratégias são demonstradas por novos protocolos de observação e suas estruturas, objetivos e proposições de valor. Quando testados quanto à confiabilidade e validade adequadas, tornam-se instrumentos importantes para avaliar quais

técnicas de aprendizagem ativa são mais frequentemente usadas durante a aula e por quanto tempo, bem como quando predomina uma abordagem tradicional baseada em palestras.

Finelli *et al.* (2014) descreveram um projeto de instrumento de observação em sala de aula para avaliar a resposta de alunos ao uso da aprendizagem ativa pelos instrutores, buscando identificar estratégias que reduzam o receio que os alunos apresentam diante do uso das técnicas ativas. Segundo os autores, este instrumento de observação, que tem sua origem científica em outros protocolos de observação na literatura capta dados do uso de aprendizagem ativa pelos instrutores e a resposta dos alunos para este contexto de aprendizagem. Furtak, Morrison e Kroog (2014) conduziram uma pesquisa focando nas avaliações em sala de aula e sua conexão com o progresso do aprendizado dos alunos em um curso de Biologia, através de diversas fontes de dados. Tais fontes incluem respostas de alunos a pré-testes e post-testes, sessões de desenvolvimento profissional e filmagens em vídeo de tais sessões. Com estes dados os autores construíram um estudo de caso que é usado para que os instrutores interpretem os dados das avaliações e da dinâmica da sala de aula, de forma a realizarem ações para melhorar o projeto de suas aulas e o conteúdo.

Smith *et al.* (2013) argumentaram que os instrutores e suas práticas de ensino têm um papel crítico na melhoria do aprendizado dos alunos em cursos STEM. Devido a isto, havia um crescente interesse em coletar informações sobre o alcance e a frequência das práticas de ensino, tanto em nível departamental, como da instituição como um todo. Os autores apresentaram para este fim um novo Protocolo de Observação em Sala de Aula para graduação em cursos STEM (sigla COPUS - *Classroom Observation Protocol for Undergraduate STEM*). Este protocolo permitiu aos professores de cursos STEM, após um curto treinamento de 1,5 horas, caracterizar de forma confiável como os professores e os alunos estão gastando seu tempo na sala de aula. Os autores ainda discutiram o desenvolvimento e a validação da ferramenta e como os dados de observação poderiam ser usados para direcionar mudanças individuais e institucionais quanto à dinâmica das salas de aula. Piburn, Sawada e Turley (2000) referenciaram diretamente um programa de reforma de ensino do estado do Arizona nos EUA e o protocolo desenvolvido pelo grupo de avaliação criado para tal, chamado Protocolo de Observação de Ensino Reformado (sigla RTOP - *Reformed Teaching Observation Protocol* no idioma Inglês). Este instrumento de observação foi criado para observar o ensino "reformado" do Estado. Os autores apresentaram o guia do instrumento bem como seu desenvolvimento e validação, e adicionaram também os resultados de uma análise de fatores exploratória do instrumento. Sua conclusão foi

que o uso do instrumento foi altamente compensador no ensino de disciplinas STEM, inclusive nas universidades, e sugeriram que ele é uni-fatorial pois engloba um simples constructo da observação.

Lund *et al.* (2015) analisaram e alavancaram os pontos fortes dos protocolos RTOP e COPUS, num contexto onde pesquisadores, professores e administradores estavam altamente interessados em medir e descrever as práticas instrucionais em cursos STEM. A pesquisa foi feita de forma empírica através de análise de observações em 269 períodos de aulas individuais correspondentes a 73 professores diferentes em 28 instituições diferentes e intensivas em pesquisa científica. Como resultado da análise, 10 grupos emergiram com perfis semelhantes, representando as práticas instrucionais mais comuns em várias disciplinas STEM. Os escores do instrumento RTOP foram usados para validar o alinhamento dos 10 perfis com os objetivos do “ensino reformado”. O artigo contribuiu para duas grandes iniciativas americanas - uma Fundação Nacional de Ciências (sigla NSF - *National Science Foundation* no idioma inglês) que aborda o grau de implementação e demonstração das reformas do ensino baseadas em evidência e outra da iniciativa de educação em STEM, da Associação Americana de Universidades (LUND *et al.*, 2015, p.1). Foi crítico para o sucesso destas iniciativas obter a habilidade de medir e descrever práticas instrucionais em sala de aula. A evolução das aplicações de protocolos de observação em Educação em Engenharia/STEM em ambientes de aprendizagem ativa pode ser observada na Figura 4.

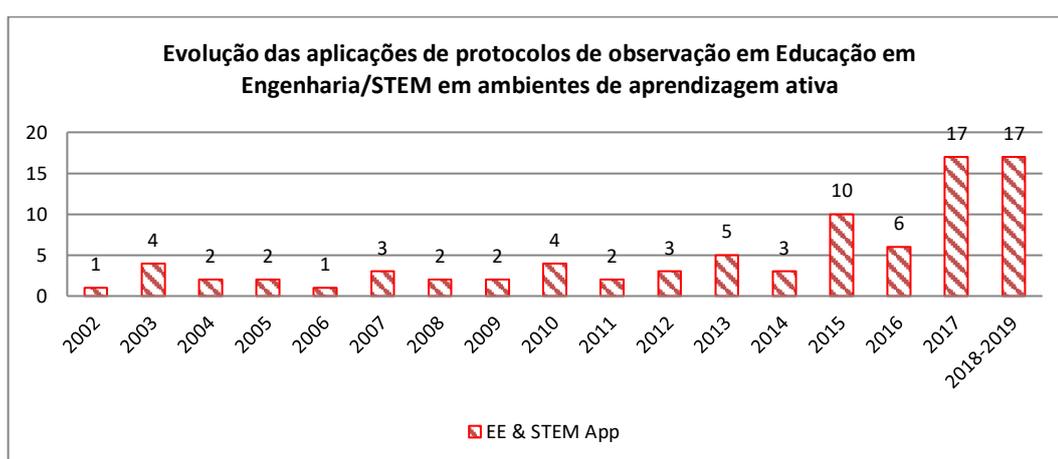


Figura 4 - Evolução dos COP's de EE/STEM em ambientes de aprendizagem ativa

Os projetos de observação em sala de aula e seus protocolos apresentaram variações em suas abordagens aos ambientes ativos de aprendizagem e os diferentes elementos projetados nos

protocolos. A maioria dos 40 protocolos selecionados se concentrou principalmente no comportamento do professor e do aluno e se tornaram a principal referência para a seleção implementada nesta tese, conforme resumido no Quadro 2.

Quadro 2 - Resumo da proposição de valor dos COP's

COP – Acrônimo	COP - Descrição e resumo da Proposição de Valor
COPUS	<i>Classroom Observation Protocol for Undergraduate STEM</i> : documenta os comportamentos da sala de aula em intervalos de 2 minutos, sem avaliar a qualidade da aprendizagem.
RTOP	<i>The Reformed Teaching Observation Protocol</i> : medir práticas de reforma nas salas de aula de Ciências e Matemática.
EQUIP	<i>Electronic Quality of Inquiry Protocol</i> : orientar e melhorar a instrução baseada em investigação, uma forma de aprendizagem ativa.
StRIP	<i>Student Response to Instructional Practices</i> : pesquisa para aulas ativas de engenharia.
TDOP	<i>Teaching Dimensions Observation Protocol</i> : protocolo de observação descritivo e bastante detalhado focado nos comportamentos e interações entre instrutores e alunos.
aRTOP	<i>The modification of RTOP</i> : para conteúdo e práticas de ciências em T&E (Tecnologia e Engenharia)
ELCOT	<i>Engineering Learning Classroom Observation Tool</i> : baseado no COPUS, para graduação EE misturado com o framework ICAP.
MCOP^2	<i>Mathematics Classroom Observation Protocol for Practices</i> : rubrica baseada na estrutura Instrução como Interação.
STROBE	STROBE é um nome não um acrônimo. Feito para documentar o engajamento dos alunos.
TPI	<i>Teaching Practices Inventory</i> : para caracterizar práticas de ensino na educação EE / STEM.
3DCOS	<i>Three-Dimension Classroom Observation System</i> : Coleta os comportamentos e interações entre professor e aluno, em que o observador preenche um painel com cada atividade codificada.
ALIT	<i>Active-Learning Inventory Tool</i> : registra comportamentos no ensino com aprendizagem ativa.
ASPECT	<i>Assessing Student Perspective of Engagement in Class Tool</i> : Observação do engajamento dos alunos para grandes turmas de EE / STEM.
BERI	<i>Behavioral Engagement Related to Instruction</i> : Para medir os níveis de engajamento dos alunos em grandes turmas, com palestras.
BOSS	<i>Behavior Observation of Students in Schools</i> : foi criado para captar o engajamento de alunos em aprendizagem ativa.
CCCO	<i>Community College Classroom Observation</i> : O protocolo foi baseado em ensino por investigação, focado no engajamento acadêmico, relacional e cognitivo.
CDAT	<i>Classroom Discourse Analysis Tool</i> : foi projetado para observar as aulas de EE / STEM para identificar os padrões do discurso em sala de aula com as lentes do raciocínio científico.
CIEOP	<i>Classroom Interactive Engagement Observation Protocol</i> : desenvolvido para detectar o comportamento e o engajamento dos alunos com a técnica de aprendizagem ativa <i>Think-Pair-Share</i> (TPS).
CLOP	<i>Cooperative Learning Observation Protocol</i> : Estudo sobre aprendizagem cooperativa no âmbito da educação em EE / STEM.
COSPERM	<i>Code for Students' Performance Measures</i> : para observação e avaliação do engajamento dos alunos.
Sem acrônimo I	Software de codificação de vídeo para codificar um COP personalizado desenvolvido no ambiente de aprendizagem ativa de forma livre (ABC - instrução ativa, combinada e colaborativa) na graduação EE / STEM (programa de engenharia).
Sem acrônimo IV	Estudo da aplicação e comparação de técnicas de aprendizagem ativa, como a Instrução <i>Blended</i> e <i>Invertida</i> , aplicada a uma disciplina EE / STEM no Ensino de Engenharia, em várias Escolas de Engenharia.
DART	<i>Decibel Analysis for Research in Teaching</i> : Uso do som em sala de aula para classificar as práticas de ensino nos cursos EE / STEM.
ETBC	<i>Effective Team Behavior Checklist</i> : medir o comportamento de equipes no ensino de engenharia.
IOP	<i>Inquiry-Based Protocol</i> : fornece uma lista de processos de investigação classificados por uma escala de uso (<i>rate</i>).
ISOCS	<i>Inquiry Science Observation Coding Sheet</i> : para observar a interação aluno-professor.
KTOP	<i>Korean Teaching Observation Protocol</i> : observar e analisar as técnicas de aprendizagem em EE / STEM.
LAMM	<i>Learner Activity Monitoring Matrix</i> : facilitar a adoção de metodologias ativas de aprendizagem no ensino de engenharia.

COP – Acrônimo	COP - Descrição e resumo da Proposição de Valor
OPAL	<i>Observation Protocol for Active Learning</i> : documentar e refinar a aprendizagem ativa de EE / STEM.
PORTAAL	<i>Practical Observation Rubric To Assess Active Learning</i> : aprendizagem ativa em grandes turmas de EE / STEM.
PSI	<i>Principles of Scientific Inquiry</i> : investigar até que ponto os estudantes estão envolvidos na investigação científica.
PULSE	<i>Protocol Base Utility to Log Student Engagement</i> : registrar e analisar dados de observação em sala de aula com vários observadores, baseados em protocolos, operando em uma plataforma móvel.
QAP	<i>Question and answer protocol</i> : os efeitos do uso de smartphones como <i>clickers</i> e tablets como quadros digitais no engajamento e aprendizagem dos alunos.
SACS	<i>The Student Actions Coding Sheet</i> : analisar a sala de aula de ciências centrada no aluno.
SBE	<i>Students' Behavioral Engagement in School Science Classroom</i> : abordagem de aprendizagem ativa para analisar o engajamento dos alunos.
SCAEI	<i>Student Class Activity and Engagement Instrument</i> : percepções dos alunos sobre as atividades da sala de aula de engenharia.
SIOI	<i>Scholastic Inquiry Observation Instrument</i> : análise psicométrica em STEM pré-universitário.
SPB	<i>Student's Participatory Behavior</i> : um protocolo baseado em ensino por investigação (<i>inquiry-based</i>) para medir engajamento.
STEM PBL	Instrumento de observação de professores para salas de aula utilizando PBL (<i>Problem Based Learning</i>).
STIR	<i>Science Teacher Inquiry Rubric</i> : um protocolo que mede o grau de implementação do ensino por investigação (<i>inquiry-based</i>).
CDOP	<i>Classroom Discourse Observation Protocol</i> : quantifica os movimentos e mudanças do discurso do professor (TDMs) nas aulas de EE / STEM.
COPEP	<i>Classroom Observation Protocol for Engineering Design</i> : mede o processo e os hábitos mentais para projetos em Engenharia.
ALCOT	<i>Active Learning Classroom Observation Tool</i> : recursos espaciais e tecnológicos de uma sala de aula com pedagogias de aprendizagem ativa e colaborativa.

Dentre estes 40 protocolos, destacaram-se para o objeto da tese:

1) O protocolo RTOP mediu as práticas de reforma nas salas de aula de ciências e matemática, uma iniciativa do governo dos EUA. O RTOP também se baseou nos conceitos construtivistas de aprendizado ativo, cobrindo o desenho das lições e a cultura da sala de aula, com uma estrutura e dimensões muito detalhadas. Ele foi baseado em um formulário de observação de 25 itens, com o objetivo de ser (a) baseado em padrões, (b) orientado a investigações e (c) centrado no aluno. Os termos em b) e c) associados ao termo “engajamento do aluno” passaram a fazer parte da ampla definição de aprendizagem ativa (SAWADA *et al.*, 2002);

2) Um dos principais marcos após 2010 foi o desenvolvimento do COPUS. Diferente do RTOP, os autores evitaram julgamentos observacionais e relataram apenas 1,5 horas necessárias para o treinamento. O COPUS documentou os comportamentos da sala de aula em intervalos de 2 minutos durante toda a duração da aula e não exigiu que os observadores fizessem julgamentos sobre a qualidade do ensino. Foi baseado em 25 códigos em apenas duas categorias: A) “O que os alunos estão fazendo” e B) “O que o instrutor está fazendo”. O resultado da confiabilidade entre avaliadores (IRR) utilizando o *Kappa* de Cohen variou de 0,79 a 0,87. As evidências de validade foram obtidas por meio de revisões de especialistas bem-sucedidas (SMITH *et al.*,

2013). O COPUS foi ainda replicado em muitos outros estudos para EE alavancados por STEM (AKIHA *et al.*, 2018; DAHER *et al.*, 2018; LEWIN *et al.*, 2016; (LUND *et al.*, 2015; LUDWIG *et al.*, 2019; TOMKIN *et al.*, 2019).

3) Com menos aplicações que COPUS e RTOP, o EQUIP foi desenvolvido para melhorar uma forma de aprendizado ativo, chamada instrução baseada em investigação, usando uma escala baseada no tempo, com indicadores e constructos que o observador avalia. O EQUIP final foi modelado com 4 constructos e seus indicadores: instrução, currículo, discurso e avaliação. O protocolo pareceu bastante complexo para uso em aulas regulares de EE, mas forneceu as rubricas associadas aos indicadores individuais que podem ser explorados junto aos professores para abordar áreas individuais onde eles podem refinar suas instruções (HORTON *et al.*, 2009). O EQUIP foi aplicado em outros casos, por exemplo em Marshall *et al.* (2011), Marshall *et al.* (2010) e Cian *et al.* (2018);

4) O TDOP é um protocolo de observação descritivo focado nos comportamentos e interações entre instrutores e alunos. O TDOP teve como objetivo captar vários detalhes nos comportamentos da sala de aula e tornou-se complexo, exigindo observadores experientes (FERRARE; HORA, 2013). O TDOP também foi discutido em vários outros estudos (CLARK *et al.*, 2016; DEMONBRUN *et al.*, 2015; HORA, 2015; LOVE *et al.*, 2017);

5) Como foi mostrado no Quadro 2 outros exemplos de protocolos com aplicações específicas foram desenvolvidos e reforçaram o foco na medição do comportamento da sala de aula (ADAMS *et al.*, 2008; BODZIN; BEERER, 2003; CIANCIOLO *et al.*, 2006; KERN *et al.*, 2007; VOLPE *et al.*, 2005; VAN AMBURGH *et al.*, 2007). Aplicações adicionais em abordagens de aprendizagem ativa com algumas adaptações dos protocolos mais conhecidos também foram apresentadas (CAMPBELL *et al.*, 2010; JOHNSON *et al.*, 2007; JONES *et al.*, 2009; KARELITZ *et al.*, 2010; KRANZFELDER *et al.*, 2019; WHEELER *et al.*, 2019); WILLIAMS; CARVALHO, 2010; XIE; CAO, 2010).

As recomendações de qual protocolo escolher como base foram baseadas nos objetivos e do escopo desta pesquisa. Para um critério baseado em robustez estatística, os protocolos testados para V&R pareceram atender a aplicações com uma maior qualidade psicométrica. Do ponto de vista prático, os protocolos mais implantados em termos de número de aplicações poderiam indicar a facilidade de uso e mais experiência fornecida pela literatura. Buscou-se maximizar o

atendimento a ambos os critérios além do foco específico na medição de comportamentos em sala de aula e não na qualidade da aula. Por essas razões, os experimentos nesta tese foram realizados com um protocolo adaptado para as aulas dos cursos de Engenharia elencados nos programas de graduação da IES participante, a partir da base de códigos e *clusters* do protocolo COPUS (LUND *et al.*, 2015; SMITH *et al.*, 2013). O protocolo COPUS foi adaptado e, além da tradução e recodificação de alguns elementos, teve uma redução na quantidade de elementos com vistas à melhor adequação ao perfil de aulas que foi observado, sendo codificado com o acrônimo **PORE – Protocolo de Observação e Reflexão em Engenharia**. O processo de adaptação e os testes de validação serão detalhados nos capítulos de metodologia e resultados.

2.5. Modelagem de Equações Estruturais

2.5.1. Fundamentos

A Modelagem de Equações Estruturais (SEM - *Structural Equation Modeling*) é um método de análise de dados multivariada de segunda geração o qual é frequentemente usado em pesquisas de ciências comportamentais porque pode testar modelos causais com fundamentação teórica (HAENLEIN; KAPLAN, 2007). Em outras palavras, a modelagem por equações estruturais (SEM) é um conjunto de técnicas estatísticas multivariadas que permitem a investigação simultânea de um conjunto de relações teóricas entre uma ou mais variáveis independentes contínuas ou discretas e uma ou mais variáveis dependentes, também contínuas ou discretas (TABACHNICK; FIDELL, 2007). Combinando aspectos da análise fatorial com regressão múltipla, o método permite ao pesquisador investigar simultaneamente múltiplas relações de dependência e independência entre variáveis latentes e variáveis observadas, como uma das mais recentes técnicas multivariadas utilizadas nas ciências comportamentais (HENSELER *et al.*, 2014).

A modelagem por equações estruturais (SEM) foi proposta para as aplicações em variáveis comportamentais por Jöreskog (1973) em seu trabalho sobre a análise de estruturas de covariância. Esse é o termo comum utilizado para várias técnicas diferentes de análise de dados multivariados, onde a matriz de variância-covariância é restrita a algum tipo particular de estrutura. O autor desenvolveu juntamente com Dag Sörbom o software LISREL (*Linear Structural Relations*), importante ferramenta para análise de modelos SEM que se tornou sinônimo da modelagem de equações estruturais (JÖRESKOG; SÖRBOM, 1982). Desde então,

a literatura tem mostrado sua utilização em diversas áreas de conhecimento, das quais pode-se citar como exemplo: Marketing (BAGOZZI; YI, 2012; HOWELL, 1987), Tecnologia da Informação (HARDIN; CHANG; FULLER, 2008), Estratégia (SARKAR; ECHAMBADI; HARRISON, 2001), Comportamento Organizacional (EDWARDS, 2001), Negócios e Gestão (FRANKE; PREACHER; RIGDON, 2008), Comportamento do consumidor (BOLLEN; BAULDRY, 2011), Desempenho Acadêmico (RUGUTT; CHEMOSIT, 2005), Aprendizado em realidade virtual (AI-LIM LEE; WONG; FUNG, 2010), Atitudes de estudantes na educação em Matemática (DAVADAS; LAY, 2018) e mesmo estudos mais específicos em Educação em Engenharia envolvendo uma análise restrita aos protocolos de observação (CIAN *et al.*, 2018).

No campo específico da Engenharia de Produção, pode-se citar exemplos em Logística (MANGLA; GOVINDAN; LUTHRA, 2016) e desenvolvimento de novos produtos (KRAUS; POPEK, 2013). Segundo Byrne (2001), o termo “modelagem de equações estruturais” transmite dois aspectos importantes do procedimento: (a) que os processos causais em estudo são representados por uma série de equações estruturais (isto é, regressão); e (b) que essas relações estruturais podem ser modeladas para permitir uma conceituação mais clara da teoria em estudo. A SEM é uma técnica de equações estruturais ou equações múltiplas, mas se diferencia da análise de trajetórias porque trabalha com variáveis latentes. As medidas não são diretamente observadas, mas sim derivadas de indicadores observáveis, como itens de uma escala de avaliação cognitiva ou de comportamento organizacional. Dessa forma, a técnica utiliza princípios teóricos e lógicos dos modelos psicométricos da análise fatorial e a lógica de teste de equações múltiplas da econometria. Uma revisão de literatura sobre a aplicação de PLS-SEM na Educação Superior foi apresentada em Ghasemy *et al.* (2020) com aplicações empíricas de PLS-SEM em 14 principais periódicos de ensino superior indexados no *Thomson Reuters Web of Science* e nos bancos de dados *Elsevier-Scopus* entre 1999 e 2018. OS autores identificaram vários problemas relacionados à triagem de dados, características do modelo, avaliação do modelo de medição e do modelo estrutural e aplicação de métodos avançados de PLS-SEM de última geração. Baseado na sua análise, foram recomendadas diretrizes para melhorar as aplicações e práticas de PLS-SEM, no ensino superior para evitar imprecisões em futuras publicações e garantir o rigor científico necessário.

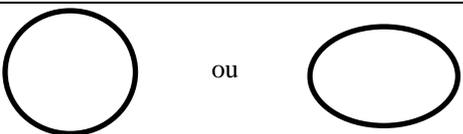
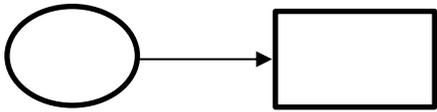
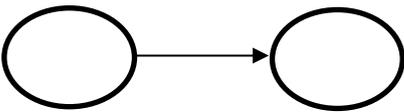
Os artigos selecionados abordaram temas diversos em educação superior, tais quais podemos citar como mais próximas ao tema desta tese: a) o papel das atitudes nas avaliações matemáticas on-line (ACOSTA-GONZAGA; WALET, 2017) ; b) Processos e resultados de alunos no

trabalho em equipe (BRAVO; LUCIA-PALACIOS; MARTIN, 2016); c) Entendendo o uso continuado da aprendizagem em aula invertida em estudantes de graduação em STEM (CAI *et al.*, 2019); d) Revisão metodológica da modelagem de equações estruturais na pesquisa do ensino superior (GREEN, 2016); e) uso do método de estudo de caso para enriquecer o resultado de aprendizagem dos alunos (NKHOMA; SRIRATANAVIRIYAKUL; QUANG, 2017); f) Análise de trajetórias usando SEM para medir o desempenho acadêmico em ciências no ensino superior (ZEEGERS, 2004). Os estudos dos diversos pesquisadores foram importantes e reforçaram a possível contribuição da pesquisa experimental apresentada nesta tese para agregar novos conhecimentos ao tema da educação superior, especificamente para o uso de modelagem PLS-SEM na Educação em Engenharia.

2.5.2. Simbologia e Terminologia SEM

A simbologia e os termos comuns na Modelagem de Equações Estruturais são ilustrados no Quadro 3 e um modelo representado por um diagrama de trajetórias é mostrado na Figura 5.

Quadro 3 - Simbologia da SEM

Símbolo	Definição
	Constructo ou Variável Latente (VL)
	Variável Observada ou Medida ou Indicada (Item) (VO)
	Correlação entre VL e VO (Modelo de Medição)
	Relação Causal – Coeficiente de Trajetória (<i>Path</i>) entre uma VL independente → Dependente (Modelo Estrutural)

Fonte: Adaptado de Hair Jr. *et al.* (2017)

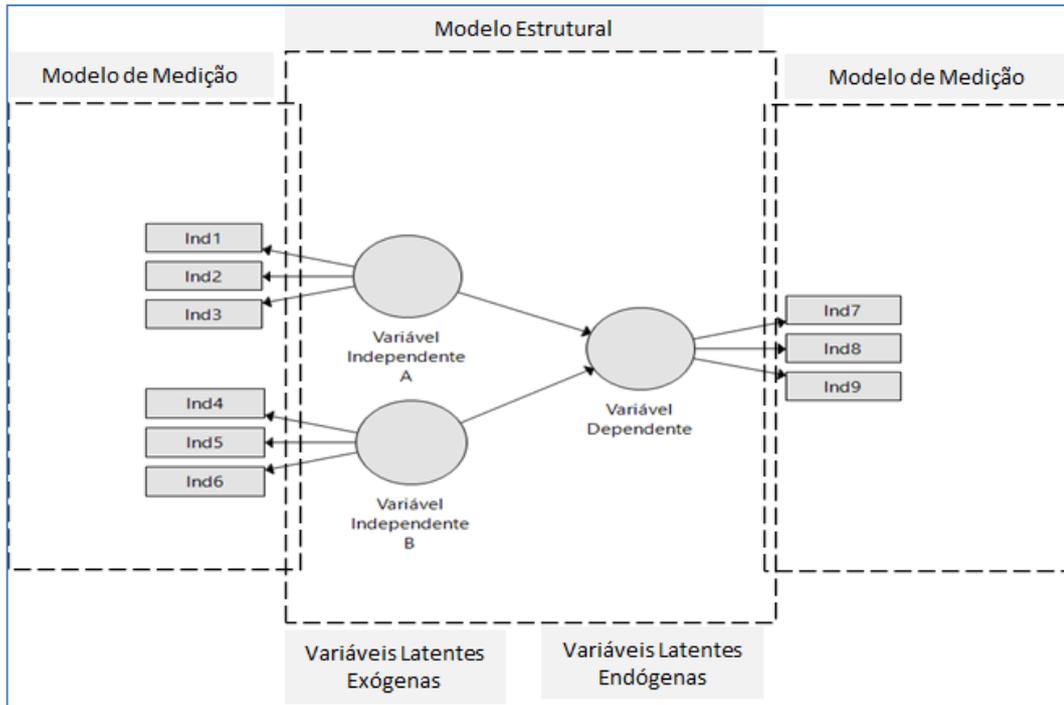


Figura 5 - Modelo básico SEM

As seguintes considerações preliminares podem ser feitas sobre a terminologia e o modelo básico SEM:

- As Variáveis Latentes são variáveis subjacentes que não podem ser observadas diretamente; elas também são conhecidas como Constructos ou Fatores. O termo “Constructo” é utilizado para expressar um conceito não mensurável diretamente. Um constructo é formado pela estrutura de covariância presente nas variáveis medidas. As variáveis latentes podem ser endógenas ou exógenas.
 - As variáveis endógenas são aquelas que têm sua variância explicada por variáveis dentro do modelo e podem ser vistas como equivalentes às variáveis dependentes em um modelo de regressão.
 - As variáveis exógenas são aquelas que têm sua variância explicada por variáveis externas ao modelo e são equivalentes às variáveis independentes em um modelo de regressão.
- O modelo interno também é conhecido como modelo estrutural.
- O modelo externo também é conhecido como modelo de medição.

- Os indicadores observados podem ser medidos diretamente, eles atuam como indicadores para uma variável latente subjacente.
- Os indicadores que causam a variável latente são chamados indicadores formativos.
- Os indicadores que são causados pela variável latente são chamados indicadores reflexivos.
- Dependendo do projeto SEM uma variável pode atuar tecnicamente como uma variável independente ou uma variável dependente para diferentes partes do modelo.
- Desde que uma variável tenha trajetórias (*paths*) que levam a ela (ou seja, setas apontando para ela de outra variável), ela é classificada como variável latente endógena.
- Quando a variável latente não tem trajetórias (*paths*) que levam a ela (ou seja, não tem setas apontando para ela de outra variável), ela é classificada como variável latente exógena.

2.5.3. A formulação do modelo geral da SEM

2.5.3.1. Estrutura latente e variáveis causais

Existem vários métodos diferentes de parametrizar modelos de equações estruturais. Segundo Bentler (1985) a equação estrutural para uma variável substantiva X_i é uma equação linear com X_i no lado esquerdo da equação e as causas diretas de X_i mais um termo de erro ε_i no lado direito da equação. Em algumas representações, algumas variáveis substantivas ocorrem apenas no lado direito das equações estruturais e não possuem uma variável de erro correspondente. Uma SEM contém informações sobre a distribuição de probabilidade conjunta sobre as variáveis substantivas e sobre as relações causais entre as variáveis substantivas.

O modelo geral de equações estruturais, conforme descrito por Jöreskog (1973), consiste em duas partes: (a) a parte estrutural que liga variáveis latentes entre si por meio de sistemas de equações simultâneas; e (b) a parte de medição que liga variáveis latentes a variáveis observadas por meio de um modelo de fatores restritos (confirmatório). A parte estrutural (a) do modelo pode ser escrita na forma matricial como mostrado na Equação (1) - Parte estrutural do modelo SEM:

$$\eta = B\eta + \Gamma\xi + \zeta \quad (1) - \text{Parte estrutural do modelo SEM}$$

onde η é um vetor de variáveis latentes endógenas (critério), ξ é um vetor de variáveis latentes exógenas (preditivas), B é uma matriz de coeficientes de regressão que relaciona as variáveis endógenas latentes entre si, Γ é uma matriz de coeficientes de regressão que relaciona variáveis endógenas com variáveis exógenas e ζ é um vetor de termos de erro de medição.

As variáveis latentes estão ligadas a variáveis observáveis (b) por meio de equações de medição para variáveis endógenas (Equação (2) - Parte endógena do modelo SEM) e exógenas (Equação (3)).

$$y_i = \Lambda_y \eta_i + \varepsilon_i \quad (2) - \text{Parte endógena do modelo SEM}$$

e

$$x_i = \Lambda_x \xi_i + \delta_i \quad (3) - \text{Parte exógena do modelo SEM}$$

onde Λ_y e Λ_x são matrizes de cargas fatoriais endógenas e exógenas, respectivamente, e ε_i e δ_i são vetores de termos de erros de medição das variáveis endógenas e exógenas, respectivamente, com $\delta_i \sim N(0, \Sigma_\delta)$ e $\varepsilon_i \sim N(0, \Sigma_\varepsilon)$. Além disso, o modelo geral especifica variâncias e covariâncias para ξ , ζ , ε e δ , denotadas por Φ , Ψ , θ_ε e θ_δ , respectivamente. δ_i e ε_i são independentes e normalmente distribuídos.

2.5.3.2. Relação da Teoria com o diagrama de trajetórias

Uma teoria pode conter conceitos teóricos, empíricos e derivados e existem três tipos possíveis de relacionamento que vinculam esses conceitos: (a) hipóteses não observacionais, que vinculam conceitos teóricos a outros conceitos teóricos; (b) definições teóricas, que conectam conceitos teóricos e derivados; e (c) regras de correspondência, que vinculam conceitos teóricos ou derivados a conceitos empíricos (BAGOZZI; PHILLIPS, 1982). Com esta estrutura em mente, pode-se construir um modelo de pesquisa para uma teoria convertendo conceitos teóricos e derivados em variáveis não observáveis (latentes). E também conceitos empíricos em indicadores, que são ligados por um conjunto de hipóteses (representando hipóteses não observacionais, definições teóricas ou regras de correspondência). Esse modelo pode ser representado graficamente por um diagrama de trajetórias já definido anteriormente e

especificado na Figura 6 (DIAMANTOPOULOS, 1994). Da Figura 6, pode-se configurar os três conjuntos de equações apresentados anteriormente, que podem ser usados para descrever as relações entre os diferentes parâmetros do modelo de pesquisa.

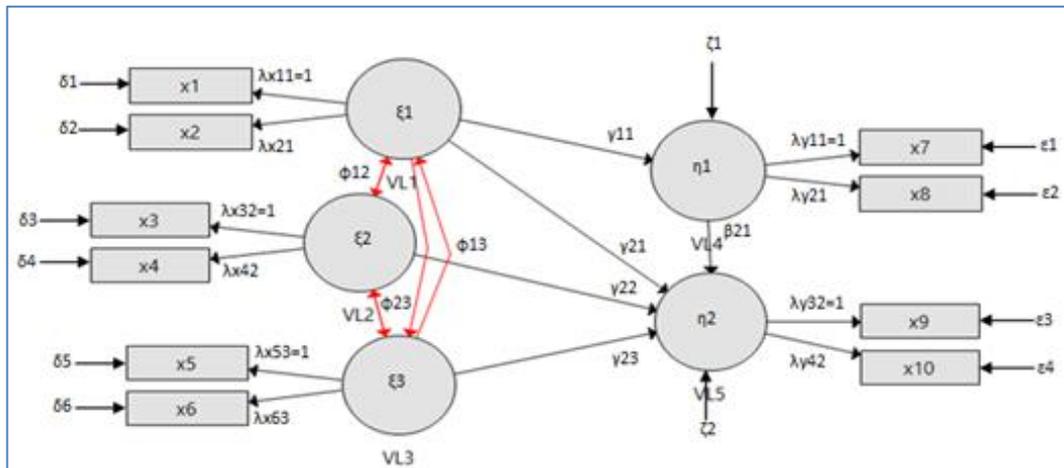


Figura 6 - A Teoria SEM e o diagrama de trajetórias

Notas: η (eta) = variável endógena latente; ξ (xi) = variável exógena latente (isto é, independente); ζ (zeta) = termo aleatório de perturbação; γ (gama) = coeficiente de trajetória; ϕ (phi) correlação entre variáveis latentes exógenas; y_i = indicadores de variáveis endógenas; ε_i (epsilon) = erros de medição para indicadores de variáveis endógenas; λ_{y_i} (lambda y) = cargas de indicadores de variável endógena; x_i = indicadores de variáveis exógenas; δ_i (delta) = erros de medição para indicadores de variáveis exógenas; λ_{x_i} (lambda x) = cargas de indicadores da variável exógena. Para cada variável latente, um dos λ foi definido igual a 1 para fixar a unidade de medida em relação a um indicador observado (porque, não sendo observadas, as variáveis latentes não têm escala definida) (BAGOZZI; PHILLIPS, 1982; DIAMANTOPOULOS, 1994).

O primeiro conjunto apresenta as equações de medição exógenas e relaciona os indicadores das variáveis exógenas (x) com seus erros de medição associados (δ) e as variáveis latentes exógenas (ξ) (Equações (4), (5), (6), (7), (8) e (9)):

$$x_1 = \lambda_{x11}\xi_1 + \delta_1 \quad (4) - \text{Medição exógena 1}$$

$$x_2 = \lambda_{x21}\xi_1 + \delta_2 \quad (5) - \text{Medição exógena 2}$$

$$x_3 = \lambda_{x32}\xi_2 + \delta_3 \quad (6) - \text{Medição exógena 3}$$

$$x_4 = \lambda_{x42}\xi_2 + \delta_4 \quad (7) - \text{Medição exógena 4}$$

$$x_5 = \lambda_{x53}\xi_3 + \delta_5 \quad (8) - \text{Medição exógena 5}$$

$$x_6 = \lambda_{x63}\xi_3 + \delta_6 \quad (9) - \text{Medição exógena 6}$$

O segundo conjunto apresenta as equações de medição das variáveis endógenas e descreve a relação entre os indicadores das variáveis endógenas (y), seus erros de medição associados (ε) e as variáveis latentes endógenas (η) (Equações (10), (11), (12), e (13)):

$$y_1 = \lambda_{y11}\eta_1 + \varepsilon_1 \quad (10) - \text{Medição endógena 1}$$

$$y_2 = \lambda_{y21}\eta_1 + \varepsilon_2 \quad (11) - \text{Medição endógena 2}$$

$$y_3 = \lambda_{y32}\eta_2 + \varepsilon_3 \quad (12) - \text{Medição endógena 3}$$

$$y_4 = \lambda_{y42}\eta_2 + \varepsilon_4 \quad (13) - \text{Medição endógena 4}$$

Finalmente, o último conjunto apresenta as equações estruturais e trata da relação entre as variáveis latentes endógenas (η) e exógenas (ξ) na Equação (14) e na Equação (15), respectivamente.

$$\eta_1 = \gamma_{11}\xi_1 + \zeta_1 \quad (14) - \text{Equação estrutural 1}$$

$$\eta_2 = \beta_{21}\eta_1 + \gamma_{21}\xi_1 + \gamma_{22}\xi_2 + \gamma_{23}\xi_3 + \zeta_2 \quad (15) - \text{Equação estrutural 2}$$

Em contraste com as equações formuladas, os termos de distúrbios ζ não refletem erros de medição, mas sim distúrbios aleatórios ou erros nas equações. Esse termo indica que as variáveis independentes não explicam perfeitamente as variáveis dependentes ou endógenas (DIAMANTOPOULOS, 1994).

2.5.4. Estimação de modelos de trajetória na variante PLS-SEM

Um resumo das distintas abordagens de PLS-SEM ou CB-SEM é apresentada em (FORNELL; BOOKSTEIN, 1982). Segundo os autores as escolhas não são arbitrárias nem diretas. Ambos se aplicam à mesma classe de modelos - equações estruturais com variáveis não observáveis e erro de medição - mas eles têm estruturas e objetivos diferentes. A CB-SEM, associada ao acrônimo LISREL (*Linear Structural Relations*) o qual também dá nome ao software de modelagem LISREL, tenta explicar as covariâncias observadas, enquanto a PLS-SEM tenta explicar as variâncias (de variáveis observadas e/ou não observadas). A CB-SEM oferece precisão estatística no contexto de suposições rigorosas, já a eficiência dos parâmetros da PLS-SEM oferece precisão de predição, simplicidade e menos suposições. Ambos os modelos tratam os resíduos da medição, mas de maneiras diferentes. PLS-SEM separa a variação "irrelevante" da parte estrutural do modelo e CB-SEM combina variação específica e erro de medição em uma única estimativa e ajusta a atenuação. Além disso, a CB-SEM requer amostras relativamente grandes para estimativa precisa e relativamente poucas variáveis e constructos para convergência; o PLS-SEM é aplicável a amostras menores em estimativas e testes de teoria e parece convergir rapidamente mesmo para modelos complexos com muitas variáveis e constructos.

Henseler, Ringle e Sinkovics (2009) e Hair *et al.* (2019) sugerem ainda as seguintes razões para utilizar a PLS-SEM:

- Quando a análise se preocupa em testar uma estrutura teórica a partir de uma perspectiva de predição.
- O modelo estrutural é complexo e inclui muitos constructos, indicadores e / ou relacionamentos do modelo.
- O objetivo da pesquisa é entender melhor o aumento da complexidade, explorando extensões teóricas de teorias estabelecidas (pesquisa exploratória para o desenvolvimento da teoria).
- Quando o modelo de trajetória inclui um ou mais constructos medidos formativamente.
- A pesquisa consiste em índices financeiros ou tipos semelhantes de artefatos de dados.
- A pesquisa é baseada em dados secundários, que podem não ter uma fundamentação abrangente da teoria da medição.

- Quando uma população pequena restringe o tamanho da amostra (por exemplo, pesquisa entre empresas); mas o PLS-SEM também funciona muito bem com amostras grandes.
- Quando questões de distribuição são uma preocupação, como falta de normalidade.
- Quando a pesquisa requer scores de variáveis latentes para análises de acompanhamento.
- As motivações mais importantes são a exploração e a predição, pois a modelagem de trajetória PLS é recomendada em um estágio inicial de desenvolvimento teórico, a fim de testar e validar modelos exploratórios.
- Outro recurso poderoso da modelagem PLS é que ela é adequada para pesquisas orientadas à predição. Dessa forma, a metodologia auxilia pesquisadores que se concentram na explicação de constructos endógenos.
- A modelagem PLS pode estimar modelos muito complexos com muitas variáveis latentes e manifestas.
- A modelagem PLS possui suposições menos rigorosas sobre a distribuição de variáveis e termos de erro.
- PLS pode lidar com os modelos de medição reflexivos e formativos.

O projeto das escalas de medição de indicadores formativos é um fator importante para a aplicação da PLS-SEM, mesmo com demandas menos exigentes nas escalas de medição, (FORNELL; BOOKSTEIN, 1982). Para capturar completamente o significado de um constructo com medidas formativas, um conjunto o mais completo possível de indicadores é idealmente necessário porque cada indicador é parte do constructo que ele está formando. Assim, uma omissão de indicadores formativos pode restringir o domínio do construto (MACKENZIE; PODSAKOFF; JARVIS, 2005) e se necessária deve ser teoricamente justificada e não puramente baseada em propriedades estatísticas (DIAMANTOPOLOUS; WINKLHOFER, 2001).

Segundo Goodhue, Lewis e Thompson (2006) o tamanho da amostra não deve ser usado como principal razão para empregar PLS-SEM, porque ele não possui grande poder estatístico em um tamanho pequeno de amostra. Eles indicam que o método é poderoso para pequenas amostras quando comparada à CB-SEM. Kahai e Cooper (2003) utilizam um tamanho de amostra igual a 31 e defendem que um benefício importante da PLS-SEM é a sua capacidade de trabalhar com menos dados do que outros pacotes de modelagem estrutural. Os autores indicam que a

mesma pode ser usada em situações em que há pelo menos cinco pontos de dados para cada trajetória (*path*) que leva ao constructo (variável) latente que recebe a maior quantidade de *paths*. A determinação do tamanho apropriado da amostra, mesmo para uma análise confirmatória (CFA) simples, depende de vários fatores, não apenas da magnitude do relacionamento e do nível de poder desejado. De fato, um pesquisador deve considerar as características distributivas dos dados, os possíveis dados ausentes, as propriedades psicométricas das variáveis examinadas e a magnitude das relações consideradas antes de decidir sobre um tamanho de amostra apropriado para estudar os fenômenos (MARCOULIDES; SAUNDERS, 2016).

Chin (1998) sugeriu que um pesquisador que use PLS-SEM deve identificar o tamanho mínimo recomendado de amostra após examinar duas possibilidades: (a) o bloco com o maior número de indicadores formativos (isto é, a maior equação de medição do chamado modo B – ver Quadro 4) ou (b) a variável dependente com o maior número de variáveis independentes afetando-a (isto é, a maior equação estrutural). O autor concluiu dizendo que o requisito de tamanho da amostra seria 10 vezes (a) ou (b), o que for maior. Essa regra prática sobre o tamanho mínimo da amostra necessário pode ser consultada utilizando uma outra abordagem similar, dependendo do número máximo de setas apontando para uma variável latente, conforme especificado no modelo de equações estruturais, de acordo com a Tabela 2. Em apenas em um número limitado de situações com dados distribuídos normalmente seria suficiente aplicar a regra prática de amostragem em PLS, de 10 casos por indicador, pois nem sempre garante estimativas estáveis e não pode ser aplicado indiscriminadamente em todas as situações (KAHAI; COOPER, 2003). Tamanhos de amostra questionáveis também podem fazer com que os erros padrão sejam superestimados ou subestimados. Erros padrão superestimados também podem resultar na perda de efeitos significativos, enquanto erros padrão subestimados podem resultar em exagerar a importância dos efeitos (CHIN; MARCOULIDES, 2013). Comparativamente, um estudo de revisão de literatura sobre uso da metodologia PLS-SEM em educação superior (não especificamente Engenharia) mostraram que o tamanho médio das amostras das diversas pesquisas foi de 315, com mediana de 216, um mínimo de 45 e um máximo de 1186 (GHASEMY *et al.*, 2020).

Tabela 2 - Tamanho de amostra mínimo sugerido em um modelo PLS-SEM

Mínimo tamanho de amostra requerido	Máximo # de setas apontadas para uma variável latente do modelo
52	2
59	3
65	4
70	5
75	6
80	7
84	8
88	9
91	10

Fonte: Adaptado de Marcoulides e Saunders (2016)

Ainda persistem críticas na literatura sobre a técnica PLS-SEM ser efetivamente um método de modelagem de equações estruturais (e.g. RÖNKKÖ; EVERMANN, 2013), mas diversos contrapontos são mostrados confirmando a aceitação, o acréscimo na sua utilização e o desenvolvimento continuado da PLS-SEM como uma técnica robusta para análise multivariada; (DENNIS COOK; FORZANI, 2020; HENSELER *et al.*, 2014).

2.5.4.1. O algoritmo original do PLS-SEM

A estimativa do modelo PLS-SEM baseia-se em uma abordagem em três estágios que pertence à família de algoritmos de mínimos quadrados alternados (MATEOS-APARICIO, 2011). O Quadro 4 ilustra o algoritmo PLS-SEM como apresentado por Lohmöller (1989) e detalhado por Henseler (2010) e Sarstedt; Ringle e Hair (2017a). O algoritmo começa com um estágio de inicialização no qual estabelece escores preliminares das variáveis latentes. Para calcular esses escores, o algoritmo normalmente usa a unidade de peso (ou seja, 1) para todos os indicadores nos modelos de medição.

Quadro 4 - Algoritmo Básico da PLS-SEM

Inicialização			
Estágio 1	Estimação iterativa de pesos e escores das variáveis latentes	Começando no passo#4 Repita os passos de 1 a 4 até a convergência ser obtida	
Passo#1	Pesos Internos (obtidos através do esquema de ponderação dos fatores)	$V_{ji} = \begin{cases} cov(Y_j; Y_i) \\ 0 \end{cases}$	$\begin{cases} \text{se } Y_j e Y_i \text{ são adjacentes;} \\ \text{se não forem.} \end{cases}$
Passo#2	Aproximação Interna	$\tilde{Y}_j := \sum_i b_{ji} Y_i$	

Passo#3	Pesos externos, resolver para:	$\tilde{Y}_{jn} = \sum_{kj} \tilde{w}_{kj} x_{kjn} + d_{jn}$	<i>Em um bloco Modo A</i>
		$x_{kjn} = \tilde{w}_{kj} \tilde{Y}_{jn} + e_{kjn}$	<i>Em um bloco Modo B</i>
Passo#4	Aproximação Externa	$Y_{jn} := \sum_{kj} \tilde{w}_{kj} x_{kjn}$	
Estágio 2	Estimação de pesos externos, cargas fatoriais externas e coeficientes de trajetória		
Estágio 3	Estimação de Parâmetros de localização		

Fonte: Adaptado de LOHMÖLLER, 1989, p. 29

O Estágio 1 do algoritmo PLS-SEM determina iterativamente os pesos internos e escores das variáveis latentes por meio de um procedimento de quatro etapas, consistente com o algoritmo original. Os pesos internos se referem aos coeficientes da trajetória, enquanto os pesos externos e cargas fatoriais externas se referem a pesos e cargas de indicadores nos modelos de medição. O passo 1 usa os escores das variáveis latentes iniciais do algoritmo para determinar os pesos internos b_{ji} entre as variáveis latentes adjacentes Y_j (ou seja, a dependente) e Y_i (ou seja, a independente) no modelo estrutural. A literatura sugere três abordagens para determinar os pesos internos (CHIN, 1998; LOHMÖLLER, 1989; TENENHAUS *et al.*, 2005). No esquema de ponderação pelo centroide (*centroid weighting*), os pesos internos são definidos como +1 se a covariância entre Y_j e Y_i for positiva e -1 se essa covariância é negativa. Caso duas variáveis latentes não estejam conectadas, o peso é definido como zero. No esquema de ponderação fatorial (*factor weighting*), o peso interno corresponde à covariância entre Y_j e Y_i e é definido como zero, caso as variáveis latentes não estejam conectadas. Finalmente, o esquema de ponderação da trajetória (*path weighting*) leva em consideração a direção dos relacionamentos do modelo interno. Como resultado, o esquema de ponderação da trajetória leva a valores de R^2 um pouco mais altos para as variáveis latentes em comparação com outros esquemas e, portanto, deve ser preferido.

Na maioria dos casos, no entanto, a escolha do esquema de ponderação interna tem muito pouca influência nos resultados. O passo 2, a aproximação interna, calcula *proxies* (i.e. substitutos) para todas as variáveis latentes \tilde{Y}_j utilizando a soma ponderada dos escores de suas variáveis latentes adjacentes Y_j . Então, para todos os indicadores nos modelos de medição, o passo 3 calcula novos pesos externos, indicando a força do relacionamento entre cada variável latente \tilde{Y}_j e seus indicadores correspondentes. Para fazer isso, o algoritmo PLS-SEM usa dois diferentes modos de estimativa. Ao usar o Modo A (ou seja, pesos das correlações), a correlação bivariada

entre cada indicador e o constructo determina os pesos externos. Por outro lado, o Modo B (isto é, pesos de regressão) calcula os pesos dos indicadores regredindo cada constructo sobre os seus indicadores associados.

Por padrão, a estimativa de constructos reflexivos baseia-se no Modo A, enquanto o PLS-SEM usa o Modo B para constructos formativamente especificados. O Quadro 4 mostra a representação formal desses dois modos, onde: x_{k_jn} representa os dados brutos para o indicador k ($k = 1, \dots, K$) da variável latente j ($j = 1, \dots, J$) e observação n ($n = 1, \dots, N$), \tilde{Y}_{jn} são os escores das variáveis latentes da aproximação interna no passo 2; \tilde{w}_{kj} são os pesos externos do passo 3, d_{jn} é o erro termo de uma regressão bivariada; e e_{k_jn} é o termo de erro de uma regressão múltipla. Os pesos atualizados do passo 3 (ou seja, \tilde{w}_{kj}) e os indicadores (ou seja, x_{k_jn}) são linearmente combinados para atualizar os escores das variáveis latentes (ou seja, \tilde{Y}_{jn}) no passo 4 (aproximação externa). Observa-se que o algoritmo PLS-SEM usa dados padronizados como entrada e sempre padroniza os escores das variáveis latentes geradas nos passos 2 e 4. Após o passo 4, uma nova iteração é iniciada; o algoritmo termina quando os pesos obtidos do passo 3 mudam marginalmente de uma iteração para a próxima (normalmente de 1×10^{-7} , ou quando o número máximo de iterações é alcançado (normalmente 300). Os estágios 2 e 3 usam os escores das variáveis latentes finais do estágio 1 como entrada para uma série de regressões ordinárias de mínimos quadrados. Essas regressões produzem as cargas fatoriais externas finais, pesos externos e coeficientes da trajetória, bem como elementos relacionados, como efeitos indiretos e totais, valores R^2 das variáveis latentes endógenas e correlações de indicadores e variáveis latentes (LOHMÖLLER, 1989).

2.5.5. A formulação do modelo PLS-SEM

Os modelos de trajetória PLS podem conter duas formas diferentes de medição do constructo: modelos baseados em fatores ou modelos compostos, baseados em compósitos (RIGDON, 2012). O modelo de fatores supõe que a variância de um conjunto de indicadores possa ser perfeitamente explicada pela existência de uma variável não observada (o fator comum) e erro aleatório individual. É o modelo padrão de pesquisa comportamental. Na Figura 7, os constructos exógenos $\xi_1 \dots \xi_3$ e o constructo endógeno η_1 são modelados como fatores. Em contraste, o constructo endógeno η_2 é modelado como um compósito formado com as

combinações lineares de seus respectivos indicadores $y_4 \dots y_8$. O modelo composto não impõe restrições às covariâncias entre indicadores do mesmo construto, ou seja, relaxa a suposição de que toda a covariância entre um bloco de indicadores é explicada por um fator comum (HENSELER; HUBONA; RAY, 2016).

Os compósitos servem como *proxies* (substitutos) para o conceito científico sob investigação (KETTERLINUS *et al.*, 1989; MARAUN; HALPIN, 2008; (RIGDON, 2012; TENENHAUS, 2008). O fato de os modelos baseados em compósitos serem menos restritivos que os modelos baseados em fatores, torna provável que eles tenham um ajuste geral mais alto no modelo (LANDIS; BEAL; TESLUK, 2000). Métodos SEM baseados em compósitos, como PLS-SEM usam a variância total para desenvolver combinações lineares de indicadores para formar as variáveis compostas que representam empiricamente as variáveis conceituais (HWANG *et al.*, 2019; KHAN *et al.*, 2019). De acordo com Henseler; Hubona e Ray (2016), o modelo estrutural consiste em constructos exógenos e endógenos, bem como a relações entre eles. Presume-se que os valores de constructos exógenos sejam dados de fora do modelo.

Assim, variáveis exógenas não são explicadas por outros constructos no modelo e não deve haver nenhuma seta no modelo estrutural que aponte para constructos exógenos. Por outro lado, constructos endógenos são pelo menos parcialmente explicados por outros constructos no modelo. Cada constructo endógeno deve ter pelo menos uma seta do modelo estrutural apontando para ele. As relações entre os constructos são geralmente assumidas como lineares, mas podem não ser. O tamanho e o significado das relações de trajetória são tipicamente o foco dos esforços científicos perseguidos na pesquisa empírica. A especificação do modelo PLS-SEM é similar ao CB-SEM, com algumas particularidades ilustradas na Figura 7. Para os modelos de medição isso implica em decisões para modelos de compósitos ou fatores e atribuição de indicadores aos constructos. Modelos baseados em fatores são predominantes para constructos comportamentais, como atitudes ou traços de personalidade. Os modelos de fatores estão fortemente ligados à teoria dos escores verdadeiros (MCDONALD, 1996), o paradigma de medição mais importante nas ciências do comportamento. Nela se assume que os termos de erro entre as medições não são correlacionados. Por exemplo, se os participantes estiverem concluindo um conjunto de medições (por exemplo, inteligência lógica e comprometimento), os termos de erro em cada uma dessas medições não são relacionados. Se um constructo tiver esse histórico e for provável que um erro de medição aleatório seja um problema, os analistas

devem escolher o modelo de fator. Os compósitos ajudam a modelar constructos emergentes, para os quais os elementos são combinados para formar uma nova entidade.

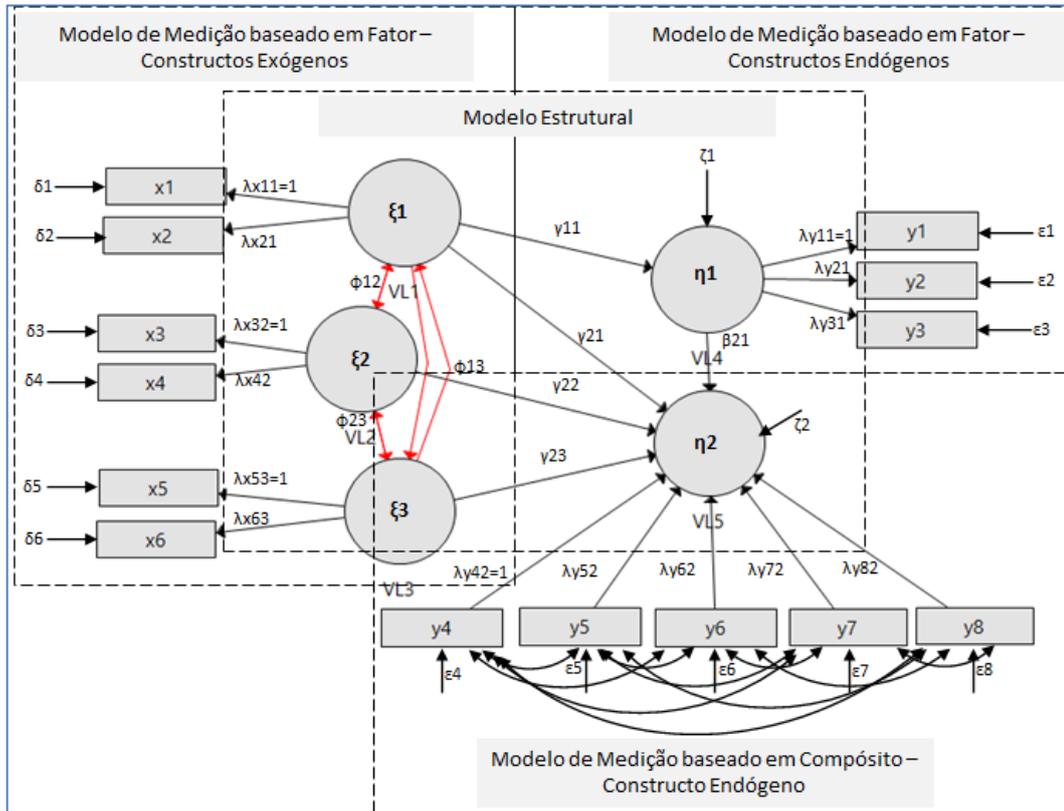


Figura 7 - Modelo PLS-SEM de Fator e Compósito (Mixed Model)

Os compósitos podem ser aplicados para modelar conceitos fortes, ou seja, a abstração de artefatos, que são objetos feitos pelo homem (HOÖK; LOWGREN, 2012). Artefatos típicos podem incluir inovações, tecnologias, sistemas, processos, estratégias, aprendizagem, instrumentos de gerenciamento ou portfólios. Sempre que um modelo contém esse tipo de constructo, é preferível optar por usar um modelo baseado em compósitos. Os modelos de medição dos modelos de trajetória PLS podem parecer menos detalhados do que os de SEM baseado em covariância, mas, de fato, algumas especificações estão implícitas e não são visualizadas. Por exemplo, nem os erros de indicadores únicos (nem suas correlações) dos modelos de fatores nem as correlações entre os indicadores de modelos de compósitos são desenhadas. Como o PLS atualmente não permite restringir esses parâmetros nem liberar as correlações de erro dos modelos de fatores, por convenção, esses elementos do modelo não são desenhados. Independentemente do tipo de medição escolhido para medir um constructo, o PLS exige que exista pelo menos um indicador disponível. Constructos sem indicadores, as

chamadas variáveis fantasmas não podem ser incluídas nos modelos de trajetória PLS (RINDSKOPF, 1984).

A ideia básica do PLS é bastante direta. Em primeiro lugar, as relações de peso, que vinculam os indicadores às suas respectivas variáveis não observáveis, são estimadas. Em segundo lugar, os valores das observações para cada variável não observável são calculados, com base na média ponderada de seus indicadores, usando as relações de peso como entrada. Finalmente, esses valores de observação são usados em um conjunto de equações de regressão para determinar os parâmetros para as relações estruturais, sendo portanto a estimativa das relações de peso a parte mais crucial de uma análise PLS (FORNELL; BOOKSTEIN, 1982).

Observa-se que seria mais fácil simplesmente assumir pesos iguais para todos os indicadores, mas essa abordagem tem desvantagens. Não existiria uma justificativa teórica para que todos os indicadores tenham o mesmo peso. Como se pode supor que as estimativas de parâmetros resultantes do modelo estrutural dependem do tipo de ponderação utilizado, pelo menos enquanto o número de indicadores não for excessivamente grande (MCDONALD, 1996), a suposição (exógena) de igualdade de pesos torna os resultados altamente arbitrários. Além disto, esse procedimento não leva em conta o fato de que alguns indicadores podem ser mais confiáveis que outros e, portanto, devem receber pesos mais altos (CHIN; MARCOLIN; NEWSTED, 2003).

Conseqüentemente, o PLS usa um processo de estimativa em duas etapas, mais complexo, para determinar os pesos (w_i): primeiro, ele começa com uma aproximação externa; nesse caso, os valores para cada variável latente (por exemplo, η_1 na Figura 7) são estimados, com base na média ponderada de seus respectivos indicadores (por exemplo, $\eta'_1 = w_1y_1 + w_2y_2 + w_3y_3$). Os pesos utilizados para calcular essa agregação são determinados de maneira semelhante à análise de componentes principais para análise reflexiva ou de regressão para indicadores formativos (CASSEL; HACKL; WESTLUND, 1999). Na próxima etapa, na aproximação interna, os valores das aprimorados das observações são determinados como uma média ponderada das variáveis latentes vizinhas (por exemplo, $\eta''_2 = w_4\eta'_1 + w_5\xi'_1 + w_6\xi'_2 + w_7\xi'_3$). Para esse processo, existem três esquemas de ponderação diferentes disponíveis (LOHMÖLLER, 1989): esquema de ponderação de centroide, fator e trajetória; mas pode-se demonstrar que a escolha entre eles tem apenas um impacto menor nos resultados finais.

Usando esta segunda estimativa dos valores dos casos, as relações de peso são modificadas (por exemplo, $\eta_2'' = w_1'y_1 + w_2'y_2 + w_3'y_3$) e o processo de aproximação interna e externa começa novamente e é repetido até que a convergência dos valores das observações (*case values*) seja alcançada (CASSEL; HACKL; WESTLUND, 1999). Nesse mesmo estudo, usando uma simulação de Monte Carlo, os autores mostraram que o PLS é bastante robusto no que diz respeito a várias inadequações (por exemplo, assimetria ou multicolinearidade dos indicadores e especificação incorreta do modelo estrutural) e que os escores das variáveis latentes sempre estão em conformidade com os valores reais.

Uma adaptação do algoritmo da modelagem PLS ordinária é o PLS consistente (*consistent PLS*) ou PLSc (HENSELER; DIJKSTRA, 2015; RIGDON; RINGLE; SARSTEDT, 2010; SARSTEDT *et al.*, 2014b; SHARMA *et al.*, 2018). O PLSc permite corrigir o chamado viés do PLS e, assim, imita os resultados baseados no modelo de fator CB-SEM (HENSELER; DIJKSTRA, 2015). Acredita-se que o uso do PLSc ajude a retificar os resultados inconsistentes, gerados pelo algoritmo tradicional do PLS. Essas inconsistências são em relação às estimativas, ou seja, valores reais desproporcionais quando um aumento no tamanho da amostra é observado. O PLSc não apenas estima os coeficientes de trajetória, correlações entre constructos e cargas de indicadores em modelos reflexivos de forma consistente, mas também é esperado que atinja os valores verdadeiros assintoticamente. Em outras palavras, o PLSc corrige as correlações entre constructos para uma atenuação de modo que as estimativas de coeficientes de trajetória e cargas fatoriais se tornem consistentes em comparação com as estimativas do PLS tradicional (HENSELER; DIJKSTRA, 2015). Nesse tipo de situação, pode-se utilizar o índices de ajuste para avaliar o modelo, tais como a raiz quadrada média residual padronizada (SRMR) e outras medidas de ajuste (HENSELER *et al.*, 2014).

2.5.6. Etapas para aplicação da abordagem PLS-SEM

Ao aplicar o PLS-SEM os pesquisadores precisam seguir um processo de várias etapas que envolve a especificação dos modelos interno e externo, coleta e exame de dados, a estimativa real do modelo e a avaliação dos resultados. A aplicação gira em torno dos quatro passos mais relevantes:

(1) especificação do modelo;

- (2) avaliação do modelo externo (Medição);
- (3) avaliação do modelo interno (Estrutural); e
- (4) Análise de robustez.

Sarstedt, Ringle e Hair (2017) fornecem uma introdução detalhada de cada uma das etapas que é resumida nas subseções a seguir.

2.5.6.1. Especificação do modelo

A Figura 8 ilustra de forma didática os conceitos já abordados até aqui que permitem o passo a passo para especificar o modelo. O estágio de especificação do modelo lida com a configuração dos modelos interno e externo. O modelo interno, ou modelo estrutural, exhibe os relacionamentos entre os constructos sendo avaliados. O modelo externo, também conhecidos como modelo de medição, é usado para avaliar as relações entre as variáveis indicadoras e seus correspondentes constructos.

A primeira etapa do uso do PLS-SEM envolve a criação de um *path model* (modelo de trajetórias) que conecta variáveis e constructos baseados em teoria e lógica. Ao criar um modelo de trajetórias como o mostrado na Figura 8, é importante distinguir a localização dos constructos, bem como as relações entre eles. Os constructos podem ser considerados como variáveis exógenas ou endógenas. Enquanto constructos exógenos atuam como variáveis independentes e não tem uma seta apontando para eles (Y_1 , Y_2 e Y_3 na Figura 8), constructos endógenos são explicados por outros constructos (Y_4 e Y_5 na Figura 8). Embora muitas vezes considerada como variável dependente dentro do relacionamento, constructos endógenos podem também atuar como variáveis independentes quando são colocadas entre dois constructos (Y_4 na Figura 8). Ao estabelecer o modelo, os pesquisadores precisam estar cientes de que, em sua forma básica, o algoritmo PLS-SEM pode lidar apenas com modelos que não têm relação circular entre os constructos. Esse requisito seria violado se revertêssemos o relacionamento $Y_2 \rightarrow Y_5$ na Figura 8. Nesta situação, Y_2 prediria Y_4 , Y_4 prediria Y_5 e Y_5 prediria Y_2 novamente, produzindo um *loop* circular (ou seja, $Y_2 \rightarrow Y_4 \rightarrow Y_5 \rightarrow Y_2$).

Após a concepção do modelo interno, o pesquisador deve especificar o modelo externo. Esta etapa requer que o pesquisador tome várias decisões, como usar uma escala de itens múltiplos

ou de itens únicos (DIAMANTOPOULOS *et al.*, 2012) ou se deve especificar o modelo externo de maneira reflexiva ou formativa (DIAMANTOPOULOS; WINKLHOFER, 2001). A especificação precisa do modelo externo é crucial porque os relacionamentos hipotetizados no modelo interno são tão válidos e confiáveis quanto o modelo externo. Na Figura 8, Y_1 e Y_2 são medidos formativamente, enquanto todos os outros constructos têm uma especificação de medição reflexiva. Nesta ilustração simples, todos os constructos têm um número igual de itens. No entanto, em pesquisa aplicada, o número de itens por constructo pode ser muito maior, especialmente quando estão envolvidas medidas formativas, pois estas por definição, precisam capturar o domínio inteiro do constructo (DIAMANTOPOULOS; WINKLHOFER, 2001).

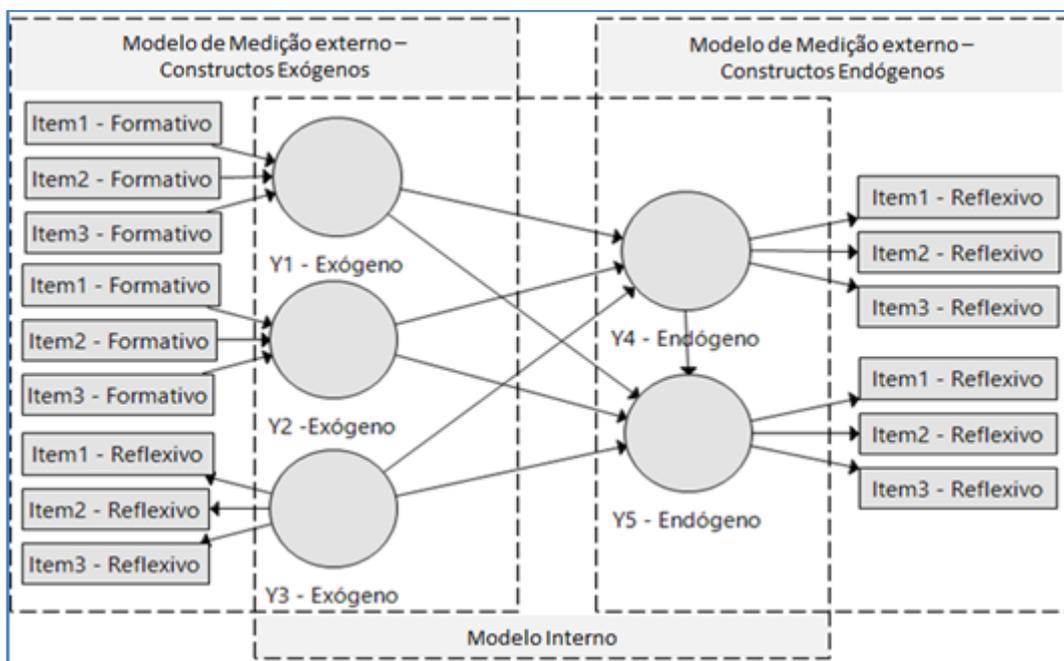


Figura 8 - Exemplo de Modelo PSL-SEM - Aplicação

2.5.6.2. Avaliação do modelo externo

Depois que os modelos interno e externo forem especificados, a próxima etapa será executar o algoritmo PLS-SEM (HENSELER; NOONAN, 2017) e, com base nos resultados, avaliar a confiabilidade e a validade das medidas do constructo no modelo externo. Iniciando com a avaliação do modelo externo, o pesquisador pode confiar que os constructos que formam a base para a avaliação das relações do modelo interno, são medidos e representados com precisão. Ao avaliar o modelo externo, o pesquisador deve distinguir entre constructos com medidas reflexivas e formativas (SARSTEDT; RINGLE; HAIR, 2017b). As duas abordagens de

medição são baseadas em conceitos diferentes e, portanto, requerem considerações para diferentes medidas avaliativas.

a) Indicadores reflexivos: Os indicadores reflexivos constituem um conjunto representativo de todos os itens possíveis dentro do domínio conceitual de um constructo (DIAMANTOPOULOS; WINKLHOFER, 2001). Como resultado, itens reflexivos são intercambiáveis, altamente correlacionados e capazes de serem omitidos sem alterar o significado do constructo. Indicadores reflexivos estão ligados a um constructo através de cargas fatoriais, que são as correlações bivariadas entre o indicador e o constructo. Ao avaliar modelos externos reflexivos, os pesquisadores devem verificar a confiabilidade e a validade.

O primeiro passo é usar a confiabilidade composta para avaliar a confiabilidade da consistência interna das medidas do constructo. O próximo passo envolve a avaliação da confiabilidade da consistência interna dos constructos. Ao usar o PLS-SEM, a confiabilidade da consistência interna é geralmente avaliada usando a confiabilidade composta ρ_c (JÖRESKOG, 1973), que é definida na forma da Equação (16) (para dados padronizados):

$$\rho_c = \frac{(\sum_{k=1}^K l_k)^2}{(\sum_{k=1}^K l_k)^2 + \sum_{k=1}^K var(e_k)} \quad (16) - \text{Confiabilidade composta}$$

onde l_k simboliza a carga fatorial externa padronizada da variável indicadora k de um constructo específico medido com indicadores K , e_k é o erro de medição de cada variável indicadora k e $var(e_k)$ denota a variância do erro de medição, que é definido como $1 - l_k^2$. Usando a confiabilidade composta, o PLS-SEM pode acomodar diferentes indicadores de confiabilidade (ou seja, diferenças nas cargas fatoriais dos indicadores), além de evitar a subestimação associada ao α de Cronbach.

Os pesquisadores devem avaliar a significância e a relevância de cada indicador e avaliar o erro padrão. Como o PLS-SEM não assume uma distribuição normal, o pesquisador pode aplicar a rotina de *Bootstrapping* para determinar o nível de significância da carga de cada indicador. *Bootstrapping* é uma técnica de reamostragem que extrai uma grande quantidade de subamostras dos dados originais (com substituição) e estima os modelos para cada subamostra.

Dessa forma, o pesquisador obtém um grande número (tipicamente 5.000 ou mais) de estimativas, que podem ser usadas para calcular um erro padrão de cada parâmetro do modelo.

O segundo passo na avaliação de indicadores reflexivos é a avaliação da validade. A validade é examinada observando-se a validade convergente e a validade discriminante de um constructo. Existe sustentação para a validade convergente quando cada item possui carga fatorial acima de 0,70 e quando a variância média extraída (AVE) de cada constructo é 0,50 ou superior. O AVE é o valor médio global do quadrado das cargas fatoriais de um conjunto de indicadores (HAIR JR. *et al.*, 2014) como mostrado na Equação (17); e é equivalente à comunalidade (*commonality*) de um constructo:

$$AVE = \frac{(\sum_{k=1}^K l_k^2)}{K} \quad (17) - AVE$$

onde l_k são as cargas fatoriais dos K indicadores. De maneira sucinta, um AVE de 0,50 mostra que o constructo explica mais da metade da variância de seus indicadores. A validade discriminante representa até que ponto o constructo é empiricamente distinto de outros constructos ou, em outras palavras, o constructo mede o que se pretende medir. Um método para avaliar a existência de validade discriminante é o critério de Fornell e Larcker (1981). Este método declara que o constructo compartilha mais variância com seus indicadores do que com qualquer outro constructo. Para testar esse requisito, a AVE de cada constructo deve ser maior que a maior correlação com qualquer outro constructo elevada ao quadrado.

A segunda opção para verificar a validade discriminante é examinando as cargas cruzadas dos indicadores. Este método, geralmente considerado mais liberal (HENSELER; RINGLE; SINKOVICS, 2009), exige que as cargas fatoriais de cada indicador em seu constructo sejam superiores às cargas cruzadas com outros constructos. A avaliação da validade discriminante no PLS-SEM envolve a análise do critério ou razão HTMT (*HeteroTrait_MonoTrait Ratio* – Razão de Hétero traço_Monotraço) de correlações (HENSELER; RINGLE; SARSTEDT, 2015). O critério HTMT é definido como o valor médio das correlações de indicadores entre constructos (1ª. parte da Equação (18), antes do sinal de divisão) em relação à média (geométrica) das correlações médias de indicadores que medem o mesmo constructo (2ª. parte da Equação (18)). O HTMT dos constructos Y_i e Y_j com, respectivamente, indicadores K_i e K_j é definido na forma da Equação (18):

$$HTMT_{ij} = \frac{1}{K_i K_j} \sum_{g=1}^{k_i} \sum_{h=1}^{k_j} r_{ig,jh} \quad (18) -$$

$$\div \left(\frac{2}{K_i(K_i - 1)} \cdot \sum_{g=1}^{k_i-1} \sum_{h=g+1}^{k_i} r_{ig,ih} \cdot \frac{2}{K_j(K_j - 1)} \cdot \sum_{g=1}^{k_j-1} \sum_{h=g+1}^{k_j} r_{jg,jh} \right)^{1/2} \quad \text{HTMT}$$

onde $r_{ig,jh}$ representa as correlações dos indicadores (isto é, dentro e através dos modelos de medição das variáveis latentes Y_i e Y_j). Baseado em pesquisas anteriores e seus resultados de estudos de simulação, Henseler, Ringle e Sarstedt (2015) sugerem um valor limiar de 0,90 se o modelo de trajetória incluir constructos conceitualmente muito semelhantes (por exemplo, satisfação afetiva, satisfação cognitiva e lealdade). Nessa situação, um valor de HTMT superior a 0,90 sugere uma falta de validade discriminante. No entanto, quando os constructos no modelo de trajetória são conceitualmente mais distintos, os pesquisadores devem considerar 0,85 como limiar para HTMT.

b) Indicadores formativos: Os princípios subjacentes às medidas de indicadores formativos são fundamentalmente diferentes daqueles do tipo reflexivo. Embora a capacidade de PLS-SEM em testar modelos usando indicadores formativos tenha atraído considerável atenção em várias disciplinas, muitos pesquisadores que aplicam o método desconsideram as etapas específicas que precisam ser seguidas na avaliação de um modelo externo formativo (HAIR; RINGLE; SARSTEDT, 2011). Sua avaliação envolve o exame de (1) a convergência (2) colinearidade do indicador e (3) significância estatística e relevância dos pesos dos indicadores. Em primeiro lugar, o pesquisador precisa avaliar a validade de conteúdo das medidas do constructo usando avaliações de especialistas. A validade de conteúdo avalia em que medida os indicadores capturam as principais facetas do constructo. Simplificando, se um item importante for omitido, a natureza do constructo pode ser alterada (DIAMANTOPOULOS *et al.*, 2012).

A avaliação empírica de modelos externos formativos requer avaliação da validade convergente, ou seja, até que ponto uma medida se relaciona com outras medidas do mesmo fenômeno (SARSTEDT; RINGLE; HAIR, 2017). Essa avaliação é feita por meio de uma análise de redundância na qual cada constructo medido formativamente é correlacionado com uma medição alternativa reflexiva ou de item único do mesmo constructo. Consequentemente,

os pesquisadores devem planejar a avaliação da validade convergente na fase de concepção da pesquisa, incluindo uma medida do constructo, ou medida de item único, do constructo medido formativamente no questionário final. Observou-se que itens únicos exibem níveis significativamente mais baixos de validade comparados às escalas de múltiplos itens (SARSTEDT *et al.*, 2016), o que pode ser particularmente problemático ao usar uma técnica de análise baseada em variância, como a PLS-SEM.

Em seguida, os indicadores do modelo externo em cada constructo devem ser testados quanto à colinearidade. Como na regressão múltipla (SARSTEDT; MOOI, 2019), a alta colinearidade entre dois ou mais indicadores pode influenciar seriamente os resultados. Mais precisamente, os pesos que vinculam os indicadores formativos aos constructos (que representam a contribuição de cada indicador ao constructo, controlando a influência de todos os outros indicadores do mesmo constructo) poderiam ser revertidos e o seu significado subestimado como resultado do aumento do erro padrão. A avaliação da colinearidade envolve o cálculo do fator de inflação de variância de cada item ($VIF = \text{Variance Inflation Factor}$) executando uma regressão múltipla de cada indicador no modelo de medição do constructo medido formativamente em todos os outros itens do mesmo constructo. Os valores R^2 da k-ésima regressão facilitam o cálculo do VIF para o k-ésimo indicador, usando a Equação (19):

$$VIF_k = \frac{1}{1 - R_k^2} \quad (19) - \text{VIF}$$

Valores mais altos de R^2 na k-ésima regressão implicam que a variância do k-ésimo item é explicada pelos outros itens no mesmo modelo de medição, o que indica problemas de colinearidade. Da mesma forma, quanto maior o VIF, maior o nível de colinearidade. Os valores de VIF acima de 5 são indicativos de colinearidade entre os indicadores.

Finalmente, os pesquisadores devem avaliar a significância e a relevância de cada indicador formativo, utilizando a rotina de *Bootstrapping* para determinar o nível de significância do peso de cada indicador. Com base no erro padrão, a significância de cada parâmetro pode ser determinada, usando valores-*t*. A avaliação da relevância dos indicadores envolve comparar os pesos dos indicadores para determinar sua contribuição relativa à formação do constructo. Em casos específicos (ou seja, quando o peso do indicador não é significativo), o pesquisador também precisa avaliar a correlação bivariada (carga fatorial) entre o indicador (não

significativo) e o constructo para decidir se deve excluir o indicador do modelo externo (SARSTEDT; RINGLE; HAIR, 2017). Contudo, a eliminação de indicadores formativos do modelo deve geralmente ser a exceção, pois a teoria da medição formativa exige que as medidas capturem completamente todo o domínio de um constructo. Em resumo, omitir um indicador é equivalente a omitir uma parte do constructo.

2.5.6.3. Avaliação do modelo interno

Uma vez que a confiabilidade e a validade do modelo externo sejam estabelecidas, várias etapas precisam ser seguidas para avaliar as relações hipotéticas dentro do modelo interno. Esse aspecto do PLS-SEM é diferente do CB-SEM, pois o modelo usa os dados da amostra para obter parâmetros que melhor preveem o constructo endógeno, em oposição à estimativa de parâmetros que minimizam a diferença entre matriz de covariância da amostra observada e matriz de covariância estimada pelo modelo. Como resultado, o PLS-SEM não possui uma estatística de qualidade de ajuste padrão e esforços anteriores para estabelecer uma estatística correspondente provaram ser altamente problemáticos (HENSELER; SARSTEDT, 2013). Em vez disso, a avaliação da qualidade do modelo é baseada em sua capacidade de prever os constructos endógenos. Os seguintes critérios facilitam essa avaliação: Coeficiente de determinação (R^2), redundância validada de forma cruzada (*cross-validated*) (Q^2), coeficientes de trajetória (*path*) e o tamanho do efeito (f^2). Antes dessa avaliação, o pesquisador precisa testar o modelo interno quanto a possíveis problemas de colinearidade. Como o modelo interno estima resultados com base em conjuntos de análise de regressão, seus valores e significâncias podem estar sujeitos a vieses se os constructos estiverem altamente correlacionados especialmente quando o modelo inclui constructos medidos formativamente (SARSTEDT; RINGLE; HAIR, 2017).

- a) Coeficiente de determinação (R^2): O R^2 é uma medida da predição do modelo. Outra maneira de visualizar o R^2 é que ele representa o efeito combinado das variáveis exógenas sobre as variáveis endógenas. Esse efeito varia de 0 a 1, com 1 representando plena precisão preditiva. Como o R^2 é adotado por uma variedade de disciplinas, os estudiosos devem confiar em uma regra prática "rudimentar" em relação a um R^2 aceitável, tais como 0,75, 0,50 ou 0,25, respectivamente, descrevendo níveis substanciais, moderados ou fracos de precisão preditiva (HAIR; RINGLE; SARSTEDT, 2011; HENSELER; RINGLE; SINKOVICS, 2009). Embora o R^2 seja uma ferramenta valiosa na avaliação da qualidade

de um modelo PLS-SEM a decisão para um modelo deve basear-se no R^2 ajustado, que penaliza o aumento da complexidade do modelo reduzindo o R^2 (ajustado) quando novos constructos são adicionados ao modelo.

- b) Redundância validada de forma cruzada (Q^2): O Q^2 é um meio de avaliar a relevância preditiva do modelo interno. A medida baseia-se em uma técnica de reutilização de amostra chamada *Blindfolding*, que omite uma parte da matriz de dados, estima os parâmetros do modelo e prevê a parte omitida usando as estimativas. Quanto menor a diferença entre os valores previstos e originais maior o Q^2 e, portanto, a precisão preditiva do modelo. Especificamente, um valor Q^2 maior que zero para um constructo endógeno específico indica a relevância preditiva do modelo para esse constructo em particular. No entanto, deve-se notar que enquanto somente comparar o valor de Q^2 a zero é indicativo se um constructo endógeno pode ser previsto, não diz nada sobre a qualidade da predição, que será maior a medida que o índice se afasta positivamente de zero (RIGDON, 2014; SARSTEDT *et al.*, 2014).
- c) Coeficientes de trajetória (*Path Coefficients*): Depois de executar um modelo PLS, são fornecidas estimativas para os coeficientes de trajetória, que representam os relacionamentos hipotéticos que ligam os constructos. Os valores dos coeficientes de trajetória são padronizados em uma faixa de -1 a +1, com coeficientes mais próximo de +1 indicando fortes relacionamentos positivos e coeficientes mais próximos de -1 indicando fortes relacionamentos negativos. Embora valores próximos a +1 e -1 sejam quase sempre estatisticamente significativos, deve-se utilizar o *Bootstrapping* para testar a significância e os erros padrão (HELM; EGGERT; GARNEFELD, 2010). Depois de verificar se as relações são significativas, o pesquisador deve considerar a relevância dos relacionamentos. Em resumo, os tamanhos dos coeficientes estruturais são significativos? Como observado em Sarstedt, Ringle e Hair (2017), muitos estudos ignoram essa etapa e apenas confiam na significância dos efeitos. Se esse passo importante for omitido, os pesquisadores poderão se concentrar em uma relação que, embora significativa, pode ser pequena demais para merecer atenção gerencial.
- d) O algoritmo de predição PLS (PLSPredict) foi desenvolvido por Shmueli *et al.* (2016). O método usa amostras de análise (treinamento) e validação para gerar e avaliar predições a partir das estimativas do modelo de trajetórias PLS. Uma amostra de treinamento é uma

parte do conjunto de dados geral usado para estimar os parâmetros do modelo (por exemplo, os coeficientes de trajetória, pesos dos indicadores e cargas). O PLSpredict executa a validação cruzada de k segmentos. Um segmento é um subgrupo da amostra total e k é o número de subgrupos. Ou seja, o conjunto total de dados é dividido aleatoriamente em k subconjuntos de dados de tamanho igual. Por exemplo, uma validação cruzada com base em $k = 5$ segmentos divide a amostra em cinco subconjuntos de dados de tamanho igual (ou seja, grupos de dados). Em síntese, o PLSpredict combina os subconjuntos $k - 1$ em uma única amostra de análise usada para prever o quinto subconjunto de dados restante. O quinto subconjunto de dados é a amostra de validação para a primeira execução de validação cruzada. Esse processo de validação cruzada é repetido k vezes (neste exemplo, cinco vezes), com cada um dos cinco subconjuntos usados uma vez como referência da amostra.

A recomendação é definir $k = 10$ (SHMUELI *et al.*, 2019), mas os pesquisadores precisam garantir que a análise amostral para cada subconjunto (segmento) atende às diretrizes de tamanho mínimo da amostra. Além disso, outros critérios para avaliar a predição fora da amostra (ou seja, a precisão de um modelo ao prever o valor do resultado de novos casos) sem usar uma amostra de validação são disponíveis, como o critério de informação bayesiano (BIC) e critério Geweke e Meese (a serem calculados na comparação de modelos). O índice para avaliação é o $Q_{predict}^2$. A interpretação dos resultados do valor de $Q_{predict}^2$ é semelhante à dos valores de Q^2 obtidos pelo procedimento de *Blindfolding*. Se o valor de $Q_{predict}^2$ for positivo, o erro de predição dos resultados do PLS-SEM é menor do que o erro de predição utilizando os valores médios; e a precisão da predição aumenta à medida que os erros de predição diminuem. Nesse caso, os modelos PLS-SEM oferecem melhor desempenho preditivo. Outras abordagens estão sendo incorporadas ao algoritmo PLSpredict para avaliar o poder preditivo de um modelo utilizando um método linear de regressão (LM) para gerar predições para as variáveis manifestas, executando uma regressão de cada um dos indicadores do constructo dependente sobre os indicadores do constructo exógeno. Essas predições são comparadas ao erro absoluto médio (MAE – *Mean Absolute Error*) que mede a magnitude média dos erros em um conjunto de predições sem considerar sua direção (acima ou abaixo) ou a raiz do erro quadrático médio (RMSE), que é definido como a raiz quadrada da média das diferenças quadráticas entre as predições e as observações reais (SHMUELI *et al.*, 2019):

e) Tamanho do efeito (f^2): O tamanho do efeito para cada modelo de trajetória pode ser determinado calculando o f^2 de Cohen. O índice é calculado observando-se a mudança em R^2 quando um constructo específico é eliminado do modelo. Para calcular f^2 , o pesquisador deve estimar dois modelos de trajetória PLS. O primeiro modelo deve ser o modelo completo, conforme especificado pelas hipóteses, produzindo o R^2 do modelo completo (ou seja, R^2 completo). O segundo modelo deve ser idêntico, exceto que um constructo exógeno selecionado é eliminado do modelo, produzindo o R^2 do modelo reduzido (isto é, R^2 reduzido). Com base no valor f^2 , o tamanho do efeito do constructo omitido para um constructo endógeno particular pode ser determinado de tal forma que 0,02, 0,15 ou 0,35 representem efeitos pequenos, médios e grandes, respectivamente (COHEN, 1988). Ou seja, se um constructo exógeno contribuir fortemente para explicar um constructo endógeno, a diferença entre R^2 completo e R^2 reduzido será alta, levando para um alto valor de f^2 . O tamanho do efeito pode ser calculado usando a Equação (20):

$$f^2 = \frac{R^2_{\text{completo}} - R^2_{\text{reduzido}}}{1 - R^2_{\text{reduzido}}} \quad (20) - \text{Tamanho do efeito}$$

2.5.6.4. Robustez

A análise de robustez leva em conta alguns índices e critérios resumidos a seguir.

- a) CTA-PLS dos Modelos de medição: Em termos de modelos de medição, a análise de confirmação tétrede (CTA-PLS) permite fundamentar empiricamente a especificação de modelos de medição, ou seja, reflexivo versus formativo (GUDERGAN *et al.*, 2008). O CTA-PLS se baseia no conceito de tétredas que descrevem a diferença do produto de um par de covariâncias do produto de outro par de covariâncias (BOLLEN; TING, 2000). Em um modelo de medição reflexivo, essas tétredas devem ser zeradas, pois se supõe que os indicadores vêm do mesmo domínio. Essa seria a hipótese nula do teste. Ao contrário, se uma das tétredas de um constructo for significativamente diferente de zero, rejeita-se a hipótese nula ($p < 0,05$) e assume-se uma medida formativa em vez de reflexiva na especificação daquele modelo. Note-se, no entanto, que o CTA-PLS é um teste empírico de modelos de medição e o método principal para determinar a especificação de um modelo reflexivo ou formativo é o raciocínio teórico (HAIR JR. *et al.*, 2017).

- b) Efeitos não lineares no Modelo estrutural: Para testar se os relacionamentos não são lineares, os pesquisadores podem executar o teste de erro de especificação, dado pela equação de regressão de Ramsey (RAMSEY, 1969), nas pontuações das variáveis latentes nas regressões parciais do modelo de trajetórias. Uma estatística de teste significativa em qualquer uma das regressões parciais indica um potencial efeito não-linear. Além disso, os pesquisadores podem estabelecer um termo de interação para mapear um efeito não linear em um modelo e testar sua significância estatística usando *Bootstrapping* (SVENSSON *et al.*, 2018). Alguns softwares de apoio possuem saídas gráficas que ajudam o pesquisador a visualizar as relações não lineares possíveis entre as variáveis.
- c) Endogeneidade do Modelo Estrutural: Quando a perspectiva da pesquisa é principalmente explicativa, os pesquisadores devem testar a endogeneidade. A endogeneidade geralmente ocorre quando os pesquisadores omitiram um constructo que se correlaciona com um ou mais constructos preditores e com o constructo dependente, em uma regressão parcial do modelo de trajetórias PLS. Para avaliar e tratar endogeneidade, os pesquisadores devem seguir o procedimento sistemático de Hult (HULT *et al.*, 2018), iniciando com a aplicação da abordagem de cópula gaussiana de Park e Gupta (PARK; GUPTA, 2012). Se a abordagem indica uma questão de endogeneidade, os pesquisadores devem implementar variáveis instrumentais que estão altamente correlacionados com os constructos independentes, mas não estão correlacionados com o termo de erro do constructo dependente para explicar as fontes de endogeneidade (BASCLE, 2008). É importante ressaltar, no entanto, que a avaliação da endogeneidade só é relevante quando o foco do pesquisador está na explicação do modelo e não em objetivos preditivos.
- d) Heterogeneidade não observada do modelo estrutural: Além dos subgrupos de dados originados da heterogeneidade observada e previamente projetada na coleta de dados pelo pesquisador, no caso desta pesquisa, os dois subgrupos que foram submetidos a níveis distintos de AA e supostamente resultaram em níveis distintos de aprendizagem, a heterogeneidade não observada ocorre quando existem subgrupos de dados não conhecidos à priori e que podem produzir estimativas de modelo substancialmente diferentes. Se for esse o caso, estimar o modelo com base em todo o conjunto de dados provavelmente produzirá resultados menos precisos (BECKER; RAI; RIGDON, 2013). Portanto, qualquer análise PLS-SEM deve incluir uma verificação de rotina para verificar a heterogeneidade não observada e se a análise de todo o conjunto de dados é ou não razoável. Sarstedt, Ringle

e Hair (2017b) propuseram um procedimento sistemático para identificar e tratar a heterogeneidade não observada. Utilizando critérios de informação derivados de uma mistura finita PLS (HAHN *et al.*, 2002), os pesquisadores podem identificar o número de segmentos a serem extraídos dos dados (se existir algum).

Se a heterogeneidade estiver presente e for teoricamente fundamentada, o próximo passo envolve a execução do procedimento POS - Segmentação Orientada por PLSpredict (BECKER; RAI; RIGDON, 2013) para descobrir a estrutura de segmentos dos dados. Diferente do FIMIX que é paramétrico, o POS é não paramétrico e não assume a normalidade dos dados. Finalmente, os pesquisadores devem tentar identificar variáveis explicativas adequadas que caracterizam os segmentos descobertos, por exemplo, usando tabela de contingência ou análises exaustivas de CHAID (*Chi-squared Automatic Interaction Detector*) (RINGLE; SARSTEDT; MOOI, 2010). Se variáveis explicativas adequadas estão disponíveis, uma análise de variável moderadora (FASSOTT; HENSELER, 2010) ou uma análise multigrupo (CHIN; DIBBERN, 2010), em combinação com uma avaliação de invariância de medição (HENSELER; HUBONA; RAY, 2016), oferece mais descobertas, conclusões e implicações particulares.

A recente evolução no estado da arte da técnica PLS-SEM tem possibilitado critérios mais rígidos na avaliação dos modelos, o que vem também sendo refletido nos softwares estatísticos especializados. A Tabela 3 sumariza alguns dos principais índices e pontos de corte recomendados mais recentemente para avaliação de modelos PLS-SEM (HAIR *et al.*, 2019).

Tabela 3 - Alguns índices recentes recomendados em PLS-SEM

Modelos de medição reflexivos	
Cargas dos indicadores reflexivos	✓ $\geq 0,708$
Confiabilidade da consistência interna	<ul style="list-style-type: none"> ✓ O alfa de Cronbach é o limite inferior, a confiabilidade composta é o limite superior vinculado à confiabilidade da consistência interna. ✓ Mínimo 0,70 (ou 0,60 em pesquisa exploratória). ✓ Máximo de 0,95 para evitar redundância de indicadores x validade do conteúdo. ✓ Recomendado 0,80 a 0,90.
Validade convergente	✓ $AVE \geq 0,50$
Validade discriminante	<ul style="list-style-type: none"> ✓ Para constructos conceitualmente semelhantes: HTMT $< 0,90$. ✓ Para constructos conceitualmente diferentes: HTMT $< 0,85$. ✓ Teste se o HTMT é significativamente menor que o valor limite
Modelos de medição formativos	
Validade convergente (análise de redundância)	✓ $\geq 0,70$ (correlação)
Colinearidade (VIF)	<ul style="list-style-type: none"> ✓ Problemas prováveis (isto é, críticos) de colinearidade quando $VIF \geq 5$. ✓ Possíveis problemas de colinearidade quando $VIF \geq 3 - 5$. ✓ Mostrar idealmente que $VIF < 3$
Significância estatística dos pesos	✓ Valor $p < 0,05$ ou intervalo de confiança de 95%.
Relevância dos indicadores com um peso significativo	✓ Pesos significativos maiores são mais relevantes (contribuem mais).
Relevância dos indicadores com um peso não significativo	✓ Cargas $\geq 0,50$ que são estatisticamente significativas são consideradas relevantes.
Modelo estrutural	
Valor de R^2	<ul style="list-style-type: none"> ✓ Os valores de R^2 de 0,75, 0,50 e 0,25 são considerados substanciais, moderados e fracos. ✓ Valores R^2 de 0,90 e superiores são típicos indicativos de super ajuste.
Valor de Q^2	<ul style="list-style-type: none"> ✓ Valores maiores que zero são significativos. ✓ Valores maiores que 0, 0,25 e 0,50 representam relevância preditiva pequena, média e grande do modelo PLS
PLSpredict e erro de previsão	<ul style="list-style-type: none"> ✓ Defina $k = 10$, assumindo que cada subgrupo atenda ao tamanho mínimo de amostra necessário. ✓ Use dez repetições, assumindo que o tamanho da amostra seja grande o suficiente. ✓ Valores $Q^2_{predict} \leq 0$ indicam que o modelo não tem desempenho satisfatório. ✓ Quanto maior o índice (> 0) menor o erro de previsão.
Comparações de modelos	✓ Selecione o modelo que minimiza o valor em BIC ou GM em comparação com o outros modelos no conjunto.
Verificações de robustez	
Modelos de medição	✓ CTA-PLS
Modelo estrutural	<ul style="list-style-type: none"> ✓ Efeitos não lineares. ✓ Endogeneidade. ✓ Heterogeneidade não observada

3. MÉTODO DE PESQUISA

3.1. Classificação da pesquisa científica

A forma clássica de se classificar pesquisas científicas está relacionada à sua finalidade, aos objetivos, à natureza e ao método.

Quanto à finalidade a pesquisa pode ser classificada em dois tipos (CAUCHICK MIGUEL, 2018; MARTINS; MELLO; TURRIONI, 2014).

- Básica: é movida pelo interesse na ampliação do conhecimento científico.
- Aplicada: orientada pelas necessidades de aplicação no mundo real.

Essa tese apresenta e discute os efeitos da aplicação de estratégias de AA em cursos de Engenharia, utilizando a modelagem das possíveis relações de causa e efeito entre aderência à AA e o desempenho dos alunos. Além de pretender explicar o fenômeno observado no estudo, pretende atender necessidades futuras de aplicação no mundo real de outras IES com desafios similares de compreender os efeitos da AA no aprendizado dos alunos. A pesquisa, portanto, é do tipo aplicada.

Com relação aos objetivos, podem haver duas formas de classificação (APPOLINARIO, 2011; BERTRAND; FRANSOO, 2002; MARTINS; MELLO; TURRIONI, 2014):

- Experimental (Normativa): visa explicitar um problema, ou seja, construir e discutir hipóteses a seu respeito (desenvolvimento de políticas, estratégias e ações para aperfeiçoar resultados disponíveis na literatura).
- Descritiva: objetivo é descrever as características de uma população, um fenômeno ou experiência para o estudo realizado.

Essa tese se utiliza de experimentos controlados com o propósito de medir e utilizar dados de observação coletados em salas de aula de cursos de Engenharia, amostrando-se disciplinas de formação básica e técnica a partir de um processo sistemático e estruturado por um instrumento de medição comumente denominado de protocolo de observação. Ao explicitar um problema relevante para a Educação em Engenharia associada aos métodos de aprendizagem ativa (i.e. a relação do aprendizado com o nível de AA) e possibilitar a sua discussão baseado em dados

experimentais para futuras políticas e ações estratégicas inovadoras que contribuam para o aperfeiçoamento do conhecimento existente no tema, esta tese se classifica como experimental (ou normativa).

Quanto à natureza da abordagem a pesquisa pode ser (APPOLINARIO, 2011; BERTRAND; FRANSOO, 2002; MARTINS; MELLO; TURRIONI, 2014):

- Quantitativa: classifica e analisa as informações e opiniões traduzidas em números e por isso requer o uso de recursos e de técnicas estatísticas.
- Qualitativa: é descritiva e o pesquisador é o instrumento-chave pois o ambiente natural é fonte direta para coletar dados que são analisados intuitivamente.

Nesse caso, pretende-se em primeiro lugar medir os níveis de ocupação do tempo de sala de aula com atividades e comportamentos (eventos) padronizados por um instrumento de observação, com e sem o uso de técnicas ativas (**nível de aderência à AA**). Então, pretende-se explorar a relação com o desempenho acadêmico dos alunos, ou seja, os valores de suas notas, relacionadas com a avaliação da **Aprendizagem**, além de previsões possíveis pela modelagem estatística a ser empregada. Assim, a pesquisa é primariamente quantitativa. O papel dos instrutores e das técnicas empregadas devem ser avaliados e associados aos resultados, o que traz um aspecto qualitativo, por ser baseado na análise do pesquisador. Esta análise é parte relevante da discussão do problema e utiliza pesquisas pós-experimentos com os professores. Estas pesquisas, associadas aos dados obtidos pelo conjunto de observações individuais de aulas de cada disciplina, apoiaram a construção de recomendações estratégicas para o aperfeiçoamento do conhecimento na aplicação de AA para a Educação em Engenharia.

Os seguintes métodos de pesquisa podem ser utilizados a partir dos estudos de Bryman (1989), Groves *et al.* (2004), Mitroff *et al.* (1974) e Yin, (2017) e outros autores citados nos métodos específicos.:

- Experimento: é usado como método de pesquisa quando se tem um objeto de estudo, selecionam-se variáveis de influência e definem-se as formas de controle para observação dos efeitos. A pesquisa experimental adquiriu considerável importância por possibilitar fortes declarações de causalidade e pela facilidade do uso de delineamentos (MONTGOMERY; RUNGER, 2011).

- *Survey*: levantamento é empregada quando envolve o questionamento direto das pessoas cujo comportamento se deseja conhecer e analisar. Um exemplo típico e bem antigo do uso deste método é o censo (GROVES *et al.*, 2004).
- Modelagem e simulação: serve para experimentar um sistema real através de um modelo e determinar como este sistema responderia às modificações propostas. Permite também a análise de cenários e de arranjos experimentais distintos (BALCI, 2012; BERTRAND; FRANSOO, 2002;

Esses métodos são associados à natureza quantitativa.

- Estudo de caso: é uma das abordagens mais antigas e envolve a pesquisa profunda e exaustiva de um ou poucos objetos a fim de permitir o seu amplo e detalhado conhecimento. Existem três tipos de estudo de caso: explanatório, exploratório e descritivo (VOSS; TSIKRIKTSIS; FROHLICH, 2002; YIN, 2017).
- Pesquisa-ação: é concebida e realizada para a resolução de um problema. Neste método, os pesquisadores e participantes da situação devem estar envolvidos de modo cooperativo ou participativo no diagnóstico e na solução de um problema (BALLANTYNE, 2004).
- *Soft System Methodology (SSM)*: auxilia a formulação e estruturação do pensamento sobre problemas em situações complexas. Seu princípio está na construção de modelos conceituais e na comparação destes com o estado real (POULTER; CHECKLAND, 2010).

Esses métodos são associados à natureza qualitativa.

- *Design Research Methodology (DRM)*: tem sido considerado como um método para a condução de pesquisas de cunho tecnológico, por exemplo tecnologias de gestão e gestão de operações, constituindo-se em uma abordagem que, quando bem aplicada, produz rigor científico efetivo. A missão principal da metodologia é, portanto, desenvolver conhecimento para a concepção e desenvolvimento de artefatos que realizem objetivos (SIMON, 1996; VAN AKEN, 2004). O método é também utilizado em pesquisas na área de tecnologia e sistemas da informação (GREGOR; HEVNER, 2013).

Esse método pode ser associado às naturezas qualitativa e quantitativa.

No quesito do método de pesquisa, o planejamento e a coleta de dados advindos de experimentos científicos controlados para observar possíveis efeitos (causalidade) em um objeto de estudo caracterizado por variáveis selecionadas de influência caracterizam o método de pesquisa como um experimento. O posterior uso de estatística avançada para revelar e analisar a explicação matemática da possível relação causal, testar arranjos de dados e sugerir alvos de predição através de modelagem de equações estruturais revela um segundo componente do método, ou seja, modelagem e simulação. Segundo o modelo proposto por (MITROFF *et al.*, 1974), dividido em quatro etapas, quais sejam conceptualização, modelagem, solução do modelo e implementação, um ciclo de pesquisa baseado neste método pode começar e terminar em qualquer uma das quatro fases desde que o pesquisador tenha conhecimento de qual modelo está a tratar e das reivindicações que podem ser feitas em cada ponto.

Em resumo, para responder às perguntas de pesquisa, a pesquisa científica dessa tese será estruturada como do tipo aplicada com objetivo experimental/normativo e o método de pesquisa será um experimento com modelagem e simulação ao testar arranjos experimentais e propor uma relação de causa-efeito com predição de um alvo ou meta. Quanto à natureza, terá uma abordagem quantitativa em diferentes etapas do processo de pesquisa. Adicione-se a isso que o método *Survey* será utilizado para questionários quantitativos e qualitativos com professores, em uma abordagem de *Mixed Methods* (CRESWELL, 2009). A técnica de coleta de dados das salas de aula será por observação estruturada, utilizando um protocolo válido e confiável de observação em sala de aula (COP).

A Figura 9 ilustra a classificação da pesquisa deste trabalho de doutorado com relação às formas clássicas, destacando a tipificação em cada uma das dimensões a partir dos autores citados nesta seção.

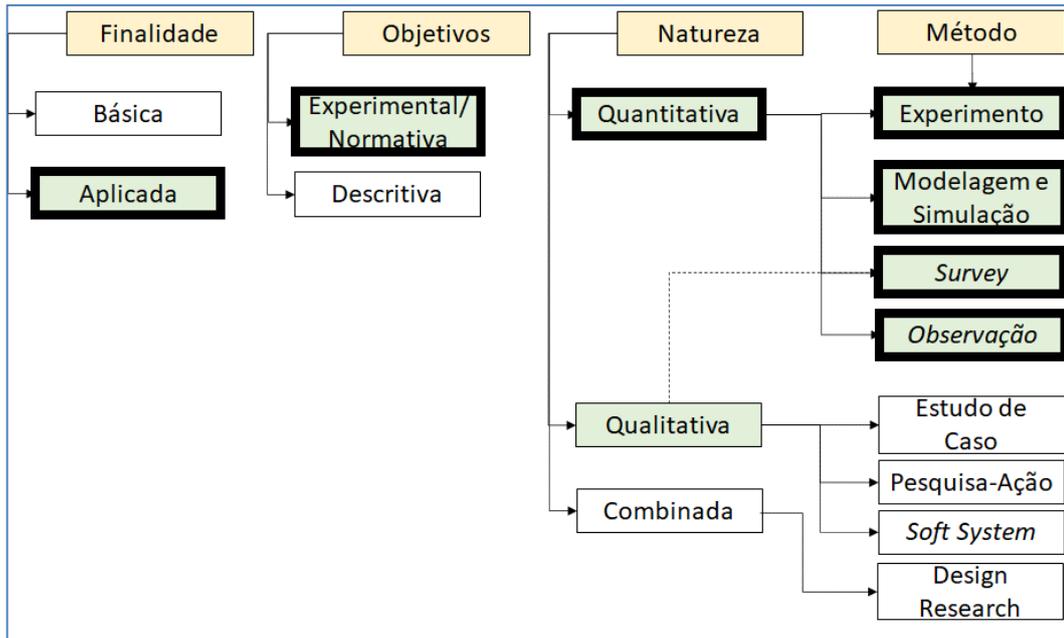
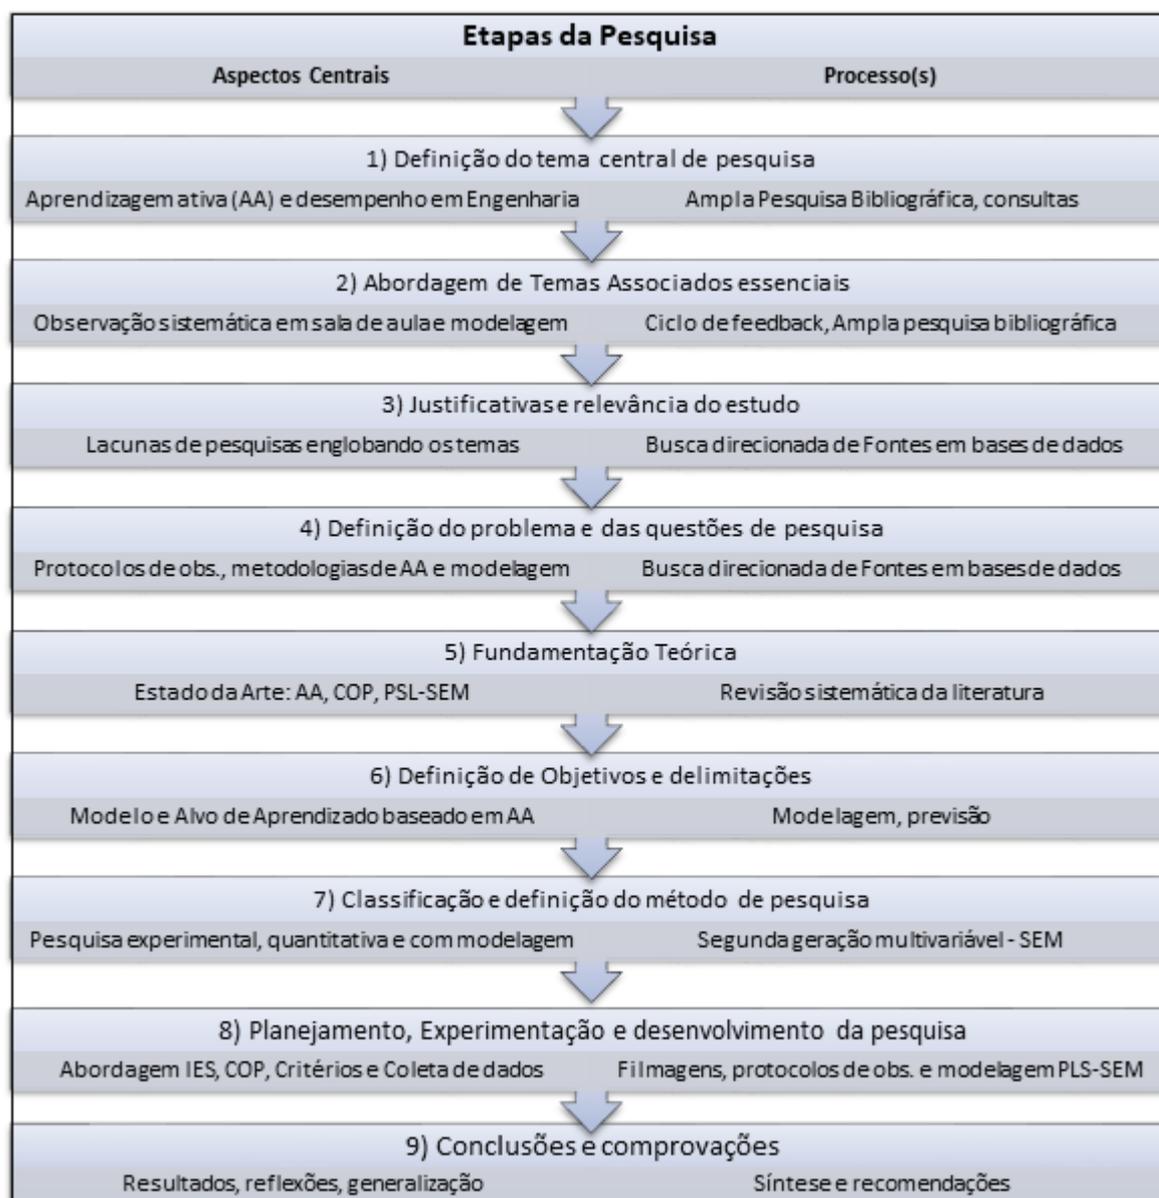


Figura 9 - Classificação da Pesquisa nesta tese

3.2. Etapas e procedimentos da Tese

O framework do Quadro 5 foi desenvolvido para guiar o processo de construção da tese seguindo as etapas e procedimentos supra citados, buscando uma abordagem sistemática e robusta.

Quadro 5 - Framework do processo de pesquisa



Fonte: O próprio autor

Três componentes resumem as informações fornecidas no framework: (1) Etapas da Pesquisa, que descrevem os passos globais de execução do projeto da tese; (2) Aspectos Centrais, que apresentam os tópicos relevantes explorados em cada uma das etapas do estudo; (3) Processo(s), que relacionam as técnicas, métodos ou abordagens adotadas pelo pesquisador para dar suporte aos componentes (1) e (2).

Na Etapa 1, buscou-se obter, discutir, definir e validar o tema central de pesquisa. O aspecto central da etapa foi a pesquisa em Aprendizagem Ativa (AA) e sua relação com o desempenho

dos alunos em cursos de Engenharia. As mais recentes discussões nos ambientes de Educação em Engenharia, sobre as experiências de aplicação e a possível eficácia das metodologias de aprendizagem ativa nestes contextos educacionais e institucionais (FREEMAN *et al.*, 2014; SANDERS; SPIEGEL; SHERER, 2018) foram consultadas em periódicos de renome na comunidade científica. Pode-se citar como exemplo PNAD, ASEE e CBE *Life Sciences Education*. Um processo amplo de pesquisa bibliográfica em dezenas de bases de dados foi adotado (e.g. Scopus, Elsevier, EBSCO, *Web of Science*, etc.) para demonstrar uma possível relevância do tema central ora definido.

Na Etapa 2 foi necessário ampliar a abordagem além do tema central, com temas secundários associados e essenciais à compreensão plena do problema que estava configurado. Seria possível obter uma medição da aderência às técnicas de aprendizagem ativa através de instrumentos de medição chamados protocolos de observação em sala de aula, alguns deles surgindo para os ambientes de EE e STEM. Além disto, associar dados de observação de ambiente social como a sala de aula, rica em comportamentos diversos de professor e alunos, com graus de desempenho individual e coletivo demandou a busca por técnicas estatísticas de segunda geração. Tais técnicas permitiriam trabalhar com variáveis que não pudessem ser medidas diretamente. Mais uma ampla pesquisa bibliográfica focalizou os instrumentos de observação sistemática e as técnicas de modelagem aplicáveis.

Na Etapa 3, uma análise crítica aprofundada foi feita de forma a justificar a relevância e necessidade da pesquisa a partir da busca direcionada de fontes bibliográficas diversas, o que além de artigos em periódicos e congressos, considerou livros, teses, dissertações, estudos de casos e seções de livros. Os três pilares conceituais da pesquisa quais sejam técnicas de aprendizagem ativa, protocolos de observação em sala de aula e modelagem multivariada de Equações Estruturais, foram investigados juntos ou associados, plenamente ou parcialmente, em diversas bases de dados. Isto confirmou a escassez e as lacunas de pesquisa relacionadas ao tema central e aos temas secundários associados.

Na Etapa 4, com a base de conhecimentos melhor definida e a necessidade da pesquisa demonstrada, foi possível direcionar buscas específicas e rastrear sobre as lacunas nos três pilares conceituais da pesquisa, abstraindo e conceitualizando de forma a definir o problema e as questões de pesquisa.

Na Etapa 5, buscou-se uma robusta Fundamentação Teórica em busca do estado da arte, utilizando-se de uma revisão de literatura ampla abrangendo em primeira etapa aprendizagem ativa (AA), os protocolos de observação (COP) e sua evolução na Educação em Engenharia e em disciplinas centrais de STEM em nível superior. Neste contexto, diversas bases de dados foram pesquisadas, com 48 fontes revelando 40 protocolos e aplicações, associadas em algum nível à evolução da aplicação de AA em EE e disciplinas STEM. Outras 44 fontes trouxeram conceitos, aplicações gerais e específicas de técnicas variadas de aprendizagem ativa em EE. Além disso, uma revisão geral foi feita nos métodos de modelagem multivariada aplicáveis para variáveis supostamente latentes, que não podem ser medidas diretamente, dentre elas a modelagem de equações estruturais e sua vertente de segunda geração, aquela baseada em mínimos quadrados parciais - PLS-SEM, a partir de 89 fontes que foram qualificadas para leitura e revisão geral. Os critérios foram detalhados na seção 2.1.

Na Etapa 6, a partir da problematização e da definição das questões de pesquisa discutidos no Capítulo 2, foi possível definir com a precisão adequada o objetivo geral e as delimitações da pesquisa, abordando a modelagem preditiva da aprendizagem baseado na aderência à AA: Medir e analisar os níveis de ocupação do tempo de sala de aula com atividades e comportamentos (eventos) padronizados por um instrumento de observação, com e sem o uso de técnicas ativas, em cursos de graduação em Engenharia (indicadores da variável latente NAA - nível de aderência à AA) e explorar a relação com o desempenho acadêmico dos alunos, ou seja, suas notas (indicadores da variável latente AP - Aprendizagem), bem como o papel de instrutores e das técnicas empregadas.

Na Etapa 7, o foco foi em definir e planejar o procedimento sistemático de pesquisa a partir da classificação e definição do método de pesquisa, do tipo de experimento e a forma de coleta de dados. Essa etapa foi crucial para a realização do projeto pois enquadrou em uma sistemática robusta o projeto e o delineamento dos experimentos, a coleta e o registro de dados. Além disto abordou a validade e a confiabilidade das observações, formatação e tratamento dos dados, modelagem e simulações, conclusões sobre comprovações e não comprovações, alvos e recomendações estratégicas. A etapa aborda o escopo global da pesquisa qual seja: pesquisa experimental, quantitativa e qualitativa (*mixed methods*), com modelagem e simulação por técnica multivariável, abordagem SEM de segunda geração, utilizando coleta de dados e observação estruturada e englobando análise de dados dependentes e independentes a partir das dimensões de abrangência intraclasse e interclasse (detalhadas na subseção 3.3.1).

Na Etapa 8, a partir de um planejamento estruturado, realiza-se efetivamente o desenvolvimento do projeto de pesquisa da tese, executando-se os experimentos planejados na IES participante. Controlou-se os experimentos para cada aula de cada disciplina e professor, sem e com AA, utilizando o COP selecionado pelas suas características de medição. Na abordagem de modelagem multivariada com constructos latentes, utilizou-se especificamente a Modelagem de Equações Estruturais por Mínimos Quadrados Parciais – PLS-SEM, entre outras razões, por ser uma técnica não paramétrica robusta em relação a não normalidade dos dados. Em geral, as premissas de não normalidade e heterodasticidade foram consideradas de forma relevante para todos os testes estatísticos realizados, paramétricos ou não paramétricos. d (ABDI *et al.*, 2015; HAIR *et al.*, 2012; HAIR; HOWARD; NITZL, 2020). A hipótese de prever um alvo de aprendizado a partir de um nível de aderência foi validada pelo modelo, cuja característica fundamental advinda da metodologia PLS-SEM é seu poder preditivo. Os resultados foram apresentados e discutidos. De forma qualitativa, a influência da forma de implementação e do tipo de técnica de AA adotada pelos professores e sua relação com o modelo também foram avaliados.

Para associar as percepções qualitativas do pesquisador e dos professores da equipe de pesquisa, o projeto dos experimentos considerou sessões e reuniões antes dos experimentos e pós experimentos com todos os professores. As primeiras foram para refletir, rever e confirmar o procedimento controlado de execução do plano experimental. As seguintes foram para apresentar o relatório do experimento inicial de cada disciplina para cada professor responsável, confirmar os próximos passos, refletir e discutir os pontos fortes e fracos da implementação versus os resultados medidos pelos indicadores de grau de desempenho. Estas atividades da equipe foram formalizadas na pesquisa (*survey*) pós-experimento independente e anônima aplicada através do Google Docs®, o que apoiou a recomendação de estratégias de AA supostamente mais eficazes para cada grupo de disciplinas no contexto específico das salas de aula. As questões da pesquisa buscaram coletar as expectativas e percepções dos professores no uso das metodologias ativas e suas perspectivas futuras. A possível generalização e a sistematização de uma metodologia de análise para outras IES foram também discutidas.

Na Etapa 9 sintetizou-se as conclusões abordando entre outras coisas, o valor agregado da pesquisa para a base de conhecimento da literatura, o aprendizado, as reflexões e as limitações,

o que foi comprovado e o que não foi em termos das hipóteses apresentadas. A possível generalização e as recomendações finais foram também apresentadas.

3.3. Experimentação e desenvolvimento da pesquisa

3.3.1. Introdução

A pesquisa foi realizada em duas dimensões:

1) Intraclasse: abordou a coleta de dados longitudinais para medir a possível relação entre o nível de atividade dentro de sala de aula centrado nos alunos (nível de aderência à AA) e os graus de desempenho do mesmo grupo de alunos. O foco foi na comparação em pares para verificação estatística se o grau de desempenho melhorou. O nível de AA foi abordado como um nível de tratamento do experimento. Além disso, esta dimensão estabeleceu a base de amostras (*baseline*) para as observações em sala de aula em ambos os ambientes tradicional e ativo, com vistas a dar sustentação para a fase de modelagem. A dimensão intraclasse foi projetada para testar mais diretamente as hipóteses H1.1 e H1.2.

2) Interclasse: Esta dimensão abordou conceitos mais abstratos. O **Nível de atividade de AA ou aderência à AA** em sala de aula foi concebido como uma variável latente independente, medida por indicadores advindos do padrão de AA estabelecido nas aulas através de um protocolo de medição (sem e com a implementação de técnicas de AA). Esta variável “causou” uma outra variável latente dependente qual seja a **Aprendizagem** dos alunos, medida pelos graus de desempenho de uma amostra de disciplinas em classes diferentes (sem e com a implementação de técnicas de AA), para modelar a possível relação entre elas. A dimensão interclasse abordou mais diretamente a hipótese H2.

O nível de significância previamente adotado como objetivo para os testes de hipótese e modelagem foi $\alpha = 0,05$, podendo variar na faixa de $0,05 \leq \alpha \leq 0,1$ dentro de padrões geralmente aceitos para pesquisa exploratória em educação (SCHUMM et al., 2013). Uma ilustração das abordagens por dimensão é mostrada na Figura 10. Ambas as dimensões englobam as respostas a todas as perguntas de pesquisa.

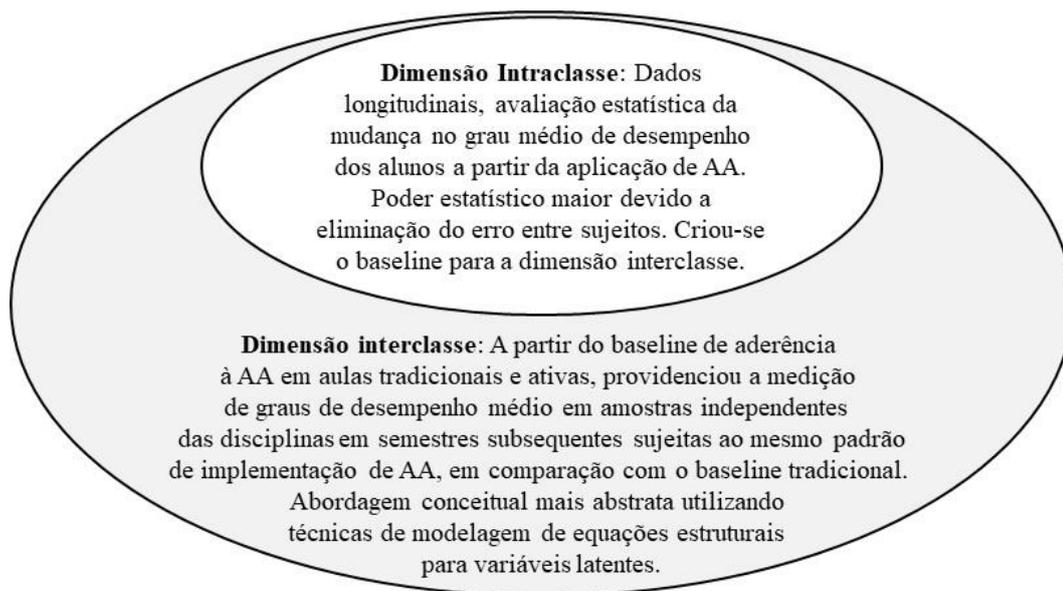


Figura 10 - Dimensões da abrangência da pesquisa

O framework na Figura 11 descreve a lógica do planejamento dos experimentos da dimensão intraclasse, os quais substanciaram as abordagens gerenciais junta à IES participante e as etapas de treinamento, coleta de dados por observação em sala de aula, avaliações parciais de desempenho, análise de dados e conclusões nesta dimensão. Esta dimensão fornece a base dados para a análise pareada e evidência da relação de causa-efeito hipotetizada, em amostras dependentes, o que foi um passo fundamental na direção da modelagem final.

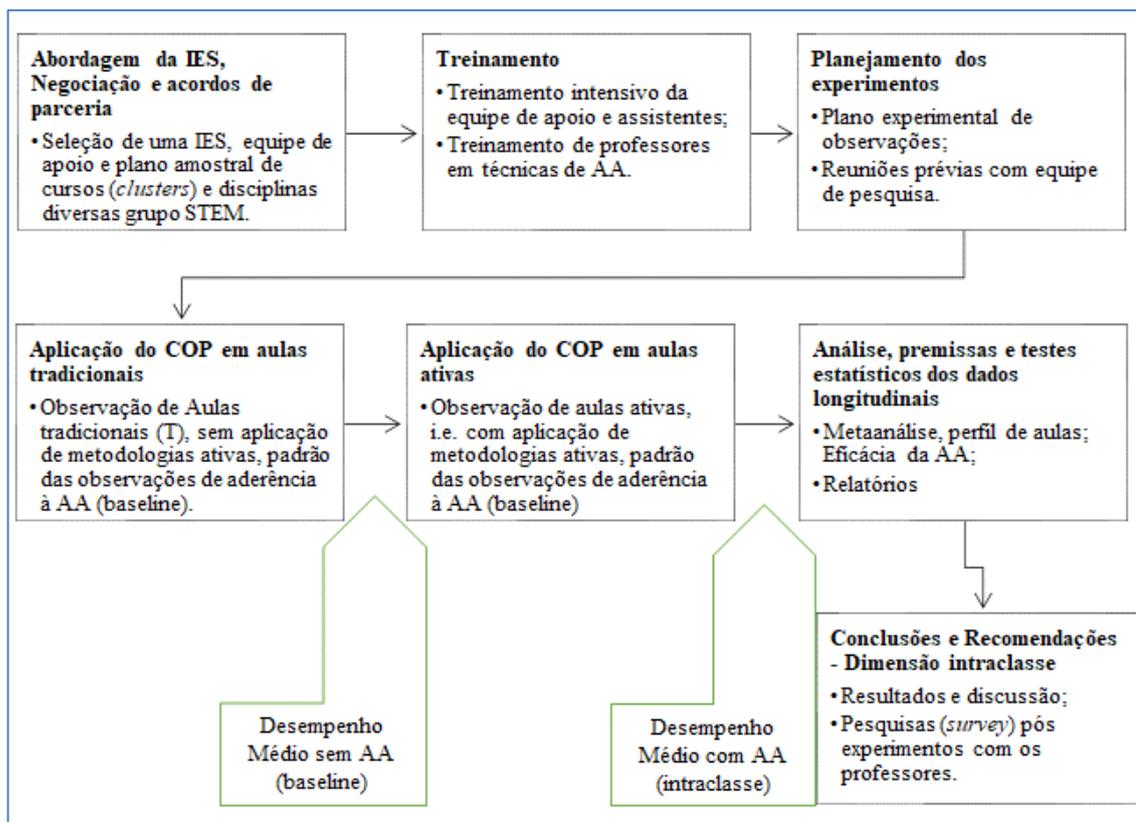


Figura 11 - Framework do planejamento dos experimentos Intraclasse

Etapas da Dimensão Intraclasse:

- a) Instituições de Ensino Superior (IES) foram elencadas priorizando-se aquela(s) com mais chance de um acordo de cooperação para pesquisa científica. Quatro IES foram consideradas na região alvo, no sul do Estado de Minas Gerais, duas delas com maior destaque devido ao seu perfil mais fortemente voltado para cursos de engenharia em diversas modalidades. As duas opções, uma universidade federal e outra IES particular exclusivamente voltada ao ensino de engenharia, foram abordadas pelo pesquisador e seu orientador e as negociações progrediram muito mais rapidamente junto a IES particular devido ao interesse estratégico da sua diretoria nas pesquisas relativas à aprendizagem ativa, sendo esta IES a que foi possível obter um acordo de cooperação viável no tempo adequado para comportar longas etapas de treinamento e filmagens em sala de aula. As filmagens envolveram alinhamento com os recursos disponíveis e com as políticas de confidencialidade e ética da IES. A instituição percebeu o potencial de aprofundamento na aprendizagem ativa e já havia treinado recentemente todos os seus

- professores em um workshop de quatro horas nas metodologias ativas mais comuns tais como sala invertida, uso de *clicker questions*, instrução por pares, PBL, POGIL e PjBL.
- b) Após a aprovação da IES para o projeto de pesquisa, procedeu-se para definir uma amostra viável de cursos que fariam parte dos experimentos, representativa de todos cursos de engenharia e que considerasse disponibilidade de recursos e restrições. Ao invés de uma custosa amostragem aleatória simples, com o apoio de um software (por exemplo, dar um número para cada curso e rodar um software para selecionar a amostra), utilizou uma abordagem o mais próxima possível da amostragem por *clusters*. Era sabido que os cursos possuem três etapas de evolução dos alunos, a partir dos Projetos Pedagógicos (PP) dos cursos, tais como: cursos básicos (acontecem no início dos cursos de engenharia, tal como Cálculo), cursos intermediários (inclui os primeiros cursos mais técnicos tais como Circuitos Digitais) e cursos avançados (inclui cursos profissionalizantes, tais como Sistemas de Comunicação). Estes seria os *clusters* e todos deveriam contribuir com pelo menos um curso para validar a representatividade da amostra. Seguiu-se então o critério de amostragem (ROSS, 1978): a) definição dos *clusters* a partir da população de cursos (3 etapas já definidas a partir dos PP); b) amostra de um número de *clusters* do total (selecionou-se todos os 3 clusters - como uma amostra de 100%) para assegurar a representatividade; c) amostra de pelo menos um curso de cada cluster, retirando os códigos e nomes dos cursos por acaso da lista de cursos a partir dos PP.
- c) Em seguida, a equipe de pesquisa (pesquisadores e alguns professores participantes) juntamente com a direção da IES validaram a amostra final de 5 cursos (6 turmas) para representar a população dos cursos da instituição. Assim, as turmas e aulas para todas as etapas dos experimentos foi planejada e um processo cuidadoso de abordagem e negociação com a equipe de apoio (filmagens, setup, gravações, armazenagem, etc.) e, principalmente, os professores participantes, buscando o comprometimento necessário para a realização dos experimentos controlados da pesquisa em sala de aula.
- d) Uma etapa intensiva de treinamento em técnicas de aprendizagem ativa (AA) de 4 horas antecedeu os experimentos de forma que os professores estivessem cientes, preparados e, com o apoio técnico do pesquisador, à vontade para escolher as ferramentas de AA que mais se adequavam ao perfil da sua disciplina. No processo de planejamento das suas disciplinas para a sistemática metodológica, todos os professores tiveram suporte do pesquisador na formatação das aulas e obtiveram complementação ao treinamento na forma de recomendações práticas sobre quais técnicas de AA e formas de aplicá-las

em sala de aula, além do provimento de artigos e referências de apoio na literatura. Um assistente de pesquisa foi treinado, além das técnicas de AA, em técnicas de observação em sala de aula utilizando protocolos de observação. Além do treinamento padrão do protocolo COPUS, o assistente (segundo observador) cumpriu no mínimo 6 horas-aulas de observações até que houvesse nível adequado de confiabilidade nas medições para só então proceder às observações comparativas reais.

- e) O protocolo COPUS , extensivamente discutido e testado na literatura e considerado adequado para EE, foi adaptado e gerou o protocolo local PORE. Este passo importante está detalhado especificamente na subseção 3.3.3. As medições foram realizadas em um mesmo período letivo, mantendo o mesmo grupo de alunos de cada turma para as duas etapas. As medições caracterizaram o nível de aderência à aprendizagem ativa (i.e., ocupação do tempo das aulas com atividades, comportamentos e eventos de aprendizagem característicos de ambientes com e sem a aplicação de metodologias ativas), a partir da estratégia de aprendizagem implementada de forma controlada pelo professor. O experimento determinou que a primeira metade da carga horária de cada disciplina elegível durante o período seria utilizada para aulas tradicionais, sem nenhuma técnica de aprendizagem ativa intencional; e a segunda metade da carga horária de cada disciplina elegível durante o período seria utilizada para aulas ativas, com alguma técnica de aprendizagem ativa intencionalmente implementada pelo professor. As turmas, portanto, foram mantidas e as medições advindas das observações geraram uma linha de base de valores observados tanto para uso nesta dimensão quanto na dimensão interclasse (modelagem).
- f) Associado aos experimentos controlados, os graus de desempenho **individuais** dos alunos nas duas etapas, em uma amostra representativa de 202 alunos, com e sem o uso de técnicas de aprendizagem ativa nas aulas, puderam ser medidos por avaliações **individuais** programadas e padronizadas de forma a não influenciar os resultados. Neste ponto da pesquisa, a partir de experiências narradas pelos professores e direção da IES, foi planejada uma avaliação sobre eventual viés histórico nas notas dos alunos por outras razões que não a aplicação de AA. Tal avaliação buscou demonstrar que quaisquer variáveis externas aos experimentos, tais como perfis de aprendizagem dos alunos, estilos de ensino dos professores, desempenhos passados dos alunos, complexidades de conteúdos nas duas etapas dos experimentos, etc. não gerariam algum viés no desempenho dos alunos, especialmente em favor da avaliação pós aplicação de AA. Para isto planejou-se um teste pareado com alto poder estatístico considerando ampla

amostra de alunos de um semestre imediatamente anterior, de forma capturar os perfis mais recentes dos participantes. Esta avaliação deve prover evidências estatísticas para ambas as dimensões da pesquisa.

- g) Uma análise qualitativa das aulas com relação às técnicas de AA utilizadas, levando em conta a literatura, os resultados individuais de cada disciplina individualmente ou grupo de disciplinas foi feita pelo pesquisador. Análises estatísticas foram planejadas para testar as hipóteses da pesquisa.
- h) Onde havia oportunidade de melhoria, as estratégias de aprendizagem ativa mais adequadas foram recomendadas, utilizando dados de pesquisas pós-experimentos com os professores da equipe de pesquisa, avaliados pela análise crítica do pesquisador e fundamentados na literatura que foi revista nesta tese.

O framework na Figura 12 descreve a lógica do planejamento dos experimentos da dimensão interclasse, os quais substanciaram a proposta de um modelo teórico que explicasse e com maior ênfase pudesse prever o comportamento da variável latente dependente – Aprendizagem e a variável latente independente – Nível de aderência á AA. Esta dimensão usa a mesma sistemática metodológica das aulas, técnicas de AA e avaliações da mesma forma que aquela aplicada à dimensão intraclasse. Neste caso, a diferença principal é que as turmas são distintas e independentes das primeiras, satisfazendo uma premissa importante da metodologia PLS-SEM.

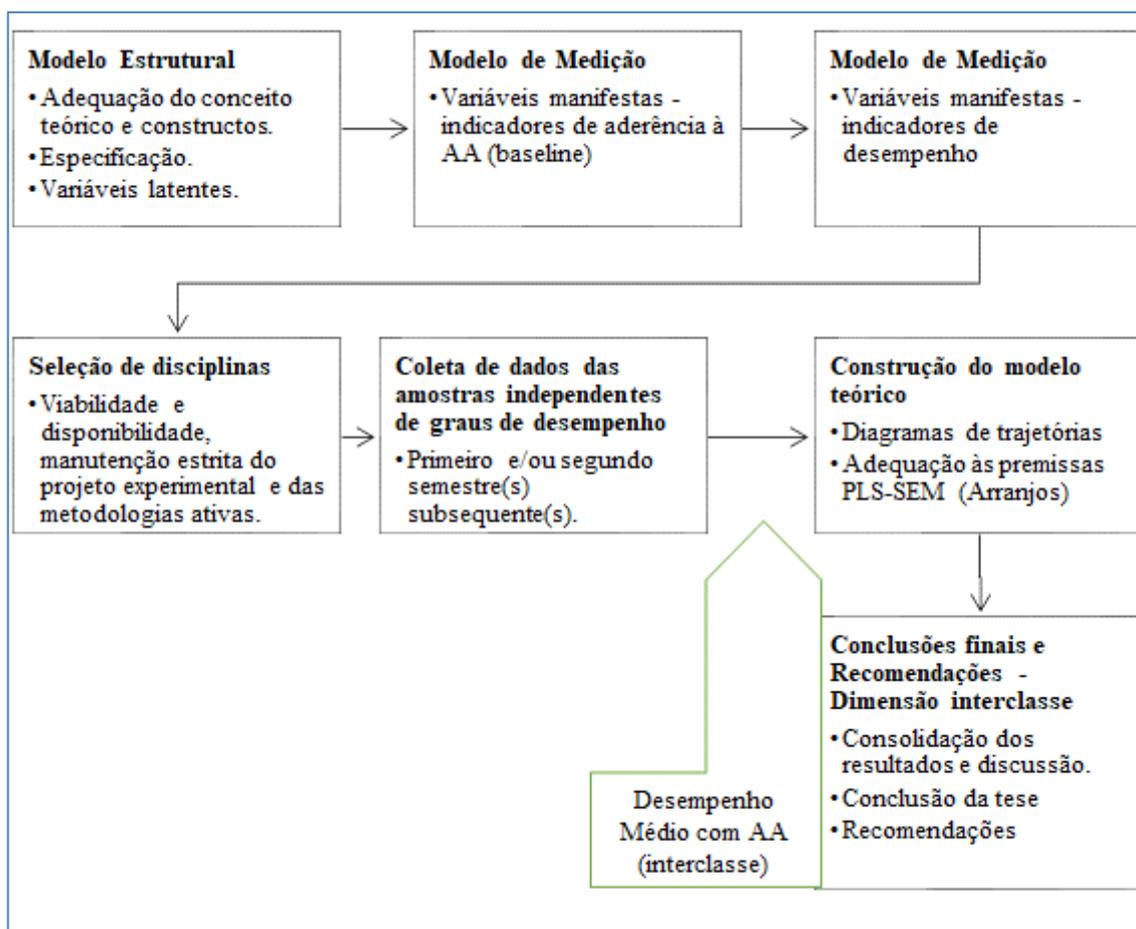


Figura 12 - Framework do planejamento dos experimentos Interclasse

Etapas da Dimensão Interclasse:

- No primeiro bloco, uma confirmação do conceito teórico central da tese foi realizada, com a confirmação dos constructos e variáveis latentes, formando o modelo estrutural adequado para a metodologia de modelagem de equações estruturais.
- Utilizando-se dos dados de observação em sala de aula coletados na dimensão intraclasse, definiu-se os indicadores para operacionalizar a variável latente de aderência à AA, considerando as adaptações já integradas no PORE para a construção dos scores da variável latente correspondente. Formou-se a parte independente do modelo de medição de equações estruturais.
- A amostra de observações máxima disponível foi de 184 a partir das disciplinas que se mantiveram nos experimentos nos semestres subsequentes. O critério de inclusão foi definido através do atendimento das seguintes premissas simultaneamente: 1) viabilidade operacional de continuar a pesquisa para o professor e para a IES participante; 2) manutenção sistemática do método experimental nas aulas e avaliações.

Para a formação dos indicadores reflexivos que operacionalizaram a variável latente de Aprendizagem, considerou-se o uso de subgrupos de médias das notas ou médias globais ou medianas globais a serem testados pelo melhor resultado de qualidade na modelagem. Formou-se a parte dependente do modelo de medição de equações estruturais. A priori, uma amostra de 184 observações considerando o método *Gamma-exponential* seria capaz de detectar um efeito de 0,089 (coeficiente de 0,178), com poder estatístico de 80% e nível de significância de 0,05 (KOCK; HADAYA, 2018), o que fornece um poder aceitável para pesquisas exploratórias capaz de detectar entre pequenos ($\sim 0,02$) e médios ($\sim 0,13$) efeitos (COHEN, 1988).

- d) Foi realizada uma nova coleta de dados de graus de desempenho nas avaliações obtidos após a aplicação das técnicas ativas associados às novas classes subsequentes para as disciplinas que se mantiveram no experimento, mantendo continuidade e consistência. se estendeu por até dois semestres posteriores ao experimento inicial.
- e) De posse dos dados e a partir do conceito teórico fundamental da tese, foi possível construir o modelo de trajetórias teórico utilizando a técnica de modelagem de equações estruturais por mínimos quadrados parciais e iniciar a modelagem e as simulações de arranjos de dados em busca do modelo mais preditivo possível, de forma a testar as hipóteses associadas da pesquisa.
- f) A partir dos resultados foi proposto um modelo com viés preditivo a partir da técnica de Modelagem por PLS-SEM adequada para lidar com dados não paramétricos. Buscou-se explicar a possível relação de causa e efeito entre o desempenho e o nível de aderência à AA. Buscou-se também evidenciar a capacidade do modelo de possibilitar a busca de um alvo de aprendizagem a partir de um nível de aderência à AA, incluindo um gráfico estimado da relação.

3.3.2. Delineamento dos Experimentos em Sala de Aula

O procedimento de coleta de dados seguiu a rígida sistemática metodológica da pesquisa, resumido a seguir.

- a) A partir do treinamento realizado com toda a equipe de pesquisa e da definição da amostra experimental de cursos e conseqüentemente das classes e dos alunos participantes, reuniões

preliminares foram feitas com a equipe de instrutores de forma a esclarecer eventuais dúvidas no método de coleta e na importância de seguir com rigor as etapas de execução dos experimentos, sincronizados com cada evento de gravação e com a agenda para as avaliações de desempenho, estas normalmente marcadas no início do semestre.

- b) Adicionalmente, reuniões adicionais foram feitas com a equipe de apoio, composta pela supervisão do setor de gravações da instituição, os operadores de câmera e os operadores de mídia para abordar os cuidados com o setup adequado, tal como a posição da câmera na sala de aula, disponibilidade de energia elétrica, riscos e falhas operacionais, repetições e *back-up*, horários de início e finalização das gravações, etc. e posteriormente o processo de salvamento e *back-up* das gravações. Não houve a permanência do operador de gravação na sala de aula, o que evitou qualquer influência no comportamento dos alunos.
- c) Durante a primeira etapa de gravação das aulas, os instrutores trabalharam suas estratégias pedagógicas de forma tradicional e as aulas foram gravadas seguindo o método. No meio do semestre, uma avaliação padronizada foi aplicada abordando a primeira parte do conteúdo. As aulas foram então medidas através de um protocolo de observação estruturada que gerou os indicadores de atividade correspondentes às aulas tradicionais. As notas das primeiras avaliações foram extraídas do sistema de gestão da IES. Todos estes dados foram tabelados em planilhas MSExcel® e armazenados pelo pesquisador.
- d) O processo se repetiu na segunda etapa de coleta de dados, na segunda metade do semestre, agora no ambiente de aprendizagem ativa implementado pelos instrutores segundo a rígida sistemática metodológica estabelecida.
- e) Limitações de recursos e falhas operacionais foram enfrentados com um plano de regravações das aulas em semanas deixadas livres, sem prejuízo do método e da amostra.

O critério específico de filmagens foi definido observando-se os recursos e viabilidade locais, os experimentos similares na literatura e discussões do pesquisador junto a outros pesquisadores que fizeram trabalhos similares (ERDMANN; STAINS, 2019; LUND *et al.*, 2015; MIKESKA *et al.*, 2019; VAN AMBURGH *et al.*, 2007). Devido ao alto custo envolvido, o tamanho possível da amostra das observações foi um desafio e buscou seguir recomendações da literatura (CHIN; MARCOULIDES, 2013; KOCK; HADAYA, 2018). A realização do plano será destacada no Capítulo 4, porém, antecipa-se que a disciplina D5 foi postergada para o 1S2020, as filmagens da abordagem tradicional foram feitas, mas o processo foi interrompido pelo evento da pandemia de COVID-19 e a amostra foi eliminada.

A Tabela 4 mostra um resumo executivo do planejamento dos experimentos.

Tabela 4 - Resumo do planejamento geral dos experimentos

Agendamento de Experimentos - Resumo								
Dimensão	Aula: Tradicional (T) Ativa (A)	Disciplina	Carga Horária Intra	Carga Horária Inter	Turmas Intra/(Inter)	Período	Horas-aula a filmar	Professor
Intra	Tradicional	D1	18	-	1	2S2018	6	P1
Intra	Ativa		18	-		2S2018	6	P1
Inter	Trad./Ativa		-	18/18	(1)	1S2019	-	P1
Intra	Tradicional	D2	18	-	1	2S2018	6	P2
Intra	Ativa		18	-		2S2018	6	P2
Inter	Trad./Ativa		-	18/18	(2)	1S2019	-	P2
Inter	Trad./Ativa		-	18/18		2S2019	-	P2
Intra	Tradicional	D3.1	18	-	1	2S2018	6	P3
Intra	Ativa		18	-		2S2018	6	P3
Inter	Trad./Ativa		-	18/18	(2)	1S2019	-	P3
Inter	Trad./Ativa		-	18/18		2S2019	-	P3
Intra	Tradicional	D3.2	18	-	1	2S2018	6	P3
Intra	Ativa		18	-		2S2018	6	P3
Inter	Trad./Ativa		-	18/18	(2)	1S2019	-	P3
Inter	Trad./Ativa		-	18/18		2S2019	-	P3
Intra	Tradicional	D4	38	-	1	1S2019	6	P4
Intra	Ativa		38	-		1S2019	6	P4
Inter	Trad./Ativa		-	38/38	(1)	2S2019	-	P4
Intra	Tradicional	D5(*)	38	-	1	1S2020	6	P5
Intra	Ativa		38	-		1S2020	6	P5
Inter	Trad./Ativa		-	38/38	(1)	1S2020	-	P5
Intra	Tradicional	D6	18	-	1	1S2019	6	P6
Intra	Ativa		18	-		1S2019	6	P6
Inter	Trad./Ativa		-	18/18	(1)	2S2019	-	P6
Totais	-	6(*)	256(*)	256(*)	7(*) (10)(*)	-	72(*)	5(*)

Fonte: O próprio autor

(*) A disciplina D5 teve a parte ativa postergada para 1S2020 e não pôde ser finalizada devido à pandemia de COVID-19

O protocolo PORE foi customizado para parametrizar a plataforma de software PGOR - Plataforma Geral de Observação e Reflexão e foi utilizado para analisar todas as aulas filmadas. A PGOR é a plataforma de software utilizada nesta tese para automatizar o processo complexo de observação e registros temporais dos eventos de sala de aula. Como referência, dentro outras, esta plataforma foi também utilizada por Lund *et al.* (2015) como o mesmo protocolo-base

COPUS selecionado para esta tese. A plataforma automatiza de forma ampla as medições de práticas instrucionais em sala de aula. Composto de dois painéis laterais e uma parte central com indicadores, consegue, através de um protocolo de observação, medir a aderência ou engajamento do professor e dos alunos às atividades em sala de aula. Observando a Figura 13, o painel esquerdo da ferramenta com botões de cor laranja, mostra o que o observador pode identificar relativo ao que os **alunos estão fazendo**. Eles podem estar ouvindo, trabalhando de forma independente, perguntando ou respondendo questões diretas, respondendo a perguntas online com o uso de *clickers*, etc. Existem botões para as diversas atividades.



Figura 13 - Protocolo PORE – adaptado do COPUS - na plataforma PGOR

No painel direito com botões de cor verde é possível identificar o que o **instrutor está fazendo**. Ele pode estar dando uma aula expositiva, escrevendo, propondo questões online com *clickers*, cobrando uma atividade, até mesmo dando um suporte individual a um aluno. Na parte central existe um cronômetro que controla os intervalos de dois minutos para os quais as medições são feitas. E na parte inferior existe um medidor opcional do nível de engajamento - se a aprendizagem ativa está sendo utilizada, ela apresenta baixo, médio ou alto nível de engajamento. Isto torna possível entender de forma global os tipos de instrução que estão sendo utilizados, porém, não foi utilizado nesta pesquisa.

Todas as aulas gravadas e verificadas da amostra foram observadas por até 2 observadores, sem repetição, representando 72 horas-aula de observações utilizadas para definir o padrão de atividade das aulas tradicionais e ativas do experimento, baseado no método e na estratégia adotada pelos instrutores. A observação pontual de um observador treinado por no mínimo 6

horas-aulas na plataforma e pelo tempo recomendado no protocolo de observação (SMITH *et al.*, 2014) pode ser resumida a seguir.

- a) Utilizando-se de um computador com extensão de tela, o vídeo da aula em questão é aberto em um software de leitura compatível em uma tela e ao mesmo tempo a plataforma PGOR é aberta em uma segunda tela. A plataforma permite diversos registros das observações gravados segundo exemplo na Figura 14.
- b) O observador então inicia a aula e ao mesmo tempo dispara o processo de observação. Com acesso aos diversos botões, ele vai marcando e desmarcando os elementos de comportamentos observados no decorrer das aulas, realizados tanto pelo instrutor como pelos alunos. Dois ou mais elementos podem ser marcados ao mesmo tempo. O protocolo estabelece uma janela de 2 minutos para registrar cada ocorrência de forma amortecer picos e vales nas marcações e desmarcações sobre os elementos.
- c) O tempo ativo da aula utilizado para cada elemento é então registrado e, ao final de uma aula típica de 100 minutos, as porcentagens médias de uso do tempo de aula se configuram como os indicadores de atividade em sala de aula, utilizados para medir a aderência à AA. Quanto mais ativa for uma aula, mais espalhado será o comportamento dos indicadores com predominância de atividades em grupo e mentoria do professor. Quanto menos ativa (tradicional) for uma aula, menor variedade de elementos serão marcados, normalmente se concentrando em instrutor palestrando ou escrevendo no quadro e alunos ouvindo individualmente e passivamente.

A Figura 14 apresenta uma ilustração da tela de observações com uma amostra das observações realizadas nessa tese por um dos observadores. É possível observar a identificação do protocolo PORE, o nome do observador e as datas nas colunas respectivas.

Protocol	User	Date	Observation data	Resume	Show	Download	Delete
PORE - Protocolo de Observação e Reflexão em Engenharia	LEOVANI MARCIAL GUIMARAES	2019-11-15	Toggle Data		Show	Export	Destroy
PORE - Protocolo de Observação e Reflexão em Engenharia	LEOVANI MARCIAL GUIMARAES	2019-11-15	Toggle Data		Show	Export	Destroy
PORE - Protocolo de Observação e Reflexão em Engenharia	LEOVANI MARCIAL GUIMARAES	2019-11-14	Toggle Data		Show	Export	Destroy
PORE - Protocolo de Observação e Reflexão em Engenharia	LEOVANI MARCIAL GUIMARAES	2019-11-14	Toggle Data		Show	Export	Destroy
PORE - Protocolo de Observação e Reflexão em Engenharia	LEOVANI MARCIAL GUIMARAES	2019-11-13	Toggle Data		Show	Export	Destroy
PORE - Protocolo de Observação e Reflexão em Engenharia	LEOVANI MARCIAL GUIMARAES	2019-11-13	Toggle Data		Show	Export	Destroy
PORE - Protocolo de Observação e Reflexão em Engenharia	LEOVANI MARCIAL GUIMARAES	2019-11-13	Toggle Data		Show	Export	Destroy
PORE - Protocolo de Observação e Reflexão em Engenharia	LEOVANI MARCIAL GUIMARAES	2019-11-12	Toggle Data		Show	Export	Destroy
PORE - Protocolo de Observação e Reflexão em Engenharia	LEOVANI MARCIAL GUIMARAES	2019-11-12	Toggle Data		Show	Export	Destroy
PORE - Protocolo de Observação e Reflexão em Engenharia	LEOVANI MARCIAL GUIMARAES	2019-11-12	Toggle Data		Show	Export	Destroy
PORE - Protocolo de Observação e Reflexão em Engenharia	LEOVANI MARCIAL GUIMARAES	2019-11-11	Toggle Data		Show	Export	Destroy

Figura 14 - Tela com lista parcial de observações

Os relatórios de observação são usados de forma agregada para examinar a evolução da aula e pode ajudar os professores a serem realimentados se eles estão ou não atingindo suas metas instrucionais. E pode ser usada também pelos departamentos ou a instituição com um todo para verificar quanto de aprendizagem ativa está ocorrendo em suas salas de aula.

3.3.3. Pesquisa Quantitativa - Aderência à AA

O Quadro 6 ilustra os elementos do COPUS e sua adaptação para o novo protocolo PORE, comparando e destacando as adaptações realizadas no protocolo original e a descrição do elemento de observação. Na primeira coluna apresenta-se os códigos dos elementos originais do COPUS totalizando 25 elementos. Na segunda coluna apresenta-se a primeira adaptação para o protocolo PORE, com uma simples tradução dos códigos para a língua portuguesa e mais algum ajuste na semântica e adição de um elemento que fizesse mais sentido para o tipo de aula nos cursos de engenharia da IES participante (por exemplo, um elemento diferenciado de trabalho em equipe não disponível no COPUS original). Inicialmente, são mantidos os mesmos 25 elementos mais 1 adição (código Instrutor-FupE). Na terceira coluna apresenta-se a indicação de qual elemento do PORE foi retirado do modelo (S=Sim; N=Não) após a aplicação de ferramentas estatísticas. E, por fim, na coluna mais à direita, a descrição de cada elemento.

A retirada dos elementos não significativos foi feita após a análise das primeiras medições do PORE. Em primeiro lugar foi aplicada regra 80/20 através do gráfico de Pareto e em sequência, como validação, foi feita uma análise fatorial utilizando componentes principais e rotação Varimax. Este processo de simplificação resultou em um protocolo bem mais enxuto e ainda assim confiável. Os fatores principais, com cargas fatoriais significativas e que foram utilizados para medições e como indicadores da variável preditora na fase de Modelagem foram: **I-Esc, I-Palest, A-O&Ind, I-MoOr, A-Out_G, I-UmUm, A-PensI, I-CkQz, A-GCkQz, I-PQpr, I-FT, I-Ad e A-AEsc.**

Quadro 6 - Elementos COPUS versus PORE

	COPUS	PORE	Retirado do Modelo	Descrição
Alunos fazendo	L	Aluno-Ouv&Ind	N	Aluno ouvindo o instrutor e tomando notas, etc.
	AnQ	Aluno-Resp	S	Aluno respondendo a uma pergunta feita pelo instrutor com o resto da classe ouvindo
	SQ	Aluno-Perg	S	Aluno fazendo perguntas
	WC	Aluno-Explic	S	Aluno explicando para o resto da classe
	SP	Aluno-ApresEsc	S	Aluno fazendo apresentação no projetor ou escrevendo no quadro
	Ind	Aluno-Pens&Ind	N	Aluno pensando individualmente, resolvendo problemas
	CG	Aluno-GrpClick_Qz	N	Aluno discutindo questões <i>clicker</i> ou Quiz/Questionário em grupos de 2 ou mais
	WG	Aluno-TrabGEx	S	Aluno trabalhando em grupo em atividades com folhas de exercícios
	OG	Aluno-Out_Grp	N	Aluno trabalhando em grupos em outras atividades (por ex.: exercícios tipo projetos, problemas, respondendo perguntas colocadas no quadro)
	Prd	Aluno-PrevRes	S	Aluno fazendo uma previsão sobre resultado de demonstração, experimento ou simulação
	T/Q	Aluno-Quiz_Ind	S	Aluno respondendo teste de avaliação ou Quiz/questionário Individual - questões rápidas
	W	Aluno-Esp	S	Aluno em espera (instrutor atrasado, trabalhando na correção de problemas de AV, instrutor ocupado de outra forma, etc.)
	O	Aluno-Outro	S	Aluno fazendo ainda outra atividade - explique!
Instrutor fazendo	Lec	Instrutor-Lec(Palest)	N	Instrutor fazendo Palestras (apresentar conteúdo, obter resultados matemáticos, apresentar a solução de um problema como parte da palestra etc.)
	RtW	Instrutor-Esc	N	Instrutor escrevendo em tempo real no quadro, projetor de documentos etc. (geralmente codificada simultaneamente com Lec)
	D/V	Instrutor-DVid	S	Instrutor mostrando ou conduzindo uma demonstração, experimento, simulação, vídeo ou animação.
	PQ	Instrutor-PropQP	S	Instrutor fazendo uma questão não <i>clicker</i> ou Questionário_ para toda a classe (não retórica) ou propondo projetos/problemas...lembrar que retórica não é pergunta verdadeira, só busca reflexão
	CQ	Instrutor-ClickQuiz	N	Instrutor colocando uma ou mais questões tipo <i>clicker</i> ou Quiz/Questionário, com um sistema eletrônico de respostas (Socrative, etc.)

COPUS	PORE	Retirado do Modelo	Descrição
AnQ	Instrutor-Resp_Q	S	Instrutor ouvindo e respondendo perguntas dos alunos com toda a classe ouvindo.
-	Instrutor-FupE	S	Instrutor fazendo follow-up de aluno - uma série de perguntas direcionadas a um aluno ou pequeno grupo para realmente abrir seu pensamento sobre uma ideia ou tópico (ou usar PropQP)
Fup	Instrutor-FupT	N	Instrutor fazendo acompanhamento / feedback sobre a pergunta ou atividade <i>clicker</i> ou Questionário_ para toda a turma
MG	Instrutor-Mo&Or	N	Instrutor se movimentando pela aula orientando o trabalho contínuo do aluno durante uma tarefa de aprendizado ativa (<i>Clicker</i> , Quiz, Projeto, Problema...)
1o1	Instrutor-Um_um	N	Instrutor fazendo discussão prolongada individual com um ou alguns indivíduos (estudantes) explicando dúvidas durante <i>clicker</i> /Questionário, sem prestar atenção para o resto da classe
Adm	Instrutor-Adm	N	Instrutor fazendo tarefas de Administração (atribuir lição de casa, retorno de resultados de testes, explicando projetos, avaliações, etc.)
W	Instrutor-Esp	S	Instrutor esperando quando houver uma oportunidade para interagir com ou observar / ouvir as atividades dos alunos ou do grupo e o instrutor não está fazendo isso
O	Instrutor-Outro	S	Instrutor fazendo ainda qualquer outra atividade que não foi definida em outros elementos.

Os observadores treinados e qualificados para as observações em sala de aula incluem o pesquisador e o assistente de pesquisa. Testes de confiabilidade entre avaliadores ou IRR (*Inter Rater Reliability*) calculado através do ICC – Correlação Intraclasse (devido a característica contínua da escala de dados) e do Alpha de Cronbach (consistência interna da escala) devem ser apresentados para assegurar nenhum viés em observações feitas utilizando o protocolo PORE, por dois observadores (RUI; FELDMAN, 2012; LIU et al., 2016). A correlação intraclasse (ICC) é definida como uma razão de variância $p_{ICC} = \frac{\sigma_{\beta}^2}{\sigma_{\beta}^2 + \sigma^2}$, onde σ_{β}^2 é a variância dos escores médios das observações e o denominador é a variância total, somando a variância dos escores médios mais a variância dos observadores σ^2 (LIU et al., 2016).

3.3.4. Pesquisa Quantitativa - Graus de desempenho

A Tabela 5 apresenta um corte de 25 amostras dos dados amostrais de saída coletados do sistema de gestão da IES participante, a partir das notas (graus de desempenho) nas duas avaliações da dimensão intraclasse. A primeira coluna é a numeração sequencial das amostras, a segunda coluna são os valores dos graus de desempenho da primeira avaliação, sem a aplicação de AA e a coluna mais à direita são os valores dos graus de desempenho da segunda

avaliação, após a aplicação de AA. O número total de amostras nesta fase da coleta de dados foi de 202 de notas para o grau de desempenho antes da aplicação de AA e 202 notas após a aplicação de AA.

Tabela 5 - Exemplo de relatório de graus de desempenho

#	Grau 1 (Nota1)	Grau 2 (Nota2)
1	58	45
2	59	68
3	60	40
4	75	44
5	57	43
6	74	78
7	75	44
8	76	70
9	86	77
10	75	69
11	51	28
12	71	76
13	52	61
14	59	42
15	64	73
16	87	85
17	71	62
18	64	55
19	59	64
20	78	83
21	59	39
22	68	57
23	80	60
24	58	62
25	50	43

3.3.5. Modelagem e Simulação

O método Modelagem e Simulação foi utilizado para a dimensão interclasse. Através deste método, buscou-se modelar uma possível relação causal entre as variáveis de entrada relativas ao nível de ocupação do tempo de aula com os diversos eventos padronizados do protocolo PORE (Nível de aderência AA) e as variáveis de saída, quais sejam, os graus de desempenho dos alunos medidos pelas suas notas parciais (Aprendizagem ou Aprendizado), possibilitando a predição de alvos de aprendizagem a partir de níveis de aderência à AA. O modelo sistêmico proposto por Mitroff *et al.* (1974) para este método foi utilizado como base para sistematizar o processo de aplicação das ferramentas de modelagem. Este modelo propõe dividir a solução de

um problema de pesquisa através da modelagem em quatro etapas: conceptualização, modelagem, solução do modelo e implementação, as quais estão ilustradas na Figura 15.

Em outro estudo científico na área de gestão de operações, onde se discute as formas de fazer modelagem e simulação Bertrand e Fransoo (2002) argumentam que as etapas a serem realizadas no modelo de Mitroff *et al.* (1974) dependem da classificação da pesquisa científica, ou seja, dependendo do alcance da pesquisa, nem todas as etapas precisariam ser cumpridas. No entanto, a pesquisa dessa tese foi tipificada como Experimental/Normativa quanto aos objetivos e de natureza Quantitativa e, para essa classe, as etapas sugeridas pelos autores coincidem com o modelo completo da Figura 15.

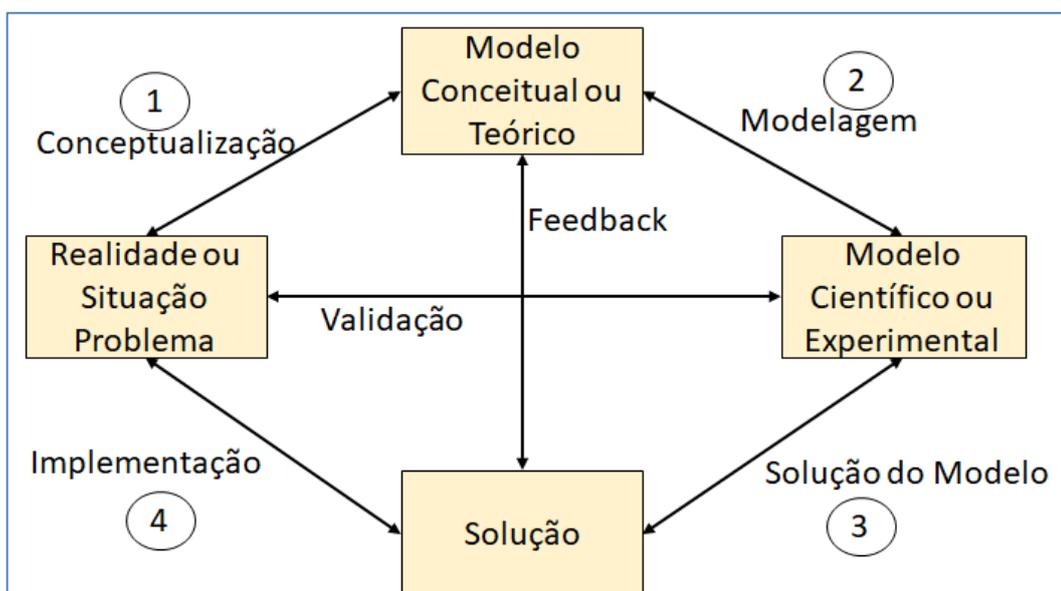


Figura 15 - Solução de Problemas de Pesquisa por Modelagem

Mitroff *et al.* (1974) argumentam que na etapa de conceptualização, o pesquisador decide quais variáveis devem estar inclusas no modelo conceitual e define o escopo e outras características iniciais intrínsecas ao problema. Na etapa de modelagem, o pesquisador utiliza o modelo conceitual e elabora um modelo matemático científico baseado em dados experimentais que define as relações causais possíveis entre as variáveis. Na etapa seguinte, solução do modelo, ocorre a resolução do modelo científico e a matemática desempenha um papel dominante. Por fim, na implementação, a solução modelada é aplicada ao problema real proposto inicialmente, finalizando o ciclo sistêmico, o qual também pode ser reiniciado caso ajustes sejam necessários ou existam outros problemas a serem trabalhados. A etapa de modelagem interage com a fase

da situação-problema através da validação da solução na realidade inicialmente apresentada (linha de validação na parte central da Figura 15).

Para a pesquisa realizada nesta tese foi realizada em primeiro lugar a etapa de conceptualização, iniciando-se com um modelo genérico associando a variável latente independente (exógena) “nível de aderência à AA” à variável latente (endógena) “Aprendizagem” e seus indicadores. Na etapa seguinte, a partir de um modelo piloto baseado nos dados experimentais, uma série de modelos alternativos foi simulada utilizando os arranjos de dados experimentais dos indicadores como base, em matrizes sucessivas, em busca de validação suficiente para a escolha do melhor modelo. Esta etapa serviu como um processo de filtragem (*screening*). Na sequência foram abordadas as etapas de solução do modelo e implementação. Técnicas de validação com indicadores diversos foram também utilizadas para assegurar a qualidade do modelo e um poder preditivo aceitável. As premissas estatísticas que devem ser atendidas total ou parcialmente para permitir uma possível generalização da metodologia também foram avaliadas para futura implementação. Cada uma das etapas desenvolvidas com base no método modelagem e simulação são detalhadas nas próximas subseções.

3.3.5.1. Conceptualização

A Figura 16 ilustra o modelo conceitual da pesquisa, englobando os três pilares, quais sejam: aprendizagem ativa na EE, protocolos de medição em sala de aula (COP) e modelagem de equações estruturais por mínimos quadrados parciais (PLS-SEM).

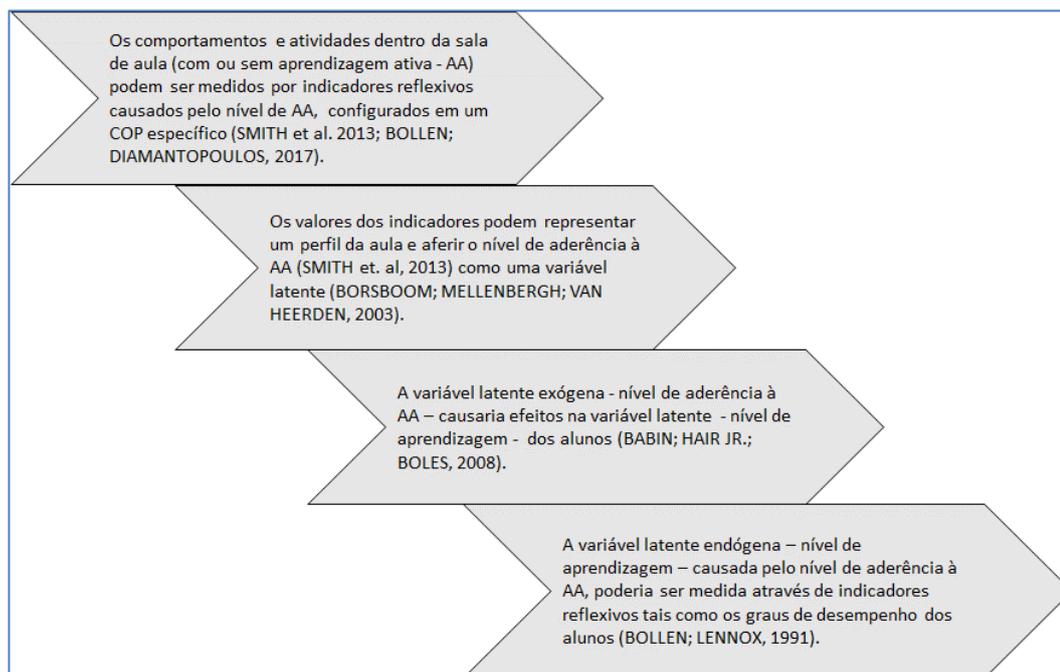


Figura 16 - Modelo Conceitual

3.3.5.2. Modelagem

De forma a simplificar a edição das equações e a apresentação dos gráficos de análise de trajetória, códigos mais concisos foram utilizados para nomear as variáveis latentes e os indicadores e são ilustrados no Quadro 7. O conjunto de variáveis foi proposto para a especificação teórica do modelo. Não se pretende esgotar nesse quadro todas as possíveis novas variáveis e suas codificações que poderão ser utilizadas nas configurações de arranjos em busca do melhor modelo (por exemplo, testar um efeito quadrático ou uma variável latente moderadora a partir dos primeiros resultados). Estas, se forem necessárias serão devidamente identificadas e apresentadas no Capítulo 4.

Quadro 7 - Opções de Codificação das variáveis

Item	Variável na formulação	Variável codificada	Descrição
1	ξ_1	S_NA	Variável Latente exógena - Nível de aderência à AA, em aulas tradicionais.
2	ξ_2	C_NA	Variável Latente exógena - Nível de aderência à AA, em aulas ativas. <i>Nota: Na análise de arranjos de dados da modelagem, C_NA e S_NA podem estar representadas por uma só variável latente - Nível de aderência à AA (NAA)</i>

Item	Variável na formulação	Variável codificada	Descrição
3	η_1	S_AP	Variável Latente endógena – Nível de Aprendizagem aulas tradicionais.
4	η_2	C_AP	Variável Latente endógena – Nível de Aprendizagem em aulas ativas. <i>Nota: Na análise de Arranjos da modelagem, S_AP e C_AP podem estar representadas por uma só variável latente – Aprendizagem (A). Eventual moderação será representada em uma análise Multigrupo (MGA).</i>
5	$x_1^s \dots x_i^s$ $x_1^c \dots x_i^c$ Com i variando de 1 até N, dependendo da eliminação de indicadores e do arranjo de dados de modelagem.	S_AF1 ... S_AF13 C_AF1...C_AF13 S_IF1...S_IF13 C_IF1...C_IF13 Correspondendo aos códigos resumidos do PORE em cada Arranjo: A-OI, A-Rp, A-Pg, A-Exp, A-AEsc, A-PI, A-GCkQz, A-GEx A-OG, A-PR, A-QzI, A-Esp A-Ou, I-Pl, I-Es, I-DV, I-PQpr I-CkQz, I-RQ, I-FE, I-FT, I-MO I-Uu, I-Ad, I-Esp, I-Ou	Até N Indicadores de cada variável latente S_NA e C_NA medindo o que os alunos e o que os instrutores estão fazendo, em aulas tradicionais e ativas, respectivamente. <i>Nota: Na análise de Arranjos da modelagem, todos os indicadores podem estar representados por somente um grupo associado a uma só variável latente - Nível de AA = NAA.</i>
6	$y_1^s \dots y_j^s$ $y_1^c \dots y_j^c$ Com j variando de 1 até M, dependendo do arranjo de dados de modelagem, com médias de subgrupos ou médias globais.	S_N1 ... S_N(M) C_N1 ... C_N(M) Correspondendo às notas N1...N(M) em cada Arranjo.	Até M Indicadores reflexivos das variáveis latentes S_AP e C_AP, medindo os graus de desempenho de alunos em aulas tradicionais e ativas, respectivamente. <i>Nota: Na análise de arranjos da modelagem, todos os indicadores podem estar representados por somente uma média global ou médias de subgrupos de notas (SG1 até SG5), associados a uma só variável latente – Aprendizagem = AP.</i>
7	B; Γ	-	Matrizes de coeficientes de regressão β e γ do modelo estrutural.
8	λ ; ω δ ; ε	-	Coefficientes (cargas fatoriais); pesos do modelo de medição e termos de erros.

Dessa forma, as variáveis latentes e seus indicadores mensuráveis foram configurados em uma tabela de dados compatível com os requisitos dos softwares de apoio para a modelagem, seguindo as etapas recomendadas e já discutidas na fundamentação teórica (SARSTEDT; RINGLE; HAIR, 2017a; KOCK, 2018), quais sejam:

- a) Especificação do Modelo de Medição reflexivo das variáveis latentes exógenas (Equação (21)):

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ \cdot \\ \cdot \\ \cdot \\ x_N \end{bmatrix} = \begin{bmatrix} \lambda_{11}^x & \lambda_{21}^x \\ \dots & \dots \\ \lambda_{1N}^x & \lambda_{2N}^x \end{bmatrix} * \begin{bmatrix} \xi_1 \\ \xi_2 \end{bmatrix} + \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \\ \delta_5 \\ \delta_6 \\ \cdot \\ \cdot \\ \cdot \\ \delta_N \end{bmatrix} \quad (21) -$$

**Especificação
do modelo
reflexivo
exógeno**

- b) Especificação do Modelo de Medição reflexivo das variáveis latentes endógenas (Equação (22)):

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \\ \cdot \\ \cdot \\ \cdot \\ y_M \end{bmatrix} = \begin{bmatrix} \lambda_{11}^y & \lambda_{21}^y \\ \dots & \dots \\ \lambda_{1M}^y & \lambda_{2M}^y \end{bmatrix} * \begin{bmatrix} \eta_1 \\ \eta_2 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \cdot \\ \cdot \\ \cdot \\ \varepsilon_M \end{bmatrix} \quad (22) -$$

**Especificação
do modelo
reflexivo
endógeno**

- c) Especificação do Modelo estrutural (Equação (23)):

$$\begin{bmatrix} \eta_1 \\ \eta_2 \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ \beta_{21} & 0 \end{bmatrix} * \begin{bmatrix} \eta_1 \\ \eta_2 \end{bmatrix} + \begin{bmatrix} \gamma_{11} & 0 \\ 0 & \gamma_{22} \end{bmatrix} * \begin{bmatrix} \xi_1 \\ \xi_2 \end{bmatrix} + \begin{bmatrix} \zeta_1 \\ \zeta_2 \end{bmatrix} \quad (23) -$$

**Especificação
do modelo
estrutural**

Como são até N indicadores reflexivos para cada variável latente (VL) exógena e até M indicadores reflexivos para cada variável latente endógena, onde N e M irão depender da otimização do modelo exógeno e também da possibilidade (ou necessidade) do uso de médias ou subgrupos de médias (e não de notas individuais) para os graus de desempenho. O diagrama de trajetórias genérico relativo a esta especificação é apresentado na Figura 17. A possibilidade de uma curvatura na resposta (efeito quadrático) e de interações também devem ser testadas no modelo.

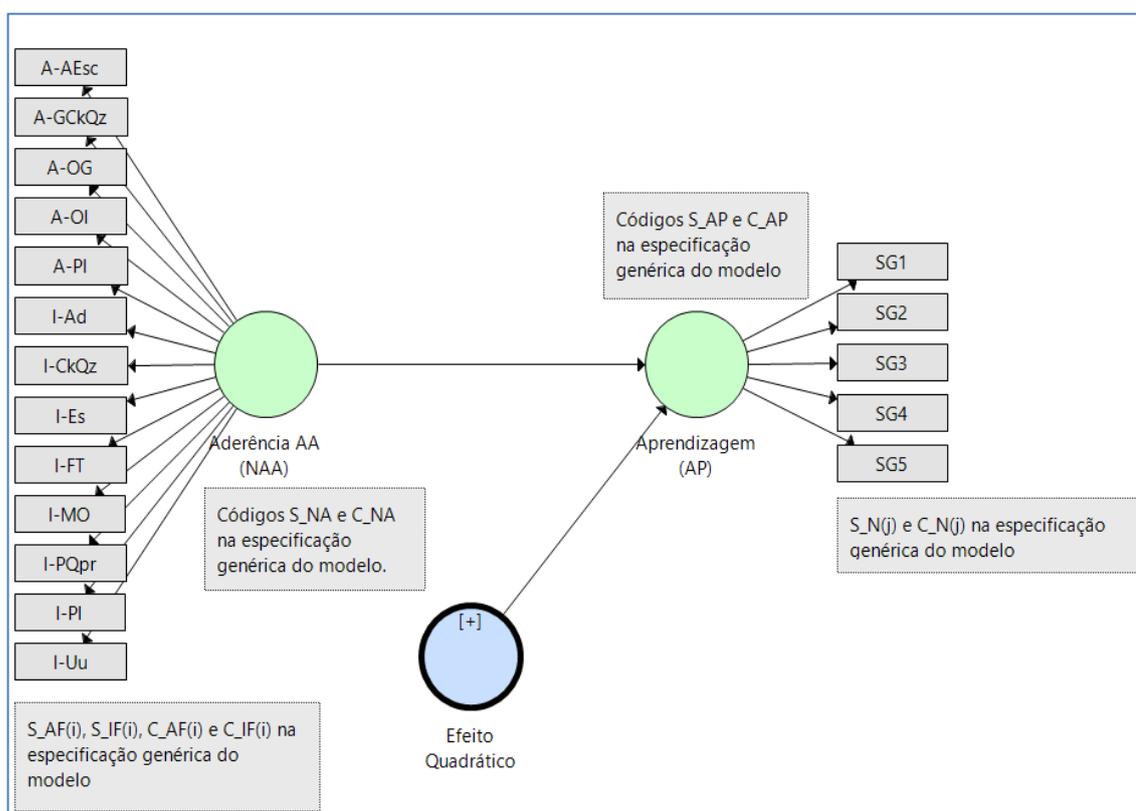


Figura 17 - Diagrama de trajetórias - Especificação genérica da tese

3.3.5.3. Solução do Modelo

As possíveis alternativas de modelos, a partir das avaliações de seu melhor ajuste aos dados, podem ser elencadas para a indicação da melhor solução. Por exemplo, na versão 3.0 do programa SmartPLS®, há diversas opções no menu de **Cálculos** que executam análises diferentes como ilustrado da Figura 18. Algumas opções são: (a) “PLS *Algorithm*” que é utilizado para rodar a SEM principal; (b) “*Bootstrapping*” que é uma técnica de reamostragem. O *Bootstrapping* avalia a significância (valor-*p*) das correlações (modelos de medição) e das

regressões (modelo estrutural); (c) “*Blindfolding*” que é utilizado para calcular a Relevância ou a Validade Preditiva (Q^2), os indicadores de Stone-Geisser e os tamanhos dos efeitos (f^2) e mais os indicadores de Cohen; (d) “FIMIX PLS”: *Finite Mixture* PLS (técnicas de classe latente ou heterogeneidade não observada), que são usadas para identificar a presença de interações e relações não lineares dentro dos dados que não haviam sido consideradas; (e) PLS *Predict*: O algoritmo de predição PLS usa amostras de treinamento e validação para gerar e avaliar predições a partir das estimativas do modelo de trajetórias PLS; além de outras funcionalidades como Análise Confirmatória, Análise Multigrupo (MGA), Permutação e o algoritmo da modelagem PLS consistente (*consistent PLS*) ou PLS_c (HENSELER; DIJKSTRA, 2015; RIGDON; RINGLE; SARSTEDT, 2010; SARSTEDT *et al.*, 2014b; SHARMA *et al.*, 2018). Outros softwares de apoio trazem outras opções de análise similares e/ou complementares.

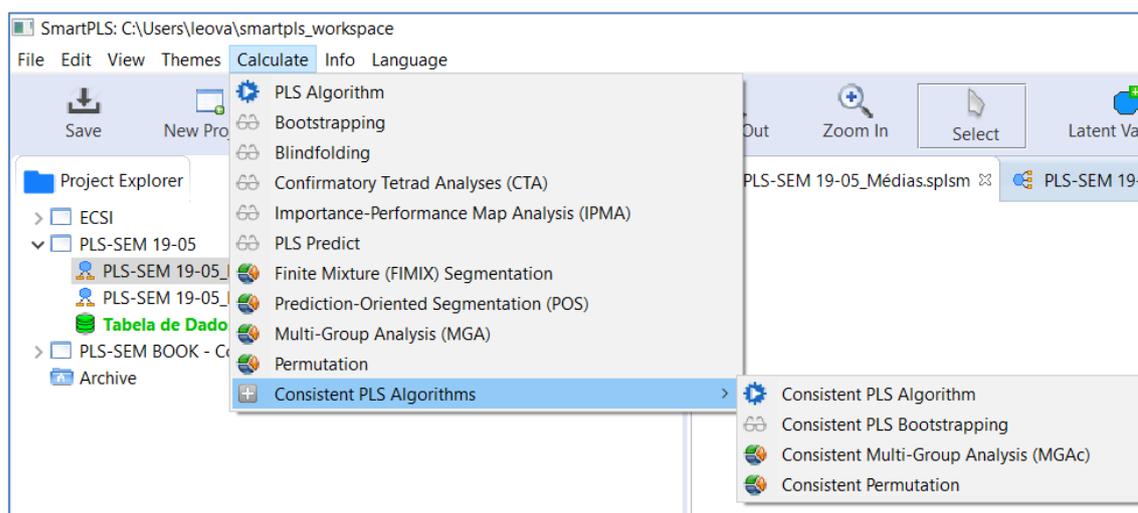


Figura 18 - Menu de Cálculos do SmartPLS® 3.0

3.3.5.4. Implementação

Os arranjos de dados para as diversas configurações de modelos são apresentados no Capítulo 4. Se o modelo tem um poder preditivo aceitável e explica uma relação causal possível entre o nível de aderência à AA e o nível de aprendizagem, é possível sistematizar uma metodologia de análise de Instituições de Ensino Superior em Engenharia para esta mesma problematização. A validação do modelo PLS-SEM para esta tese e para futuras implementações é feita com uma série de critérios e indicadores recomendados na literatura com faixas e pontos de corte (HAIR *et al.*, 2019; SARSTEDT; RINGLE; HAIR, 2017a).

A Tabela 6 reproduzida do Capítulo 2, resume alguns dos indicadores recomendados e os pontos de corte para a avaliação e validação do modelo PLS-SEM (HAIR *et al.*, 2019; SARSTEDT; RINGLE; HAIR, 2017a).

Tabela 6 - Critérios para avaliação e validação dos modelos de Medição e Estrutural

Modelos de medição reflexivos	
Cargas dos indicadores reflexivos	✓ $\geq 0,708$
Confiabilidade da consistência interna	<ul style="list-style-type: none"> ✓ O alfa de Cronbach é o limite inferior, a confiabilidade composta é o limite superior vinculado à confiabilidade da consistência interna. ✓ Mínimo 0,70 (ou 0,60 em pesquisa exploratória). ✓ Máximo de 0,95 para evitar redundância de indicadores x validade do conteúdo. ✓ Recomendado 0,80 a 0,90.
Validade convergente	✓ $AVE \geq 0,50$
Validade discriminante	<ul style="list-style-type: none"> ✓ Para constructos conceitualmente semelhantes: HTMT $< 0,90$. ✓ Para constructos conceitualmente diferentes: HTMT $< 0,85$. ✓ Teste se o HTMT é significativamente menor que o valor limite
Modelos de medição formativos	
Validade convergente (análise de redundância)	✓ $\geq 0,70$ (correlação)
Colinearidade (VIF)	<ul style="list-style-type: none"> ✓ Problemas prováveis (isto é, críticos) de colinearidade quando $VIF \geq 5$. ✓ Possíveis problemas de colinearidade quando $VIF \geq 3 - 5$. ✓ Mostrar idealmente que $VIF < 3$
Significância estatística dos pesos	✓ Valor $p < 0,05$ ou intervalo de confiança de 95%.
Relevância dos indicadores com um peso significativo	✓ Pesos significativos maiores são mais relevantes (contribuem mais).
Relevância dos indicadores com um peso não significativo	✓ Cargas $\geq 0,50$ que são estatisticamente significativas são consideradas relevantes.
Modelo estrutural	
Valor de R^2	<ul style="list-style-type: none"> ✓ Os valores de R^2 de 0,75, 0,50 e 0,25 são considerados substanciais, moderados e fracos. ✓ Valores R^2 de 0,90 e superiores são típicos indicativos de super ajuste.
Valor de Q^2	<ul style="list-style-type: none"> ✓ Valores maiores que zero são significativos. ✓ Valores maiores que 0, 0,25 e 0,50 representam relevância preditiva pequena, média e grande do modelo PLS
PLSpredict e erro de predição	<ul style="list-style-type: none"> ✓ Defina $k = 10$, assumindo que cada subgrupo atenda ao tamanho mínimo de amostra necessário. ✓ Use dez repetições, assumindo que o tamanho da amostra seja grande o suficiente. ✓ Valores $Q^2_{predict} \leq 0$ indicam que o modelo não tem desempenho satisfatório. ✓ Quanto maior o índice (> 0) menor o erro de previsão.
Comparações de modelos	✓ Selecione o modelo que minimiza o valor em BIC ou GM em comparação com o outros modelos no conjunto.
Verificações de robustez	
Modelos de medição	✓ CTA-PLS
Modelo estrutural	<ul style="list-style-type: none"> ✓ Efeitos não lineares. ✓ Endogeneidade. ✓ Heterogeneidade não observada

Como uma implementação futura na IES participante, a qual não está no escopo dessa tese, a proposta é usar a capacidade de predição do modelo para propor um score de aprendizagem a ser atingido e a partir dele sugerir um nível de aderência à AA. Uma composição dos eventos observáveis em sala de aula que possam ajustar os indicadores para atingir este alvo será buscada. A forma como um nível de aderência de AA afeta o nível de aprendizagem pode ser assegurada se estratégias adequadas de implementação das técnicas de aprendizagem ativa forem adotadas, o que será também abordado nos resultados apresentados no Capítulo 4.

4. RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os números efetivos obtidos dos experimentos reais e são feitas análises estatísticas abrangentes dos dados experimentais buscando sua validade e confiabilidade, bem como a proposição do modelo baseado em PLS-SEM. Adicionalmente, a análise crítica e a validação do modelo são realizadas através das discussões dos resultados em comparação ou contextualização com a literatura vigente (por exemplo, nos índices de qualidade e ajuste), de forma a responder as perguntas de pesquisa. Para prover consistência nos dados da pesquisa e utilizar amplamente estes dados coletados na IES participante, seja nas salas de aula, sistemas de gestão de desempenho ou pesquisas, os resultados e discussões das análises serão apresentados em duas dimensões: a) intraclasse, de forma global e por disciplina, para atender as premissas estatísticas e prover evidências demonstrar ou não as hipóteses da pesquisa, H1.1, H1.2; b) interclasse, utilizando dados globais dos indicadores, a partir da amostra de disciplinas participaram da extensão do processo de coleta de dados independentes de desempenho em semestres subsequentes, para prover evidências e demonstrar ou não a hipótese H2 da pesquisa. Neste caso, diversas abordagens quanto à composição da base de dados e aos algoritmos de simulação serão feitas em busca do melhor modelo preditivo em equilíbrio com aceitável qualidade de ajuste, sem deixar de atender as premissas estatísticas

4.1. Análise estatística na dimensão intraclasse

4.1.1. Experimento com amostras pareadas

A partir do plano original de experimentos, foi possível realizar a coleta de dados em todas as disciplinas, exceto aquela codificada como D5, cuja postergação para 1S2020 foi inviabilizada pela pandemia de COVID-19. Ao final, nesta dimensão, a amostra englobou 256 horas-aula de 5 disciplinas e 6 turmas (D1, D2, D3.1, D3.2 e D4 e D6), com 72 horas de filmagens e 202 alunos. Um corte parcial das amostras de graus de desempenho dos alunos no conjunto de todas as disciplinas é mostrado na Tabela 7. Dentro deste escopo, busca-se testar a hipótese H1.1 e responder à pergunta de pesquisa 1.

Tabela 7 - Corte parcial das amostras de graus de desempenho

#	Nota1-Global	Nota2-Global
1	47	45
2	54	42
3	47	23
4	33	28
..	40	49
..	28	59
..	38	82
..	85	96
201	46	62
202	68	80

Como o *test-t* pareado utiliza a média das diferenças para verificar a hipótese nula de que as médias das amostras são iguais (i. e. as médias das diferenças é zero), importa a distribuição desse novo *set* de dados. A Figura 19 evidencia que a distribuição é normal pelo teste de Anderson-Darling ($p > 0,05$), não se rejeitando a hipótese nula e confirmando a validade plena do teste. Na sequência, o relatório copiado da janela *Session* do Minitab® e o *boxplot* da Figura 20 demonstram evidência estatística que as médias dos alunos não foram iguais e melhoraram com a aplicação das técnicas ativas. O resultado apresentou valor $p = 0,000$. É possível então rejeitar a hipótese nula que as médias foram iguais. Assim, na avaliação global, a hipótese teórica de melhora no desempenho dos alunos (aumento significativo da média) a partir de uma implementação de técnicas ativas foi demonstrada.

Em valores nominais, as médias foram maiores na segunda avaliação (64,67) comparado com a primeira (57,61), o que representa 14% de aumento sobre a primeira nota. Em medidas de desvio padrão representou ~40% do desvio padrão médio das amostras. Em comparação Freeman et. al., (2014) concluíram com seu estudo publicado na revista americana PNAS (*Proceedings of the National Academy of Science*) sobre a melhoria do desempenho em diversos experimentos comparativos de aprendizagem tradicional com aprendizagem ativa para alunos de cursos STEM em torno de metade do desvio padrão das amostras. Alguns outliers surgiram devido a grandes diferenças observadas entre a primeira e segunda nota (por ex.: a amostra de número 66 mostrou que um aluno tirou 20 na primeira avaliação e 95 na segunda avaliação), mas os outliers em avaliações são possíveis e a análise prática do pesquisador foi de manter todos os outliers, pois eles podem ocorrer aleatoriamente para qualquer direção dos

dados, portanto, sem viés a priori para os resultados. A amostra foi suficiente para detectar um efeito de 0,35 (8 pontos) com > 80% de poder estatístico (COHEN, 1988).

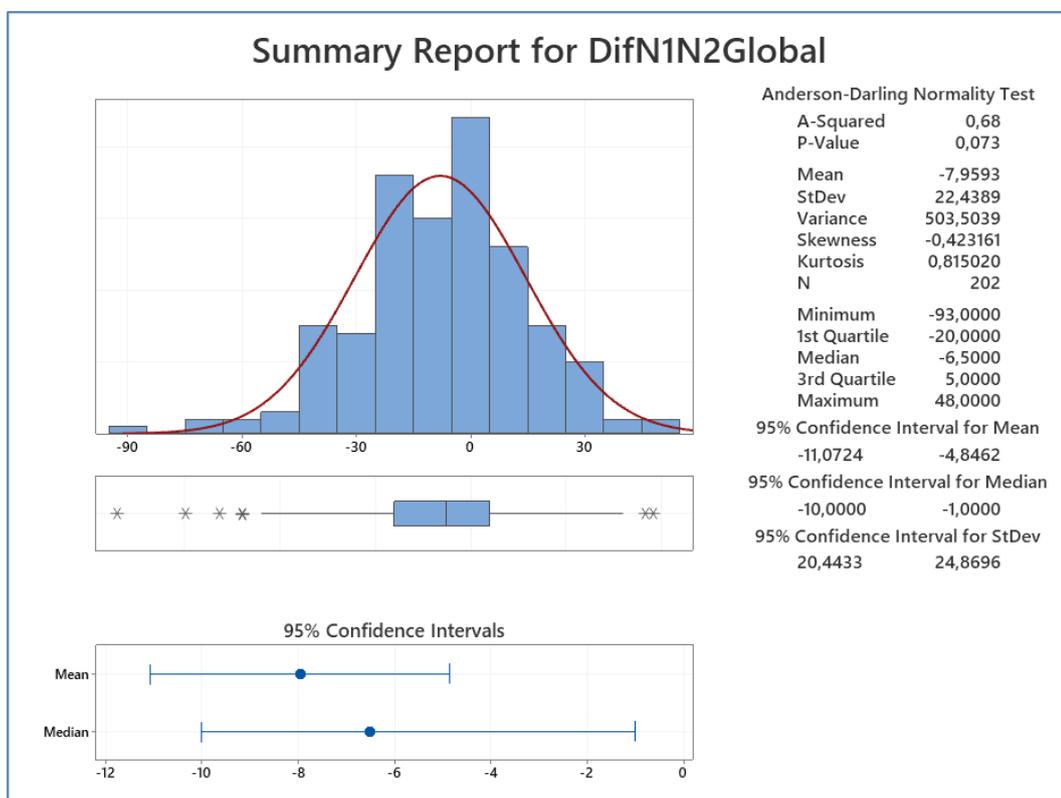


Figura 19 - Teste de normalidade para a distribuição das diferenças

Paired T-Test and CI: Nota1_Global; Nota2_Global

Descriptive Statistics

Sample	N	Mean	StDev	SE Mean
Nota1_Global	202	56,71	22,54	1,59
Nota2_Global	202	64,67	26,36	1,85

Estimation for Paired Difference

Mean	StDev	SE Mean	95% Upper Bound for $\mu_{\text{difference}}$
-7,96	22,44	1,58	-5,35

$\mu_{\text{difference}}$: population mean of (Nota1_Global - Nota2_Global)

Test

Null hypothesis

$H_0: \mu_{\text{difference}} = 0$

Alternative hypothesis

$H_1: \mu_{\text{difference}} < 0$

T-Value	P-Value
-5,04	0,000

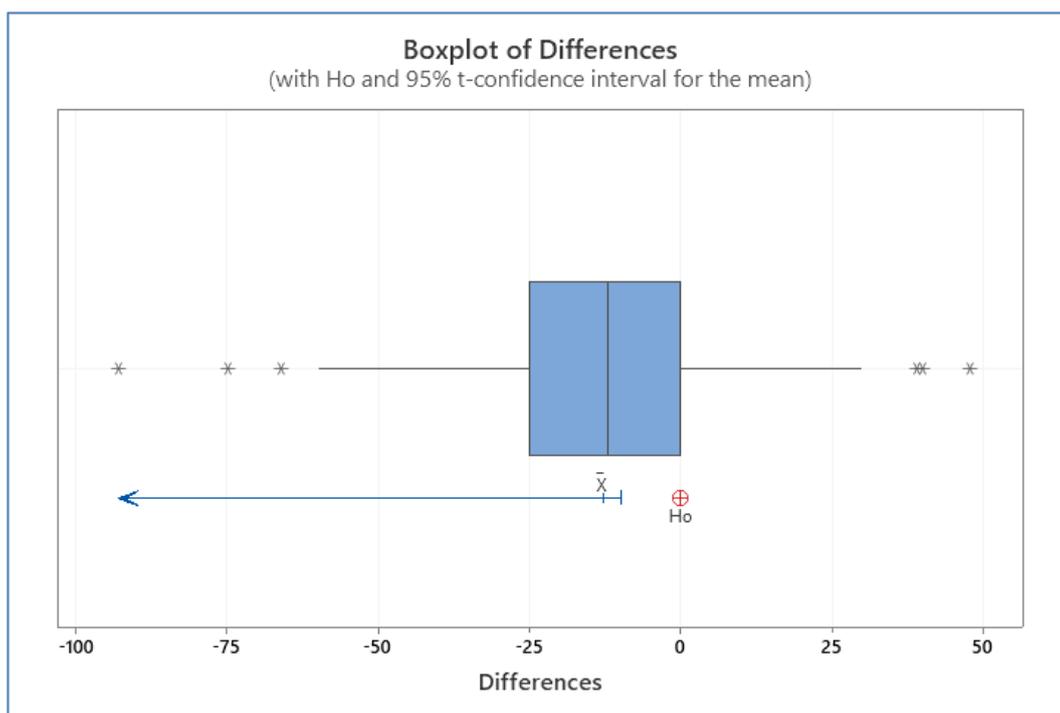


Figura 20 - Diferenças entre as médias globais das amostras

4.1.1.1. Avaliação da influência de outros fatores

Em resposta a questão do possível viés entre as notas da primeira e da segunda avaliação, causado por alguma variável ou fator externo ao experimento, foi definido no método que uma avaliação seria feita. Uma das hipóteses a serem validadas nessa IES na dimensão intraclasses é que as técnicas de AA contribuem para a melhoria do desempenho dos alunos, separando-se a influência de outros fatores, que não foram alterados intencionalmente nos experimentos controlados. Para assegurar que não haveria previamente um viés de aumento das notas da segunda avaliação (NP2) em relação à primeira (NP1), foi realizado um teste estatístico apropriado, o teste t pareado unilateral à esquerda, com grau de significância $\alpha = 0,05$, considerando as hipóteses: $H_0 = \text{média das diferenças de } (NP1 - NP2) = 0$; $H_1 = \text{média das diferenças de } (NP1 - NP2) < 0$. O teste abrangeu avaliações do semestre anterior ao início do projeto dos experimentos (2S2017) coletadas de forma aleatória, em duas amostras pareadas de 4409 notas de 4409 alunos. O resultado obtido do Minitab® demonstra evidência para rejeitar a hipótese nula que a média das diferenças dessas avaliações são iguais ($p = 0,000$) e a média de NP2 (61,619; SD = 25,743) é na verdade ligeiramente menor do que NP1 (62,876; SD = 23,678). O poder estatístico do teste foi próximo de 85% para detectar uma

diferença (efeito) de 1 ponto entre as médias. O efeito calculado pelo d de Cohen = 0,05 é muito baixo e trivial (COHEN, 1988); e teoricamente com pouco significado prático no caso de rejeição da hipótese nula. Portanto, não houve evidência de viés de diferença das médias em favor das notas da segunda avaliações. Assim, o único fator passível de controle do pesquisador que foi alterado foi a implementação das técnicas ativas na segunda metade do curso. Estima-se, portanto, que outras variáveis não controláveis (aspectos psicológicos, infraestrutura, temperatura, pressão, humidade, perfil, histórico, estilo, etc.), que poderiam afetar os comportamentos em sala de aula e, supostamente, os graus de desempenho, tenham seus efeitos aleatórios compensados e explicados na parcela de erro das medições.

4.1.2. Análise global intraclasse – perfil e estratégias de AA

A análise e discussão desta subseção devem apoiar a resposta à pergunta de pesquisa 3, pois abordam o perfil global das aulas e disciplinas. A Figura 21 ilustra o comparativo de nível de atividade nas aulas tradicionais (T) e ativas (A) considerando a média entre todas as disciplinas e representa como se comportam os indicadores da variável latente exógena. As aulas tradicionais representadas pelos indicadores das barras hachuradas apresentam barras mais altas na utilização do tempo de aula com palestras (63,74%), escrita no quadro (29,62%) e audição passiva (75,93%), como esperado. O tempo alocado para tarefas administrativas e de espera do instrutor chegam a um máximo de 6,90% do tempo ativo, já identificados pelas observações como eventos específicos durante as aulas amostradas, tais como avisos, manutenção, atrasos, etc.

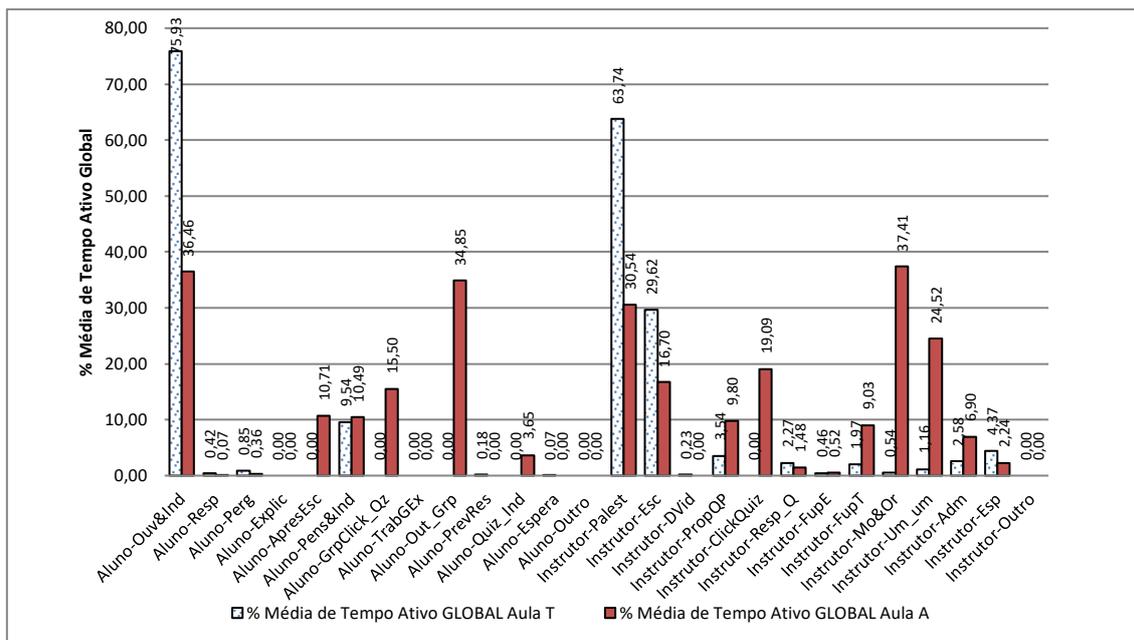


Figura 21 - Análise Global Aula Tradicional x Ativa - % Média de Tempo Ativo

Nas barras sólidas, percebe-se quedas de 63,74% para 30,54% da porcentagem do tempo total ativo da aula gasto com palestras e de 29,62% para 16,70% da porcentagem relativa do tempo gasto com escrita no quadro, por parte do instrutor. Por parte dos alunos, houve redução de 75,93% para 36,46% da porcentagem de tempo relativo ao total ativo da aula gasto em audição passiva. Houve uma compensação entre as disciplinas D3.1, D3.2 e D6 que privilegiaram técnicas de mini projetos e associadas ao PjBL e tiveram quedas mais expressivas, em comparação com as outras disciplinas que mesmo nas aulas ativas ainda continuaram utilizando de forma importante as palestras e escrita no quadro, com maior passividade dos alunos.

Os eventos de maior destaque que surgiram nas aulas ativas, em contraponto, foram indicados pelo protocolo de observação como: a) o instrutor propondo projetos ou questões em grupo (Instrutor-ProQP), com 9,80% do tempo relativo e propondo Quiz (Instrutor-ClickQuiz) com 19,90%; b) os alunos fazendo os projetos em grupo (Aluno-Out_Grp) que levou o indicador de zero para 34,85% e fazendo Quiz em grupos (Aluno-GrpCLick_Qz) com 15,50% do tempo ativo, potencializando efeito positivo no aprendizado; c) instrutor caminhando pela sala e orientando os alunos enquanto os mesmos resolvem os projetos (Instrutor-Mo&Or), cujo valor foi 37,41% e a extensão da discussão e das explicações para um ou outro aluno específico de qualquer grupo, enquanto os outros alunos ouvem nas proximidades (Instrutor-Um_Um), cujo valor chegou a 24,52%. Outros tiveram valores muito baixos, com efeito não significativo no resultado dos experimentos. O protocolo de observação PORE utilizado para as observações

foi adaptado do COPUS, o qual tem extensa validação na literatura (SMITH et al., 2013). No entanto, os observadores desta pesquisa, o pesquisador (Obs1) e um assistente de pesquisa (ObsA), tiveram suas observações testadas para confiabilidade através do índice IRR (*Inter Rater Reliability*) e alpha de Cronbach. Os resultados de IRR obtidos através do Minitab® utilizando a estatística ICC para 3 observações de 2 observadores das mesmas aulas mostraram uma média do ICC > 0,95 e um alpha de Cronbach > 0,9, valores que reportam alta confiabilidade e consistência interna, respectivamente, aceitos pela literatura vigente (LIU et al., 2016; RUI; FELDMAN, 2012).

4.2. Os efeitos das estratégias de AA em disciplinas individuais

Esta seção fornece uma análise individual das disciplinas utilizadas para testar a hipótese H1.2 e complementar a resposta à pergunta de pesquisa 3. O resultado e o perfil dos cursos individuais são apresentados na Tabela 8, de acordo com as estratégias e técnicas de AA implementadas pelos instrutores. O teste de hipótese para a diferença entre as amostras de Grau 1 e 2 (Grau 1 - Grau 2) foi definido como: $H_0: \mu_{\text{difference}} = 0$; $H_1: \mu_{\text{difference}} < 0$, pois a hipótese alternativa teórica aponta para uma melhora esperada após a aplicação de AA (Grau 1 < Grau 2).

Tabela 8 - Resultado individual de disciplinas e técnicas de AA aplicadas

Disciplina	Amostra (N)	Grau 1 Médio (SD)	Grau 2 Médio (SD)	Avaliação	Paired t-test P-value	Técnica AA predominante
D1	24	41 (10)	38 (18)	Nenhuma mudança significativa	0.779	<i>Socrative® Quizzes, Team Based Learning, Flipped Classroom</i>
D2	55	51 (23)	70 (23)	Aumento significativo da média	0.000	<i>Socrative® Quizzes, Team Based Learning, Flipped Classroom</i>
D3 Turma 1	33	85 (14)	94 (13)	Aumento significativo da média	0.001	<i>Team Based Learning, Project-Based Learning</i>
D3 Turma 2	25	66 (16)	77 (16)	Aumento significativo da média	0.005	<i>Team Based Learning, Project-Based Learning</i>
D4	34	45 (18)	53 (20)	Aumento significativo da média	0.029	<i>Socrative® Quizzes, Peer Instruction, TBL, Flipped Classroom</i>
D5	31	55 (16)	48 (22)	Nenhuma mudança significativa	0.988	<i>Team Based Learning, Project Based Learning</i>

A discussão dos efeitos das estratégias de AA, consolidadas ou em cursos individuais, revelou os altos e baixos da implementação de AA em um ambiente de EE tão complexo (CHRISTIE; DE GRAAFF, 2016) e também permitiu ao autor sugerir estratégias para implementações futuras em contexto semelhante ou diferente. Embora a comparação das notas consolidadas para avaliar efeitos na aprendizagem tenha mostrado evidências de efeito significativo e sejam um indicador relevante (AUYUANET et al., 2018; KIM, 2020), as estratégias tiveram papéis relevantes no sucesso das implementações de cada disciplina. A discussão dos resultados individuais revelou várias oportunidades para informar pesquisas futuras. De acordo com as discussões e pesquisas pós-experimento com os instrutores, os resultados de D2, D3 e D4 mostraram melhora nas notas dos alunos após suas implementações específicas de técnicas de AA. D2 e D4 usaram uma abordagem semelhante e mais simples. Ambos usaram os questionários da plataforma Socrative® como principal ferramenta de tecnologia, pois o suporte para perguntas *clicker* não estava disponível nas salas de aula (MAZUR; WATKINS, 2009). Eles se associaram a discussões em grupo no caso de D2, discussão entre pares e questionários antes e depois do trabalho individual e discussões em pares no caso de D4 (MAZUR, 1997), e abordagens TBL para ambos sem pré-definir a equipe de trabalho (MICHAELSEN; SWEET, 2008). Pareceu bastante positivo como os instrutores se concentraram em seu papel de mentores para cada grupo, andando pela sala de aula e monitorando o trabalho dos alunos durante as tarefas. Porém, D2 e D4 ainda usaram aulas expositivas nas aulas ativas. D3 usou a mesma abordagem para as suas aulas e praticamente aboliu as aulas expositivas. As aulas adaptaram técnicas de aprendizagem baseadas em projetos – PjBL (PECORE, 2015), utilizando de fato mini projetos, trabalhos de grupo (TBL sem grupos pré-definidos) e tutoria intensiva. Os alunos ainda apresentaram suas soluções no quadro verde, motivando a sua participação. Os miniprojetos de D3 eram propostos para solução em uma ou duas aulas, abordando situações que utilizassem circuitos lógicos de diversos tipos, que seriam associados e configurados para gerar a figura de resposta de saída esperada. É interessante notar que a infraestrutura da sala de aula não se mostrou a mais adequada para uma interação efetiva entre os alunos para trabalhos em grupo.

D1 e D6 não mostraram mudança estatisticamente significativa nas notas após a implementação de AA. A abordagem de D1 era semelhante a D2 e D4, mas o instrutor focava na solução individual dos questionários, eventualmente permitindo grupos de dois membros e aproveitando a discussão entre pares (MAZUR, 1997). Um conjunto de perguntas foi elaborado previamente como um questionário que pareceu bastante complexo. Observou-se também na

análise que ainda havia um tempo razoável de dedicação à aula expositiva e as soluções do quiz acabaram com explicações complementares e soluções parciais por parte do instrutor, e não apenas dos alunos. Semelhante a D2, D3 e D4, a infraestrutura da sala de aula era um móvel fixo, sem facilitação de trabalho em grupo e interação. D5 adotou uma técnica de AA eficaz e bem conhecida - PjBL (MITCHELL; ROGERS, 2020; PECORE, 2015) como principal técnica, semelhante ao D3, mas sem alcançar a melhoria de desempenho esperada. Neste caso eram projetos amplos de implementar um sistema microprocessado inteiro, incluindo a programação, durando praticamente a segunda metade inteira do curso. Depois de observar as aulas várias vezes, não foi possível detectar nenhum evento que gerasse essa diferença. Houve mentoria, trabalho em grupo e percepção de progresso e interações. No entanto, o instrutor observou que alguns alunos em grupos de 3 não trabalharam de forma eficaz, dependendo de seu interesse específico em outras atividades extraclasse. Como alguns deles estavam no final do programa, o interesse individual parece ter sido afetado. Não foi possível confirmar essa avaliação pela gravação do vídeo, mas apenas pela percepção do instrutor. Por outro lado, o projeto da infraestrutura da sala de aula D6 estava em conformidade com o formato recomendado para AA (JOHNSON *et al.*, 2019).

A percepção dos professores da equipe após os experimentos intraclasse foi capturada por uma *survey* utilizando a plataforma Google Docs®. Em uma primeira abordagem eles revelaram o quanto aplicaram de uma ou mais técnicas de aprendizagem e o quanto pretendiam aplicar no futuro. As quatro técnicas mais mencionadas são ilustradas na Figura 22, Figura 23, Figura 24 e Figura 25:

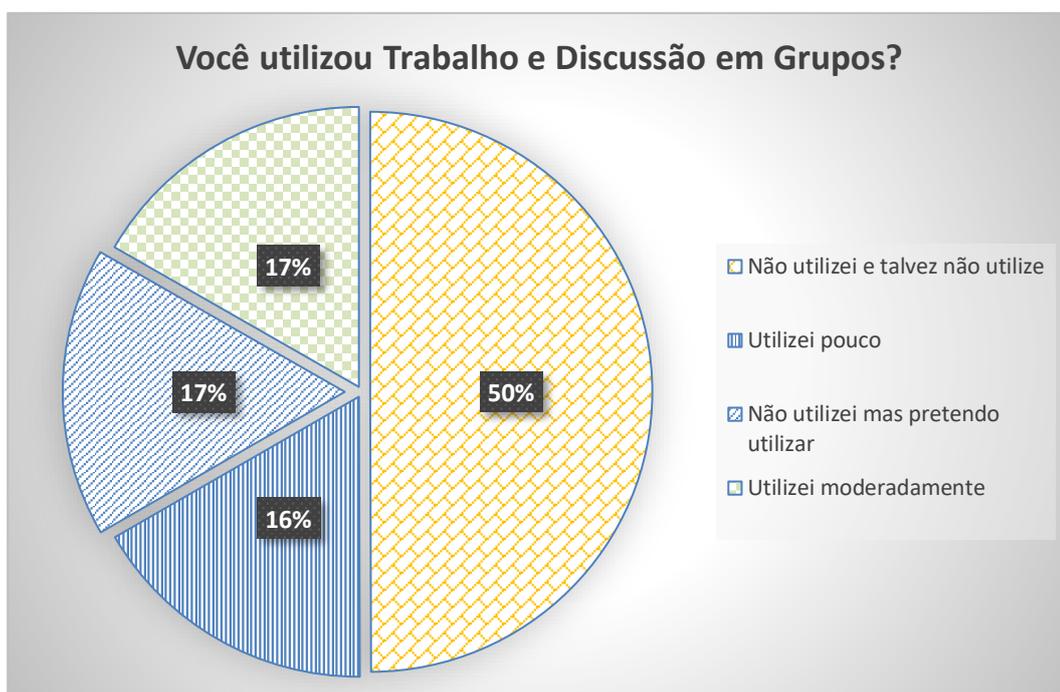


Figura 22 - Percepção dos professores I

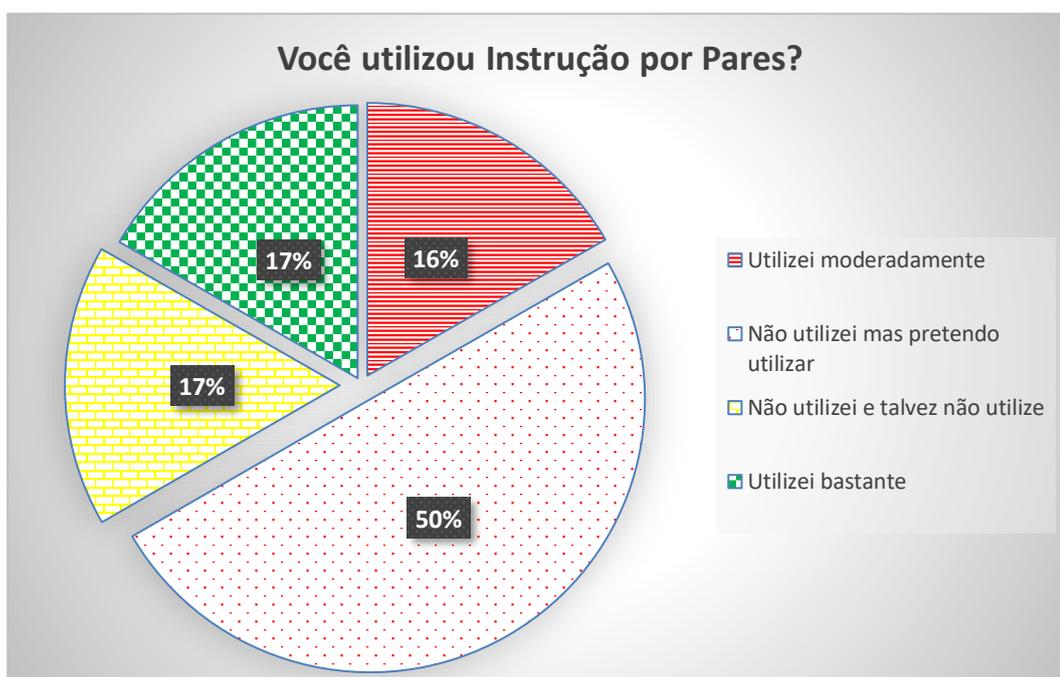


Figura 23 - Percepção dos professores II

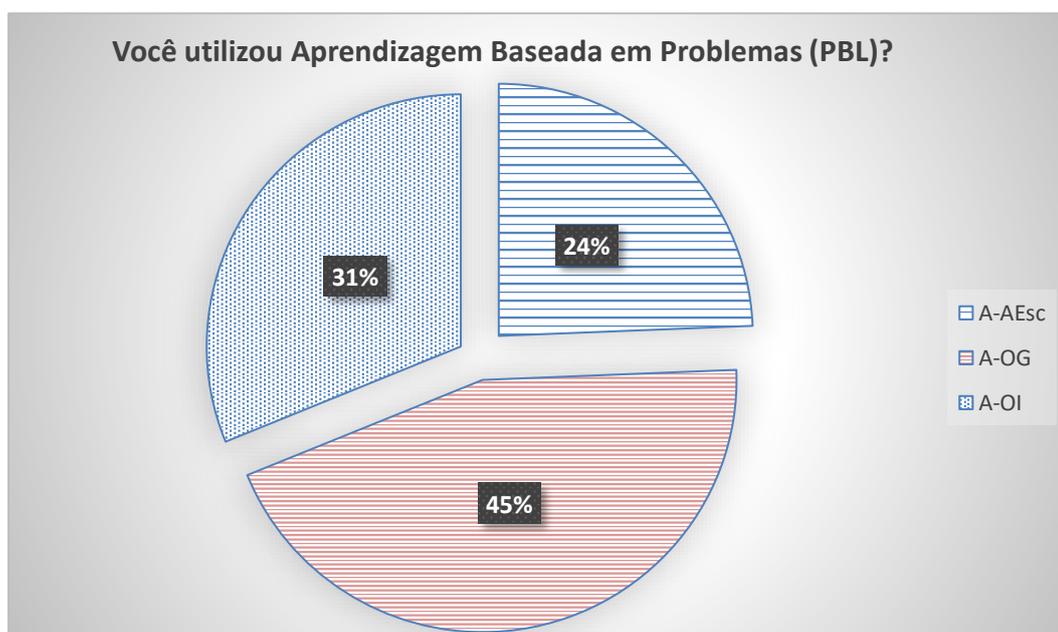


Figura 24 - Percepção dos professores III

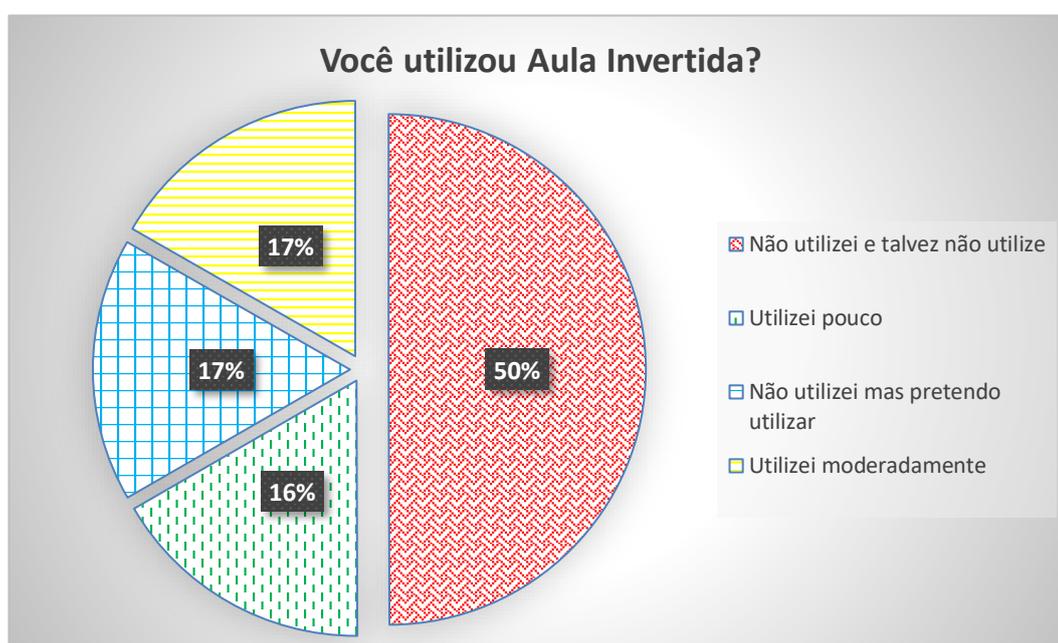


Figura 25 - Percepção dos professores IV

Outras 30 perguntas permearam todos os detalhes da experiência dos professores. Os resultados obtidos e apresentados através de diversos gráficos estão disponíveis como material suplementar que pode ser solicitado a posteriori ao pesquisador.

Além disto, uma análise qualitativa foi feita através da coleta de opiniões e sugestões livres dos professores no escopo da mesma pesquisa, com duas perguntas, as quais transmitiram uma visão objetiva sobre o processo experimental. Percebe-se a visão positiva sobre a aplicação atual de AA e perspectivas futuras, mas sem apontar os desafios e resistências potenciais associadas ao perfil dos alunos.

Pergunta 1: “Quais aspectos das técnicas de aprendizagem ativa você achou mais úteis ou valiosas”?

Respostas:

- “A maior vantagem que observei foi a possibilidade de interagir com os alunos no momento em que eles encontram a primeira dificuldade para resolver os problemas relacionados com os conteúdos ministrados”.
- “A modalidade de instrução por pares combinada com *clicker* parece adequada a disciplinas como D1. Acaba "tomando" boa parte do conteúdo, mas os alunos parecem gostar, principalmente por causa da pontuação da atividade. Não sei se se motivariam sem que houvesse pontuação. Aliás, mesmo havendo, notei que a preparação para a atividade (que deveria ser feita em casa) deixou a desejar. A passividade do aluno da IES participante é cultural!”
- “Não sei responder, utilizei poucos métodos”.
- “Um maior interesse dos alunos”.
- “Os alunos ficam mais interessados em pesquisar soluções novas para os problemas propostos”.
- “Questões usando perguntas no computador (celular)”.

Pergunta 2: “Quais aspectos das técnicas de aprendizagem ativa, do curso ou da instituição você mudaria para uma implementação ainda melhor”?

Respostas:

- “Devido a minha curta experiência neste assunto, ainda não consigo apresentar sugestões de melhorias”.
- “No próximo semestre irei aplicar novamente a *peer instruction* + *clicker*, distribuindo as atividades ao longo do semestre. Hoje aplico 3 provas normais, descartando a menor

nota. No semestre que vem aplicarei 2 provas e comporei uma terceira nota com a média das notas das *clicker questions*. Ainda assim descartarei a menor dentre as 3. Uma vantagem é que a nota final das *clicker questions* só será conhecida ao final do semestre, o que reduzirá a chance de algum aluno passar com apenas duas notas e sumir das aulas”.

- “Ter mais orientações e tempo de como poderia ser aplicado na minha disciplina.”
- “Maior tempo para planejamento”.
- “Trabalhar com grupos menores. Fazer avaliações intermediárias nos grupos de trabalho”.
- “Aproximação do aluno com o professor”.

Com base nos resultados individuais quantitativos e qualitativos, foi possível sugerir que estratégias diferenciadas de sala de aula, que incluem as técnicas de AA, podem ser um elemento de apoio no sucesso da implementação de técnicas de aprendizagem ativa no ensino de engenharia.

A Tabela 9 apresenta as estratégias de AA propostas nesta tese com base nos elementos do protocolo, na eficácia de cada estratégia de curso utilizada no experimento pelos instrutores, na visão global e na literatura disponível.

Tabela 9 - Estratégias de AA propostas a partir da pesquisa

Disciplina	Características	Referências selecionadas da literatura	Estratégias de AA propostas
D1, D2	A abordagem teórica na área da Engenharia (letra E do grupo STEM)	(Mazur 1997), (Mazur and Watkins 2009), (Bruff 2009), (Bishop and Verleger 2013), (Clark et al. 2016), (Lefebvre and Prakash 2018), (Hora 2015).	<ul style="list-style-type: none"> a. Sala de aula invertida com perguntas <i>Clicker</i> usando uma plataforma automatizada; b. Discussões em pares para conceitos; c. Aplicar a mesma pergunta <i>clicker</i>, após a discussão e comparar. Explicar novamente o conceito se o desempenho for < 70% de acerto. d. Mini problemas de engenharia com casos reais em grupos e mentoria eficaz incentivando os alunos a buscar soluções; e. Pausa e <i>Think-Pair-Share</i> como técnicas de apoio; f. Valorização e inclusão dessas atividades no processo global de avaliação; g. Implementar avaliações do tipo formativas (avaliar várias vezes no decorrer das atividades do período dando feedback ao aluno de como ele está desenvolvendo), misturando com avaliações somativas (meio e final do semestre).
D3, D5	Abordagem de raciocínio lógico e científico (letra T do grupo STEM)	(Prince and Felder 2006), (Kelly et al. 2005), (Hadim and Esche 2002), (Cian et al. 2018), (Guimarães et al. 2016).	<ul style="list-style-type: none"> a. Mini problemas em pares com perguntas <i>Clicker</i> em plataforma automatizada antes e depois da atividade, revisando os conceitos se o desempenho global ficar abaixo de 70%; b. Aprendizagem Baseada em Problemas (PBL) com equipes de até 4 pessoas (para dividir melhor o trabalho e assegurar relativa participação de todos), ocupando até 1/3 da carga horária. c. Aprendizagem Baseada em Projetos (PjBL) com equipes de até 4 pessoas (para dividir melhor o trabalho e assegurar relativa participação de todos), ocupando até 80% da carga horária; d. Salas de aula flexíveis na infraestrutura para permitir a máxima interação da equipe. e. Incluir essas atividades no processo de avaliação, como na estratégia anterior. No caso de PBL e PjBL, tornar o processo totalmente formativo (sem provas ou exames, somente relatórios sequenciais e apresentações).

Disciplina	Características	Referências selecionadas da literatura	Estratégias de AA propostas
D4	Abordagem de raciocínio matemático e científico (letras S e M do grupo STEM)	(Mazur 1997), (Mazur and Watkins 2009), (Bruff 2009), (Bishop and Verleger 2013), (Clark et al. 2016), (Lefebvre and Prakash 2018), (Sunal et al. 2016).	<ul style="list-style-type: none"> a. Palestras abordando conceitos centrais; b. Sala de aula invertida e perguntas de <i>Clicker</i> antes e depois da discussão em pares para os conceitos centrais em uma plataforma automatizada; c. Revisar os conceitos se o desempenho global ficar abaixo de 70%; d. Usar Pausa e <i>Think-Pair-Share</i> como técnicas de apoio durante as palestras. e. Implementar avaliações do tipo formativas (avaliar várias vezes no decorrer das atividades do período dando feedback ao aluno de como ele está desenvolvendo), misturando com avaliações somativas (meio e final do semestre).

4.3. Implementação, análise e validação do modelo PLS-SEM

Esta seção aborda os resultados da pesquisa na dimensão interclasse e busca testar e demonstrar a hipótese H2 e responder à pergunta de pesquisa 2. Nesta dimensão, foi possível incluir 184 horas-aula de 4 disciplinas e 4 turmas (D1, D2, D3.2 e D4) que puderam prosseguir com os experimentos seguindo a sistemática metodológica nos semestres subsequentes às primeiras medições intraclasse. Estas horas-aula formaram o conjunto de 184 observações para a modelagem, dentro da especificação original do modelo PLS-SEM. No lado dos participantes, restaram para esta dimensão 171 alunos (e seus graus de desempenho) da amostra de perfil tradicional (sem técnicas de AA) destas disciplinas e mais 197 novos alunos da amostra de perfil ativo (com técnicas de AA), independentes, de semestres subsequentes. As discussões apresentadas na fundamentação teórica de PLS-SEM evidenciaram sua adequação para uma relativa flexibilidade no tamanho da amostra, premissas menos restritas sobre as distribuições de frequência (não normalidade dos dados) e o poder estatístico da metodologia (HAIR *et al.*, 2017).

Pretende-se, portanto, fazer a avaliação e validação dos modelos externo e interno do sistema de equações estruturais especificado nesta pesquisa, a partir de uma sequência de três etapas:

- 1) Análise de Interação: visa a construção de arranjos de dados que permitam simular possíveis interações utilizando efeitos moderadores, quadráticos ou não, utilizando as funcionalidades de análise de dados do WarpPLS®.

- 2) Análise preliminar: demonstra a evidência estatística da relação positiva de causa-efeito, verifica a relevância preditiva do modelo utilizando o PLS no algoritmo tradicional e faz a caracterização prévia de não linearidade no modelo.
- 3) Análise final: realizar a avaliação completa do modelo, experimentando reduções ou adições de indicadores (HAYDUK; LITTVAY, 2012) e algoritmos de apoio que permitam a maximização da qualidade preditiva do modelo, através das funcionalidades do SmartPLS®. A literatura de delineamento de experimentos envolvendo número elevado de variáveis destaca o princípio da parcimônia, por exemplo em (GUIMARAES; AZEVEDO JR., 2020, p.121), segundo o qual o modelo mais simples que explica os dados é provavelmente o modelo melhor.

4.3.1. Análise de interações e escolha do arranjo de dados

Nesta etapa, experimentou-se arranjos de dados que permitiram simular possíveis interações utilizando efeitos moderadores, quadráticos ou não, utilizando as funcionalidades do WarpPLS®. Os dados e as matrizes completas de dados estão disponíveis como dados suplementares. A Figura 26 mostra um resumo dos resultados. Para possibilitar a simulação de efeitos de interação de outras variáveis exógenas no modelo estrutural, foi feita uma alteração da especificação original do modelo e as observações foram divididas em dois conjuntos (relativos às observações sem e com AA), codificados como arranjos 92+92 D1-D4 e 13+13 D1-D4. O primeiro arranjo usou as observações (*cases*) originais e o segundo usou subgrupos de médias como forma de reduzir eventuais valores faltantes e analisar os efeitos. Foi então possível simular um possível efeito moderador (interação) do desempenho dos alunos na primeira avaliação, sem AA (variável S_AP) sobre o desempenho da segunda avaliação, com AA (C_AP). Os resultados demonstraram não haver interação significativa com baixo coeficiente de determinação ($R^2 = 0,11$ e $R^2 = 0,09$). A confiabilidade composta CR > 0,95 indicou alto índice de colinearidade (confirmado com VIF > 14,7), com provável alinhamento direto e desencadeando correlações infladas entre os termos de erro dos indicadores. Isto demonstrou a inviabilidade dos modelos com interação (SARSTEDT; RINGLE; HAIR, 2017a). Para comparação, *screening* (filtragem) e confirmação do melhor arranjo, foram simulados outros dois arranjos em modelos sem interação, 24 D1-D4 (médias de subgrupos de observações) e 184 D1-D4 (especificação original). Observando os coeficientes de trajetória e de determinação (predição dentro da amostra) do modelo estrutural, o melhor desempenho,

satisfatório em termos dos critérios normalmente aceitos (HAIR et al., 2019), foi o arranjo 184 D1-D4 com $R^2 = 0,45$ e $\beta = 0,67$.

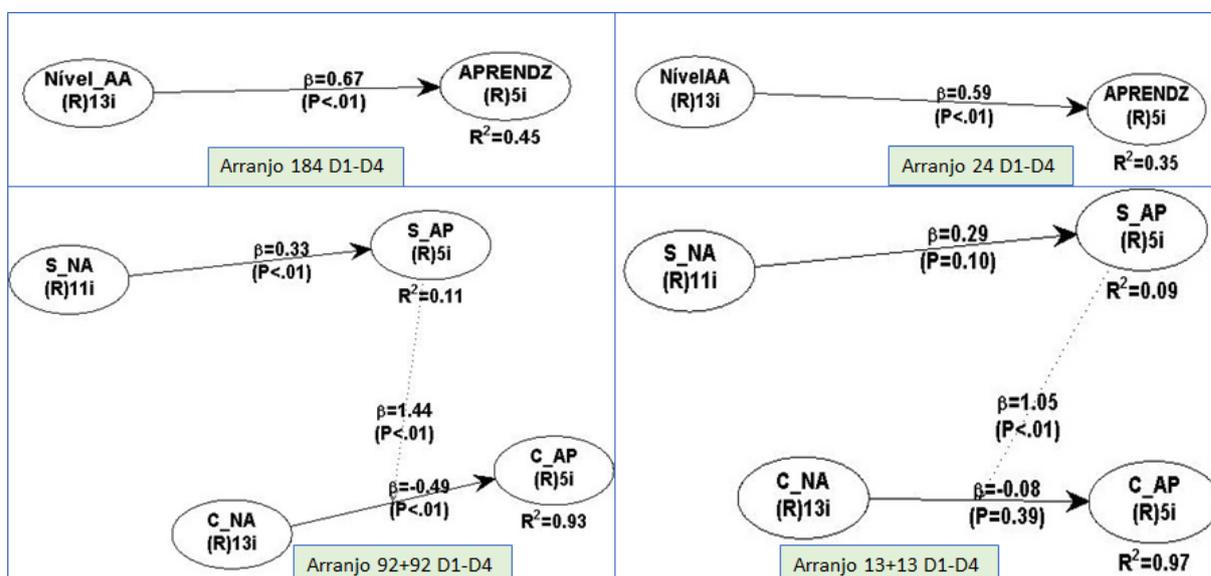


Figura 26 - Resumo de resultados do *screening* de arranjos

4.3.2. Análise Preliminar

Nesta etapa pretendeu-se caracterizar de forma mais abrangente o conjunto de dados selecionado anteriormente no arranjo 184 D1-D4, na condição de um teste-piloto. Objetivamente, verificou-se a evidência estatística da relação positiva de causa-efeito, a relevância preditiva (utilizando o PLS no algoritmo tradicional, menos restritivo), a caracterização prévia de não linearidade no modelo, o que daria indicações de curvatura na relação entre as variáveis latentes e indicaria os melhores algoritmos de análise.

Na análise da relação de causa-efeito, a amostra de 197 notas permitiu detectar um efeito de 0,25, equivalente a 5 pontos de diferença nas notas globais com poder estatístico de 0,70 e $\alpha = 0,05$. Como as amostras são independentes e aproximadamente normais ($p < 0,005$ e $p = 0,1$ para as notas com e sem AA, respectivamente) o teste de hipóteses da ANOVA de 1 fator, com correção para variâncias diferentes, resultou em $p = 0,035$, médias de Nota1 = 51,80 (SD = 19,92) e de Nota2 = 56,84 (SD = 25,73), rejeitando a hipótese de igualdade das médias, ou seja, a média global após a aplicação de AA nas turmas independentes foi estatisticamente maior: 10% ou 22% do desvio padrão médio (GAUS; MAYER; MUCHE, 2015; KIM; CHOI, 2019;

RUBIN, 2017). Como complemento, utilizou-se o teste não paramétrico de Mann-Whitney para confirmar esta diferença, sem as restrições (premissas) da ANOVA. O resultado demonstrou a diferença no ponto exato de corte da significância com $p = 0,05$. Os dados foram computados no Minitab®. Em comparação com a dimensão intraclasse, a melhoria no desempenho foi ligeiramente menor, equivalente a 5 pontos em uma escala de 0 a 100. No entanto, observou-se que o efeito menor a ser detectado ficou próximo ao limite do poder estatístico pois o tamanho amostral foi também um pouco menor, além do fator de erro entre sujeitos que está presente nesta configuração, já que são alunos diferentes. De toda forma, o desempenho melhorou de forma similar à dimensão intraclasse, já que toda a sistemática metodológica experimental, as técnicas de AA e o padrão das avaliações foram mantidas.

A especificação do modelo foi definida como no Capítulo 3. A tabela de dados de medição foi montada com os indicadores de **Aderência à AA** em um conjunto de 184 observações associadas às aulas sem e com aprendizagem ativa, devidamente codificados, advindos do baseline da dimensão intraclasse. Da mesma forma, foram tabelados os indicadores da **Aprendizagem** contendo a) as médias de subgrupos e médias globais das avaliações realizadas nos ambientes de aulas tradicionais (sem o tratamento utilizando técnicas de AA) originados do baseline da dimensão intraclasse e b) os dados independentes das avaliações realizadas em ambiente de aulas ativas (utilizando técnicas de AA) da dimensão interclasse, em semestres subsequentes. Os dados foram filtrados para aquelas disciplinas que foram mantidas na pesquisa (D1, D2, D3 e D4).

A Tabela 10 resume os resultados da análise preliminar rodando o algoritmo ordinário do PLS-SEM no software SmartPLS®, de acordo com o critério obtido na literatura vigente. Os resultados indicaram um desempenho preditivo aceitável e foi possível validar o modelo piloto com bons índices em outros testes, como foi destacado na coluna Análise.

Tabela 10 - Resultados da análise preliminar da modelagem

	Resultados	Análise	Referência
Causa-efeito e predição dentro da amostra	$R^2 = 0,488$	Valor moderado $\sim 0,50$	HAIR <i>et al.</i> , 2019
Relevância Preditiva	$Q^2 = 0,348$ (AP)	Valores entre 0,25 e 0,50 são de média para grande.	HAIR <i>et al.</i> , 2019
Efeito quadrático	Coefficiente = 0,143	Existe uma relação não linear que deve ser considerada.	HAIR <i>et al.</i> , 2019

	Resultados	Análise	Referência
Cargas/Pesos	8 em 13 > 0,50 para indicadores de NAA. Todos > 0,70 para indicadores de AP	Será testada a eliminação de indicadores com cargas baixas < 0,50.	HAIR <i>et al.</i> , 2019
Convergência	AVE=0,456 para NAA e 0,776 para AP	De média para forte convergência com AVE > 0,50	HAIR <i>et al.</i> , 2019
Confiabilidade geral do modelo	<i>Composite Reliability</i> > 0,892	Valores > 0,70 para pesquisas exploratórias	HAIR <i>et al.</i> , 2019

O valor de do coeficiente de determinação $R^2 = 0,448$, que avalia a relação de causa-efeito e também o poder de predição dentro das amostras, ficou na faixa de valores moderados, compatível com o que foi encontrado na análise de interação e escolha do modelo 184 D1-D4 em outro software de análise. A relevância preditiva da variável dependente foi $Q^2 = 0,348$ e pode ser considerada de média para grande. Já as cargas fatoriais ficaram acima de 0,70 para todos os 5 indicadores da variável AP e, no caso de NAA, 8 de 13 indicadores ficaram acima de 0,50. Neste caso, há que se testar a eliminação iterativa de indicadores com cargas baixas e observar o comportamento do modelo quanto ao desempenho a posteriori. Os indicadores de convergência (AVE = 0,456 e 0,776) demonstraram convergência de média para forte e a confiabilidade geral (CR > 0,892) ficou acima de 0,70, ponto de corte para pesquisas exploratórias e menor que 0,95, o que poderia indicar que os itens são redundantes (DIAMANTOPOULOS *et al.*, 2012).

4.3.3. Modelagem, avaliação e ajuste do arranjo 184 D1-D4

Um corte parcial da tabela de dados utilizada é mostrado na Tabela 11. A tabela original parte de uma matriz de 184 x 18 (3312 células) e por esta razão, como já mencionado, esta e outras tabelas de dados estão disponíveis como material suplementar, podendo ser solicitadas ao pesquisador.

Tabela 11 - Corte parcial da tabela de observações no arranjo 184 D1-D4

Grupo	A-OI	A-PI	I-PI	I-Es	I-PQpr	I-FT	I-MO	I-Uu	I-Ad	MédiaObs	Média	SG1	SG2	SG3	SG4	SG5
SEM	31,9	4,8	43,2	64,1	8,8	2,5	0,0	0,0	0,9	12,0	40,7	46,0	38,0	40,7	40,7	37,6
SEM	12,9	0,2	12,9	67,8	1,1	5,5	0,0	0,0	0,0	7,7	40,72	46,0	38,0	40,7	40,7	37,6
SEM	4,6	0,0	14,6	69,4	2,3	0,0	0,0	0,0	0,6	7,0	50,67	59,8	50,9	62,0	31,1	49,5
SEM	16,1	13,1	46,6	72,4	3,6	2,8	2,0	0,6	3,3	12,3	66,4	66,6	70,6	60,2	67,4	67,2
SEM	26,4	23,4	30,9	56,6	3,7	0,8	15,8	5,5	0,1	12,6	44,8	56,9	34,0	41,1	45,7	46,5
SEM	5,1	0,0	6,7	74,9	0,2	0,0	0,0	0,0	1,5	6,8	57,9	56,9	34,0	41,1	45,7	46,5

Grupo	A-OI	A-PI	I-PI	I-Es	I-PQpr	I-FT	I-MO	I-Uu	I-Ad	MédiaObs	Média	SG1	SG2	SG3	SG4	SG5
COM	37,5	3,8	41,2	79,5	3,3	6,5	7,7	0,7	0,0	19,0	46,72	58,9	49,5	41,7	39,4	43,8
COM	59,8	0,0	73,4	78,9	0,3	12,2	22,3	15,0	7,0	29,5	51,54	58,0	60,2	56,8	58,5	48,3
COM	88,1	0,0	88,1	91,2	18,8	10,4	49,7	33,6	5,3	39,0	69,53	64,4	70,6	82,6	65,3	74,9
COM	46,5	1,2	50,3	79,8	2,08	4,8	0,0	2,7	6,9	17,8	46,2	56,7	37,2	38,8	45,2	53,2

Iniciou-se a modelagem com a especificação mostrada na Figura 27 e a primeira rodada do algoritmo PLS do SmartPLS®, pois este algoritmo fornece mais robustez na análise da configuração reflexiva do modelo (RINGLE; WENDE; BECKER, 2015). Os primeiros índices tais como os coeficientes de trajetória, cargas fatoriais e coeficiente de determinação são mostrados na Figura 27. No entanto, diversos procedimentos, algoritmos e técnicas PLS, além do algoritmo principal PLS, foram executados para gerar todos os índices que estão tabulados nas tabelas até o final desta seção, onde também são discutidos e avaliados, em busca do melhor modelo. São eles: a) *Bootstrapping* PLS consistente; b) *Blindfolding*; c) Análise confirmatória de tétrades (CTA); d) *PLSPredict* e e) PLS-POS - *Prediction Oriented Segmentation*. Os relatórios completos do software SmartPLS® (RINGLE; WENDE; BECKER, 2015) estão disponíveis como material suplementar, no formato MSEXcel®.

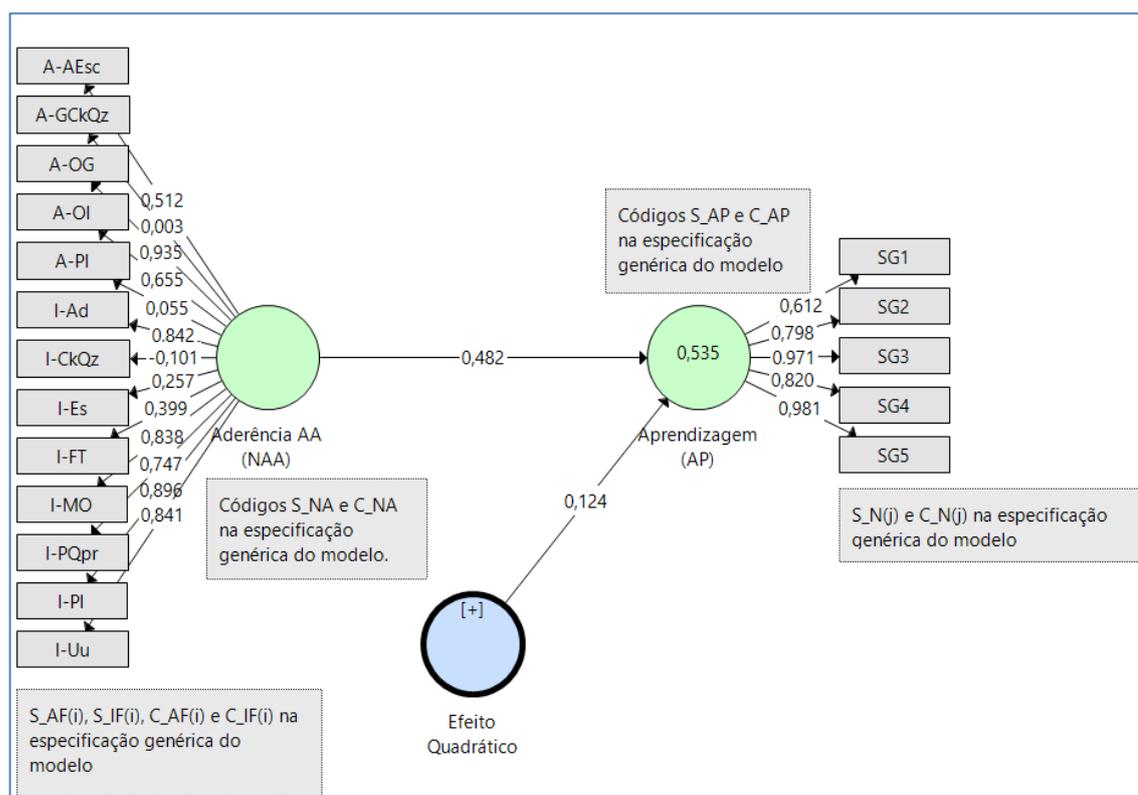


Figura 27 - Modelo preditivo inicial da Aprendizagem

A busca do melhor modelo seguiu os critérios e índices recomendados em Hair *et al.* (2019), além de Henseler; Ringle; Sinkovics (2009), Akter; D’ambra; Ray (2011) e outros autores citados diretamente nas tabelas subsequentes. As tabelas são associadas a categorias típicas de indicadores e intercaladas pela discussão e validação dos resultados, apoiados pelos softwares SmartPLS® (RINGLE; WENDE; BECKER, 2015) e WarpPLS® (KOCK, 2020b). Destaca-se a coluna de **Resultados**, que foi objeto para a última coluna à direita de **Avaliação e Ajustes**, onde se encontra o resumo da avaliação baseado nos critérios apresentados.

4.3.3.1. Ajuste global do modelo

A Tabela 12 mostra dois indicadores para a validação do ajuste global.

Tabela 12 - Ajuste global do modelo

Índice	Critério	Resultados	Discussão: Avaliação e Ajustes
<i>Goodness of Fit (GoF)</i> (TENENHAUS et al., 2005)	<ul style="list-style-type: none"> ✓ GoF pequeno = 0,10 ✓ GoF médio = 0,25 ✓ GoF grande = 0,36 	✓ GoF=0,588	✓ Ajuste adequado, bem acima da linha de corte;
SRMR	✓ SRMR≤0,1	✓ SRMR=0,1	✓ Ajuste adequado, sem folga neste índice.

No entanto, segundo (Hair Jr. *et al.* (2017), a interpretação de índices de ajuste deve ser cautelosa para os modelos PLS-SEM, pois os critérios propostos estão em seu estágio inicial de pesquisa e não são totalmente compreendidos. Os softwares de apoio fornecem alguns índices, mas acredita-se que há muito mais pesquisas necessárias para aplicá-los de forma adequada. Assim, para esta tese, forma apresentados dois destes índices que se mostraram dentro dos critérios atualmente estabelecidos, o que em primeira análise, validam estas características do modelo PLS-SEM.

4.3.3.2. Validação dos modelos de medição reflexivos

A Tabela 13 mostra os indicadores para a validação dos modelos reflexivos.

Tabela 13 - Validação dos modelos de medição reflexivos

Índice	Critério	Resultados	Discussão: Avaliação e Ajustes
Cargas, significância e erros dos indicadores reflexivos (Indicator Reliability – IR)	✓ $\geq 0,708$, validado por <i>Consistent Bootstrapping</i> (significância)	✓ IR > 0,70 para 7 em 13 indicadores de NAA, mas apenas 3 não são significativos ($p\text{-value} > 0,05$). ✓ IR > 0,70 para 4 em 5 indicadores de AP, mas todos são significativos ($p\text{-value} < 0,05$).	✓ Ajuste adequado; ✓ Possível eliminação de até 3 indicadores de NAA e validação.
Confiabilidade da consistência interna (Composite Reliability – CR)	✓ Mínimo 0,70 (ou 0,60 em pesquisa exploratória). ✓ Máximo de 0,95 para evitar redundância de indicadores x validade do conteúdo. ✓ Recomendado 0,80 a 0,90.	✓ CR = 0,860 para NAA. ✓ CR = 0,825 para AP. ✓ Os valores do alpha de Cronbach e rho_A também são > 0,863.	✓ Ajuste adequado
Validade convergente	✓ AVE $\geq 0,50$ (FORNELL; LARCKER, 1981b).	✓ AVE = 0,406 para NAA. ✓ AVE = 0,718 para AP	✓ Ajuste marginal para NAA e adequado para AP.
Validade discriminante (Cross Loadings)	✓ Cargas fatoriais de indicadores de um constructo são maiores que suas cargas em outros constructos do modelo.	✓ OK para todos os indicadores.	✓ Ajuste adequado.
Validade discriminante (HTMT) (HENSELER, et al. 2015)	✓ Para constructos conceitualmente semelhantes: HTMT < 0,90. ✓ Para constructos conceitualmente diferentes: HTMT < 0,85.	✓ HTMT = 0,648	✓ Ajuste adequado.

Iniciando-se pela confiabilidade ($IR = Indicator Reliability$) dos indicadores medidas pelas cargas fatoriais e um critério aceitável de $IR > 0,708$, observa-se 7 dos 13 indicadores de NAA atendem o critério. Destes 7 indicadores, apenas 3 não são significativos ($p\text{-value} > 0,05$). No caso de AP, 4 em 5 indicadores atendem o critério, mas todos são significativos ($p\text{-value} < 0,05$). Uma simulação de exclusão iterativa dos indicadores não significativos identificados pelo algoritmo de *Consistent Bootstrapping* deve ser realizada no refinamento do modelo. No *Bootstrapping* do SmartPLS® (RINGLE; WENDE; BECKER, 2015), o erro padrão é o desvio padrão das estimativas das médias amostrais em relação às amostras originais. Os resultados mostram erros insignificantes, com todos os $p\text{-value} < 0,05$, a maioria igual a 0,000. A Tabela 14 mostra um corte parcial dos erros padrão (STDEV no *Bootstrapping*) para alguns indicadores de ambas as variáveis latentes do modelo, extraído do SmartPLS®:

Tabela 14 - Corte parcial dos erros padrão dos indicadores

Indicador	Original Sample (O)	Sample Mean (M)	Standard Deviation (STDEV)	T Statistics	P Values
I-Pl <- (NAA)	0,902	0,898	0,037	24,633	0,000
I-Uu <- (NAA)	0,847	0,834	0,051	16,687	0,000
SG1 <- (AP)	0,611	0,61	0,029	20,807	0,000
SG2 <- (AP)	0,805	0,803	0,026	30,981	0,000

Uma análise de resíduos da variável dependente AP foi realizada e o resultado descritivo dos está ilustrado na Tabela 15, extraída do relatório do SmartPLS®. Apesar dos escores médios dos resíduos serem de baixa magnitude, percebe-se valores relevantes de assimetria e curtose. Um teste de Anderson-Darling realizado no Minitab®, demonstrou que a distribuição dos resíduos não é normal com $p\text{-value} < 0,005$. Esta constatação não afeta a qualidade do modelo, pois o PLS-SEM e os testes de significância feitos como algoritmo *Consistent Bootstrapping* são não paramétricos e não tem a premissa de normalidade dos dados. (RINGLE; WENDE; BECKER, 2015),

Tabela 15 - Análise de resíduos

	Mean	Median	Min	Max	Standard Deviation	Excess Kurtosis	Skewness	Cases
Aprendizagem (AP)	-0,14	-0,336	-1,051	1,771	0,717	2,161	1,578	184

A confiabilidade da consistência interna (*Composite Reliability – CR*), com critério de aceitação $CR > 0,60$ para pesquisa exploratória (SARSTEDT; RINGLE; HAIR, 2017a), obteve um valor $CR = 0,860$ para NAA e $CR=0,825$ para AP. Os valores do alpha de Cronbach e rho_A, com relevância menor, foram também $> 0,80$. Desta forma, o modelo apresentou ajuste aceitável neste quesito.

De acordo com Fornell e Larcker (1981a), a validade convergente (AVE) maior que 0,50 indica que o modelo converge para um resultado satisfatório. Os valores obtidos de $AVE = 0,406$ para NAA e $AVE = 0,718$ para AP mostram que a variável AP tem uma aceitação marginal abaixo do valor de corte. De forma similar, recomenda-se a exclusão iterativa (um a um, após observar os resultados a cada passo) dos indicadores não significativos identificados pelo algoritmo de *Consistent Bootstrapping*. É esperado que ao eliminar os indicadores com cargas fatoriais

(correlações) de menor valor, conseqüentemente, haverá a elevação do valor de AVE da variável AP.

A validade discriminante pode ser avaliada pela análise cruzada de cargas fatoriais ou pelo indicador HTMT (*HeteroTrait-MonoTrait*) que é definido como a média do valor das correlações de itens nos constructos. Problemas de validade discriminatória estão presentes quando os valores HTMT são altos. O critério recomendado é $HTMT < 0,90$ (HENSELER; RINGLE; SARSTEDT, 2015). O cálculo de HTMT resultou em $0,659 < HTMT < 0,835$ para AP, NAA e efeito quadrático, estando, portanto, dentro do critério aceitável para validação.

4.3.3.3. Validação do modelo estrutural

A Tabela 16 mostra os indicadores para a validação do modelo estrutural.

Tabela 16 - Validação do modelo estrutural

Índice	Critério	Resultados	Discussão: Avaliação e Ajustes
Valor de R^2	<ul style="list-style-type: none"> ✓ Os valores de R^2 de 0,75, 0,50 e 0,25 são considerados substanciais, moderados e fracos. ✓ Valores R^2 de 0,90 e superiores são típicos indicativos de super ajuste. 	✓ $R^2=0,535$ para AP.	✓ Ajuste adequado, entre moderado e substancial.
Colinearidade	✓ VIF (<i>Variation Inflation Factor</i>) entre 3 e 5 para estudos exploratórios (DIAMANTOPOULOS; SIGUAW, 2006).	✓ $VIF=4,387$	✓ Ajuste adequado para o projeto experimental da tese.
Valor de Relevância Preditiva Q^2	<ul style="list-style-type: none"> ✓ Valores maiores que zero são significativos. ✓ Valores maiores que 0, 0,25 e 0,50 representam relevância preditiva pequena, média e grande do modelo PLS 	<ul style="list-style-type: none"> ✓ $Q^2=0,348$ para AP (redundância). ✓ $Q^2=0,647$ para AP (comunalidade). 	✓ Ajuste adequado, com relevância preditiva de média para muito grande.
Valor de Relevância Preditiva PLSpredict e erro de predição. (SHMUELI et al., 2016; SHMUELI et al., 2019)	<ul style="list-style-type: none"> ✓ Critério de Valores $Q^2_{predict}$ similares aos valores de Q^2. ✓ Maiores valores do índice indicam menores erros de predição. 	<ul style="list-style-type: none"> ✓ $Q^2_{predict}=0,453$ para AP. ✓ $Q^2_{predict}=0,339$ para indicadores de AP. 	✓ Ajuste adequado, com relevância preditiva média para AP e seus indicadores.

Índice	Critério	Resultados	Discussão: Avaliação e Ajustes
Tamanho do Efeito	✓ Duas vezes o tamanho do efeito: Pequeno = 0,02, Médio = 0,13, Grande = 0,26 (COHEN, 1988).	✓ $f^2 = 0,114$ para AP. ✓ $f^2 = 0,036$ para o efeito quadrático (EQ).	✓ Ajuste marginalmente adequado ~ médio efeito para AP e entre pequeno e médio para EQ.
Coefficiente β	✓ Duas vezes o tamanho do efeito: Pequeno = 0,02, Médio = 0,13, Grande = 0,26 (COHEN, 1988), validado por <i>Consistent Bootstrapping</i> (significância).	✓ $\beta = 0,482$ e $p=0,000$.	✓ Ajuste adequado, entre médio e grande efeito e com alta significância estatística.
Coefficiente do Efeito Quadrático	✓ Duas vezes o tamanho do efeito: Pequeno = 0,02, Médio = 0,13, Grande = 0,26 (COHEN, 1988), validado por <i>Consistent Bootstrapping</i> (significância).	✓ $\gamma = 0,124$ e $p=0,011$.	✓ Ajuste adequado, entre pequeno e médio efeito e com relevante significância estatística, mesmo com um coeficiente de valor baixo 0,124.

Inicia-se pelo valor do coeficiente de determinação e R^2 , cujo critério de aceitação aponta que valores de 0,75, 0,50 e 0,25 são considerados substanciais, moderados e fracos. Valores acima de 0,90 são típicos indicativos de super ajuste, com número excessivo de indicadores ou colinearidade. Para este modelo, o valor de $R^2 = 0,535$ para a variável dependente AP se mostrou aceitável, entre moderado e forte. Assim, como um filtro antes de concluir sobre o fator de determinação, deve-se examinar a colinearidade de forma similar ao que se faz com os modelos formativos (usando os valores VIF). Um valor seguro próximo a 3 e abaixo (HAIR et al., 2019) e de forma mais liberal entre 3 e 5 baseados em alguns estudos empíricos (DIAMANTOPOULOS; SIGUAW, 2006) foram os critérios utilizados. O modelo apresentou VIF = 4,387, aceitável para o critério mais liberal, em um estudo empírico e exploratório.

Os valores de relevância preditiva podem ser avaliados pelo índice Q^2 , como foi descrito na revisão da literatura. Pequenas diferenças entre os valores previstos e originais se convertem em um valor mais alto de Q^2 , indicando uma maior precisão preditiva e menor erro de predição. Como um princípio básico, valores Q^2 superiores a 0, 0,25 e 0,50 representam relevância preditiva pequena, média e grande do modelo PLS, respectivamente, à medida que os erros de predição diminuem. A técnica usada para calcular Q^2 é denominada *Blindfolding* e é uma técnica de reutilização de amostras (SHMUELI et al., 2016). Os valores para a variável dependente AP do modelo foram 0,348 para redundância e 0,647 para comunalidade, representando ajuste adequado com relevância preditiva de média para muito grande.

Uma outra forma mais robusta de avaliar a relevância preditiva do modelo é através do PLSPredict (SHMUELI et al., 2016; SHMUELI et al., 2019). A interpretação dos resultados do valor de $Q^2_{predict}$ é semelhante à avaliação dos valores de Q^2 obtidos pelo procedimento de *Blindfolding* no PLS-SEM. Se o valor de $Q^2_{predict}$ for positivo, o erro de predição dos resultados do PLS-SEM é menor do que o erro de predição de utilizando os valores médios e a precisão da predição aumenta à medida que os erros de predição diminuem. Nesse caso, os modelos PLS-SEM oferecem melhor desempenho preditivo. Utilizando o mesmo critério de Q^2 , o $Q^2_{predict}$ do modelo foi de 0,453 para AP e 0,339, em média, para os indicadores de AP, representando ajuste adequado com relevância preditiva de média para grande.

Os outros três últimos indicadores da Tabela 16 lidam com avaliações dos efeitos e dos coeficientes. Nos critérios apresentados, os efeitos estão com ajuste marginalmente adequado sendo médio efeito para AP e entre pequeno e médio para o efeito quadrático EQ. No entanto, o teste de *Bootstrapping* confirmou significância estatístico relevante com $p\text{-value} = 0,000$. Para o caso do coeficiente o ajuste foi adequado, entre médio e grande efeito e com alta significância estatística e para o caso do coeficiente de EQ, o ajuste foi adequado, entre pequeno e médio efeito e com relevante significância estatística, mesmo com um coeficiente de valor baixo igual a 0,124.

4.3.3.4. Validação de robustez do modelo

A Tabela 17 mostra os indicadores para a validação de robustez do modelo.

Tabela 17 - Validação de robustez do modelo

Índice	Critério	Resultados	Discussão: Avaliação e Ajustes
Modelos de Medição	✓ CTA-PLS.	✓ O CTA-PLS é um teste empírico para determinar a especificação de um modelo reflexivo ou formativo, mas o método principal é o raciocínio teórico (HAIR JR. et al., 2017).	✓ O modelo teórico é reflexivo: A estratégia de AA causa os indicadores de observação e a Aprendizagem causa indicadores de grau de desempenho.

Índice	Critério	Resultados	Discussão: Avaliação e Ajustes
Modelo estrutural	✓ Efeitos não lineares.	✓ Efeito quadrático identificado nas análises do SmartPLS® e WarpPLS® (SVENSSON et al., 2018).	✓ Ajuste adequado. Incorporado ao modelo.
Modelo estrutural	✓ Endogeneidade.	✓ Relevante quando o foco do pesquisador está na explicação do modelo e não em objetivos preditivos.	✓ A pesquisa nesta tese privilegia os objetivos preditivos.
Modelo estrutural	✓ Heterogeneidade não observada utilizando a Segmentação orientada para a predição PLS - PLS-POS (BECKER; RAI; RIGDON, 2013).	<ul style="list-style-type: none"> ✓ Seg1=67; Seg2=117. ✓ Coeficiente Seg1 = -0,966. ✓ Efeito Quadrático Seg1 = 0,313. ✓ Coeficiente Seg2 = 0,882. ✓ Efeito Quadrático Seg2 = 0,054. ✓ $R^2=0,803$ no Seg1. ✓ $R^2=0,926$ no Seg2. 	✓ Antecipava-se uma identificação de 2 grupos, dado que o projeto experimental considerou dois níveis de tratamento com perfis de AA distintos e desempenhos distintos numa relação de causa-efeito. O teste POS veio a indicar esta segmentação. Isto traz oportunidades para futuros estudos nesta mesma base de dados utilizando análise PLS-POS e multigrupo (MGA), por exemplo analisando diferenças de desempenho quanto ao gênero dos alunos.

Inicia-se pelos modelos de medição, através da confirmação tétrede (CTA-PLS), Ela permite fundamentar empiricamente a especificação de modelos de medição, ou seja, reflexivo versus formativo (GUDERGAN et al., 2008). É um teste empírico para determinar a especificação de um modelo reflexivo ou formativo, mas o método principal é o raciocínio teórico (HAIR JR. et al., 2017). Como neste caso, o modelo teórico é reflexivo, isto é, a estratégia de AA causa os indicadores de observação e a Aprendizagem causa os indicadores de grau de desempenho, o teste não se aplicaria. De fato, os resultados se mostraram dúbios indicando que qualquer especificação (ou nenhuma) dos modelos seria adequada.

No modelo estrutural, os testes de efeitos não-lineares foram realizados e o efeito foi identificado e significativo, sendo que um efeito quadrático foi incorporado ao modelo. Além disso, o termo de interação testado para mapear um efeito não linear do modelo foi identificado com relevante significância estatística usando *Bootstrapping* (SVENSSON et al., 2018).

Para avaliar e tratar endogeneidade, segue-se o procedimento sistemático de Hult (HULT et al., 2018), iniciando-se com a aplicação da abordagem de cópula gaussiana de Park e Gupta (PARK; GUPTA, 2012). O indicador não é relevante pois o foco da pesquisa desta tese privilegia os objetivos preditivos (HAIR *et al.*, 2019).

Sarstedt, Ringle e Hair (2017b) propuseram um procedimento sistemático utilizando a execução do procedimento POS - Segmentação Orientada por PLSpredict para descobrir a estrutura de segmentos dos dados. O indicador de heterogeneidade não observada utilizando esta técnica indicou a presença de dois segmentos de dados na matriz de observações. Como os experimentos foram realizados de forma sistemática para detectar relações entre as variáveis em dois níveis de tratamento com perfis de AA distintos e desempenhos distintos numa relação de causa-efeito, antecipava-se uma identificação de 2 grupos. O teste POS veio a indicar esta segmentação. Isto traz oportunidades para futuros estudos nesta mesma base de dados utilizando análise PLS-POS e análise multigrupo (MGA), por exemplo, analisando diferenças de desempenho quanto ao gênero dos alunos.

Em geral, portanto, os resultados do modelo são aceitáveis em praticamente todos os indicadores relevantes apresentados pela literatura e estão atrelados às evidências de significância estatística, respondendo à pergunta de pesquisa 3, além de demonstrar a hipótese proposta H2. O modelo matemático demonstrou evidências de relação positiva de causa-efeito e relevância preditiva em todos os índices de qualidade (HENSELER; HUBONA; RAY, 2016). No entanto, uma possível melhoria apontada foi no índice de validade convergente – AVE = 0,406 (critério $AVE \geq 0,50$ (FORNELL; LARCKER, 1981b) para o constructo NAA, que mede a colinearidade entre os indicadores. Após a eliminação de 3 indicadores não significativos do constructo NAA (A-PI, A-GCkQz e I-CkQz), houve melhora significativa para novo valor **AVE = 0,535**, entrando na faixa acima do valor de corte de 0,50 (FORNELL; LARCKER, 1981b).

Desta forma, o modelo apresentou ajuste aceitável neste quesito. Os novos valores da confiabilidade composta melhoraram para CR = 0,913 para NAA e CR=0,925 para AP, assim como os valores do alpha de Cronbach e rho_A agora $> 0,90$. Outros índices praticamente não se alteraram, com mudanças na segunda ou terceira casa decimal para cima ou para baixo, sem alterar a qualidade do modelo, onde os coeficientes resultantes foram todos significativos e com $p = 0,000$. No entanto o coeficiente do efeito quadrático ficou ligeiramente menor e igual a

0,140, mas ainda com relevante significância estatística, o que será confirmado na estimativa de *best-fitting* curve na plataforma WarpPLS® (KOCK, 2020b), demonstrada na subseção 4.3.3.5. A Figura 28 mostra o ajuste final.

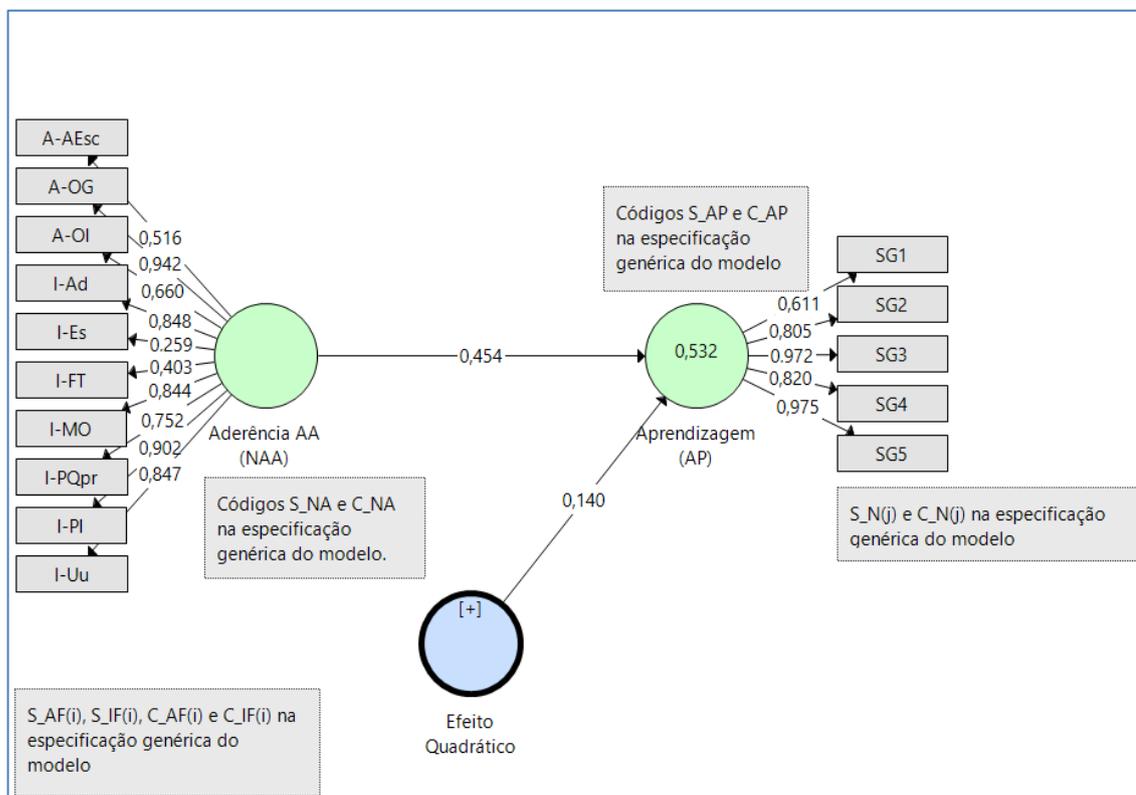


Figura 28 - Modelo preditivo final da Aprendizagem

4.3.3.5. *Best fitting curve* do modelo preditivo de Aprendizagem

A Figura 29, obtida do software WarpPLS®, mostra a curva aproximada, em escala não padronizada, da relação matemática revelada pelo modelo e a faixa estimada para predição dos escores de Aprendizagem a partir de escores de níveis de aderência à AA. Percebe-se que existe o efeito não linear mais evidente em uma faixa intermediária de valores e que se assemelha a uma parábola, se aproximando portanto do suposto efeito quadrático significativo detectado nos testes anteriores. O formato da curva destaca também uma ocorrência de zonas de comportamentos específicos da relação para serem analisadas. Nesta faixa, todos os coeficientes apresentaram significância estatística relevante ($p < 0,01$), com um nível de significância de 0,05.

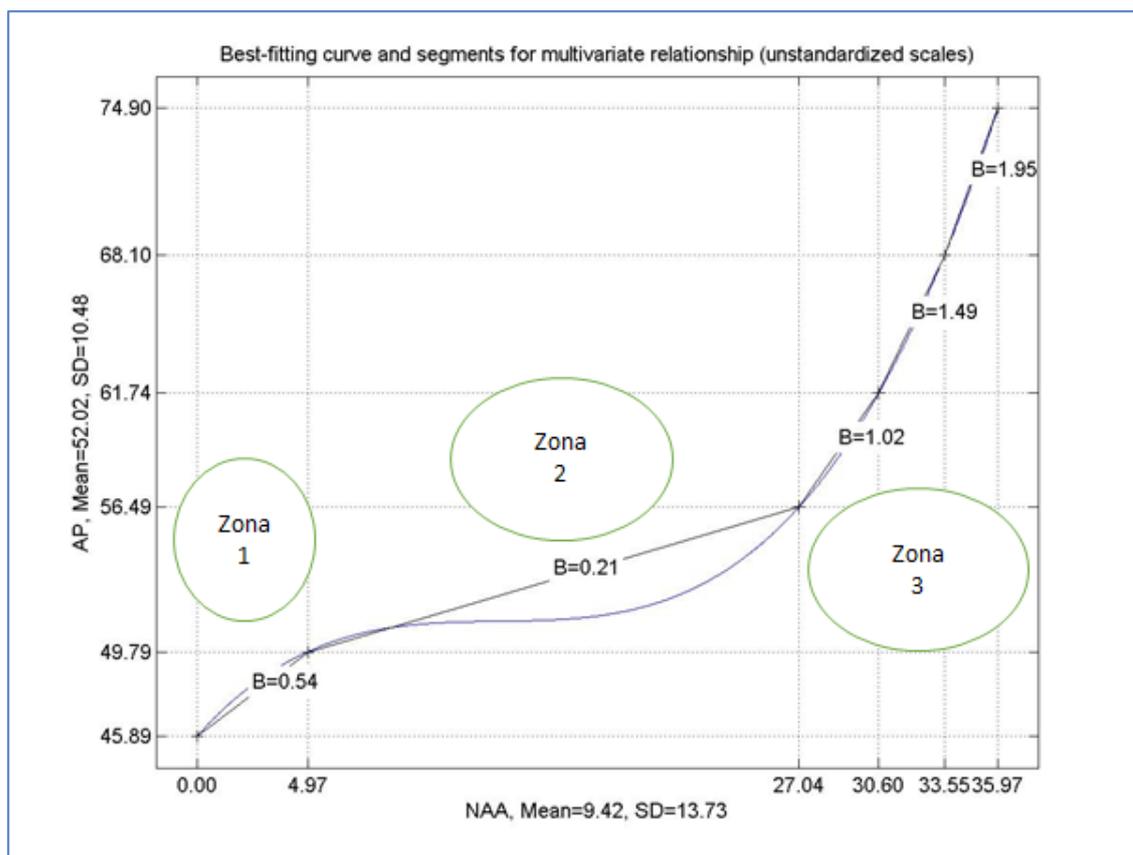


Figura 29 - Relação da Aprendizagem com nível de AA – Melhor Ajuste

Seria possível interpretar a relação em função de diversas abordagens tais como o perfil de aprendizagem dos alunos, os estilos, as notas, os conteúdos e até do tempo/duração da aplicação das técnicas de AA. No entanto, com a sistemática metodológica dos experimentos, a questão de um possível viés prévio que alterasse de forma significativa o comportamento estimado desta curva foi respondida no teste realizado em 4.1.1.1, de forma que se estas variáveis ou fatores externos, se existiram, se comportaram de forma aleatória sem causar viés significativo. Assim, uma interpretação mais provável do modelo a partir desta curva precisa estar baseada na teoria e nas diversas análises observacionais das aulas realizadas efetivamente neste estudo. Esta abordagem mostrou **três zonas** na faixa de valores capturados pela curva estimada do modelo: 1) a primeira quando haveria de nenhuma até pouca atividade típica de AA na sala de aula (por exemplo, o instrutor palestrando e os alunos ouvindo, mais a introdução de alguma atividade rápida em grupo), detectada pelo protocolo de observação. Nesta zona, o efeito na aprendizagem existe e já provoca uma pequena mudança de patamar no desempenho; 2) a segunda indica mais atividade, tais como práticas em equipe e participação dos alunos em discussões. O efeito na aprendizagem é significativo estatisticamente, mas provoca pouca mudança real no desempenho dos alunos, o que parece indicar uma barreira prévia ao tipo

diferenciado de aulas; c) a terceira mostra um possível maior engajamento a partir de um certo ponto (*trigger*) dentro da sala de aula. Há elevação das atividades em grau médio (por exemplo, uma grande tarefa ou várias tarefas sequenciais em grupo e com o professor fazendo tutoria, além de provocar as discussões em pares ou equipes, etc.), mas o efeito é bem mais significativo no desempenho, o que o faz mudar efetivamente de patamar. Do ponto de vista preditivo, em geral, através de simples interpolação, observa-se que um score médio entre 0 e 35,97 no nível de aderência AA pode prever um nível de Aprendizagem entre 45,89 e 74,90 medido em graus de desempenho médio. Sugere-se pelos resultados que a curva terá um perfil mais próximo ao da zona 3, quando as estratégias de AA e suas técnicas forem aplicadas de forma mais eficaz.

5. CONCLUSÃO E CONSIDERAÇÕES FINAIS

5.1. Conclusão

A realização desta pesquisa possibilitou uma reflexão ampla sobre o uso de metodologias ativas em cursos de Engenharia em uma IES privada e com tradição da Educação em Engenharia (EE), o Instituto Nacional de Telecomunicações (INATEL). Foram analisados seus potenciais efeitos no desempenho acadêmico, como mais um elemento de inspiração para pesquisas e aplicações ainda mais abrangentes em outras instituições e comparações interinstituições, a partir do modelo e da metodologia desenvolvida nesta tese. A pesquisa contou com um planejamento rígido e sistemático dos experimentos dentro das salas de aula, utilizando um protocolo de observação em sala de aula para obter dados o mais objetivos possível dos comportamentos reais de professores e alunos em duas situações ou tratamentos distintos: sem e com a implementação de técnicas ativas de aprendizagem (AA). O grupo de pesquisa que incluiu os professores, assistentes e técnicos, com apoio da direção da instituição foi devidamente treinado para a execução dos experimentos em suas aulas, além das frequentes sessões de reflexão antes dos experimentos e pós-experimentos. Em especial, destaca-se a etapa intensiva de treinamento em técnicas de aprendizagem ativa (AA) de 3 horas para os professores da equipe de pesquisa. O treinamento antecedeu os experimentos, de forma que eles estivessem cientes, preparados e, com o apoio técnico do pesquisador, à vontade para escolher as ferramentas de AA que mais se adequavam ao perfil da sua disciplina. No processo de planejamento das suas disciplinas para a sistemática metodológica, todos os professores tiveram suporte do pesquisador na formatação das aulas e obtiveram complementação ao treinamento na forma de recomendações práticas sobre quais técnicas de AA e formas de aplicá-las em sala de aula, além do provimento de artigos e referências de apoio na literatura. Um assistente de pesquisa foi treinado, além das técnicas de AA, em técnicas de observação em sala de aula utilizando protocolos de observação. Além do treinamento padrão do protocolo COPUS, o assistente (segundo observador) cumpriu no mínimo 6 horas-aulas de observações até que houvesse nível adequado de confiabilidade nas medições para só então proceder às observações comparativas reais.

No entanto, o processo de negociação e conquista do apoio da diretoria da instituição, de forma a prover suporte para o enfrentamento pioneiro do desafio de abrir as portas das salas de aula para filmagens de professores e alunos foi um grande diferencial e adicionou valor relevante

para a contribuição da pesquisa para a EE. A instituição percebeu o potencial de aprofundamento na aprendizagem ativa e já havia treinado recentemente todos os seus professores em um workshop de quatro horas nas metodologias ativas mais comuns tais como sala invertida, uso de *clicker questions*, instrução por pares, PBL, POGIL e PjBL.

A relação de causa e efeito entre os níveis de atividade das aulas característicos do tratamento (nível de fator) sem técnicas ativas implementadas e com técnicas ativas implementadas foi demonstrada experimentalmente em duas dimensões de abrangência. A primeira, intraclasse, abordou especificamente as perguntas de pesquisa 1 e 3, e os testes de hipóteses H1.1 e H1.2. Os resultados demonstraram com um alto poder estatístico e sem a parcela de erro entre sujeitos, que existe a relação de causa-efeito fundamentada pela teoria e que o desempenho acadêmico médio global foi aproximadamente 14% melhor quando avaliado em uma mesma amostra de alunos, com o mesmo tipo de avaliação, comparando os tratamentos sem e com aplicação de técnicas ativas de aprendizagem (AA), respectivamente. Além da discussão global, foi possível demonstrar que a aplicação de técnicas de AA não é a bala de prata para todas as disciplinas, instrutores e cursos, e por conseguinte, nem mesmo para as instituições de ensino. Algumas disciplinas não contribuíram positivamente para o resultado global e houve um grande aprendizado extraído das análises das prováveis causas desses resultados comparando às outras disciplinas e turmas e também confrontando com a literatura vigente. A riqueza das informações gravadas e depois capturadas pelo protocolo de observação permitiu propor estratégias viáveis de AA que podem elevar o potencial de sucesso na aplicação destas técnicas em novos estudos e cursos de engenharia, contribuindo para a discussão latente da eficácia dos métodos ativos na EE. Os dados de observações em sala de aula obtidos através do protocolo de observação e mesmo os dados de graus de desempenho obtidos dos sistemas de gestão da IES participante foram escrutinizados quanto ao seu perfil estatístico para minimizar os erros de medição e desvios nas análises estatísticas. Em geral estes dados originais não atenderam plenamente as premissas de normalidade e homocedasticidade, tendo que ser tratados com as técnicas compatíveis, incluindo o uso de médias de subgrupos para aproximar a normalidade e técnicas não paramétricas quando isso não foi plenamente aceitável e fundamentado pela teoria.

Na dimensão interclasse, mais abrangente e abstrata, buscou-se especificamente responder a pergunta de pesquisa 3 e testar a hipótese H2. Nesta dimensão, ampliou-se o alcance da pesquisa para comparações com turmas subsequentes, com amostras independentes de graus de desempenho. Manteve-se o mesmo perfil de atividade em sala de aula com as mesmas técnicas

de AA e também com o mesmo tipo de avaliações, consistentemente aplicadas pelos professores, de forma sistemática e dentro do método experimental definido. Esta dimensão possibilitou a utilização de técnicas mais avançadas de modelagem, tais como a modelagem por equações estruturais na vertente PLS-SEM, utilizando-se do estado da arte das ferramentas e das métricas de avaliação que garantissem o melhor desempenho do modelo escolhido, a partir de experimentação de diversos arranjos de dados. A abordagem dos tipos de dados coletados levou em consideração o perfil comportamental e atitudinal, como é mais comum nas ciências sociais e humanas, aqui associadas à Engenharia pelo veio da Educação. Quando lidamos com certos tipos de conceitos teóricos mais abstratos, tais como o nível de atividade dentro de uma sala de aula, com complexas interações entre alunos e professor-aluno, ou ainda o nível de aprendizagem dos alunos, não é possível medi-los diretamente. Como a maioria das pesquisas em educação concentra-se em variáveis que não são diretamente observáveis tal como a própria Aprendizagem e um possível nível de atividade comportamental dentro das salas de aula, conceitos centrais tratados nesta pesquisa. Esses conceitos foram representados por constructos operacionalizados variáveis latentes. Os dados utilizados para medir indiretamente essas variáveis latentes, em geral, não seguem as premissas de normalidade previstas para os métodos paramétricos de análise estatística, justificando a escolha em favor da modelagem PLS-SEM. A pesquisa contou com uma ampla abordagem de fundamentação teórica. Dentre os componentes críticos para a realização da mesma destacaram-se a ampla e crescente disponibilidade de fontes sobre aplicações e métodos com o PLS-SEM, incluindo novos softwares e algoritmos de apoio. Os resultados da análise preliminar demonstraram a viabilidade de modelar um constructo latente tal como a Aprendizagem (AP) e sua relação com outro constructo latente de Nível de Aderência às técnicas de AA (NAA), estudados em duas situações com dados de desempenho independentes. Na comparação paramétrica e não paramétrica dos desempenhos dos dois ambientes de aprendizagem, a diferença entre as médias foi demonstrada em torno de 10%, equivalente a um efeito de 0,25, ou 5 pontos. Com o uso das mesmas premissas do experimento, o resultado foi ligeiramente menor, mas similar à dimensão intraclasse, ainda que a amostra tenha sido menor e o fator de erro entre sujeitos incorporado ao modelo. A análise preliminar foi feita utilizando 184 registros de observação e graus de desempenho médios de 368 alunos. Na etapa seguinte da experimentação, foi possível comparar o desempenho de 4 modelos utilizando arranjos de dados distintos, formatando as matrizes em blocos segmentados por nível de tratamento e utilizando médias de subgrupos. Com esta técnica foi possível variar o número de indicadores e reduzir as células com valores inexistentes (*missing values*), comuns em observações com muitos indicadores, onde um ou mais podem

simplesmente não serem acionados. O arranjo final escolhido 184 D1-D4 teve o melhor desempenho global medido por alguns indicadores chave para esta pesquisa, tais como o fator de determinação, tamanho do efeito e relevância preditiva. modelo para testar a consistência com os indicadores e observações. A partir deste arranjo, foi especificado e calculado um modelo que passou por um estrito processo de validação, a partir do estado da arte de índices apresentados na literatura. O modelo se mostrou aceitável e adequado para a proposição da tese e teve melhorias exercitadas em apenas dois índices marginais. A partir da maximização do padrão de qualidade do modelo-alvo da pesquisa, foi possível apresentar a sua configuração final que contou com a adição de um efeito quadrático. Foi então demonstrado sua relevância de predição com interpolação no gráfico estimado pelos softwares de apoio. Para a faixa de escores médios entre 0 e 35,97 no nível de aderência AA foi possível prever um nível de Aprendizagem entre 45,89 e 74,90 em graus de desempenho médio, em 3 zonas que se destacaram: a primeira com pouca atividade de AA e um efeito significativo no grau médio de desempenho; a segunda com pouco efeito no grau de desempenho mesmo com um aumento relevante da atividade de AA e; por fim a terceira zona mostrando um maior engajamento na sala de aula, de forma que um aumento moderado da atividade de AA provocou efeito consistente e relevante no desempenho, em novo patamar de valores. Sugere-se que estratégias de AA aplicadas de forma eficaz possam apresentar um comportamento preditivo do modelo similar ao da zona 3.

Observamos também a quantidade de técnicas de aprendizagem ativa que foram apresentadas na literatura e a forte associação das técnicas que envolvem cada vez mais os alunos como PBL, POGIL, PjBL e TBL como sendo cada vez mais associadas aos resultados de aprendizagem, inclusive demonstrada na análise de estratégias realizada nesta pesquisa. Tanto a literatura quanto os resultados observados nesta tese destacaram que algumas técnicas tem o potencial de gerar efeitos positivos no desempenho e, portanto, na Aprendizagem. Destacaram-se a Aula Invertida com Questões *Clicker* para conceitos, antes e depois da discussão em pares, em plataforma automatizada, que foram utilizadas de forma adaptada em D1 e D4 pela ausência da infraestrutura nesta IES (o *clicker* foi substituído pelo Quiz da plataforma Socrative®). Em D3.1 e D3.2, o uso de mini problemas de engenharia com casos reais em grupos de 2 a 4, com mentoria efetiva do professor, incentivando os alunos a buscarem as soluções, foi outro destaque que fez parte das estratégias recomendadas. Além do que foi efetivamente observado de alguma forma nas aulas, recomendou-se outras técnicas de apoio tais como as Pausas e *Think-Pair-Share* e o uso de avaliação formativa total ou parcial. Foram recomendadas também

estratégias para a Aprendizagem Baseada em Problemas (PBL) com equipes de até 4 pessoas ocupando até 1/3 da carga horária. As equipes de até 4 pessoas foram recomendadas baseado em discussões entre o pesquisador e os professores da equipe de pesquisa, que pelo perfil do aluno local, percebeu-se que mais que 4 pessoas dividiriam demais a carga de trabalho e talvez algum aluno ficasse, intencionalmente ou não, sem a devida participação para efetivar a aprendizagem. De outro lado, sempre dependerá da extensão do problema a ser resolvido. A Aprendizagem Baseada em Projetos (PjBL) foi observada em D5 e segue a mesma recomendação, com equipes de até 4 pessoas, mas prevendo trabalhos mais longos, ocupando até 80% da carga horária. As salas de aula flexíveis na sua infraestrutura, para possibilitar máxima interação das equipes, foram também indicadas para ambas as técnicas PBL e PjBL.

No caso dos protocolos de observação em sala de aula (COP), a interpretação da base de conhecimento extraída de fontes globais revelou várias abordagens de observação em sala de aula e diferentes perspectivas para o desenvolvimento e evolução de aplicativos e protocolos, incluindo aqueles específicos para Educação em Engenharia. A discussão das aplicações de cada protocolo permitiu reflexões profundas e o desenvolvimento de evidências consideráveis sobre as pesquisas atuais, comparações, relacionamentos e as principais perspectivas sobre as novas aplicações discutidas neste estudo. Na linha do tempo, os projetos publicados de observação em sala de aula e aplicativos com protocolos novos ou disponíveis que, por design, incorporavam elementos ativos de aprendizado, cresceram fortemente nos últimos 6 anos, mostrando alguma estabilização e redução de 2017 a 2020. Impulsionados pelos novos desafios da educação no mundo que exige um aprendizado mais ativo e centrado no aluno, novos instrumentos foram desenvolvidos para atender a essa demanda, especialmente nos EUA. Após o movimento do Ensino Reformado, na década de 2000, vários protocolos foram projetados para ambientes de aprendizado ativos e baseados em perguntas, e alguns deles direcionados à EE. Os resultados sugeriram que a maioria das aplicações e o crescimento da pesquisa dos COPs são derivados de novas ferramentas projetadas para essas áreas. A pesquisa revelou as tendências nos aplicativos de observação em sala de aula, concentrando-se nas abordagens ativas crescente da EE. Foram detalhadas várias características relevantes de dezenas de protocolos, demonstrando sua robustez e desdobramentos. implantação. Parecia que testes de validade e confiabilidade estabeleceram o padrão para consolidação de COPs e replicações seguras em outros estudos.

Por fim, esta pesquisa conseguiu atingir os objetivos propostos inicialmente. As hipóteses associadas às perguntas de pesquisa foram demonstradas na análise global de causa-efeito e na modelagem da Aprendizagem pelo método PLS-SEM. Duas disciplinas não puderam contribuir positivamente para as médias pós AA, mas geraram dados relevantes para as recomendações estratégicas que também eram mérito do estudo. Os dados coletados sobre o efeito em sala de aula do uso de técnicas instrucionais ativas juntamente com os graus de desempenho e seu tratamento estatístico trouxeram contribuição relevante para a pesquisa em EE. Além disto, especialmente, a apresentação de uma técnica ainda pouco utilizada de modelagem por PLS-SEM dentro da base de conhecimento da EE, contribuíram com uma Metodologia que pode auxiliar os instrutores e a administração das instituições de ensino superior a melhorar a abordagem ativa de suas aulas e cursos.

Espera-se também que a ampliação do uso de ferramentas e protocolos de observação em sala de aula traga novas oportunidades de pesquisa em outros formatos e abordagens de forma a utilizar dados relevantes das salas de aula em apoio a melhoria da Educação em Engenharia no Brasil. Com o conhecimento apresentado nesta pesquisa, o professor pode elaborar estratégias para promover motivação e proporcionar a necessária experiência para que os alunos tenham sucesso profissional. Aqueles professores que desejam aumentar o desempenho acadêmico dos alunos em suas disciplinas podem se dedicar em melhorar a qualidade geral de seu próprio ensino através da integração de elementos de estratégias ativas de aprendizagem e de relações com os alunos criando um ambiente de sala de aula que incentive a cooperação e a harmonia das equipes de trabalho. Tais mudanças nos métodos de ensino são talvez as mais prováveis em aumentar o desempenho acadêmico dos alunos.

5.2. Limitações e oportunidades para futuras pesquisas

Observou-se que os melhores resultados globais da Aprendizagem (AP) representaram um aumento significativo estatisticamente entre 10% e 14% no valor médio dos indicadores desta variável latente endógena, nas duas dimensões de análise. Mesmo que significativos estatisticamente na sua abordagem global, os valores individuais de duas das cinco disciplinas da amostra, na dimensão intraclasse, não contribuíram positivamente para a relação de causa-efeito hipotetizada e merecem ser estudados mais profundamente em pesquisas futuras. Além

disto, com recursos mais amplos, pode-se optar por um método de amostragem aleatória simples, mais robusto em termos de poder estatístico e evitação de qualquer viés que induza a maior probabilidade de cometer erros tipo I e/ou II nos testes de hipóteses. A experimentação dos dados no ambiente do PLS-SEM permitiu um modelo com moderado a alto poder preditivo e ficou dentro das expectativas da pesquisa. No entanto, há uma limitação para generalização dos resultados, pois os efeitos foram de pequenos ou médios em algumas análises e o menor tamanho amostral reduziu o poder estatístico. Além disso, há limitações no tratamento estatístico dos dados, quando o tamanho amostral é restrito e quando existem muitos zeros nas observações, desbalanceamento de dados (no caso das notas) e valores ausentes (no caso um elemento do protocolo que não foi acionado em nenhum momento da aula). A colinearidade observada, mesmo que aceitável no estudo exploratório e experimental pode ser melhor analisada e tratada em uma abordagem com modelos PLS-SEM utilizando variáveis latentes de segunda ordem.

A IES participante é tradicional no estudo de engenharia no Brasil há 56 anos, no entanto, representa uma amostra singular em apenas um campus, diante de todas as IES privadas e públicas que possuem cursos de engenharia no Brasil, o que limita a generalização dos resultados específicos da pesquisa. Com a metodologia apresentada, novos estudos precisam ser feitos incorporando as melhorias recomendadas através de novas estratégias que sejam aplicadas desde o planejamento dos objetivos de aprendizagem. A partir daí, elas devem ser implementadas de forma mais robusta com total envolvimento de instrutores e alunos, dentro de uma estratégia mais ampla que deve ser definida e direcionada (gerenciada) continuamente pela IES em questão. Tais novos estudos podem também ser replicados com essa metodologia melhorada em uma IES de maior porte, com uma amostra de observações ainda maior e, portanto, com poder estatístico maior. Estudos comparativos também podem ser desenvolvidos em pesquisas colaborativas entre pesquisadores de diferentes IES de Engenharia ou entre IES de Engenharia e departamentos de Engenharia em grandes universidades públicas ou privadas. O desempenho de alunos é uma conquista e é influenciada por uma infinidade de outros fatores além dos que pudemos controlar neste estudo, incluindo objetivos pessoais (YI; IM, 2004), estilos cognitivos (WITKIN, 1976). Obter melhor pontuação não é necessariamente o objetivo de todos os alunos (MCGILL; KLOBAS, 2009). Outras pesquisas também mostraram que há evidências de que os antecedentes culturais e biográficos de estudantes de diferentes origens podem influenciar a forma como usam e pensam sobre aprendizagem ativa e participação no seu próprio aprendizado (COLLIS, 1999; PALMA-RIVAS, 2000). Assim, novas pesquisas

podem também acessar estas diferentes características e suas implicações para a aplicação de AA pelos administradores de IES e aqueles professores ou coordenadores que fazem os projetos dos Projetos Pedagógicos (PP) e planos de ensino.

O uso da análise PLS-POS - *Prediction Oriented Segmentation* e PLS-MGA – *Multigroup Analysis* abriu novas oportunidades de pesquisas com os dados dos experimentos atuais e com novos experimentos futuros, pois estes algoritmos permitem identificar subgrupos de dados dentro das observações globais. Esta identificação possibilita a caracterização de alguma heterogeneidade com relação, por exemplo, aos dados biográficos dos alunos, às turmas noturnas versus diurnas, aos entrantes em períodos pares e ímpares, etc. Uma oportunidade latente pode ser aplicar a metodologia orientando-se pelas recomendações estratégicas sobre as técnicas de aprendizagem ativa sugeridas para cada perfil de disciplina no grupo STEM. Estas estratégias, ao responderem à pergunta de pesquisa 2 e supostamente apoiarem o poder preditivo do modelo apresentado como resultado principal da pesquisa desta tese, criaram a oportunidade de se testar uma nova hipótese: estas estratégias, se aplicadas, efetivamente melhorarão a qualidade preditiva do modelo, ou seja, tal hipótese pode ser testada na IES participante em um novo set de experimentos futuros.

Além destas possíveis iniciativas futuras, numa abordagem mais operacional, o protocolo de observação PORE (adaptado do COPUS) pode ser revisto nos seus elementos e no projeto da escala para ser melhor adequado às premissas para indicadores da modelagem PLS-SEM e para as aulas típicas de engenharia, incluindo as considerações para indicadores reflexivos e formativos. Por fim, mesmo com os melhores mecanismos de pesquisa e critérios de seleção, podem não ter sido capturadas uma ou mais fontes que adicionariam informações complementares à base de conhecimento apresentada na tese.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABDI, H. et al. Partial least squares for IS researchers: an overview and presentation of recent advances using the PLS approach. **Journal of Finance**, v. 53, n. 1, p. 1–10, 2015.
- ACOSTA-GONZAGA, E.; WALET, N. R. The role of attitudinal factors in mathematical on-line assessments: a study of undergraduate STEM students. **Assessment and Evaluation in Higher Education**, v. 43, n. 5, p. 710–726, 2017.
- ADAMS, S. G. et al. Development of a protocol to measure team behavior in engineering education. **IEEE Engineering Management Review**, v. 37, n. 1, p. 52, 2008.
- AI-LIM LEE, E.; WONG, K. W.; FUNG, C. C. How does desktop virtual reality enhance learning outcomes? A structural equation modeling approach. **Computers and Education**, v. 55, n. 4, p. 1424–1442, 2010.
- AKIHA, K. et al. What Types of Instructional Shifts Do Students Experience? Investigating Active Learning in Science, Technology, Engineering, and Math Classes across Key Transition Points from Middle School to the University Level. **Frontiers in Education**, v. 2, n. January, 2018.
- AKTER, S.; D'AMBRA, J.; RAY, P. An evaluation of PLS based complex models: The roles of power analysis, predictive relevance and GoF index. **17th Americas Conference on Information Systems 2011, AMCIS 2011**, v. 2, p. 1313–1319, 2011.
- APPOLINARIO, F. **Dicionário De Metodologia Científica: Um Guia Para A Produção Do Conhecimento Científico**. 2ed. ed. São Paulo - SP: ATLAS, 2011.
- ASOK, D. et al. Active learning environment for achieving higher-order thinking skills in engineering education. **Proceedings - 2016 IEEE 4th International Conference on MOOCs, Innovation and Technology in Education, MITE 2016**, p. 47–53, 2017.
- AUYUANET, A. et al. FísicActiva: applying active learning strategies to a large engineering lecture. **European Journal of Engineering Education**, v. 43, n. 1, p. 55–64, 2018.
- BABIN, B. J.; HAIR JR., J. F.; BOLES, J. S. Publishing Research in Marketing Journals Using SEM. **Journal of Marketing Theory and Practice**, v. 4, n. 16, p. 279–285, 2008.
- BAGOZZI, R. P.; PHILLIPS, L. W. Representing and Testing Organizational Theories: A Holistic Construal. **Administrative Science Quarterly**, v. 27, n. 3, p. 459, 1982.
- BAGOZZI, R. P.; YI, Y. Specification, evaluation, and interpretation of structural equation models. **Journal of the Academy of Marketing Science**, v. 40, n. 1, p. 8–34, 2012.
- BALCI, O. A life cycle for modeling and simulation. **Simulation**, v. 88, n. 7, p. 870–883, 2012.
- BALLANTYNE, D. Action research reviewed: a market-oriented approach. **European Journal of Marketing**, v. 38, n. 3/4, p. 321–337, 2004.
- BARAK, M. Teaching engineering and technology: Cognitive, knowledge and problem-solving taxonomies. **Journal of Engineering, Design and Technology**, v. 11, n. 3, p. 316–333, 2013.
- BARRON, B.; DARLING-HAMMOND, L. Teaching for meaningful learning: A review of research on inquiry-based and cooperative learning. In: **Powerful learning: What we know about teaching for** [s.l: s.n.].
- BARROWS, H. S. A taxonomy of problem-based learning methods. **Medical Education**, v. 1, n. 20, p. 481–486, 1986.

BASCLE, G. Controlling for endogeneity with instrumental variables in strategic management research. **Strategic Organization**, v. 6, n. 3, p. 285–327, 2008.

BECKER, J. M.; RAI, A.; RIGDON, E. Predictive validity and formative measurement in structural equation modeling: Embracing practical relevance. **International Conference on Information Systems (ICIS 2013): Reshaping Society Through Information Systems Design**, v. 4, p. 3088–3106, 2013.

BENTLER, P. M. **Theory and Implementation of EQS: A Structural Equations Program**. 1ed. ed. Los Angeles]: BDMP Statistical Software Inc., 1985.

BERTRAND, J. W. M.; FRANSOO, J. C. Operations management research methodologies using quantitative modeling. **International Journal of Operations and Production Management**, v. 22, n. 2, p. 241–264, 2002.

BISHOP, J. L.; VERLEGER, M. **The Flipped Classroom: A Survey Of The Research**. 120th ASEE Annual Conference & Exposition. **Anais...**2013

BLIGH, D. A. **What's the Use of Lectures?** 1 ed. ed. San Francisco - CA: Jossey-Bass, 2000.

BLOOM, B. S. **Taxonomy of Educational Objectives. Vol. 1: Cognitive Domain**. McKay ed. New York: [s.n.].

BODZIN, A. M.; BEERER, K. M. Promoting inquiry-based science instruction: The validation of the Science Teacher Inquiry Rubric (STIR). **Journal of Elementary Science Education**, v. 15, n. 2, p. 39–49, 2003.

BOLLEN, K. A.; BAULDRY, S. Three Cs in Measurement Models: Causal Indicators, Composite Indicators, and Covariates. **Psychological Methods**, v. 16, n. 3, p. 265–284, 2011.

BOLLEN, K. A.; TING, K. F. A tetrad test for causal indicators. **Psychological Methods**, v. 5, n. 1, p. 3–22, 2000.

BONWELL, C.; EISON, J. **Active Learning: Creating Excitement in the Classroom. 1991 ASHE-ERIC Higher Education Reports**. [s.l: s.n.].

BORDA, E. et al. Initial implementation of active learning strategies in large, lecture STEM courses: lessons learned from a multi-institutional, interdisciplinary STEM faculty development program. **International Journal of STEM Education**, v. 7, n. 1, 2020.

BORREGO, M.; BERNHARD, J. The emergence of engineering education research as an internationally connected field of inquiry. **Journal of Engineering Education**, v. 100, n. 1, p. 14–47, 2011.

BORSBOOM, D.; MELLENBERGH, G. J.; VAN HEERDEN, J. The Theoretical Status of Latent Variables. **Psychological Review**, v. 110, n. 2, p. 203–219, 2003.

BOUD, D.; FELETTI, G. **The Challenge of Problem-based Learning**. London - UK: Routledge, 1997.

BOWDEN, J. L. H.; D'ALESSANDRO, S. Co-creating value in higher education: The role of interactive classroom response technologies. **Asian Social Science**, v. 7, n. 11, p. 35–47, 2011.

BRAVO, R.; LUCIA-PALACIOS, L.; MARTIN, M. J. Processes and outcomes in student teamwork. An empirical study in a marketing subject. **Studies in Higher Education**, v. 41, n. 2, p. 302–320, 2016.

BROWN, T. Design Thinking - Design Básico. **Harvard Business Review**, p. 1–10, 2008.

BRUFF, D. **Teaching with Classroom Response Systems: Creating Active Learning Environments**. [s.l: s.n.]. v. 33

- BRYMAN, A. **Research methods and organization studies (contemporary social research)**. 1a. ed. London - UK: Routledge, 1989. v. 1
- BYRNE, B. M. Structural Equation Modeling With AMOS, EQS, and LISREL: Comparative Approaches to Testing for the Factorial Validity of a Measuring Instrument. **International Journal of Testing**, v. 1, n. 1, p. 55–86, 2001.
- CAI, J. et al. Understanding the continued use of flipped classroom instruction: a personal beliefs model in Chinese higher education. **Journal of Computing in Higher Education**, v. 31, n. 1, p. 137–155, 2019.
- CAMPBELL, C. M. et al. From Comprehensive to Singular: A Latent Class Analysis of College Teaching Practices. **Research in Higher Education**, v. 58, n. 6, p. 581–604, 2017.
- CAMPBELL, T.; ABD-HAMID, N. H.; CHAPMAN, H. Development of instruments to assess teacher and student perceptions of inquiry experiences in science classrooms. **Journal of Science Teacher Education**, v. 21, n. 1, p. 13–30, 2010.
- CASALE, A. **Aprendizagem Baseada em Problemas: desenvolvimento de competências para o ensino em engenharia**. [s.l: s.n.].
- CASSEL, C.; HACKL, P.; WESTLUND, A. H. Robustness of partial least-squares method for estimating latent variable quality structures. **Journal of Applied Statistics**, v. 26, n. 4, p. 435–446, 1999.
- CAUCHICK MIGUEL, P. ET AL. (ORG). **Metodologia da Pesquisa em Produção e Gestão de Operações**. 2a. ed. Rio de Janeiro: Elsevier, 2018.
- CHANG, C. C. et al. Is blended e-learning as measured by an achievement test and self-assessment better than traditional classroom learning for vocational high school students? **International Review of Research in Open and Distance Learning**, v. 15, n. 2, p. 213–231, 2014.
- CHEN, W.; LOOI, C.-K. Active classroom participation in a Group Scribbles primary science classroom. **British Journal of Educational Technology**, v. 42, n. 4, p. 676–686, 2011.
- CHIN, W. W. The partial least squares approach for structural equation modeling. **Modern methods for business research**, n. November, p. 295–336, 1998.
- CHIN, W. W.; DIBBERN, J. An Introduction to a Permutation Based Procedure for Multi-Group PLS Analysis: Results of Tests of Differences on Simulated Data and a Cross Cultural Analysis of the Sourcing of Information System Services Between Germany and the USA. **Handbook of Partial Least Squares**, p. 171–193, 2010.
- CHIN, W. W.; MARCOLIN, B. L.; NEWSTED, P. R. A Partial Least Squares Latent Variable Modeling Approach for Measuring Interaction Effects: Results from a Monte Carlo Simulation Study and an Electronic-Mail Emotion/Adoption Study. **Information Systems Research**, v. 14, n. 2, p. 189–217, 2003.
- CHIN, W. W.; MARCOULIDES, G. A. **New Perspectives in Partial Least Squares and Related Methods**. [s.l: s.n.]. v. 56
- CHOWDHURY, F. the Power of Using Pause Procedure During Accounting Lecture: an Action Research Study. **European Journal of Business and Social Sciences**, v. 5, n. 06, p. 101–108, 2016.
- CHRISTENSEN, C. M.; CARLILE, P. R. Course research: Using the case method to build and teach management theory. **Academy of Management Learning and Education**, v. 8, n. 2, p. 240–251, 2009.
- CHRISTIE, M.; DE GRAAFF, E. The philosophical and pedagogical underpinnings of Active Learning in Engineering Education. **European Journal of Engineering Education**, v. 42, n. 1, p. 5–16, 2016.

CIAN, H. et al. Inquiry Classroom Patterns of Student Cognitive Engagement: An Analysis Using Growth Curve Modeling. **Journal of Science Teacher Education**, v. 29, n. 4, p. 326–346, 2018.

CIANCIOLO, B. J.; FLORY, L.; ATWELL, J. Evaluating the Use of Inquiry-Based Activities: Do Student and Teacher behaviors really change. **Research and Teaching**, n. January 2006, 2006.

CLARK, R. M. et al. Flipping engineering courses: A school wide initiative. **Advances in Engineering Education**, v. 5, n. 3, p. 1–39, 2016.

COHEN, J. **Statistical Power Analysis for the Behavioral Sciences**. 1ed. ed. Hillsdale - NJ: Lawrence Erlbaum Associates, 1988.

COLLIS, B. **Designing for differences: Cultural issues in the design of WWW-based course-support sites****British Journal of Educational Technology**, 1999.

CRESWELL JOHN W. Mapping the Field of Mixed Methods Research. **Journal of Mixed Methods Research**, v. 3, n. 2, p. 95–108, 2009.

DAHER, T. et al. **Exploring Engineering Faculty Experiences with COPUS: Strategies for Improving Student Learning**. 2018 ASEE Conference & Exposition. **Anais...**2018

DAVADAS, S. D.; LAY, Y. F. Factors affecting students' attitude toward mathematics: A structural equation modeling approach. **Eurasia Journal of Mathematics, Science and Technology Education**, v. 14, n. 1, p. 517–529, 2018.

DE GRAAFF, E.; KOLMOS, A. The history of problem-based and project-based learning. In: DE GRAAFF, E.; KOLMOS, A. (Eds.). . **Management of change : implementation of problem-based and project-based learning in engineering**. 1 ed. ed. Rotterdam - Netherlands: Sense Publishers, 2007. p. 1–8.

DEMONBRUN, R. M. et al. **Measuring student response to instructional practices (StRIP) in traditional and active classrooms**. 123rd American Society for Engineering Education Annual Conference and Exposition. **Anais...**2016

DEMONBRUN, R. M.; FINELLI, C. J.; SHEKHAR, P. **Methods for establishing validity and reliability of observation protocols**. 122nd ASEE Annual Conference and Exposition. **Anais...**2015

DENNIS COOK, R.; FORZANI, L. Fundamentals of path analysis in the social sciences. **arXiv**, 2020.

DIAMANTOPOULOS, A.; WINKLHOFER, H. M. Index Construction with Formative Indicators: An Alternative to Scale Development. **Journal of Marketing Research**, v. 38, n. 2, p. 269–277, 2001.

DIAMANTOPOULOS, A. Modelling with LISREL: A guide for the uninitiated. **Journal of Marketing Management**, v. 10, n. 1–3, p. 105–136, 1994.

DIAMANTOPOULOS, A. et al. Guidelines for choosing between multi-item and single-item scales for construct measurement: A predictive validity perspective. **Journal of the Academy of Marketing Science**, v. 40, n. 3, p. 434–449, 2012.

DIAMANTOPOULOS, A.; SIGUAW, J. A. Formative versus reflective indicators in organizational measure development: A comparison and empirical illustration. **British Journal of Management**, v. 17, n. 4, p. 263–282, 2006.

DIAMANTOPOULOS, A.; WINKLHOFER, H. M. Index construction with formative indicators: An alternative to scale development. **Journal of Marketing Research**, v. 38, n. 2, p. 269–277, 2001.

DOCHY, F. et al. Effects of problem-based learning: a meta-analysis. **Learning and Instruction**, v. 13, p. 533–568, 2003.

DOPPELT, Y. Assessing creative thinking in design-based learning. **International Journal of Technology and Design Education**, v. 19, n. 1, p. 55–65, 2009.

DOUGLAS, E. P.; CHIU, C.-C. **Use of guided inquiry as an active learning technique in engineering**. Proceedings of the Research in Engineering Education Symposium. **Anais...**2009

DOUGLAS, E. P.; CHIU, C. C. Implementation of Process Oriented Guided Inquiry Learning (POGIL) in Engineering. **Advances in Engineering Education**, v. 3, n. 3, p. 1–16, 2013.

EBERLEIN, T. et al. Pedagogies of engagement in science: A comparison of PBL, POGIL, and PLTL. **Biochemistry and Molecular Biology Education**, v. 36, n. 4, p. 262–273, 2008.

EDWARDS, J. R. Multidimensional Constructs in Organizational Behavior Research: An Integrative Analytical Framework. **Organizational Research Methods**, v. 4, n. 2, p. 144–192, 2001.

ELLIS, G. W.; RUDNITSKY, A.; SILVERSTEIN, B. Using concept maps to enhance understanding in engineering education. **International Journal of Engineering Education**, v. 20, n. 6, p. 1012–1021, 2004.

ERDMANN, R. M.; STAINS, M. Classroom as genome: Using the tools of genomics and bioinformatics to illuminate classroom observation data. **CBE Life Sciences Education**, v. 18, n. 1, p. 1–12, 2019.

ESCRIVÃO FILHO, E.; RIBEIRO, L. R. DE C. Aprendendo com PBL – Aprendizagem Baseada em Problemas: relato de uma experiência em cursos de engenharia da EESC-USP. **Minerva – Pesquisa e Tecnologia**, v. 6, n. 1, p. 23–30, 2009.

FASSOTT, G.; HENSELER, J. Testing Moderating Effects in PLS Path Models: An Illustration of Available Procedures. In: **Handbook of Partial Least Squares**. [s.l.: s.n.].

FELDER, R. M.; BRENT, R. **Teaching and Learning STEM: A Practical Guide**. 1. ed. San Francisco - CA: Jossey-Bass, 2016.

FERNANDES, S. et al. Engaging students in learning: Findings from a study of project-led education. **European Journal of Engineering Education**, v. 39, n. 1, p. 55–67, 2014.

FERNANDES, S.; FLORES, M. A.; LIMA, R. M. Students' views of assessment in project-led engineering education: Findings from a case study in Portugal. **Assessment and Evaluation in Higher Education**, v. 37, n. 2, p. 163–178, 2012.

FERRARE, JOSEPH J; HORA, M. T. **A Review of Classroom Observation Techniques in Postsecondary Settings** WCER Working Paper, Wisconsin Center for Education Research. [s.l.: s.n.].

FINELLI, C. J. et al. **A classroom observation instrument to assess student response to active learning**. 2014 IEEE Frontiers in Education Conference (FIE) Proceedings. **Anais...**2014Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7044084>>

FOGG-ROGERS, L.; LEWIS, F.; EDMONDS, J. Paired peer learning through engineering education outreach. **European Journal of Engineering Education**, v. 42, n. 1, p. 75–90, 2017.

FORNELL, C.; BOOKSTEIN, F. L. Two Structural Equation Models: LISREL and PLS Applied to Consumer Exit-Voice Theory. **Journal of Marketing Research**, v. 19, n. 4, p. 440, 1982.

FORNELL, C.; LARCKER, D. F. Structural Equation Models with Unobservable Variables and Measurement Error: Algebra and Statistics. **Journal of Marketing Research**, v. 18, n. 3, p. 382, 1981a.

FORNELL, C.; LARCKER, D. F. Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. **Journal of Marketing Research**, v. 18, n. 1, p. 39, 1981b.

FRANKE, G. R.; PREACHER, K. J.; RIGDON, E. E. Proportional structural effects of formative indicators. **Journal of Business Research**, v. 61, n. 12, p. 1229–1237, 2008.

FREEMAN, S. et al. **Active learning increases student performance in science, engineering, and mathematics**. Proceedings of the National Academy of Sciences of the United States of America.

Anais...2014Disponível em:

<<http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=4060654&tool=pmcentrez&rendertype=abstract>>

FREY, R. F. A visual approach to helping instructors integrate, document, and refine active learning. **Journal of College Science Teaching**, v. 33, n. 5, p. 24–26, 2016.

FRUCHTER, B. R. A/E/C teamwork: A collaborative design and learning space. **Journal of Computing in Civil Engineering**, v. 13, n. October, p. 261–269, 1999.

FURTAK, E. M.; MORRISON, D.; KROOG, H. Investigating the Link Between Learning Progressions and Classroom Assessment. **SCIENCE EDUCATION**, v. 98, n. 4, p. 640–673, 2014.

GAUS, W.; MAYER, B.; MUCHE, R. Interpretation of Statistical Significance - Exploratory Versus Confirmative Testing in Clinical Trials, Epidemiological Studies, Meta-Analyses and Toxicological Screening (Using Ginkgo biloba as an Example). **Journal of Clinical and Experimental Pharmacology**, v. 5, n. 4, p. 1–6, 2015.

GHASEMY, M. et al. This fast car can move faster: a review of PLS-SEM application in higher education research. **Higher Education**, 2020.

GLEASON, B. L. et al. An active-learning strategies primer for achieving ability-based educational outcomes. **American journal of pharmaceutical education**, v. 75, n. 9, p. 186, 2011.

GÓMEZ PUENTE, S. M.; VAN EIJCK, M.; JOCHEMS, W. Towards characterising design-based learning in engineering education: a review of the literature. **European Journal of Engineering Education**, v. 36, n. 2, p. 137–149, 2011.

GOODHUE, D.; LEWIS, W.; THOMPSON, R. **Partial least squares for IS researchers: an overview and presentation of recent advances using the PLS approach**. Proceedings of the 39th Hawaii International Conference on System Sciences. Anais...2006Disponível em:

<<http://dx.doi.org/10.1016/j.jfineco.2011.12.001>%5Cn<http://www.blackwell-synergy.com/doi/abs/10.1111/0022-1082.95722>%5Cn<http://dx.doi.org/10.1016/j.jfineco.2011.05.003>%5Cn<http://linkinghub.elsevier.com/retrieve/pii/S0927539804000908>%5Cn<http://www.nber.org/>>

GORDON, T. et al. Shifting towards inquiry-orientated learning in a high school outreach program. **International Journal of Innovation in Science and Mathematics Education**, v. 23, n. 6, p. 63–74, 2015.

GREEN, T. A methodological review of structural equation modelling in higher education research. **Studies in Higher Education**, v. 41, n. 12, p. 2125–2155, 2016.

GREGOR, S.; HEVNER, A. R. Positioning and presenting design science research for maximum impact. **MIS Quarterly: Management Information Systems**, v. 37, n. 2, p. 337–355, 2013.

GROVES, R. M. . et al. **Survey methodology**. 1a. ed. New Jersey: Wiley-Blackwell, 2004.

GUDERGAN, S. P. et al. Confirmatory tetrad analysis in PLS path modeling. **Journal of Business Research**, v. 61, n. 12, p. 1238–1249, 2008.

GUIMARÃES, L.; LIMA, R. Changes in teaching and learning practice in an undergraduate logistics and transportation course using problem-based learning. **Journal of University Teaching & Learning Practices**, v. 18, n. 3, 2021.

GUIMARÃES, L. M.; AZEVEDO JR., J. B. **Estatística Aplicada em Engenharia com Minitab - Vol.2**. 1ed. ed. Santa Rita do Sapucaí - MG: Kindle Direct Publishing, 2020.

GUIMARÃES, L. M.; CERQUEIRA, R. J.; NORONHA, J. L. PBL (Problem-Based Learning) methodology application proposal in a production engineering undergraduate course at AT Itajubá Federal University (UNIFEI). **International Journal of Active Learning**, p. 35–55, 2016.

HADIM, H. A.; ESCHE, S. K. Enhancing the engineering curriculum through project-based learning. **32nd Annual Frontiers in Education**, v. 2, p. 2–7, 2002.

HAENLEIN, M.; KAPLAN, A. M. A Beginner's Guide to Partial Least Squares Analysis. **Understanding Statistics**, v. 3, n. 4, p. 2005–2006, 2007.

HAEP, A.; BEHNKE, K.; STEINS, G. Classroom observation as an instrument for school development: School principals' perspectives on its relevance and problems. **Studies in Educational Evaluation**, v. 49, p. 1–6, 2016.

HAHN, C. H. et al. Capturing Customer Heterogeneity using a Finite Mixture PLS Approach. **SSRN Electronic Journal**, 2002.

HAIR, J. F. et al. The Use of Partial Least Squares Structural Equation Modeling in Strategic Management Research: A Review of Past Practices and Recommendations for Future Applications. **Long Range Planning**, v. 45, n. 5–6, p. 320–340, 2012.

HAIR, J. F. et al. Mirror, mirror on the wall: a comparative evaluation of composite-based structural equation modeling methods. **Journal of the Academy of Marketing Science**, v. 45, n. 5, p. 616–632, 2017.

HAIR, J. F. et al. When to use and how to report the results of PLS-SEM Article information. **European Business Review**, v. 31, n. 1, p. 2–24, 2019.

HAIR, J. F.; HOWARD, M. C.; NITZL, C. Assessing measurement model quality in PLS-SEM using confirmatory composite analysis. **Journal of Business Research**, v. 109, n. November 2019, p. 101–110, 2020.

HAIR, J. F.; RINGLE, C. M.; SARSTEDT, M. PLS-SEM: Indeed a silver bullet. **Journal of Marketing Theory and Practice**, v. 19, n. 2, p. 139–152, 2011.

HAIR JR., J. F. et al. Partial least squares structural equation modeling (PLS-SEM): An emerging tool in business research. **European Business Review**, v. 26, n. 2, p. 106–121, 2014.

HAIR JR., J. F. et al. **A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)**. 2ed. ed. Thousand Oaks, CA: [s.n.].

HALABI, O. Immersive virtual reality to enforce teaching in engineering education. **Multimedia Tools and Applications**, v. 79, n. 3–4, p. 2987–3004, 2020.

HARDIN, A. M.; CHANG, J. C. J.; FULLER, M. A. Clarifying the use of formative measurement in the IS discipline: The case of computer self-efficacy. **Journal of the Association for Information Systems**, v. 9, n. 9, p. 544–546, 2008.

HARRIS, A. H.; COX, M. F. Developing an observation system to capture instructional differences in engineering classrooms. **Journal of Engineering Education**, v. 92, n. 4, p. 329–336, 2003.

HAYDUK, L. A.; LITTVAY, L. Should researchers use single indicators, best indicators, or multiple indicators in structural equation models? **BMC Medical Research Methodology**, v. 12, 2012.

HELM, S.; EGGERT, A.; GARNEFELD, I. Modeling the Impact of Corporate Reputation on Customer Satisfaction and Loyalty Using Partial Least Squares. In: **Handbook of Partial Least Squares**. [s.l.: s.n.]. p. 515–534.

HENSELER, J. On the convergence of the partial least squares path modeling algorithm. **Computational Statistics**, v. 25, n. 1, p. 107–120, 2010.

HENSELER, J. et al. Common Beliefs and Reality About PLS: Comments on Rönkkö and Evermann (2013). **Organizational Research Methods**, v. 17, n. 2, p. 182–209, 2014.

HENSELER, J.; DIJKSTRA, T. K. CONSISTENT PARTIAL LEAST SQUARES PATH MODELING. **MIS Quarterly: Management Information Systems**, v. 39, n. 2, p. 297–316, 2015.

HENSELER, J.; HUBONA, G.; RAY, P. A. Using PLS path modeling in new technology research: Updated guidelines. **Industrial Management and Data Systems**, v. 116, n. 1, p. 2–20, 2016.

HENSELER, J.; NOONAN, R. Partial Least Square Path Modeling: Basic Concepts issues and Application. **Leeflang et al. (eds.), Advanced Methods for Modeling Markets, International Series in Quantitative Marketing**, p. 361–381, 2017.

HENSELER, J.; RINGLE, C. M.; SARSTEDT, M. A new criterion for assessing discriminant validity in variance-based structural equation modeling. **Journal of the Academy of Marketing Science**, v. 43, n. 1, p. 115–135, 2015.

HENSELER, J.; RINGLE, C. M.; SINKOVICS, R. R. The use of partial least squares path modeling in international marketing. **Advances in International Marketing**, v. 20, n. 2009, p. 277–319, 2009.

HENSELER, J.; SARSTEDT, M. Goodness-of-fit indices for partial least squares path modeling. **Computational Statistics**, v. 28, n. 2, p. 565–580, 2013.

HMELO-SILVER, C. E. Problem-Based Learning: What and How Do Students Learn ? **Educational Psychology Review**, v. 16, n. 3, p. 235–267, 2004.

HOÖK, K.; LOWGREN, J. Strong concepts: Intermediate-level knowledge in interaction Design research. **ACM Transactions on Computer-Human Interaction**, v. 19, n. 3, p. 1–18, 2012.

HORA, M. T. Toward a Descriptive Science of Teaching: How the TDOP Illuminates the Multidimensional Nature of Active Learning in Postsecondary Classrooms. **Science Education**, v. 99, n. 5, p. 783–818, 2015.

HORTON, R.; MARSHALL, J. C.; WHITE, C. EQUIPPing Teachers; A protocol to guide and improve inquiry-based instruction. **The Science Teacher**, v. 76, n. 4, p. 46–53, 2009.

HOWELL, R. D. Covariance Structure Modeling and Measurement Issues: A Note on “Interrelations among a Channel Entity’s Power Sources”. **Journal of Marketing Research**, v. 24, n. 1, p. 119, 1987.

HU, H. H.; SHEPHERD, T. D. Using POGIL to help students learn to program. **ACM Transactions on Computing Education**, v. 13, n. 3, 2013.

HULT, G. T. M. et al. Addressing endogeneity in international marketing applications of partial least squares structural equation modeling. **Journal of International Marketing**, v. 26, n. 3, p. 1–21, 2018.

HWANG, H. et al. A concept analysis of methodological research on composite-based structural equation modeling: bridging PLSPM and GSCA. **Behaviormetrika**, n. 0123456789, 2019.

JOHNSON, A. W. et al. How a Flexible Classroom Affords Active Learning in Electrical Engineering. **IEEE Transactions on Education**, v. 62, n. 2, p. 91–98, 2019.

JOHNSON, C. C.; KAHLE, J. B.; FARGO, J. D. Effective Teaching Results in Increased Science Achievement for All Students. **Science Education**, v. 91, n. 1, p. 36–74, 2007.

JONES, S. et al. Lessons learned from developing a learning-focused classroom observation form. In: **To improve the academy**. [s.l.: s.n.]. p. 199–222.

JÖRESKOG, K. G. **Analysis of Covariance Structures**. [s.l.] ACADEMIC PRESS, INC., 1973.

JÖRESKOG, K. G.; SÖRBOM, D. Recent Developments in Structural Equation formulated a general model, the LISREL model, for systems of structural equations. **Journal of Marketing Research**, v. XIX, n. November, p. 404–420, 1982.

KAHAI, S. S.; COOPER, R. B. Exploring the core concepts of media richness theory: The impact of cue multiplicity and feedback immediacy on decision quality. **Journal of Management Information Systems**, v. 20, n. 1, p. 263–299, 2003.

KAVANAGH, L.; CROSTHWAITE, C. Triple-objective Team Mentoring. Achieving Learning Objectives with Chemical Engineering Students. **Education for Chemical Engineers**, v. 2, n. 1, p. 68–79, 2007.

KELLY, P. A. et al. A Comparison of In-Class Learner Engagement Across Lecture , Problem-Based Learning , and Team Learning Using the STROBE Classroom Observation Tool. **Teaching and Learning in Medicine**, v. 17, n. 2, p. 112–118, 2005.

KERN, A. L.; MOORE, T. J.; AKILLIOGLU, F. C. **Cooperative learning: Developing an observation instrument for student interactions**. Proceedings - Frontiers in Education Conference, FIE. **Anais...**2007

KETTERLINUS, R. D. et al. Partial least squares analysis in developmental psychopathology. **Development and Psychopathology**, v. 1, n. 4, p. 351–371, 1989.

KHAN, G. F. et al. Methodological research on partial least squares structural equation modeling (PLS-SEM): An analysis based on social network approaches. **Internet Research**, v. 29, n. 3, p. 407–429, 2019.

KIM, J. H.; CHOI, I. **Choosing the Level of Significance: A Decision-theoretic Approach** **Abacus**, 2019.

KIM, J. Y. A longitudinal study of the relation between creative potential and academic achievement at an engineering university in Korea. **Journal of Engineering Education**, v. 109, n. 4, p. 704–722, 2020.

KLEIN-GARDNER, S. S.; WALKER, A. Defining Global Competence for Engineering Students. **ASEE**, v. 1, n. 1072, p. 1–17, 2011.

KOCK, N. Single missing data imputation in PLS-based structural equation modeling. **Journal of Modern Applied Statistical Methods**, v. 17, n. 1, 2018.

KOCK, N. Full latent growth and its use in PLS-SEM: Testing moderating relationships. **Data Analysis Perspectives Journal**, v. 1, n. 1, p. 1–5, 2020a.

KOCK, N. **WarpPLS User Manual: Version 7** Laredo, TX ScriptWarp Systems., , 2020b.

KOCK, N.; HADAYA, P. Minimum sample size estimation in PLS-SEM: The inverse square root and gamma-exponential methods. **Information Systems Journal**, v. 28, n. 1, p. 227–261, 2018.

KRANZFELDER, P. et al. The Classroom Discourse Observation Protocol (CDOP): A quantitative method for characterizing teacher discourse moves in undergraduate STEM learning environments. **PLoS ONE**, v. 14, n. 7, p. 1–21, 2019.

KRAUS, A.; POPEK, S. Structural model of fruit juice quality determining factors in product design and development. **British Food Journal**, v. 115, n. 6, p. 865–875, 2013.

- KURUNDAWADE, S. R.; KAVALE, S. M. IIEECP intervention in teaching-learning process: An experience. **Journal of Engineering Education Transformations**, v. 31, n. 3, p. 192–199, 2018.
- LACUESTA, R.; PALACIOS, G.; FERNÁNDEZ, L. Active Learning through Problem Based Learning Methodology in Engineering Education. p. 1–6, 2009.
- LANDIS, R. S.; BEAL, D. J.; TESLUK, P. E. A Comparison of Approaches to Forming Composite Measures in Structural Equation Models. **Organizational Research Methods**, v. 3, n. 2, p. 186–207, 2000.
- LEFEBVRE, O.; PRAKASH, S. A Quantitative Study of the Role of Active Learning and Engagement in Improving Environmental Engineering Students' Learning Performance. **Engineering Education for a Smart Society**, v. 627, 2018.
- LEVRINI, O. et al. Defining and Operationalizing Appropriation for Science Learning. **Journal of the Learning Sciences**, v. 24, n. 1, p. 93–136, 2015.
- LEWIN, J. D. et al. A campus-wide investigation of clicker implementation: The status of peer discussion in STEM classes. **CBE Life Sciences Education**, v. 15, n. 1, p. 1–12, 2016.
- LIMA, R. M. et al. A case study on project led education in engineering: students' and teachers' perceptions. **European Journal of Engineering Education**, v. 32, n. 3, p. 337–347, 2007.
- LIMA, R. M.; ANDERSSON, P. H.; SAALMAN, E. Active Learning in Engineering Education: a (re)introduction. **European Journal of Engineering Education**, v. 42, n. 1, p. 1–4, 2017.
- LIMA, R. M.; MESQUITA, D. **Glossário de Abordagens de Aprendizagem Ativa IDEADIGITAL - Boletins** Centro IDEA-UMinho, , mar. 2021. Disponível em:
<<https://idea.uminho.pt/pt/ideadigital/entradas/Paginas/entrada33.aspx>>
- LIN, J.; MIAO, C.; SUN, W. Engaging Students in Active Learning by Introducing Game Development into Software Engineering. **International Journal of Information Technology**, v. 17, n. 2, p. 1–8, 2011.
- LIU, J. et al. Correlation and agreement: overview and clarification of competing concepts and measures. **Shanghai Archives of Psychiatry**, v. 28, n. 2, p. 115–120, 2016.
- LOHMÖLLER, J.-B. Predictive vs. Structural Modeling: PLS vs. ML. **Latent Variable Path Modeling with Partial Least Squares**, n. 1983, p. 199–226, 1989.
- LOVE, T. S.; WELLS, J. G.; PARKES, K. A. Examining the teaching of science, and technology and engineering content and practices: An instrument modification study. **Journal of Technology Education**, v. 29, n. 1, p. 45–66, 2017.
- LUDWIG, P. M.; COLLEEN, S.; PRINS, B. A Validated Novel Tool for Capturing Faculty-Student Joint Behaviors with the COPUS Instrument †. v. 20, n. 3, p. 1–9, 2019.
- LUND, T. J. et al. The Best of Both Worlds: Building on the COPUS and RTOP Observation Protocols to Easily and Reliably Measure Various Levels of Reformed Instructional Practice. **CBE—Life Sciences Education**, v. 14, p. 1–12, 2015.
- MACKENZIE, S. B.; PODSAKOFF, P. M.; JARVIS, C. B. The problem of measurement model misspecification in behavioral and organizational research and some recommended solutions. **Journal of Applied Psychology**, v. 90, n. 4, p. 710–730, 2005.
- MAGALHAES, J. M. et al. Implementation of a PBL/CDIO methodology at ISEP-P.PORTO Systems Engineering Course. **3rd International Conference of the Portuguese Society for Engineering Education, CISPEE 2018**, 2018.

MANGLA, S. K.; GOVINDAN, K.; LUTHRA, S. Critical success factors for reverse logistics in Indian industries: A structural model. **Journal of Cleaner Production**, v. 129, p. 608–621, 2016.

MARAUN, M. D.; HALPIN, P. F. Manifest and Latent Variates. **Measurement: Interdisciplinary Research & Perspective**, v. 6, n. 1–2, p. 113–117, 2008.

MARCOULIDES, G. A.; SAUNDERS, C. Editor ' s Comments : PLS : A Silver Bullet ? Stable URL : <http://www.jstor.org/stable/25148727> Editor ' s Comments _____ . v. 30, n. 2, 2016.

MARKOPOULOS, A. P. et al. Gamification in engineering education and professional training. **International Journal of Mechanical Engineering Education**, v. 43, n. 2, p. 118–131, 2015.

MARSHALL, J. C. et al. **Comparative Analysis of Two Inquiry Observational Protocols: Striving to Better Understand the Quality of Teacher-Facilitated Inquiry-Based Instruction School Science and Mathematics**, 2011. Disponível em: <<http://doi.wiley.com/10.1111/j.1949-8594.2011.00091.x>>

MARSHALL, J. C.; SMART, J.; HORTON, R. M. The design and validation of equipment: An instrument to assess inquiry-based instruction. **International Journal of Science and Mathematics Education**, v. 8, n. 2, p. 299–321, 2010.

MARTÍNEZ, G. et al. The Effectiveness of Concept Maps in Teaching Physics Concepts Applied to Engineering Education: Experimental Comparison of the Amount of Learning Achieved With and Without Concept Maps. **Journal of Science Education and Technology**, v. 22, n. 2, p. 204–214, 2013.

MARTINS, G. A.; THEÓPHILO, C. R. **Metodologia da investigação científica para ciências sociais aplicadas**. 2 ed. ed. São Paulo - SP: ATLAS, 2009.

MARTINS, R. A.; MELLO, C. H. P.; TURRIONI, J. B. **Guia para elaboração de monografia e TCC em Engenharia de Produção**. 1a. ed. São Paulo: ATLAS, 2014.

MATEOS-APARICIO, G. Partial least squares (PLS) methods: Origins, evolution, and application to social sciences. **Communications in Statistics - Theory and Methods**, v. 40, n. 13, p. 2305–2317, 2011.

MATSUSHITA, O. et al. Effects of Design Thinking on transnational collaborative projects in engineering. **2015 IEEE 7th International Conference on Engineering Education, ICEED 2015**, p. 112–117, 2016.

MAZUR, E. **Peer Instruction - A User's manual**. 1 Ed. ed. New York - NY: Pearson Education, Inc, 1997.

MAZUR, E.; WATKINS, J. Just-in-Time Teaching and Peer Instruction. **Just in Time Teaching: Across the Disciplines, and Across the Academy**, p. 39–62, 2009.

MCDONALD, R. P. Path Analysis with Composite Variables. **Multivariate Behavioral Research**, v. 31, n. 2, p. 239–270, 1996.

MCGILL, T. J.; KLOBAS, J. E. A task-technology fit view of learning management system impact. **Computers and Education**, v. 52, n. 2, p. 496–508, 2009.

MEC, M. DA E. C. N. DE E. C. DE E. **RESOLUÇÃO Nº 2, DE 24 DE ABRIL DE 2019**. Disponível em: <http://portal.mec.gov.br/index.php?option=com_docman&view=download&alias=112681-rces002-19&category_slug=abril-2019-pdf&Itemid=30192>. Acesso em: 18 jun. 2020.

MEHTA, G. et al. A Study of Self-regulated Learning in an Online Gaming Environment for Engineering Education. **International Journal of Information and Education Technology**, v. 7, n. 6, p. 406–410, 2017.

MENEKSE, M. et al. Differentiated overt learning activities for effective instruction in engineering classrooms. **Journal of Engineering Education**, v. 102, n. 3, p. 346–374, 2013.

MEYERS C.; JONES, T. B. **Promoting active learning: strategies for the college classroom**. San Francisco - CA: Jossey-Bass, 1993.

MICHAELSEN, L. K.; SWEET, M. The Essential Elements of Team-Based Learning. **New Directions for Teaching and Learning**, v. 2008, n. 116, p. 7–27, 2008.

MIKESKA, J. N. et al. Using classroom observations to evaluate science teaching: Implications of lesson sampling for measuring science teaching effectiveness across lesson types. **Science Education**, v. 103, n. 1, p. 123–144, 2019.

MINNER, D.; DELISI, J. **Inquiring into Science Instruction Observation Protocol (ISIOP) User's Manual**, 2012.

MITCHELL, J. E.; ROGERS, L. Staff perceptions of implementing project-based learning in engineering education. **European Journal of Engineering Education**, v. 45, n. 3, p. 349–362, 2020.

MITROFF, I. I. et al. On Managing Science in the Systems Age: Two Schemas for the Study of Science as a Whole Systems Phenomenon. **Interfaces**, v. 4, n. 3, p. 46–58, 1974.

MONTGOMERY, D. C.; RUNGER, G. C. **Applied Statistics and Probability for Engineers**. 5 ed. ed. Hoboken, NJ: John Wiley & Sons, Inc., 2011.

MUÑOZ MARCIAM@UCSC.CL, M. . et al. Active learning in first-year engineering courses at Universidad Católica de la Santísima Concepción, Chile. **Australasian Journal of Engineering Education**, v. 19, n. 1, p. 27–38, 2013.

NKHOMA, M.; SRIRATANAVIRIYAKUL, N.; QUANG, H. LE. Using case method to enrich students' learning outcomes. **Active Learning in Higher Education**, v. 18, n. 1, p. 37–50, 2017.

NORMAN, G. R.; SCHMIDT, H. G. The psychological basis of problem-based learning: A review of the evidence. **Academic Medicine**, v. 67, n. 9, p. 557–565, 1992.

NOVAK, G. M. **Just-in-time teaching : blending active learning with web technology**. [s.l.: s.n.].

NOVAK, J. D.; CAÑAS, A. J. **The Theory Underlying Concept Maps and How to Construct Them** **Technical Report IHMC CmapTools 2006-01**. [s.l.: s.n.]. Disponible em: <<http://cmap.ihmc.us/Publications/ResearchPapers/TheoryUnderlyingConceptMaps.pdf>>.

PALMA-RIVAS, N. Using Technology to Facilitate Learning for Minority Students. **New Directions for Community Colleges**, v. 2000, n. 112, p. 73–83, 2000.

PALMER, S.; HALL, W. An evaluation of a project-based learning initiative in engineering education. **European Journal of Engineering Education**, v. 36, n. 4, p. 357–365, 2011.

PARK, S.; GUPTA, S. Handling endogenous regressors by joint estimation using copulas. **Marketing Science**, v. 31, n. 4, p. 567–586, 2012.

PECORE, J. L. From Kilpatrick's project method to project-based learning. **International Handbook Progressive Education**, p. 155–171, 2015.

PIBURN, M.; SAWADA, D.; TURLEY, J. Reformed teaching observation protocol (RTOP) reference manual. **... of Teachers**, p. 1–41, 2000.

POULTER, J.; CHECKLAND, P. Soft Systems Methodology. In: REYNOLDS, M.; HOLWELL, S. (Eds.). **Systems Approaches to Managing Change: A Practical Guide**. London - UK: Springer-Verlag London Limited, 2010. p. 191–242.

PREVALLA, B.; UZUNBOYLU, H. Flipped learning in engineering education. **TEM Journal**, v. 8, n. 2, p. 656–661, 2019.

PRINCE, M. J.; FELDER, R. M. Inductive Teaching and Learning Methods: Definitions, Comparisons, and Research Bases. **Journal of Engineering Education**, v. 95, n. 2, p. 123–138, 2006.

RAMSEY, J. B. Tests for Specification Errors in Classical Linear Least-Squares Regression Analysis. **Journal of the Royal Statistical Society: Series B (Methodological)**, v. 31, n. 2, p. 350–371, 1969.

REIS, A. C. B.; BARBALHO, S. C. M.; ZANETTE, A. C. D. A bibliometric and classification study of Project-based Learning in Engineering Education. **Producao**, v. 27, n. Special Issue, p. 1–16, 2017.

REQUIES, J. M. et al. Journal of Technology and Science Education EVOLUTION OF PROJECT-BASED LEARNING IN SMALL GROUPS IN. v. 8, n. 1, p. 45–62, 2018.

RIGDON, E. E. Rethinking Partial Least Squares Path Modeling: In Praise of Simple Methods. **Long Range Planning**, v. 45, n. 5–6, p. 341–358, 2012.

RIGDON, E. E. Rethinking Partial Least Squares Path Modeling: Breaking Chains and Forging Ahead. **Long Range Planning**, v. 47, n. 3, p. 161–167, 2014.

RIGDON, E. E.; RINGLE, C. M.; SARSTEDT, M. **Structural modeling of heterogeneous data with partial least squares**. [s.l: s.n.]. v. 7

RINDSKOPF, D. Using phantom and imaginary latent variables to parameterize constraints in linear structural models. **Psychometrika**, v. 49, n. 1, p. 37–47, 1984.

RINGLE, C. M.; SARSTEDT, M.; MOOI, E. Response-Based Segmentation Using Finite Mixture Partial Least Squares. **Annals of Information Systems**, v. 8, p. 19–49, 2010.

RINGLE, C. M.; WENDE, S.; BECKER, J. M. “**SmartPLS 3.**”Boeningstedt - GmbHSmartPLS GmbH, , 2015. Disponível em: <<http://www.smartpls.com>>

RÖNKKÖ, M.; EVERMANN, J. A Critical Examination of Common Beliefs About Partial Least Squares Path Modeling. **Organizational Research Methods**, v. 16, n. 3, p. 425–448, 2013.

ROSS, K. N. Sample design for educational survey research. **Evaluation in Education. International Progress**, v. 2, n. 2, p. 105–195, 1978.

RUBIN, M. Do p values lose their meaning in exploratory analyses? It depends how you define the familywise error rate. **Review of General Psychology**, v. 21, n. 3, p. 269–275, 2017.

RUGUTT, J.; CHEMOSIT, C. A Study of Factors that Influence College Academic Achievement: A Structural Equation Modeling Approach. **Journal of Educational Research & Policy Studies**, v. 5, n. 1, p. 66–90, 2005.

RUI, N.; FELDMAN, J. M. IRR (Inter-Rater Reliability) of a COP (Classroom Observation Protocol)--A Critical Appraisal. **US-China Education Review**, v. B, n. 3, p. 305–315, 2012.

SANDERS, M.; SPIEGEL, S.; SHERER, J. Z. **Moving Beyond “Does Active Learning Work?” with the Engineering Learning Observation Protocol (ELCOT)**. 2018 ASEE Conference & Exposition. **Anais...2018**

SARKAR, M. B.; ECHAMBADI, R. A. J.; HARRISON, J. S. Alliance entrepreneurship and firm market performance. **Strategic Management Journal**, v. 22, n. 6–7, p. 701–711, 2001.

SARSTEDT, M. et al. Partial least squares structural equation modeling (PLS-SEM): A useful tool for family business researchers. **Journal of Family Business Strategy**, v. 5, n. 1, p. 105–115, 2014a.

SARSTEDT, M. et al. On the Emancipation of PLS-SEM: A Commentary on Rigdon (2012). **Long Range Planning**, v. 47, n. 3, p. 154–160, 2014b.

SARSTEDT, M. et al. Estimation issues with PLS and CBSEM: Where the bias lies! **Journal of Business Research**, v. 69, n. 10, p. 3998–4010, 2016.

SARSTEDT, M.; MOOI, E. **A Concise Guide to Market Research**. [s.l.: s.n.].

SARSTEDT, M.; RINGLE, C. M.; HAIR, J. F. Partial least squares structural equation modeling. In: (EDS), H. ET AL. (Ed.). . **Handbook of Market Research**. [s.l.] Springer International Publishing, 2017a. v. 21p. 1–16.

SARSTEDT, M.; RINGLE, C. M.; HAIR, J. F. Treating unobserved heterogeneity in PLS-SEM: a multi-method approach. In: LATAN, H.; NOONAN, R. (Eds.). . **Partial Least Squares Path Modeling: Basic Concepts, Methodological Issues and Applications**. Cham: Springer International Publishing, 2017b. p. 197–217.

SAVERY, J. R. Overview of Problem-Based Learning: Definitions and Distinctions Origins of PBL. **The Interdisciplinary Journal of Problem-based Learning**, v. 1, n. 1, p. 5–16, 2006.

SAWADA, D. et al. Measuring reform practices in science and mathematics classrooms: The Reformed Teaching Observation Protocol. **School Science and Mathematics**, v. 102, n. October, p. 245–253, 2002.

SCHREIBER, J. B. et al. Reporting structural equation modeling and confirmatory factor analysis results: A review. **Journal of Educational Research**, v. 99, n. 6, p. 323–338, 2006.

SCHUMM, W. R. et al. Determining statistical significance (alpha) and reporting statistical trends: controversies, issues, and facts 1 . **Comprehensive Psychology**, v. 2, n. 1, p. Article 10, 2013.

SHARMA, P. N. et al. **Prediction-Oriented Model Selection in Partial Least Squares Path Modeling** **Decision Sciences**, 2018.

SHEKHAR, P. et al. Development of an Observation Protocol to Study Undergraduate Engineering Student Resistance to Active Learning. **International Journal of Engineering Education on**, v. 31, n. 1, p. 597–609, 2015.

SHMUELI, G. et al. The elephant in the room: Predictive performance of PLS models. **Journal of Business Research**, v. 69, n. 10, p. 4552–4564, 2016.

SHMUELI, G. et al. Predictive model assessment in PLS-SEM: guidelines for using PLSpredict. **European Journal of Marketing**, v. 53, n. 11, p. 2322–2347, 2019.

SIMON, H. A. **The Sciences of the Artificial**. 3 ed. ed. Cambridge: MIT Press, 1996.

SMITH, M. K. et al. The classroom observation protocol for undergraduate stem (COPUS): A new instrument to characterize university STEM classroom practices. **CBE Life Sciences Education**, v. 12, n. 4, p. 618–627, 2013.

SMITH, M. K. et al. COPUS Training Guide. **CBE-Life Sciences Education**, v. 12, n. 4, p. 1–2, 2014.

STEARNS, L. M. et al. A Teacher Observation Instrument for PBL Classroom Instruction. **Journal of STEM Education**, v. 13, n. 3, p. 7–17, 2012.

SUNAL, D. W. et al. The 21st Century Physics Classroom: What Students, Teachers, and Classroom Observers Report. **School Science and Mathematics**, v. 116, n. 3, p. 116–126, 2016.

SVENSSON, G. et al. Framing the triple bottom line approach: Direct and mediation effects between economic, social and environmental elements. **Journal of Cleaner Production**, v. 197, p. 972–991, 2018.

TABACHNICK, B. G.; FIDELL, L. S. **Using Multivariate Statistics**. 7th. Editi ed. New York: Pearson Education, Inc, 2007.

TEIXEIRA, K. C. B. et al. Peer instruction methodology for linear algebra subject: A case study in an engineering course. **Proceedings - Frontiers in Education Conference, FIE**, v. 2015, 2015.

TENENHAUS, M. et al. PLS path modeling. **Computational Statistics and Data Analysis**, v. 48, n. 1, p. 159–205, 2005.

TENENHAUS, M. Component-based structural equation modelling. **Total Quality Management and Business Excellence**, v. 19, n. 7–8, p. 871–886, 2008.

THARAYIL, S. et al. Strategies to mitigate student resistance to active learning. **International Journal of STEM Education**, v. 5, n. 1, p. 7, 2018.

TOLNAY, T. K.; SPIEGEL, S.; SHERER, J. Z. **Development of the Engineering Learning Classroom Observation Tool (ELCOT)**. ASEE Annual Conference & Exposition. **Anais...2017**

TOMKIN, J. H. et al. Evidence that communities of practice are associated with active learning in large STEM lectures. **International Journal of STEM Education**, p. 1–15, 2019.

TYNJÄLÄ, P. Towards expert knowledge? A comparison between a constructivist and a traditional learning environment in the university. **International Journal of Educational Research**, v. 31, p. 357–442, 1999.

USKOV, A.; SEKAR, B. Serious games, gamification and game engines to support framework activities in engineering: Case studies, analysis, classifications and outcomes. **IEEE International Conference on Electro Information Technology**, p. 618–623, 2014.

VAN AKEN, J. E. Management Research Based on the Paradigm of the Design Sciences: The Quest for Field-Tested and Grounded Technological Rules. **Journal of Management Studies**, v. 41, n. 2, p. 219–246, 2004.

VAN AMBURGH, J. A. et al. A tool for measuring active learning in the classroom. **American Journal of Pharmaceutical Education**, v. 71, n. 5, 2007.

VIJAYAN, K. K.; MORK, O. J.; GISKE, L. A. L. Integration of a Case Study into Learning Factory for Future Research. **Procedia Manufacturing**, v. 31, p. 258–263, 2019.

VILLARINI, Á. Teoría y pedagogía del pensamiento crítico. **Perspectivas psicológicas**, v. 3–4, p. 35–42, 2004.

VOLPE, R. J. et al. **Observing students in classroom settings: A review of seven coding schemes** **School Psychology Review**, 2005.

VOSS, C.; TSIKRIKTSIS, N.; FROHLICH, M. Case research in operations management. **International Journal of Operations and Production Management**, v. 22, n. 2, p. 195–219, 2002.

WALTHER, J. et al. Engineering competence? An interpretive investigation of engineering students' professional formation. **Journal of Engineering Education**, v. 100, n. 4, p. 703–740, 2011.

WANG, S.; WANG, H. Teaching Design Thinking Through Case Analysis: Joint Analytical Process. **Decision Sciences Journal of Innovative Education**, v. 9, n. 1, p. 113–118, 2011.

WHEELER, L. B. et al. Development and validation of the Classroom Observation Protocol for Engineering Design (COPED). **Journal of Research in Science Teaching**, v. 56, n. 9, p. 1285–1305, 2019.

WIGGINS, G.; MCTIGHE, J. **Understanding by Design**. 2 ed. ed. Alexandria, Virginia.: Merrill Education/ASCD College Textbook Series, 2005.

WILLIAMS, B.; CARVALHO, I. **Using The LAMM Classroom Observation System To Facilitate The Adoption Of Active Learning Methodologies**. International IGIP-SEFI Annual Conference 2010. **Anais...**2010

WITKIN, H. A. Cognitive style in academic performance and in teacher-student relations. In: (ED.), S. M. (Ed.). **. Individuality in Learning**. San Francisco - CA: Jossey-Bass., 1976.

WOLD, H. **Path Models with Latent Variables: The NIPALS Approach**. [s.l.] ACADEMIC PRESS, INC., 1975.

WOLD, H. Evaluation of Econometric Models. **Evaluation of Econometric Models Volume**, v. 48, n. 3, p. 841, 1980.

XIE, Z.; CAO, X. Construction three-dimensional observation system of teacher-student interaction behavior in classroom and Practice. **2010 2nd International Conference on Education Technology and Computer (ICETC)**, p. 2–5, 2010.

YI, M. Y.; IM, K. S. Predicting computer task performance: Personal goal and self-efficacy. **Journal of Organizational and End User Computing**, v. 16, n. 2, p. 20–37, 2004.

YIN, R. K. **Case Study Research and Applications: Design and Methods**. Sixth edit ed. Newbury Park, CA: SAGE Publications, Inc., 2017.

ZEEGERS, P. Student learning in higher education: A path analysis of academic achievement in science. **Higher Education Research and Development**, v. 23, n. 1, p. 35–56, 2004.

ZOLIN, R.; FRUCHTER, R.; LEVITT, R. E. Realism and Control: Problem-Based Learning Programs as a Data Source for Work-Related Research. **International Journal of Engineering Education**, v. 19, n. 6, p. 788–798, 2003.