

Relatório de Pesquisa IPR RP – 025

**ESTADO DA ARTE E PREMISSAS PARA
OS EFEITOS DE ESCALONAMENTO POR
BOMBEAMENTO A PARTIR DO MÉTODO
DA AASHTO – ANALOGIAS COM
MODELOS DE ZONAS CLIMÁTICAS NÃO
TEMPERADAS COMO FLÓRIDA E SUL DA
CALIFÓRNIA**

BRASÍLIA/DF
JULHO/2026

MINISTÉRIO DOS TRANSPORTES
DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTES
DIRETORIA-GERAL
DIRETORIA DE PLANEJAMENTO E PESQUISA
INSTITUTO DE PESQUISAS EM TRANSPORTES

Relatório de Pesquisa IPR RP – 025

**ESTADO DA ARTE E PREMISSAS PARA OS
EFEITOS DE ESCALONAMENTO POR
BOMBEAMENTO A PARTIR DO MÉTODO DA
AASHTO – ANALOGIAS COM MODELOS DE
ZONAS CLIMÁTICAS NÃO TEMPERADAS COMO
FLÓRIDA E SUL DA CALIFÓRNIA**

Elaboração: Fundação para o Desenvolvimento Tecnológico da Engenharia

Processo: 50600.008130/2026-47

DOI: 10.70859/IPR-RP-025/2026

Brasília/DF

Julho/2026

EQUIPE TÉCNICA:

Eng.º José Tadeu Balbo, D.Sc.– Escola Politécnica da Universidade de São Paulo – FDTE

Eng.ª Andréia Posser Cargnin, D.Sc.– Escola Politécnica da Universidade de São Paulo – FDTE

Matemático Fábio Henrique Pereira, D.Sc. – Escola Politécnica da Universidade de São Paulo – FDTE

Meteorologista Mariana Fadigatti Picolo, D.Sc. – Escola Politécnica da Universidade de São Paulo – FDTE

Eng.º Andrés Gabriel César Torres, M.Sc.– Escola Politécnica da Universidade de São Paulo – FDTE

Eng.º Matheus Silva Camargo (Engenharia Civil), mestrando – Escola Politécnica da Universidade de São Paulo – FDTE

REVISÃO DE EDITORAÇÃO:

Eng.º Luiz Heleno Albuquerque Filho, DsC. – IPR/DPP/DNIT

Eng.ª Simoneli Fernandes Mendonça – IPR/DPP/DNIT

Eng.ª Victória Barbosa Costa Garcia Vieira – Consórcio Progen/HPT

Brasil. Departamento Nacional de Infraestrutura de Transportes.

Diretoria-geral. Diretoria de Planejamento e Pesquisa.

Instituto de Pesquisas em Transportes.

Estado da arte e premissas para os efeitos de escalonamento por bombeamento a partir do método da AASHTO – Analogias com modelos de zonas climáticas não temperadas como Flórida e Sul da Califórnia – Brasília, 2026.

219 p. (Relatório de Pesquisa – IPR RP 025)

O conteúdo apresentado neste documento é de inteira responsabilidade dos autores.

A reprodução completa ou parcial desta publicação é permitida, sem alterar seu conteúdo, desde que não tenha fim comercial e que seja citada a referência bibliográfica completa.

RESUMO

O presente Relatório de Pesquisa IPR RP 025, apresenta o detalhamento e avanços do projeto de pesquisa. Seu conteúdo versa sobre os modelos de degradação por formação de escalonamentos (degraus) em juntas transversais de PCS e WT, como item de abertura, bem como os avanços relacionados à clusterização de áreas climáticas no território brasileiro e à simulação por elementos finitos em 2D de casos de estruturas de PCS para os estudos metodológicos de aprendizado de máquina, com finalidade de desenvolvimento de modelos baseados em inteligência artificial, para a predição de diferenciais térmicos em placas de concreto rodoviárias e das respostas mecânicas dessas estruturas sob ação de carga e temperaturas. Como resultados principais do andamento dos estudos no período de setembro de 2025 a fevereiro de 2026, podem ser colocados em destaque: (a) proposta metodológica para modelagem do escalonamento em juntas de PCS com base no banco de dados do LTPP-NCHRP dos EUA; (b) proposta de clusterização do território nacional em quinze zonas climáticas típicas; (c) proposta de metodologias de IA para geração de respostas estruturais de PCS solicitados por cargas rodoviárias e ambientais; (d) detecção de necessidade de aprofundamento em coleta de dados sobre diferenciais térmicos para o desenvolvimento do projeto. Todas as atividades desenvolvidas denotam um cronograma de andamento do projeto adequado e atendido, com as diretrizes gerais para o aprofundamento na definição de modelos empírico-mecanicistas para consolidação de uma norma de dimensionamento estrutural e funcional de PCS e WT no Brasil nos períodos que se seguem.

Palavras-chave: Pavimentos de Concreto; Normas Federais; Método de Projeto; Especificações; Metodologia.

ABSTRACT

This Research Report IPR RP 025 presents the details and progress of the research project. Its content focuses on degradation models due to the formation of faults in transverse joints of PCS and WT, as an opening item, as well as advances related to the clustering of climatic areas in Brazilian territory and 2D finite element simulation of PCS structure cases, for methodological machine learning studies to develop artificial intelligence-based models, for predicting thermal differentials in road concrete slabs and the mechanical responses of these structures under load and temperature. Key results of the studies conducted between September 2025 and February 2026 include: (a) a methodological proposal for modeling faulting in PCS transversal joints based on the US LTPP-NCHRP database; (b) a proposal for clustering the national territory into fifteen typical climatic zones; (c) proposal of AI methodologies for generating structural responses of PCS requested by road loads and environmental loads; (d) detection of the need for further data collection on thermal differentials for the development of the project. All activities developed denote an adequate and met project progress schedule, with general guidelines for further development in the definition of empirical-mechanistic models for the consolidation of a structural and functional design standard for PCS and WT in Brazil in the following periods.

Keywords: Concrete Pavements; Federal Standards; Design Method; Specifications; Methodology.

LISTA DE SÍMBOLOS E ABREVIATURAS

AASHTO	<i>American Association of State Highway and Transportation Officials</i>
ARA	<i>Applied Research Associates</i>
ABNT	Associação Brasileira de Normas Técnicas
BIC	Critério de informação Bayesiano
BT	Barra de transferência de carga
CNN	Rede neural convolucional
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
CRCP	Pavimento de concreto com armadura contínua
DBSCAN	<i>Density-Based Spatial Clustering of Applications with Noise</i>
DJF	Dezembro/Janeiro/Fevereiro
DNIT	Departamento Nacional de Infraestrutura de Transportes
DOE	<i>Design of Experiments</i>
DOT	<i>Department of Transportation</i>
DT_{max}	Diferencial térmico máximo
E	Módulo de elasticidade
ECMWF	<i>European Centre for Medium-Range Weather Forecasts</i>
EPUSP	Escola Politécnica da Universidade de São Paulo
ERA5	<i>Fifth Generation of European ReAnalysis</i>
ESRD	Eixo simples de rodas duplas
FAA	<i>Federal Aviation Administration</i>
FAPESP	Fundação de Amparo à Pesquisa do Estado de São Paulo
FEA	<i>Finite Element Analysis</i>
FEM	<i>Finite Element Method</i>
FDTE	Fundação para o Desenvolvimento Tecnológico da Engenharia
FIB	<i>The International Federation for Structural Concrete</i>
H	Umidade relativa do ar
h	Espessura da placa
INMET	Instituto Nacional de Meteorologia
IA	Inteligência artificial
IPR	Instituto de Pesquisas em Transportes
JJA	Junho/Julho/Agosto

k	Módulo de reação do subleito
MAE	Erro absoluto médio
MAM	Março/Abril/Maio
MT	Ministério dos Transportes
MEPDG	<i>Mechanistic-Empirical Pavement Design Guide</i>
MLP	<i>Multilayer Perceptron</i>
NHI	Número de horas de insolação
NCHRP	<i>National Cooperative Highway Research Program</i>
OMM	Organização Meteorológica Mundial
PCA	<i>Portland Cement Association</i>
PCS	Pavimento de Concreto Simples
PNV	Plano Nacional Viário
R^2	Coeficiente de determinação
ReLU	<i>Rectified Linear Unit</i>
RF	<i>Random Forest</i>
RMSE/MSE	Erro quadrático médio
RT	Relatório Técnico de Andamento de Pesquisa
RNA	Redes Neurais Artificiais
SON	Setembro/Outubro/Novembro
T_{ar}	Temperatura atmosférica média
TT_{max}	Temperatura máxima de topo
UIUC	<i>University of Illinois Urbana-Champaign</i>
USP	Universidade de São Paulo
WT	<i>Whitetopping</i>
XGBoost	<i>Extreme Gradient Boosting</i>
ZCIT	Zona de Convergência Intertropical
ΔT	Diferencial linear de temperatura

LISTA DE ILUSTRAÇÕES

Figura 2.1. Fluxograma para processo de cálculo incremental do escalonamento de junta em PCS	36
Fonte: adaptado de NCHRP (2003).....	36
Figura 2.9 – Boxplot da precipitação acumulada para os estados americanos e regiões do Brasil.....	49
Figura 2.10 – Boxplot da temperatura máxima média para os estados americanos e regiões do Brasil.....	49
Figura 2.11 – Boxplot da temperatura mínima média para os estados americanos e regiões do Brasil.....	50
Figura 2.12 – Boxplot da temperatura média para os estados americanos e regiões do Brasil	50
Figura 2.13 – Boxplot da umidade relativa para os estados americanos e regiões do Brasil	50
Figura 2.14 – Boxplot da velocidade do vento para os estados americanos e regiões do Brasil.....	51
Figura 3.1 – Modelo de elementos finitos para o sistema de pavimento (Tabatabaie e Barenberg, 1978).....	54
Figura 3.2 – Variáveis consideradas na modelagem empregando ISLAB 2005	60
Figura 3.3 – Características geométricas do modelo e posicionamento do ESRD	61
Figura 3.4 – Estrutura de pavimento modelado com o ISLAB 2005	63
Figura 3.5 – Comportamento de esforço por variação de carga	81
Figura 3.6 – Comportamento de esforço por variação de ΔT	82
Figura 3.7 – Comportamento de esforço por variação de módulo de elasticidade	83
Figura 3.8 – Comportamento de esforço por variação de módulo de reação do subleito ..	84
Figura 4.1 – Placa isolada carregada modelada no ABAQUS	85
Figura 4.2 – Definição de pressão de carga aplicada na infraestrutura	86
Figura 4.3 – Definição dos parâmetros de materiais	87
Figura 4.4 – Placa de concreto apoiada sobre fundação elástica.....	87
Figura 4.5 – Seleção do tipo de elemento que compõe a malha	88
Figura 4.6 – Malha gerada na placa isolada modelada no ABAQUS.....	89

Figura 4.7 – Esforço máximo na direção x.....	89
Figura 4.8 – Esforço máximo na direção y.....	90
Figura 4.9 – Deflexão na placa isolada.....	90
Figura 5.1 – Localização das estações de superfície operadas pelo INMET.....	96
Figura 5.2 – Índices Silhouette (a) Davies-Bouldin (b) Sdbw (c) calculados para os três testes utilizando 8, 9 e 10 clusters.....	103
Figura 5.3 – Heatmap com os resultados do Mann-Whitney para o Xmeans (esquerda) e Fuzzy C-means (direita) utilizando 10 clusters. Quadrados sombreados para valores acima de 0,05.....	104
Figura 5.4 – Nomenclatura obtida pela mediana dos clusters utilizando os critérios indicados na Tabela 5.3: (a) resultados das análises de cluster para o teste 1 com o Xmeans; (b) para o teste 3 com o Xmeans e (c) Fuzzy C-means.	105
Figura 5.5 – Índices calculados para os dois testes com os dados do ERA5-Land+MERGE e teste 3 com os dados das estações de superfície: (a) Silhouette; (b) Davies-Bouldin e (c) Sdbw.....	108
Figura 5.6 – <i>Heatmap</i> com os resultados do Mann-Whitney para o Kmeans (a), Xmeans (b) e Fuzzy C-means (c) utilizando 10 clusters para o teste 2. Quadrados sombreados para valores acima de 0,05.....	110
Figura 5.7 – Resultados das análises de cluster para o Brasil utilizando as metodologias Kmeans (a), Xmeans (b) e Fuzzy C-means (c). Nomenclatura obtida pela mediana dos clusters utilizando os critérios mostrados na Tabela 5.3.....	111
Figura 5.8 – Heatmap com os resultados do Mann-Whitney teste para o Kmeans (esquerda acima), Xmeans (direita acima) e Fuzzy C-means (abaixo) utilizando 15 clusters. Quadrados sombreados para valores acima de 0,05	113
Figura 5.9 – Resultados das análises de cluster para o Brasil utilizando as metodologias Kmeans (a), Xmeans (b) e Fuzzy C-means (c) para 15 clusters. Nomenclatura obtida pela mediana dos clusters utilizando os critérios indicados na Tabela 5.3	114
Figura 5.10 – Variabilidade sazonal da precipitação acumulada (mm) nos 15 clusters obtidos pelas análises com o Kmeans. O padrão das cores e a nomenclatura seguem conforme descrito na Figura 5.9	119
Figura 5.11 – Variabilidade sazonal da temperatura (° C) nos 15 clusters obtidos pelas análises com o Kmeans. O padrão das cores e a nomenclatura seguem conforme descrito na Figura 5.9.....	121

Figura 5.12 – Variabilidade sazonal da radiação solar incidente na superfície (kJ m^{-2}) nos 15 clusters obtidos pelas análises com o Kmeans. O padrão das cores e a nomenclatura seguem conforme descrito na Figura 5.9.....	123
Figura 5.13 – Variabilidade sazonal da velocidade do vento (m s^{-1}) nos 15 clusters obtidos pelas análises com o Kmeans. O padrão das cores e a nomenclatura seguem conforme descrito na Figura 5.9	125
Figura 5.14 – Classificação climática obtida pelo Kmeans sobreposta com as rodovias federais - PNV (linhas vermelhas) – Preliminar	126
Figura 6.1 – <i>Layout</i> da pista experimental USP-FAPESP (1999 a 2001)	129
Figura 6.2 – Histórico de treinamento para modelo 1	132
Figura 6.3 – Comparação entre valores de treinamento e teste com coeficiente de determinação, para modelo 1	132
Figura 6.4 – Histórico de treinamento para modelo 2	134
Figura 6.5 – Comparação entre valores de treinamento e teste com coeficiente de determinação, para modelo 2	134
Figura 6.6 – Histórico de treinamento para modelo 3	136
Figura 6.7 – Comparação entre valores de treinamento e teste com coeficiente de determinação, para modelo 3	136
Figura 6.8 – Histórico de treinamento para modelo 4	137
Figura 6.9 – Comparação entre valores de treinamento e teste com coeficiente de determinação, para modelo 4	138
Figura 6.10 – Modelo de referência desenvolvido no Brasil para o ano cheio e combinações de estações climáticas (Balbo e Sevari, 2022)	140
Figura 6.11 – Histórico de treinamento do modelo 5	142
Figura 6.12 – Comparação entre valores de treinamento e teste com coeficiente de determinação. Resultados para modelo 5	142
Figura 6.13 – Valores de DT_{\max} preditos a partir dos valores estimados de temperatura máxima de topo (TT_{\max_pred})	143
Figura 6.14 – Histórico de treinamento do modelo 6	144
Figura 6.15 – Comparação entre valores de treinamento e teste	144
Figura 6.16 – Histórico de treinamento do modelo 7 para métrica MSE	145
Figura 6.17 – Comparação entre valores reais e preditos na etapa de teste (modelo 7)	145

Figura 6.18 – Evolução do erro de treinamento e teste para as métricas <i>MSE</i>	147
Figura 6.19 – Comparação entre valores reais x preditos para	148
etapa de teste – modelo 8	148
Figura 6.20 – Erro de treinamento e teste do modelo 9 para a métrica <i>MSE</i>	149
Figura 6.21 – Comparação entre valores reais versus preditos para etapa de teste.....	149
Figura 6.22 – Tensões (nas direções y e x, em MPa × 10) e deflexões (em cm)	153
Figura 6.23 – Representação esquemática de uma arquitetura padrão de CNN, incluindo camadas convolucionais, funções de ativação, camadas de <i>pooling</i> e camadas totalmente conectadas	156
Figura 6.24 – Exemplos de mapas de características obtidos de amostras do planejamento	157
Figura 6.25 – Convergência da função de perda <i>MSE</i> durante o treinamento e o teste para a tensão máxima nas direções (a) x e (b) y	159
Figura 6.26 – Respostas previstas versus observadas para os conjuntos de treinamento e teste, para (a) tensão máxima na direção x, (b) tensão máxima na direção y e (c) deflexão máxima	160
Tabela AP 1 – Condições de contorno para os casos indicados nas imagens do Apêndice 1	162

LISTA DE TABELAS

Tabela 2.1 – Valores de LTE assumidos para diferentes tipos de base	34
Tabela 2.2 – Coeficientes de calibração para o modelo de previsão de escalonamento de juntas de PCS.....	43
Tabela 2.3 – Resumo dos dados meteorológicos para os estados do sul dos EUA	45
Tabela 2.4 – Resumo das condições climáticas das regiões brasileira	47
Tabela 2.5 – Associações entre Climas Brasileiros (regiões) e nos EUA (estados).....	51
Tabela 3.1 – Características (principais) do software ISLAB	57
Tabela 3.2 – Parâmetros de geometria e materiais	62
Tabela 3.3 – Parâmetros das juntas transversais e longitudinais	63
Tabela 3.4 – Parâmetros de temperatura e carga.....	64
Tabela 3.5 – Casos avaliados por modelagem FEM-2D.....	65
Tabela 3.6 – Porcentagem de variação do esforço máximo segundo variação de carga ..	81
Tabela 3.7 – Porcentagem de variação do esforço máximo segundo variação de espessura	82
Tabela 3.8 – Porcentagem de variação do esforço máximo segundo variação de ΔT	82
Tabela 3.9 – Porcentagem de variação do esforço máximo segundo variação de módulo de elasticidade.....	83
Tabela 3.10 – Porcentagem de variação do esforço máximo segundo variação de módulo de reação do subleito.....	84
Tabela 4.1 – Esforços máximos e deflexão obtidos em placa isolada	91
Tabela 5.1 – Conjunto de dados utilizados nas análises de cluster	95
Tabela 5.2 – Definição dos índices utilizados na avaliação dos resultados das análises de cluster	100
Tabela 5.3 – Critérios e definições da classificação de Köppen-Geiger	101
Tabela 5.4 – Variáveis utilizadas em cada teste nas análises de cluster	103
Tabela 5.5 – Variáveis utilizadas nas análises de cluster.....	108
Tabela 6.1 – Métricas para o modelo 1	132
Tabela 6.2 – Métricas para o modelo 2.....	135
Tabela 6.3 – Métricas para o modelo 3.....	136

Tabela 6.4 – Métricas para o modelo 4.....	138
Tabela 6.5 – Resultados de precisão para etapa de testes na previsão da temperatura máxima de topo (<i>melhor resultado em destaque</i>).....	139
Tabela 6.6 – Métricas de treinamento e teste para modelo 5	143
Tabela 6.7 – Resumo de desempenho do modelo 6 (treino/teste).....	144
Tabela 6.8 – Resultados de precisão dos modelos para previsão da temperatura máxima de topo (melhor resultado em destaque)	146
Tabela 6.9 – Resultados de precisão para etapa de testes na previsão do diferencial térmico máximo a partir dos dados climáticos (melhor resultado em destaque)	150
Tabela 6.10 – Intervalo de variação dos parâmetros de entrada para obtenção das respostas mecânicas da placa	153
Tabela 6.11 – Amostra de parâmetros de entrada e respostas mecânicas das placas obtidas por análise de elementos finitos em duas dimensões	154

SUMÁRIO

1	INTRODUÇÃO.....	15
2	ESTADO DA ARTE E PREMISSAS PARA OS EFEITOS DE ESCALONAMENTO EM JUNTAS TRANSVERSAIS DE PCS E WT	17
2.1	MODELOS DE PREVISÃO DE ESCALONAMENTO DE JUNTAS TRANSVERSAIS EM PCS	20
2.1.1	MODELO SHRP P-020 (MODELOS DA AASHTO 1993)	20
2.1.2	FHWA RPPR 1997.....	22
2.1.3	MODELO DA ACPA (1984)	24
2.1.4	MODELO FHWA NAPCOM (NATIONWIDE PAVEMENT COST MODEL).....	25
2.1.5	MODELO NCHRP 1-34	26
2.1.6	MODELO PAVESPEC 3.0	29
2.2	MODELAGEM DA LTE NAS JUNTAS TRANSVERSAIS	30
2.2.1	MODELO DO MEPDG – AASHTO (NCHRP, 2004)	31
2.2.2	CALIBRAÇÃO DO MODELO DE ESCALONAMENTO DO MEPDG	36
2.3	METODOLOGIA PARA CALIBRAÇÃO DO MODELO DE ESCALONAMENTO PARA O CLIMA BRASILEIRO	43
3.	MODELAGEM DE PAVIMENTOS DE CONCRETO – ANÁLISE POR ELEMENTOS FINITOS 2D	52
3.1	PROGRAMA DE MODELAGEM POR ELEMENTOS FINITOS ISLAB 2000.....	53
3.1.1	ASPECTOS BÁSICOS DO PROGRAMA ISLAB 2000	53
3.1.2	EVOLUÇÃO DO PROGRAMA ISLAB	56
3.2	METODOLOGIA PARA GERAÇÃO DO EXPERIMENTO FATORIAL 2D	59
3.2.1	CONDIÇÕES E PARÂMETROS DE MODELAGEM	59
3.2.2	RESULTADOS OBTIDOS	64
3.2.3	DISCUSSÃO SOBRE OS RESULTADOS.....	81
4.	COMPARAÇÃO PRELIMINAR DAS RESPOSTAS FEA 2D VERSUS FEA 3D ..	85
5.	IDENTIFICAÇÃO DE REGIÕES DE CLIMA HOMOGÊNEO NO BRASIL.....	92
5.1	CLASSIFICAÇÃO CLIMÁTICA.....	92
5.2	ANÁLISE DE CLUSTER	93
5.3	METODOLOGIA PARA CLUSTERIZAÇÃO	94
5.3.1	DADOS EMPREGADOS	94
5.3.2	METODOLOGIAS PARA ANÁLISE DE CLUSTER	97
5.3.3	NOMENCLATURA DOS CLUSTERS.....	100

5.4	RESULTADOS OBTIDOS PARA CLUSTERIZAÇÃO	102
5.4.1	ESTAÇÃO DE SUPERFÍCIE INMET	102
5.4.2	ERA5-LAND E MERGE.....	107
5.5	VARIABILIDADES SAZONAIS DOS CLUSTERS	116
6.	FASE INICIAL DE APRENDIZADO DE MÁQUINA: ESTUDOS METODOLÓGICOS E TESTES DE MODELOS.....	127
6.1	CONSIDERAÇÕES PRELIMINARES	127
6.2	ESTUDO DE CORRELAÇÃO ENTRE OS GRADIENTES TÉRMICOS OBSERVADOS EM PLACAS DE CONCRETO DE PISTA EXPERIMENTAL E AS CONDIÇÕES CLIMÁTICAS LOCAIS	128
6.2.1	PREVISÃO DA TEMPERATURA MÁXIMA DE TOPO EM FUNÇÃO DE VARIÁVEIS CLIMÁTICAS	129
6.2.2	PREVISÃO DO DIFERENCIAL TÉRMICO COMO FUNÇÃO DA TEMPERATURA MÁXIMA DE TOPO E CARACTERÍSTICAS DA PLACA DE CONCRETO.....	141
6.2.3	PREVISÃO DO DIFERENCIAL TÉRMICO EM FUNÇÃO DE VARIÁVEIS CLIMÁTICAS	146
6.2.4	EXPERIMENTOS ADICIONAIS PARA PREVISÃO DO DIFERENCIAL TÉRMICO EM FUNÇÃO DE VARIÁVEIS CLIMÁTICAS	149
6.3	TÉCNICAS DE FUSÃO DE DADOS E APRENDIZADO PROFUNDO PARA EXTRAÇÃO DE CARACTERÍSTICAS NO PROCEDIMENTO AVANÇADO DE DIMENSIONAMENTO DE PAVIMENTOS DE CONCRETO	151
6.3.1	PROJETO DE EXPERIMENTOS E SIMULAÇÃO POR FEA.....	152
6.3.2	CONJUNTO DE DADOS PARA MODELAGEM COM APRENDIZADO DE MÁQUINA.....	153
6.3.3	REDES NEURAIS CONVOLUCIONAIS.....	155
6.3.4	ABORDAGEM PROPOSTA: CRIAÇÃO DOS MAPAS DE CARACTERÍSTICAS	156
6.3.5	METODOLOGIA EMPREGADA - MODELO DE REGRESSÃO BASEADO EM CNN	158
6.4	RESULTADOS E DISCUSSÃO	158
6.5	CONSIDERAÇÕES FINAIS.....	161
	APÊNDICE A – CASOS DE SIMULAÇÕES 2D DE PCS: IMAGENS DE SAÍDA GERADAS PELO PROGRAMA ISLAB 2005	162
	APÊNDICE B – MODELAGEM DE PLACA ISOLADA: IMAGENS DE SAÍDA GERADO PELOS PROGRAMAS ISLAB 2005 E ABAQUS.....	209
	REFERÊNCIAS BIBLIOGRÁFICAS	213

1 INTRODUÇÃO

O presente Relatório de Pesquisa IPR RP 025 é referente ao projeto de pesquisa “PESQUISA E DESENVOLVIMENTO DE NORMAS E ESPECIFICAÇÕES TÉCNICAS PARA PROJETO ESTRUTURAL, MATERIAIS, EXECUÇÃO E CONTROLE DE OBRAS RODOVIÁRIAS COM PAVIMENTOS DE CONCRETO SIMPLES”, contratado pelo DNIT/MT e em execução pela Fundação para o Desenvolvimento Tecnológico da Engenharia.

Este IPR RP 025 intitula-se “Estado da arte e premissas para os efeitos de escalonamento por bombeamento a partir do método da AASHTO - Analogias com modelos de zonas climáticas não temperadas como Flórida e Sul da Califórnia”. Seu conteúdo abrange quatro aspectos dos estudos para desenvolvimento de método de projeto de PCS e WT, conforme contrato firmado entre as partes:

Apresentação do estado da arte sobre o desempenho de pavimentos de concreto (PCS e WT) no que tange ao desempenho das juntas transversais quanto ao escalonamento progressivo (formação de degraus) ao longo da operação rodoviária, considerados parâmetros climáticos, deformabilidade de camadas de apoio e aspectos energéticos, tendo como mote o fenômeno de bombeamento de finos de camadas inferiores para bases granulares e juntas serradas, com perda de volume no sistema de apoio, gerando estados de deformação não previstos por modelos teóricos adotados para análise mecanicista, revelando um aspecto empírico-observacional do desempenho desejado para essas estruturas.

Simulações de tensões e deformações (em duas dimensões, 2D, como modelo em estado plano de tensões) para um conjunto de casos típicos para pavimentos PCS e WT recém construídos, com a finalidade de forjar um banco de dados preliminar para testes de aprendizado de máquina para a modelagem de efeitos mecânicos devidos a cargas e temperaturas.

Simultaneamente, esse banco de dados servirá para ajustes e comparações, diga-se calibrações, na etapa sucessiva, quando se iniciam as análises com modelagem em três dimensões (3D), empregando modelos de sólidos elásticos em elementos finitos conectados, bem como sistemas de apoio (subleito e bases granulares) mais realísticos do que o modelo de líquido denso (para soluções 2D), empregando subleitos como meio elástico contínuo quando tensões de cisalhamento são relevantes para as análises.

Simulação preliminar em 3D empregando o programa ABAQUS, devidamente licenciado em meio ao segundo semestre de andamento do presente projeto, indicando comparações simples entre o modelo ISLAB 2005 e o ABAQUS, para alguns casos quando empregou-se parametrização idêntica para simulações 2D e 3D.

Apresentação dos estudos de fracionamento e definição de clusters climáticos para o território nacional, associando-os preliminarmente ao PNV do DNIT, para finalidades de definição de necessidades de dados de posicionamento geográfico de rodovias federais para associação precisa com as zonas climáticas definidas.

Estudo metodológico de aprendizado de máquina para a previsão de tensões e deformações em PCS e WT, com indicação das técnicas empregadas, a simulação dos dados criados a partir das análises em 2D, os resultados obtidos e conclusões para prosseguimento dos trabalhos na etapa sucessiva. Nesse caso são também apresentados os modelos de previsão de diferenciados térmicos em PCS e WT, empregando-se modelos de IA tendo como fonte de dados os estudos financiados pela FAPESP entre 1999 e 2001, que compreenderam instrumentação e coletas de dados em pista experimental com quinze seções diferenciadas de PCS em São Paulo, na Cidade Universitária Armando Sales de Oliveira. Discute-se então a necessidade de coleta de novos dados a partir de novos experimentos, apresentando-se a proposta de coleta imediata durante as próximas etapas desse projeto, embora fora do escopo original de trabalhos e atividades, sem ônus para o DNIT-IPR.

Os dois temas acima relacionados fazem parte da Meta 1 do projeto de pesquisa. Aborda-se também, em itens diferentes, de modo mais sumarizado, atividades que compõem o projeto como um todo e que já foram desenvolvidas, ao menos parcialmente, para o encaminhamento de metodologia nacional de dimensionamento de pavimentos de concreto simples e *whitetoppings*, conforme abaixo enumerados:

Modelagem preliminar de efeitos de cargas e ambientais sobre placas de concreto, empregando-se modelagem 2D por elementos finitos, de modo precedente ao emprego de modelagem 3D, para se verificar os efeitos de determinados parâmetros de projeto de modo preliminar;

Análises balizadoras sobre a aplicação de modelos de aprendizado de máquina no processo de estabelecimento do critério de dimensionamento estrutural do MEPDG (Mechanistic-Empirical Pavement Design Guide) da AASHTO.

São ainda apresentadas, de modo também sumarizado, as atividades desenvolvidas concernentes à Meta 2 que objetiva a atualização, complementação e eventual redação de novas normas técnicas relacionadas aos materiais, tecnologias de dosagem, execução e de controle tecnológico, empregado na pavimentação rígida rodoviária.

2 ESTADO DA ARTE E PREMISSAS PARA OS EFEITOS DE ESCALONAMENTO EM JUNTAS TRANSVERSAIS DE PCS E WT

O escalonamento de juntas consiste em um dos principais tipos de defeitos que influenciam a qualidade de rolamento e a serventia de pavimentos de concreto simples (PCS ou WT), sendo definido como o desnível entre juntas transversais entre placas de concreto adjacentes.

Deste modo, escalonamentos acentuados em PCS têm impactos significativos nos custos associados ao ciclo de vida dos pavimentos, com forte tendência de demanda por manutenção precoce, devido à perda de serventia e aumentos substanciais nos custos operacionais dos veículos. Além disso, impõe a sensação de péssima qualidade de rolamento para os usuários, o que por vezes é fonte de preconceitos de natureza prática sobre a solução de pavimentação em concreto.

A ocorrência de escalonamento em juntas de PCS está associada a deflexões excessivas nas bordas e nos cantos das placas, que sob ação de carga geram energia imposta sobre camadas inferiores que, quando saturadas, desenvolvem bombeamento de finos ascensional pelas juntas (inclusive pode ocorrer em juntas longitudinais em condições mais severas), gerando erosão de material mais fino em camadas inferiores (na região subjacente à área carregada), de modo que esses finos são paulatinamente depositados sobre as superfícies das placas nas proximidades de juntas. Notavelmente, um cenário óbvio de degradação.

Como por suposto, um método de projeto de pavimentos deve ter em conta todos os processos de dano estrutural, que possuem consequências funcionais percebidas pelos usuários. Esses processos de danificação devem ser racionalmente mitigados desde as análises iniciais de projetos de execução, buscando combinações de bases, juntas, dispositivos de drenagem superficiais e subsuperficiais, para o longo retardamento ou mesmo impedimento do desenvolvimento do fenômeno bem conhecido dos engenheiros geotécnicos.

A progressão do defeito é potencializada quando o pavimento apresenta, de forma combinada, baixa transferência de carga através das juntas (ou fissuras, nesse caso, não tratadas), solicitação de eixos de veículos de carga, umidade excessiva (água saturando matérias, dita água livre), nas camadas subjacentes, envidando erosão e bombeamento de finos do subleito e mesmo de camadas de base e de sub-base.

Por conseguinte, a progressão e a formação de desníveis (ditos degraus, no inglês usa-se *faulting*) em juntas transversais se estabelecem se as seguintes condições forem satisfeitas:

- Ocorrência de deflexões diferenciais significativas entre placas sucessivas, que transferem energia aos materiais das camadas inferiores, causando movimentações do material saturado abaixo da placa, culminando no bombeamento ascensional com conseguinte erosão de camadas subjacentes às placas.
- Presença de materiais erodíveis nas camadas de base, sub-base e subleito, como bases granulares não estabilizadas com elevados percentuais de finos, notórias candidatas a sofrerem erosão, mesmo com captação de águas subsuperficiais promovida em projeto e obra.
- Presença de água livre na estrutura do pavimento (em geral por impedimento de vazão após eventos climáticos ou mesmo por ausência de drenagem, incluindo negligência em fase de projeto) levando à saturação dos materiais subjacentes na interface placa/base ou base tratada/subleito, fornecendo o meio para o bombeamento.

Cabe salientar que o fenômeno do bombeamento de finos se estabelece quando as camadas inferiores se encontram saturadas, seja por drenagem ineficiente ou pela infiltração de água pelas juntas e eventuais fissuras no concreto do PCS, de tal sorte que, quando a estrutura é solicitada pelas cargas do tráfego em tais condições, conforme a carga se aproxima da junta, a placa se desloca verticalmente, causando a remoção de água e finos por poro-pressão (ou pressão neutra).

A solicitação cíclica dos eixos dos veículos de carga leva a um acúmulo de material fino solto (inconsolidado) sob a placa descarregada, que a eleva na junta ou trinca, concomitantemente ao rebaixamento da placa carregada, culminando em uma diferença de nível ao longo da junta (ou trinca), ou seja, no escalonamento. Além disso, a erosão sob a placa de concreto causa o descalçamento junto a bordas e cantos, promovendo a ocorrência de momento fletores excessivos no topo das placas nessas áreas próximas às juntas, causando quebra, e por conseguinte, a peça sem apoio é assentada pelas cargas muito brevemente. Geram-se assim degraus pelas alterações volumétricas no apoio de placas: por excesso ou por redução.

As pistas experimentais da AASHTO *Road Test* contribuíram sobremaneira para elucidar a simbiose entre o fenômeno do bombeamento e escalonamento de juntas transversais em PCS, observando-se que as seções apresentando valores de serventia (*Present Serviceability Index – PSI*) de 1,51, após milhares de solicitações de eixos, apresentavam intenso bombeamento de finos. Essa constatação levou os engenheiros do grande experimento rodoviário a assumir que o bombeamento de finos poderia ser minimizado se a base ou sub-base fosse estabilizada e, portanto, resistente à erosão, ou ainda, que a

¹ PSI (VSA) = 1,5 denotava o fim do limite de trafegabilidade estabelecido, apresentando péssimas condições de rolamento.

água que infiltrou na estrutura fosse rapidamente drenada da estrutura (drenagem subsuperficial muito eficiente²). Não obstante, nem sempre a estabilização de materiais granulares previne o bombeamento, uma vez que o fenômeno pode se manifestar abaixo da base estabilizada assentada sobre um subleito suscetível à umidade. Além do que a umidade e saturação do subleito pode ocorrer em razão de infiltração ascensional ou lateral, conforme a região, os tipos de fundações e o regime climático local. Evidentemente, no caso brasileiro, descarta-se os fenômenos de gelo no final do outono e degelo na primavera.

Resultados de estudos em campo realizados no Chile, na década de 1980, mostraram que a redução do suporte das camadas inferiores, associada ao empenamento da placa na junta ou em fissuras, aumenta a poro-pressão interna e o bombeamento de finos, em decorrência das maiores deflexões observadas. Ademais, no verão, o risco de escalonamento é reduzido, uma vez que as juntas se encontram mais fechadas devido à expansão térmica da placa e maior transferência de carga entre elas³. Por outro lado, o escalonamento em juntas tende a se acentuar em dias mais frios, quando as juntas estão mais abertas e, principalmente na presença de elevados teores de umidade nas camadas inferiores do pavimento (típico em climas temperados).

Por fim, quanto maior a diferença entre deflexões em bordas de placa carregada e descarregada sucessivas, devido à baixa ou inexistente capacidade de transferência de carga entre juntas transversais (ou mesmo em fissuras), mais intenso será o bombeamento de finos e o escalonamento.

Dentre os escassos modelos de previsão de escalonamento de juntas transversais de PCS disponíveis e retratados na literatura técnica internacional, a seguir são apresentados aqueles abordados durante os estudos desenvolvidos no projeto NCHRP 1-37A - *Guide for Mechanistic-Empirical Design of New and Rehabilitated Pavement Structures* (NCHRP, 2004) - que balizou o desenvolvimento do *Mechanistic-Empirical Pavement Design Guide* (MEPDG) da AASHTO.

² Note-se aqui que existe uma dicotomia entre o emprego de bases estabilizadas, com asfalto ou ligante hidráulico, no que tange à drenagem subsuperficial. De fato, tais bases funcionam efetivamente e eficientemente como barreira para a percolação de águas pluviais para o subleito, ao passo que, nessas bases, águas infiltradas por juntas e fissuras tendem a se acumular nas interfaces placa de concreto/base, gerando outros tipos de defeitos por ocorrência de poro-pressão, como a ruptura de matérias nessa zona de transição. Isso mobiliza na grande maioria dos casos o emprego de bases granulares muito bem graduadas e compactadas, com sistema de coleta de umidade percolada em drenos inseridos nessas camadas, o que as demais não permitem. Não parece muito lógico o encaixe de sistema subsuperficial de coleta de águas sob as bases impermeáveis.

³ Observar que o verão no Chile é bastante variável em termos atmosféricos, de norte a sul, não sendo diretamente comparável aos climas típicos costeiros, centrais, áridos ou equatoriais prevalentes no Brasil.

2.1 MODELOS DE PREVISÃO DE ESCALONAMENTO DE JUNTAS TRANSVERSAIS EM PCS

2.1.1 Modelo SHRP P-020 (Modelos da AASHTO 1993)

Durante os primeiros estudos a partir de dados do *Long Term Pavement Performance* (LTPP) realizados na década de 1990 durante o programa SHRP⁴ (*Strategic Highway Research Project*), foram desenvolvidos dois modelos para a previsão de escalonamento de juntas de PCS, sendo um deles para pavimentos com barras de transferência de carga (BT) e o outro no caso de PCS sem barras de transferência de cargas em juntas transversais. Esses modelos são aqueles empregados no guia de projeto de pavimentos da AASHTO de 1993.

O modelo para o caso de PCS com barras de transferência de carga é dado pelo seguinte equacionamento de natureza empírica:

$$FAULTD = CESAL^{0,25} \cdot \left[0,0238 + 0,0006 \cdot \left(\frac{JTSPACE}{10} \right)^2 + 0,0037 \cdot \left(\frac{100}{KSTATIC} \right)^2 + 0,0039 \cdot \left(\frac{AGE}{10} \right)^2 - 0,0037 \cdot EDGESUP - 0,0218 \cdot DOWELDIA \right]$$

(Equação 2.1)

Onde:

FAULTD é o escalonamento médio na junta transversal com barra de transferência – BT (em polegadas);

CESAL é o número de solicitações acumuladas do eixo padrão (80 kN) na faixa de tráfego de projeto (em milhões);

JTSPACE é o espaçamento médio das juntas transversais (em pés);

KSTATIC é o módulo de reação estático do subleito determinado por retroanálise (libra/força/polegada cúbica);

AGE é a idade do pavimento em anos decorridos após construção (anos);

EDGESUP é a amarração da borda longitudinal (valor 1 para acostamento de concreto; valor 0 para qualquer outro tipo de acostamento) – uma variável *dummy*;

DOWELDIA é o diâmetro das BT nas juntas (polegadas).

⁴ O Programa Estratégico de Pesquisa Rodoviária (SHRP) foi estabelecido em 1987 pela AASHTO para abordar questões críticas enfrentadas pelos sistemas rodoviários federais e estaduais nos EUA.

O modelo acima descrito foi obtido para uma amostra de tamanho $n = 595$, tendo-se obtido o coeficiente de regressão (R^2) de 0,534 e erro padrão estimado (SEE) de 0,028 in (0,7 mm). Observe-se que o modelo não explica cerca de 50 % das medidas verificadas em pista, tendo-se empregado técnicas estatísticas convencionais para sua elaboração.

Para o caso de PCS sem barras de transferência de carga em juntas transversais, o modelo preditivo resultou:

$$FAULTND = CESAL^{0,25} \cdot \left[-0,07575 + 0,0251 \cdot \sqrt{AGE} + 0,0013 \cdot \left(\frac{PRECIP}{10} \right)^2 + 0,0012 \cdot \left(FI \cdot \frac{PRECIP}{1000} \right) - 0,0378 \cdot DRAIN \right] \quad (\text{Equação 2.2})$$

Onde:

FAULTND é o escalonamento médio na junta transversal sem BT (polegadas);

CESAL é o número de solicitações acumuladas do eixo padrão (80 kN) na faixa de tráfego (milhões);

PRECIP é a precipitação média anual (polegadas);

FI é o índice de congelamento médio (°F x dia);

AGE é a idade do pavimento em anos decorridos após construção (anos);

DRAIN é o tipo de drenagem (1 para existência de drenos subsuperficiais longitudinais; 0 para outros tipos).

Este modelo foi desenvolvido para $n = 25$ com $R^2 = 0,550$ e $SEE = 0,047$ in (1,2 mm). Observe-se que a precipitação média anual se tornou parâmetro relevante para o modelo bem como a existência de drenos longitudinais sob os pavimentos, o que não afetou de modo explícito o modelo de desempenho para pavimentos com BT. É também um modelo preditivo limitado por não se ajustar a cerca de 50 % das observações em pistas reais como fontes de dados.

A partir dos modelos acima descritos observa-se que ambos são definidos em função do tráfego da idade do pavimento, a despeito de outras variáveis, indicando a tendência de modelos sem BT desenvolverem maiores desníveis entre as placas do que nas seções com a presença de BT.

⁵ Número de seções de rodovias em concreto analisadas em termos de dados monitorados ao longo dos anos.

Esse conhecimento, portanto, de natureza empírica, é insofismável. Além disso, é notável os baixos valores de coeficiente de correlação obtidos e erro padrão elevado em face ao universo amostral empregado para seu desenvolvimento.

2.1.2 FHWA RPPR 1997

Em 1997, a FHWA (*Federal Highway Administration*) desenvolveu outros dois modelos, igualmente para juntas com e sem BT, no âmbito do projeto FHWA RPPR liderado pelo Prof. Michael Darter e pelo então pesquisador Lev Khazanovich (YU *et al.*, 1998).

Para o caso do modelo preditivo de escalonamento de juntas para PCS com BT, chegou-se à função empírica:

$$FAULTD = CESAL^{0,25} \cdot [0,0628 - 0,0628 \cdot C_d + 0,3673 \cdot 10^{-8} \cdot BSTRESS^2 + 0,4116 \cdot 10^{-5} \cdot JTSPACE^2 + 0,7466 \cdot 10^{-9} \cdot FI^2 \cdot PRECIP^{0,5} - 0,009503 \cdot BASE - 0,01917 \cdot WIDENLANE + 0,0009217 \cdot AGE]$$

(Equação 2.3)

Onde:

C_d é o coeficiente de drenagem modificado da AASHTO⁶, calculado a partir de informações da base de dados;

$BSTRESS$ é a tensão cisalhante máxima de contato entre aço/concreto na BT (libra-força por polegada quadrada);

$BASE$ é o tipo de base (0 para base não estabilizada e 1 para base estabilizada);
 $WIDENLANE$ é a faixa de rolamento alargada (0 para faixa sem alargamento e 1 para faixa alargada).

$JTSPACE$ é o espaçamento médio das juntas transversais (em pés);

AGE é a idade do pavimento em anos decorridos após construção (anos);

FI é o índice de congelamento médio (°F x dia);

$PRECIP$ é a precipitação média anual (polegadas).

O modelo apresenta os seguintes parâmetros estatísticos de regressão: $n = 146$, $R^2 = 0,60$ e $SEE = 0,022$ in (0,56 mm). Uma significativa melhoria na função em relação ao modelo original da SHRP. Interessante notar que foi verificada redução no escalonamento para faixas de tráfego alargadas.

⁶ Ver Guia para Projeto de Pavimentos da AASHTO, edição de 1993.

Já para o caso de PCS sem BT nas juntas transversais, o modelo de predição de desempenho do escalonamento resultou:

$$FAULTND = CESAL^{0,25} \cdot \left[0,2347 - 0,1516 \cdot C_d - 0,00025 \cdot \frac{h_{PCC}^2}{JTSPACE} - 0,0115 \cdot \right. \\ \left. BASE + 0,7784 \cdot 10^{-7} \cdot FI^{1,5} \cdot PRECIP^{0,25} - 0,002478 \cdot DAYS90^{0,5} - 0,0415 \cdot \right. \\ \left. WIDENLANE \right]$$

(Equação 2.4)

Onde:

h_{PCC} é a espessura da placa de concreto (polegadas);

$DAYS90$ é a média anual de dias quentes (dias com a temperatura máxima superior a 32 °C).

Os demais parâmetros no modelo acima possuem os mesmos significados e unidades de medida já apontados nos modelos anteriores. Os parâmetros estatísticos de regressão, nesse caso, resultaram em: $n = 131$; $R^2 = 0,45$; $SEE = 0,034$ in (0,86 mm).

Tal qual o modelo da AASHTO de 1993, esses modelos apresentaram baixos coeficientes de correlação, a despeito do maior número de amostras envolvidas na modelagem⁷. Além disso, destaca-se a consideração como variável da presença ou não de faixa alargada na previsão do escalonamento. O modelo sugere que PCS com faixa alargada apresentam menores desníveis médios entre as juntas do que pavimentos sem faixa alargada, o que é intuitivo tendo em vista que ao se aumentar a largura da faixa, se reduz o risco de solitação crítica nos cantos das placas.

Observa-se também que, como nos modelos SHRP, os modelos FHWA não apresentam a espessura da placa de concreto como parâmetro representativo para o fenômeno. Assim tem-se o sentimento do abandono de considerações sobre intertravamento de agregados nas faces fissuradas em todos os quatro modelos acima apresentados.

⁷ Isso é um sinal da grande variabilidade observada nas seções experimentais e de que possam existir outros aspectos que condicionam o comportamento dos pavimentos que não está contemplado nos modelos. Aqui, evidentemente, suspeita-se da ausência de características relacionadas aos subleitos, bem como os diversos tipos de bases granulares, com distribuição granulométrica e natureza genética inexoravelmente distintas. Os modelos empíricos, de maneira geral, têm por regra não contemplar diversos aspectos de difícil caracterização dos fenômenos envolvidos.

2.1.3 Modelo da ACPA (1984)

Em 1984 a *American Portland Cement Association* (ACPA) publicou dois modelos empírico-mecanicistas para predição do escalonamento em juntas de PCS, providas ou não de BT, a partir de estudos originalmente desenvolvidos pela *Portland Cement Association* (PCA). Esses modelos consideram a erodibilidade do material da base/subleito como o principal fator determinante para o escalonamento, e calculam o percentual de dano por erosão no canto de uma placa a partir do conceito de dano cumulativo linear de Palmgren-Miner, conforme a equação:

$$EROSION = 100 \sum \frac{C_2 \cdot n_i}{N_i} \quad (\text{Equação 2.5})$$

Onde:

EROSION é o dano percentual por erosão;

n_i é o número real de solicitações de carga de cada grupo de eixo i ;

N_i é o número de repetições de carga disponíveis (toleráveis) para o grupo de eixo i ;

$C_2 = 0,06$ para pavimentos sem acostamento de concreto (asfálticos, granulares ou inexistentes) e $0,94$ para pavimentos com acostamento de concreto (amarrados com barras de ligação).

O número N de solicitações disponíveis para cada eixo é calculado pela seguinte relação de potência:

$$\log N = 14,524 - 6,777 \cdot (C_1 \cdot P - 9,0)^{0,103} \quad (\text{Equação 2.6})$$

Onde:

P é a taxa de realização de trabalho de cada passagem de eixo no canto da placa;

$$C_1 = 1 - \left(\frac{KSTATIC}{200} \cdot \frac{4}{h_{PCC}} \right)^2; \quad (\text{Equação 2.7})$$

$$P = \frac{268,7 \cdot p^2}{h_{PCC}/KSTATIC^{0,73}} \quad (\text{Equação 2.8})$$

Sendo:

$KSTATIC$ é o módulo de reação do subleito (libra-força por polegada cúbica);

h_{PCC} é a espessura da placa (polegadas);

p é a pressão na interface entre placa-fundação (libra-força por polegada quadrada).

Deste modo, os modelos finais de escalonamento em juntas de PCS, providas ou não de BT, são dados pelas seguintes e respectivas equações:

$$FAULTD = EROSION^{0,25} \cdot \left[0,0038332 \cdot \left(\frac{PRECIP}{10} \right)^{1,84121} + 0,0057763 \cdot JSPACE^{0,38274} \right] \quad (\text{Equação 2.9})$$

$$FAULTND = EROSION^{0,25} \cdot [9,75873 \cdot 10^{-4} \cdot PRECIP^{0,91907} + 0,0060291 \cdot JSPACE^{0,54428} - 0,016799 \cdot DRAIN] \quad (\text{Equação 2.10})$$

Onde:

FAULTD é o escalonamento médio de juntas transversais com BT (polegadas);

FAULTND é o escalonamento médio de juntas transversais sem BT (polegadas);

EROSION é a erosão acumulada calculada (%);

PRECIP é a precipitação anual (polegadas);

JTSPACE é o espaçamento médio entre juntas transversais (pés);

DRAIN é a variável *dummy* quanto à existência de drenos nas bordas (1 para drenos presentes; 0 para inexistência de drenos).

2.1.4 Modelo FHWA NAPCOM (*Nationwide Pavement Cost Model*)

Em 1997, a FHWA desenvolveu um novo modelo com abordagem empírico-mecanicista para previsão do escalonamento em PCS, que foi posteriormente recalibrado, em 1999, com dados do LTPP, resultando na seguinte equação:

$$FAULT = DAMAGE^{0,3} \cdot [0,05 + 0,00004 \cdot WETDAYS - 0,0024 \cdot DOWDIA - 0,025 \cdot C_d \cdot (0,5 + BASE)] \quad (\text{Equação 2.11})$$

Onde:

FAULT é o escalonamento médio nas juntas (polegadas);

$DAMAGE = n/N$;

n é o número de solicitações reais acumuladas do eixo-padrão (80 kN);

N é o número de aplicações de carga disponíveis (toleráveis) do eixo-padrão;

Cd é o coeficiente de drenagem da AASHTO;

$BASE$ é o tipo de base (0 para base erodível; 1 para base não erodível);

$WETDAYS$ é o número médio de dias chuvosos em base anual;

$DOWDIA$ é o diâmetro das BT (polegadas).

Os parâmetros estatísticos observados nos cálculos foram: $n = 120$; $R^2 = 0,56$; $SEE = 0,03$ in (0,8 mm). Observa-se, por tanto, que o grau de confiança na aplicação do novo modelo não se alterou em relação aos modelos anteriormente desenvolvidos. O viés mecanicista do método consiste na determinação de N em função das tensões críticas de projeto par dimensionamento à fadiga do concreto.

O número de aplicações de carga disponíveis para um dado eixo carregado é determinado pela equação:

$$\log N = 4,27 - 1,6 \cdot \log(DE - 0,002) \quad (\text{Equação 2.12})$$

Sendo DE o diferencial da densidade de energia elástica do subleito.

Esse modelo ilustra que a presença de BT nas juntas transversais reduz significativamente o escalonamento pela redução do diferencial da densidade da energia de deformação do subleito, como os demais modelos já prediziam, em consonância com o conhecimento a partir da observação em décadas.

2.1.5 Modelo NCHRP 1-34

O modelo com ampla amostragem veio a ser desenvolvido em finais da década de 1990 no âmbito do programa do *National Cooperative Highway Research Project* (YU *et al.*, 1998).

$$\text{FAULT} = \text{DAMAGE}^{0,2475} \cdot [0,2405 - 0,00118 \cdot \text{DAYS90} + 0,001216 \cdot \text{WETDAYS} - 0,04336 \cdot \text{BASETYPE} - (0,004336 + 0,007059 \cdot (1 - \text{DOWEL})) \cdot \text{LCB}] \quad (\text{Equação 2.13})$$

No qual:

$BASETYPE$ é o tipo de base (0 para base não estabilizada; 1 para base asfáltica (ATB), cimentada (CTB) ou concreto magro (LCB));

LCB é a variável *dummy* refletindo a presença de base de concreto magro (1 se LCB está presente; 0 se não há LCB);

DAYS90 é o número de dias por ano com temperatura máxima superior a 32 °C (90 °F);

WETDAYS é a média de dias chuvosos em período anual;

DOWEL é a variável *dummy* indicativa da presença de BT (1 se presente; 0 se ausente);

DAMAGE = n/N ;

n é o número de solicitações reais acumuladas do eixo-padrão (80 kN);

N é o número de aplicações de carga disponíveis (toleráveis) do eixo-padrão.

Neste caso os estudos envolveram amostragem de 391 seções, resultando nos parâmetros estatísticos $R^2 = 0,50$ e $SSE = 0,035$ in (0,89 mm). Novamente, sem melhorias aparentes no grau de previsibilidade do desempenho.

O número N de solicitações do eixo-padrão é calculado conforme a seguinte equação:

$$\log N = 0,785983 - 0,92991 \cdot (1 + 0,40 \cdot \text{PERM} \cdot (1 - \text{DOWEL})) \cdot \log DE$$

(Equação 2.14)

Na qual:

PERM é a permeabilidade da base (0 para base não permeável – tratadas -; 1 para base permeável – granulares -);

DE é o diferencial da densidade de energia no canto da placa.

O diferencial da densidade de energia (*DE*) no canto é definido como a diferença na energia de deformação elástica sob a placa carregada e a placa descarregada (diferencial de deformação), e é considerada o principal parâmetro mecanicista que governa a progressão do escalonamento de juntas. A relação entre a densidade da energia de deformação do subleito elástico, as deflexões na placa de concreto e o módulo de reação do subleito, é dada por:

$$E = \frac{k \cdot \delta^2}{2} \quad \text{(Equação 2.15)}$$

Sendo E a densidade da deformação elástica (energia de deformação do subleito de uma área unitária do subleito), δ a deflexão e k o módulo de reação (estático) do subleito.

Por definição tem-se que:

$$DE = E_L - E_{UL} = \frac{k \cdot \delta_L^2}{2} - \frac{k \cdot \delta_{UL}^2}{2} \quad (\text{Equação 2.16})$$

$$DE = \frac{k}{2} \cdot (\delta_L - \delta_{UL}) \cdot (\delta_L + \delta_{UL}) \quad (\text{Equação 2.17})$$

O termo $(\delta_L + \delta_{UL}) - L$ significa *loaded* e *UL* significa *unloaded* – é igual à deflexão no canto e representa a flexibilidade total da placa. Quanto maior a flexibilidade da placa, maior *DE* e o potencial de evolução do escalonamento. Já o termo $(\delta_L - \delta_{UL})$ é a diferença de deflexão no canto entre as placas carregada e descarregada e representa o movimento relativo entre ambas. Quanto maior a diferença de deflexões, maior o escalonamento das juntas ou fissuras. Assim, o diferencial de deflexões no canto depende da LTE no canto livre.

Como a eficiência de transferência de carga (*Load Transfer Efficiency*) é dada pela relação entre a deflexão na placa descarregada e a placa carregada, tem-se:

$$LTE = \frac{\delta_{UL}}{\delta_L} \cdot 100 \% \quad (\text{Equação 2.18})$$

$$DE = \frac{k}{2} \cdot (\delta_L + \delta_{UL}) \cdot \left[\frac{1 - \frac{LTE}{100}}{1 + \frac{LTE}{100}} \right] \quad (\text{Equação 2.19})$$

Pela equação acima observa-se que a LTE tem influência significativa no diferencial da densidade da energia de deformação do subleito. Além disso, outro parâmetro muito significativo no cômputo de *DE* é o fator não-dimensional da rigidez do intertravamento dos agregados (*AGG**), calculado conforme a equação a seguir:

$$Agg^* = \left(\frac{Agg}{k\ell} \right) = 2,3 \exp \left(1 - 1,987 \cdot \frac{JTSPACE}{\ell} + 3,48 \cdot DOWELDIA^{3,56} \right) \quad (\text{Equação 2.20})$$

Onde:

Agg é a rigidez da transferência de carga para os agregados (libra-força por polegada quadrada);

k é o módulo de reação do subleito dinâmico (libra-força por polegada cúbica);

ℓ é o raio de rigidez relativa da placa de concreto (polegadas) dado por:

$$\ell = \sqrt[4]{\frac{E_{PCC} \cdot h_{PCC}^3}{12 \cdot (1 - \mu^2) \cdot k}} \quad (\text{Equação 2.21})$$

Sendo:

E_{PCC} o módulo de elasticidade do concreto (libra-força por polegada quadrada);

h_{PCC} a espessura da placa de concreto (polegadas);

μ o coeficiente de Poisson do concreto;

$JTSPACE$ o espaçamento entre as juntas transversais (pés);

$DOWELDIA$ o diâmetro das barras de transferência (polegadas).

2.1.6 Modelo PAVESPEC 3.0

Esse modelo foi desenvolvido a partir da recalibração do modelo desenvolvido no projeto NCHRP 1-34, que resultou na seguinte equação:

$$FAULT = DAMAGE^{0,275} \cdot [0,1741 - 0,0009911 \cdot DAYS90 + 0,001082 \cdot PRECIP] \quad (\text{Equação 2.22})$$

Sendo:

$FAULT$ o escalonamento médio das placas de concreto (polegadas);

$DAMAGE = n/N$;

$DAYS90$ o número de dias por ano com temperatura máxima superior a 32 °C (90 °F);

$PRECIP$ a precipitação média anual (polegadas).

O modelo empregou o maior número de seções amostrais dentre todos anteriormente apresentados, num total de $n = 511$, resultando a modelagem estatística em $R^2 = 0,56$ e $SEE = 0,029$ in (0,74 mm).

O número (N) de solicitações disponíveis (toleráveis) para o eixo-padrão é calculado pela equação:

$$\log N = 0,785983 - \log EROD - 0,92991 \cdot (1 + 0,40 \cdot PERM \cdot (1 - DOWEL)) \cdot \log(DE \cdot (1 - 1,432 \cdot DOWELDIA + 0,513 \cdot DOWELDIA^2)) \quad (\text{Equação 2.23})$$

Onde:

EROD é o fator de erodibilidade da base (entre 0,50 e 7,5, dependendo de seu tipo);

PERM é a permeabilidade da base (0 para base não permeável; 1 para base permeável);

DOWEL é a presença de BT (1 com BT; 0 sem BT);

DOWELDIA é o diâmetro da BT (máximo de 1,50 polegadas);

DE é o diferencial de densidade da energia de deformação no canto.

Para este modelo, a rigidez devido ao intertravamento dos agregados é dada pela equação:

$$Agg^* = \left(\frac{Agg}{k\ell} \right) = 2,3 \exp \left(1 - 1,987 \cdot \frac{JTSPACE}{\ell} + 3,48 \cdot DOWELDIA^{2,2} \right)$$

(Equação 2.24)

2.2 MODELAGEM DA LTE NAS JUNTAS TRANSVERSAIS

A principal diferença entre o modelo PAVESPAC 3.0 e o modelo empregado no MEPDG de 2002 (NCHRP 1-34) é o fato de que o último considera o dano incremental na avaliação do desempenho global da estrutura. Assim, a deterioração da junta reduz a capacidade de transferência de carga de uma placa para outra (LTE), aumentando a magnitude da deflexão diferencial no canto da placa e, por conseguinte, aumentando a magnitude da diferença da densidade de energia de deformação elástica do subleito para o mesmo nível de tráfego.

Se uma placa apresenta LTE muito baixo, então a deflexão na placa descarregada é muito menor que a deflexão na junta da placa carregada, e a LTE é próxima de zero. Por outro lado, se a capacidade de transferência de carga é elevada, então as deflexões nas duas placas são similares, e assim o valor de LTE se aproxima de 100 %.

O processo de transferência de carga se desenvolve por meio da contribuição de três mecanismos de transferência, a saber:

- Transferência de carga pelo intertravamento dos agregados na face vertical fissurada na junta.
- Transferência de carga pelas barras de transferência (caso presentes).
- Transferência de carga pela base/subleito, em especial por bases tratadas.

2.2.1 Modelo do MEPDG – AASHTO (NCHRP, 2004)

Conforme mencionado acima, o modelo do MEPDG utiliza a abordagem do dano incremental acumulado mensalmente, de modo que os fatores (e parâmetros) mudam ao longo de todo o período do projeto, incluindo a transferência de carga, propriedades dos materiais⁸, condições climáticas sazonais, cargas do tráfego, condições de suporte do subleito, dentre outros.

Assim, cada incremento representa uma combinação específica de fatores precedentes ao longo de períodos distintos (estações). No modelo, a deterioração das juntas reduz a capacidade de transferência de carga (LTE) e aumenta a diferença de deflexões entre as placas carregada e descarregada, aumentando a magnitude do diferencial da energia de deformação do subleito.

O escalonamento mensal é calculado pela soma dos incrementos de todos os meses anteriores ao longo da vida de serviço da estrutura, a partir da exposição ao tráfego, conforme as seguintes equações:

$$Fault_m = \sum_{i=1}^m \Delta Fault_i \quad (\text{Equação 2.25})$$

$$\Delta Fault_i = C_{34} \cdot (FAULTMAX_{i-1} - Fault_{i-1})^2 \cdot DE \quad (\text{Equação 2.26})$$

$$FAULTMAX_i = FAULTMAX_0 + C_7 \cdot \sum_{j=1}^m DE_j \cdot \log(1 + C_5 \cdot 5,0^{EROD})^{C_6} \quad (\text{Equação 2.27})$$

$$FAULTMAX_0 = C_{12} \cdot \delta_{curling} \cdot \left[\log(1 + C_5 \cdot 5,0^{EROD}) \cdot \log\left(\frac{P_{200} \cdot WetDays}{p_s}\right) \right]^{C_6} \quad (\text{Equação 2.28})$$

Onde:

$Fault_m$ é o escalonamento médio ao final do mês m (polegadas);

$\Delta Fault_i$ é o incremento mensal do escalonamento médio durante o mês i (polegadas);

$FAULTMAX_i$ é o escalonamento médio máximo para o mês i (polegadas);

$FAULTMAX_0$ é o escalonamento máximo inicial da junta transversal (polegadas);

$EROD$ é o fator de erodibilidade da base/sub-base;

⁸ Isso implica em um processo complexo de conhecimento de desempenho ao longo do tempo no que tange, por exemplo: resistências e módulos de elasticidade do concreto; idem para bases tratadas; idem para fundações; juntas mais ou menos abertas em invernos e verões, respectivamente; etc.

DE_j é o diferencial da densidade de energia da deformação do subleito acumulada durante o mês i ;

$\delta_{curling}$ é a deflexão máxima mensal da placa de concreto devido ao empenamento (térmico);

p_s é a sobrecarga sobre o subleito (libras-força);

P_{200} é o percentual passante na peneira #200 (0,075 mm) do material constituinte do subleito;

$WetDays$ é a média de dias úmidos do ano (com índice pluviométrico maior do que 0,1 polegadas);

$C_{1,2,3,4,5,6,7,12,34}$ = constantes de calibração global do MEPDG.

$$C_{12} = C_1 + C_2 \cdot FR^{0,25} \quad (\text{Equação 2.29})$$

$$C_{34} = C_3 + C_4 \cdot FR^{0,25} \quad (\text{Equação 2.30})$$

Onde:

FR é o índice de congelamento da base definido como o percentual do tempo que a temperatura de topo da base encontra-se abaixo de 0 °C.

Para a análise do escalonamento, cada passagem de um eixo pode causar apenas uma ocorrência de carregamento crítico (i.e., quando DE atinge um valor máximo). Como o desenvolvimento do escalonamento é crítico à noite, quando a placa se encontra empenada para cima, as juntas estão com abertura maior e, conseqüentemente, a eficiência de transferência de carga é menor (apenas as repetições de carga aplicadas entre 20 h e 8 h são consideradas na análise).

Ainda, o diferencial térmico linear equivalente para o período noturno é determinado para cada mês como sendo a diferença média entre temperaturas de topo e de fundo da placa de concreto (entre 20 h e 8 h). Para cada mês do ano, o gradiente de temperatura equivalente é determinado pela equação:

$$\Delta T_m = \Delta T_{t,m} - \Delta T_{b,m} + \Delta T_{sh,m} + \Delta T_{PCW} \quad (\text{Equação 2.31})$$

Sendo ΔT_m a diferença de temperatura efetiva para o mês m , $\Delta T_{t,m}$ a temperatura média na superfície do concreto (entre 20 h e 8 h) para o mês m , $\Delta T_{b,m}$ a temperatura média no fundo da placa de concreto (entre 20 h e 8 h) para o mês m .

$\Delta T_{sh,m}$ a diferença de temperatura equivalente devido à retração reversível para o mês m para concreto com idade avançada, ou seja, após a retração estar completamente desenvolvida; e, finalmente, ΔT_{PCW} é a diferença de temperatura equivalente devido ao empenamento permanente (construtivo).

A temperatura na placa de concreto é determinada em 11 pontos uniformemente espaçados ao longo de sua espessura, para cada horário do dia, a partir dos dados climáticos disponíveis. Essas distribuições de temperatura são convertidas em diferenças de temperatura equivalente (linear) entre topo e fundo da placa.

As deflexões de canto para as placas são calculadas internamente no MEPDG com base em redes neurais desenvolvidas e implementadas no software para tais cálculos a partir de simulações com programa de elementos finitos.

O escalonamento máximo é ajustado a cada solicitação dos eixos rodoviários utilizando a energia diferencial acumulada ao longo do período anterior (energia diferencial acumulada das solicitações dos eixos para todos os meses). Para cada incremento, para cada tipo de eixo, as deflexões no canto das placas carregada e descarregada são calculadas internamente no programa por meio de redes neurais, conforme já comentado. O diferencial da energia de deformação do subleito (DE), tensão de cisalhamento no canto da placa (τ) e a tensão máxima de suporte da barra de transferência de carga (se presentes) são calculadas pelas seguintes equações:

$$DE = \frac{k}{2} \cdot (\delta_L^2 - \delta_{UL}^2) \quad \text{(Equação 2.32)}$$

$$\tau = \frac{Agg \cdot (\delta_L - \delta_{UL})}{h_{PCC}} \quad \text{(Equação 2.32)}$$

$$\sigma_b = \frac{\zeta_d \cdot (\delta_L - \delta_{UL})}{d \cdot dsp} \quad \text{(Equação 2.34)}$$

Onde:

DE é o diferencial da energia de deformação do subleito (libra-força por polegada);

δ_L é a deflexão de canto da placa carregada (polegadas);

δ_{UL} é a deflexão de canto da placa descarregada (polegadas);

Agg é o fator de rigidez devido ao intertravamento dos agregados;

k é o módulo de reação do subleito (libra-força por polegadas cúbicas);

h_{PCC} é a espessura da placa de concreto (polegadas);

ζ_d é o fator de rigidez da barra de transferência de carga = $J_d \cdot k \cdot l \cdot dsp$;

d é o diâmetro da barra de transferência (polegadas);

dsp é o espaçamento das barras de transferência (polegadas);

J_d é a rigidez não-dimensional da barra de transferência no momento da aplicação de carga;

ℓ é o raio de rigidez relativa da placa de concreto (polegadas).

A magnitude das deflexões na proximidade da junta transversal é muito influenciada pela LTE na junta. A LTE oferecida pelo conjunto base/subleito é definida em função do tipo de base, conforme apresentado na Tabela 2.1.

Tabela 2.1 – Valores de LTE assumidos para diferentes tipos de base

Tipo de base	LTE _{base}
Base granular	20 %
Base estabilizada (asfáltica e cimentada)	30 %
Concreto compactado com rolo (CCR)	40 %

Nota: base asfáltica = base estabilizada com emulsão asfáltica, RAP espumado, etc.;
base cimentada = solo cimento, solo-brita cimento, brita graduada tratada com cimento etc

Para finalidades de avaliar a LTE inicial são calculadas as parcelas de contribuição dos três mecanismos envolvidos - intertravamento dos agregados, barras de transferência de carga e contribuição da camada de base/subleito -, conforme se segue.

$$LTE_{junta} = 100 \cdot \left(1 - \left(1 - \frac{LTE_{BT}}{100} \right) \cdot \left(1 - \frac{LTE_{agreg}}{100} \right) \cdot \left(1 - \frac{LTE_{base}}{100} \right) \right)$$

(Equação 2.35)

Onde:

LTE_{junta} = LTE total na junta transversal (%);

LTE_{BT} = LTE da junta se o as barras de transferência são o único mecanismo de transferência de carga;

LTE_{agreg} = LTE da junta se o intertravamento dos agregados é o único mecanismo de transferência;

LTE_{base} = LTE da junta se a base é o único mecanismo de transferência de carga.

A perda da capacidade de cisalhamento (Δs) devido às aplicações repetidas de cargas de roda é caracterizada em termos da abertura da junta transversal, tendo por base em uma função derivada da análise de dados de ensaios de transferência de carga desenvolvida pela *Portland Cement Association* (PCA), conforme os modelos abaixo:

$$\Delta s = \begin{cases} 0 & \text{se } w < 0,001 \cdot h_{PCC} \\ \sum \frac{0,005}{1,0+(j_w/h_{PCC})^{-5,7}} \cdot \left(\frac{n_j}{10^6}\right) \cdot \left(\frac{\tau_j}{\tau_{ref}}\right) & \text{se } j_w < 3,8 \cdot h_{PCC} \\ \sum \frac{0,068}{1,0+6 \cdot (j_w/h_{PCC}-3)^{-1,98}} \cdot \left(\frac{n_j}{10^6}\right) \cdot \left(\frac{\tau_j}{\tau_{ref}}\right) & \text{se } j_w > 3,8 \cdot h_{PCC} \end{cases} \quad \text{(Equação 2.36)}$$

Onde:

n_j é o número de aplicações e carga para o incremento atual, por grupo de carga;

w é a abertura da junta, milésimos de polegada (0,001 polegada, ou *mils*);

τ_j é a tensão de cisalhamento na fissura transversal proveniente do modelo de resposta para o grupo de carga;

τ_{ref} é a tensão de cisalhamento de referência dos resultados da PCA (libra-força por polegada quadrada), conforme se segue:

$$\tau_{ref} = 111,1 \cdot \exp\{-\exp[0,9988 \cdot \exp(-0,1089 \log J_{AGG})]\}$$

O dano nas barras de transferência é calculado conforme a seguinte equação:

$$DAM_{BT} = C_8 \sum \left(\frac{J_d \cdot (\delta_L - \delta_{UL}) \cdot dsp}{d \cdot f_c'} \right) \quad \text{(Equação 2.37)}$$

Onde:

DAM_{BT} é o dano na interface aço-concreto;

C_8 é o coeficiente igual a 400;

J_d é a rigidez não-dimensional da BT no momento da aplicação de carga;

δ_L é a deflexão no canto da placa carregada (polegadas);

δ_{UL} é a deflexão no canto da placa descarregada (polegadas);

dsp é o espaçamento entre BT adjacentes na trilha de roda (polegadas);

f_c' é a resistência à compressão do concreto (libra-força por polegada quadrada);

d é o diâmetro da BT (polegadas).

A Figura 2.1 ilustra um diagrama de fluxo para o processo de cálculo dos parâmetros envolvidos no modelo de previsão do escalonamento.

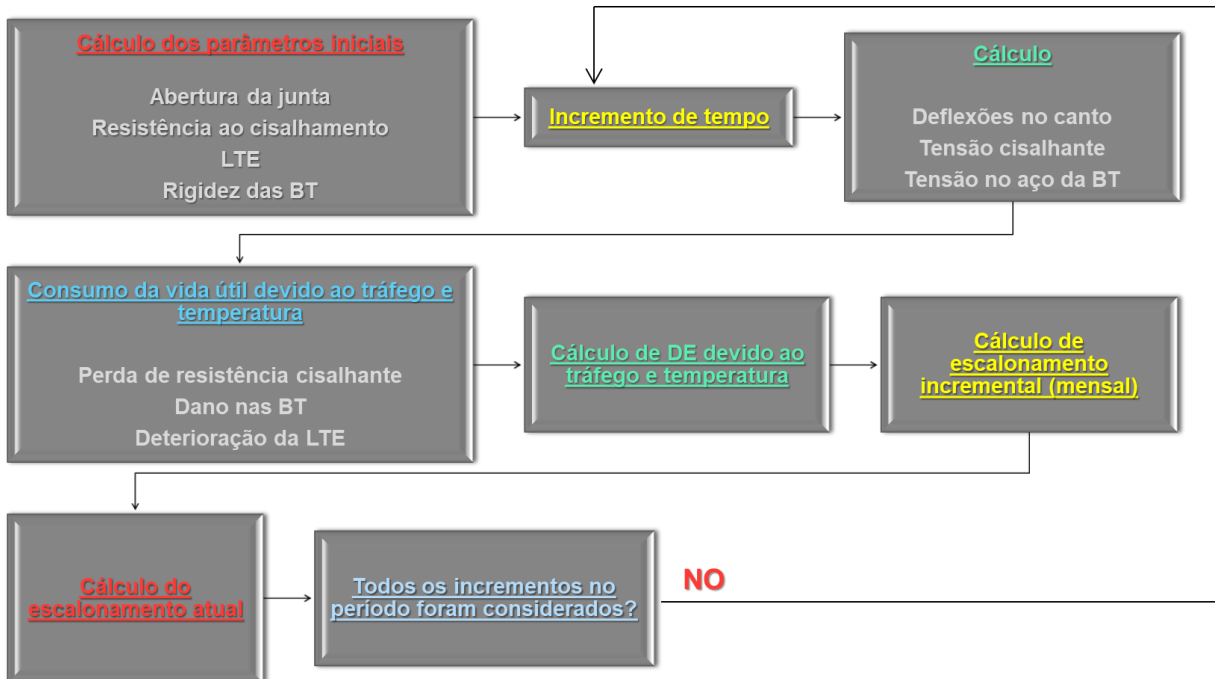


Figura 2.1. Fluxograma para processo de cálculo incremental do escalonamento de junta em PCS

Fonte: adaptado de NCHRP (2003)

2.2.2 Calibração do modelo de escalonamento do MEPDG

As equações do modelo de escalonamento de junta transversal de PCS apresentadas no MEPDG são resultado da calibração global realizada a partir do monitoramento de 248 seções de pavimentos de concreto localizadas em 22 estados estadunidenses, sendo 138 seções provenientes do programa LTPP e 110 seções do estudo da FHWA *Performance of Concrete Pavements* (Khazanovich, *et al.*, 2004; YU *et al.*, 1998).

O processo de calibração envolveu a determinação das constantes de calibração C_1 a C_7 , e a constante C_8 correspondentes à taxa de deterioração das BT, buscando a minimização da função erro:

$$ERR(C_1, C_2, \dots, C_8) = \sum_{ob=1}^{N_{ob}} (FaultPredicted_{ob} - FaultMeasured_{ob})^2 \quad (\text{Equação 2.38})$$

Onde:

ERR = função erro; C_1, C_2, \dots, C_8 = constantes de calibração;

$FaultPredicted_{ob}$ = escalonamento previsto para a observação (ob) na base de dados de calibração;

$FaultMeasured_{ob}$ = escalonamento medido para a observação (ob) na base de dados de calibração;

N_{ob} = número de observações na base de dados.

Para minimizar a função erro, as seguintes condições devem ser satisfeitas:

$$\frac{\partial ERR(C_1, C_2, \dots, C_8)}{\partial C_1} = 0 \quad (\text{Equação 2.39})$$

$$\frac{\partial ERR(C_1, C_2, \dots, C_8)}{\partial C_2} = 0 \quad (\text{Equação 2.40})$$

$$\frac{\partial ERR(C_1, C_2, \dots, C_8)}{\partial C_8} = 0 \quad (\text{Equação 2.41})$$

Para a calibração global do MEPDG, que envolveu 534 observações, foram obtidos os seguintes valores para as constantes de calibração, com $R^2 = 0,71$ e erro padrão estimado (SEE) de 0,0267 in (0,68 mm): $C_1 = 1,29$; $C_2 = 1,10$; $C_3 = 0,001725$; $C_4 = 0,0008$; $C_5 = 250$; $C_6 = 0,40$; $C_7 = 1,20$; $C_8 = 400$.

Khazanovich *et al.* (2004) realizaram uma análise de sensibilidade das variáveis críticas envolvidas no modelo buscando garantir que o escalonamento previsto resulta em valores de escalonamento coerentes, considerando uma ampla faixa de variação dos parâmetros de projeto, conforme ilustrado nas Figuras 2.2 a 2.8.




Figura 2.2. Efeito do diâmetro da barra no escalonamento previsto




Figura 2.3: Efeito da erodibilidade da base no escalonamento previsto para PCS sem BT




Figura 2.4: Efeito da erodibilidade da base no escalonamento previsto para PCS com BT (AC = concreto asfáltico)




Figura 2.5: Efeito do tipo de acostamento no escalonamento previsto para PCS sem BT




Figura 2.6 Efeito do tipo de acostamento no escalonamento previsto para PCS com BT




Figura 2.7 Efeito do espaçamento entre juntas (comprimento da placa) no escalonamento previsto para PCS sem BT




Figura 2.8. Efeito do espaçamento entre juntas (comprimento da placa) no escalonamento previsto para PCS com BT

Conclui-se, a partir dos resultados obtidos por Khazanovich *et al.* (2004) que:

- O modelo prevê a progressão do escalonamento com o tempo, ou seja, com o acúmulo do tráfego;
- O escalonamento é altamente sensível ao diâmetro das barras de transferência de cargas (BT) de modo que a escolha adequada do diâmetro das barras constitui, normalmente, a solução mais efetiva em termos de custo para controlar a formação de degraus nas juntas;
- O tratamento da base granular com teores adequados de agente estabilizante (asfalto, emulsão asfáltica, asfalto espumado, cimento) reduz o potencial de erosão, de modo que o desenvolvimento de menor grau de escalonamento é esperado se bases menos suscetíveis à erosão forem empregadas;
- A utilização de acostamentos de concreto, bem como a consideração do alargamento da faixa de rolamento, contribui para a minimização do escalonamento, especialmente no segundo caso, quando o aumento da largura da faixa afasta a carga de roda da junta longitudinal e do canto da placa;
- Em última análise, placas mais curtas (com até 3,6 m) resultam em abertura de juntas menores, de modo que o intertravamento dos agregados atua para manter elevados níveis de LTE, além de os efeitos do empenamento nas deflexões nos cantos serem menos pronunciados em placas com dimensões reduzidas.

Cabe destacar que a confiabilidade é um aspecto importante a ser considerado no modelo do MEPDG, sendo definida como a probabilidade (P) de cada indicador de desempenho (defeitos) do pavimento seja inferior ao limiar estabelecido para a vida de projeto da estrutura. Para o escalonamento, a confiabilidade é expressa conforme a equação:

$$R = P(\mu F < C\mu F) \quad (\text{Equação 2.42})$$

Onde μF é o escalonamento médio das juntas transversais e $C\mu F$ é o escalonamento médio crítico das juntas transversais.

O modelo prevê o escalonamento das juntas para um nível de confiabilidade de 50 %, de modo que o escalonamento para tal confiabilidade é previsto conforme a seguinte equação:

$$Fault_{Ri} = Fault_i + STD_{Fi} \cdot Z_R \quad (\text{Equação 2.43})$$

Onde:

$Fault_{Ri}$ é o escalonamento previsto para o nível de confiabilidade R para o ano i ;

STD_{Fi} é o desvio padrão do escalonamento no nível previsto de escalonamento médio para o ano i (conforme equação abaixo):

$$STD_{Fi} = a \cdot Fault_i^b + c \quad (\text{Equação 2.44})$$

Onde:

Z_R é o desvio normal padrão para o nível de confiabilidade R ;

$Fault_i$ é o escalonamento prévios para confiabilidade de 50 % para o ano i .

a , b e c são constantes de calibração.

Ao longo dos anos foram publicados diversos estudos sobre a calibração dos modelos do MEPDG em vista das condições climáticas locais dos estados americanos, conforme a base de dados do LTPP foi sendo progressivamente ampliada. Alguns desses estudos com seus respectivos coeficientes de calibração são referenciados na Tabela 2.2.

Tabela 2.2 – Coeficientes de calibração para o modelo de previsão de escalonamento de juntas de PCS

Projeto	NCHRP 1-40D ^a	NCHRP 20-07 ²	PennDOT	Colorado ^b	Arizona ^c
<i>C</i> ₁	1,0184	0,595	0,595	0,51	0,0355
<i>C</i> ₂	0,9165	1,636	1,636	0,00838	0,1147
<i>C</i> ₃	0,002185	0,00217	0,00147	0,00147	0,00436
<i>C</i> ₄	0,000884	0,00444	0,00444	0,00835	1,10E-07
<i>C</i> ₅	250	250	250	5.999	20.000
<i>C</i> ₆	0,40	0,47	0,40	0,08404	20.389
<i>C</i> ₇	1,83312	7,3	7,3	5,9293	0,189
Constantes para cálculo de confiabilidade do modelo					
	NCHRP 1-40D ¹	NCHRP 20-07 ²	PennDOT	Colorado ³	Arizona ³
<i>a</i>	0,0097	0,07162	0,08162	0,0831	0,037
<i>b</i>	0,5178	0,368	0,03481	0,3426	0,6532
<i>c</i>	0,014	0,00806	0,008	0,00521	0,001

Nota: ^a NCHRP (*National Cooperative Highway Research Program*) 1-40D: primeira recalibração do MEPDG realizada em 2007;
^b NCHRP 20-07: recalibração realizada em 2011;
^c calibrações locais.

Fonte: Adaptado de Salles e Khazanovich (2021)

Mu *et al.* (2016) compilaram os principais estudos de calibração global e local realizados para o modelo de escalonamento em juntas de pavimentos de concreto, tendo observado que, dos sete estados que realizaram calibrações para PCS, cinco deles (Iowa, Lousiana, Missouri, Ohio e Washington) adotaram os coeficientes de calibração globais para o desvio padrão; apenas os estados do Arizona e Colorado propuseram coeficientes locais diferentes daqueles propostos na calibração global. O estado da Pensilvânia também realizou uma calibração local do modelo, propondo uma pequena alteração nos coeficientes de calibração (ver Tabela 2.2).

2.3 METODOLOGIA PARA CALIBRAÇÃO DO MODELO DE ESCALONAMENTO PARA O CLIMA BRASILEIRO

A calibração empírica de qualquer modelo de desempenho de pavimentos pressupõe a utilização de uma base de dados robusta, consistente e confiável de pavimentos que atendam aos parâmetros de desempenho para os quais foram projetados para o período de projeto adotado, formando assim, um banco de dados indispensável para um sistema de gerência de pavimentos para a malha de interesse.

No caso de pavimentos de concreto simples, é sabido que a malha rodoviária brasileira pavimentada em PCS é de aproximadamente 3 % da totalidade, denotando uma não tradição do uso da tecnologia no país. Além disso, um dos únicos exemplos de notório sucesso no emprego de PCS no Brasil é a Rodovia dos Imigrantes, ligando a capital

São Paulo a Santos. Construída na primeira metade da década de 1970, apresentou bom desempenho até os dias atuais. Em 2004, quando foi concessionada a rodovia, apenas 6 % das onze mil placas requereram reparações de menor ou maior monta⁹.

No geral, PCS executados no Brasil apresentam, por razões diversas que permeiam focos de avanço tecnológico no presente projeto de pesquisa, rupturas precoces (por vezes em torno de 5 a 8 anos após abertura ao tráfego), por motivos os quais não são objeto de discussão neste documento, mas que, indubitavelmente, impactam na não existência de dados suficientes para a calibração de modelos de desempenho de PCS. Não é viável calibração sem monitoração ao menos dos parâmetros básicos de desempenho ao longo dos anos. Fora isso, modelos de desempenho para pavimentos de concreto requerem coleta consistente de dados de ao menos duas décadas.

Por essa razão, para a calibração do modelo de desempenho de escalonamento em juntas transversais de PCS do MEPDG, apresentado e discutido anteriormente, será adotada a base de dados do LTPP- AASHTO.

Para tal meta será necessário fazer uma triagem e análise minuciosa das seções em estados dos EUA que foram selecionados, na expectativa de apresentarem alguma similaridade com o clima brasileiro, de modo que se possa selecionar as seções expostas às condições climáticas que ao menos possuam maior proximidade daquelas observadas no extenso território brasileiro.

Por razões óbvias, consideradas as condições equatoriais, tropicais e subtropicais brasileiras, os estados americanos selecionados são aqueles mais ao Sul, para os quais os dados das seções de PCS monitoradas foram obtidos da base de dados do LTPP, de acesso público (<https://infopave.fhwa.dot.gov/>). Esses estados são: Alabama, Flórida, Califórnia, Mississippi, Louisiana, Georgia e Carolina do Sul.

A partir da seleção das informações de interesse que compõe a base de dados, foram extraídas, até esse momento, as condições climáticas das seções de PCS pertinentes, construídas e monitoradas em cada um desses estados, cujas informações são sumarizadas nas Tabelas 2.3 e 2.4 que se seguem.

⁹ Comunicação pessoal de José Tadeu Balbo junto à Concessionária em 2004.

Tabela 2.3 – Resumo dos dados meteorológicos para os estados do sul dos EUA

Alabama						
Mês	Precip. (mm)	Tmax (°C)	Tmín (°C)	Tmed (°C)	UR (%)	Vento (m/s)
1	136,8	12,5	1,6	8,5	68,6	2,73
2	131,7	15,1	3,6	8,8	68,5	2,84
3	145,4	19,5	7,2	11,6	64,4	2,85
4	126,0	23,9	11,2	15,8	67,3	2,67
5	113,3	27,8	16,1	20,1	71,0	2,31
6	101,3	31,2	20,3	24,0	72,4	1,96
7	115,0	32,8	22,3	25,7	73,4	1,90
8	89,4	32,6	21,8	25,4	72,2	1,77
9	106,2	29,9	18,5	22,1	70,9	2,12
10	77,1	24,4	12,2	16,1	70,9	2,10
11	118,4	18,3	6,1	10,8	69,6	2,29
12	129,4	13,8	3,3	7,5	68,9	2,64
Califórnia						
Mês	Precip. (mm)	Tmax (°C)	Tmín (°C)	Tmed (°C)	UR (%)	Vento (m/s)
1	60,8	14,3	8,1	11,1	75,6	2,6
2	55,7	16,2	9,3	12,0	70,0	2,9
3	44,4	17,4	9,4	13,5	63,8	3,2
4	23,7	19,3	11,5	15,8	57,9	3,6
5	11,6	19,8	12,2	18,9	53,5	4,0
6	3,4	21,6	13,8	21,8	50,0	4,0
7	3,1	22,7	13,7	24,5	49,3	3,6
8	4,1	22,4	13,9	24,0	50,7	3,4
9	7,6	22,1	13,4	22,1	53,2	3,1
10	17,9	21,1	13	18,1	58,2	2,7
11	33,7	17,8	11,6	13,5	66,7	2,4
12	54,9	14,5	8,7	10,9	74,4	2,6
Georgia						
Mês	Precip. (mm)	Tmax (°C)	Tmín (°C)	Tmed (°C)	UR (%)	Vento (m/s)
1	123,6	12,2	2,0	9,4	67,5	3,0
2	114,2	14,6	3,8	10,0	66,1	3,1
3	122,5	18,8	7,4	13,0	64,9	3,2
4	100,7	23,2	11,4	16,8	65,3	2,9
5	94,8	27,3	16,3	21,1	68,8	2,6
6	111,1	30,6	20,3	24,9	71,0	2,4
7	119,5	32,2	22,1	26,6	71,8	2,2
8	114,5	31,7	21,8	26,0	72,7	2,1
9	97,2	28,8	18,8	23,1	72,3	2,3
10	80,6	23,6	12,7	17,4	71,0	2,3
11	89,7	17,8	6,8	12,4	69,5	2,5
12	114,5	13,4	3,6	9,6	69,2	2,7

South Carolina						
Mês	Precip. (mm)	Tmax (°C)	Tmín (°C)	Tmed (°C)	UR (%)	Vento (m/s)
1	100,6	14,6	5,5	7,7	-	-
2	91,7	16,3	6,7	8,6	-	-
3	91,8	18,9	10,3	12,1	-	-
4	80,7	22,7	14,8	16,4	-	-
5	80,1	26,4	17,6	20,9	-	-
6	101,0	29,2	22,8	25,1	-	-
7	105,4	30,3	24,4	27,0	-	-
8	114,7	29,7	24,7	26,2	-	-
9	95,8	27,7	20,4	22,8	-	-
10	86,3	24,0	14,8	17,0	-	-
11	83,4	19,5	10,4	11,6	-	-
12	98,3	16,4	7,0	8,4	-	-
Flórida						
Mês	Precip. (mm)	Tmax (°C)	Tmín (°C)	Tmed (°C)	UR (%)	Vento (m/s)
1	74,4	23,1	12	16,4	72,2	3,3
2	74,5	24,5	13,1	17,0	71,0	3,4
3	92,2	25,2	15,3	18,8	69,7	3,6
4	66,5	26,3	16,9	21,2	68,5	3,5
5	94,5	28,3	20,5	24,3	69,7	3,3
6	180,7	30,5	22,4	26,9	74,1	2,8
7	180,9	31,1	23,3	27,8	75,3	2,5
8	188,5	31,6	23,8	27,8	76,2	2,5
9	172,9	30,8	22,9	26,7	74,3	2,9
10	93,7	28,5	19,1	23,2	71,9	3,2
11	66,8	25,9	15,4	19,5	73,4	3,2
12	67,1	23,7	12,9	17,2	73,4	3,0
Mississippi						
Mês	Precip. (mm)	Tmax (°C)	Tmín (°C)	Tmed (°C)	UR (%)	Vento (m/s)
1	134,7	14,1	2,6	8,4	71,1	3,3
2	132,5	16,7	4,3	10,0	69,9	3,4
3	149,3	20,8	8,0	15,8	66,7	3,5
4	134,6	24,7	11,8	17,8	67,2	3,3
5	132,2	28,8	16,7	20,9	70,8	2,8
6	108,8	32,2	20,8	24,8	71,8	2,3
7	114,0	33,4	22,3	26,5	72,8	2,1
8	103,4	33,4	21,9	26,1	71,8	2,0
9	103,3	31,0	18,9	22,9	70,8	2,4
10	99,5	25,7	12,3	17,8	70,2	2,5
11	121,6	19,6	6,4	15,2	71,0	2,8
12	148,4	15,3	5,5	14,3	72,0	3,1

Para o clima brasileiro, foram coletadas informações de séries históricas de dados meteorológicos obtidos na homepage do Instituto Nacional de Meteorologia (INMET) para as regiões Sul, Sudeste, Centro-Oeste, Norte e Nordeste. Foram então extraídos os valores médios mensais para cada região, considerando todos os anos da série histórica (de 2000 a 2025), para os seguintes parâmetros: precipitação acumulada, temperatura máxima, temperatura mínima, temperatura média, umidade relativa e velocidade média do vento, conforme apresentado na Tabela 2.4.

Tabela 2.4 – Resumo das condições climáticas das regiões brasileira

Sul						
Mês	Precip. (mm)	Tmax (°C)	Tmín (°C)	Tmed (°C)	UR (%)	Vento (m/s)
1	161.4	27.9	18.3	21.7	75.8	2.9
2	137.5	27.7	18.2	21.6	76.8	2.7
3	131.5	26.4	17.2	20.4	78.3	2.6
4	117.2	23.4	14.6	17.8	79.3	2.5
5	118.1	19.7	11.6	14.6	80.9	2.6
6	115.8	18.0	9.8	12.9	80.7	2.7
7	111.9	17.8	9.1	12.4	79.0	2.8
8	102.3	19.5	10.0	13.6	76.2	3.1
9	144.5	20.1	11.7	17.1	75.2	3.1
10	148.0	22.3	13.7	19.3	75.1	3.1
11	121.6	24.1	15.1	20.5	72.7	3.1
12	128.6	26.2	16.9	22.3	72.2	3.0
Sudeste						
Mês	Precip. (mm)	Tmax (°C)	Tmín (°C)	Tmed (°C)	UR (%)	Vento (m/s)
1	242.9	29.6	20.6	23.6	75.8	1.7
2	164.1	29.4	20.3	23.4	75.5	1.6
3	185.6	28.9	19.8	22.9	77.7	1.6
4	120.1	26.9	18.1	21.1	78.0	1.5
5	69.0	24.8	15.7	18.9	76.8	1.5
6	50.0	24.2	14.6	18.1	76.1	1.5
7	46.1	23.9	13.9	17.5	73.4	1.6
8	54.7	24.7	14.4	18.1	72.2	1.8
9	63.8	25.6	15.4	19.1	72.3	2.0
10	130.7	26.3	17.2	20.6	75.4	2.0
11	199.9	26.5	18.0	20.9	77.2	1.9
12	234.5	28.1	19.4	22.3	77.6	1.8
Centro-Oeste						
Mês	Precip. (mm)	Tmax (°C)	Tmín (°C)	Tmed (°C)	UR (%)	Vento (m/s)
1	199.1	30.1	20.7	23.9	74.9	2.0
2	180.5	30.3	20.5	23.8	74.7	1.8
3	173.5	30.4	20.4	23.8	74.9	1.8
4	115.9	30.1	19.6	23.4	71.8	1.9
5	39.2	28.6	17.0	21.6	67.5	1.9
6	19.3	28.3	15.7	20.8	63.3	2.0
7	10.1	28.8	15.0	20.7	54.8	2.2
8	17.7	30.8	16.6	22.5	46.3	2.5

Centro-Oeste						
Mês	Precip. (mm)	Tmax (°C)	Tmín (°C)	Tmed (°C)	UR (%)	Vento (m/s)
9	43.4	32.6	19.4	24.8	47.8	2.5
10	118.1	32.1	20.6	25.0	60.3	2.3
11	190.7	30.6	20.6	24.1	70.4	2.1
12	200.8	30.4	20.8	24.0	73.5	2.0
Norte						
Mês	Precip. (mm)	Tmax (°C)	Tmín (°C)	Tmed (°C)	UR (%)	Vento (m/s)
1	248.5	31.6	23.6	26.1	74.9	1.4
2	278.6	31.2	23.5	25.8	74.7	1.4
3	307.6	31.4	23.5	25.9	74.9	1.2
4	253.9	31.6	23.6	26.1	71.8	1.2
5	190.7	31.7	23.5	26.2	67.5	1.2
6	111.5	31.9	23.1	26.3	63.3	1.3
7	73.9	32.7	22.6	26.5	54.8	1.4
8	62.8	33.9	23.2	27.4	46.3	1.5
9	87.8	34.4	23.7	27.6	47.8	1.5
10	116.1	33.6	23.8	27.4	60.3	1.5
11	154.4	32.8	23.8	27.0	70.4	1.4
12	213.1	31.9	23.8	26.4	73.5	1.4
Nordeste						
Mês	Precip. (mm)	Tmax (°C)	Tmín (°C)	Tmed (°C)	UR (%)	Vento (m/s)
1	106.1	31.3	24.2	26.8	73.1	2.4
2	130.1	31.3	24.3	26.8	74.4	2.3
3	195.9	31.2	24.1	26.7	75.7	2.1
4	216.1	30.8	23.9	26.4	77.4	2.0
5	234.7	30.1	23.4	25.9	78.2	2.1
6	201.7	29.5	22.8	25.2	77.3	2.2
7	169.0	29.1	22.0	24.6	75.9	2.4
8	98.6	29.6	22.0	24.9	72.6	2.6
9	66.8	30.4	22.7	25.5	70.9	2.8
10	41.8	31.1	23.6	26.3	69.4	2.9
11	41.3	31.6	24.2	26.8	69.7	2.9
12	51.1	31.5	24.3	27.0	70.6	2.7

Por fim, destaca-se que os dados apresentados nas tabelas acima, para fins de comparação de clima entre os estados do Sul dos EUA com as regiões brasileiras, embora sejam apresentados, para fins de visualização, em valores médios, esses valores representam as médias das seções do LTPP construídas em PCS nos estados selecionados. Para fins de calibração, nas etapas seguintes deste projeto, os dados climáticos registrados para cada uma das seções serão comparados com os dados das regiões brasileiras, seção por seção, para verificação de quais delas melhor se aproximam das condições locais aqui observadas, de modo que seus registros da série histórica de desempenho sobre o escalonamento das juntas de concreto sejam utilizados como base de dados para a calibração do MEPDG para o Brasil.

Nas figuras 2.9 a 2.14 são apresentados os dados das Tabelas 2.3 e 2.4 para visualização das distribuições mensais de precipitação acumulada, temperaturas médias máximas e mínimas, umidade relativa do ar e velocidade do vento para os estados americanos considerados bem como as regiões brasileiras.




Figura 2.9 – Boxplot da precipitação acumulada para os estados americanos e regiões do Brasil




Figura 2.10 – Boxplot da temperatura máxima média para os estados americanos e regiões do Brasil




Figura 2.11 – Boxplot da temperatura mínima média para os estados americanos e regiões do Brasil




Figura 2.12 – Boxplot da temperatura média para os estados americanos e regiões do Brasil




Figura 2.13 – Boxplot da umidade relativa para os estados americanos e regiões do Brasil




Figura 2.14 – Boxplot da velocidade do vento para os estados americanos e regiões do Brasil

Analisando preliminarmente as informações contidas acima, pode-se criar uma tabela de associações de parâmetros climáticos (médios), buscando-se um primeiro paralelo entre as condições observadas no Brasil e no Sul estadunidenses, o que é apresentado na Tabela 2.4. Observa-se que para as zonas intertropicais/equatoriais do Brasil ocorrem impossibilidades de associações climáticas mais evidentes em relação às condições nos EUA.

Tabela 2.5 – Associações entre Climas Brasileiros (regiões) e nos EUA (estados)

Parâmetro atmosférico	Precipitação	Temperatura máxima	Temperatura média	Temperatura mínima	Umidade relativa do ar	Velocidade dos ventos
Centro-Oeste	Flórida	-	Flórida	-	Alabama-Geórgia	-
Nordeste	Flórida	-	-	-	Flórida	Alabama
Norte	-	-	-	-	Alabama-Geórgia	-
Sudeste	Flórida	Mississippi-Flórida	Flórida	Flórida	Flórida-Mississippi	-
Sul	Alabama-Mississippi	Alabama-Geórgia-Carolina do Sul	Mississippi-Geórgia-Califórnia	Carolina do Sul	Flórida-Mississippi	-

3. MODELAGEM DE PAVIMENTOS DE CONCRETO – ANÁLISE POR ELEMENTOS FINITOS 2D

A modelagem de PCS empregando técnica numérica, precisamente, o método dos elementos finitos, é a forma de abordagem mais ampla e mais precisa para a predição de esforços solicitantes nessas estruturas planas, sendo indiscutível seu emprego contemporâneo, como visto na revisão bibliográfica apresentada no IPR RP 016.

Para os propósitos do presente projeto de pesquisa, na etapa semestral que se conclui com a apresentação do presente documento, a modelagem amplamente conduzida foi aquela em duas dimensões. Para tanto, empregou-se o programa computacional ISLAB2000 para o qual a equipe de projeto possui licença de emprego.

A modelagem em 2D (em duas dimensões, para placas em estado plano de tensões¹⁰), embora não sendo a definidora de parâmetros para o desenvolvimento dos modelos por inteligência artificial para consolidação de método nacional de projeto de PCS (incluídos os WT), se fez necessária devido a duas principais razões e motivações, atreladas ao desenvolvimento dos trabalhos, a saber:

- Iniciação da modelagem de aprendizado de máquina a partir de um experimento fatorial relativamente amplo, que fornecesse os parâmetros de simulação de deformações e tensões nas placas de concreto a partir de parâmetros tidos solidamente como dados de projeto: geometria de placas, cargas de eixos rodoviários, propriedades do concreto, efeitos térmicos, dentre outros básicos. Existem várias alternativas, com eficiência a ser demonstrada, para o treinamento de máquina para que, fornecidos parâmetros essenciais de natureza estrutural, sejam computadas por IA os deslocamentos e tensões críticas no concreto, que são parâmetros básicos não apenas para o projeto dessas estruturas, como para sua verificação estrutural.
- É mister ter-se uma clara visão da correlação existente entre resultados de simulações 2D e 3D. No passado, a exemplo de propostas elaboradas por agências e pesquisadores, procurava-se estabelecer uma correlação entre tensões 2D e 3D para, simplesmente, por facilidade, todo o desenvolvimento de matrizes parâmetros *versus* respostas mecânicas ser levado a termo empregando-se modelagem 2D, muito mais simples para a época.

¹⁰ Observe-se aqui, de plano, que a modelagem 2D é também referenciada por alguns estudiosos, como modelagem 2,5D para o caso de placas, quando a espessura da placa (do elemento finito) entra em jogo na formulação da matriz de rigidez tangente relacionando deslocamentos e forças aplicadas.

- Isso não se justifica atualmente face à disponibilidade de softwares de análise FEA 3D de elevado desempenho, acessíveis em termos econômicos e com interfaces de alta simplicidade. Entende-se, portanto, a necessidade de estabelecer um paralelo seguro, para os engenheiros ainda não habituados com modelagem 3D (e por vezes mesmo com modelagem 2D), demonstrada a coerência entre o uso de diferentes modelagens FEM, para um mesmo problema, porém empregando técnicas muito diferentes entre si.

3.1 PROGRAMA DE MODELAGEM POR ELEMENTOS FINITOS ISLAB 2000

3.1.1 Aspectos básicos do programa ISLAB 2000

O ILSL (*Illinois-Slab*) foi desenvolvido originalmente a partir do ano de 1978 na Universidade de Illinois, pelo engenheiro Tabatabaie (então estudante de doutorado sob a orientação do Prof., Ernest J. Barenberg), para a análise de pavimentos de concreto, também mencionado tradicionalmente como pavimentos rígidos mais genericamente (Tabatabaie e Barenberg, 1978). A versão inicial do programa, denominada ILLISLAB, empregou o Fortran IV como linguagem de máquina para suas rotinas e sub-rotinas, pautando-se pela Teoria de Placas Isótropas (medianamente delgadas), para a determinação de respostas mecânicas de placas de concreto de PCS sob ação de cargas rodoviárias.

O tipo de elemento finito empregado, com sua respectiva matriz de rigidez formulada com base no conceito de energia de deformação volumétrica, foi publicado anos antes (na modelagem original das placas de concreto foi adotado o elemento de placa retangular desenvolvido por Melosh, (1963), conforme ilustrado na Figura 3.1 (a) na sequência.

Em consonância com a Teoria Clássica de Placas Isótropas, o programa assume que as verticais à superfície média da placa não deformada permanecem planas após as deformações (hipótese de Navier-Bernoulli), sem alongamento, e normais à superfície média da placa deformada. Adicionalmente, assume que cada lâmina paralela à superfície média está em um estado plano de tensões, não havendo desenvolvimento de tensões axiais ou cortante no plano devido ao carregamento aplicado (em decorrência, as tensões verticais de cisalhamento são nulas¹¹).

¹¹ No caso de ocorrência de cisalhamento vertical estar-se-ia no horizonte de cascas ou chapas (efeitos de punção presentes), ou mesmo blocos.




Figura 3.1 – Modelo de elementos finitos para o sistema de pavimento (Tabatabaie e Barenberg, 1978)

Para bases estabilizadas e revestimentos aderidos, admite-se compatibilidade total de deformações (verticais e horizontais) na interface. Por outro lado, no caso de bases e revestimentos não aderidos, as tensões de cisalhamento na interface são desprezadas. Quanto ao subleito, foi modelado como uma fundação de Winkler, sendo representado por uma série de molas lineares-elásticas desconectadas.

As barras posicionadas nas juntas são consideradas como compostas de materiais homogêneos, isotrópicos e elástico-lineares (cabem, em tese, várias alternativas de materiais), estando localizadas na posição horizontal coincidente com a linha neutra da placa (tensões normais nulas). Além disso, quando as barras constituem o principal mecanismo de transferência de carga, tanto o momento quanto o esforço de cisalhamento são transferidos através da junta. Por outro lado, quando o intertravamento de agregados é o mecanismo predominante, a transferência de carga entre placas sucessivas ocorre essencialmente por meio de esforços de cisalhamento.

Para o elemento de placa empregado, cada nó de elemento possui um deslocamento vertical (w) na direção z , uma rotação (θ_x) em torno do eixo x e uma rotação (θ_y) em torno do eixo y . Associados a esses componentes de deslocamento, existem três componentes de força: uma força vertical (P_w) aplicada sobre o nó perpendicularmente ao elemento, um momento em torno do eixo x (P_{θ_x}) e um momento em torno do eixo y (P_{θ_y})¹². O deslocamento e a força estão relacionados pela equação matricial abaixo apresentada (Equação 3.1).

¹² Para melhor compreensão das interações entre deslocamentos em nós de elementos contíguos sugere-se consultar: Balbo, J.T. *Aplicação do método dos elementos finitos na avaliação estrutural de pavimentos rígidos rodoviários*. Primeiro modelo numérico-computacional para a análise de pavimentos de concreto desenvolvido no Brasil. Ver Capítulos 5 e 6. Edição Revisada de 35 anos (comemorativa). São Paulo, 2025. Impressão: Votorantim Cimentos.

$$\{P\}_c = [K_{top} + K_{bottom} + K_{sub}]_e \{D\}_e \quad (\text{Equação 3.1})$$

Na qual K_{top} , K_{bottom} e K_{sub} representam, respectivamente, as matrizes de rigidez da camada superior, da camada inferior e do subleito. P_e e D_e representam vetores de forças e de deslocamentos no elemento de placa. A notação matricial é repetida para o caso em que duas camadas estão aderidas (como no caso de uma placa e base estabilizada). Para esses casos, define-se o eixo neutro do elemento com base na definição de uma camada equivalente, utilizando o conceito de ‘seção transformada’.

Para a análise das barras de transferência de cargas utiliza-se o elemento de barra com 2 graus de liberdade por nó (Figura 3.1b). O deslocamento vertical (w) na direção z e a rotação (θ_y) em torno do eixo y são os dois componentes de deslocamentos em cada nó. Esses dois deslocamentos estão relacionados com a força vertical (P_w) e o momento em torno do eixo y ($P_{\theta y}$). A Equação 3.2 apresenta a relação força–deslocamento para cada elemento de barra.

$$\{P\}_b = [K_{dowel}]_b \{D\}_b \quad (\text{Equação 3.2})$$

Onde K_{dowel} representa a matriz de rigidez da barra de transferência, P_b o vetor de forças e D_b o vetor de deslocamentos do elemento de barra.

A deformação relativa entre a barra de transferência e o concreto ao seu entorno é representada como a rigidez de um elemento de mola vertical. Esse elemento se estende entre a barra e o concreto circundante na face da junta.

Para a modelagem do sistema de intertravamento de agregados é utilizado um elemento de mola com um grau de liberdade por nó (Figura 3.1c). O deslocamento vertical na direção z e sua força vertical correspondente (P_w) são relacionados conforme a Equação 3.3.

$$\{P\}_s = [K_{Agg}]_s \{D\}_s \quad (\text{Equação 3.3})$$

Onde K_{Agg} representa a matriz de rigidez do elemento de mola, P_s é o vetor de forças e D_s é o vetor de deslocamentos do elemento de mola.

A matriz de rigidez global da estrutura de pavimento (placa+base+subleito) K_s é formulada pela superposição do efeito das rigidezes individuais dos elementos, utilizando as propriedades topológicas ou de conexão entre elementos do sistema de pavimento. A matriz de rigidez global é utilizada para resolver o sistema de equações lineares simultâneas na forma apresentada na Equação 3.4.

$$\{P\}_s = [K]_s \{\Delta\}_s \quad (\text{Equação 3.4})$$

Onde P_S são as cargas externamente aplicadas a todo o sistema, e Δ_S são os deslocamentos dos nós de todo o sistema. Determinados os deslocamentos em cada nó dos elementos, determinam-se as deformações específicas nas direções x e y e, finalmente, as tensões correspondentes empregando-se a Lei de Hooke Generalizada.

Tabatabaie e Raissi (1978) compararam os resultados gerados pelo programa ILLISLAB com os resultados obtidos pelas soluções das equações de Westergaard, com os gráficos de influência desenvolvidos por Pickett e Ray, bem como com medidas em pistas experimentais como a AASHTO *Road Test* e o *Public Roads Test Arlington Experimental Farm*). Para todos os casos, foram obtidas correlações adequadas e resultados satisfatórios, garantindo a idoneidade do método numérico desenvolvido no âmbito da UIUC.

3.1.2 Evolução do programa ISLAB

Desde sua criação e divulgação preliminar em 1978, o programa passou por sucessivas revisões e atualizações, derivadas de pesquisas no âmbito da pós-graduação na UIUC. Em primórdios dos anos 90, Nasim *et al.* (1991) modificaram o ILLI-SLAB para gerar funções de influência que permitissem prever históricos de deformação ao longo do tempo.

Outras capacidades, como a implementação de diferentes modelos para tratamento de deslocamentos no subleito (Khazanovich e Ioannides, 1993) e carregamento térmico (Korovesis, 1990), foram incorporados ao programa, sucessivamente. O carregamento térmico é relevante para representar o desempenho em serviço do pavimento de concreto. Assim, a adição de um modelo para representar a influência da temperatura aumentou as possibilidades de análises com o programa.

Em 1994, o ILLI-SLAB foi modificado e passou a ser denominado ILSL2. Essa nova versão¹³ incorporou a capacidade de analisar a ação independente (não aderida) de duas camadas (Khazanovich, 1994), incluídos aqui os *overlays*. Posteriormente, em 1998, a ERES *Division of Applied Research Associates* (ARA), uma Empresa privada sediada em Champaign, IL, em parceria com os *Department of Transportation* (DOT) dos estados de Michigan e Minnesota, com a *Michigan Technological University*, a *University of Michigan*, a *Michigan State University* e a *University of Minnesota Twin Cities*, desenvolveu o software interativo ISLAB 2000. Esse programa constitui uma revisão do ILSL2, apresentando a capacidade de modelar múltiplas camadas, juntas desalinhas e um incremento no número máximo de nós.

¹³ Programa em linguagem FORTRAN 90, eventualmente disponível em alguns ambientes de pesquisa no Brasil, como na EPUSP, requer o emprego de suíte Fortran para implantação em microcomputadores eletrônicos.

Além disso o programa incorpora a análise da ação independente de duas camadas de pavimento sob distribuição de temperatura linear ou não linear (Abdalla, 2005). A versão mais recente do programa corresponde ao ISLAB 2005, que foi a última atualização do sistema¹⁴.

Conforme descritas por Wang *et al.* (2006), as principais características do software de elementos finitos ISLAB encontram-se sintetizadas na Tabela 3.1.

Tabela 3.1 – Características (principais) do software ISLAB

Categoria	Descrição
Elementos	Elementos com quatro nós e 12 graus de liberdade.
Placa de concreto	Modelada como placa medianamente delgada, com pequenas deformações, elástica e homogênea.
Barras de transferência	Consideradas como elementos elásticos lineares.
Fundação e camadas	Fundação do tipo Winkler (molas) para pavimentos de múltiplas placas. Modelos de: Boussinesq, Pasternak, Kerr–Vlasov e Zhemochkin–Sinitsyn–Shtaerman para placas isoladas.
Camadas acima do subleito	Uma ou duas camadas de material sobre o subleito (base+sub-base).
Condições de aderência	Camadas podem ser aderidas, não aderidas ou parcialmente aderidas.
Contato placa/subleito	Contato parcial permitido entre a placa e o subleito.
Número de placas	Número total de placas definido pelo usuário.
Propriedades das camadas	Espessura e rigidez podem variar dentro de uma mesma camada.
Acostamento de concreto	Modelado com ou sem barras de ligação.
Cargas	Múltiplas rodas e eixos permitidos.
Área de carga	Área de carregamento de formato retangular.
Transferência de carga	Intertravamento de agregados, barras de transferência de carga (circulares ou quadradas), ou ambos.
Tensões de cisalhamento	Tensões de cisalhamento permitidas na junta com condições de transferência de carga por intertravamento de agregados.
Gradiente térmico	Distribuição de temperatura linear ou não linear ao longo da profundidade da placa.

¹⁴ Na homepage da ARA *Research Associates* observa-se há anos não estar mais disponível a licença do software, nem sob pagamento.

No que se refere à execução de projetos, o ISLAB dispõe de uma interface gráfica simples e intuitiva, desenvolvida para facilitar tanto a inserção dos dados de entrada quanto a visualização e interpretação dos resultados. Entre as principais saídas fornecidas pelo programa destacam-se as deflexões e rotações nos nós, as reações verticais nos nós localizados na superfície do subleito, as tensões normais, de cisalhamento e principais nas juntas, além de um resumo das tensões e deflexões máximas na placa, na base ou no revestimento, avaliadas tanto no topo quanto na face inferior de cada camada.

O ISLAB tem sido utilizado em diversos projetos de pesquisa relacionados à análise estrutural de pavimentos de concreto, essencialmente nos Estados Unidos da América, incluindo influência do tipo de base, configuração geométrica, propriedades do material da placa e interação entre cama das (Covarrubias, 2012; Koh *et al.*, 2022; Sachs *et al.*, 2018; Shi *et al.*, 2021; Souder *et al.*, 2020). Porém, a influência do ISLAB na análise de pavimentos de concreto ultrapassou o âmbito acadêmico, alcançando aplicações diretas em metodologias de dimensionamento de pavimentos. O programa serviu de base para o desenvolvimento do modelo de rede neural empregado na geração das respostas estruturais de PCS e CRCP (Pavimento de concreto com armadura contínua) no *Mechanistic-Empirical Pavement Design Guide* (MEPDG), desenvolvido no projeto NCHRP 1-37A do *National Cooperative Highway Research Program* (NCHRP) (Wang *et al.*, 2006; Kim; Gopalakrishnan; Ceylan, 2011). Esse esforço culminou no atual método de dimensionamento de pavimentos de concreto adotado nos Estados Unidos da América.

Nesse contexto, o ISLAB 2000 foi recomendado no *AASHTO Guide for Mechanistic-Empirical Design of New and Rehabilitated Pavement Structures*, em virtude de sua eficiência computacional e da precisão das previsões estruturais fornecidas (Abdalla, 2005). Contudo, como se expôs na nota de rodapé número 5 anterior, O ISLAB 2005 aparente não é mais disponível para licenciamentos.

Apesar de sua ampla utilização, o ISLAB apresenta limitações, especialmente no que se refere à modelagem das condições de contorno e do estado inicial de tensões em pavimentos de concreto armado com juntas e em pavimentos de concreto continuamente armado.

No tocante à representação da infraestrutura, o programa não contempla os efeitos da drenagem; as juntas podem ser posicionadas apenas paralelamente aos eixos x e y; e a área de carregamento é restrita à geometria retangular. Ainda assim, o software representa um avanço significativo em relação aos métodos tradicionais de dimensionamento de pavimentos de concreto (por exemplo, PCA 66 ou 84, cartas de influência de Picket e Ray, Método FAA vigente, dentre outros), ao possibilitar análises mecanicistas mais detalhadas.

Todavia, por se tratar de um modelo bidimensional (2D) baseado no método dos elementos finitos, o ISLAB 2005 apresenta restrições quanto à representação de fenômenos tridimensionais. Em particular, não é capaz de modelar com elevada fidelidade as forças reais de fricção horizontal na interface entre camadas distintas do pavimento, nem de capturar respostas locais mais refinadas, como as tensões desenvolvidas na interface entre a barra de transferência e o concreto. Para prejuízo de análises mais abalizadas, não considera aspectos geotécnicos importantes como simplesmente a modelagem do subleito como meio contínuo e sujeito a distorções cisalhantes.

Um outro condicionante para não se continuar com o emprego do programa ISLAB, relacionado ao difícil acesso ao programa para os usuários na atualidade, é que programas abertos de enorme versatilidade vêm sendo empregados, em especial no âmbito de países da União Europeia, com vantagens numerosas sobre técnicas de FEA ou FEM em 2D¹⁵.

3.2 METODOLOGIA PARA GERAÇÃO DO EXPERIMENTO FATORIAL 2D

Nesta fase dos trabalhos, conforme proposto, buscou-se a simulação de uma quantidade razoável de condições para pavimentos de concreto simples, com duas finalidades explícitas:

- a) testes de treinamento de modelos de aprendizagem de máquina;
- b) preparação de banco de dados comparativos para os estudos iniciais em 3D empregando-se o programa ABAQUS, o que será melhor desenvolvido na próxima etapa dos trabalhos.

3.2.1 Condições e parâmetros de modelagem

A avaliação estrutural de pavimentos de concreto no ISLAB foi desenvolvida com o objetivo de representar as condições típicas observadas em pavimentos novos em serviço, tanto no que se refere à geometria de placas, quanto aos parâmetros estruturais adotados.

Os resultados obtidos, foram posteriormente empregados na etapa inicial de aprendizado de máquina (modelagem de IA), correspondente à fase inicial de desenvolvimento de ferramenta para dimensionamento de PCS e WT.

¹⁵ Acrescente-se aqui obrigatoriamente o fato e percepção clara de que no futuro, para atualizações do método de projeto de pavimentos de concreto do DNIT, as novas gerações de engenheiros trabalharam com abordagens estruturais cada vez mais visuais, possivelmente com análises dinâmicas em complementação às estáticas, empregando IA e com sucessiva evaporação tecnológica das limitações dos programas em 2D, o que torna essencial para no Brasil se trabalhar, no presente projeto, com tecnologias 3D que cada vez mais se expandirão no mercado de engenharia.

Portanto, considerando que, em condições reais, múltiplas características estão envolvidas e interagem entre si, foi definida uma faixa de valores para cinco parâmetros, agrupados em: espessura da placa de concreto, módulo de elasticidade do concreto, módulo de reação do subleito (módulo de Westergaard ou hipótese de Winkler do Líquido Denso), diferencial linear de temperatura (entre topo e fundo de placa) e nível de carga por ESRD.

Os parâmetros selecionados foram definidos de modo a representar distintos casos de infraestrutura, contemplando aspectos geométricos (espessura), propriedades dos materiais (módulo de elasticidade do concreto e módulo de reação do subleito) e condições de serviço (diferencial de temperatura e nível de carga por ESRD). A Figura 3.2 a seguir apresenta os valores das variáveis estabelecidas para a modelagem.

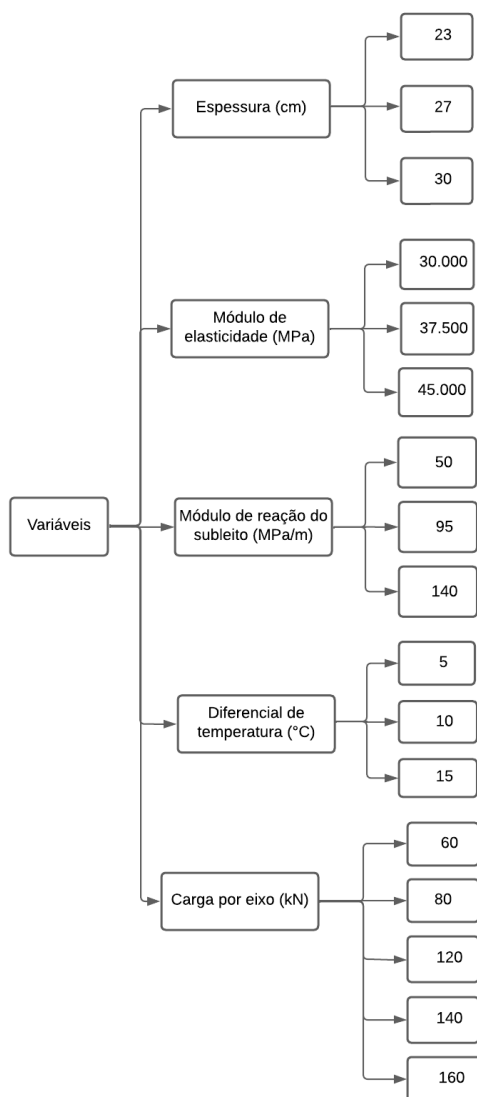


Figura 3.2 – Variáveis consideradas na modelagem empregando ISLAB 2005

Com relação às características das camadas do pavimento, o ISLAB 2005 possui três seções para introduzir os dados de entrada. Na primeira seção, são incorporadas as informações dimensionais sobre a camada de rolamento, ou seja, as placas de concreto.

No caso do presente estudo, a infraestrutura esta composta por duas faixas de rolamento conformadas por três placas de concreto de 3,60 m × 5,00 m. Lateralmente a cada faixa de rolamento, foram incluídas uma faixa de acostamento composta por três placas de 3,00 m × 5,00 m (Figura 3.3). Em todas as faixas, a camada superficial é composta de concreto (de cimento Portland ou de misturas de ligantes hidráulicos). Além disso, nesta seção foi definida uma malha média¹⁶ para a discretização em elementos finitos para todas as modelagens.

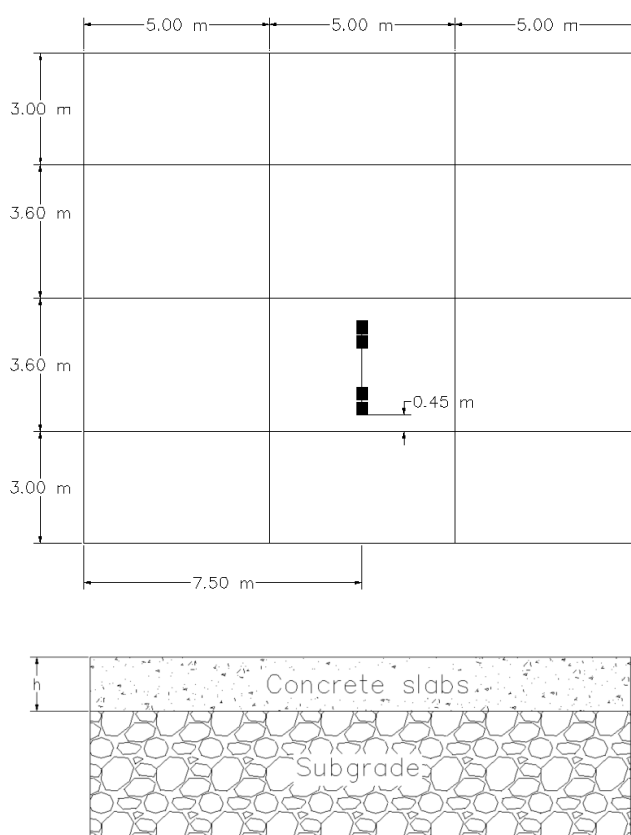


Figura 3.3 – Características geométricas do modelo e posicionamento do ESRD

A segunda guia de entrada de dados concentra-se nos parâmetros dos materiais que compõem cada camada da estrutura do pavimento. Baseado em valores referenciais, o concreto foi representado com peso específico de 2.400 kg/m³ e coeficiente de expansão térmica de 9,8E-06 °C⁻¹ (Roesler *et al.*, 2008; de Salles, Balbo e Khazanovich, 2019).

¹⁶ Nota do pesquisador principal: Malhas grossas e finas são disponíveis no ISLAB 2005. As primeiras causam acréscimos nas tensões. A escolha se pautou pela experiência de emprego do software em retroanálises conduzidas em estudos desenvolvidos para diversos segmentos rodoviários em PCS no Brasil.

Com a finalidade de incluir nas análises concretos convencionais e de resistências elevadas, foram estabelecidas variações do módulo de elasticidade na faixa 30.000, 37.500 e 45.000 MPa.

Na terceira guia de dados é declarado o parâmetro relacionado à rigidez das camadas de apoio. Nesse requisito, foi variado o parâmetro de modulo de reação do subleito entre 50, 95 e 140 MPa/m. Os valores selecionados representam condições realistas de placas de concreto sobre bases granulares, bases asfálticas e bases cimentadas (Balbo, 2009). Na Tabela 3.2 são sumarizados os parâmetros de entradas referente a geometria e parâmetros dos materiais considerados na modelagem.

Tabela 3.2 – Parâmetros de geometria e materiais

Parâmetro	Valor	Unidade
Tipo de malha de elementos finitos		
Malha	Mediana	-
Geometria das placas		
Placa de concreto		
Largura	3,6	m
Comprimento	5	m
Acostamento		
Largura	3	m
Comprimento	5	m
Camada superficial de concreto		
Espessura	23	cm
	27	cm
	30	cm
Coeficiente de Poisson	0,2	-
Coeficiente de expansão térmica	9,80E-06	°C ⁻¹
Peso específico do concreto	2.400	kg/m ³
Módulo de elasticidade do concreto	30.000	MPa
	37.500	MPa
	45.000	MPa
Subleito (fundação em solo)		
Modulo de reação do subleito com base granular, Base asfáltica e base cimentada.	50	MPa/m
	95	MPa/m
	140	MPa/m

No tocante às características das juntas transversais, a decisão de utilizar o diâmetro, comprimento e espaçamento das barras de transferência de cargas (BT) apresentados na Tabela 3.3 pauta-se pela recomendação do documento ABNT PR 1011 (2011). Para o caso das juntas longitudinais, são utilizados valores típicos de diâmetro, comprimento e espaçamento, conforme indicado na literatura (Balbo, 2009).

Em ambas as juntas, foi definida uma largura de fissura de junta de 0,2 cm. Esse valor corresponde à largura na qual a transferência de carga por intertravamento de agregados diminui ao ponto de requerer suporte de outros sistemas (Colley e Humphrey, 1967; Jensen e Hansen, 2001). Na Tabela 3.3 são apresentados os parâmetros de entrada no que tange às juntas, utilizados na modelagem de todos os casos apresentados na avaliação realizada.

Tabela 3.3 – Parâmetros das juntas transversais e longitudinais

Parâmetro	Juntas transversais	Juntas longitudinais	Unidade
Diâmetro da barra	3,2	1,5	cm
Módulo de elasticidade da barra	210	210	GPa
Coefficiente de Poisson	0,3	0,3	-
Módulo de suporte da BT	400	400	MPa/mm
Parâmetro k_p (interação BT)	400	400	MPa/mm
Comprimento da barra	45	80	cm
Espaço entre barras aprox.	30	80	cm
Considerando cortante	sim	sim	-
Considerando momento	sim	sim	-

Para todos os casos, as barras incorporadas nas modelagens estão constituídas de aço, que é o material tradicional para a fabricação de barras de transferência de carga e barras de ligação. Essas barras apresentam módulo de elasticidade em torno de 210 GPa (Guo *et al.*, 1995; Sargand, 2001).

A influência do clima tropical foi avaliada buscando-se as tensões geradas em condições com 5 °C, 10 °C e 15 °C de diferencial de temperatura entre o topo e fundo da placa. A análise considera a configuração de carga de um Eixo Simples de Rodas Duplas (ESRD). Juntamente com a carga do eixo e a pressão dos pneus, o ISLAB requer definir as distâncias que caracterizam o eixo em estudo e o posicionamento do eixo em relação a estrutura modelada. Seguindo-se os padrões de análise tradicionais, o eixo foi localizado centralizado à placa do meio do conjunto de placas, a 45 cm da junta longitudinal entre a placa (faixa de rolamento) e o acostamento.

A Figura 3.4 exemplifica a configuração geométrica final do pavimento empregada em todos os 405 casos modelados pelo programa. Na Tabela 3.4 é apresentado o resumo de propriedades e entradas para temperaturas e cargas.




Figura 3.4 – Estrutura de pavimento modelado com o ISLAB 2005

Tabela 3.4 – Parâmetros de temperatura e carga

Parâmetro	Valor	Unidade
Temperaturas		
Diferencial linear de temperatura	5	°C
	10	°C
	15	°C
Cargas		
Tipo de carga	ESRD	
Distância entre rodas S1	0,34	m
Distância entre rodas S2	1,81	m
Distância entre rodas S3	2,15	m
Localização transversal	3,45	m
Localização longitudinal	7,5	m
Cargas dos eixos	60	kN
	80	kN
	120	kN
	140	kN
	160	kN
Pressão nos pneumáticos/superfície	0,54	MPa

3.2.2 Resultados obtidos

Na Tabela 3.5 são apresentados os resultados das simulações em 2D realizadas com ISLAB 2005 para as condições expostas no presente documento. No Apêndice A são apresentadas as imagens de saída fornecidas pelo programa empregado com suas interfaces gráficas. As saídas buscadas no programa, para cada caso, foram as tensões de tração na flexão máximas no fundo da placa carregada, em ambas as direções, e o deslocamento vertical máximo em um nó (deflexão).

Tabela 3.5 – Casos avaliados por modelagem FEM-2D

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
1	23	30.000	50	5	60	1,49	0,87	0,45
2	23	30.000	50	5	80	1,75	1,04	0,45
3	23	30.000	50	5	120	2,23	1,33	0,45
4	23	30.000	50	5	140	2,45	1,45	0,46
5	23	30.000	50	5	160	2,67	1,56	0,49
6	23	30.000	50	10	60	2,10	1,16	0,83
7	23	30.000	50	10	80	2,41	1,40	0,83
8	23	30.000	50	10	120	2,90	1,71	0,83
9	23	30.000	50	10	140	3,12	1,83	0,83
10	23	30.000	50	10	160	3,34	1,94	0,83
11	23	30.000	50	15	60	2,50	1,22	1,19
12	23	30.000	50	15	80	2,86	1,50	1,19
13	23	30.000	50	15	120	3,49	1,98	1,20
14	23	30.000	50	15	140	3,76	2,17	1,20
15	23	30.000	50	15	160	4,01	2,32	1,20
16	23	30.000	95	5	60	1,53	0,97	0,33
17	23	30.000	95	5	80	1,76	1,13	0,33
18	23	30.000	95	5	120	2,17	1,38	0,33
19	23	30.000	95	5	140	2,36	1,49	0,33
20	23	30.000	95	5	160	2,55	1,58	0,34
21	23	30.000	95	10	60	2,20	1,25	0,65
22	23	30.000	95	10	80	2,51	1,52	0,65
23	23	30.000	95	10	120	2,99	1,90	0,65
24	23	30.000	95	10	140	3,17	2,02	0,65

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
25	23	30.000	95	10	160	3,35	2,11	0,65
26	23	30.000	95	15	60	2,62	1,28	0,96
27	23	30.000	95	15	80	2,98	1,58	0,96
28	23	30.000	95	15	120	3,61	2,10	0,96
29	23	30.000	95	15	140	3,88	2,32	0,96
30	23	30.000	95	15	160	4,13	2,51	0,96
31	23	30.000	140	5	60	1,54	1,04	0,28
32	23	30.000	140	5	80	1,76	1,19	0,28
33	23	30.000	140	5	120	2,12	1,43	0,28
34	23	30.000	140	5	140	2,30	1,52	0,28
35	23	30.000	140	5	160	2,47	1,61	0,28
36	23	30.000	140	10	60	2,24	1,30	0,56
37	23	30.000	140	10	80	2,55	1,58	0,56
38	23	30.000	140	10	120	3,05	2,00	0,56
39	23	30.000	140	10	140	3,21	2,12	0,56
40	23	30.000	140	10	160	3,37	2,22	0,56
41	23	30.000	140	15	60	2,69	1,31	0,84
42	23	30.000	140	15	80	3,05	1,62	0,84
43	23	30.000	140	15	120	3,66	2,16	0,84
44	23	30.000	140	15	140	3,93	2,39	0,84
45	23	30.000	140	15	160	4,19	2,60	0,84
46	23	37.500	50	5	60	1,64	0,91	0,48
47	23	37.500	50	5	80	1,91	1,09	0,48
48	23	37.500	50	5	120	2,41	1,38	0,49
49	23	37.500	50	5	140	2,65	1,51	0,49
50	23	37.500	50	5	160	2,88	1,62	0,49

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
51	23	37.500	50	10	60	2,28	1,17	0,88
52	23	37.500	50	10	80	2,62	1,43	0,88
53	23	37.500	50	10	120	3,19	1,81	0,89
54	23	37.500	50	10	140	3,42	1,93	0,89
55	23	37.500	50	10	160	3,66	2,04	0,89
56	23	37.500	50	15	60	2,66	1,20	1,26
57	23	37.500	50	15	80	3,07	1,49	1,26
58	23	37.500	50	15	120	3,77	1,98	1,28
59	23	37.500	50	15	140	4,09	2,20	1,28
60	23	37.500	50	15	160	4,37	2,39	1,28
61	23	37.500	95	5	60	1,71	1,05	0,36
62	23	37.500	95	5	80	1,95	1,21	0,36
63	23	37.500	95	5	120	2,38	1,47	0,36
64	23	37.500	95	5	140	2,59	1,58	0,36
65	23	37.500	95	5	160	2,79	1,68	0,36
66	23	37.500	95	10	60	2,39	1,24	0,70
67	23	37.500	95	10	80	2,73	1,53	0,70
68	23	37.500	95	10	120	3,31	1,99	0,70
69	23	37.500	95	10	140	3,54	2,15	0,70
70	23	37.500	95	10	160	3,74	2,27	0,70
71	23	37.500	95	15	60	2,82	1,25	1,02
72	23	37.500	95	15	80	3,22	1,55	1,03
73	23	37.500	95	15	120	3,92	2,08	1,03
74	23	37.500	95	15	140	4,23	2,32	1,03
75	23	37.500	95	15	160	4,52	2,54	1,03
76	23	37.500	140	5	60	1,75	1,13	0,31

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
77	23	37.500	140	5	80	1,97	1,29	0,31
78	23	37.500	140	5	120	2,35	1,54	0,31
79	23	37.500	140	5	140	2,54	1,64	0,31
80	23	37.500	140	5	160	2,73	1,73	0,31
81	23	37.500	140	10	60	2,45	1,29	0,61
82	23	37.500	140	10	80	2,79	1,58	0,61
83	23	37.500	140	10	120	3,37	2,07	0,61
84	23	37.500	140	10	140	3,60	2,26	0,61
85	23	37.500	140	10	160	3,80	2,40	0,61
86	23	37.500	140	15	60	2,91	1,28	0,90
87	23	37.500	140	15	80	3,31	1,59	0,90
88	23	37.500	140	15	120	4,00	2,14	0,91
89	23	37.500	140	15	140	4,31	2,38	0,91
90	23	37.500	140	15	160	4,59	2,61	0,91
91	23	45.000	50	5	60	1,76	0,95	0,51
92	23	45.000	50	5	80	2,05	1,13	0,51
93	23	45.000	50	5	120	2,57	1,43	0,51
94	23	45.000	50	5	140	2,82	1,55	0,52
95	23	45.000	50	5	160	3,06	1,67	0,52
96	23	45.000	50	10	60	2,41	1,16	0,92
97	23	45.000	50	10	80	2,78	1,43	0,92
98	23	45.000	50	10	120	3,42	1,86	0,93
99	23	45.000	50	10	140	3,69	2,01	0,93
100	23	45.000	50	10	160	3,93	2,13	0,94
101	23	45.000	50	15	60	2,79	1,18	1,30
102	23	45.000	50	15	80	3,23	1,47	1,31

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
103	23	45.000	50	15	120	3,99	1,97	1,33
104	23	45.000	50	15	140	4,33	2,20	1,34
105	23	45.000	50	15	160	4,65	2,40	1,34
106	23	45.000	95	5	60	1,86	1,10	0,39
107	23	45.000	95	5	80	2,12	1,28	0,39
108	23	45.000	95	5	120	2,57	1,54	0,39
109	23	45.000	95	5	140	2,79	1,65	0,39
110	23	45.000	95	5	160	3,00	1,76	0,39
111	23	45.000	95	10	60	2,55	1,23	0,74
112	23	45.000	95	10	80	2,92	1,52	0,74
113	23	45.000	95	10	120	3,56	2,01	0,74
114	23	45.000	95	10	140	3,82	2,21	0,74
115	23	45.000	95	10	160	4,07	2,38	0,74
116	23	45.000	95	15	60	2,96	1,23	1,07
117	23	45.000	95	15	80	3,41	1,53	1,07
118	23	45.000	95	15	120	4,16	2,06	1,08
119	23	45.000	95	15	140	4,51	2,30	1,09
120	23	45.000	95	15	160	4,83	2,53	1,09
121	23	45.000	140	5	60	1,92	1,18	0,33
122	23	45.000	140	5	80	2,17	1,37	0,33
123	23	45.000	140	5	120	2,57	1,63	0,33
124	23	45.000	140	5	140	2,76	1,73	0,33
125	23	45.000	140	5	160	2,96	1,83	0,33
126	23	45.000	140	10	60	2,62	1,27	0,65
127	23	45.000	140	10	80	2,99	1,57	0,65
128	23	45.000	140	10	120	3,62	2,08	0,65

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
129	23	45.000	140	10	140	3,89	2,30	0,65
130	23	45.000	140	10	160	4,13	2,49	0,65
131	23	45.000	140	15	60	3,04	1,27	0,94
132	23	45.000	140	15	80	3,51	1,57	0,95
133	23	45.000	140	15	120	4,26	2,11	0,96
134	23	45.000	140	15	140	4,60	2,36	0,96
135	23	45.000	140	15	160	4,92	2,59	0,96
136	27	30.000	50	5	60	1,22	0,65	0,47
137	27	30.000	50	5	80	1,43	0,78	0,47
138	27	30.000	50	5	120	1,82	1,00	0,47
139	27	30.000	50	5	140	2,00	1,09	0,48
140	27	30.000	50	5	160	2,18	1,18	0,48
141	27	30.000	50	10	60	1,71	0,85	0,83
142	27	30.000	50	10	80	1,96	1,03	0,83
143	27	30.000	50	10	120	2,38	1,28	0,84
144	27	30.000	50	10	140	2,56	1,38	0,84
145	27	30.000	50	10	160	2,74	1,46	0,85
146	27	30.000	50	15	60	2,00	0,89	1,18
147	27	30.000	50	15	80	2,30	1,09	1,18
148	27	30.000	50	15	120	2,82	1,44	1,19
149	27	30.000	50	15	140	3,05	1,58	1,20
150	27	30.000	50	15	160	3,27	1,71	1,20
151	27	30.000	95	5	60	1,29	0,75	0,35
152	27	30.000	95	5	80	1,47	0,87	0,35
153	27	30.000	95	5	120	1,81	1,07	0,35
154	27	30.000	95	5	140	1,96	1,15	0,35

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
155	27	30.000	95	5	160	2,12	1,22	0,35
156	27	30.000	95	10	60	1,81	0,92	0,66
157	27	30.000	95	10	80	2,07	1,12	0,66
158	27	30.000	95	10	120	2,49	1,44	0,66
159	27	30.000	95	10	140	2,67	1,56	0,66
160	27	30.000	95	10	160	2,83	1,64	0,66
161	27	30.000	95	15	60	2,14	0,93	0,95
162	27	30.000	95	15	80	2,44	1,15	0,96
163	27	30.000	95	15	120	2,95	1,52	0,96
164	27	30.000	95	15	140	3,19	1,69	0,96
165	27	30.000	95	15	160	3,40	1,84	0,97
166	27	30.000	140	5	60	1,33	0,82	0,29
167	27	30.000	140	5	80	1,49	0,94	0,29
168	27	30.000	140	5	120	1,80	1,12	0,29
169	27	30.000	140	5	140	1,94	1,20	0,29
170	27	30.000	140	5	160	2,08	1,26	0,29
171	27	30.000	140	10	60	1,87	0,96	0,57
172	27	30.000	140	10	80	2,12	1,16	0,57
173	27	30.000	140	10	120	2,54	1,51	0,57
174	27	30.000	140	10	140	2,72	1,65	0,57
175	27	30.000	140	10	160	2,87	1,75	0,57
176	27	30.000	140	15	60	2,22	0,96	0,84
177	27	30.000	140	15	80	2,51	1,18	0,84
178	27	30.000	140	15	120	3,02	1,57	0,85
179	27	30.000	140	15	140	3,25	1,74	0,85
180	27	30.000	140	15	160	3,47	1,90	0,85

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
181	27	37.500	50	5	60	1,32	0,67	0,49
182	27	37.500	50	5	80	1,55	0,81	0,50
183	27	37.500	50	5	120	1,96	1,03	0,50
184	27	37.500	50	5	140	2,15	1,13	0,51
185	27	37.500	50	5	160	2,34	1,22	0,51
186	27	37.500	50	10	60	1,82	0,85	0,87
187	27	37.500	50	10	80	2,10	1,04	0,88
188	27	37.500	50	10	120	2,58	1,33	0,89
189	27	37.500	50	10	140	2,78	1,44	0,89
190	27	37.500	50	10	160	2,98	1,52	0,89
191	27	37.500	50	15	60	2,12	0,87	1,23
192	27	37.500	50	15	80	2,44	1,08	1,24
193	27	37.500	50	15	120	3,01	1,43	1,25
194	27	37.500	50	15	140	3,27	1,59	1,26
195	27	37.500	50	15	160	3,51	1,73	1,26
196	27	37.500	95	5	60	1,43	0,80	0,37
197	27	37.500	95	5	80	1,62	0,92	0,37
198	27	37.500	95	5	120	1,98	1,12	0,38
199	27	37.500	95	5	140	2,15	1,21	0,38
200	27	37.500	95	5	160	2,31	1,28	0,38
201	27	37.500	95	10	60	1,95	0,91	0,70
202	27	37.500	95	10	80	2,23	1,11	0,70
203	27	37.500	95	10	120	2,71	1,46	0,70
204	27	37.500	95	10	140	2,92	1,60	0,70
205	27	37.500	95	10	160	3,12	1,72	0,71
206	27	37.500	95	15	60	2,27	0,91	1,00

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
207	27	37.500	95	15	80	2,60	1,13	1,01
208	27	37.500	95	15	120	3,17	1,50	1,02
209	27	37.500	95	15	140	3,43	1,67	1,02
210	27	37.500	95	15	160	3,68	1,83	1,02
211	27	37.500	140	5	60	1,47	0,86	0,32
212	27	37.500	140	5	80	1,67	1,00	0,32
213	27	37.500	140	5	120	1,99	1,20	0,32
214	27	37.500	140	5	140	2,14	1,27	0,32
215	27	37.500	140	5	160	2,29	1,34	0,32
216	27	37.500	140	10	60	2,02	0,94	0,61
217	27	37.500	140	10	80	2,30	1,15	0,61
218	27	37.500	140	10	120	2,78	1,52	0,61
219	27	37.500	140	10	140	2,99	1,67	0,62
220	27	37.500	140	10	160	3,18	1,81	0,62
221	27	37.500	140	15	60	2,35	0,94	0,89
222	27	37.500	140	15	80	2,69	1,15	0,89
223	27	37.500	140	15	120	3,26	1,54	0,90
224	27	37.500	140	15	140	3,51	1,72	0,90
225	27	37.500	140	15	160	3,76	1,89	0,90
226	27	45.000	50	5	60	1,41	0,69	0,52
227	27	45.000	50	5	80	1,64	0,83	0,52
228	27	45.000	50	5	120	2,07	1,06	0,52
229	27	45.000	50	5	140	2,28	1,16	0,53
230	27	45.000	50	5	160	2,48	1,25	0,53
231	27	45.000	50	10	60	1,91	0,84	0,90
232	27	45.000	50	10	80	2,21	1,04	0,91

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
233	27	45.000	50	10	120	2,73	1,35	0,92
234	27	45.000	50	10	140	2,96	1,47	0,92
235	27	45.000	50	10	160	3,18	1,57	0,93
236	27	45.000	50	15	60	2,20	0,86	1,26
237	27	45.000	50	15	80	2,54	1,06	1,27
238	27	45.000	50	15	120	3,15	1,42	1,29
239	27	45.000	50	15	140	3,43	1,58	1,30
240	27	45.000	50	15	160	3,70	1,73	1,31
241	27	45.000	95	5	60	1,54	0,82	0,40
242	27	45.000	95	5	80	1,76	0,96	0,40
243	27	45.000	95	5	120	2,13	1,17	0,40
244	27	45.000	95	5	140	2,30	1,25	0,40
245	27	45.000	95	5	160	2,48	1,33	0,40
246	27	45.000	95	10	60	2,06	0,89	0,73
247	27	45.000	95	10	80	2,36	1,10	0,73
248	27	45.000	95	10	120	2,89	1,46	0,74
249	27	45.000	95	10	140	3,12	1,61	0,74
250	27	45.000	95	10	160	3,34	1,75	0,74
251	27	45.000	95	15	60	2,35	0,90	1,03
252	27	45.000	95	15	80	2,72	1,11	1,04
253	27	45.000	95	15	120	3,33	1,48	1,06
254	27	45.000	95	15	140	3,61	1,65	1,06
255	27	45.000	95	15	160	3,88	1,82	1,07
256	27	45.000	140	5	60	1,59	0,88	0,34
257	27	45.000	140	5	80	1,81	1,04	0,34
258	27	45.000	140	5	120	2,16	1,26	0,34

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
259	27	45.000	140	5	140	2,32	1,34	0,34
260	27	45.000	140	5	160	2,48	1,41	0,34
261	27	45.000	140	10	60	2,15	0,92	0,64
262	27	45.000	140	10	80	2,45	1,14	0,64
263	27	45.000	140	10	120	2,97	1,51	0,65
264	27	45.000	140	10	140	3,20	1,67	0,65
265	27	45.000	140	10	160	3,42	1,82	0,65
266	27	45.000	140	15	60	2,42	0,93	0,92
267	27	45.000	140	15	80	2,80	1,14	0,92
268	27	45.000	140	15	120	3,44	1,52	0,94
269	27	45.000	140	15	140	3,71	1,70	0,94
270	27	45.000	140	15	160	3,98	1,86	0,94
271	30	30.000	50	5	60	1,06	0,53	0,48
272	30	30.000	50	5	80	1,24	0,64	0,48
273	30	30.000	50	5	120	1,58	0,82	0,49
274	30	30.000	50	5	140	1,74	0,90	0,49
275	30	30.000	50	5	160	1,90	0,98	0,49
276	30	30.000	50	10	60	1,47	0,69	0,83
277	30	30.000	50	10	80	1,69	0,83	0,83
278	30	30.000	50	10	120	2,06	1,05	0,84
279	30	30.000	50	10	140	2,22	1,13	0,84
280	30	30.000	50	10	160	2,38	1,20	0,85
281	30	30.000	50	15	60	1,72	0,72	1,16
282	30	30.000	50	15	80	1,97	0,88	1,17
283	30	30.000	50	15	120	2,43	1,16	1,18
284	30	30.000	50	15	140	2,63	1,28	1,19

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
285	30	30.000	50	15	160	2,82	1,39	1,19
286	30	30.000	95	5	60	1,14	0,62	0,36
287	30	30.000	95	5	80	1,30	0,72	0,36
288	30	30.000	95	5	120	1,59	0,89	0,36
289	30	30.000	95	5	140	1,73	0,96	0,36
290	30	30.000	95	5	160	1,87	1,02	0,36
291	30	30.000	95	10	60	1,59	0,75	0,66
292	30	30.000	95	10	80	1,81	0,91	0,66
293	30	30.000	95	10	120	2,18	1,18	0,66
294	30	30.000	95	10	140	2,35	1,28	0,66
295	30	30.000	95	10	160	2,50	1,36	0,66
296	30	30.000	95	15	60	1,86	0,76	0,94
297	30	30.000	95	15	80	2,12	0,93	0,95
298	30	30.000	95	15	120	2,57	1,23	0,95
299	30	30.000	95	15	140	2,77	1,36	0,96
300	30	30.000	95	15	160	2,97	1,49	0,96
301	30	30.000	140	5	60	1,18	0,69	0,30
302	30	30.000	140	5	80	1,33	0,79	0,30
303	30	30.000	140	5	120	1,60	0,94	0,30
304	30	30.000	140	5	140	1,73	1,01	0,30
305	30	30.000	140	5	160	1,85	1,07	0,30
306	30	30.000	140	10	60	1,64	0,78	0,57
307	30	30.000	140	10	80	1,86	0,95	0,57
308	30	30.000	140	10	120	2,24	1,23	0,57
309	30	30.000	140	10	140	2,40	1,35	0,58
310	30	30.000	140	10	160	2,55	1,45	0,58

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
311	30	30.000	140	15	60	1,93	0,78	0,83
312	30	30.000	140	15	80	2,20	0,95	0,83
313	30	30.000	140	15	120	2,64	1,27	0,84
314	30	30.000	140	15	140	2,84	1,41	0,84
315	30	30.000	140	15	160	3,04	1,54	0,84
316	30	37.500	50	5	60	1,14	0,55	0,50
317	30	37.500	50	5	80	1,33	0,66	0,50
318	30	37.500	50	5	120	1,69	0,85	0,51
319	30	37.500	50	5	140	1,86	0,93	0,51
320	30	37.500	50	5	160	2,03	1,00	0,52
321	30	37.500	50	10	60	1,56	0,69	0,86
322	30	37.500	50	10	80	1,80	0,84	0,87
323	30	37.500	50	10	120	2,21	1,08	0,88
324	30	37.500	50	10	140	2,40	1,17	0,88
325	30	37.500	50	10	160	2,57	1,24	0,89
326	30	37.500	50	15	60	1,81	0,71	1,20
327	30	37.500	50	15	80	2,08	0,87	1,21
328	30	37.500	50	15	120	2,57	1,15	1,22
329	30	37.500	50	15	140	2,79	1,28	1,23
330	30	37.500	50	15	160	3,01	1,39	1,24
331	30	37.500	95	5	60	1,25	0,65	0,38
332	30	37.500	95	5	80	1,42	0,76	0,38
333	30	37.500	95	5	120	1,74	0,93	0,38
334	30	37.500	95	5	140	1,88	1,00	0,38
335	30	37.500	95	5	160	2,03	1,06	0,39
336	30	37.500	95	10	60	1,70	0,74	0,69

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
337	30	37.500	95	10	80	1,94	0,90	0,69
338	30	37.500	95	10	120	2,36	1,18	0,70
339	30	37.500	95	10	140	2,55	1,30	0,70
340	30	37.500	95	10	160	2,73	1,40	0,70
341	30	37.500	95	15	60	1,96	0,74	0,98
342	30	37.500	95	15	80	2,24	0,91	0,99
343	30	37.500	95	15	120	2,74	1,21	1,00
344	30	37.500	95	15	140	2,96	1,35	1,00
345	30	37.500	95	15	160	3,18	1,47	1,01
346	30	37.500	140	5	60	1,30	0,71	0,32
347	30	37.500	140	5	80	1,48	0,83	0,32
348	30	37.500	140	5	120	1,77	1,00	0,32
349	30	37.500	140	5	140	1,90	1,06	0,33
350	30	37.500	140	5	160	2,03	1,12	0,33
351	30	37.500	140	10	60	1,77	0,76	0,61
352	30	37.500	140	10	80	2,01	0,93	0,61
353	30	37.500	140	10	120	2,43	1,23	0,61
354	30	37.500	140	10	140	2,62	1,36	0,61
355	30	37.500	140	10	160	2,80	1,47	0,62
356	30	37.500	140	15	60	2,02	0,77	0,87
357	30	37.500	140	15	80	2,32	0,94	0,87
358	30	37.500	140	15	120	2,83	1,24	0,88
359	30	37.500	140	15	140	3,05	1,38	0,89
360	30	37.500	140	15	160	3,27	1,52	0,89
361	30	45.000	50	5	60	1,20	0,56	0,52
362	30	45.000	50	5	80	1,40	0,67	0,52

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
363	30	45.000	50	5	120	1,78	0,86	0,53
364	30	45.000	50	5	140	1,96	0,95	0,53
365	30	45.000	50	5	160	2,14	1,02	0,54
366	30	45.000	50	10	60	1,63	0,68	0,89
367	30	45.000	50	10	80	1,88	0,84	0,89
368	30	45.000	50	10	120	2,33	1,09	0,91
369	30	45.000	50	10	140	2,53	1,19	0,91
370	30	45.000	50	10	160	2,72	1,27	0,92
371	30	45.000	50	15	60	1,87	0,70	1,23
372	30	45.000	50	15	80	2,16	0,86	1,24
373	30	45.000	50	15	120	2,67	1,14	1,26
374	30	45.000	50	15	140	2,92	1,27	1,26
375	30	45.000	50	15	160	3,15	1,39	1,27
376	30	45.000	95	5	60	1,34	0,67	0,40
377	30	45.000	95	5	80	1,53	0,79	0,40
378	30	45.000	95	5	120	1,86	0,96	0,40
379	30	45.000	95	5	140	2,01	1,03	0,40
380	30	45.000	95	5	160	2,17	1,10	0,40
381	30	45.000	95	10	60	1,78	0,73	0,72
382	30	45.000	95	10	80	2,04	0,89	0,72
383	30	45.000	95	10	120	2,50	1,17	0,73
384	30	45.000	95	10	140	2,71	1,30	0,73
385	30	45.000	95	10	160	2,90	1,41	0,73
386	30	45.000	95	15	60	2,01	0,73	1,00
387	30	45.000	95	15	80	2,33	0,90	1,01
388	30	45.000	95	15	120	2,86	1,19	1,03

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)	Esforço máximo em y (MPa)	Esforço máximo em x (MPa)	Deflexão máxima (mm)
389	30	45.000	95	15	140	3,10	1,33	1,03
390	30	45.000	95	15	160	3,34	1,46	1,04
391	30	45.000	140	5	60	1,40	0,71	0,34
392	30	45.000	140	5	80	1,59	0,85	0,34
393	30	45.000	140	5	120	1,91	1,04	0,34
394	30	45.000	140	5	140	2,05	1,11	0,34
395	30	45.000	140	5	160	2,19	1,17	0,34
396	30	45.000	140	10	60	1,87	0,75	0,63
397	30	45.000	140	10	80	2,13	0,92	0,63
398	30	45.000	140	10	120	2,58	1,22	0,64
399	30	45.000	140	10	140	2,79	1,35	0,64
400	30	45.000	140	10	160	2,98	1,47	0,64
401	30	45.000	140	15	60	2,07	0,76	0,89
402	30	45.000	140	15	80	2,40	0,92	0,90
403	30	45.000	140	15	120	2,96	1,22	0,91
404	30	45.000	140	15	140	3,20	1,36	0,92
405	30	45.000	140	15	160	3,44	1,50	0,92

3.2.3 Discussão sobre os resultados

Os resultados obtidos indicam tendências claras segundo o tipo de variável avaliada. Ao comparar resultados com parâmetros semelhantes, incrementar a espessura da placa de concreto diminui o esforço máximo gerado pelo efeito combinado de carga e diferencial de temperatura (Figuras 3.7 a 3.10).

O nível de esforço gerado na placa aumenta com o incremento da carga (Figura 3.5). Nesse sentido, tomando como exemplo os casos 1 a 5, 136 a 140 e 271 a 275, fica evidenciado que um para uma mesma espessura de placa a tensão máxima pode variar mais de 40 % ao comparar a respostas obtidas para cargas de 60 kN e de 160 kN para o ESRD (Tabela 3.6).




Figura 3.5 – Comportamento de esforço por variação de carga

Tabela 3.6 – Porcentagem de variação do esforço máximo segundo variação de carga

Espessura	Varição entre esforços com carga min. e máx. (%)
23	44,2
27	44,1
30	62,5

Referente à variação do esforço máximo segundo a variação de espessura, foram comparados os esforços obtidos nas placas com espessuras de 23 cm e de 30 cm para cada nível de carregamento. Os resultados indicam uma variação de esforço superior a 28 % (Tabela 3.7), observando-se de fato uma relação biunívoca entre carga e tensão para mesmas espessuras de placa.

Tabela 3.7 – Porcentagem de variação do esforço máximo segundo variação de espessura

Carga de eixo (kN)	Varição entre esforços com espessura min. (23 cm) e máx. (30 cm) (%)
60	29,4
80	29,4
120	29,2
140	29,0
160	28,9

Comportamento semelhante é identificado ao se comparar casos com variações de diferencial de temperatura (ΔT) entre topo e fundo das placas de concreto (Figura 3.6). Nessa condição, incrementar o diferencial de temperatura de 5 °C a 15 °C representa elevar o esforço máximo na infraestrutura. A Tabela 3.8 apresenta a porcentagem de variação de esforço por diferencial de temperatura para placas com 23 cm (casos 1, 6 e 11), 27 cm (casos 136, 141 e 146) e 30 cm (casos 271, 276 e 281), sendo calculadas porcentagens de variação de até de 40 %.




Figura 3.6 – Comportamento de esforço por variação de ΔT

Tabela 3.8 – Porcentagem de variação do esforço máximo segundo variação de ΔT

Espessura	Varição entre esforços com ΔT min. e máx. (%)
23	40,1
27	39,1
30	38,6

O módulo de elasticidade (E) foi outra das variáveis consideradas nesta etapa de projeto. Os modelos mostram como incrementar o valor de módulo incrementa o esforço máximo nas placas (Figura 3.7), o que era esperado pois a tensão é diretamente proporcional à rigidez da placa ($E \cdot h^3/12$).

Para exemplificar esse comportamento, foram selecionados os casos 1, 46 e 91 para espessuras de placas de 23 cm, os casos 136, 181 e 226 para espessuras de placas de 27 cm, e os casos 271, 316 e 361 para espessuras de 30 cm. As comparações indicam um incremento de até 15 % devido ao incremento no valor do módulo de elasticidade do concreto (Tabela 3.9).




Figura 3.7 – Comportamento de esforço por variação de módulo de elasticidade

Tabela 3.9 – Porcentagem de variação do esforço máximo segundo variação de módulo de elasticidade

Espessura (cm)	Variação entre esforços com $E_{min.}$ e $E_{máx.}$ (%)
23	15,1
27	13,5
30	12,2

Em relação ao módulo de reação do subleito (k), os resultados indicam um leve incremento no esforço máximo ao variar o valor de 50 MPa/m para 140 MPa/m (Figura 3.8). Tomando como exemplo os casos 1, 16 e 31 para placas com espessura de 23 cm, casos 136, 151 e 166 para placas com espessuras de 27 cm e casos 271, 286 e 301 para placas de 30 cm, as comparações indicam que as variações de esforços entre valores extremos de k não superam o 11 % (Tabela 3.10).




Figura 3.8 – Comportamento de esforço por variação de módulo de reação do subleito

Tabela 3.10 – Porcentagem de variação do esforço máximo segundo variação de módulo de reação do subleito

Espessura	Varição entre esforços com $k_{min.}$ e $k_{máx.}$ (%)
23	3,2
27	7,9
30	10,8

Dos resultados obtidos das simulações por elementos finitos empregando ISLAB é identificado a sensibilidade da resposta estrutural da infraestrutura ante as variações das condições presentes na etapa de serviço. Das variáveis consideradas, espessura de placas, nível de carga, diferencial térmico entre topo e fundo de placas apresentaram as maiores porcentagens de variações (28 % a 63 %). Seguido das porcentagens de até 15 % obtidos ao modificar o módulo de elasticidade do concreto.

Finalmente, o módulo de reação do subleito foi a variável com menor influência na mudança de esforços com valores entre 3,2 % e 10,8 % de variação. Esse comportamento já foi descrito anteriormente por Balbo (2009) e pode ser explicado pela definição teórica do conceito do parâmetro de módulo de reação do subleito.

4. COMPARAÇÃO PRELIMINAR DAS RESPOSTAS FEA 2D VERSUS FEA 3D

Devido às limitações próprias das hipóteses para modelagem de pavimentos de concreto por elementos finitos em 2D, que restringem à representação de fenômenos tridimensionais, o presente estudo iniciou a etapa de desenvolvimento de modelos de pavimentos por elementos finitos 3D, conforme previsto no escopo original.

Com esse objetivo, recentemente foi licenciado e instalado o programa ABAQUS/CAE 2026 para modelamento por elementos finitos 3D. Para cumprir com as exigências requeridas na elaboração das simulações computacionais, foi adquirida uma workstation Intel Xeon w3-2535 com 10 núcleos e 20 processadores lógicos, 64 GB de memória RAM, 2 TB de armazenamento e placa de vídeo NVIDIA RTX A1000.

Como avaliação preliminar das respostas estruturais para PCS fornecidas pelo ABAQUS, foi desenvolvido o caso de análise de uma placa de concreto isolada de 3,60 m x 5 m (largura e comprimento), com espessura de 23 cm. A placa é dimensionada no módulo *Part*. Nessa etapa também é definida, na superfície da placa, a área correspondente à aplicação das cargas sobre a infraestrutura.

Para o presente estudo, foi considerada uma carga de 15 kN aplicada em uma área quadrada de 30 cm x 30 cm, representando a carga de roda de um ESRD de 60 kN, posicionada a 45 cm da borda longitudinal. Na Figura 4.1 é apresentada a imagem gráfica de placa discretizada em elementos finitos, gerada pela interface gráfica do ABAQUS.




Figura 4.1 – Placa isolada carregada modelada no ABAQUS

O valor de carga aplicada é introduzido em termos de pressão sobre a superfície. Portanto, é calculada a relação entre carga de roda e área carregada, que é o valor especificado no módulo *Load* do programa (Figura 4.2).

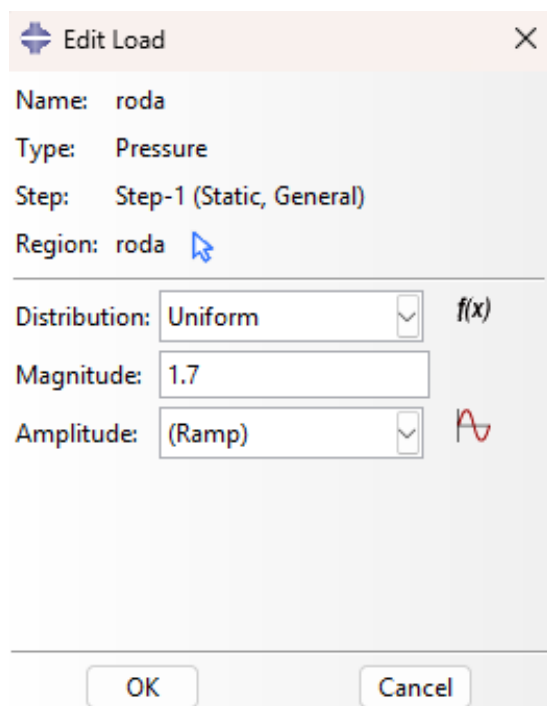


Figura 4.2 – Definição de pressão de carga aplicada na infraestrutura

Por ser um caso simplificado preliminar comparativo, não foram consideradas BT em juntas transversais, nem ocorrência de diferencial de temperatura entre topo e fundo da placa. Os parâmetros referentes ao concreto foram adotados coerentemente com os valores empregados nos casos modelados com o ISLAB, selecionado o módulo de elasticidade de 30.000 MPa, peso específico do concreto de 2400 kg/m³ e coeficiente de Poisson de 0,2 para o material. As especificações requeridas sobre os materiais foram introduzidas no módulo *Property* (Figura 4.3)

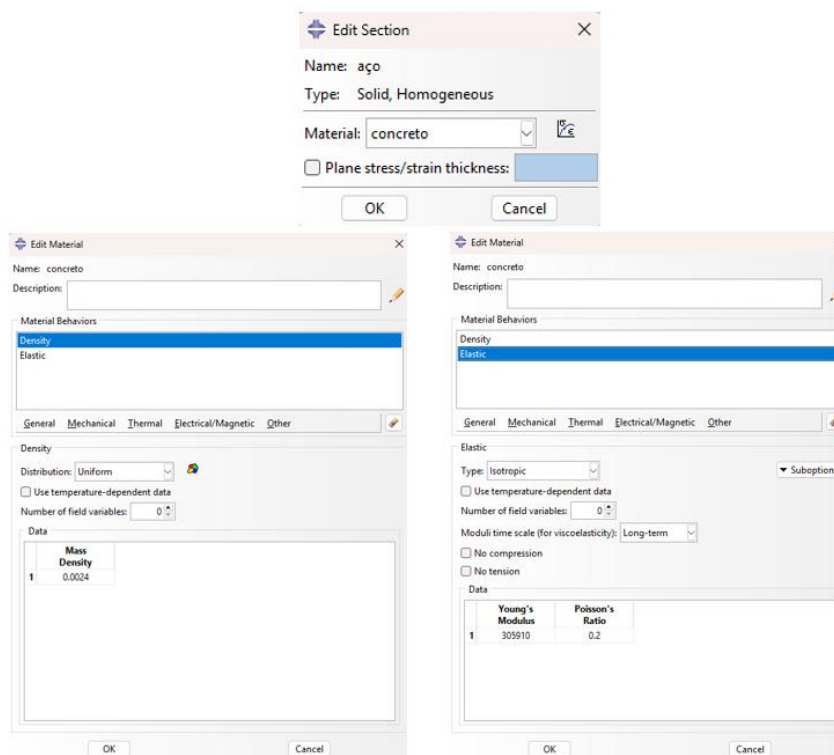


Figura 4.3 – Definição dos parâmetros de materiais

A placa simulada encontra-se apoiada sobre uma fundação de *Winkler* (líquido denso representado por molas idênticas abaixo de cada nós da placa discretizada) com módulo de reação do subleito de 50 MPa/m. Para modelar essa condição, foi definida, no módulo *Assembly*, uma interação na face inferior da placa, de modo a representar o comportamento de fundação elástica. Como dado de entrada, o programa solicita o valor da rigidez da fundação, i.e., o módulo de reação do subleito (Figura 4.4).




Figura 4.4 – Placa de concreto apoiada sobre fundação elástica

No módulo *Mesh* do ABAQUS é caracterizada a discretização e tipo de malha juntamente aos elementos que compõe a malha, cada uma das partes do modelo. Para o presente estudo¹⁷ foi selecionado elemento de malha do tipo Hex C3D8R, correspondentes a elementos de blocos hexaédricos 3D de 8 nós, com integração reduzida (Figura 4.5).

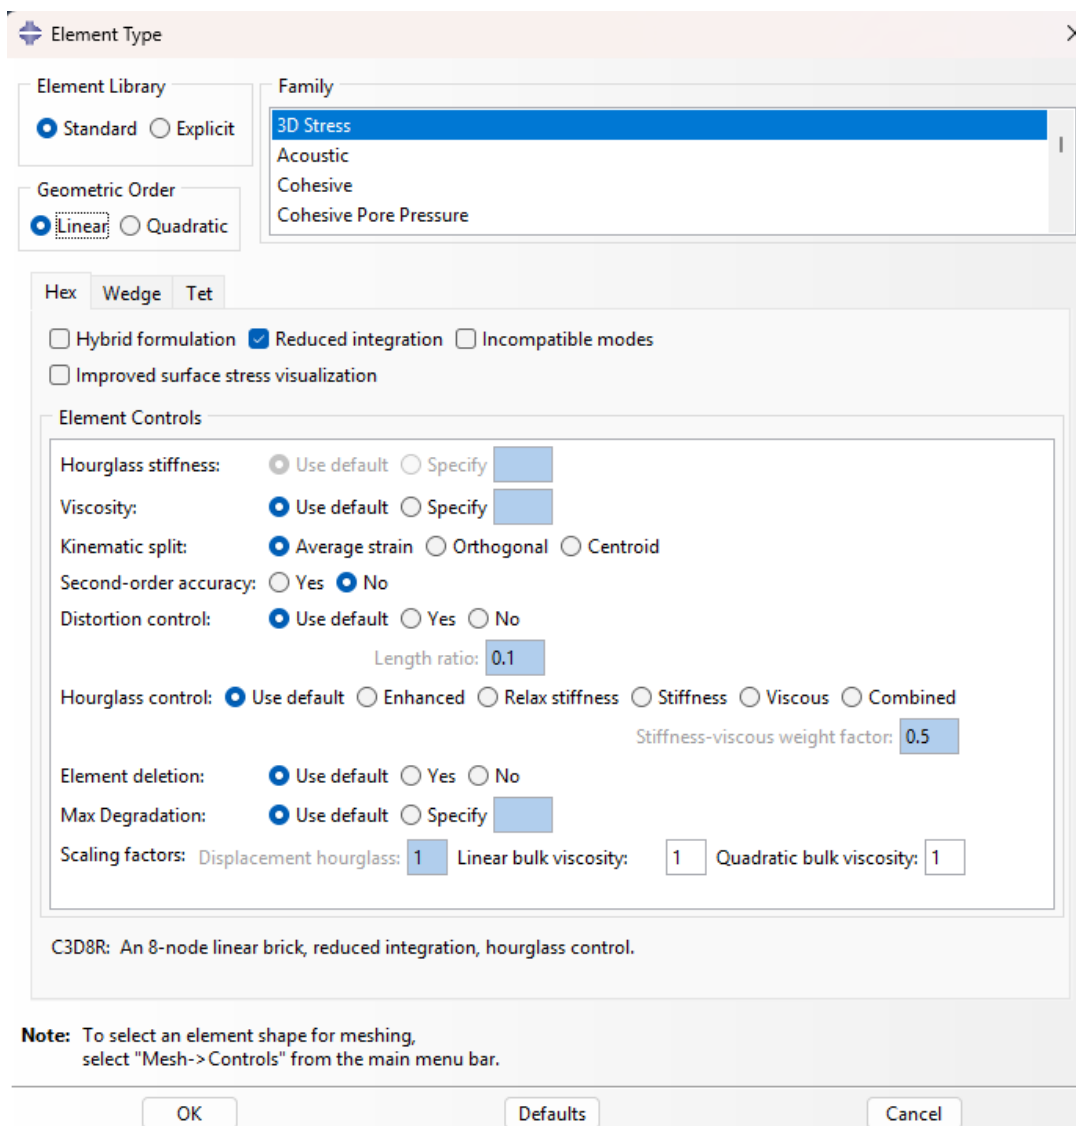


Figura 4.5 – Seleção do tipo de elemento que compõe a malha

¹⁷ Na sequência dos trabalhos, eventualmente, outros elementos para representar as peças finitas de concreto serão avaliados.

A partir da definição da malha obtém-se a discretização do modelo em pequenos elementos de blocos interligados entre si por meio de nós (Figura 4.6). Assim, no momento da aplicação da carga, cada nó apresenta uma reação decorrente não apenas da carga aplicada, mas também da sua interação com os nós vizinhos, em função das relações de continuidade impostas pelo modelo numérico.




Figura 4.6 – Malha gerada na placa isolada modelada no ABAQUS

Os esforços máximos obtidos na modelagem são apresentados nas Figuras 4.7 e 4.8. Na Figura 4.9 apresenta-se a deflexão máxima resultante da aplicação da carga.




Figura 4.7 – Esforço máximo na direção x




Figura 4.8 – Esforço máximo na direção y




Figura 4.9 – Deflexão na placa isolada

Os resultados obtidos por meio do ABAQUS foram comparados com aqueles fornecidos pelo ISLAB. Para isso, foi realizado o procedimento de inserção dos dados de entrada, conforme descrito na seção de metodologia no presente documento (item 3). Os valores de esforços máximos e de deflexão obtidos por ambos os programas são apresentados na Tabela 4.1.

Tabela 4.1 – Esforços máximos e deflexão obtidos em placa isolada

Software	Esforço máximo y (MPa)	Esforço máximo x (MPa)	Deflexão (mm)
ABAQUS	0,427	0,223	0,12
ISLAB	0,423	0,279	0,10

Os resultados apresentam semelhança entre si, evidenciando coerência na entre as modelagens numéricas por FEA analisadas. Contudo, considerando a capacidade do programa 3D em refinar a configuração de malha do sistema modelado e a flexibilidade na definição das condições de contorno dos casos a modelar, espera-se uma convergência mais representativa do comportamento gerado em condições reais de serviço. Portanto, novos casos de estudo estão sendo desenvolvidos e ampliados visando representar com maior fidelidade o comportamento observado em PCS e WT.

No Apêndice B são apresentadas as imagens de saída oferecidas pelos dois programas empregados nos presentes estudos preliminares.

5. IDENTIFICAÇÃO DE REGIÕES DE CLIMA HOMOGÊNEO NO BRASIL

5.1 CLASSIFICAÇÃO CLIMÁTICA

Classificações climáticas consistem no agrupamento de dados climatológicos em classes com base em condições e variabilidades similares. Esse agrupamento facilita a análise espacial das características e variabilidades que ocorrem dentro de uma região ou país, além de permitir a observação da relação entre o clima e os sistemas físicos e biológicos, como topografia e vegetação.

A primeira classificação climática foi desenvolvida por Köppen em 1900, sendo que posteriormente diversas adaptações foram desenvolvidas (Köppen, 1936; Geiger, 1954, 1961). A classificação de Köppen-Geiger, um dos métodos mais frequentemente utilizado, é baseada na relação da vegetação com o clima e considera limiares de precipitação e temperatura mensais e anuais. (Kottek *et al.*, 2006; Belda *et al.*, 2014; Rahimi, Laux e Khalili, 2020).

Lima *et al.* (2023) utilizaram a classificação de Köppen-Geiger para avaliar o impacto das mudanças climáticas no Brasil. A comparação entre o cenário atual e o cenário de maior emissão de gases do efeito estufa (RCP 8.5) mostra diminuição da prevalência do clima tropical de floresta e monção, com expansão dos climas áridos e de savana. Esse impacto está principalmente relacionado com a mudança nos padrões de chuvas, e indica a possibilidade de futuras alterações nas classes identificadas considerando o clima atual. O que alerta para futuras alterações em padrões técnicos para os projetos de infraestrutura rodoviária, com efeito, para as situações de necessidade de predição de diferenciais térmicos em PCS e WT, especificamente.

A classificação climática possui diversas aplicabilidades em agricultura, engenharia de transportes, gestão de recursos hídricos, na identificação de áreas suscetíveis a inundações ou ondas de calor, no estudo de mudanças climáticas e no setor de energia (Lyra, Oliveira-Júnior e Zeri, 2014; Carvalho *et al.*, 2016; Yang *et al.*, 2020; Sa'adi, Shahid e Shiru, 2021; Souza *et al.*, 2022). Yang *et al.* (2020) utilizaram uma classificação climática para avaliar o desempenho de pavimentos asfálticos em relação às variáveis atmosféricas em cada região climática.

Com o avanço de métodos estatísticos, novas técnicas foram desenvolvidas para agrupar dados climatológicos, possibilitando a inclusão de novas variáveis e gerando resultados mais precisos (Netzel e Stepinski, 2016; Abbasi *et al.*, 2022; Lasantha, Oki e Tokuda, 2022).

Importa ao presente projeto em desenvolvimento, a modelagem do clima para previsão de temperaturas atmosféricas, umidade relativa do ar e níveis de insolação ou radiação solar, para finalidades de previsão da temperatura de superfícies em concreto empregadas para a construção de PCS e WT, por meio de uma clusterização consistente de áreas no território brasileiro.

5.2 ANÁLISE DE CLUSTER

O objetivo da análise de cluster é a divisão e agrupamento de dados em classes ou clusters de maneira que os objetos dentro de cada classe apresentem similaridades. Em outras palavras, a análise de cluster consiste na junção de dados em grupos homogêneos e distintos. É uma técnica empregada em diversos estudos para classificação climática (Lyra, Oliveira-Júnior e Zeri, 2014; Carvalho *et al.*, 2016; Netzel e Stepinski, 2016; Martins Monteiro e Martins, 2019; Yang *et al.*, 2020; Machado *et al.*, 2021; Sa'adi, Shahid e Shiru, 2021; Souza *et al.*, 2022).

A análise de cluster é feita sem a necessidade de conhecimento prévio da classificação dos dados. Existem diversas metodologias para análise cluster, a saber: k-means; Ward; ISODATA; Redes Neurais Probabilísticas; Random Forest; X-means; Fuzzy-cmeans. Grande parte dos estudos de classificação climática utilizam as técnicas K-means e Ward (Lyra, Oliveira-Júnior e Zeri, 2014; Carvalho *et al.*, 2016; Yang *et al.*, 2020; Sa'adi, Shahid e Shiru, 2021; Lasantha, Oki e Tokuda, 2022; Souza *et al.*, 2022). As metodologias diferem entre si na definição do que constitui um cluster e como identificá-los. Os métodos podem ser hierárquicos, não hierárquicos, baseados em densidade, ou agrupamento difuso.

Nos métodos hierárquicos (por exemplo, o Ward) a classificação consiste em uma série de partições que pode partir de um único grupo contendo todos os indivíduos, até n grupos, cada um contendo um único indivíduo; ou partir de n grupos cada um contendo um único indivíduo até um único grupo contendo todos os indivíduos. O método é finalizado em um passo intermediário contendo um número de clusters pré-definido.

Uma desvantagem de métodos hierárquicos é que, assim que os dados são atribuídos a um grupo, eles (os dados) não podem ser removidos, ou seja, o método não permite realocação de dados. Nos métodos não hierárquicos, como é o caso do K-means, o número de clusters é também escolhido previamente; de tal sorte que o centro de cada cluster é determinado, e os dados são atribuídos aos clusters baseando-se na distância entre o dado e o centro de cada classe. Por meio de um método iterativo, os dados podem ser realocados até que os centroides permaneçam relativamente estáveis. Portanto, a vantagem com relação a métodos hierárquicos é que este permite a realocação de dados.

O agrupamento baseado em densidade identifica grupos distintos partindo da ideia de que um grupo em um espaço de dados é uma região contígua de alta densidade de pontos, separada de outros agrupamentos por regiões esparsas. Os pontos nessas regiões esparsas são considerados como discrepantes (*outliers*). Inclusive, esse tipo de metodologia pode ser também utilizada para identificação de *outliers* em um conjunto de dados. Um exemplo de agrupamento baseado em densidade é o DBSCAN.

No agrupamento difuso, diferente dos anteriores, os pontos de dados podem pertencer a mais de um cluster, e associados a cada um dos pontos estão os níveis de associação que indicam o grau em que os pontos de dados pertencem aos diferentes clusters. Neste caso, assume-se que o número de clusters é conhecido, e a função de pertinência ou associação de cada objeto em cada cluster é estimada usando-se um método iterativo (Everitt *et al.*, 2011).

5.3 METODOLOGIA PARA CLUSTERIZAÇÃO

5.3.1 Dados empregados

Dois conjuntos de dados foram utilizados nas análises de cluster:

- o primeiro consiste em dados meteorológicos das estações de superfície operadas pelo Instituto Nacional de Meteorologia (INMET);
- o segundo é uma combinação de dados de reanálise do ERA5 e de precipitação do MERGE.

Na Tabela 5.1 é apresentado um resumo dos conjuntos de dados utilizados, bem como as variáveis selecionadas de cada conjunto. Temperatura de orvalho é a temperatura que o ar deve ser resfriado para atingir saturação, sendo uma medida de umidade.

Tabela 5.1 – Conjunto de dados utilizados nas análises de cluster

Conjunto de dados	Variáveis utilizadas	Resolução espacial	Resolução temporal
Estações de superfície INMET	Temperatura Temperatura máxima Temperatura mínima Temperatura do ponto de orvalho Radiação solar incidente na superfície Radiação solar máxima Precipitação Velocidade do vento		Horário, diário e mensal ^a
ERA5-Land	Temperatura Temperatura máxima Temperatura mínima Temperatura do ponto de orvalho Radiação solar incidente na superfície Velocidade do vento	0,01 x 0,01.º	Horário, diário, mensal
MERGE	Precipitação	0,01 x 0,01.º	Horário, diário, médias e acumulados mensais e anuais

^aDados de radiação solar estão apenas disponíveis na frequência horária.

O ERA5 (*fifth generation of European ReAnalysis*) é um conjunto de dados de reanálise gerado pelo ECMWF (*European Centre for Medium-Range Weather Forecasts*). A reanálise combina dados de modelo com observações de todo o mundo em um conjunto de dados globalmente completo e consistente usando as leis da física. Esse processo é chamado de assimilação de dados e é baseado no método utilizado por modelos numéricos de previsão de tempo em que, a cada determinado período, a saída do modelo é combinada com novas observações disponíveis, de forma a produzir uma melhor estimativa do estado da atmosfera. O ERA5 utiliza dados de observação de diversas fontes no processo de assimilação como dados de satélite, radiossondagens, estações de superfície, medidas realizadas por aeronaves, radares etc. (Hersbach *et al.*, 2020).

O ERA5-Land é um conjunto de dados aprimorados que integra o ERA5 com foco nas porções de terra (Muñoz-Sabater *et al.*, 2021). Os dados possuem maior resolução espacial do que os dados do ERA5. O ERA5-Land possui 50 variáveis disponíveis globalmente a cada hora, com resolução espacial de 9 km a partir do ano de 1950.

O MERGE é um produto de precipitação desenvolvido pelo Centro de Previsão de Tempo e Estudos Climáticos (CPTEC) que combina precipitação estimada por satélite com dados de pluviômetros (Rozante *et al.*, 2010, 2020). O MERGE possui resolução espacial de $0,1^\circ \times 0,1^\circ$, com dados diários e climatológicos disponíveis a partir de 1998. De maneira geral, o MERGE apresenta melhores estimativas de precipitação para o Brasil e América do Sul do que outros produtos de precipitação (Rozante *et al.*, 2010; Cassalho *et al.*, 2020; Reis *et al.*, 2020).

As estações de superfície do INMET, apresentadas na Figura 5.1, possuem dados disponíveis a partir do ano 2000. Os dados possuem resolução temporal de 1 hora, mas também podem ser obtidos com frequência diária ou como médias mensais.




Figura 5.1 – Localização das estações de superfície operadas pelo INMET

Neste trabalho, foram utilizadas as médias sazonais das variáveis descritas na Tabela 5.1 para a realização das classificações. Apesar de possuírem a mesma resolução, as grades dos dados do ERA5-Land e do MERGE não coincidem. Em face da circunstância, utilizando a interpolação por vizinhos mais próximos (*nearest neighbor*), os dados do MERGE foram colocados na mesma grade dos dados do ERA5-Land. Para o cálculo das médias sazonais dos dados do ERA5-Land foram utilizados 30 anos de dados, abrangendo o período 1991-2020, como proposto pela Organização Meteorológica Mundial (OMM). Para os dados do MERGE, as médias foram calculadas para o todo o período disponível.

Para os dados das estações do INMET, antes da aplicação das metodologias de cluster para a análise dos dados e decisão, foi feita uma análise de consistência utilizando o intervalo interquartil (IQR) para identificação de *outliers*.

5.3.2 Metodologias para análise de cluster

Após discussões no âmbito da equipe de pesquisa, foram selecionadas cinco metodologias para classificação climática do Brasil. São elas:

- Ward;
- K-means;
- X-Means;
- K-medoids;
- Fuzzy C-means.

A descrição que se segue dos métodos Ward e K-means foi compilada a partir de Wilks (2019).

Ward é um método de clusterização hierárquico, que se inicia considerando que o conjunto de dados consiste de n grupos contendo uma observação cada. O primeiro passo é encontrar dois grupos que estão mais próximos e combiná-los em um novo grupo. Em cada passo subsequente, os dois grupos mais próximos são combinados para formar um grupo maior. No método de Ward, de todas as maneiras possíveis de agrupar dois grupos, os pares a serem misturados são escolhidos de modo a minimizar a soma do quadrado da distância entre os pontos e o centroide (média) de cada grupo, somada entre todos os clusters.

Resumidamente, o método Ward busca minimizar a soma das variâncias dentro dos grupos. O processo continua até que no passo final todas as observações estejam agrupadas em um único grupo. A ideia é que em algum ponto entre o primeiro e o último passo, os dados estarão agrupados de maneira a apresentar informações relevantes sobre aquele conjunto de dados. Portanto, é necessário definir previamente o número desejado de clusters. Uma desvantagem de métodos hierárquicos como Ward, é que assim que os dados são atribuídos a um grupo, não podem ser removidos posteriormente, ou seja, o método não permite realocação de dados.

Métodos não hierárquicos também agrupam os dados de acordo com uma medida de distância. O K-means é um exemplo desse tipo de clusterização e tem como objetivo minimizar a soma dos quadrados dos erros de predição. Inicialmente, os centros dos clusters são selecionados; após a inicialização, a técnica consiste em fazer um *loop* entre duas etapas.

Na primeira, os dados são atribuídos para o cluster mais próximo baseado na distância entre o dado e o centroide. Após isso, novos centroides são determinados pela média de todos os valores atribuídos a cada cluster. A distância entre os dados e os novos centroides é recalculada e as observações que não estão mais próximas são movidas até que os centroides permanecem relativamente estáveis.

A métrica de distância do K-means é a Euclidiana. A inicialização dos centroides pode ser feita de forma aleatória ou pelo K-means ++. No K-means++ a inicialização começa com a escolha aleatória do primeiro centroide. Para os subsequentes, é calculada a distância de cada ponto para o centroide já existente; após isso, o próximo centroide é escolhido com probabilidade proporcional ao quadrado dessa distância. Pontos mais distantes de centroides já existentes tem maior chance de serem selecionados. A necessidade de especificar os centroides iniciais é uma desvantagem do método K-means.

O K-medoids é um algoritmo de agrupamento baseado em partições, sendo similar ao K-means. No entanto, diferente do K-means, que utiliza média dos pontos como centroides, o K-medoids seleciona pontos de dados reais (medóides) como centros do cluster. O número de clusters também deve ser previamente selecionado. Como descrito em Madhulatha (2011), o método possui seis passos:

- a) seleção arbitrária dos medóides;
- b) os dados são associados aos medóides similares, sendo que a similaridade é definida por uma medida de distância que pode ser Euclidiana, Manhattan ou Minkowski;
- c) seleção arbitrária de outro ponto (não medóide) de cada cluster;
- d) verificação do custo da troca do medóide pelo ponto selecionado no passo anterior, ou seja, verifica-se se a troca reduziria a soma total das distâncias;
- e) se o custo calculado for menor que 0, o medóide inicial é trocado pelo novo;
- f) repete os passos 2 a 5 até que não ocorra alteração nos medóides.

O X-means é um método baseado no algoritmo K-means, porém tendo sido desenvolvido para superar as desvantagens do antigo método. Neste caso, o número de clusters não precisa ser definido previamente; apenas os números mínimos e máximos de classes são especificados e o algoritmo determina a melhor escolha (Pelleg, Moore, e Others, 2000).

O método é inicializado considerando um número mínimo de clusters. O X-means entra em ação após cada execução do K-means, tomando decisões sobre qual subconjunto dos centroides atuais deve se dividir para obter um melhor ajuste.

A decisão de divisão é feita calculando o *critério de informação Bayesiano* (BIC). Por exemplo, se um cluster é dividido em dois, e se o BIC score é maior para os clusters divididos, a separação é aceita. O algoritmo é finalizado quando o número máximo de clusters pré-determinado é atingido, ou quando as divisões não apresentam melhoras no BIC score.

O Fuzzy C-means é um algoritmo de agrupamento difuso, em que, como mencionado na seção anterior, cada ponto pode estar associado a mais de um cluster e para cada ponto é associado um grau de pertinência que varia de 0 a 1. O método segue os seguintes passos:

- a) inicialização do algoritmo, igual ao do K-means, com a necessidade de determinação prévia do número de clusters;
- b) os graus de pertinência são calculados para cada ponto com relação a cada cluster. O grau de pertinência é relacionado ao inverso da distância entre o ponto e o centróide;
- c) os novos centróides são calculados pela média dos pontos ponderada pelo grau de pertinência.

O método é iterativo e repete os passos 2 e 3 até que a variação cumulativa dos graus de pertinência entre duas iterações seja menor que um limiar pré-definido (Kononenko e Kukar, 2007).

A avaliação dos resultados foi realizada por meio de diversos índices, descritos na Tabela 5.2 e por análise visual da distribuição espacial das classes; assim, foi possível escolher a melhor metodologia e o número mais apropriado de cluster.

Da mesma maneira, os resultados obtidos com os dados do INMET e com os dados do ERA5-Land+MERGE também foram comparados, com a finalidade de ser identificado o melhor conjunto de dados para classificação climática do Brasil.

Tabela 5.2 – Definição dos índices utilizados na avaliação dos resultados das análises de cluster

Índices	Definição	Como analisar
Silhouette	Avalia semelhança de um dado com seu próprio cluster em comparação com os outros clusters.	Varia entre -1 e 1, quanto maior o score melhor o resultado.
Davies-Bouldin	Representa a similaridade média entre os clusters, sendo a similaridade uma medida que compara a distância entre os agrupamentos com o tamanho dos próprios agrupamentos.	Valor mínimo igual a 0. Quanto menor e mais próximo de zero o score, melhor o resultado.
SDBw	Avalia a variância intra-cluster e a separação inter-cluster (calculado considerando a densidade). É uma soma entre os dois termos.	O menor valor do índice indica o melhor resultado.

5.3.3 Nomenclatura dos clusters

As classes obtidas pelas análises de cluster foram nomeadas de acordo com as características médias de temperatura e de precipitação de cada cluster, considerando a classificação climática de Köppen-Geiger apresentada na Tabela 5.3. A classificação possui mais duas classes, frio e polar, que não estão descritas na referida tabela, pois não ocorrem no Brasil. A nomeação dos clusters a partir da classificação de Köppen-Geiger facilita a identificação das características climáticas de cada classe.

Tabela 5.3 – Critérios e definições da classificação de Köppen-Geiger

Tipo/Subtipo	Descrição	Critério
	Tropical	$T_{frio} > 18.^\circ \text{ C}$
A	f Tropical floresta	0 a 2 meses com precipitação < 60 mm
	m Tropical de monção	$P_{seco} \geq 100 - (P_{anual}/25)$
	w Tropical de savana	$P_{seco} \leq 100 - (P_{anual}/25)$
	Árido	$P_{anual} < 10 * P_{th}$
B	W Deserto	$P_{anual} < 5 * P_{th}$
	S Estepe (Semiárido)	$P_{anual} \geq 5 * P_{th}$
	h Frio	$T_{anual} \geq 18.^\circ \text{ C}$
	k Quente	$T_{anual} < 18.^\circ \text{ C}$
	Subtropical	$T_{quente} > 10.^\circ \text{ C}$ e $0 < T_{frio} < 18.^\circ \text{ C}$
C	s Verão seco	$P_{sdry} < 40$ e $P_{sdry} < P_{wwet}/3$
	w Inverno seco	$P_{wdry} < P_{swet}/10$
	f Sem estação seca	Nem C_s ou C_w
	a Verão quente	$T_{quente} \geq 22$
	b Verão ameno	$T_{mon10} \geq 4$
	c Verão frio	$1 \leq T_{mon10} < 4$

T_{anual} = Temperatura do ar média anual;

T_{frio} = Temperatura do ar no mês mais frio;

T_{quente} = Temperatura do ar no mês mais quente;

T_{mon10} = número de meses com temperatura do ar $>10.^\circ \text{ C}$;

P_{anual} = Precipitação média anual;

P_{seco} = Precipitação do mês mais seco;

P_{sdry} = Precipitação do mês mais seco no verão;

P_{wdry} = Precipitação do mês mais seco no inverno;

P_{swet} = Precipitação do mês mais chuvoso no verão;

P_{wwet} = Precipitação do mês mais chuvoso no inverno;

$P_{th} = 2 * T_{anual}$ se $>70\%$ da precipitação ocorre no inverno;

$P_{th} = 2 * T_{anual} + 28$ se $>70\%$ da precipitação ocorre no verão;

ou $P_{th} = 2 * T_{anual} + 14$.

Verão (inverno) corresponde ao período de seis meses mais quentes (frios) entre Outubro – Março (Abril – Setembro). Adaptado de (Beck *et al.*, 2018).

5.4 RESULTADOS OBTIDOS PARA CLUSTERIZAÇÃO

5.4.1 Estação de superfície INMET

Utilizado os dados de estações de superfície, as variáveis mencionadas acima foram combinadas de maneira a gerar três testes. O objetivo dos testes é identificar a melhor combinação dos dados que ao mesmo tempo possa contemplar as variáveis relevantes para temperatura de superfície e desempenho de pavimentos, e obter resultados coerentes.

As variáveis usadas em cada teste são apresentadas na tabela 5.4. No primeiro teste, a velocidade do vento não foi utilizada, mas como é um parâmetro importante, foi incluída posteriormente nos testes 2 e 3. Os testes foram realizados para três números de clusters, nominalmente, 8, 9 e 10. Lembrando que no X-means o número de clusters não é definido, apenas o número máximo. Neste caso, utilizou-se 8, 9 e 10 clusters como número máximo, e assim, a própria metodologia determinou o número ideal de classes, que acabou sendo igual ao máximo.

Os índices avaliados e apresentados na Figura 5.2 indicam que, de maneira geral, os resultados para todas as metodologias são superiores para o teste 1, ou seja, quando a velocidade do vento não é incluída.

Considerando as análises para os três testes, os piores resultados são obtidos pelo método Ward para o teste 1, e Ward e K-medoids para os testes 2 e 3. Isso é particularmente visto pelas análises dos índices Silhouette e Davies-Bouldin, enquanto a diferença dos valores do índice Sdbw entre as metodologias tende a ser menor.

O Xmeans e Fuzzy C-means se mostram como metodologias mais adequadas para as análises de clusters para o Brasil. Para o teste 1, o melhor resultado foi obtido pelo Xmeans para 10 clusters, o que pode ser concluído pela observação de que o índice Silhouette possui o maior valor, enquanto os índices Davies-Bouldin e Sdbw apresentam os menores valores em comparação com às demais metodologias.

Tabela 5.4 – Variáveis utilizadas em cada teste nas análises de cluster

Variáveis	
Temperatura	Teste 1
Temperatura máxima	
Temperatura mínima	
Temperatura do ponto de orvalho	
Radiação solar incidente na superfície	
Radiação solar máxima	
Precipitação	Teste 2
Temperatura	
Temperatura máxima	
Temperatura mínima	
Temperatura do ponto de orvalho	
Radiação solar incidente na superfície	
Radiação solar máxima	Teste 3
Precipitação	
Velocidade do vento	
Temperatura	
Temperatura máxima	
Temperatura mínima	
Temperatura do ponto de orvalho	
Radiação solar incidente na superfície	
Precipitação	
Velocidade do vento	




Figura 5.2 – Índices Silhouette (a) Davies-Bouldin (b) Sdbw (c) calculados para os três testes utilizando 8, 9 e 10 clusters

As metodologias Ward e Kmedoids possuem alto custo computacional. No primeiro caso é necessária memória suficiente para realocar os dados; já no segundo caso, o tempo de processamento é elevado e cada análise de cluster consumiu em torno de 10 minutos. Considerando ainda os resultados acima discutidos, conclui-se que ambas não possuem bom custo-benefício para análise de clusters no Brasil.

Com relação à inclusão da velocidade do vento nas análises, o teste 3, de maneira geral, apresenta resultados melhores que o teste 2. Os melhores resultados para o teste 2 foram obtidos pelo Fuzzy C-means para 10 clusters. Para o teste 3, os valores dos índices para o Xmeans e Fuzzy C-means são similares, mas novamente indicam 10 como número ideal de clusters. Como mencionado anteriormente, a velocidade do vento é um parâmetro relevante para temperatura de superfície de pavimentos; portanto, pode-se considerar que a combinação de dados mais adequada é a utilizada no teste 3 (Figura 5.3).

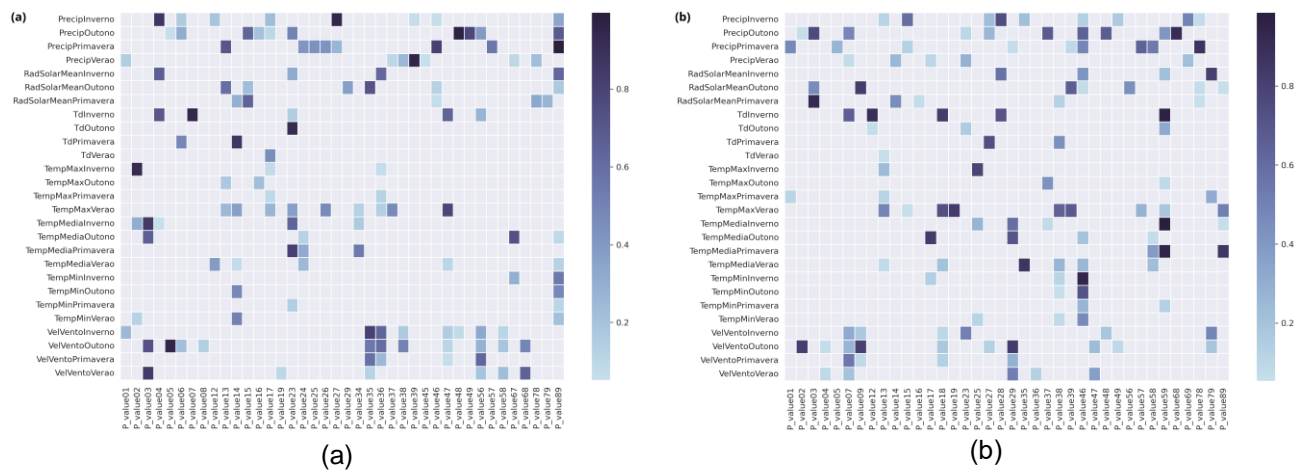


Figura 5.3 – Heatmap com os resultados do Mann-Whitney para o Xmeans (esquerda) e Fuzzy C-means (direita) utilizando 10 clusters. Quadrados sombreados para valores acima de 0,05

Antes da análise espacial dos resultados, o teste Mann-Whitney foi aplicado com intuito de auxiliar na decisão da melhor metodologia para o teste 3. O teste não paramétrico de Mann-Whitney é usado para se verificar se dois grupos pertencem ou não à mesma população. Para isso, o teste avalia a igualdade das medianas. O teste foi aplicado para cada variável e os clusters foram comparadas entre si. O nível de significância para o teste é de 0,05, ou seja, se o valor de p calculado pelo teste para dois clusters for maior que 0,05, a hipótese nula não pode ser rejeitada e a diferença entre os clusters não é estatisticamente significativa.

Na Figura 5.3 foram apresentados heatmaps com os resultados. Em sombreado estão apresentados apenas os valores de p acima de 0,05, portanto, quanto maior o número de quadrados sombreados, maior o número de clusters que não possuem diferenças estatisticamente significativas. Por exemplo, olhando para a última coluna do gráfico à esquerda (para o Xmeans), tem-se o valor de p obtido pelo teste para comparação dos clusters 8 e 9 para cada variável considerada. Nota-se, neste caso, que a diferença não é estatisticamente significativa para precipitação no outono, inverno e primavera. A comparação das imagens revela novamente que os resultados obtidos são adequados para ambas as metodologias, já que não se observam diferenças nas quantidades de clusters que não possuem diferença estatisticamente significativa.

O resultado de clusterização apresentado na Figura 5.4 para o Xmeans, sem a utilização da velocidade do vento nas análises, mostra alguns padrões relacionados com a topografia do país, biomas e a distribuição sazonal de chuva.

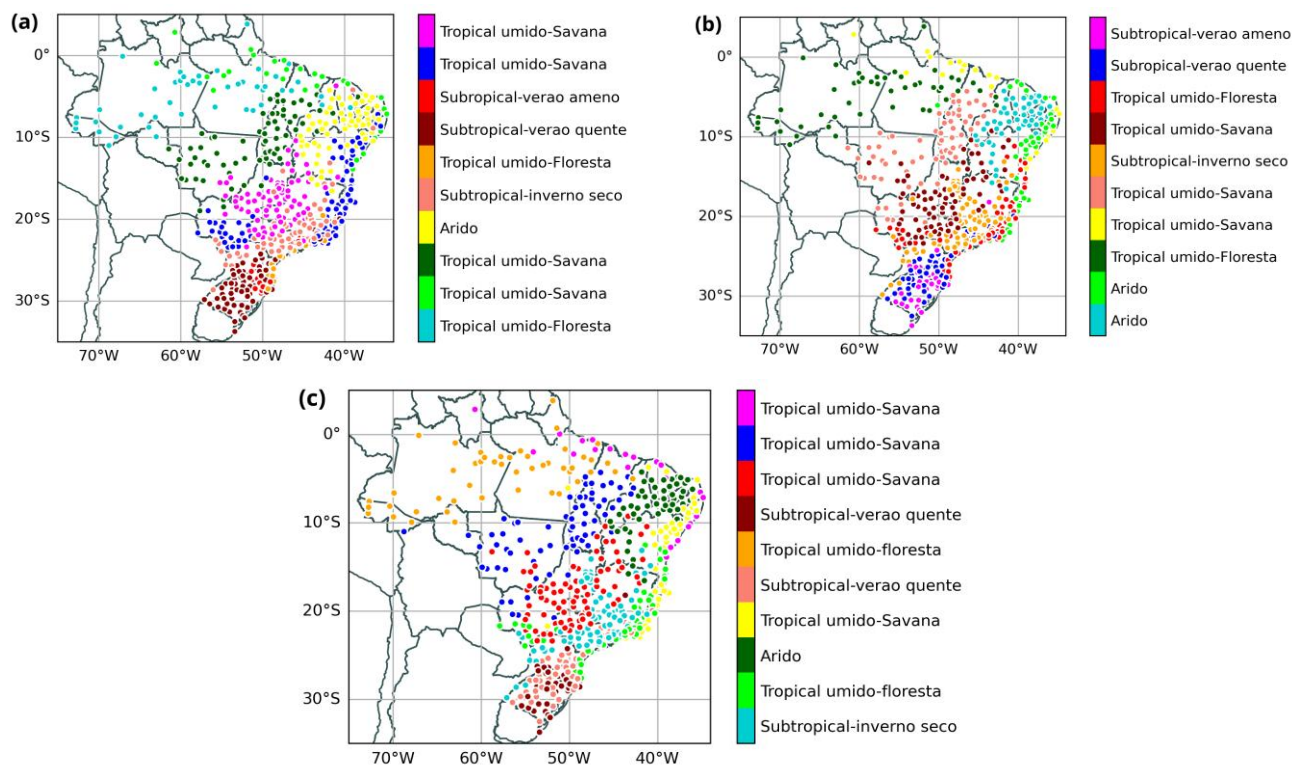


Figura 5.4 – Nomenclatura obtida pela mediana dos clusters utilizando os critérios indicados na Tabela 5.3: (a) resultados das análises de cluster para o teste 1 com o Xmeans; (b) para o teste 3 com o Xmeans e (c) Fuzzy C-means.

Para a região Sul do território brasileiro, a classificação a partir das características médias dos clusters identifica um predomínio das classes subtropicais com ausência de estação seca, o que é coerente do ponto de vista climático. Destaca-se inclusive o cluster em vermelho na região da Serra Catarinense.

A classe subtropical de inverno seco aparece se estendendo do norte do Paraná e abrangendo as áreas mais elevadas do Sudeste, como a Serra do Mar, Serra da Mantiqueira, Região Serrana do Rio de Janeiro e Espírito Santo. O que novamente é coerente, sendo que essa região possui uma estação seca bem definida no período de Junho/Julho/Agosto (JJA). Inclusive, o clima no norte do Paraná tende a ser mais próximo de São Paulo do que o restante da região Sul, e a análise de clusters consegue identificar esse padrão.

O cluster em laranja (Tropical de Floresta) compreende áreas mais baixas da costa de Santa Catarina, Paraná e São Paulo. A região do cluster em amarelo, classificada como árido, contempla a região da Caatinga no Nordeste brasileiro. O bioma Amazônico aparece dividido em duas classes, em azul e verde-claro no mapa, classificadas como Tropical de Floresta e de Savana, respectivamente. Inclusive o cluster verde-claro se estende pelo litoral do nordeste, região de Mata Atlântica. Nessas áreas, o máximo de precipitação ocorre nos meses de JJA.

No entanto, a região Norte do Brasil poderia ter mais divisões, já que o padrão de chuva apresenta máximo na parte sul em Dezembro/Janeiro/Fevereiro (DJF), na parte central em Março/Abril/Maio (MAM) e em JJA no extremo norte. Pela análise visual dos resultados conclui-se que, pelo menos, 10 clusters devem ser efetivamente considerados para representar a variabilidade sazonal no Brasil.

Os resultados para o teste 3, ou seja, com a inclusão da velocidade do vento nas análises, é muito similar entre as metodologias Xmeans e Fuzzy C-Means, com exceção de algumas diferenças pontuais. Neste caso, observa-se novamente o predomínio das classes subtropicais no Sul do Brasil, mas a região da Serra Catarinense não aparece mais destacada em um cluster. O cluster subtropical de inverno seco abrange o norte do Paraná, áreas mais altas de São Paulo, Minas Gerais, só que diferentemente da análise anterior, também se estende pelas áreas de topografia mais elevadas em Goiás. Essa área pertence à classe Tropical de Savana no teste 1, classe esta que também contempla o oeste de São Paulo, parte de Minas Gerais, e pequenas áreas de Mato Grosso e Mato Grosso do Sul.

Da perspectiva climática, a classificação obtida incluindo a velocidade do vento (teste 3) não é tão coerente quanto à obtida no teste 1, já que as áreas mais centrais de Minas Gerais e de Goiás são mais quentes que o restante do cluster.

Na análise com o Xmeans para o teste 3, a característica média do cluster em verde-claro que se estende pelo Nordeste e costa do Rio de Janeiro e Espírito Santo, é de clima árido, o que novamente não é razoável considerando a variabilidade sazonal dos estados do Sudeste. Na análise utilizando o Fuzzy C-means, esse cluster, devido a algumas diferenças, possui características médias de clima Tropical de Savana, sendo mais coerente. No entanto, o problema na região Sudeste e Central com a classe Subtropical de Inverno Seco, também aparece com o Fuzzy C-means.

A região de clima árido é maior no teste 1. Tal diferença ocorre em razão do padrão da variabilidade espacial e sazonal da velocidade do vento. Os resultados são similares para a região Norte entre as duas metodologias e nos dois testes apresentados.

De maneira geral, no teste 1 é possível observar maior relação com características físicas e padrões de variabilidade de chuva e temperatura, apesar de alguns problemas discutidos. Com os dados das estações de superfície, não foi possível chegar a um resultado satisfatório com a inclusão de todas as variáveis relevantes para temperatura e desempenho de pavimentos de concreto. Uma das possíveis explicações é a baixa densidade em algumas áreas. Assim como o número de clusters, ou seja, é possível que para um maior número de variáveis utilizadas, mais clusters devam ser considerados. Essas hipóteses serão avaliadas na sequência.

5.4.2 ERA5-Land e MERGE

Considerando os resultados e a discussão da seção anterior, optou-se por não utilizar as metodologias Ward e Kmedoids, cujos resultados foram inferiores do que os obtidos com o restante das metodologias, não compensando pelo alto custo computacional de ambas. Ainda mais tendo em vista que o conjunto de dados composto pelo ERA5-Land + MERGE possui maior densidade espacial e, portanto, um número de pontos muito maior.

As variáveis utilizadas nas análises de cluster são apresentadas na Tabela 5.5. A análise foi inicialmente realizada sem a média sazonal da velocidade do vento, que em segundo teste posterior, foi incluída.

Tabela 5.5 – Variáveis utilizadas nas análises de cluster

Teste	Variáveis
1	Temperatura 2 m
	Temperatura máxima 2 m
	Temperatura mínima 2 m
	Temperatura do ponto de orvalho 2 m
	Radiação solar incidente na superfície
	Precipitação
2	Temperatura
	Temperatura máxima 2 m
	Temperatura mínima 2 m
	Temperatura do ponto de orvalho 2 m
	Radiação solar incidente na superfície
	Precipitação
	Velocidade do vento a 10 m

Na Figura 5.5 são apresentados os índices calculados para os dois testes utilizando as três metodologias selecionadas, assim como também apresenta uma comparação com os índices obtidos para o teste 3 (ver Tabela 5.4) com os dados das estações de superfície. Todos os índices indicam que os resultados com o ERA5-Land+MERGE são superiores aos obtidos com o outro conjunto de dados. Isso está possivelmente relacionado com a consistência temporal e cobertura espacial dos dados.

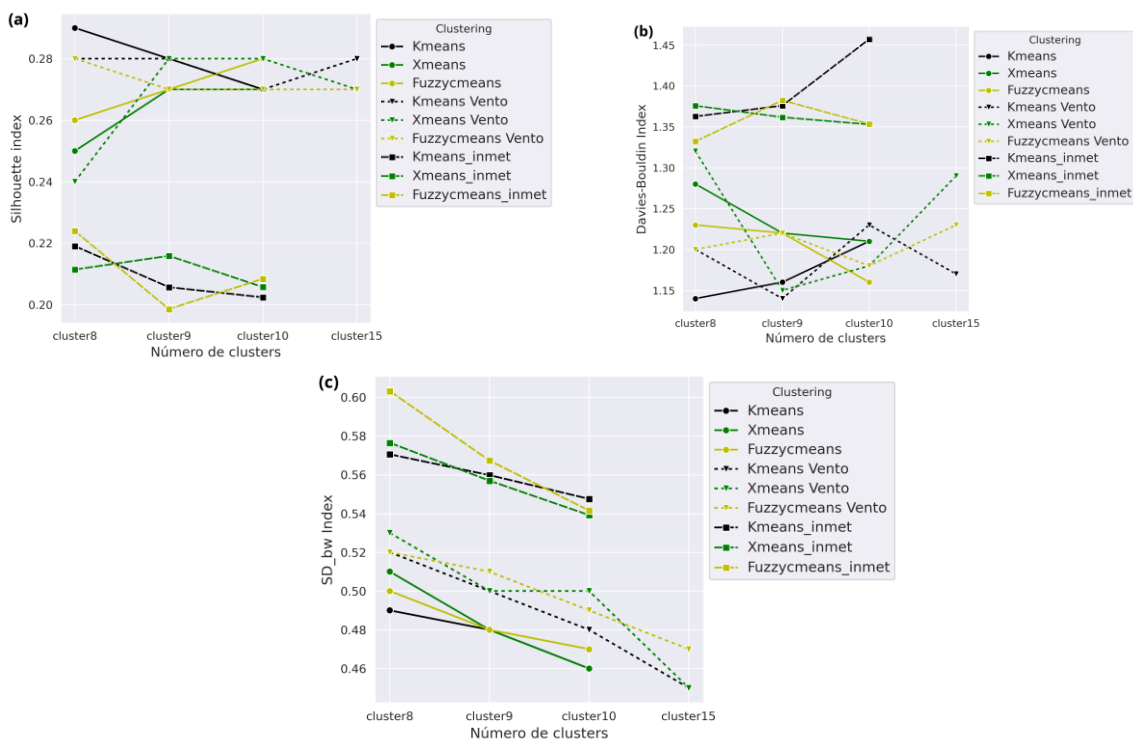


Figura 5.5 – Índices calculados para os dois testes com os dados do ERA5-Land+MERGE e teste 3 com os dados das estações de superfície: (a) Silhouette; (b) Davies-Bouldin e (c) Sdbw

Com relação aos resultados obtidos com o ERA5-Land + MERGE, apenas o índice Sdbw indica uma perda de qualidade nos resultados com a inclusão da velocidade do vento. O índice Sdbw mostra que o número ideal de clusters para as três metodologias e em ambos os testes é 10. Ainda de acordo com este índice, no primeiro teste, o Xmeans apresenta resultados melhores, enquanto no segundo teste, o Kmeans é ligeiramente superior. Já os outros índices apresentam variações com relação a melhor metodologia e o melhor número de clusters.

Aqui é importante lembrar que a discussão da seção anterior mostrou que o número mínimo de 10 clusters é necessário para compreender as variabilidades sazonais e as características físicas do Brasil. Assim, não apenas as análises dos índices são importantes, mas também a análise espacial dos resultados.

No primeiro teste, o Fuzzy C-means e o Xmeans são superiores ao Kmeans para 10 clusters. Já no segundo, os resultados são mais variáveis. Assim, da mesma maneira que na seção anterior, o teste de Mann-Whitney foi utilizado para auxiliar na escolha da melhor metodologia.

Na Figura 5.6 é apresentado o *heatmap* com os resultados do teste Mann-Whitney para as metodologias Kmeans, Xmeans e Fuzzy C-means, considerando a velocidade do vento nas análises de cluster para 10 classes. Observa-se novamente que os resultados são melhores do que os obtidos com os dados das estações do INMET, já que um número bem maior de clusters apresenta diferenças significativas. Pela análise da Figura 5.6, dentre as três metodologias analisadas, o Kmeans e Fuzzy C-means apresentam resultados superiores, já que o Xmeans possui um número ligeiramente maior de clusters que não possuem diferenças significativas.




Figura 5.6 – Heatmap com os resultados do Mann-Whitney para o Kmeans (a), Xmeans (b) e Fuzzy C-means (c) utilizando 10 clusters para o teste 2. Quadrados sombreados para valores acima de 0,05

Na Figura 5.7 são apresentados os resultados das análises para o Brasil, obtidos com as três metodologias, para 10 clusters, considerando as variáveis do teste 2. Os clusters obtidos pelo Kmeans e Fuzzy C-means são similares. Nestas duas análises, o bioma Amazônico possui o predomínio de quatro clusters, dois com características tropicais de floresta e dois, tropicais de savana. Essa divisão consegue contemplar melhor as variações sazonais de precipitação na região do que os resultados discutidos na seção anterior.

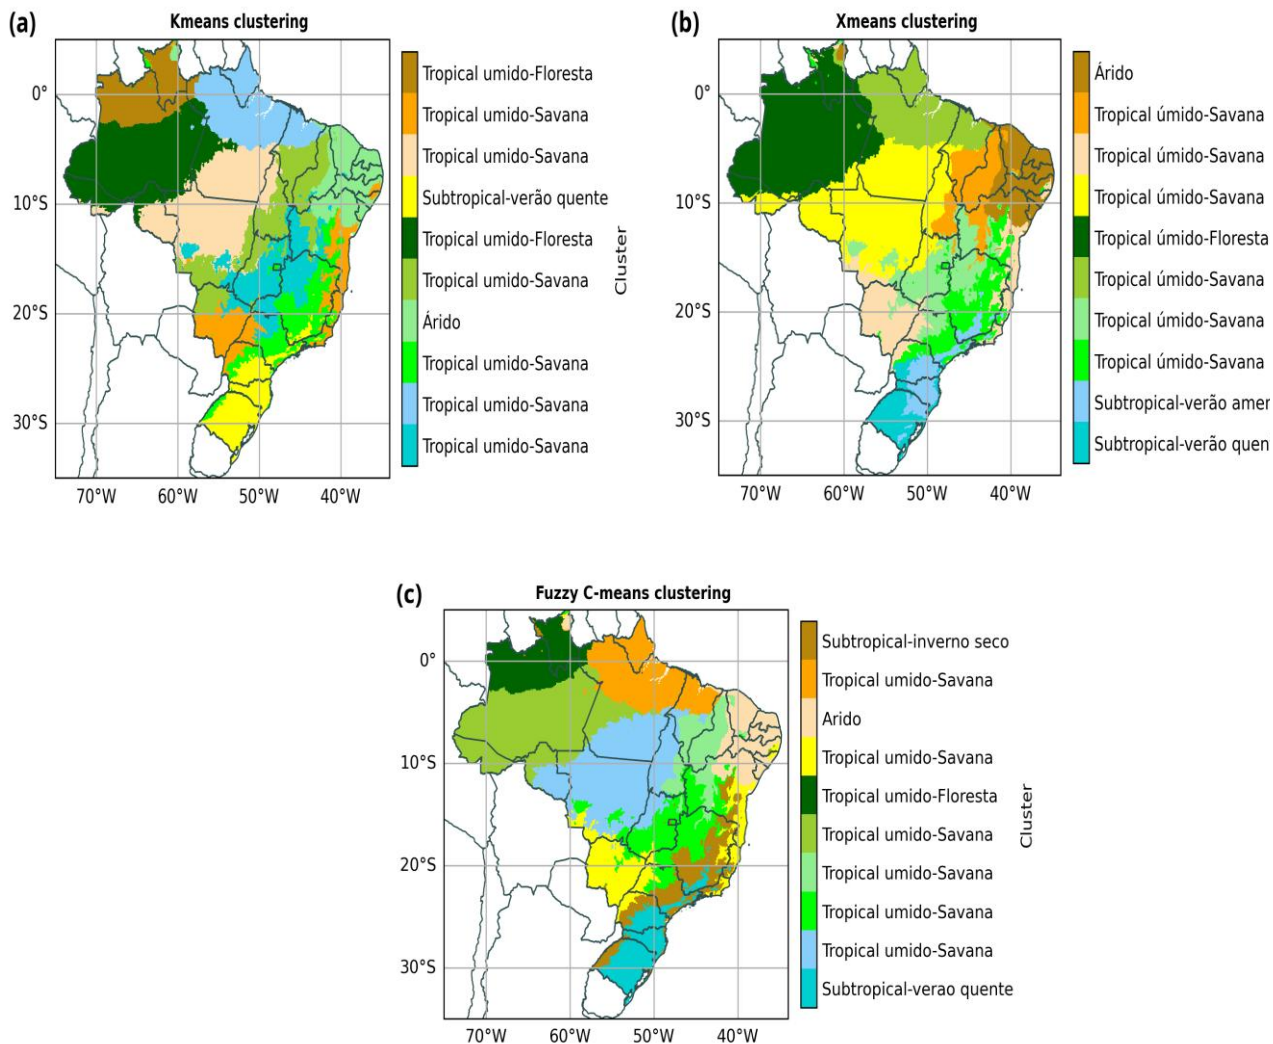


Figura 5.7 – Resultados das análises de cluster para o Brasil utilizando as metodologias Kmeans (a), Xmeans (b) e Fuzzy C-means (c). Nomenclatura obtida pela mediana dos clusters utilizando os critérios mostrados na Tabela 5.3

Nos resultados com o Xmeans, o bioma Amazônico está dividido, em grande parte, em três clusters. No Sul e Sudeste do Brasil, o Kmeans e o Fuzzy C-means identificam um cluster classificado como Subtropical de verão quente, que abrange grande parte dos estados do Sul e se estende pelas regiões da Serra do Mar e Serra da Mantiqueira, no Sudeste. É uma região bastante ampla e seriam necessários mais clusters para melhor representação da variabilidade climática destas áreas.

Assim como o cluster classificado como Tropical de savana no Kmeans e Subtropical de inverno seco no Fuzzy C-means que contempla o oeste do Rio Grande do Sul, norte do Paraná, parte de São Paulo, Minas Gerais e Bahia, também necessitaria, do ponto de vista climático, de mais divisões. O Xmeans, no entanto, apresenta uma divisão melhor para regiões Sul e Sudeste. A região Sul do Brasil aparece dividida em dois clusters com características subtropicais, sendo que um deles, classificado como subtropical de verão ameno, se estende por áreas de topografia elevada no Sul e Sudeste.

A divisão das classes climáticas no Nordeste e Centro-Oeste brasileiros são similares nos resultados obtidos pelas três metodologias. No Nordeste, destaca-se o cluster com características de clima árido na região da Caatinga.

Considerando as discussões sobre os resultados das análises de clusters trazidas nesta e na seção anterior, foram realizadas algumas tentativas de aumentar o número de clusters para verificar se as características físicas e as variabilidades sazonais das variáveis atmosféricas poderiam ser melhor representadas.

Como os resultados com os dados do ERA5-Land + MERGE se mostraram superiores ao obtidos com os dados de estações de superfície, as análises com aumento no número de clusters foram conduzidas apenas para esse conjunto de dados. Como no Xmeans não é necessário definir o número de clusters previamente, apenas o máximo, procedeu-se a teste com esta metodologia em que foi estabelecido um número máximo de 20 clusters. O Xmeans identificou 15 clusters para o Brasil. Com isso, as análises com o Kmeans e Fuzzy C-means foram novamente realizadas, desta feita com 15 clusters. Os índices para esses resultados também são apresentados e comparados na Figura 5.8.

Os três índices analisados indicam melhoras nos resultados com o Kmeans com o aumento no número de cluster de 10 para 15. Inclusive, das três metodologias, o Kmeans se mostra como a ferramenta mais adequada. Pela análise do Mann-Whitney teste (Figura 5.8), o Kmeans é similar ao Xmeans; já o Fuzzy C-means possui ligeiramente menos clusters com diferenças significativas. O índice Sdbw também indica que o Xmeans e o Kmeans são igualmente satisfatórios.

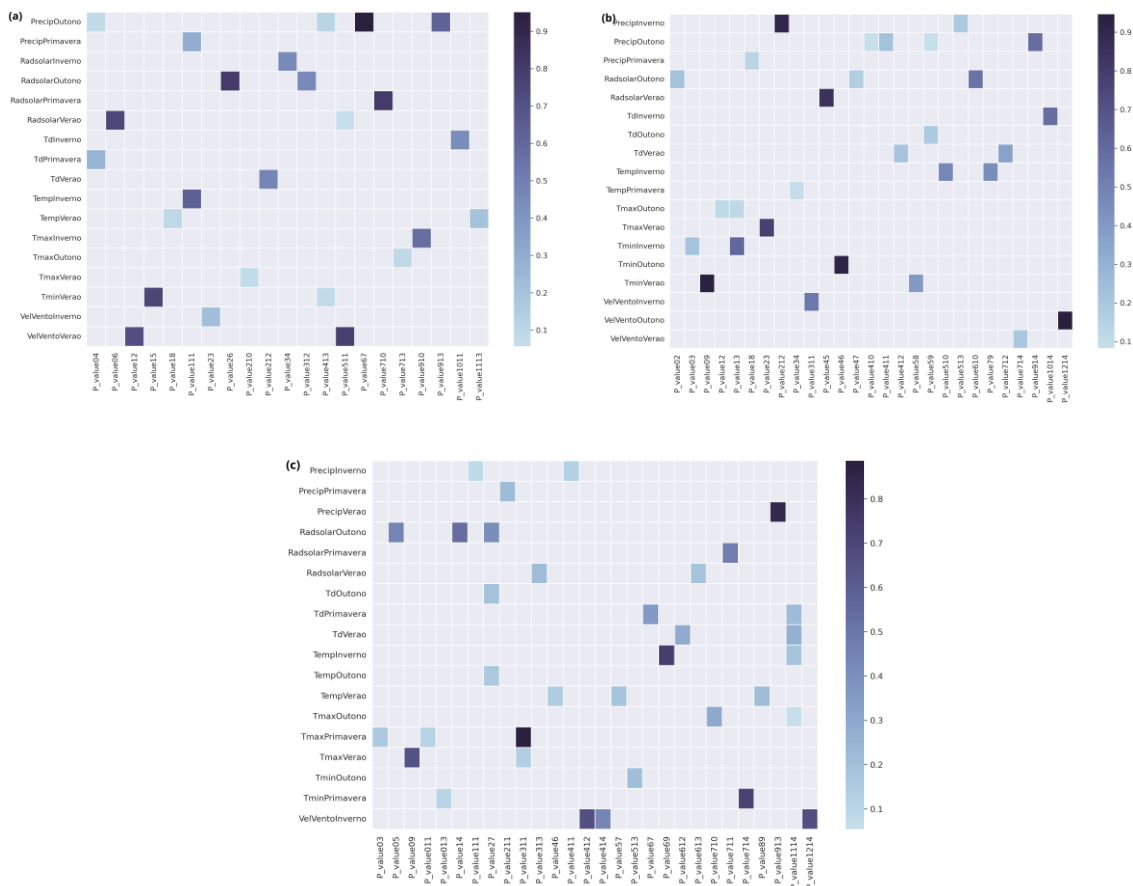


Figura 5.8 – Heatmap com os resultados do Mann-Whitney teste para o Kmeans (esquerda acima), Xmeans (direita acima) e Fuzzy C-means (abaixo) utilizando 15 clusters. Quadrados sombreados para valores acima de 0,05

Os resultados para as três metodologias com 15 clusters são apresentados na Figura 5.9. Os resultados para o Fuzzy C-means e o Kmeans se assemelham na região no bioma Amazônico, na região Sul e parte do Sudeste. Inclusive, em ambos os casos, a classificação na região do bioma Amazônico é similar àquela obtida com 10 clusters. Nessa área, dois clusters possuem clima tropical de floresta com precipitação média acumulada mensal acima de 60 mm em pelo menos 10 meses do ano. Todavia, nos dois casos, observa-se uma melhora na distribuição dos clusters nas regiões Sul e Sudeste. As áreas mais altas, correspondendo à Serra Geral, à Serra do Mar e à Serra da Mantiqueira estão agrupadas em um mesmo cluster (em azul-claro no mapa), classificado como subtropical com verão ameno.

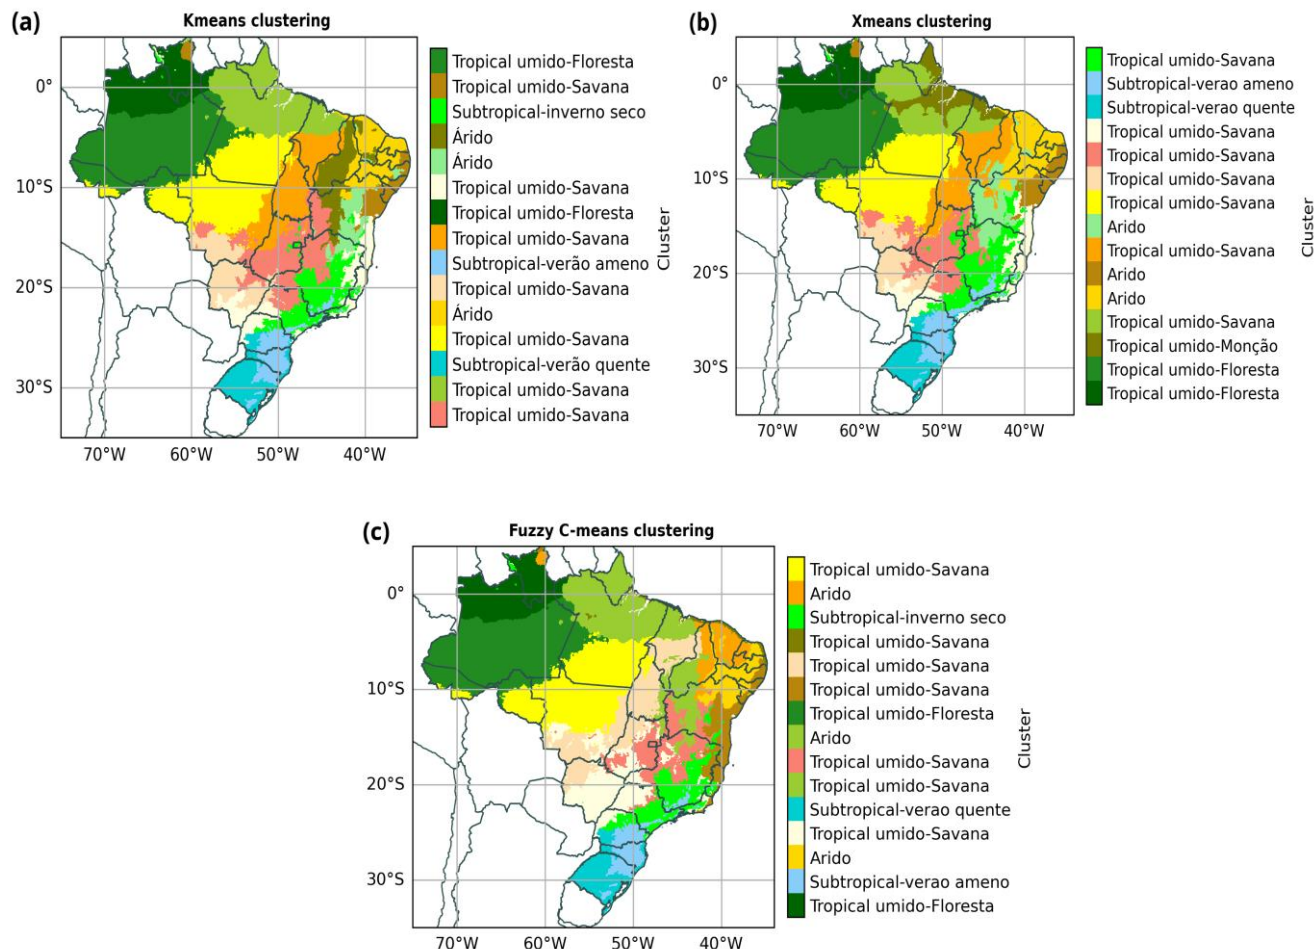


Figura 5.9 – Resultados das análises de cluster para o Brasil utilizando as metodologias Kmeans (a), Xmeans (b) e Fuzzy C-means (c) para 15 clusters. Nomenclatura obtida pela mediana dos clusters utilizando os critérios indicados na Tabela 5.3

No caso do Fuzzy C-means, o cluster ao redor em verde, com clima subtropical de inverno seco, se estende pelo norte do Paraná, São Paulo e regiões de serra em Minas Gerais, sendo coerente do ponto de vista climático, já que essas áreas possuem temperaturas mais amenas com inverno seco. Já o cluster rosa, abrange regiões de topografia (menos elevadas) em Minas Gerais, Goiás e Bahia.

A região de clima árido aparece nesse caso dividida em três clusters, que abrangem a Caatinga e parte do Cerrado. A costa do Nordeste fica separada em outro cluster (em marrom) que se estende pelo litoral do Sudeste. Toda essa área é caracterizada como região de planície. Observa-se um cluster pequeno contornando o litoral norte do Nordeste e da região Norte.

Esse cluster caracteriza uma área com velocidade do vento mais intensa, principalmente na primavera. Entretanto, a distribuição sazonal de chuva não é similar ao longo desta faixa; isto se torna mais evidente no trimestre de MAM, em que o norte do Pará e Maranhão atingem o pico de chuva com acumulados médios acima de 1.000 mm, enquanto em outras áreas os acumulados ficam abaixo de 300 mm.

Nos resultados com o Kmeans, o cluster em verde, classificado como subtropical de inverno seco, é similar ao obtido com o Fuzzy C-means, no entanto, também abrange áreas mais elevadas em Goiás neste caso. O cluster em rosa se estende por uma região mais ampla nesta análise, contemplando grande parte da área central do cerrado. Outro ponto de destaque é que, com o Kmeans, nota-se um cluster na região do Pantanal, abrangendo também uma pequena parte do cerrado; toda essa área se caracteriza como uma planície.

O clima árido também aparece dividido em três clusters, basicamente compreendendo a região da caatinga. No entanto, no Nordeste, os resultados diferem com relação à disposição dos clusters. Novamente, o litoral do Nordeste aparece com clima tropical de savana separado do interior, mas esse cluster fica restrito à região da costa do Nordeste. Essa separação do litoral do Nordeste é importante já que é uma área com mais chuva e com máximo de precipitação no trimestre de JJA. O cluster na faixa litorânea do Norte e Nordeste não está presente nos resultados com o Kmeans.

Os resultados com o Xmeans melhoram na região Amazônica com relação à análise com 10 clusters, e se tornam similares àqueles obtidos empregando-se Kmeans e Fuzzy C-means. A diferença é a presença de um cluster no norte do Maranhão e no Pará, classificado como Tropical de Monção. Essa separação ocorre pelo padrão de distribuição sazonal de chuva, já que o acumulado nessa área no trimestre de JJA é maior do que no restante destes estados. No Sul, sudeste e Centro-Oeste brasileiros, a classificação se assemelha aos resultados obtidos com o Kmeans.

Já no Nordeste, os clusters diferem. Três clusters possuem características médias de clima árido, inclusive o cluster em marrom abrangendo parte do interior e a costa. Esse cluster se assemelha ao cluster também em marrom nos resultados com o Kmeans, porém abrangendo área maior no interior, e por tal razão, em média, o cluster é classificado como árido. A costa do Nordeste é uma área de Mata Atlântica e é mais úmida que o interior. Essas diferenças nesta região do cluster na distribuição de chuva se acentuam no período de JJA. Portanto, a classificação obtida pelo Kmeans e Fuzzy C-means nessa região é mais coerente.

Conclui-se, finalizado o estudo de clusterização, que para as três metodologias o aumento no número de clusters de 10 para 15 melhorou a representação das características físicas e variabilidades sazonais das variáveis atmosféricas encontradas no Brasil.

Os resultados com o Fuzzy C-means e Kmeans são mais adequados, mas das análises acima (Figuras 5.5 e 5.8) ficou evidenciado que o Kmeans possui resultados superiores. Sendo assim, na sequência se apresenta uma análise das variabilidades sazonais das variáveis atmosféricas para cada cluster obtido utilizando o Kmeans. A base de setorização climática para o território nacional ficou, portanto, estabelecida em quinze (15) clusters conforme metodologia e discussões presentemente apresentadas.

5.5 VARIABILIDADES SAZONAIS DOS CLUSTERS

Observa-se que no cluster com características de tropical de floresta, localizado na parte sul e central da região Norte, os acumulados são maiores no verão e outono, atingindo um mínimo no inverno. Já no outro cluster tropical de floresta mais ao Norte, os acumulados são maiores os trimestres de MAM e JJA, com mínimo na primavera. Isso está relacionado com a monção da América do Sul e com a posição da Zona de Convergência Intertropical (ZCIT).

Entre os clusters com clima tropical de savana, observa-se diferenças tanto nos acumulados sazonais como na distribuição ao longo dos trimestres. Os maiores acumulados ocorrem no cluster verde-amarelado localizado entre o Amapá, norte do Pará e Maranhão, inclusive, diferentemente do restante dos casos, o máximo de precipitação ocorre no outono (MAM) devido à posição da ZCIT, com mínimo na primavera. Os menores acumulados dentre os climas tropicais de savana são observados no clusters do litoral do Nordeste, onde os máximos ocorrem no trimestre de JJA. Nesta estação, nota-se grande variabilidade da precipitação acumulada dentro do cluster.

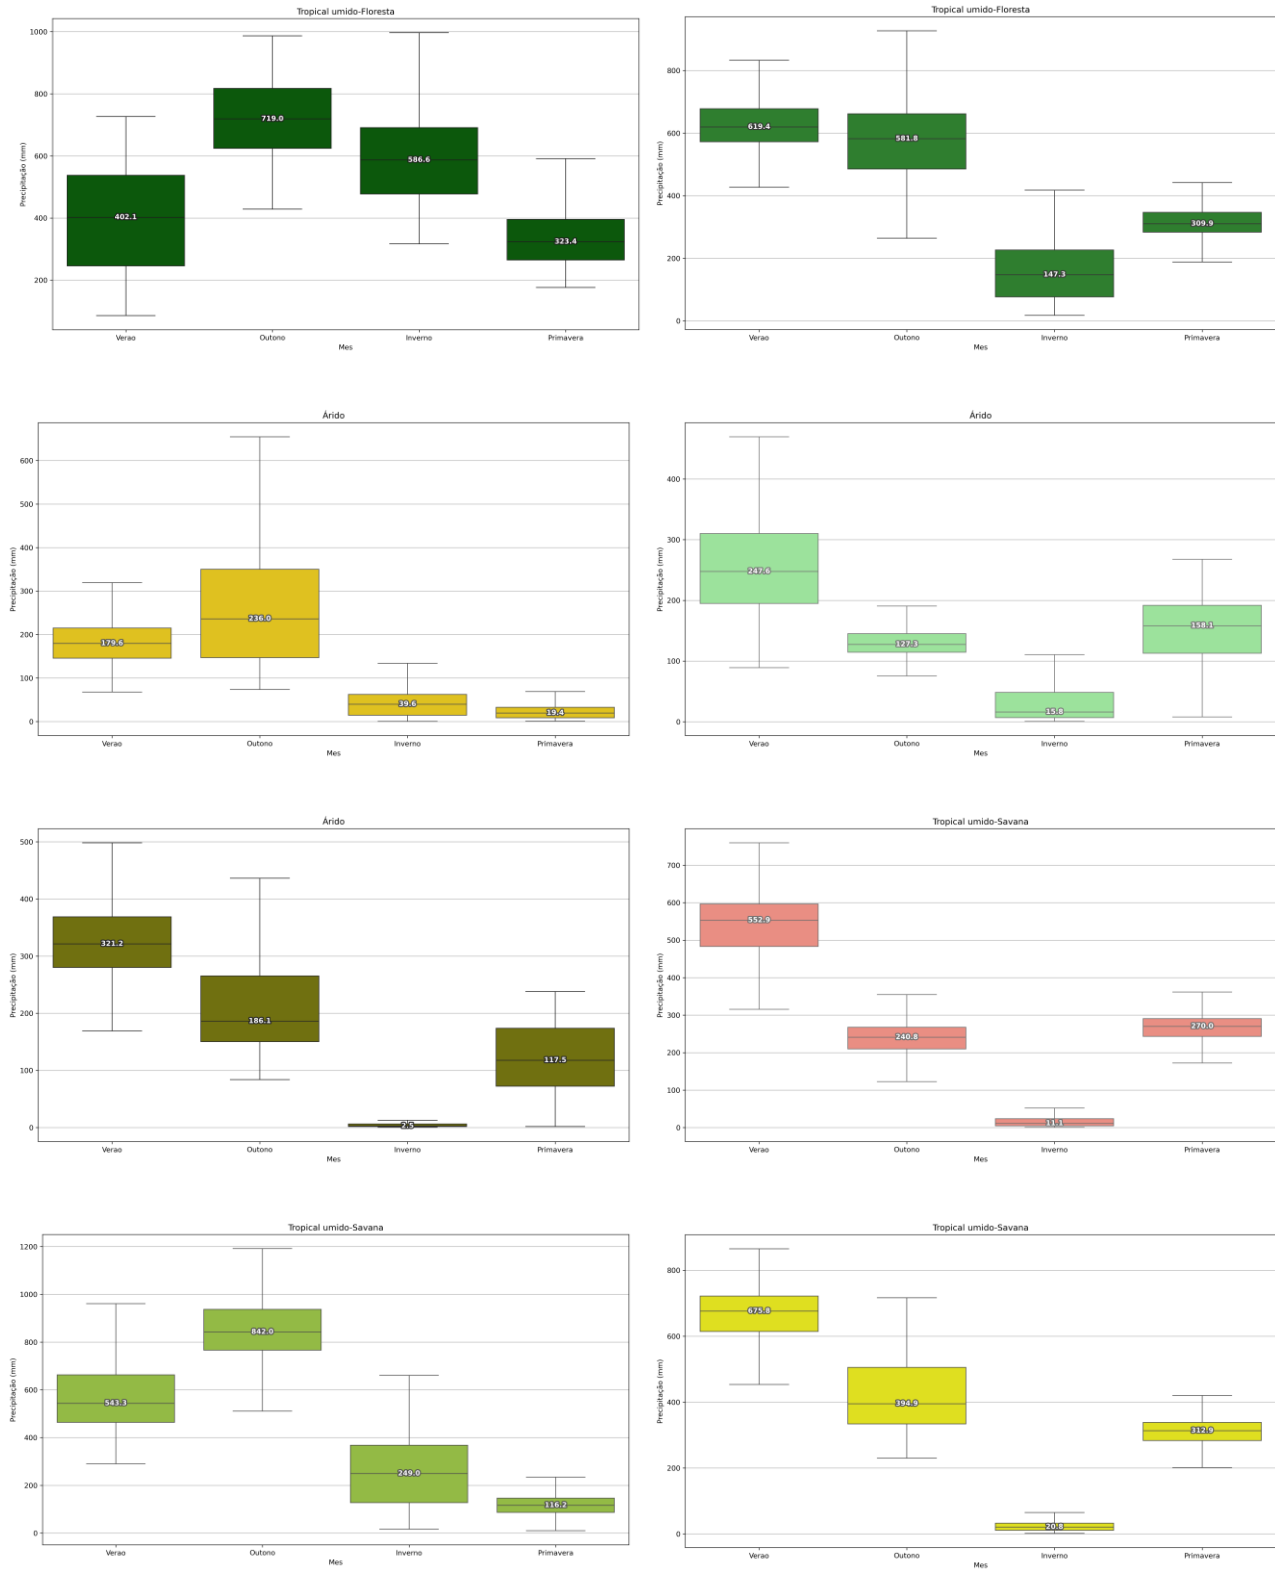
Outro ponto importante é que a sazonalidade da precipitação é menos evidente neste cluster do que nos outros com o mesmo clima. Estes outros clusters possuem máximo de precipitação no verão e mínimo no inverno. No cluster em laranja que abrange Tocantins, sul do Maranhão e parte de Goiás e Mato Grosso, a mediana varia de quase 600 mm no verão para 6 mm no inverno. Apenas o cluster com clima árido em verde-oliva apresenta valor mais baixo do que este também no trimestre de JJA. Ainda assim, considerando as quatro estações, o cluster com clima árido em dourado, abrangendo o centro-norte do Nordeste, é mais seco, com precipitação média em torno de 40 mm no inverno e 20 na primavera. O máximo neste cluster ocorre no trimestre de MAM, enquanto no restante dos clusters com clima árido o pico da chuva é no verão com mínimo em JJA. Nos clusters subtropicais de verão (ameno e quente) a precipitação é bem distribuída ao longo do ano, ou seja, não existe estação seca e chuvosa bem definida. No cluster em verde-claro, como esperado, o máximo ocorre no verão e o mínimo no inverno.

Com relação à temperatura e à radiação solar incidente na superfície, como esperado, as maiores variações ao longo das estações do ano ocorrem nos clusters mais ao Sul do país. Nos clusters de clima tropical de floresta a temperatura média varia em torno de 1° C, enquanto no clima subtropical de verão quente, entre o verão e o inverno, a variação é de 10 °C. Além da questão da latitude, em geral, os maiores valores de temperatura e radiação solar ocorrem nos meses com menos chuva, devido a menor cobertura de nuvens. O cluster mais quente e com maior incidência de energia solar, bem como o mais seco acima mencionado, é o cluster em dourado com maiores valores nos meses de DJF e SON.

Os clusters com ventos mais intensos são os da região Nordeste, os três de clima árido e de clima tropical de savana na costa. Nos quatro, o vento é mais intenso nos trimestres de JJA e SON. Os clusters tropical de savana no Norte do Brasil (verde-oliva) e o subtropical de verão quente, também possuem ventos mais intensos do que o restante dos clusters, apesar de mais fracos do que no Nordeste. Nessas áreas a velocidade do vento pode ser um fator importante para a temperatura de superfície de pavimentos. Os ventos mais fracos ocorrem no extremo norte do país, no cluster com clima tropical de floresta.

Concluindo, nas Figuras 5.10 a 5.13, apresentadas continuamente nas páginas que se seguem, são representadas as variabilidades sazonais observadas, e na Figura 5.14 as sobreposições dos 15 clusters (obtidos pelo Kmeans) com as rodovias federais no Brasil (PNV), permitindo com isso a identificação do clima predominante em cada trecho das rodovias. Para a tabulação da inserção das rodovias em cada um dos clusters estabelecidos será necessária a locação em termos de coordenadas geográficas, ainda que aproximadas, dos trechos, com seus marcos de início e fim dentro de cada cluster específico.

Na continuidade dos trabalhos serão estabelecidos os parâmetros atmosféricos para previsão e temperaturas de superfície em pavimentos de concreto, dentro de cada cluster definido na presente fase de trabalhos que se conclui.



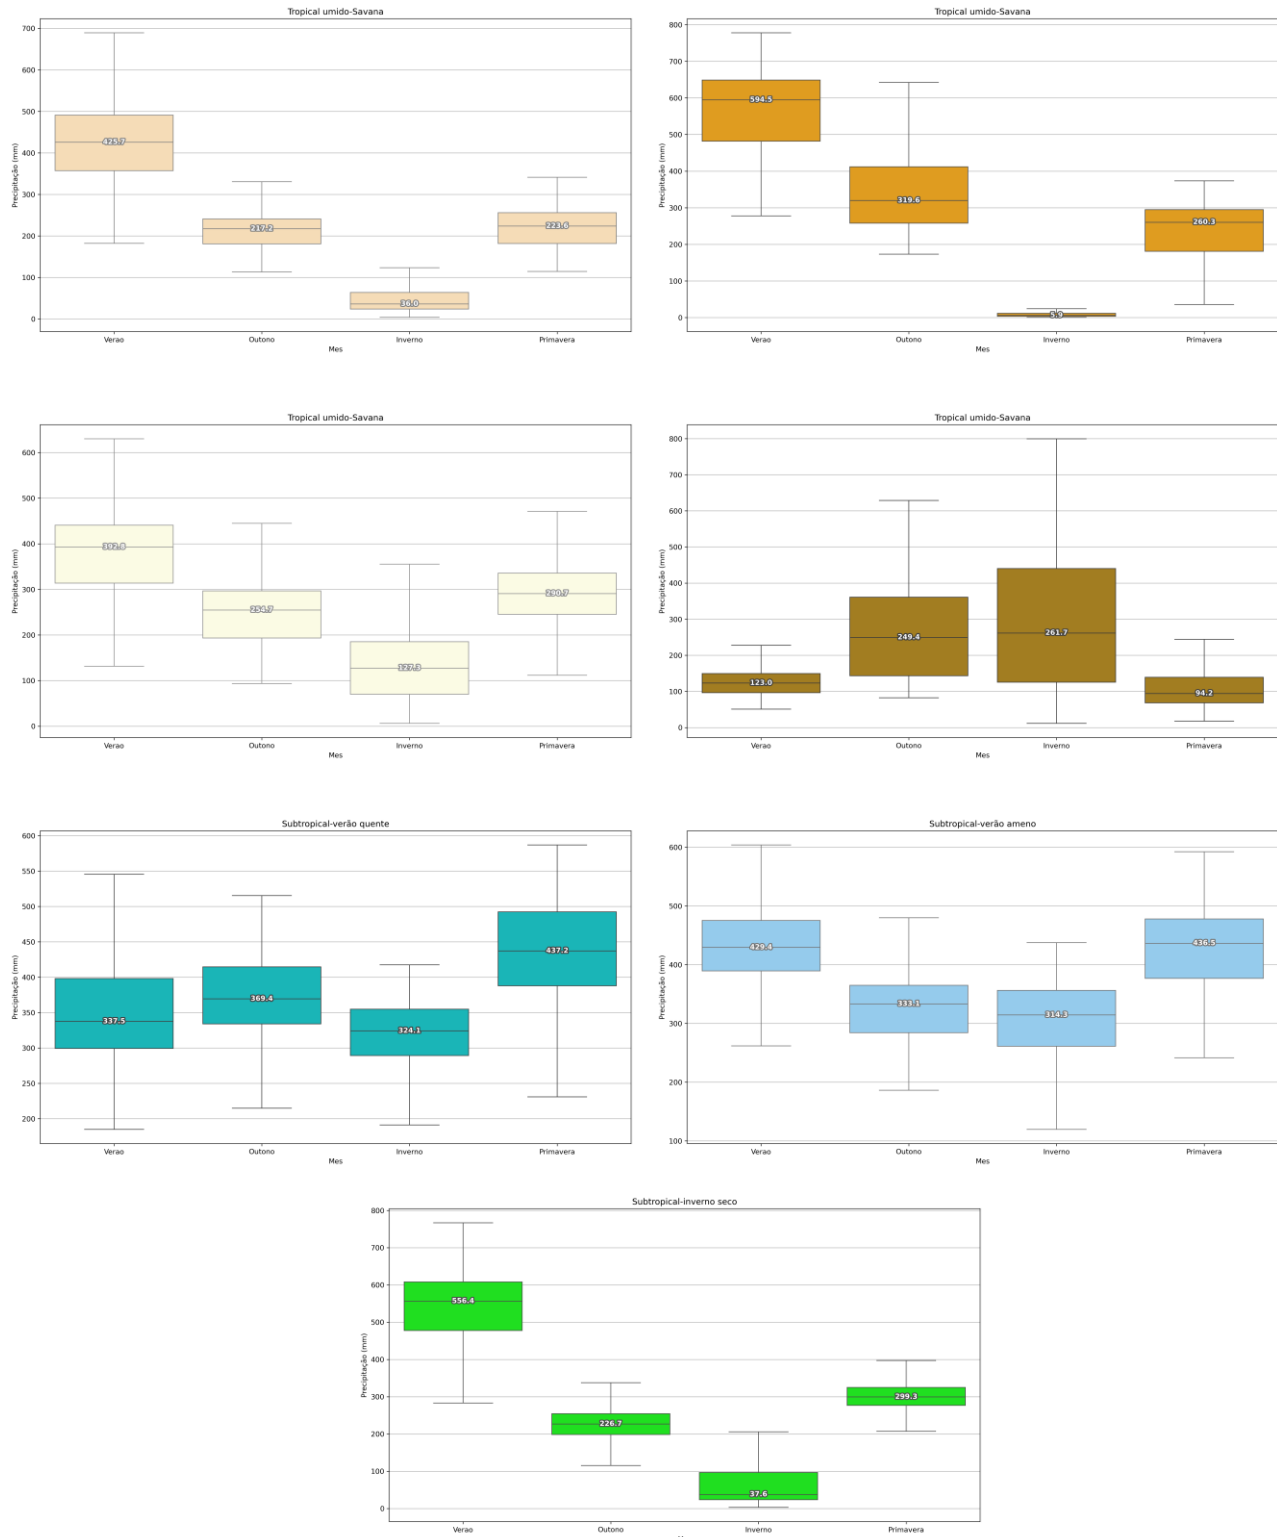


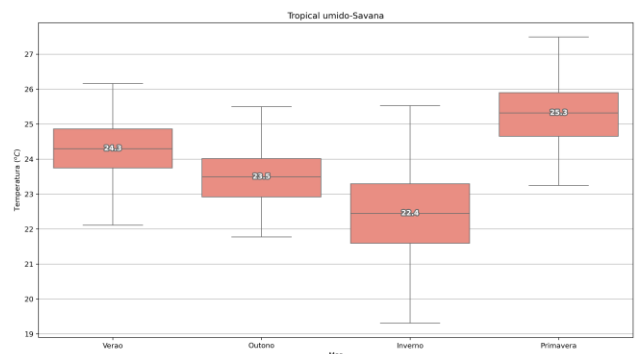







Figura 5.10 – Variabilidade sazonal da precipitação acumulada (mm) nos 15 clusters obtidos pelas análises com o Kmeans. O padrão das cores e a nomenclatura seguem conforme descrito na Figura 5.9



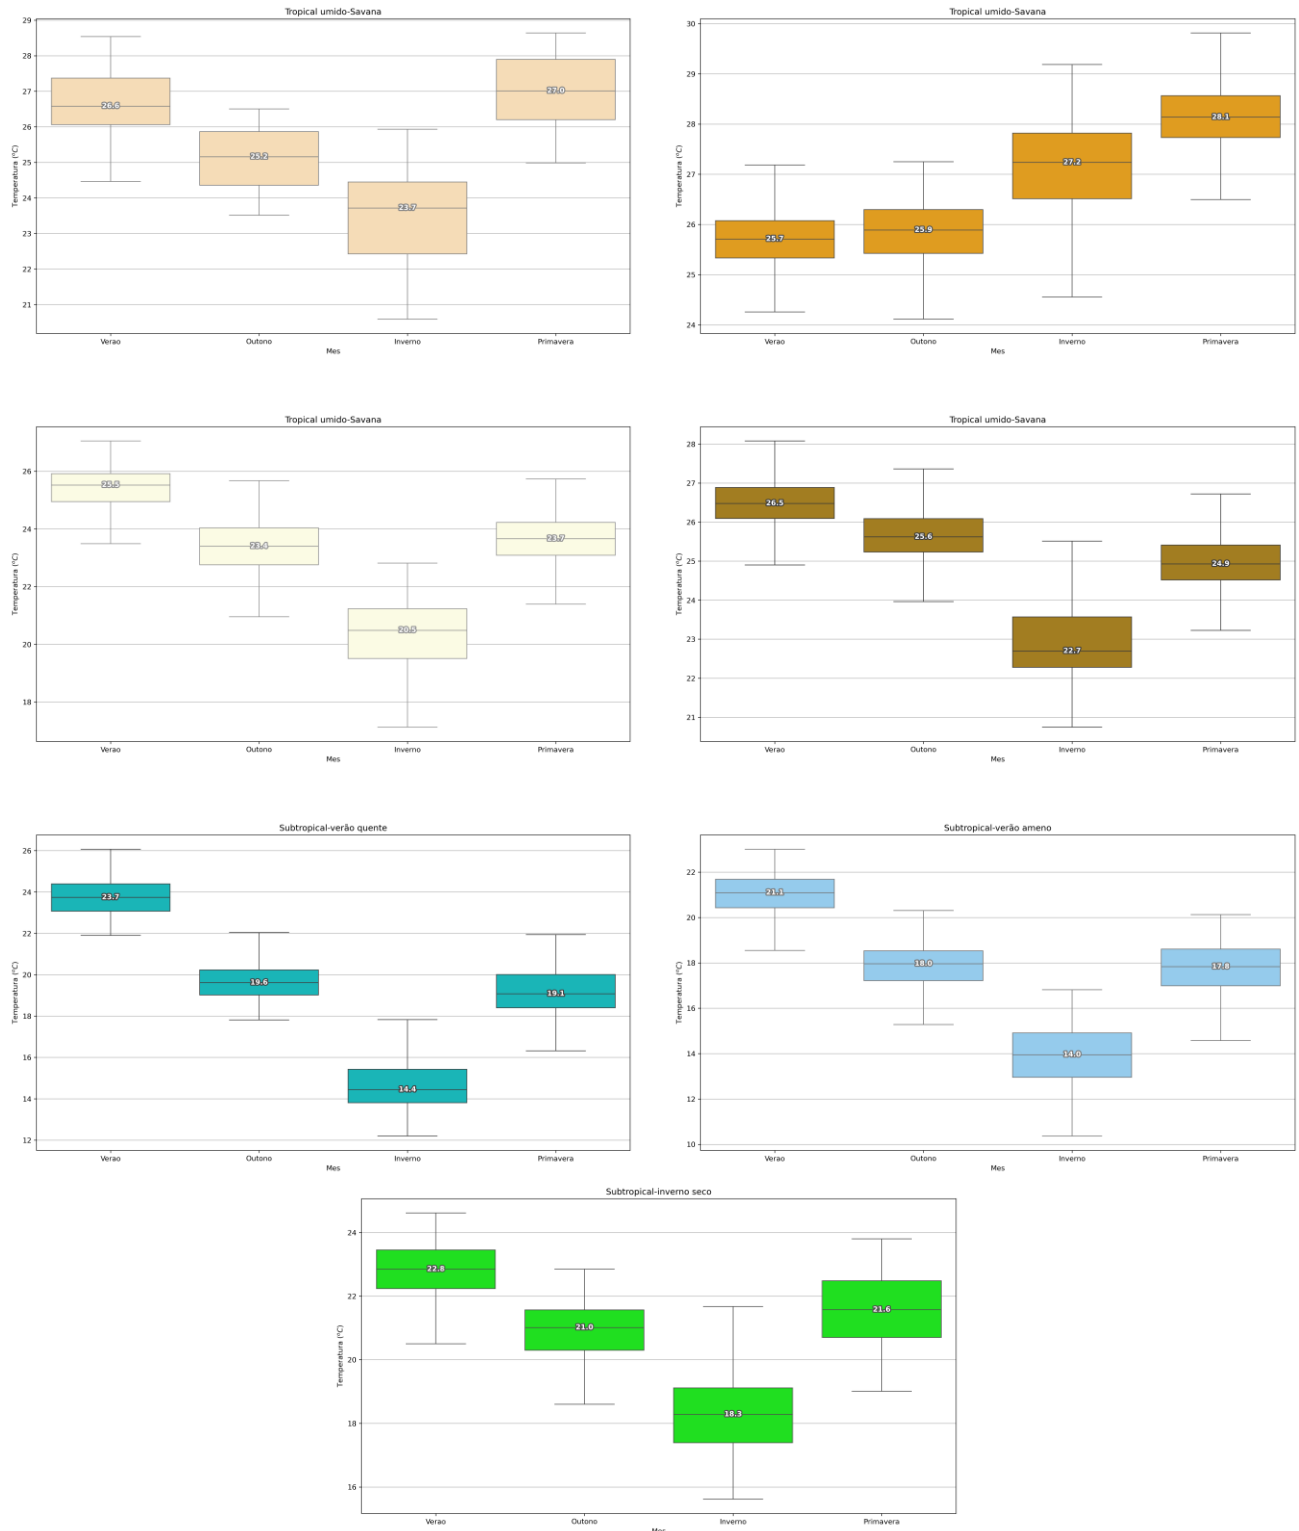










Figura 5.11 – Variabilidade sazonal da temperatura (°C) nos 15 clusters obtidos pelas análises com o Kmeans. O padrão das cores e a nomenclatura seguem conforme descrito na Figura 5.9



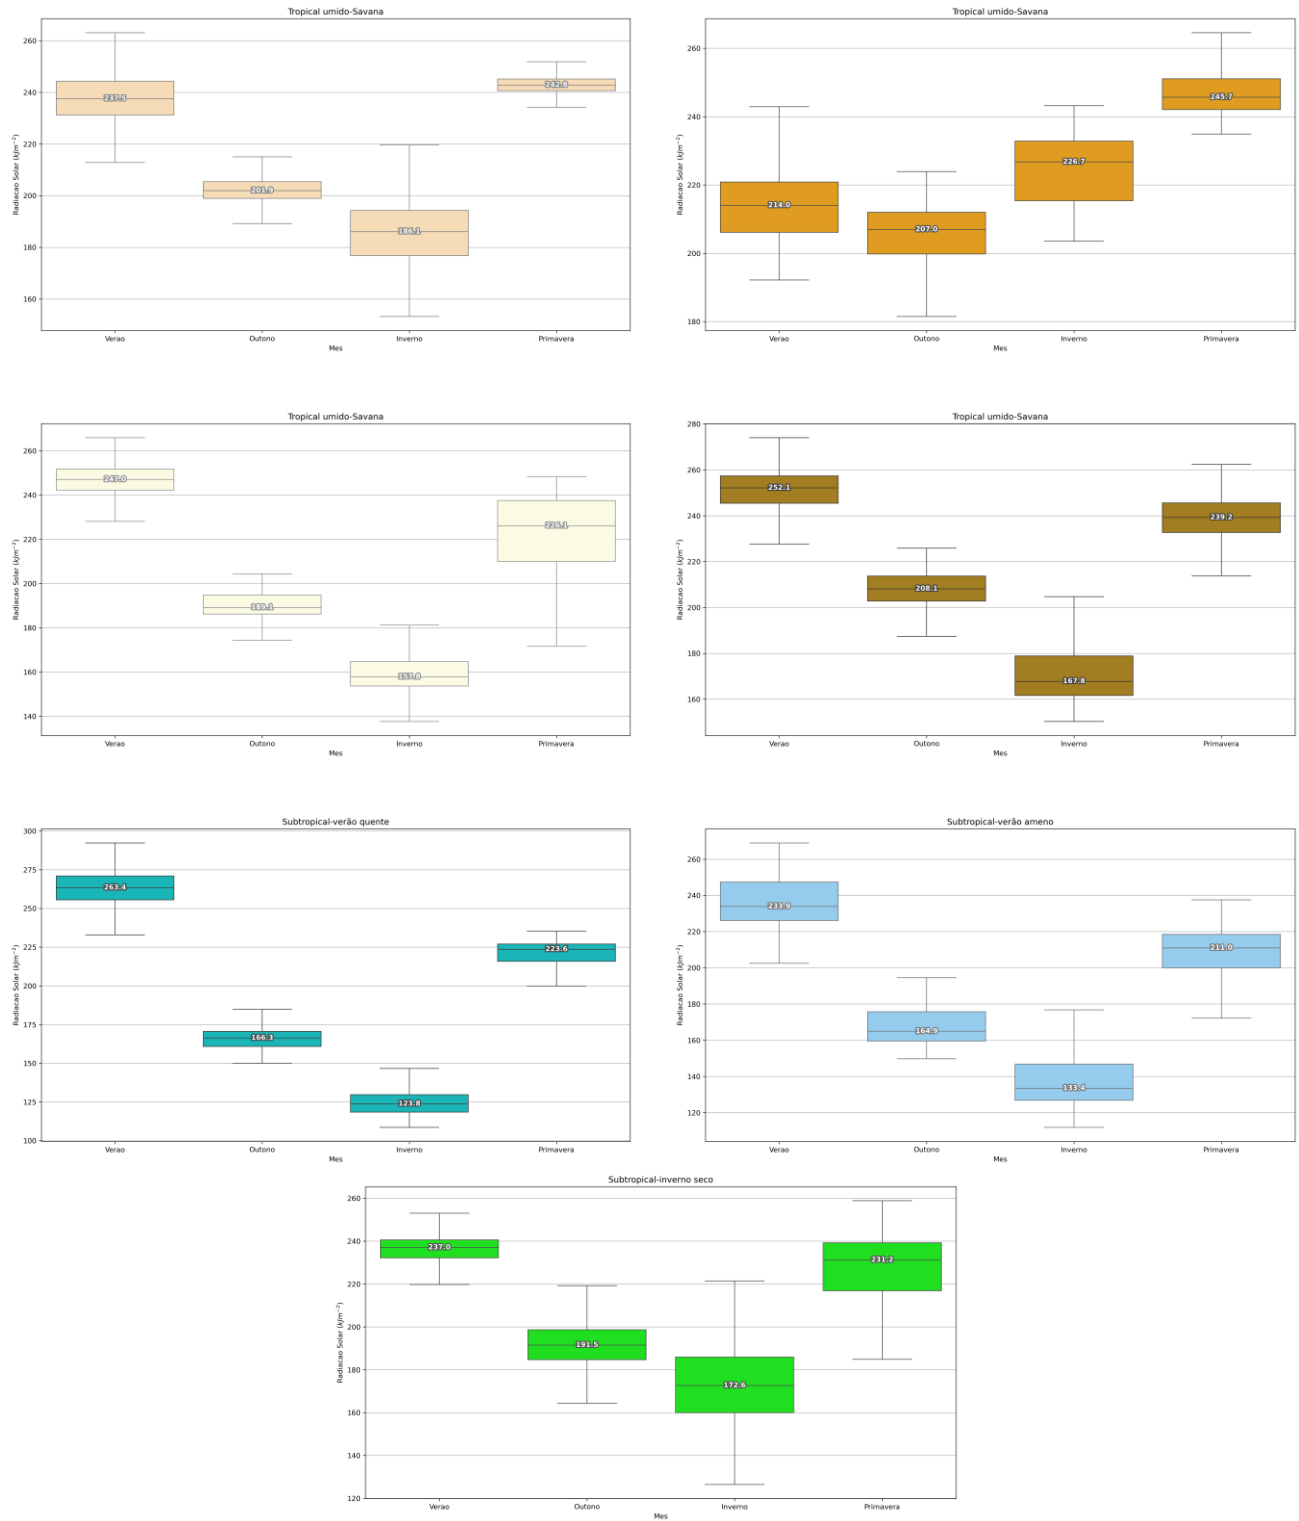










Figura 5.12 – Variabilidade sazonal da radiação solar incidente na superfície (kJ m^{-2}) nos 15 clusters obtidos pelas análises com o Kmeans. O padrão das cores e a nomenclatura seguem conforme descrito na Figura 5.9



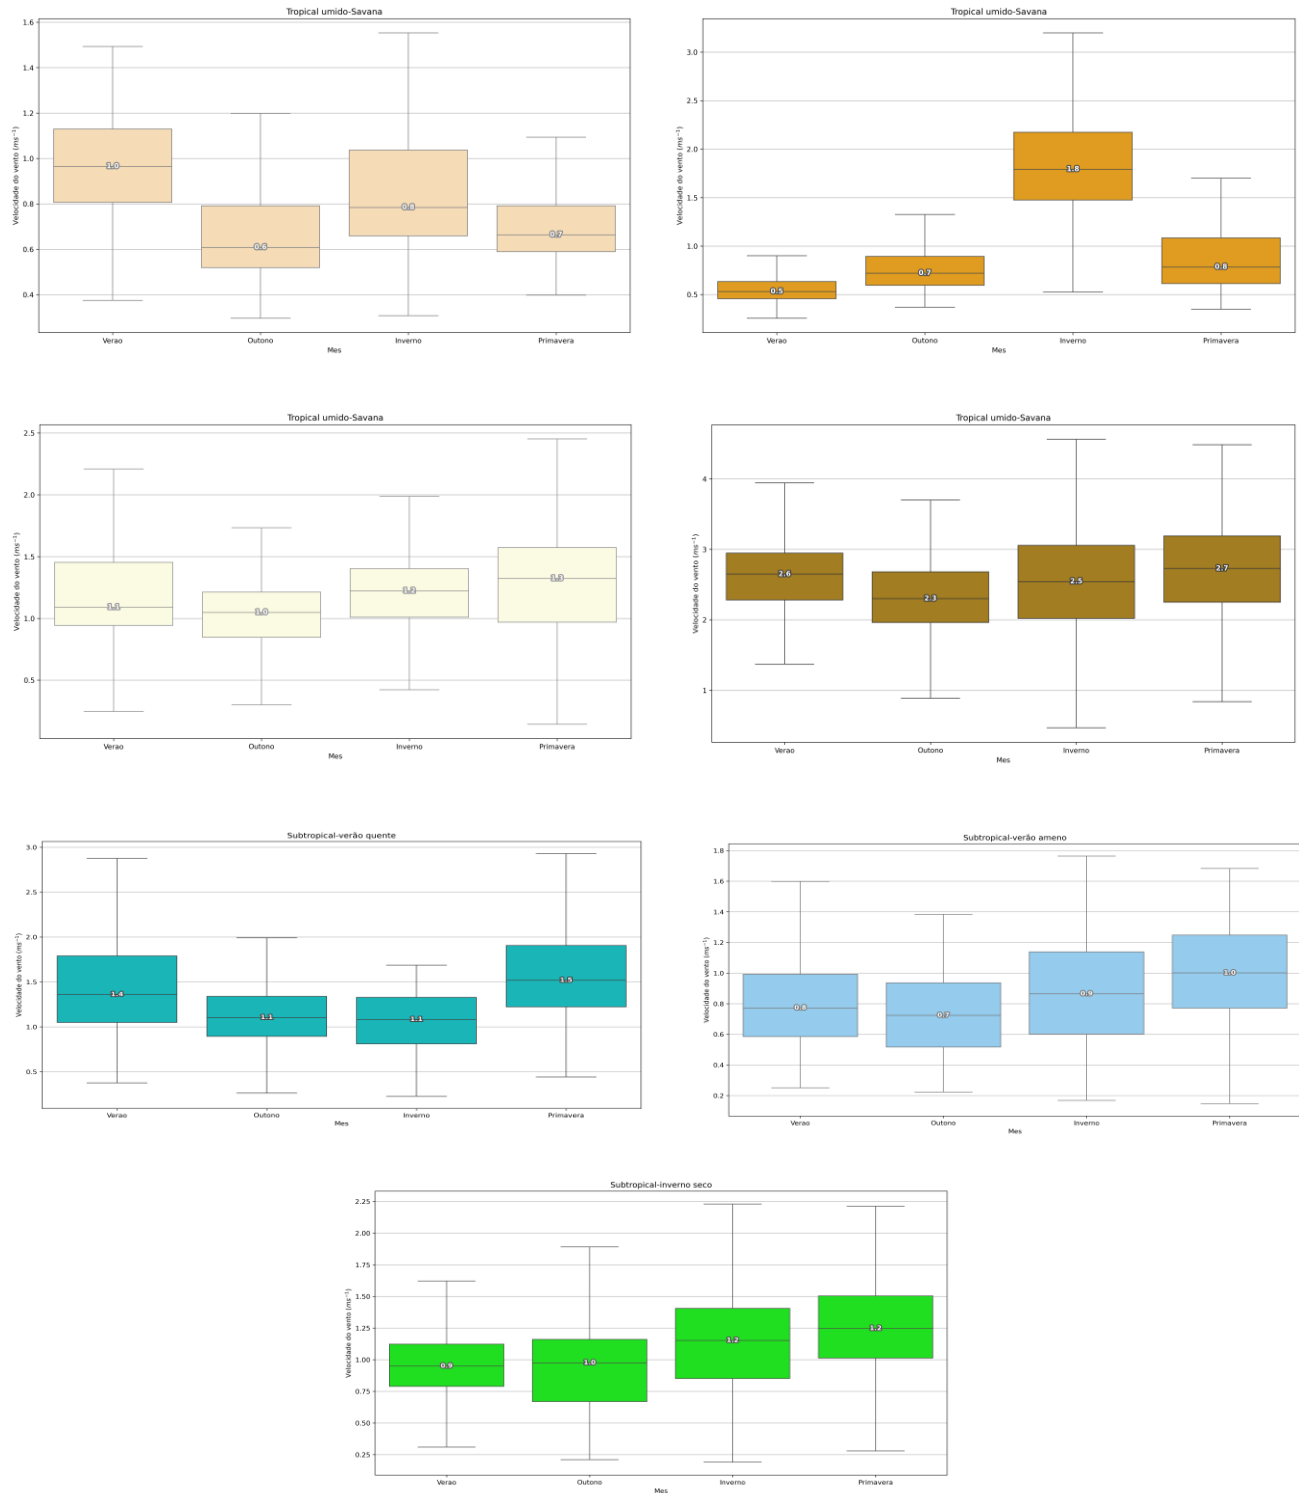


Figura 5.13 – Variabilidade sazonal da velocidade do vento ($m s^{-1}$) nos 15 clusters obtidos pelas análises com o Kmeans. O padrão das cores e a nomenclatura seguem conforme descrito na Figura 5.9

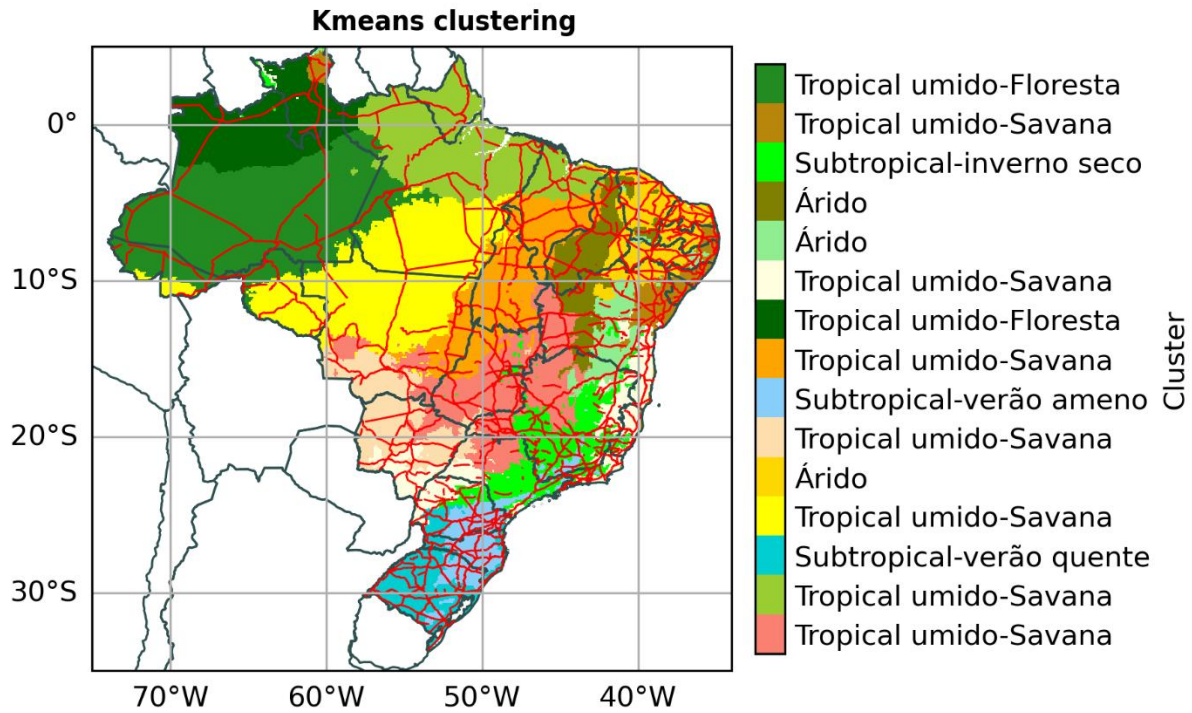


Figura 5.14 – Classificação climática obtida pelo Kmeans sobreposta com as rodovias federais - PNV (linhas vermelhas) – Preliminar

6. FASE INICIAL DE APRENDIZADO DE MÁQUINA: ESTUDOS METODOLÓGICOS E TESTES DE MODELOS

O projeto em andamento previu a aplicação de modelos de aprendizado de máquina na estimação de diferenciais térmicos e de tensões e deslocamentos em PCS e WT, a partir de dados reais (de temperaturas) e com base na modelagem numérica das respostas estruturais a partir de dados simulados por Elementos Finitos em 2D e 3D.

No presente relatório, como esclarecido no item 3, apresenta-se o estudo de modelagem de IA para cálculo de tensões e deformações geradas a partir de modelo de FEM em 2D, explicitamente, empregando o programa ISLAB 2005.

6.1 CONSIDERAÇÕES PRELIMINARES

Este item é apresenta uma descrição das atividades desenvolvidas com foco na aplicação de técnicas avançadas de processamento de dados e uso de inteligência artificial ao dimensionamento de pavimentos de concreto. São abordados dois pontos principais do desenvolvimento, a saber:

- desenvolvimento e comparação de modelos de redes neurais para estimação de temperaturas de topo e diferenciais térmicos nas placas de concreto da pista experimental;
- aplicação de modelos de aprendizado de máquina na modelagem da resposta estrutural a partir de dados simulados por elementos finitos em 2D.

O conteúdo deste item descreve os fundamentos conceituais, as motivações técnicas e as metodologias adotadas para aprimorar tanto a análise da resposta estrutural de pavimentos no contexto mecanístico-empírico, quanto para melhor explorar a correlação entre os gradientes térmicos observados nas placas de concreto de pista experimental no campus da USP em São Paulo (amplos dados disponíveis, ainda que com limitações), bem como as condições climáticas locais, para possibilitar a generalização dos resultados para outras localidades.

O objetivo principal foi investigar estratégias que ampliem a confiabilidade dos modelos preditivos, especialmente em condições de projeto não convencionais ou pouco representadas nos conjuntos de dados originais.

Destaca-se, como resultado, além dos modelos de aprendizagem de máquina desenvolvidos e testados, a produção de um artigo científico abordando o segundo ponto tratado neste relatório, o qual foi aceito e deverá ser apresentado no 7th *FIB Congress*¹⁸, uma das maiores e mais respeitadas conferências em concreto estrutural atualmente.

6.2 ESTUDO DE CORRELAÇÃO ENTRE OS GRADIENTES TÉRMICOS OBSERVADOS EM PLACAS DE CONCRETO DE PISTA EXPERIMENTAL E AS CONDIÇÕES CLIMÁTICAS LOCAIS

Esta seção apresenta a análise da relação entre os diferenciais térmicos registrados nas placas de concreto da pista experimental USP-FAPESP¹⁹ e as condições climáticas predominantes na região de estudo. O objetivo é compreender de que forma os fatores ambientais influenciam a distribuição de temperatura ao longo da espessura das placas e, conseqüentemente, o comportamento térmico do pavimento.

Para essa investigação, foram considerados como dados de interesse as temperaturas máximas e mínimas do ar, a umidade relativa, os dados pluviométricos, a velocidade do vento, o número de horas de insolação e as condições gerais do tempo, como ocorrência de chuva ou presença de nebulosidade. A análise conjunta dessas variáveis buscou identificar padrões de correlação que contribuam para uma melhor compreensão da resposta térmica do pavimento sob condições climáticas reais e variáveis. O *layout* das placas e equipamentos de medição é ilustrado na Figura 6.1 (ver nota 10).

As análises de dados foram realizadas nas seções A, C e D da pista experimental instrumentada, totalizando 190 dias de leituras, sendo 59 dias para a seção A, 66 dias para a seção C e 65 dias para a seção D. Destes 190 dias de leituras, 74 dias ocorreram na primavera, 39 no verão, 43 no outono e 34 no inverno. Com base nesses dados foram realizados três conjuntos de experimentos envolvendo:

- previsão da temperatura máxima de topo em função de variáveis climáticas;
- previsão do diferencial térmico como função da temperatura máxima de topo e características da placa e;
- previsão do diferencial térmico em função de variáveis climáticas.

¹⁸ FIB | The International Federation for Structural Concrete.

¹⁹ Balbo, J. T. Análise Teórica dos Gradientes Térmicos em Pavimentos de Concreto na Pista Experimental USP-FAPESP com o programa ILSL2. Relatório de pesquisa, Fundação de Amparo à Pesquisa do Estado de São Paulo, São Paulo, 2001.

Para cada um desses três conjuntos foram treinados e avaliados diversos modelos baseados em redes neurais artificiais, que são descritos na sequência.




Figura 6.1 – Layout da pista experimental USP-FAPESP (1999 a 2001)

6.2.1 Previsão da temperatura máxima de topo em função de variáveis climáticas

Esse primeiro conjunto de experimentos teve como objetivo desenvolver modelos para a previsão da temperatura máxima no topo das placas de concreto. Para isso, foram consideradas variáveis climáticas diretamente relacionadas ao processo de aquecimento superficial ao longo do dia.

Como variáveis preditoras, utilizou-se o número de horas de insolação (NHI), definido com base no período entre o amanhecer e 15 horas; a temperatura atmosférica média (T_{ar}), calculada a partir das temperaturas máxima e mínima registradas entre 9 horas e 15 horas; e a umidade relativa do ar (H), medida às 15 horas, por representar a condição mais próxima do momento de ocorrência da temperatura máxima no topo da placa.

A variável resposta adotada nos modelos corresponde às temperaturas máximas observadas no topo das placas, permitindo avaliar a capacidade preditiva das variáveis climáticas selecionadas em relação ao aquecimento superficial do pavimento.

Para estimar os valores de temperatura máxima de topo (TT_{max}) a partir das variáveis climáticas, foram desenvolvidos modelos de regressão baseados em redes neurais artificiais (RNA). O problema é de natureza contínua, portanto utilizou-se uma arquitetura do tipo *Multilayer Perceptron* (MLP) implementada com o framework *TensorFlow/Keras*.

O modelo básico inicial possui três camadas ocultas densamente conectadas (*Dense layers*) com 64, 32 e 16 neurônios, respectivamente, todas utilizando a função de ativação ReLU, adequada para tratar relações não lineares entre variáveis climáticas e a temperatura máxima medida no topo das placas. Para reduzir risco de sobreajuste (*overfitting*), foram incluídas camadas de *Dropout* com taxas de 15 % e 10 %, desativando aleatoriamente parte dos neurônios durante o treino.

A camada de saída contém um único neurônio com ativação linear, apropriado para tarefas de regressão. O modelo foi otimizado com o algoritmo Adam, que ajusta a taxa de aprendizado de forma adaptativa, e a função de perda utilizada foi o erro quadrático médio (RMSE/MSE), métrica-padrão em problemas de regressão contínua. Durante o treinamento, monitorou-se também o erro absoluto médio (MAE).

Os dados foram divididos em conjuntos de treino e teste na proporção 80/20 (salvo informação contrária), sendo que apenas os dados de treino foram usados para ajustar o escalonamento das variáveis (via *StandardScaler*). Além disso, adotou-se *early stopping* com paciência de 20 épocas, interrompendo o treinamento caso a perda de validação deixasse de melhorar, o que evita treinamento excessivo e promove melhor generalização dos resultados para dados fora do conjunto de treinamento.

Ao final, o desempenho foi avaliado por meio das métricas RMSE, MAE e coeficiente de determinação (R^2), além de gráficos de perda (treino versus validação) e de comparação entre valores reais e estimados, tanto no conjunto de treino, quanto no conjunto de teste.

Para o desenvolvimento dos modelos preditivos nesse primeiro conjunto de experimentos, adotou-se uma estratégia de agregação dos dados experimentais com base nos valores da variável independente TT_{max} . Como, em diversas situações, um mesmo valor das variáveis de entrada (clima em uma mesma data) estava associado a múltiplas observações de TT_{max} , foi realizado o agrupamento dos dados por data, calculando-se, para cada grupo, a média correspondente da variável resposta.

O modelo foi então ajustado utilizando esses valores médios, de modo a representar a tendência central da relação entre as variáveis e reduzir a influência de flutuações experimentais de caráter aleatório.

Essa abordagem apresenta como principal vantagem a redução do ruído nos dados, resultando em uma relação funcional mais estável e suave entre as variáveis. Além disso, favorece a identificação da tendência média do fenômeno físico em estudo, o que é particularmente útil quando o interesse está na resposta representativa do sistema e não em variações pontuais. O método também pode contribuir para maior robustez numérica do ajuste e melhor interpretabilidade dos resultados.

Por outro lado, a agregação implica a perda de informações sobre a variabilidade das observações individuais, uma vez que a dispersão dos valores de TT_{max} para uma mesma data deixa de ser explicitamente considerada no treinamento do modelo. Com isso, o modelo resultante descreve apenas o comportamento médio do sistema, não sendo adequado para representar a variabilidade ou estimar intervalos de previsão associados às respostas. Além disso, caso o número de observações que compõem cada média varie significativamente entre os grupos, pode ocorrer diferença na confiabilidade estatística dos pontos utilizados no ajuste, o que deve ser considerado na interpretação dos resultados. Essa estratégia também reduz o número de amostras para criação do modelo. Seguem as especificações e resultados dos modelos treinados.

Modelo 1: Nesse primeiro experimento os dados foram consolidados pela data, considerando todas as placas. As variáveis temperatura do ar máxima (T_{max}) e mínima (T_{min}) foram usadas como entrada, além de NHI e H .

Os resultados obtidos para o modelo 1 são apresentados nas Figuras 6.2 e 6.3. A Figura 6.2 apresenta o histórico do treinamento do modelo, permitindo acompanhar a evolução do processo de aprendizado ao longo das épocas, bem como a tendência de convergência da função de erro para os conjuntos de treinamento e validação. Essa análise possibilita verificar a estabilidade do treinamento e identificar eventuais indícios de sobreajuste ou subajuste.

A Figura 6.3 apresenta o gráfico de comparação entre os valores observados e os valores estimados pelo modelo, considerando os conjuntos de treinamento e de teste. Nesse gráfico também é indicado o coeficiente de determinação, utilizado como métrica de desempenho para avaliar a qualidade do ajuste. A proximidade dos pontos em relação à linha de referência indica o nível de concordância entre valores previstos e medidos, permitindo uma avaliação visual e quantitativa da capacidade preditiva do modelo.




Figura 6.2 – Histórico de treinamento para modelo 1




Figura 6.3 – Comparação entre valores de treinamento e teste com coeficiente de determinação, para modelo 1

As métricas obtidas nas etapas de treinamento e teste são apresentadas na Tabela 6.1. As métricas obtidas nas etapas de treinamento e teste indicam diferenças relevantes no desempenho do modelo quando aplicado aos dados utilizados no ajuste e a dados não observados durante o processo de aprendizado.

Tabela 6.1 – Métricas para o modelo 1

Etapa	RMSE	MAE	R^2
Treino	3,4911	2,7228	0,7214
Teste	5,3273	4,0941	0,4331

Na fase de treinamento, o modelo apresentou RMSE de 3,4911, MAE de 2,7228 e coeficiente de determinação (R^2) de 0,7214. Esses resultados indicam um ajuste satisfatório aos dados de treino, com capacidade razoável de explicar a variabilidade da variável resposta e erros médios relativamente moderados. O valor de R^2 próximo de 0,72 sugere que o modelo consegue capturar uma parcela significativa da relação entre as variáveis, representando adequadamente a tendência média do conjunto utilizado no treinamento. Entretanto, ao ser avaliado no conjunto de teste, observou-se uma redução considerável no desempenho.

O RMSE aumentou para 5,3273 e o MAE para 4,0941, indicando maior magnitude média dos erros de previsão. Além disso, o coeficiente de determinação caiu para 0,4331, revelando que a capacidade explicativa do modelo diminuiu substancialmente quando aplicado a dados não utilizados no ajuste.

Essa diferença entre os resultados de treinamento e teste sugere limitação na capacidade de generalização do modelo. Em termos práticos, embora o modelo apresente bom ajuste aos dados conhecidos, seu desempenho é significativamente inferior ao prever novos valores, o que pode indicar sobreajuste, presença de variabilidade não capturada pelas variáveis explicativas, ou ainda, limitação do conjunto de dados utilizado para treinamento. Também é possível que a relação entre as variáveis seja mais complexa do que a representada pelo modelo adotado, ou que existam fatores relevantes não incluídos na modelagem.

De modo geral, os resultados indicam que o modelo consegue representar razoavelmente bem o comportamento médio dos dados de treinamento, mas apresenta desempenho apenas moderado em condições de generalização. Isso sugere a necessidade de aprimoramentos, como a inclusão de novas variáveis explicativas, aumento do conjunto de dados, ajuste da complexidade do modelo ou adoção de estratégias adicionais de regularização e validação.

Modelo 2: Usa média entre T_{min} e T_{max} como entrada (divisão 90/10)

O modelo 2 foi desenvolvido a partir da mesma base de dados e da mesma estrutura geral adotada no modelo anterior, mantendo-se o procedimento de preparação e divisão do conjunto de dados. A principal modificação consistiu na redefinição de uma das variáveis de entrada, passando-se a utilizar como preditor a temperatura média do período, calculada como a média entre os valores mínimo (T_{min}) e máximo (T_{max}).

Além disso, foi adotada uma divisão dos dados em 90 % para treinamento e 10 % para teste, com o objetivo de avaliar o desempenho do modelo em dados não utilizados no ajuste. Essa alteração busca verificar se a utilização de uma medida representativa da temperatura média contribui para melhorar a capacidade preditiva e a estabilidade do modelo. Os resultados correspondentes estão apresentados nas Figuras 6.4 e 6.5.




Figura 6.4 – Histórico de treinamento para modelo 2




Figura 6.5 – Comparação entre valores de treinamento e teste com coeficiente de determinação, para modelo 2

As métricas obtidas nas etapas de treinamento e teste são apresentadas na Tabela 6.2. Em comparação com o modelo anterior, observa-se um comportamento distinto no desempenho entre as etapas de treinamento e teste. No treinamento, o modelo 2 apresentou desempenho inferior, com aumento dos erros (RMSE e MAE) e redução do coeficiente de determinação ($R^2 = 0,5329$), indicando menor capacidade de ajuste aos dados utilizados no aprendizado.

Tabela 6.2 – Métricas para o modelo 2

Etapa	RMSE	MAE	R^2
Treino	4,5877	3,4680	0,5329
Teste	3,8035	3,2843	0,6841

Entretanto, no conjunto de teste, o modelo apresentou desempenho melhor que o observado no treinamento e também superior ao do modelo anterior, com redução dos erros e aumento do coeficiente de determinação ($R^2 = 0,6841$). Esse resultado sugere melhor capacidade de generalização, indicando que a utilização da temperatura média entre T_{min} e T_{max} como variável de entrada pode ter contribuído para tornar o modelo mais estável e menos sensível a variações específicas do conjunto de treinamento.

De modo geral, embora o ajuste aos dados de treino seja mais modesto, o modelo 2 demonstra desempenho mais consistente em dados não observados, o que representa uma característica desejável em aplicações preditivas.

Modelo 3: ajustando parâmetros no modelo anterior (1000 épocas; divisão 90/10)

O modelo 3 foi desenvolvido a partir da mesma configuração estrutural e do conjunto de dados utilizados no modelo 2, tendo como principal objetivo aprimorar o processo de treinamento e avaliar possíveis ganhos de desempenho por meio do ajuste de parâmetros do modelo.

Nessa etapa, manteve-se a divisão dos dados em 90 % para treinamento e 10 % para teste, porém foi ampliado o número de épocas de treinamento para 1000, permitindo maior tempo de aprendizado e refinamento dos parâmetros internos da rede. Essa modificação busca verificar se um processo de treinamento mais prolongado contribui para melhorar a capacidade de ajuste do modelo e sua generalização em dados não observados. Os resultados de convergência são ilustrados nas Figuras 6.6 e 6.7, e as métricas obtidas nas etapas de treinamento e teste na Tabela 6.3.




Figura 6.6 – Histórico de treinamento para modelo 3




Figura 6.7 – Comparação entre valores de treinamento e teste com coeficiente de determinação, para modelo 3

Tabela 6.3 – Métricas para o modelo 3

Etapa	RMSE	MAE	R^2
Treino	4,1965	3,1028	0,6092
Teste	3,1910	2,7529	0,7777

A ampliação do número de épocas de treinamento no modelo 3 resultou em melhora consistente no desempenho geral, especialmente na capacidade de generalização. Em relação ao modelo 2, observou-se redução dos erros e aumento do coeficiente de determinação tanto no conjunto de treinamento quanto, de forma mais expressiva, no conjunto de teste.

No treinamento, houve melhora moderada, com redução do RMSE e do MAE e aumento do R^2 para 0,6092, indicando ajuste mais refinado aos dados utilizados no aprendizado. Entretanto, o avanço mais significativo ocorreu no conjunto de teste, no qual o modelo apresentou redução adicional dos erros e elevação do coeficiente de determinação para 0,7777, o maior valor obtido entre os modelos avaliados até aqui.

Esses resultados indicam que o aumento do número de épocas permitiu melhor convergência do processo de treinamento, favorecendo a captura de padrões relevantes nos dados sem comprometer a capacidade de generalização. De modo geral, o modelo 3 apresenta desempenho mais equilibrado e robusto, sugerindo que o refinamento do treinamento contribuiu positivamente para a qualidade das previsões.

Modelo 4: Caso anterior voltando divisão para 80/20

O Modelo 4 foi desenvolvido a partir da mesma configuração adotada no modelo 3, preservando a estrutura do modelo, as variáveis de entrada e os parâmetros de treinamento, incluindo o número de épocas. A única modificação introduzida nesta etapa foi a redefinição da divisão dos dados, retornando ao particionamento de 80 % para treinamento e 20 % para teste, conforme utilizado no modelo 1.

Essa alteração teve como objetivo avaliar a sensibilidade do desempenho do modelo à proporção de dados destinados ao treinamento e à validação externa, permitindo uma comparação direta com os resultados iniciais e uma análise mais consistente do efeito da disponibilidade de dados de teste sobre a capacidade de generalização do modelo. Os resultados correspondentes estão nas Figuras 6.8 e 6.9.




Figura 6.8 – Histórico de treinamento para modelo 4




Figura 6.9 – Comparação entre valores de treinamento e teste com coeficiente de determinação, para modelo 4

As métricas obtidas nas etapas de treinamento e testes são apresentadas na Tabela 4. Os resultados do modelo 4 indicam que a alteração na divisão dos dados teve impacto direto no desempenho, especialmente na etapa de teste. Em comparação com o modelo 3, que utilizava divisão 90/10, observa-se desempenho semelhante no conjunto de treinamento, com valores de erro praticamente inalterados e leve redução do coeficiente de determinação ($R^2 = 0,5976$), indicando ajuste comparável aos dados utilizados no aprendizado.

Tabela 6.4 – Métricas para o modelo 4

Etapa	<i>RMSE</i>	<i>MAE</i>	R^2
Treino	4,1961	3,0829	0,5976
Teste	4,5731	3,5090	0,5823

Todavia, no conjunto de teste houve piora perceptível no desempenho, com aumento dos erros (*RMSE* e *MAE*) e redução do coeficiente de determinação para 0,5823. Essa diferença sugere menor capacidade de generalização em relação a modelo 3, que havia apresentado desempenho mais elevado com maior proporção de dados destinados ao treinamento.

De modo geral, os resultados indicam que a redução da quantidade de dados disponíveis para o treinamento impactou negativamente a qualidade das previsões em dados não observados, reforçando a importância do tamanho do conjunto de treinamento para a capacidade preditiva do modelo nesse problema específico.

O resumo dos resultados dessa etapa de previsão da temperatura máxima de topo, considerando o primeiro conjunto de experimentos e a fase de testes, é apresentado na Tabela 6.5. Esses resultados consolidam o modelo 3 como o mais equilibrado e robusto na qualidade das previsões e capacidade de generalização.

Tabela 6.5 – Resultados de precisão para etapa de testes na previsão da temperatura máxima de topo (melhor resultado em destaque)

Modelo	RMSE	MAE	R²
#1	5,3273	4,0941	0,4331
#2	3,8035	3,2843	0,6841
#3	3,1910	2,7529	0,7777
#4	4,5731	3,5090	0,5823

Para efeitos de comparação, na Figura 6.10 apresentam-se os resultados do modelo de referência desenvolvido no trabalho de doutorado (Saveri, 2002), orientado pelo Prof. Balbo, na EPUSP.

Destaca-se, no entanto, que ainda existe muito espaço para melhorias, as quais podem ser obtidas ampliando o volume de dados com mais experimentos ou, possivelmente, aplicando técnicas de ampliação de dados e reamostragem.

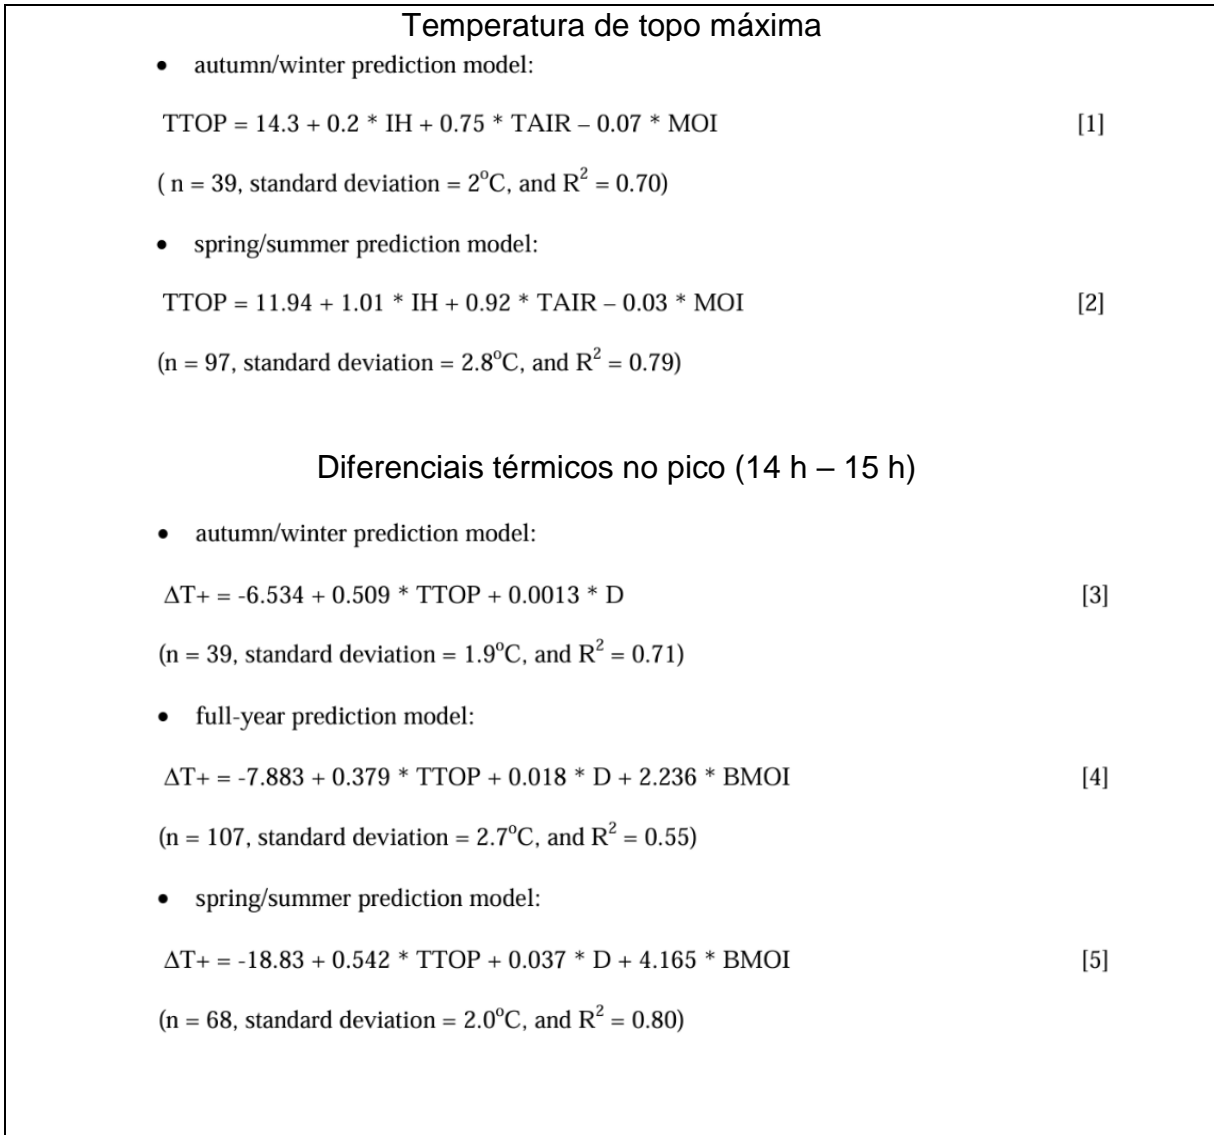


Figura 6.10 – Modelo de referência desenvolvido no Brasil para o ano cheio e combinações de estações climáticas (Balbo e Sevari, 2022)

6.2.2 Previsão do diferencial térmico como função da temperatura máxima de topo e características da placa de concreto

O segundo conjunto de experimentos envolveu a previsão do diferencial térmico a partir dos dados de temperatura máxima de topo e de espessuras de placas. Nesse caso, foram realizadas simulações tanto usando a temperatura máxima de topo prevista nos experimentos anteriores, quanto os valores reais dessa variável medidos na pista experimental USP-FAPESP.

O modelo base desenvolvido neste caso é uma rede neural *feedforward* (MLP) construída com *TensorFlow/Keras* para um problema de regressão, assim enunciado:

- Prever DT_{max} (diferencial térmico máximo) a partir de duas variáveis explicativas, espessura do concreto e TT_{max_real} (valor real de TT_{max}).

A arquitetura contém três camadas ocultas densas com 64, 32 e 16 neurônios, ativação ReLU, e camadas de Dropout (0,15 e 0,10) para reduzir *overfitting*. A saída é um único neurônio com ativação linear (adequada para regressão contínua).

O modelo foi treinado minimizando a função de perda *MSE* (Erro Quadrático Médio) e monitorando *MAE* como métrica auxiliar. Os dados foram divididos em treino e teste (80/20) e as variáveis escaladas com *StandardScaler*; adotou-se *early stopping* para interromper o treinamento caso a perda de validação não melhorasse por 25 épocas, preservando os melhores pesos.

Após o ajuste com TT_{max_real} , o modelo foi utilizado para estimar DT_{max} , recebendo como entrada TT_{max_pred} (predições de TT_{max}), permitindo avaliar o efeito da incerteza nas entradas sobre a previsão final. O desempenho foi analisado por *RMSE*, *MAE* e R^2 , e visualizado por gráficos de perda (treino *versus* validação) e *scatter plots* de valores reais x preditos.

Modelo 5: O treinamento do modelo usa como entrada os valores reais da temperatura de topo

O uso dos dados reais como entrada para o modelo visa capturar a real relação entre essa variável e o diferencial térmico máximo (DT_{max}). Após o treinamento do modelo, valores preditos da temperatura de topo são usados na avaliação. Assim, todos os valores de temperatura de topo coletados foram utilizados (valores diferentes coletados em um mesmo dia, em placas diferentes), totalizando 267 amostras.

Os resultados correspondentes são apresentados nas Figuras 6.11 a 6.13. Na Figura 6.11 ilustra-se o histórico de treinamento, sugerindo que há espaço para uma maior evolução (aumentar número de épocas de treinamento, por exemplo). Os resultados das métricas de desempenho no treinamento confirmam essa constatação (R^2 0,5358). Uma comparação entre valores de treinamento e teste com coeficiente de determinação é apresentada na Figura 6.12. Por fim, o resultado da análise utilizando valores preditos de TT_{max} são apresentados na Figura 6.13, mostrando que a precisão do modelo ainda é insuficiente.




Figura 6.11 – Histórico de treinamento do modelo 5




Figura 6.12 – Comparação entre valores de treinamento e teste com coeficiente de determinação. Resultados para modelo 5




Figura 6.13 – Valores de DT_{max} preditos a partir dos valores estimados de temperatura máxima de topo (TT_{max_pred})

Um resumo de desempenho do modelo nas etapas de treinamento e teste, usando apenas os dados reais como entrada, é apresentado na Tabela 6.6 que se segue.

Tabela 6.6 – Métricas de treinamento e teste para modelo 5

Etapa	RMSE	MAE	R^2
Treino	2,6629	2,2132	0,5358
Teste	2,9220	2,4248	0,4291

Modelo 6: Modelo com as mesmas configurações anteriores, mas aumentando número de épocas de treinamento para 1000

O aumento no número de épocas visou melhorar o ajuste insuficiente observado no modelo anterior (5). Todos os demais parâmetros foram mantidos fixos. Apesar de aprimorar um pouco o treinamento, essa ação não foi suficiente para promover uma melhoria significativa na capacidade de generalização (valor de R^2 na etapa de teste), conforme pode ser observado na Tabela 6.7 com as métricas e nas Figuras 6.14 e 6.15.

A modificação implementada na arquitetura da rede neural resultou em uma pequena melhoria do desempenho preditivo no conjunto de teste, evidenciada pela redução simultânea de RMSE e MAE e pelo aumento do coeficiente de determinação (R^2).

O ganho observado indica pequeno aprimoramento da capacidade de generalização e maior poder explicativo do modelo, mas ainda com espaço para mais investigação. Destaca-se que um aumento ainda mais significativo no número de épocas não resultou em uma maior elevação dessa capacidade.

Importante destacar que existem várias entradas em que o mesmo valor TT_{max_real} e espessura de placas de concreto resultam em valores diferentes de DT_{max} , em diferentes placas. Tal condição impede que essas duas variáveis sejam suficientes para explicar toda a variação em DT_{max} , resultando em um baixo coeficiente de determinação.

Tabela 6.7 – Resumo de desempenho do modelo 6 (treino/teste)

Etapa	RMSE	MAE	R ²
Treino	2,5432	2,1212	0,5763
Teste	2,5506	2,1503	0,5797




Figura 6.14 – Histórico de treinamento do modelo 6




Figura 6.15 – Comparação entre valores de treinamento e teste

Modelo 7: Utiliza-se os valores preditos de temperatura máxima de topo (TT_{max_pred}) como entradas para o treinamento do modelo

Ao contrário dos dois modelos anteriores, que usam dados reais medidos na pista experimental na etapa de treinamento do modelo, aqui foram usados os dados preditos no primeiro conjunto de experimentos.

Observa-se que ao utilizar os valores preditos de TT_{max} o modelo aprende, de fato, a relação que será utilizada em campo, uma vez que os valores de temperatura máxima de topo reais não são, em geral, conhecidos. Essa abordagem, no entanto, reduz o número de amostras, pois passa-se a ter um único valor de temperatura de topo por data. Nesse caso, calcula-se a média de DT_{max} agrupando os dados por data. Os resultados correspondentes são apresentados nas Figuras 6.16 e 6.17.




Figura 6.16 – Histórico de treinamento do modelo 7 para métrica MSE




Figura 6.17 – Comparação entre valores reais e preditos na etapa de teste (modelo 7)

As métricas do modelo obtidos na etapa de testes foram: $RMSE$: 1,9772; MAE : 1,5642; R^2 : 0,6383. O resumo dos resultados para esse segundo conjunto de experimentos, para previsão do diferencial térmico máximo, considerando a etapa de testes, é apresentado na Tabela 6.8.

Tabela 6.8 – Resultados de precisão dos modelos para previsão da temperatura máxima de topo (melhor resultado em destaque)

Modelo	$RMSE$	MAE	R^2
5	2,9220	2,4248	0,4291
6	2,5506	2,1503	0,5797
7	1,9772	1,5642	0,6383

A comparação entre os modelos 5, 6 e 7 permite a percepção de uma evolução progressiva no desempenho, com reduções consistentes em $RMSE$ e MAE e aumento gradual do R^2 . O $RMSE$ diminui de 2,9220 para 1,9772 ao longo das versões, enquanto o MAE é reduzido de 2,4248 para 1,5642. Paralelamente, o R^2 cresce de 0,4291 para 0,6383.

Apesar dessa contínua melhora, os resultados ainda indicam desempenho moderado. Mesmo no modelo 7, cerca de 36 % da variabilidade da variável resposta permanece não explicada ($R^2 = 0,6383$), o que sugere que o modelo ainda não captura integralmente a estrutura dos dados. Além disso, os valores absolutos de $RMSE$ e MAE ainda podem ser considerados elevados, dependendo da escala e da aplicação prática do problema.

Portanto, embora as modificações tenham produzido avanços consistentes, os indicadores apontam que o modelo ainda apresenta limitações em termos de precisão e poder explicativo, indicando a necessidade de ajustes adicionais, seja na arquitetura, na engenharia de atributos ou na qualidade/quantidade dos dados utilizados.

6.2.3 Previsão do diferencial térmico em função de variáveis climáticas

Os modelos desenvolvidos nos conjuntos de experimentos anteriores possibilitam, partir dos dados climáticos e, posteriormente, dos dados relacionados às placas, chegar na estimação do diferencial térmico. No entanto, tal estimação é realizada em duas etapas.

Nesse terceiro conjunto de experimentos o que se buscou foi desenvolver modelos de previsão do Diferencial Térmico Máximo diretamente a partir dos dados climáticos, em uma única etapa, e sem a necessidade de prever explicitamente a temperatura máxima de topo.

Assim, os modelos criados neste terceiro conjunto de experimentos usam os dados climáticos e a espessura da placa para estimar diretamente o diferencial térmico máximo (DT_{max}). O modelo aprende relações não lineares entre clima + espessura e o diferencial térmico DT_{max} , permitindo estimar esse comportamento para novos cenários.

Modelo 8: Modelo de regressão via rede neural artificial (MLP).

As características e a arquitetura do modelo são como se seguem.

- Variáveis de entrada: umidade, insolação, espessura, temperatura do ar
- Variável alvo: DT_{max}
- Arquitetura: 32 neurônios (ReLU), 16 neurônios (ReLU), 8 neurônios (ReLU), 1 neurônio (saída linear)
- Otimizador: Adam
- Função de custo: MSE
- Métricas avaliadas: MAE , $RMSE$, R^2
- Dados normalizados via StandardScaler
- Divisão treino/teste: 80/20

Os resultados de convergência correspondentes, para a métrica MSE , são ilustrados na Figura 6.18. Uma comparação entre valores reais versus preditos para etapa de teste com coeficiente de determinação é apresentado na Figura 6.19.




Figura 6.18 – Evolução do erro de treinamento e teste para as métricas MSE




Figura 6.19 – Comparação entre valores reais x preditos para etapa de teste – modelo 8

Os resultados apresentados ($RMSE = 2,0245$; $MAE = 1,5984$; $R^2 = 0,6208$) indicam um desempenho intermediário do modelo. A diferença relativamente pequena entre $RMSE$ e MAE sugere que não há predominância de erros extremos muito elevados, isto é, o modelo não parece estar sendo fortemente impactado por *outliers*. O $RMSE$ ligeiramente superior ao MAE é esperado, uma vez que o erro quadrático penaliza mais fortemente desvios maiores.

O valor de $R^2 = 0,6208$ indica que aproximadamente 62 % da variabilidade da variável resposta é explicada pelo modelo. Trata-se de um nível razoável de capacidade explicativa, mas ainda distante de um ajuste considerado forte em aplicações que exigem alta precisão preditiva. Em outras palavras, cerca de 38 % da variância permanece não explicada, o que evidencia espaço para melhorias (teóricas e experimentais).

De forma geral, os resultados apontam para um modelo com desempenho consistente e estável, porém ainda com limitações em termos de poder explicativo e redução de erro, podendo se beneficiar de aprimoramentos na modelagem, seleção de variáveis ou ajuste de hiperparâmetros. Assim, o modelo a seguir (modelo 9) foi criado com um aumento no número de épocas de treinamento.

Modelo 9: aumento do número de épocas de treinamento de 200 para 500.

Resultados correspondentes ao modelo 9 são apresentados nas Figuras 6.20 e 6.21. Observa-se que não houve melhora nos resultados, com uma leve redução no coeficiente de determinação. Resumo das métricas obtidas para esse modelo: $RMSE$: 2,1786; MAE : 1,8372; R^2 : 0,5609.




Figura 6.20 – Erro de treinamento e teste do modelo 9 para a métrica MSE




Figura 6.21 – Comparação entre valores reais versus preditos para etapa de teste

6.2.4 Experimentos adicionais para previsão do diferencial térmico em função de variáveis climáticas

Em função dos resultados apenas moderados, obtidos com o modelo baseado em redes neurais, foram avaliados dois outros modelos de aprendizado de máquina baseados em árvores de decisão: *Random Forest* (RF) e *XGBoost*, ambos amplamente utilizados em tarefas de regressão devido à sua robustez, capacidade de modelar relações não lineares e bom desempenho com dados tabulares.

O Random Forest é um modelo de *ensemble* do tipo *bagging* que combina múltiplas árvores de decisão independentes. Cada árvore é treinada com uma amostra aleatória dos dados (com reposição) e utiliza subconjuntos aleatórios de variáveis em cada divisão. A predição final é obtida pela média das árvores.

Essa estratégia reduz a variância do modelo e evita o sobreajuste, tornando o RF estável e fácil de ajustar. Seus principais hiperparâmetros são o número de árvores (*n_estimators*), profundidade máxima (*max_depth*) e os limites de divisão (*min_samples_split* e *min_samples_leaf*).

O XGBoost (*Extreme Gradient Boosting*) é um modelo baseado na técnica de *boosting*, em que as árvores são construídas de forma sequencial. Cada nova árvore tenta corrigir os erros cometidos pelas árvores anteriores, otimizando uma função de perda através do método do gradiente. O XGBoost inclui melhorias importantes, como regularização (*L1/L2*), controle de taxa de aprendizado (*learning_rate*), amostragem parcial (*subsample*) e divisão controlada de variáveis (*colsample_bytree*), o que resulta em alta precisão e excelente generalização.

Por ser mais sensível aos hiperparâmetros, costuma apresentar desempenho superior quando bem ajustado, especialmente em problemas com padrões complexos.

Os resultados para esses dois novos modelos em comparação aos dois modelos anteriores (modelos 8 e 9), são apresentados na Tabela 6.9.

Tabela 6.9 – Resultados de precisão para etapa de testes na previsão do diferencial térmico máximo a partir dos dados climáticos (melhor resultado em destaque)

Modelo	RMSE	MAE	R ²
8	2,0245	1,5984	0,6208
9	2,1786	1,8372	0,5609
RF	2,1530	1,7550	0,5710
XGBoost	1,9950	1,6140	0,6320

Observa-se que a aplicação do XGBoost para estimação do diferencial térmico máximo diretamente a partir dos dados climáticos produziu resultados com uma precisão semelhante ao melhor resultado obtido utilizando as variáveis explicativas espessura e temperatura máxima de topo com o modelo 7 (Tabela 6.8).

6.3 TÉCNICAS DE FUSÃO DE DADOS E APRENDIZADO PROFUNDO PARA EXTRAÇÃO DE CARACTERÍSTICAS NO PROCEDIMENTO AVANÇADO DE DIMENSIONAMENTO DE PAVIMENTOS DE CONCRETO

Neste item é tratada a aplicação de modelos de aprendizado de máquina na modelagem da resposta estrutural (deflexões máximas e tensões de tração na flexão máximas), a partir de dados simulados por elementos finitos em 2D, conforme exposto no item 3 do presente documento.

Nesta etapa, foram desenvolvidas e testadas diferentes abordagens, tanto para fusão dos dados oriundos das simulações na forma de mapas de *features*, quanto para os modelos de redes neurais profundas aplicados para a estimação da resposta estrutural (tensões e deflexões nas placas de PCS e WT).

O guia empírico-mecanicista de dimensionamento de pavimentos, consolidado no MEPDG da *American Association of State Highway and Transportation Officials* (AASHTO), combina modelos físicos e técnicas de inteligência artificial para estimar o comportamento estrutural de pavimentos de forma eficiente. Em termos gerais, esse método integra análises baseadas em elementos finitos com redes neurais artificiais previamente treinadas, permitindo calcular rapidamente respostas estruturais relevantes, como tensões e deflexões em placas de concreto.

Essa estrutura híbrida apresenta vantagens significativas em termos de rapidez computacional e aplicabilidade prática. Entretanto, sua confiabilidade pode ser reduzida quando aplicada a cenários diferentes daqueles utilizados na calibração original dos modelos. Isso ocorre, por exemplo, em situações envolvendo rodovias de baixo volume de tráfego, bases tratadas com cimento de elevada rigidez ou gradientes térmicos atípicos. Nesses casos, frequentemente torna-se necessário realizar novas simulações numéricas e atualizar ou retreinar os modelos preditivos, o que aumenta o custo computacional e o tempo de análise.

Com o objetivo de reduzir essas limitações, as atividades desenvolvidas neste período investigaram o uso de técnicas de fusão de dados como estratégia para enriquecer a representação das variáveis de projeto. A proposta central consiste em combinar diferentes variáveis relevantes – como carga de eixo e gradiente de temperatura – de modo a gerar representações mais informativas do comportamento estrutural do pavimento. Essas combinações são organizadas em mapas de características, que sintetizam padrões complexos de interação entre variáveis físicas.

Esses mapas são então utilizados como entrada para o treinamento de redes neurais convolucionais, um tipo de modelo de aprendizado profundo especialmente adequado para identificar padrões espaciais em dados estruturados. O uso dessas redes permite não apenas melhorar a capacidade preditiva dos modelos, mas também possibilita uma interpretação visual das interações entre variáveis de projeto, contribuindo para maior transparência e compreensão física dos resultados.

De forma geral, a abordagem proposta estabelece uma estrutura de análise mais robusta e interpretável para a previsão da resposta estrutural de pavimentos em uma gama ampliada de condições de projeto.

Isso contribui para tornar as aplicações mecanístico-empíricas mais confiáveis, especialmente em situações que extrapolam os cenários tradicionais de calibração dos modelos. Além disso, o método favorece a exploração sistemática de novas combinações de parâmetros de projeto, apoiando decisões de engenharia mais fundamentadas e adaptáveis a diferentes contextos operacionais.

6.3.1 Projeto de experimentos e simulação por FEA

Para os experimentos realizados nesta etapa foi considerado um Planejamento Fatorial Completo (*Design of Experiments – DOE*), contemplando cinco variáveis de projeto relevantes para o comportamento de pavimentos rígidos: espessura da placa h (cm); módulo de elasticidade do concreto E (MPa); módulo de reação do subleito k (MPa/m); diferencial de temperatura entre o topo e a base da placa ΔT (°C); carga de eixo simples P (kN) – ver item 3 do presente documento para maiores detalhes -.

Os intervalos de variação dos parâmetros utilizados nas simulações são apresentados na Tabela 6.10, e foram obtidos conforme descrito anteriormente no presente documento (item 3). Conforme apresentado na Tabela 6.10, cada parâmetro de entrada foi avaliado em três níveis discretos, resultando em $3^5 = 243$ configurações experimentais. Para cada configuração, foram obtidas, por meio de simulações mecanicistas, três respostas estruturais: a tensão máxima de tração na direção Y (σ_Y , MPa); a tensão máxima de tração na direção X (σ_X , MPa); e a deflexão máxima da placa (δ , mm).

Tabela 6.10 – Intervalo de variação dos parâmetros de entrada para obtenção das respostas mecânicas da placa

Parâmetro de Entrada	Valores	Observações / Justificativas
Espessura da placa h (cm)	23 – 27 – 30	Valores que abrangem vias de médio a alto volume de tráfego.
Módulo de elasticidade do concreto E (N/mm ²)	30.000 – 37.500 – 45.000	Inclui desde concretos convencionais até concretos de alta resistência.
Módulo de reação do subleito k (N/mm ² /m)	50 – 95 – 140	Valores realistas para placas apoiadas sobre solos/bases granulares, bases asfálticas e camadas cimentadas.
Diferencial linear de temperatura ΔT (°C)	5 – 10 – 15	Valores representativos de condições típicas de clima tropical.
Carga de eixo simples P (kN)	80 – 120 – 160	Valores típicos de projeto, geralmente entre 100 e 130 kN.

6.3.2 Conjunto de dados para modelagem com aprendizado de máquina

As simulações realizadas no ISLAB 2005 compreenderam um conjunto de placas de pavimento interligadas por barras de transferência (*dowel bars*) nas juntas transversais e barras de amarração (*tie bars*) nas juntas longitudinais. A geometria da via hipotética consiste em duas faixas de tráfego e dois acostamentos (via simples). O eixo do caminhão está posicionado sobre a região central de uma das placas, porém mais próximo da junta longitudinal localizada entre a faixa externa e o acostamento. Um exemplo das respostas gráficas de tensões e deflexões é apresentado na Figura 6.22 para a simulação nº 9.

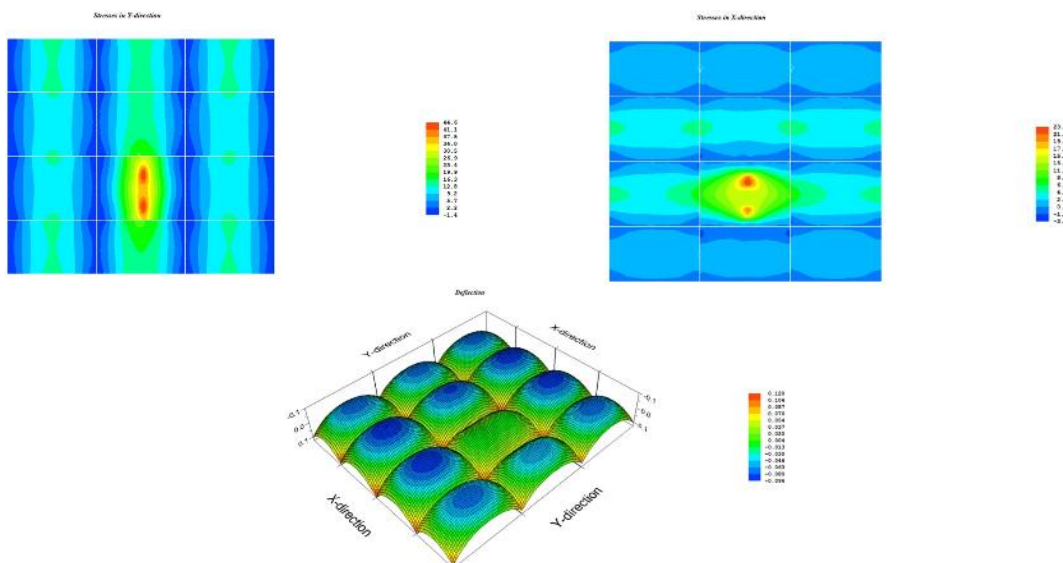


Figura 6.22 – Tensões (nas direções y e x, em MPa × 10) e deflexões (em cm)

Na Tabela 6.11 é apresentado um conjunto de amostras (experimento fatorial parcial) dos parâmetros de entrada utilizados na simulação das tensões (tensão máxima de flexão na base da placa nas direções x e y), bem como das deformações verticais máximas (deflexões) nas placas.

Observa-se que, quando a espessura aumenta, as tensões diminuem; as tensões aumentam conforme a Lei de *Hooke* generalizada quando o módulo de elasticidade E é maior; o ΔT provoca aumento nas tensões e nas deflexões, assim como cargas de eixo mais elevadas.

Tabela 6.11 – Amostra de parâmetros de entrada e respostas mecânicas das placas obtidas por análise de elementos finitos em duas dimensões

Caso	h (cm)	E (MPa)	k (MPa/m)	ΔT (°C)	P (kN)	σ_y (MPa)	σ_x (MPa)	δ (mm)
1	23	30.000	50	5	80	1,75	1,04	0,45
2	23	30.000	50	5	120	2,23	1,33	0,45
3	23	30.000	50	5	160	2,67	1,56	0,49
4	23	30.000	50	10	80	2,41	1,40	0,83
5	23	30.000	50	10	120	2,90	1,71	0,83
6	23	30.000	50	10	160	3,34	1,94	0,83
7	23	30.000	50	15	80	2,86	1,50	1,19
8	23	30.000	50	15	120	3,49	1,98	1,20
37	23	37.500	95	5	80	1,95	1,21	0,36
38	23	37.500	95	5	120	2,38	1,47	0,36
39	23	37.500	95	5	160	2,79	1,68	0,36
40	23	37.500	95	10	80	2,73	1,53	0,70
41	23	37.500	95	10	120	3,31	1,99	0,70
42	23	37.500	95	10	160	3,74	2,27	0,70
43	23	37.500	95	15	80	3,22	1,55	1,03
44	23	37.500	95	15	120	3,92	2,08	1,03
45	23	37.500	95	15	160	4,52	2,54	1,03
73	23	45.000	140	5	80	2,17	1,37	0,33
74	23	45.000	140	5	120	2,57	1,63	0,33
75	23	45.000	140	5	160	2,96	1,83	0,33
76	23	45.000	140	10	80	2,99	1,57	0,65
77	23	45.000	140	10	120	3,62	2,08	0,65
78	23	45.000	140	10	160	4,13	2,49	0,65
79	23	45.000	140	15	80	3,51	1,57	0,95
80	23	45.000	140	15	120	4,26	2,11	0,96
81	23	45.000	140	15	160	4,92	2,59	0,96
145	27	45.000	95	5	80	1,76	0,96	0,40
146	27	45.000	95	5	120	2,13	1,17	0,40

Caso	h (cm)	E (MPa)	k (MPa/m)	ΔT (°C)	P (kN)	σ_Y (MPa)	σ_X (MPa)	δ (mm)
147	27	45.000	95	5	160	2,48	1,33	0,40
148	27	45.000	95	10	80	2,36	1,10	0,73
149	27	45.000	95	10	120	2,89	1,46	0,74
150	27	45.000	95	10	160	3,34	1,75	0,74
151	27	45.000	95	15	80	2,72	1,11	1,04
152	27	45.000	95	15	120	3,33	1,48	1,06
153	27	45.000	95	15	160	3,88	1,82	1,07
208	30	37.500	140	5	80	1,48	0,83	0,32
209	30	37.500	140	5	120	1,77	1,00	0,32
210	30	37.500	140	5	160	2,03	1,12	0,33
211	30	37.500	140	10	80	2,01	0,93	0,61
212	30	37.500	140	10	120	2,43	1,23	0,61
213	30	37.500	140	10	160	2,80	1,47	0,62
214	30	37.500	140	15	80	2,32	0,94	0,87

6.3.3 Redes neurais convolucionais

A proposta de criação de mapas de características a partir dos dados das simulações por elementos finitos possibilitaram explorar o potencial das redes neurais convolucionais, um tipo de modelo de aprendizado profundo, especialmente adequado para identificar padrões espaciais em dados estruturados

Redes Neurais Convolucionais (CNNs) são uma classe de modelos de aprendizado profundo especificamente projetados para processar dados com estrutura em grade, como imagens e sinais distribuídos espacialmente. Ao explorar conectividade local e compartilhamento de pesos, as CNNs conseguem aprender representações hierárquicas de características de forma eficiente, reduzindo significativamente o número de parâmetros treináveis quando comparadas às redes neurais totalmente conectadas.

Uma arquitetura típica de CNN é composta por uma sequência de camadas convolucionais, funções de ativação não lineares, camadas de *pooling* e camadas totalmente conectadas, conforme ilustrado na Figura 6.23. As camadas convolucionais realizam a extração de características por meio da aplicação de um conjunto de filtros (*kernels*) aprendíveis que percorrem os dados de entrada, gerando mapas de características que destacam padrões espaciais relevantes, como bordas, texturas e formas.




Figura 6.23 – Representação esquemática de uma arquitetura padrão de CNN, incluindo camadas convolucionais, funções de ativação, camadas de *pooling* e camadas totalmente conectadas

Para introduzir não linearidade e possibilitar a modelagem de relações complexas, funções de ativação como a Unidade Linear Retificada (ReLU) são aplicadas após cada camada convolucional. Em seguida, camadas de *pooling* são utilizadas para reduzir a resolução espacial dos mapas de características, melhorando a eficiência computacional e proporcionando um certo grau de invariância a translações.

Uma das principais vantagens das CNNs reside na sua capacidade de aprender representações hierárquicas. As camadas mais superficiais geralmente capturam características de baixo nível (por exemplo, bordas e cantos), enquanto as camadas mais profundas aprendem padrões mais abstratos e específicos da tarefa. Esse mecanismo de aprendizado hierárquico torna as CNNs particularmente eficazes para tarefas como classificação de imagens, detecção de objetos, segmentação semântica e detecção de anomalias.

6.3.4 Abordagem proposta: criação dos mapas de características

Como mencionado, foi considerado um Planejamento Fatorial Completo, contemplando cinco variáveis de projeto relevantes para o comportamento de pavimentos rígidos: (a) espessura da placa h (cm); (b) módulo de elasticidade do concreto E (MPa); (c) módulo de reação do subleito k (MPa/m); (d) diferencial de temperatura ΔT ($^{\circ}\text{C}$); e (e) carga de eixo P (kN).

Cada fator foi avaliado em três níveis discretos, resultando em $3^5 = 243$ configurações experimentais. Para cada configuração, três respostas estruturais foram obtidas por meio de simulações mecanicistas: tensão máxima de tração na direção Y (σ_Y , MPa), tensão máxima de tração na direção X (σ_X , MPa) e deflexão máxima da placa (δ , mm).

Para garantir invariância de escala e estabilidade numérica, cada variável de projeto foi normalizada para o intervalo unitário. Assim, os valores das cinco variáveis de projeto em cada linha da Tabela 6.11 resultam em vetor de projeto normalizado definido como:

$$\hat{x} = [\hat{h} \ \hat{E} \ \hat{k} \ \widehat{\Delta T} \ \hat{P}] \quad \text{(Equação 6.1)}$$

Cada configuração experimental (cada vetor) é codificada como um mapa de características que refletem a interação de fatores, representado por uma matriz simétrica:

$$I = \hat{x}^T \hat{x} \quad \text{(Equação 6.2)}$$

ou, explicitamente,

$$I_{ij} = \hat{x}_i \hat{x}_j \quad \text{para} \quad i, j = 1, \dots, 5 \quad \text{(Equação 6.3)}$$

Resultando em uma imagem de dimensão 5×5 para cada amostra. Exemplos dessas imagens geradas para algumas configurações experimentais (amostras do planejamento) são apresentados na Figura 6.24.

Os termos da diagonal (da imagem) representam a intensidade das variáveis de projeto individuais, enquanto os termos fora da diagonal codificam as interações par a par entre os fatores. A estrutura espacial da matriz preserva as relações físicas e permite que os filtros convolucionais aprendam padrões de interação localizados. É importante destacar que essa codificação utiliza apenas variáveis de projeto, garantindo causalidade e possibilitando inferência para combinações inéditas de fatores.




Figura 6.24 – Exemplos de mapas de características obtidos de amostras do planejamento

6.3.5 Metodologia empregada - Modelo de regressão baseado em CNN

Uma rede neural convolucional independente foi treinada para cada variável de resposta (σ_Y , σ_X , δ). A entrada da rede consiste em imagens 5 x 5 de canal único que codificam os fatores experimentais.

A arquitetura é composta por duas camadas convolucionais com profundidade crescente de filtros (16 e 32 filtros, respectivamente), ambas utilizando kernels 3 x 3 e funções de ativação ReLU para capturar interações locais e de ordem superior entre os fatores de entrada. O uso de *kernels* pequenos resulta em menor número de parâmetros e exige menos operações computacionais. As camadas convolucionais são seguidas por uma camada totalmente conectada com 32 neurônios e ativação ReLU, e uma camada final linear de saída que fornece previsões contínuas das respostas-alvo.

O treinamento do modelo foi realizado utilizando o otimizador *Adam*, com taxa de aprendizado de 10^{-3} , e a função de perda erro quadrático médio (*MSE*). Cada modelo foi treinado por 20 épocas, com tamanho de lote (batch size) igual a 16, utilizando um conjunto de validação para avaliar o desempenho de generalização.

Arquiteturas e parâmetros de treinamento idênticos foram adotados para todas as variáveis de resposta, a fim de garantir consistência nas análises.

O desempenho do modelo também foi avaliado por meio do coeficiente de determinação (R^2), calculado independentemente para os conjuntos de treinamento e teste. As análises gráficas incluíram curvas de convergência, comparações entre valores previstos e observados, e distribuições dos resíduos.

6.4 RESULTADOS E DISCUSSÃO

A seguir apresentam-se os resultados obtidos a partir do *framework* de aprendizado de máquina proposto, aplicado ao conjunto de dados de respostas mecanicistas de pavimentos. Inicialmente, o desempenho do modelo é avaliado utilizando métricas padrão de regressão e análises de resíduos para as tensões máximas previstas e as deflexões. Em seguida, a capacidade preditiva e o comportamento de generalização da rede neural convolucional são analisados por meio da comparação entre os conjuntos de treinamento e teste. Em conjunto, esses resultados fornecem uma avaliação abrangente da acurácia, robustez e consistência física da abordagem proposta.

Na Figura 6.25 é apresentada a convergência da função de perda durante o treinamento e o teste para as tensões máximas nas direções x e y, indicando um comportamento de aprendizado relativamente estável, sem evidências de sobreajuste.




Figura 6.25 – Convergência da função de perda *MSE* durante o treinamento e o teste para a tensão máxima nas direções (a) x e (b) y

Na Figura 6.26 são apresentadas as respostas previstas *versus* observadas para os conjuntos de treinamento e teste, considerando as três variáveis de resposta. A CNN alcançou coeficientes de determinação de $R^2 = 0,963$, $R^2 = 0,967$ e $R^2 = 0,995$ no conjunto de teste para as respostas tensão máxima na direção x, tensão máxima na direção y e deflexão máxima, respectivamente, demonstrando forte capacidade preditiva e bom desempenho de generalização.

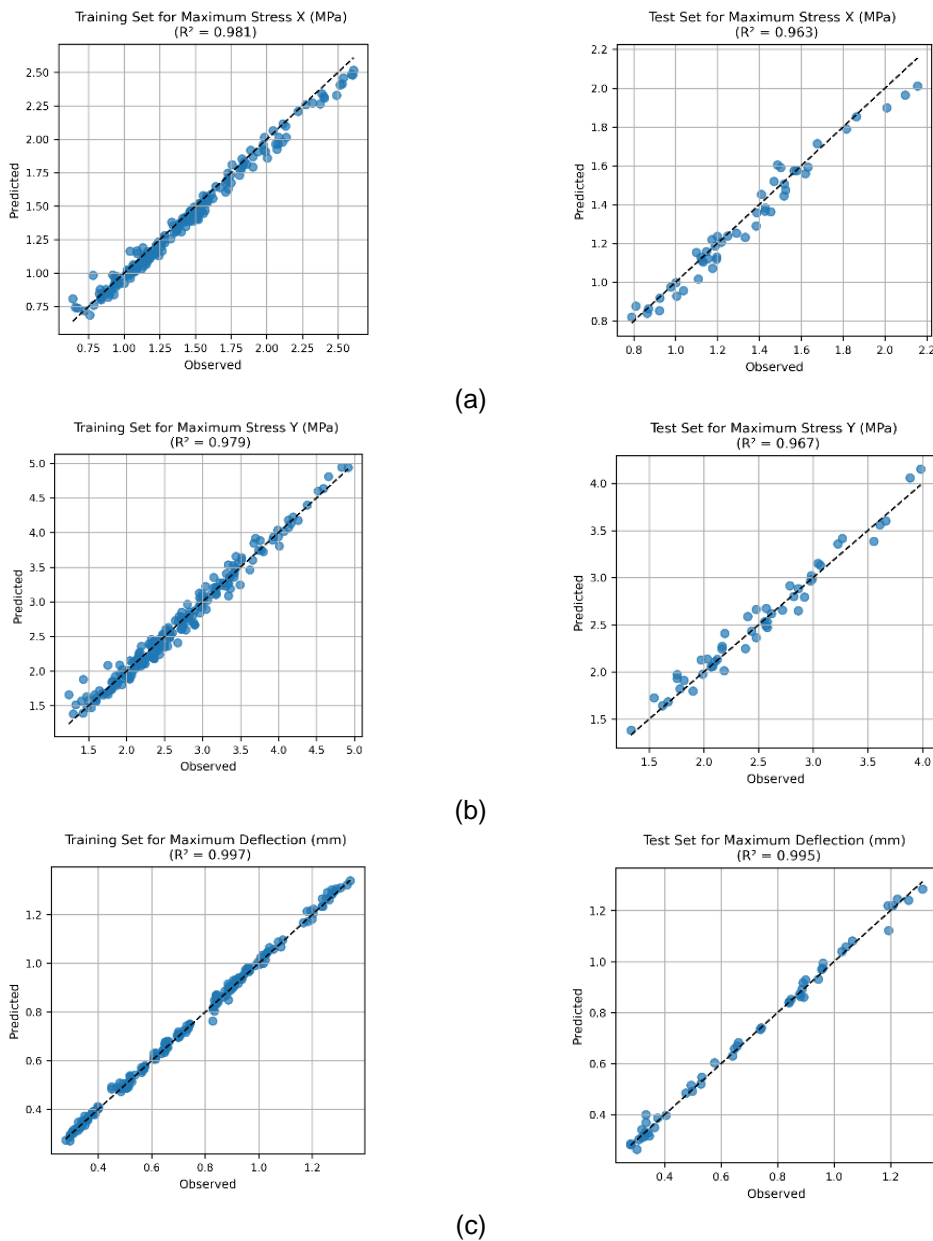


Figura 6.26 – Respostas previstas versus observadas para os conjuntos de treinamento e teste, para (a) tensão máxima na direção x, (b) tensão máxima na direção y e (c) deflexão máxima

As análises de resíduos realizadas no conjunto de teste indicam que o modelo CNN proposto fornece previsões não viesadas para todas as respostas estruturais. A deflexão máxima apresenta a menor dispersão dos resíduos, seguida pela tensão máxima na direção x, enquanto a tensão máxima na direção y apresenta maior variabilidade devido à sua maior sensibilidade a efeitos térmicos e de contorno. De modo geral, os padrões dos resíduos confirmam a robustez e a consistência física da abordagem de modelagem proposta.

6.5 CONSIDERAÇÕES FINAIS

Este estudo da aplicação de modelos de aprendizado de máquina na modelagem da resposta estrutural de placas de PCS, a partir de dados simulados por elementos finitos em 2D, apresentados no presente documento, propôs um novo *framework* orientado por dados para aplicações em engenharia de pavimentos, baseado na fusão de amostras provenientes do planejamento de experimentos (DOE) em representações baseadas em imagens, as quais são posteriormente utilizadas para treinar um regressor fundamentado em rede neural convolucional (CNN).

Os resultados demonstram forte desempenho preditivo para respostas relevantes do pavimento, incluindo as tensões máximas nas direções x e y e a deflexão máxima, com coeficientes de determinação consistentemente elevados tanto para os conjuntos de treinamento quanto de teste. Esses achados indicam que a abordagem proposta é capaz de capturar com precisão as relações não lineares entre as variáveis de projeto e as respostas estruturais, mantendo bom desempenho de generalização.

A principal contribuição desta proposta reside na codificação baseada em imagens das variáveis de projeto do pavimento. Ao transformar as amostras do DOE em matrizes bidimensionais estruturadas, a abordagem possibilita a exploração plena da capacidade da CNN de aprender padrões espaciais, que podem não ser capturados de forma eficiente quando se utilizam entradas vetoriais tradicionais. Essa estratégia de fusão de dados permite que os filtros convolucionais identifiquem padrões localizados e características hierárquicas que relacionam diretamente os parâmetros de projeto do pavimento às respostas mecânicas, ampliando a capacidade de modelagem de sistemas de pavimentos complexos.

As imagens geradas representam explicitamente tanto os efeitos individuais dos fatores quanto suas interações, que são fundamentais na análise do comportamento de pavimentos. Os termos da diagonal codificam a intensidade das variáveis de projeto individuais, enquanto os termos fora da diagonal representam as interações par a par entre os fatores. A organização espacial da matriz preserva as relações físicas entre as variáveis de projeto, permitindo que a CNN aprenda mecanismos orientados por interações que influenciam as respostas do pavimento sob carregamento. Isso é particularmente relevante na engenharia de pavimentos, onde propriedades dos materiais, configurações das camadas e condições de carregamento interagem de maneira altamente acoplada.

APÊNDICE A – CASOS DE SIMULAÇÕES 2D DE PCS: IMAGENS DE SAÍDA GERADAS PELO PROGRAMA ISLAB 2005

Neste Apêndice A as saídas de respostas de alguns dos 405 casos modelados para o presente estudo. Na sequência são apresentadas, primeiramente, as saídas de resultados dos esforços máximos nas direções X e Y, e posteriormente, os resultados de deflexões produzidas pela combinação de carga de eixo e diferencial de temperatura definida para caso. Os casos apresentados referem-se àqueles tabulados na Tabela 3.5 – Casos avaliados por modelagem FEM-2D, do item 3.3.2 na página 75 do presente relatório.

Justifica-se aqui a apresentação de apenas alguns casos selecionados para economicidade de figuras no presente documento, sendo que as imagens para todas as simulações estão devidamente arquivadas e registradas nos arquivos digitais empregados para memória documental de todos os trabalhos realizados no bojo da presente pesquisa.

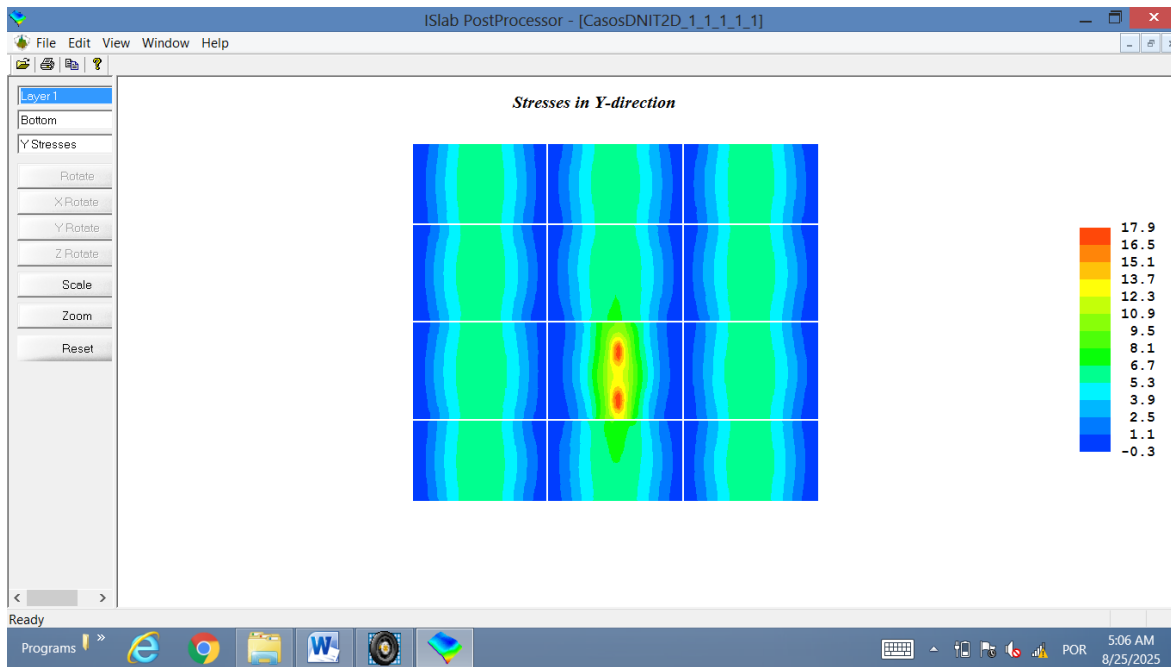
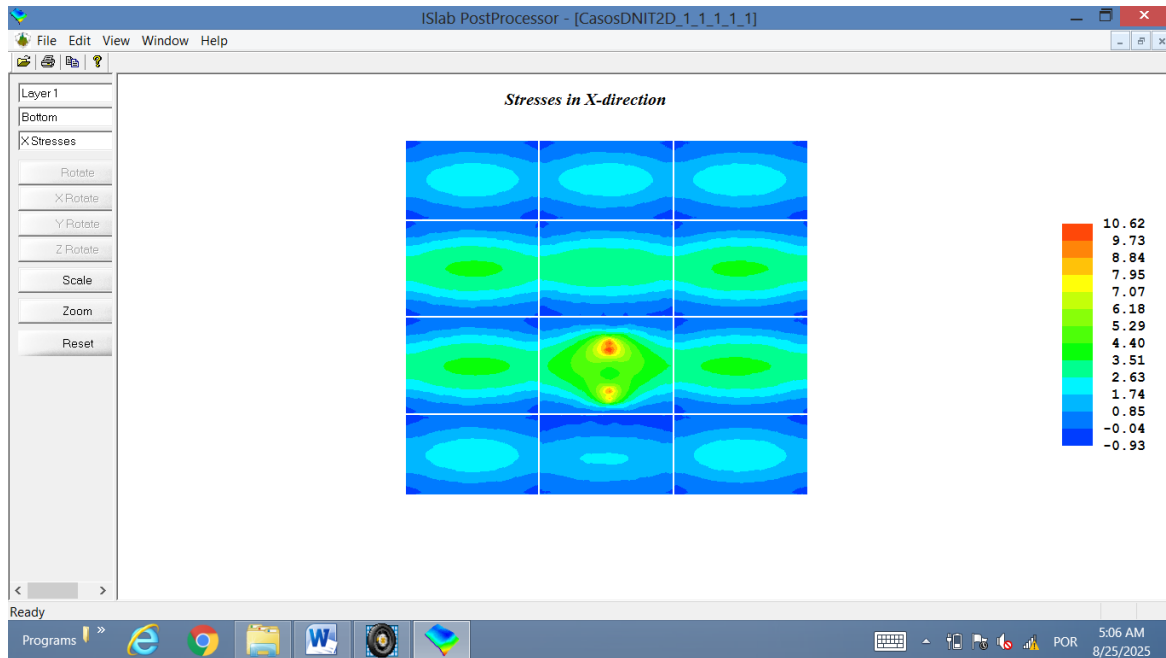
Para melhor compreensão das condições de contorno empregadas em cada caso das simulações realizadas (o que é devidamente indicado na Tabela 3.5 acima referida), apresenta-se uma Tabela A.1 simplificada, com indicação, apenas para os casos ilustrado neste apêndice, do caso, da espessura da placa de concreto, do módulo de elasticidade do concreto, do módulo de reação do subleito, do diferencial térmico entre topo e fundo da placa de concreto e da carga total sobre o eixo simples de rodas duplas posicionado sobre a placa de concreto.

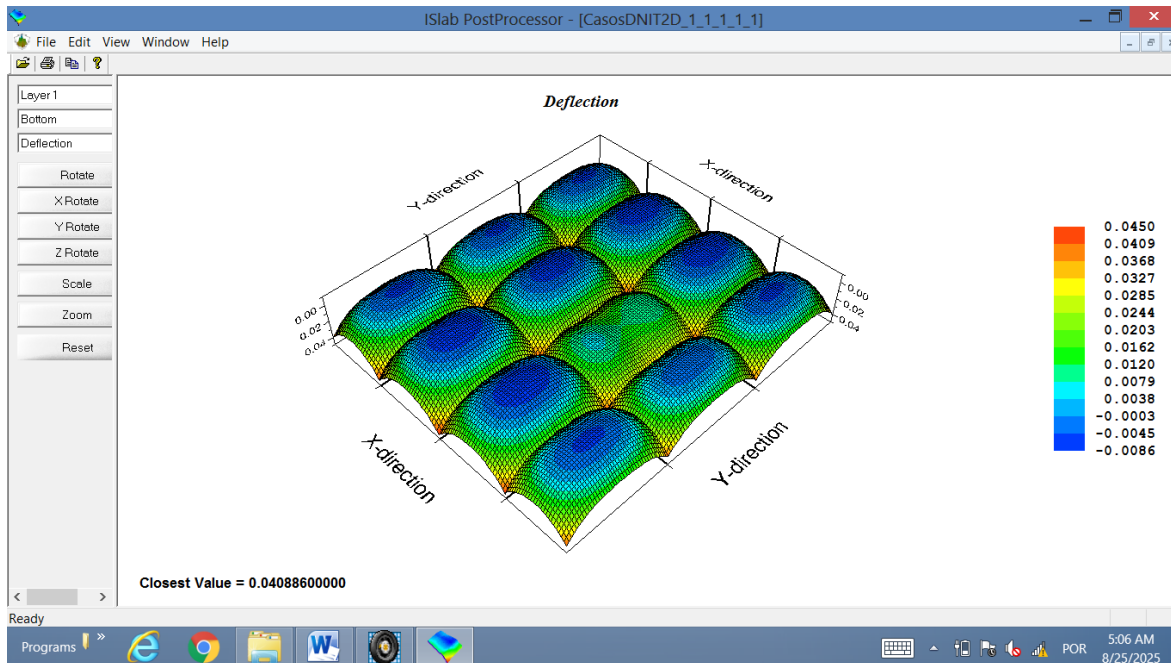
Tabela AP 1 – Condições de contorno para os casos indicados nas imagens do Apêndice 1

Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)
2	23	30.000	50	5	80
5	23	30.000	50	5	160
13	23	30.000	50	15	120
15	23	30.000	50	15	160
20	23	30.000	95	5	160
24	23	30.000	95	10	140
37	23	30.000	140	10	80
50	23	37.500	50	5	160
69	23	37.500	95	10	140
72	23	37.500	95	15	80
83	23	37.500	140	10	120
100	23	45.000	50	10	160

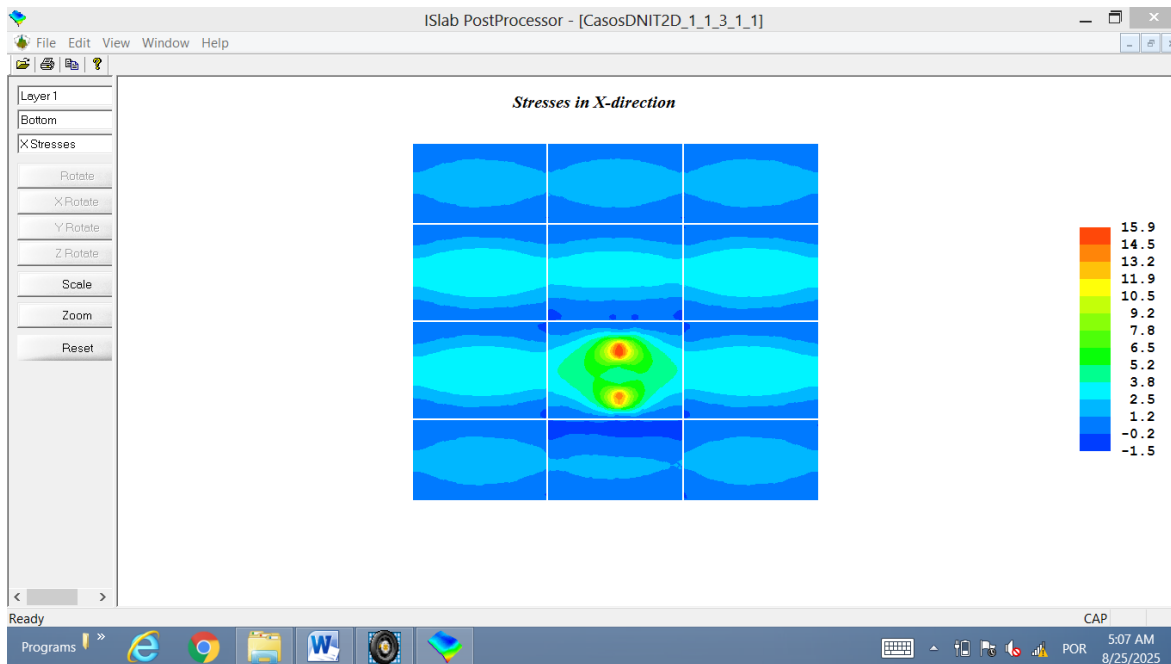
Caso	Espessura (cm)	Módulo de elasticidade (MPa)	Módulo de reação do subleito (Mpa/m)	Diferencial de temperatura (°C)	Carga do eixo (kN)
110	23	45.000	95	5	160
124	23	45.000	140	5	140
153	27	30.000	95	5	120
154	27	30.000	95	5	140
155	27	30.000	95	5	160
156	27	30.000	95	10	60
157	27	30.000	95	10	80
158	27	30.000	95	10	120
159	27	30.000	95	10	140
168	27	30.000	140	5	120
171	27	30.000	140	10	60
191	27	37.500	50	15	60
228	27	45.000	50	5	120
246	27	45.000	95	10	60
250	27	45.000	95	10	160
258	27	45.000	140	5	120
279	30	30.000	50	10	140
285	30	30.000	50	15	160
305	30	30.000	140	5	160
338	30	37.500	95	10	120
356	30	37.500	140	15	60
364	30	45.000	50	5	140
372	30	45.000	50	15	80
393	30	45.000	140	5	120
402	30	45.000	140	15	80
403	30	45.000	140	15	120
404	30	45.000	140	15	140
405	30	45.000	140	15	160

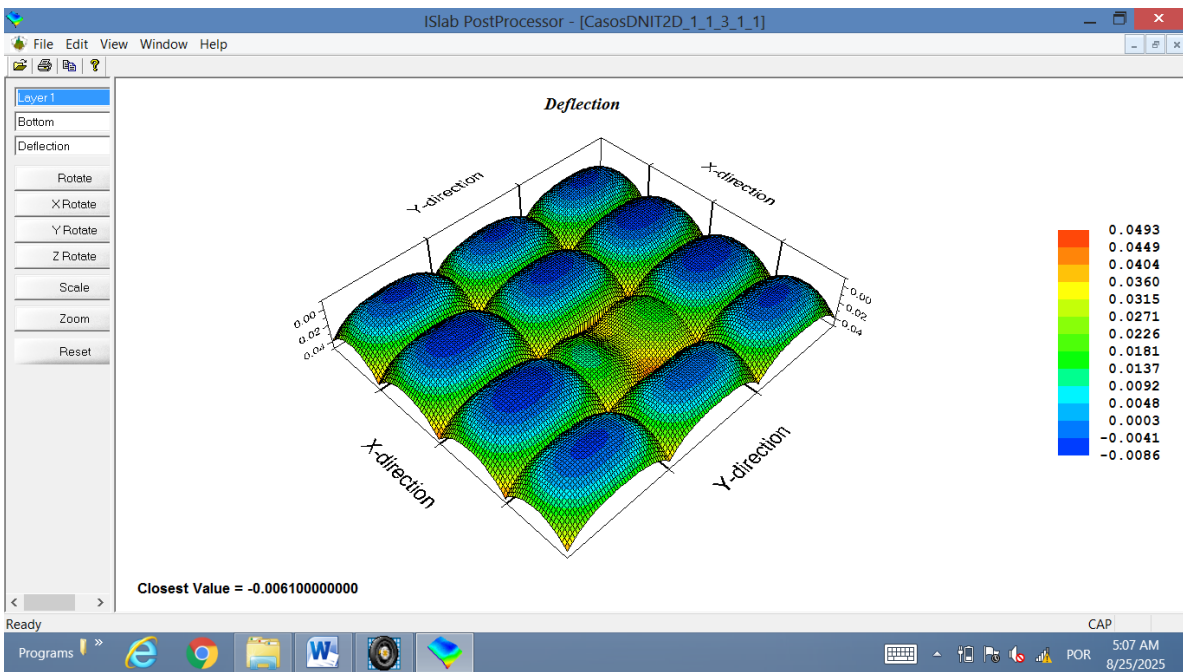
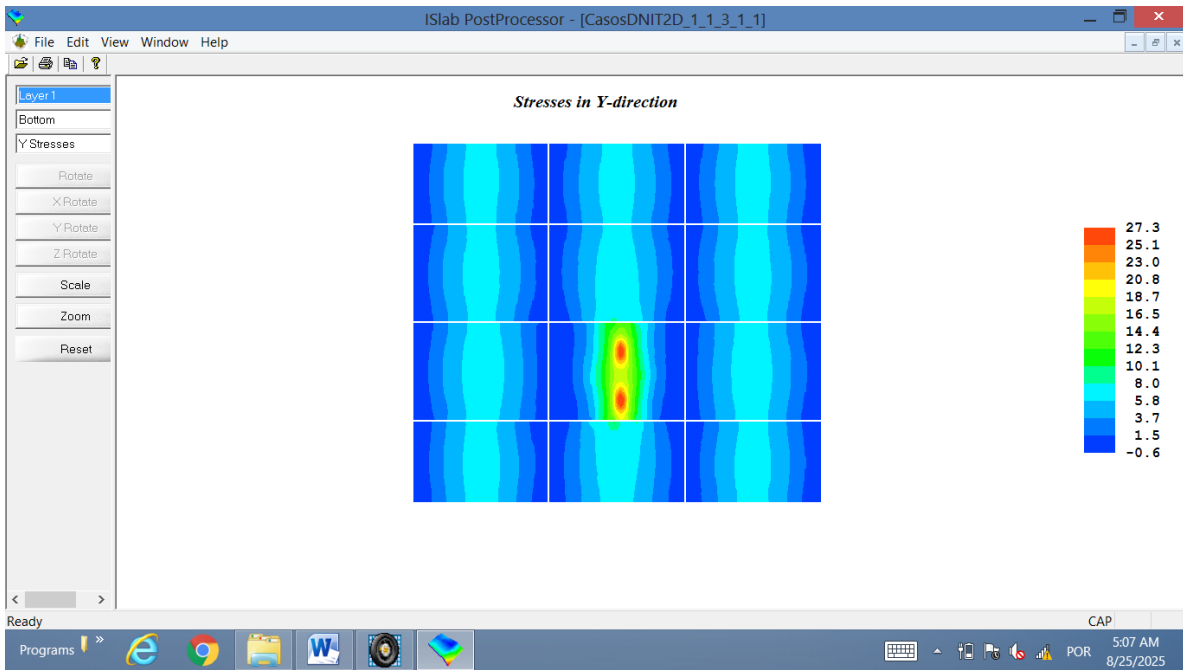
- Caso 2



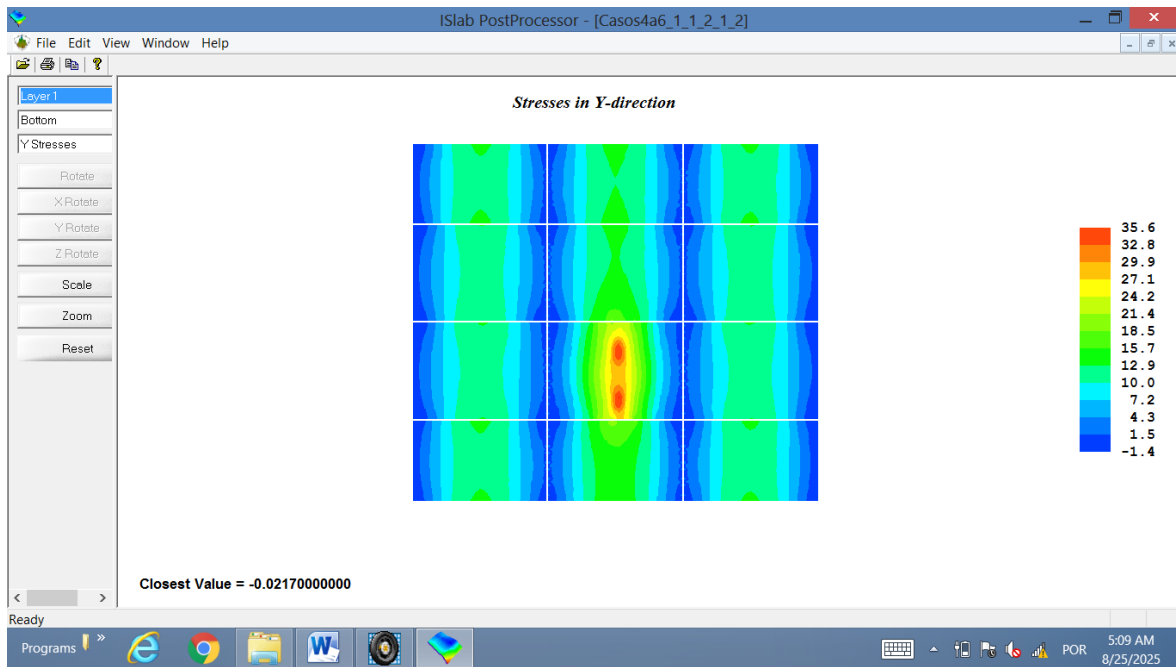
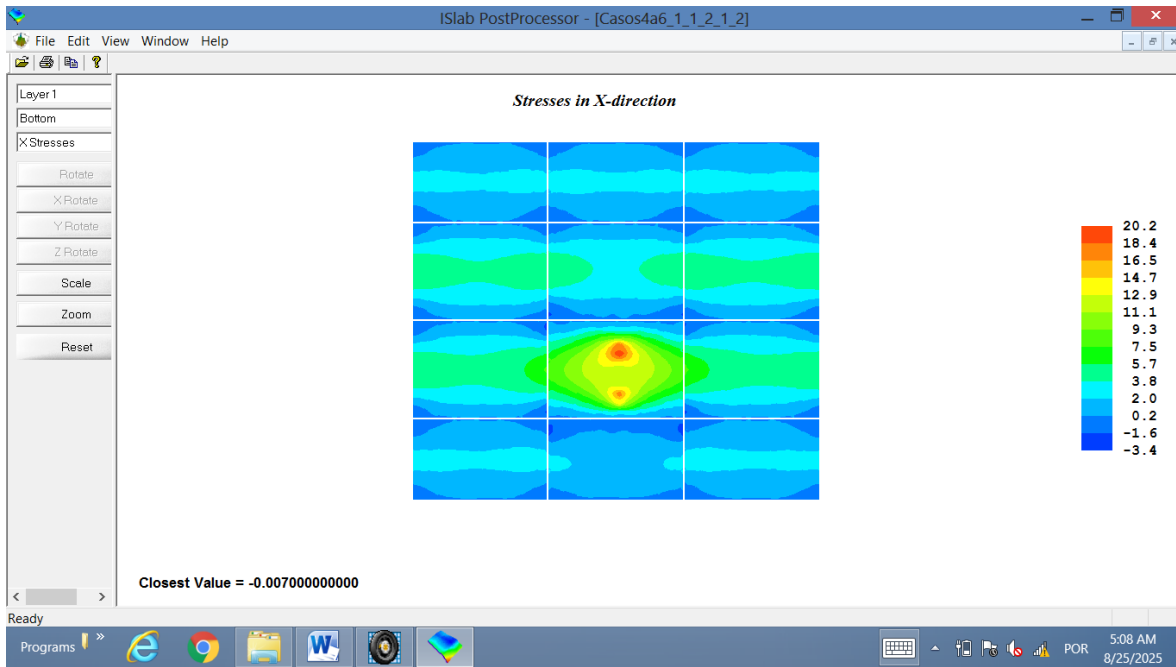


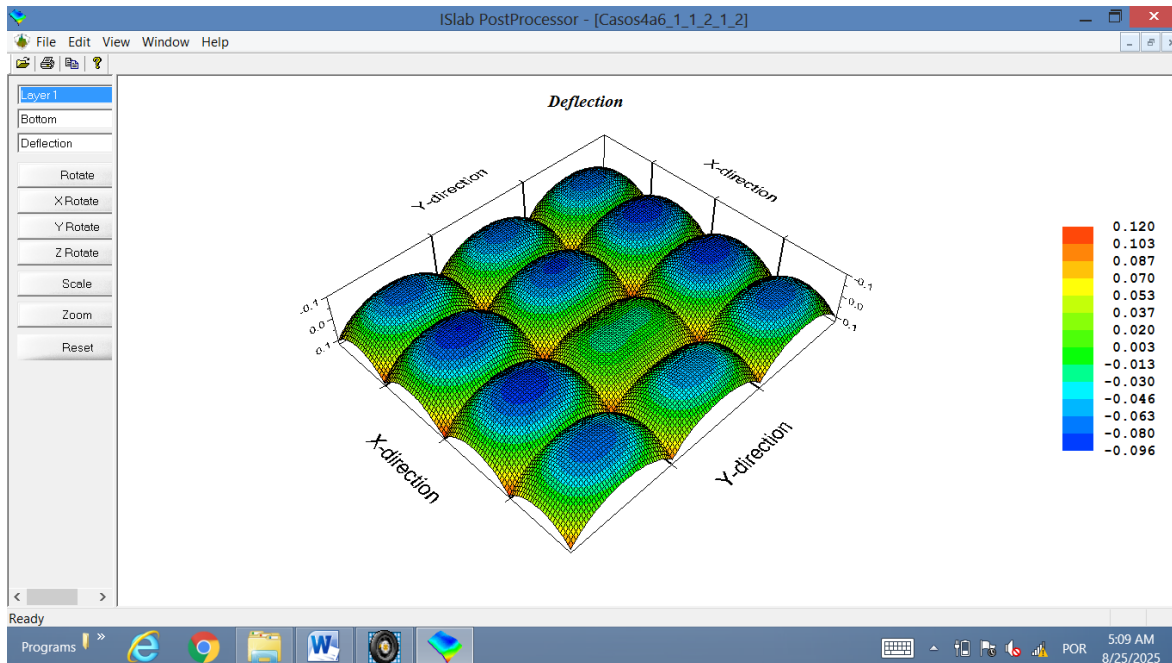
- Caso 5



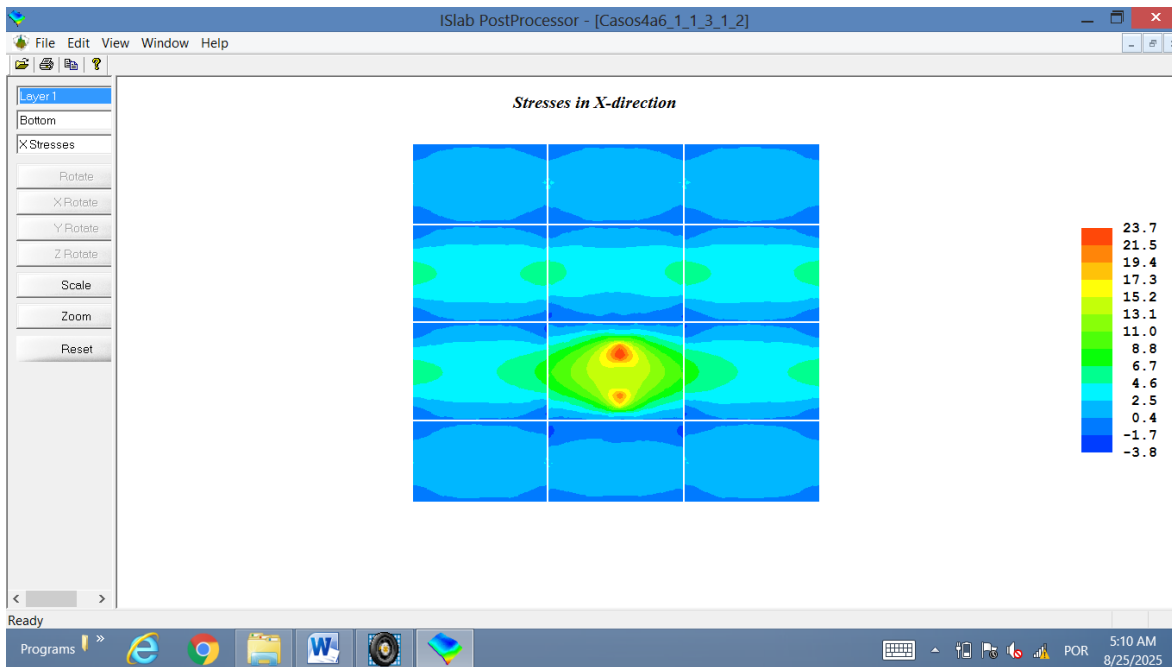


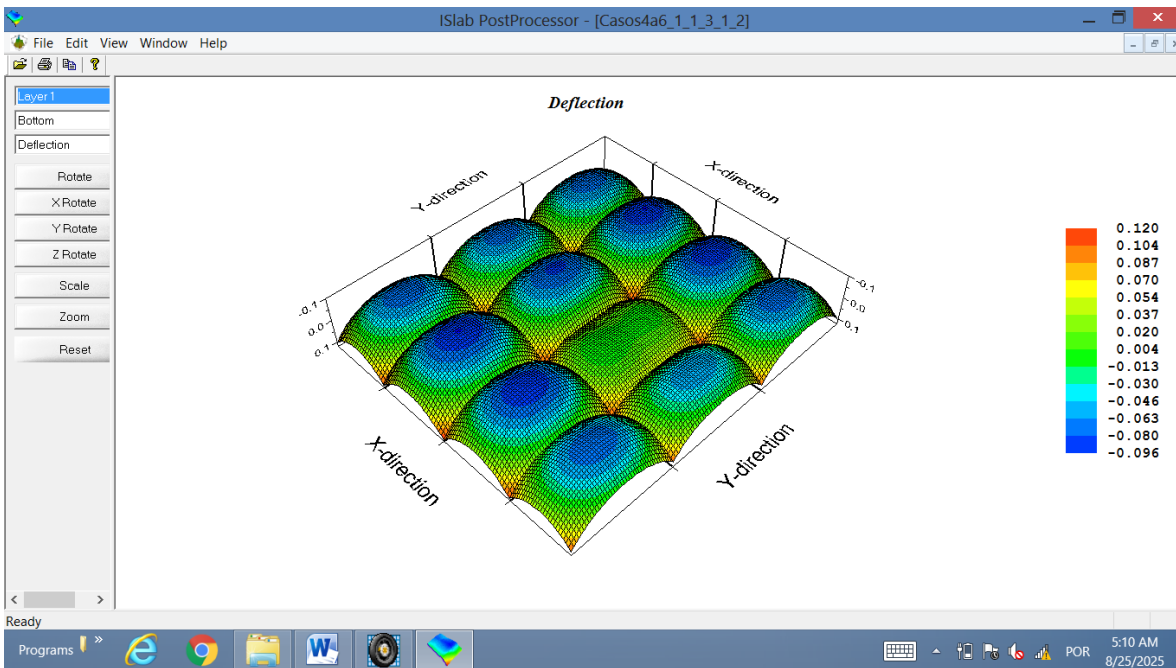
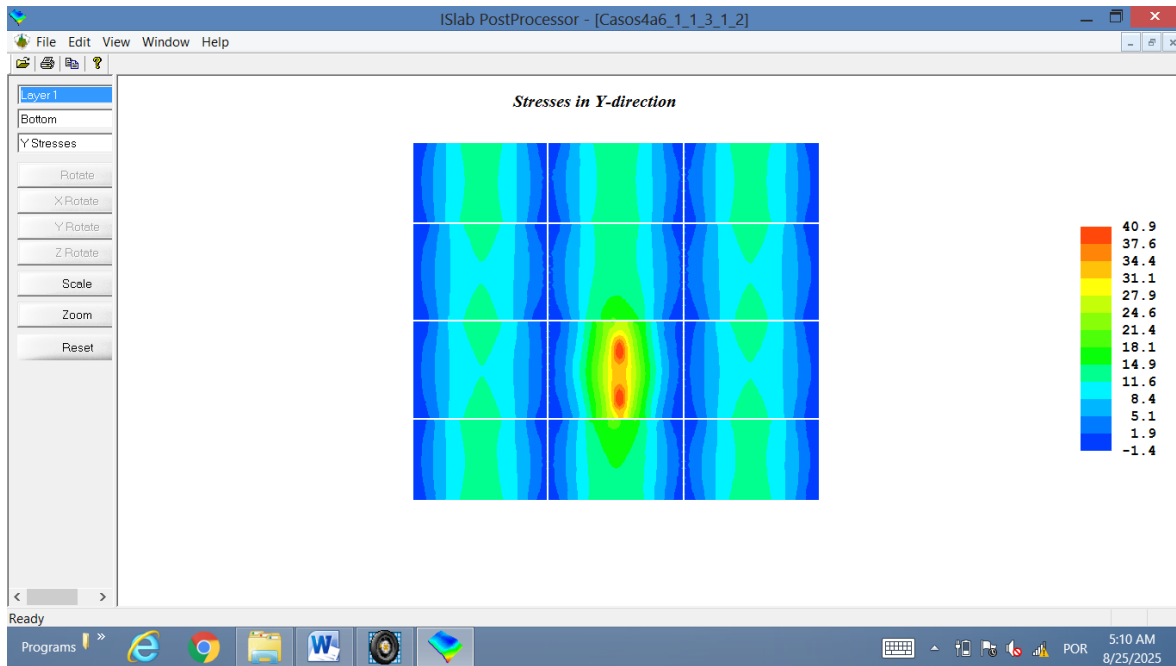
- Caso 13



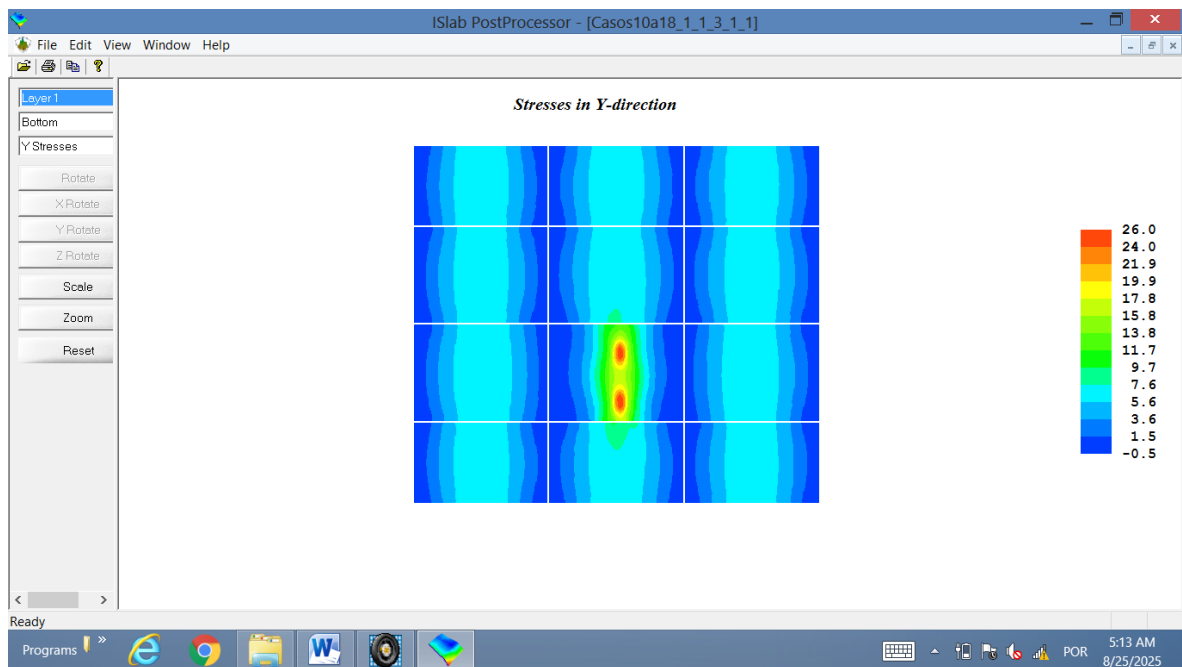
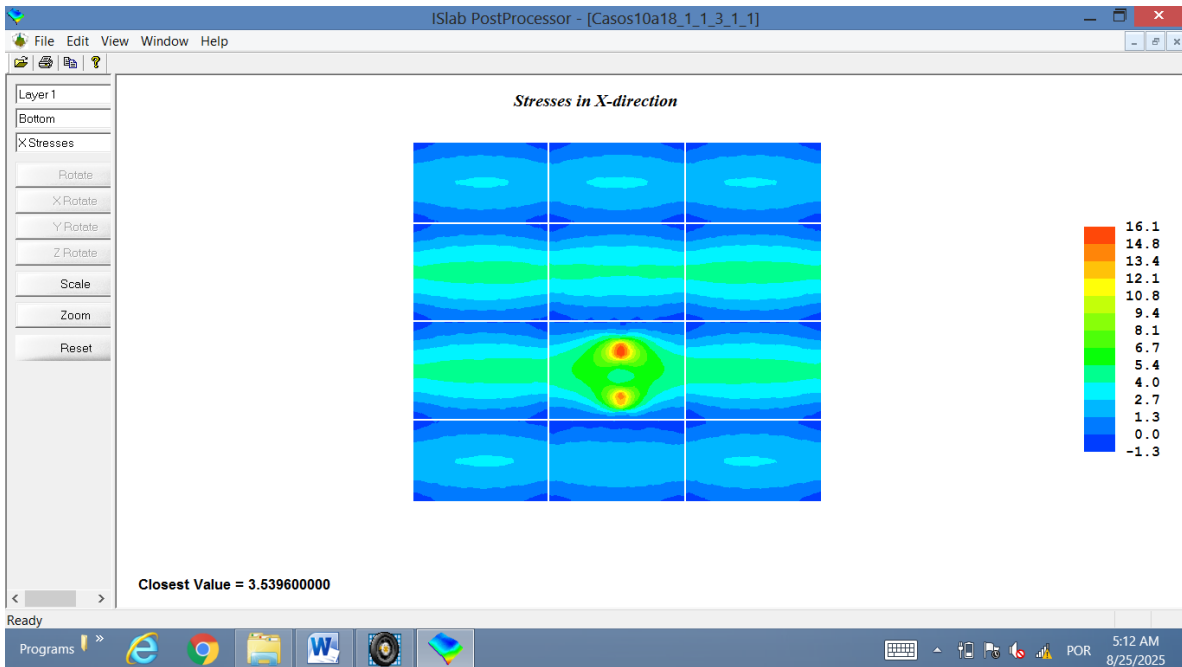


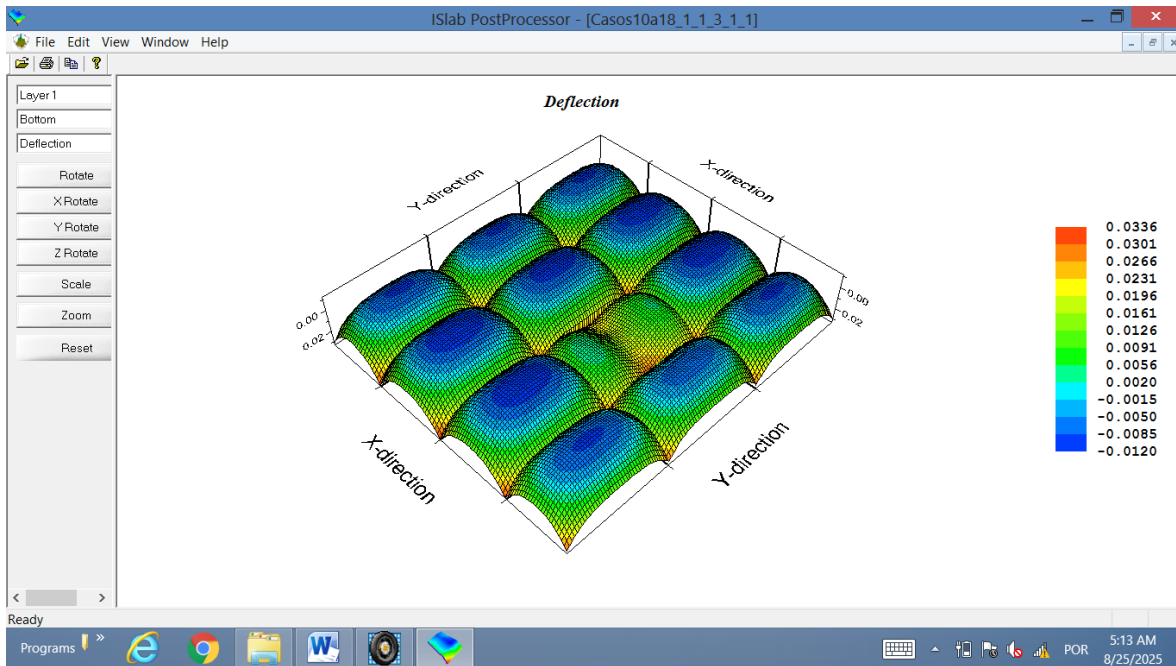
- Caso 15



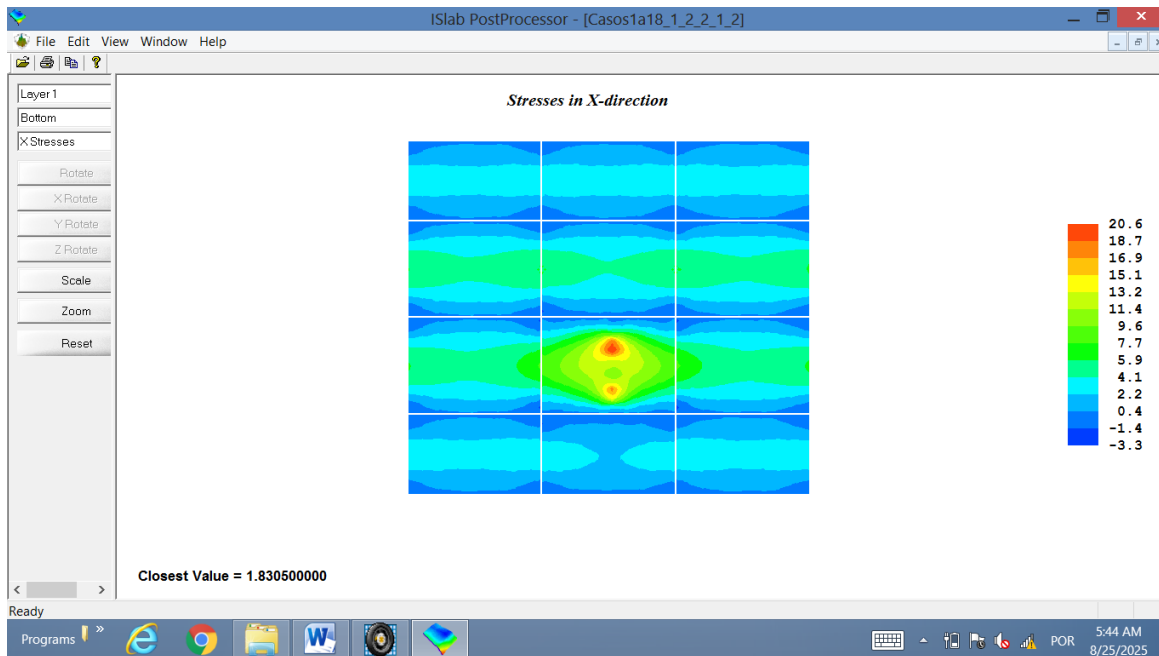


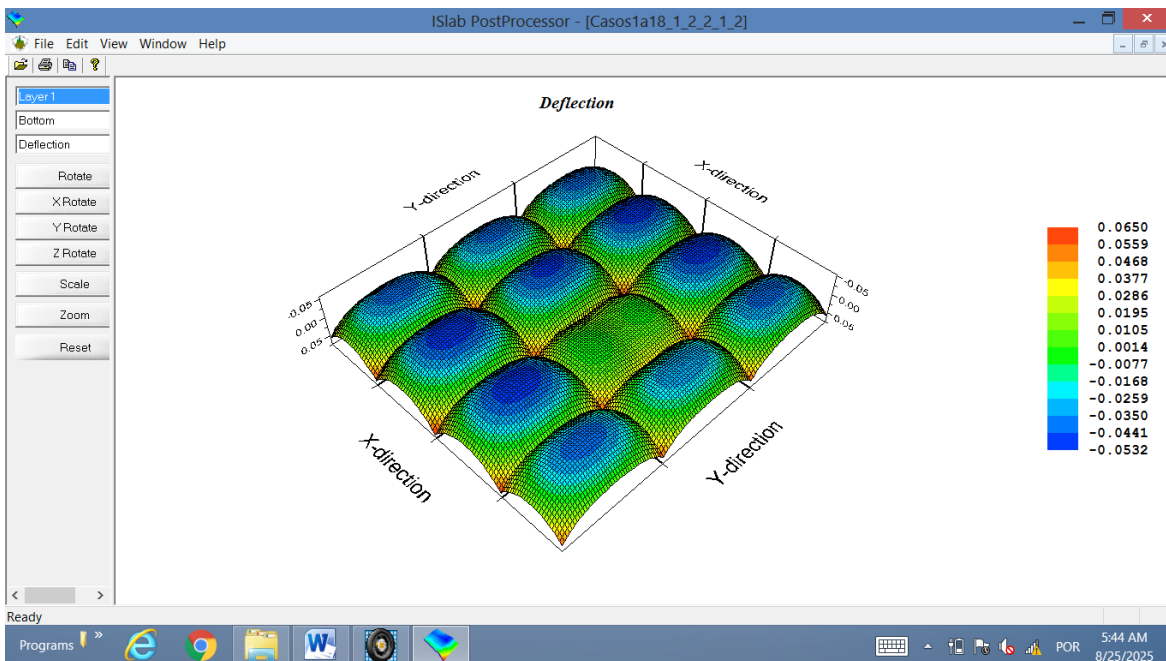
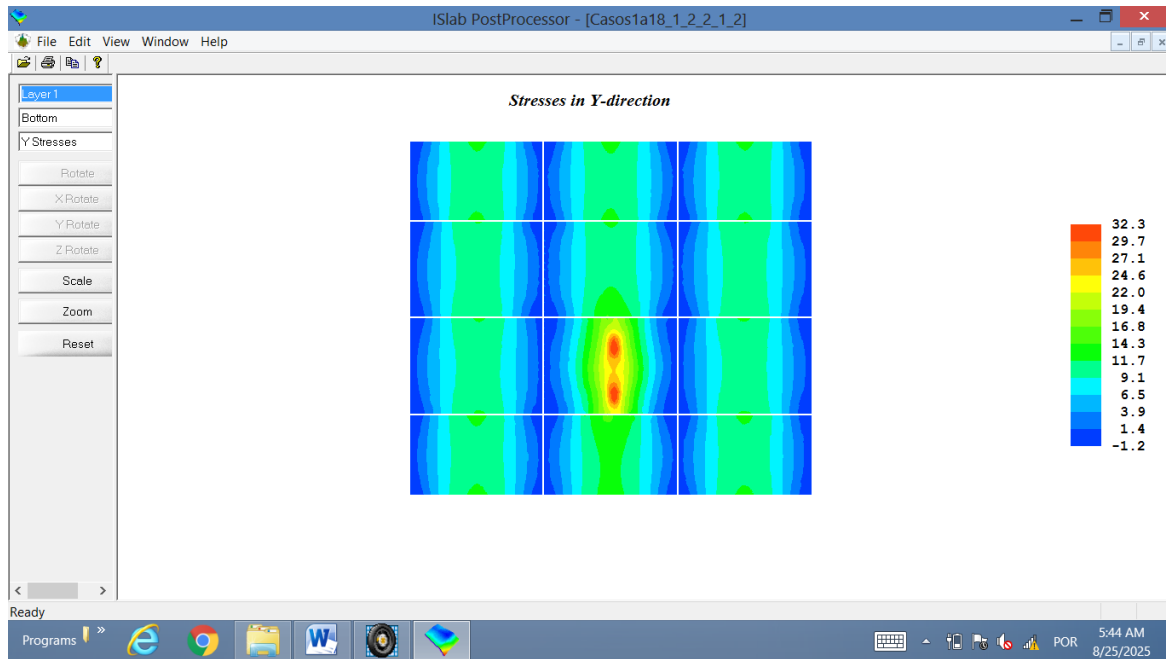
- Caso 20



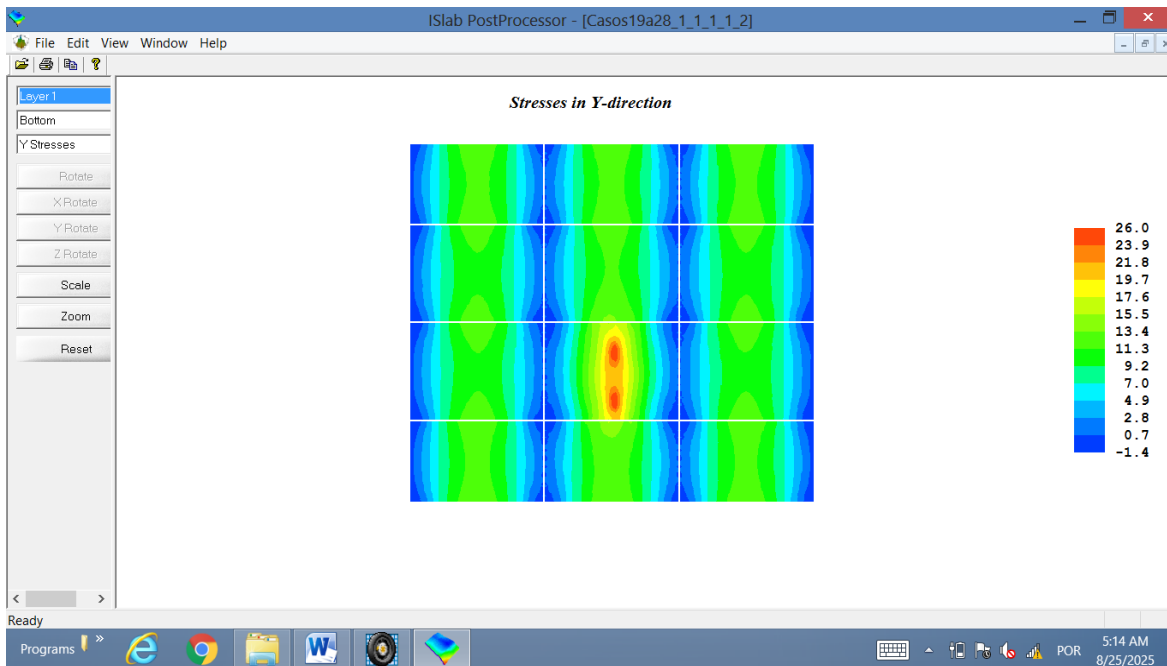
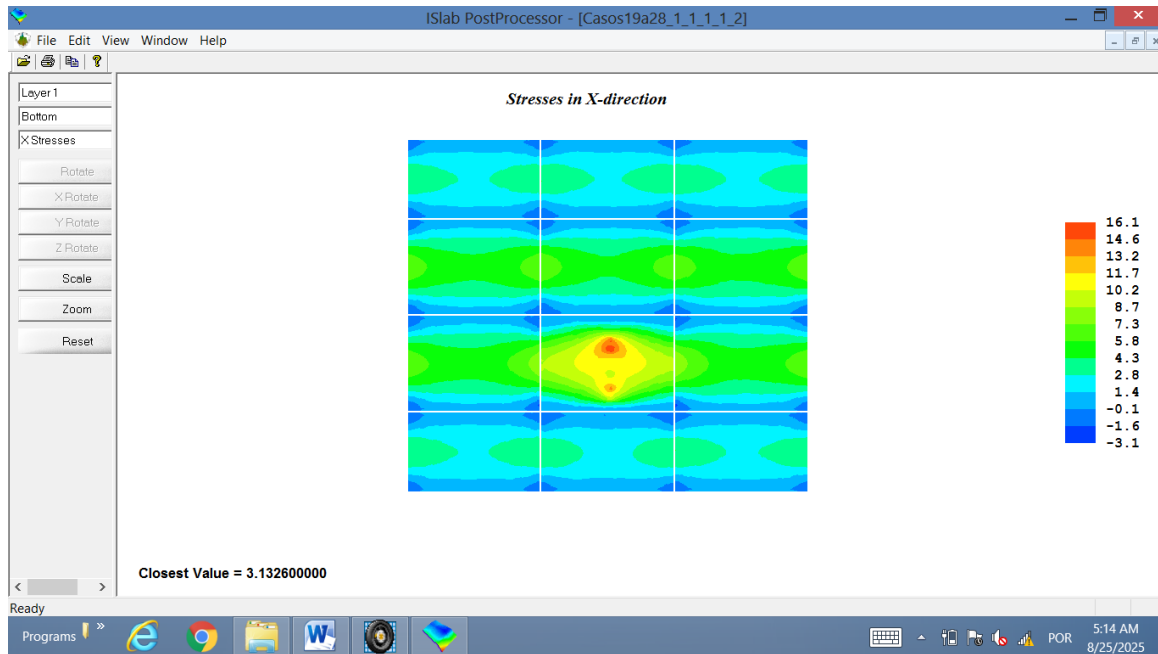


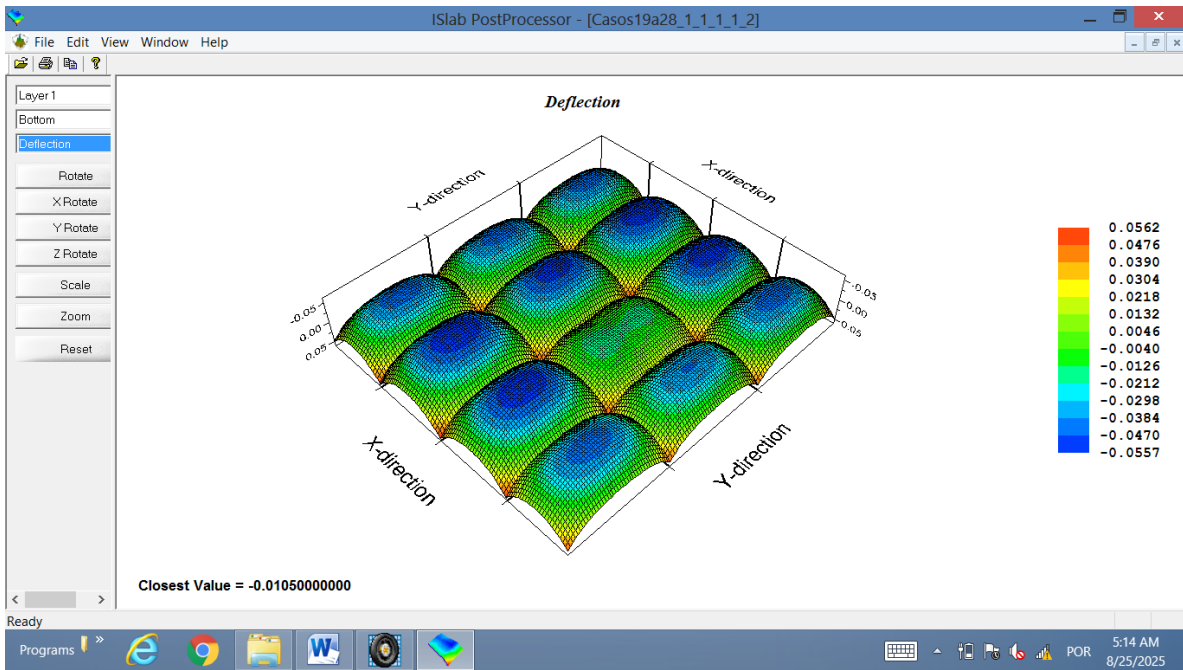
- Caso 24



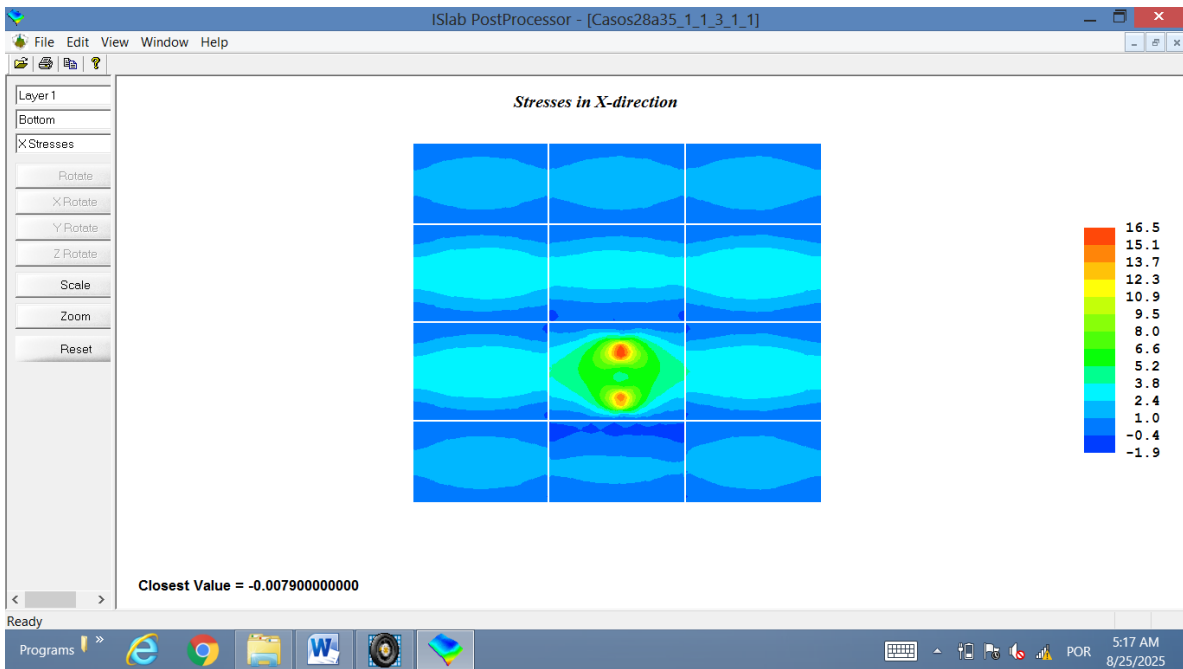


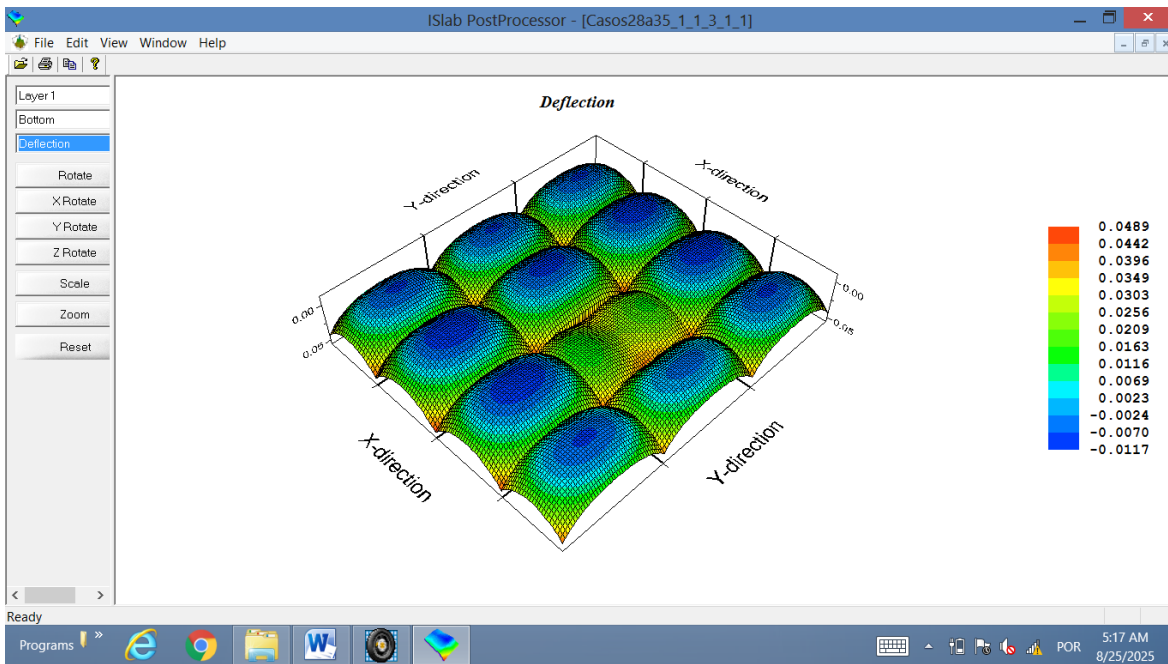
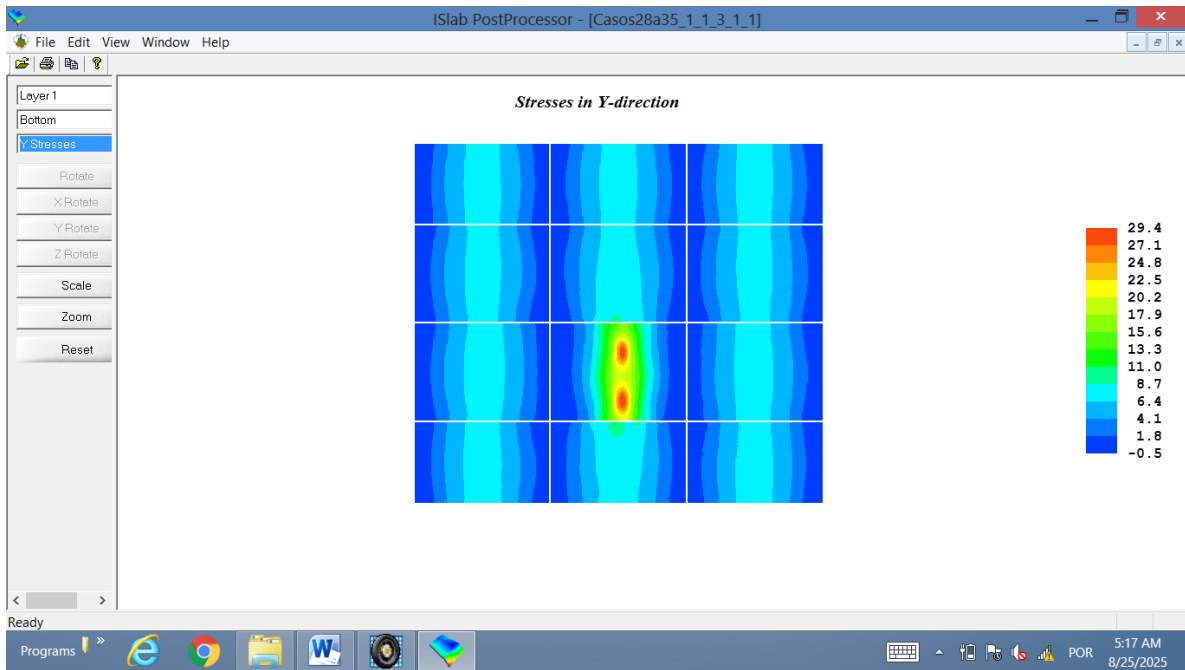
- Caso 37



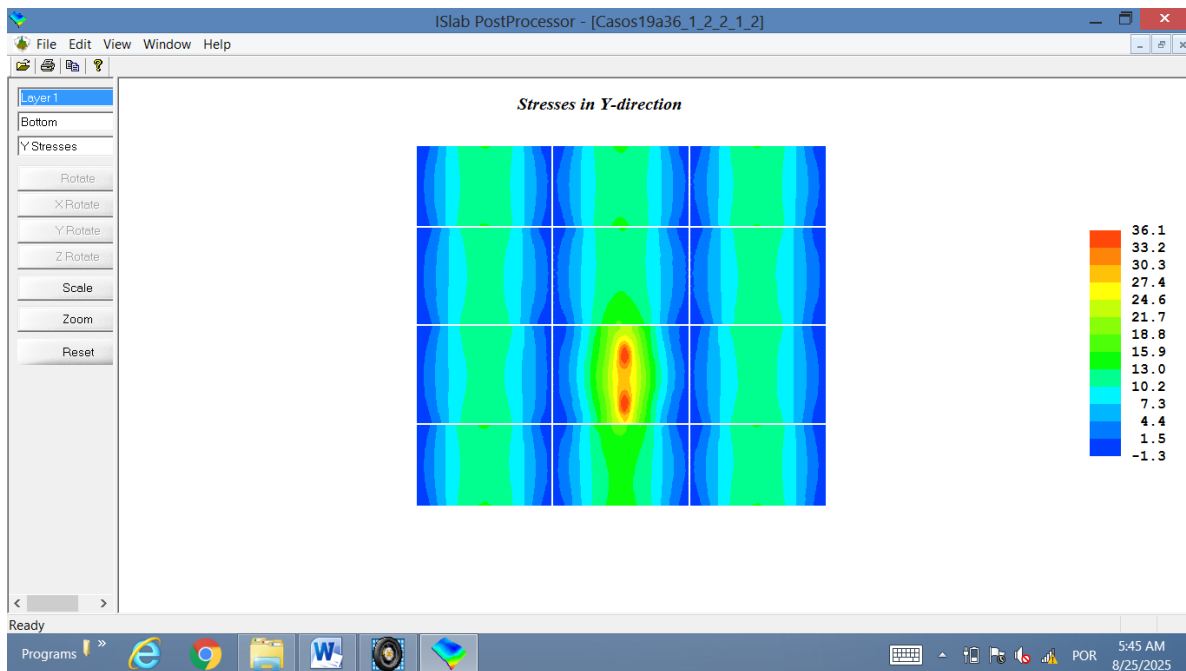
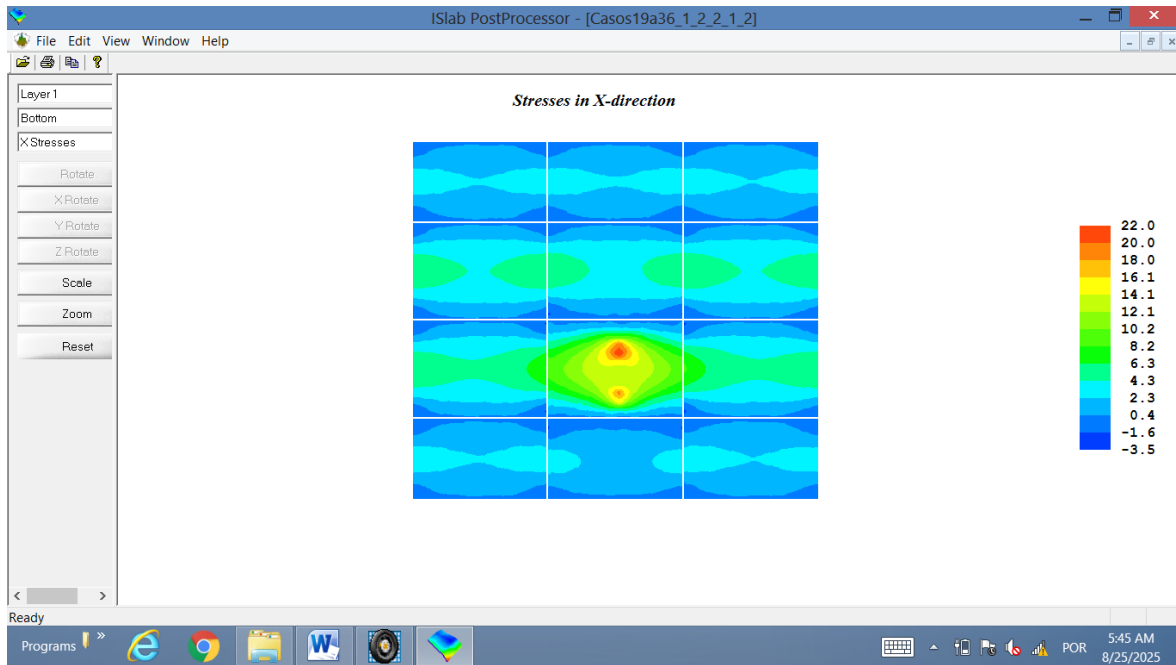


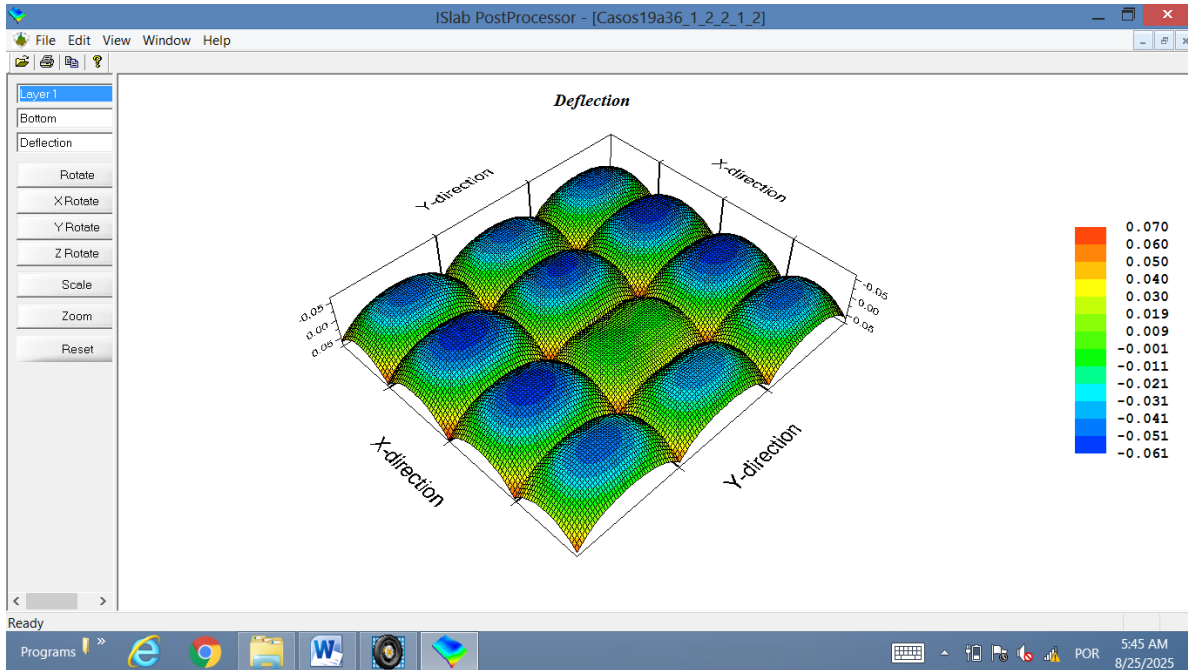
- Caso 50



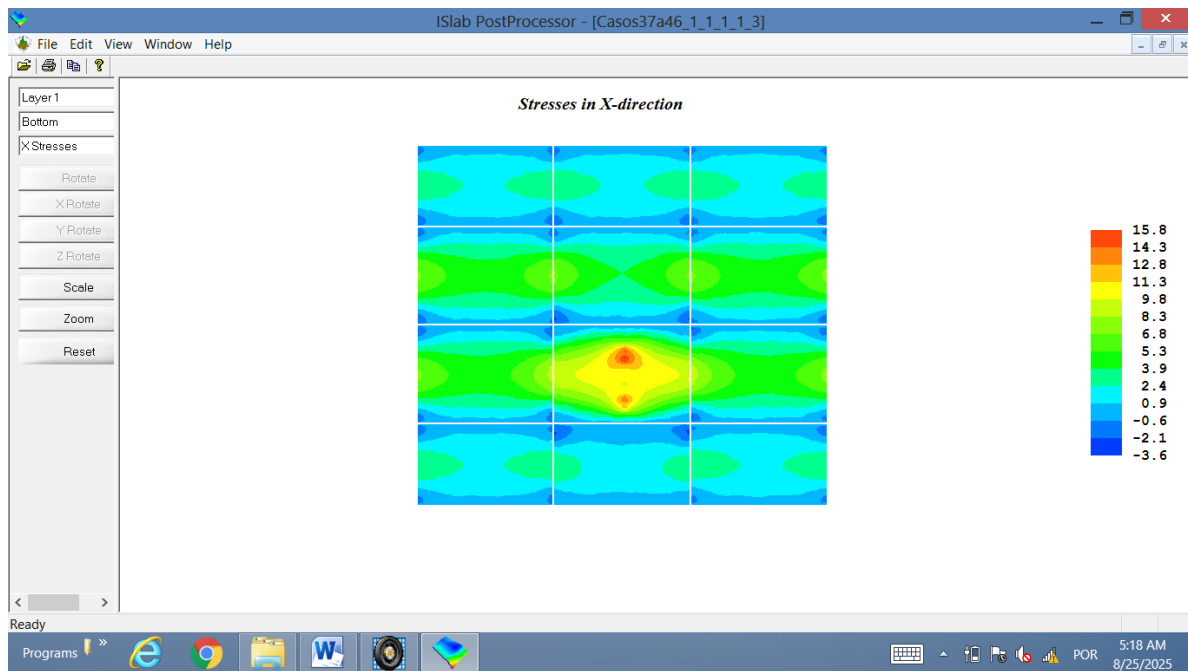


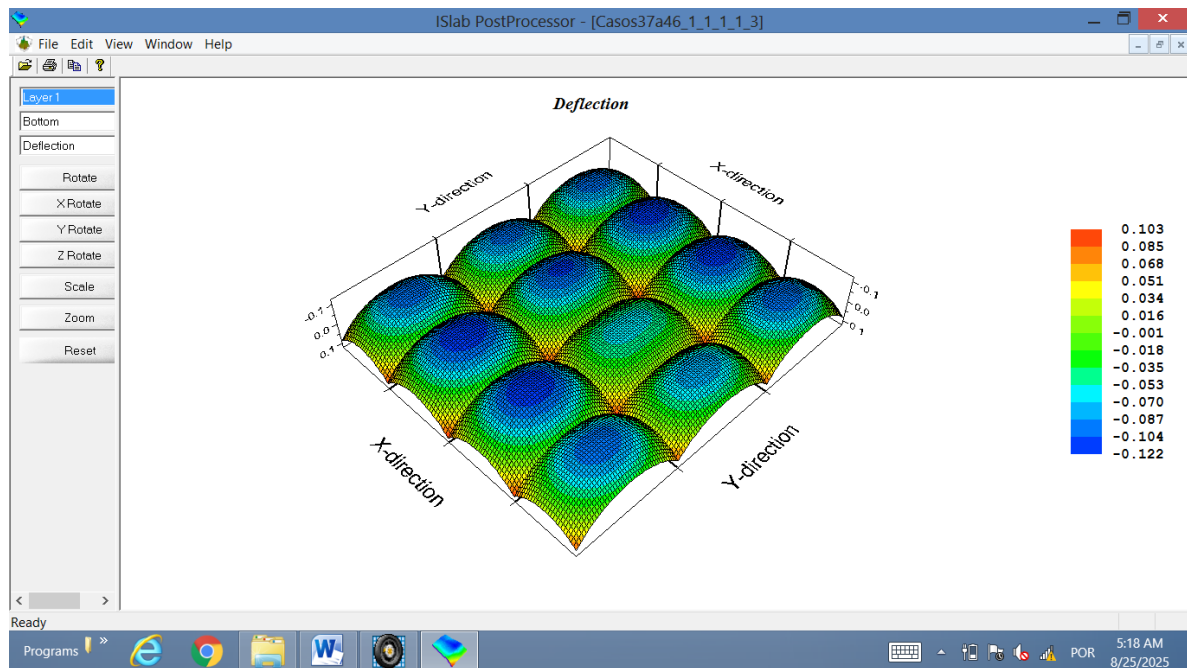
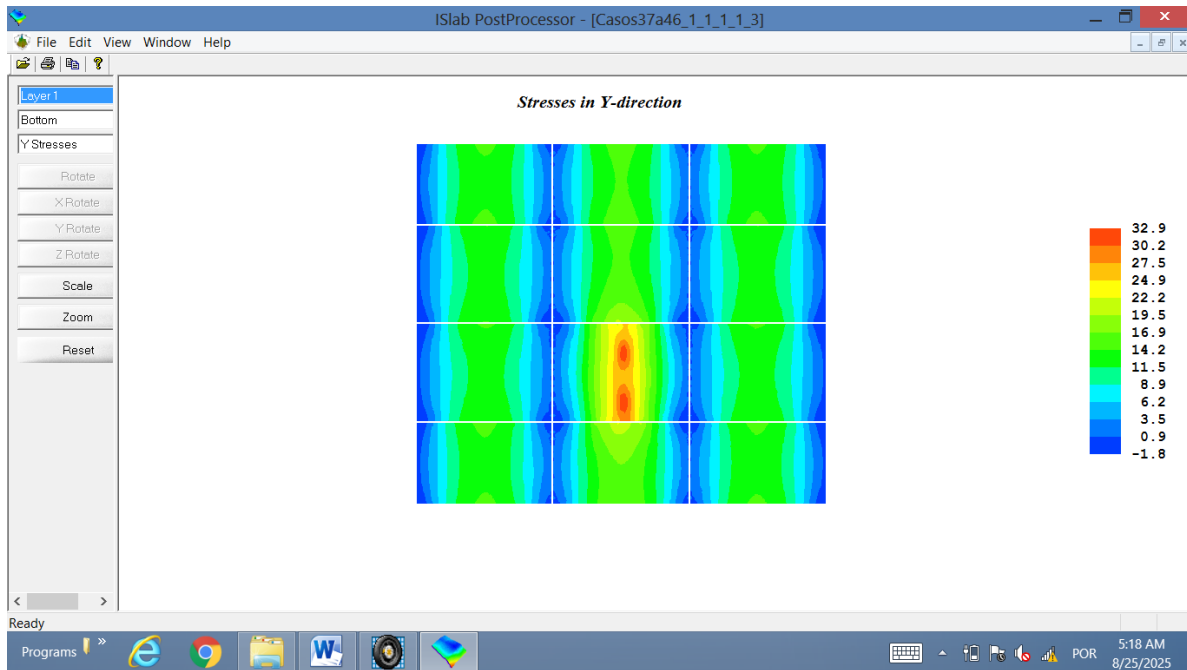
- Caso 69



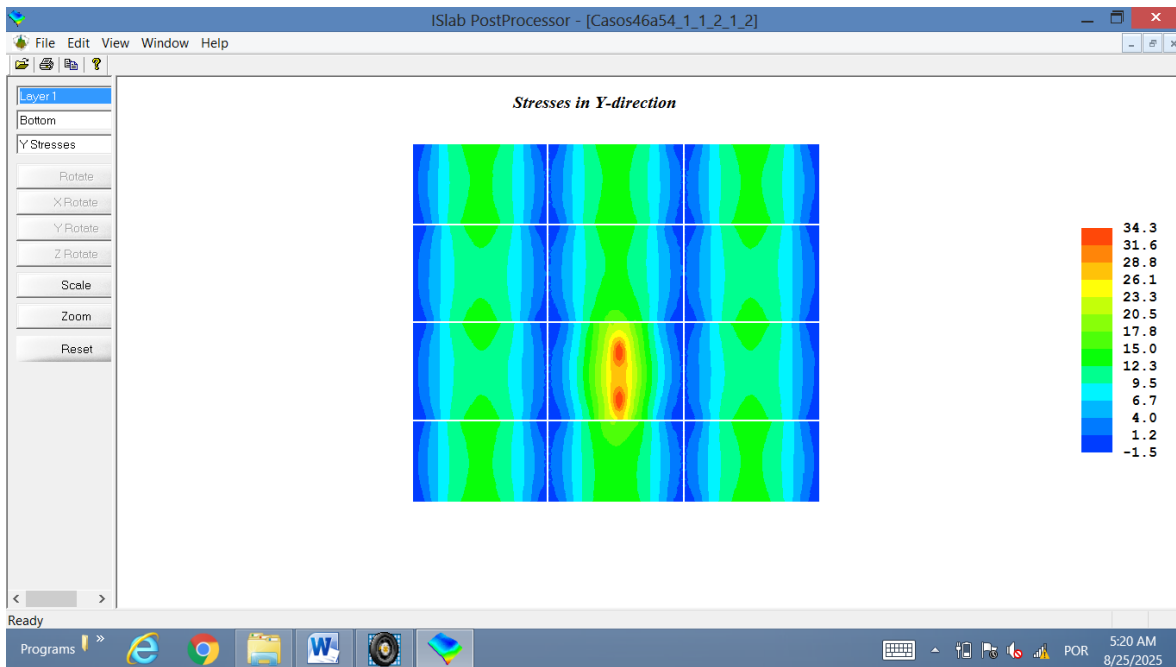
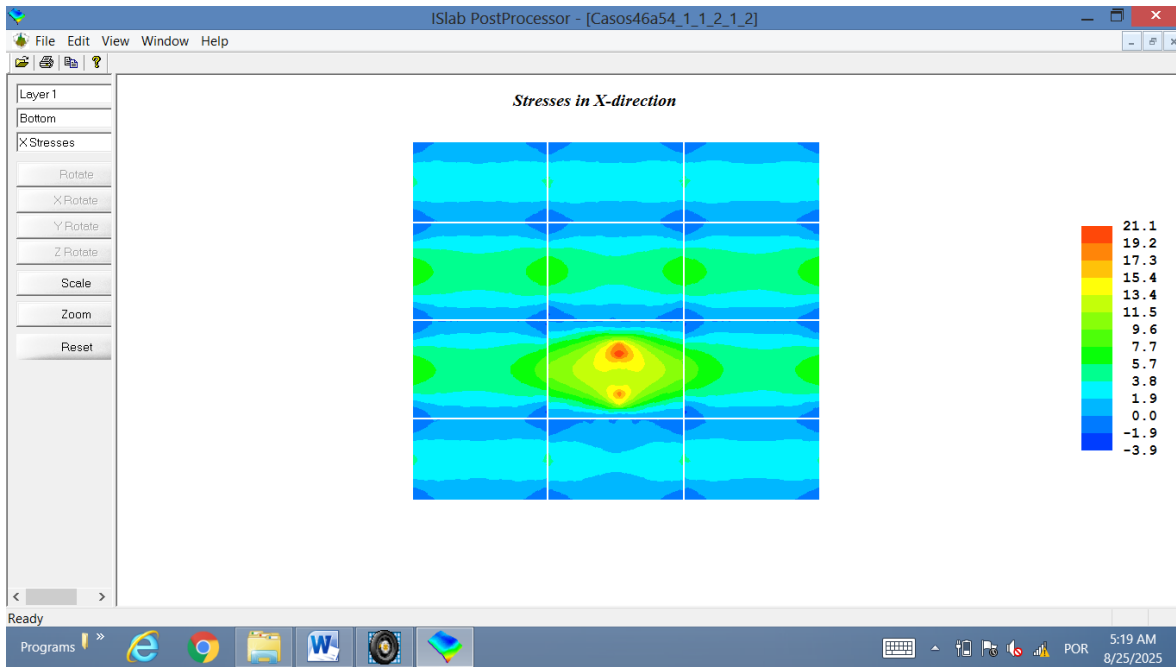


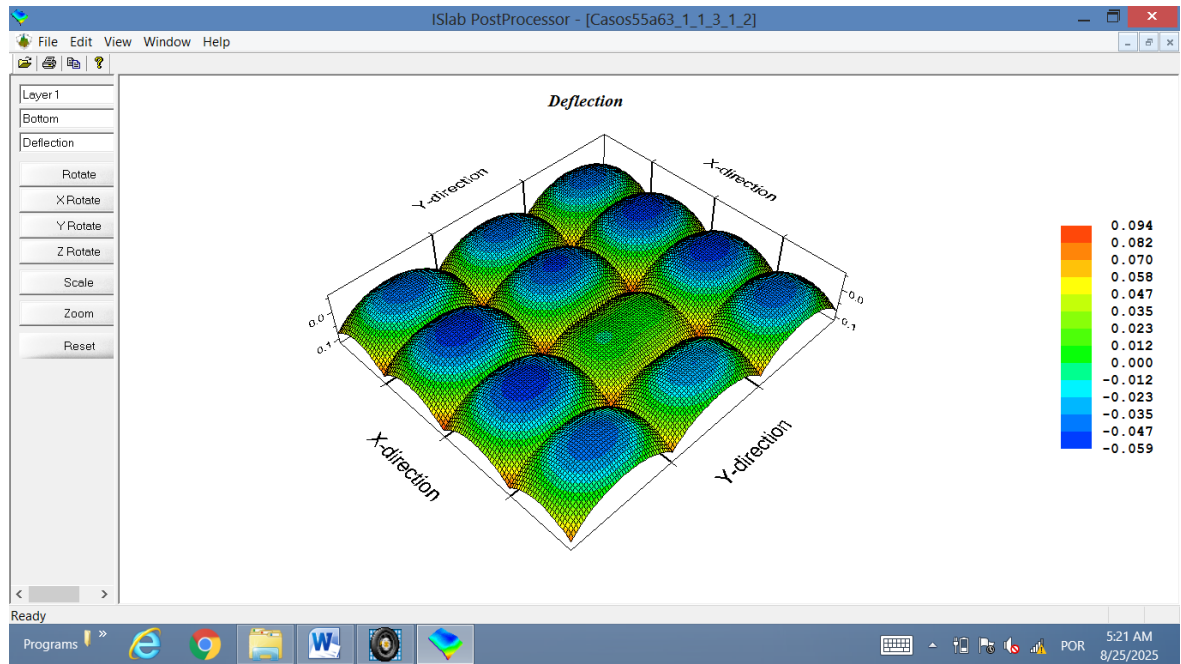
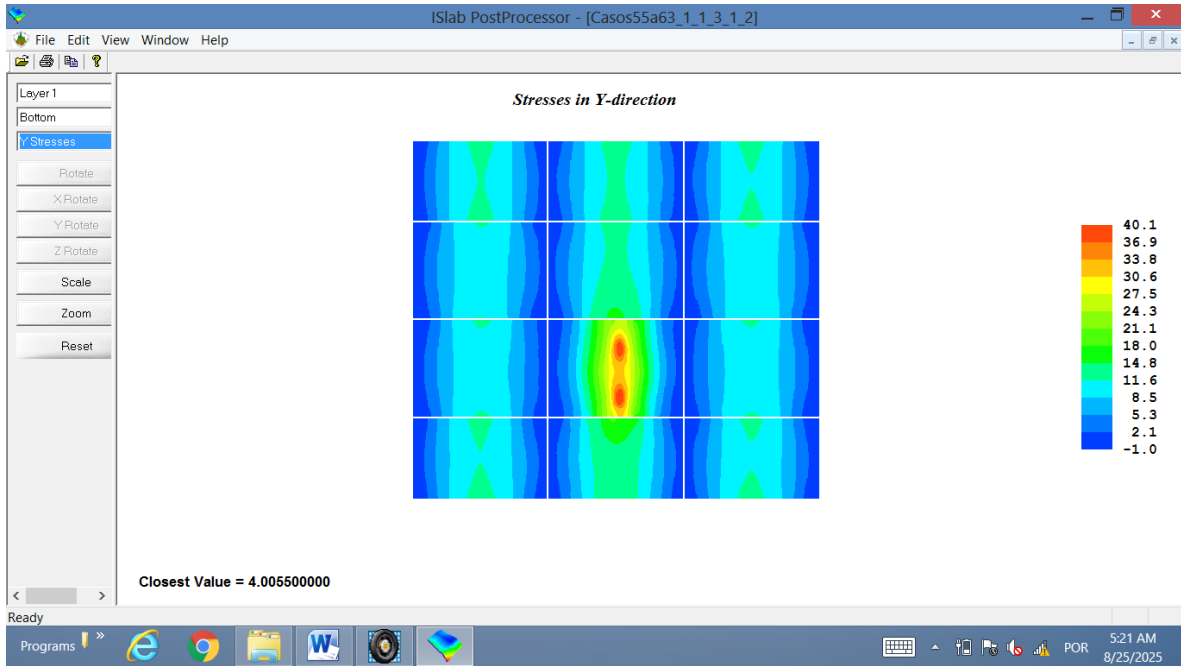
- Caso 72



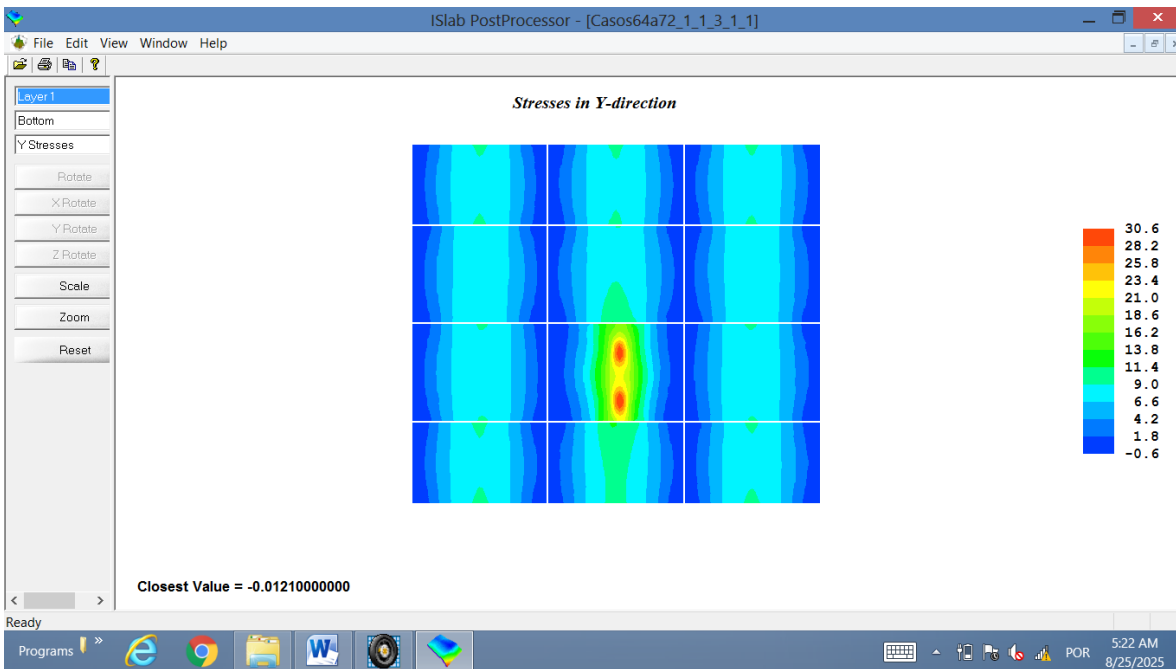
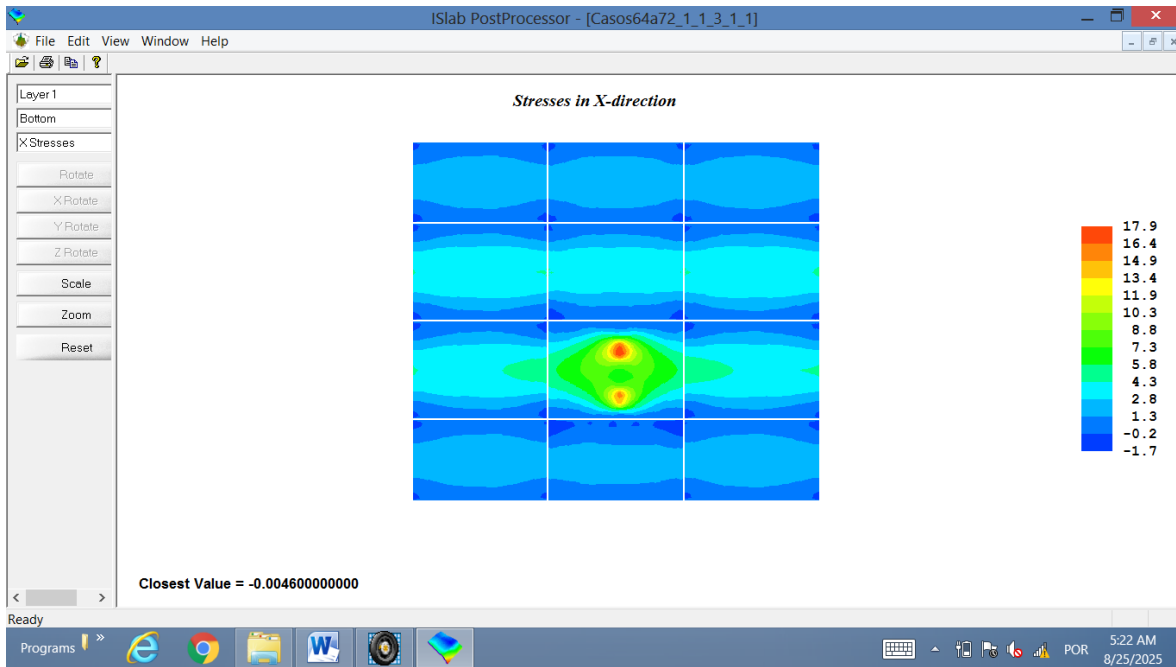


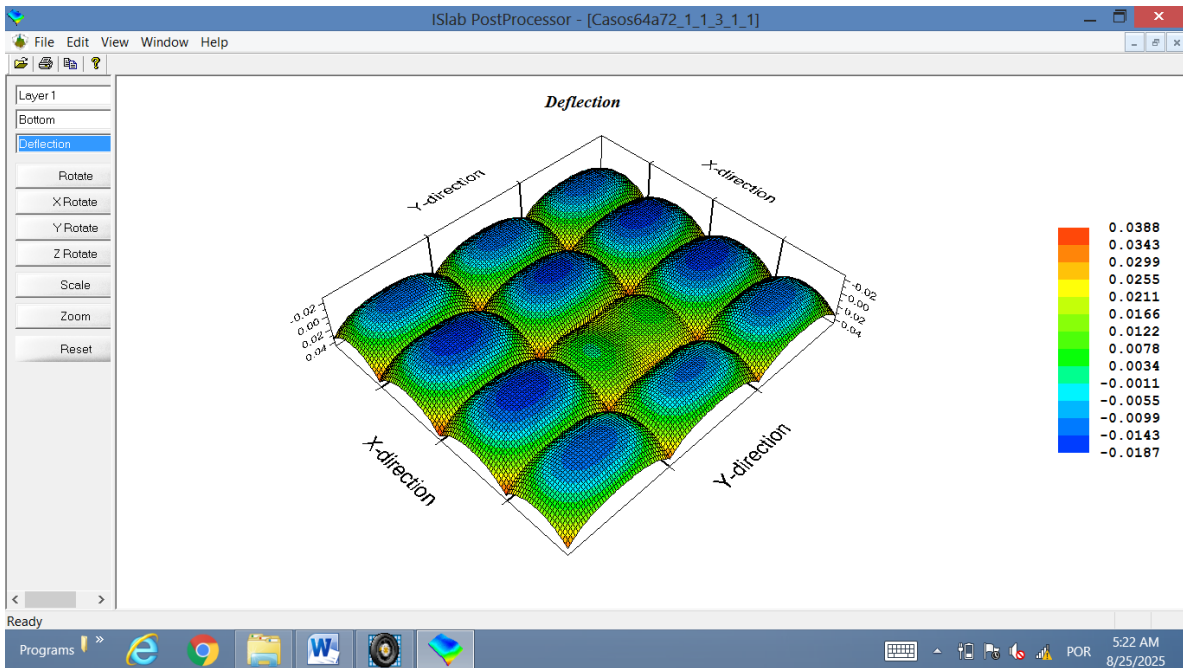
- Caso 83






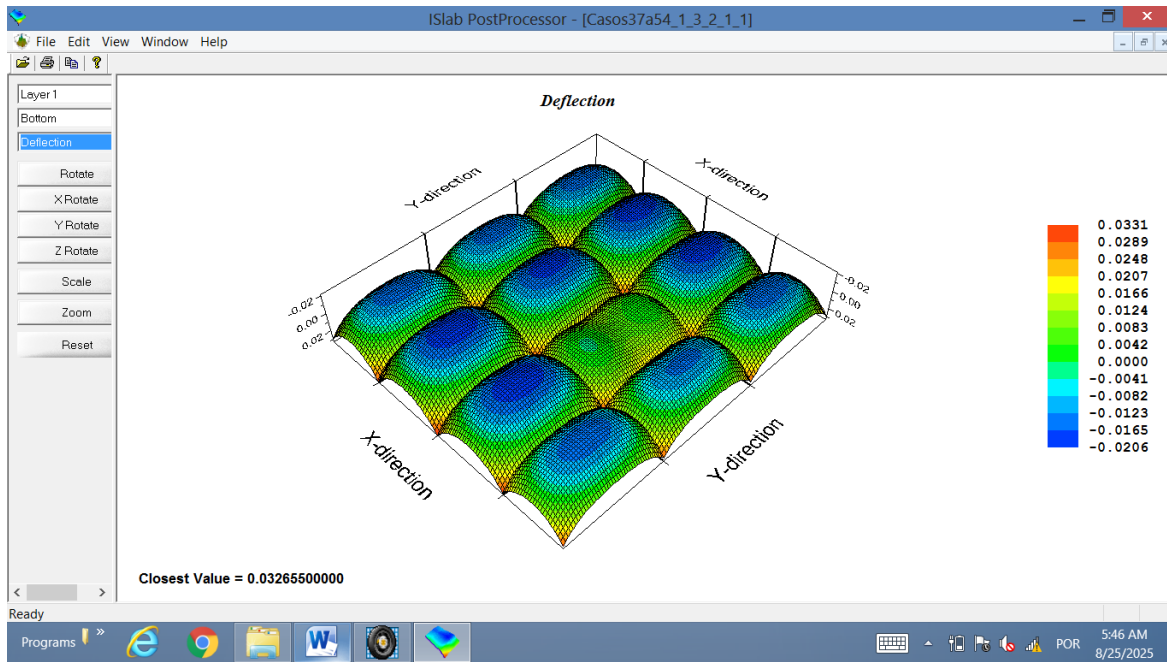
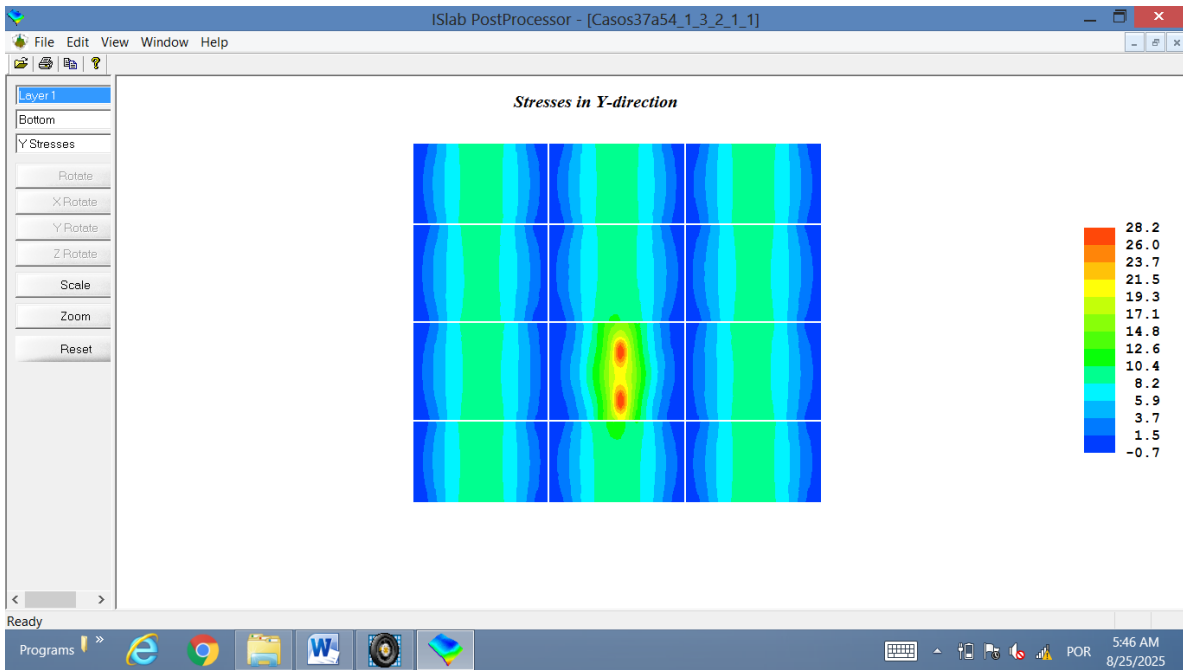
- Caso 110



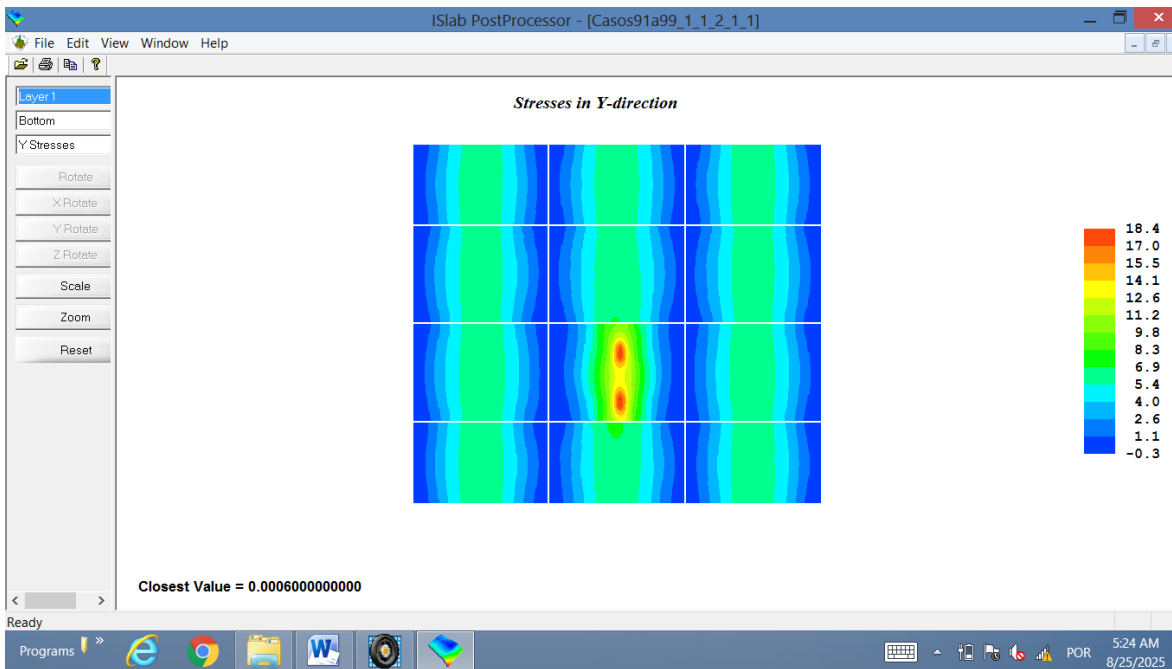
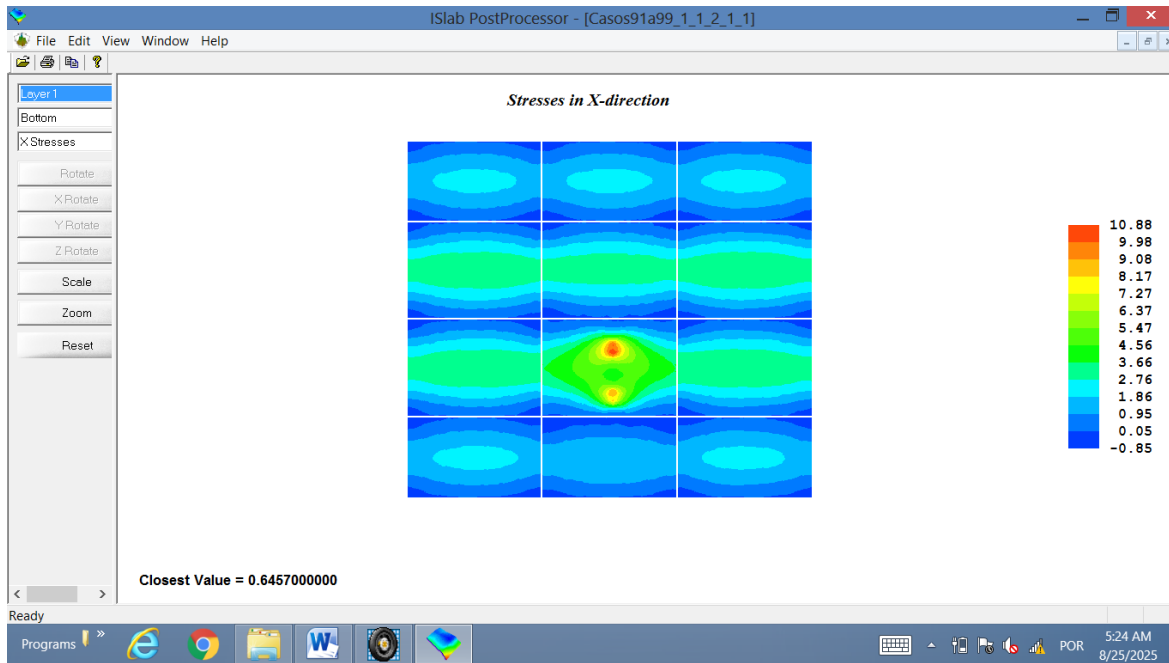


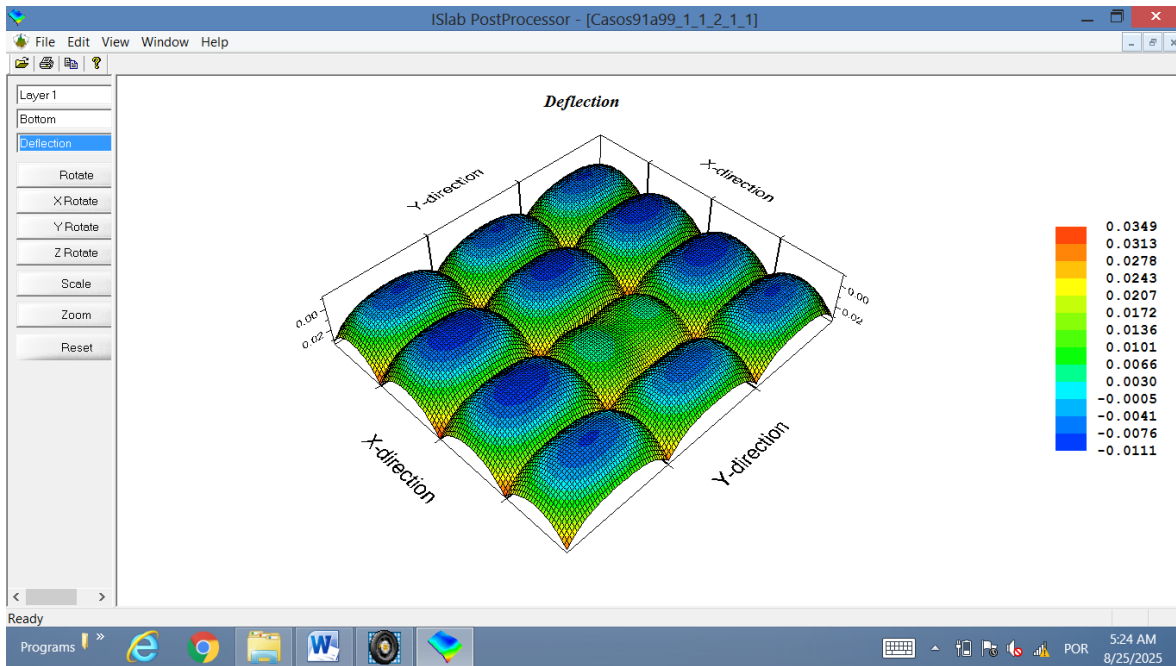
- Caso 124



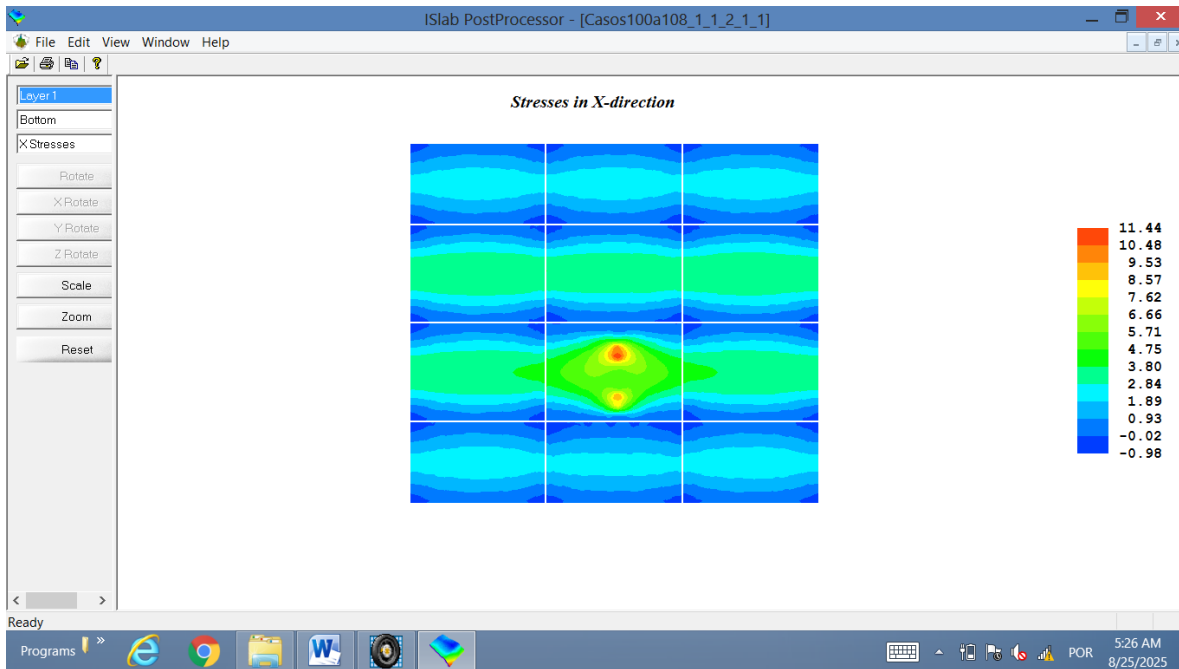


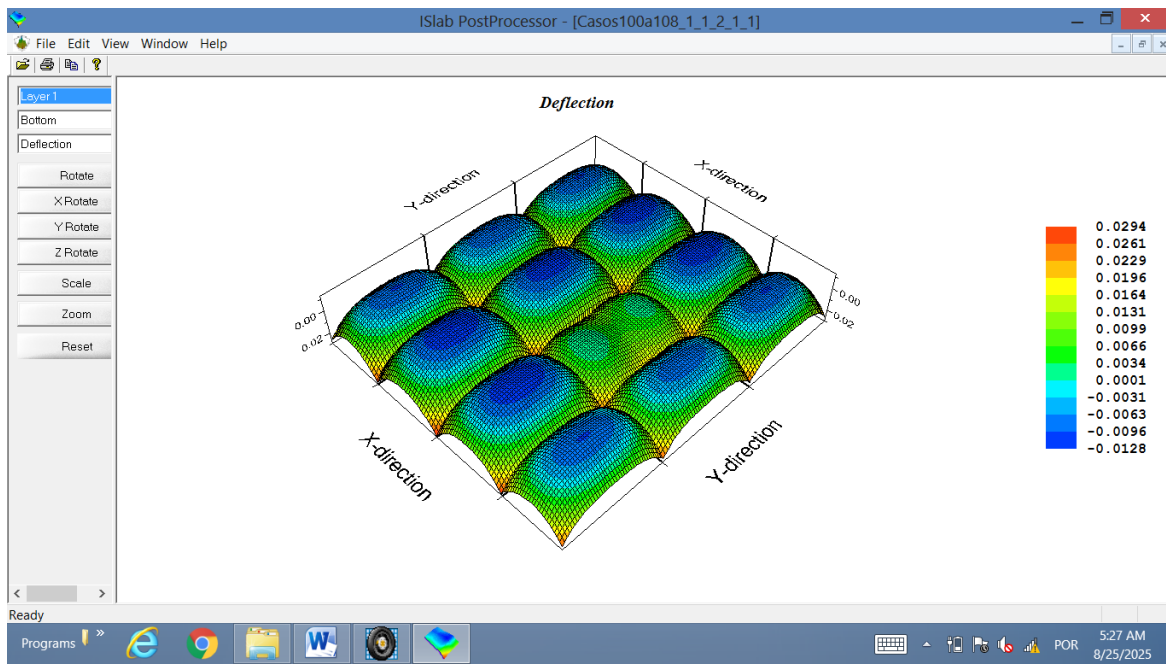
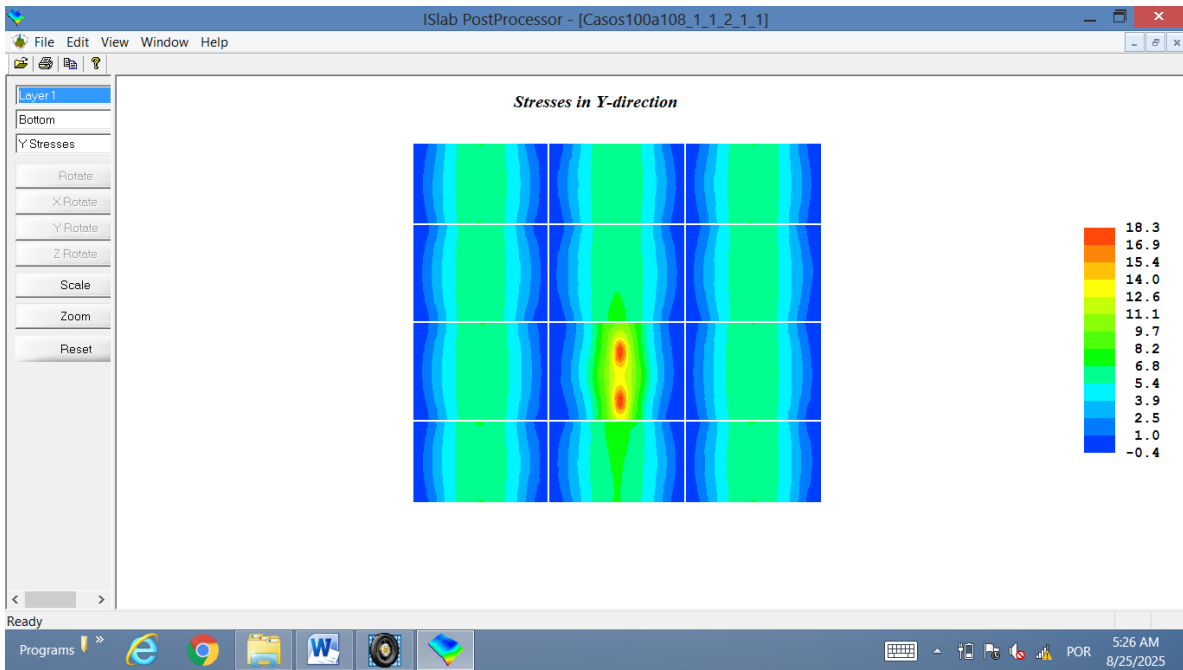
- Caso 153



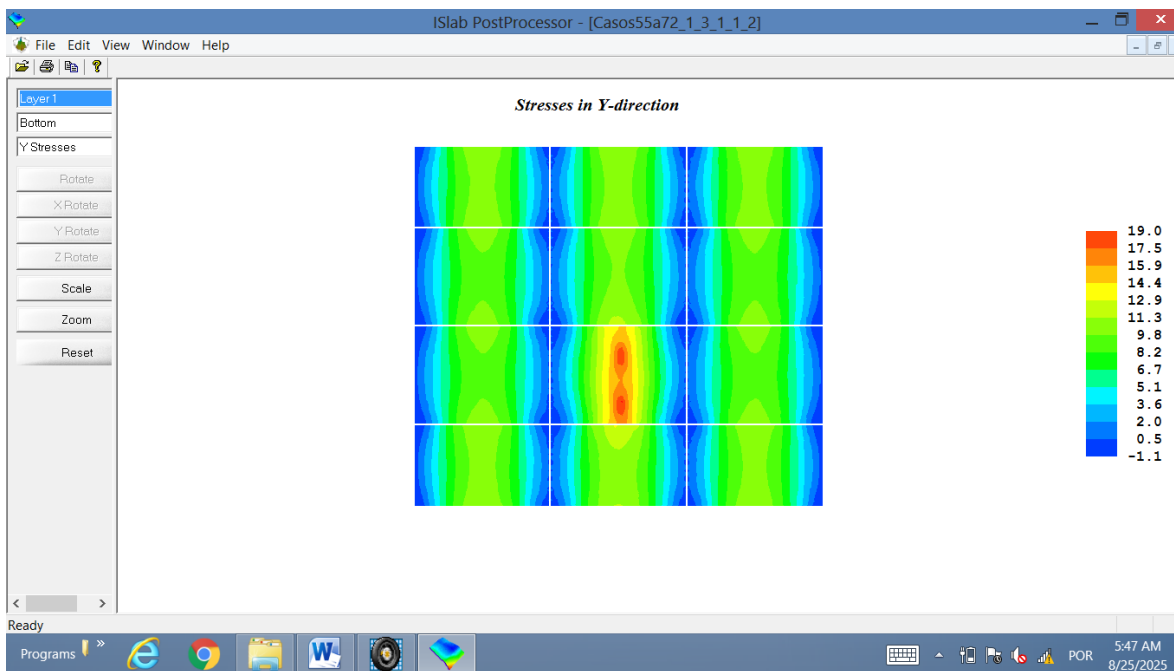
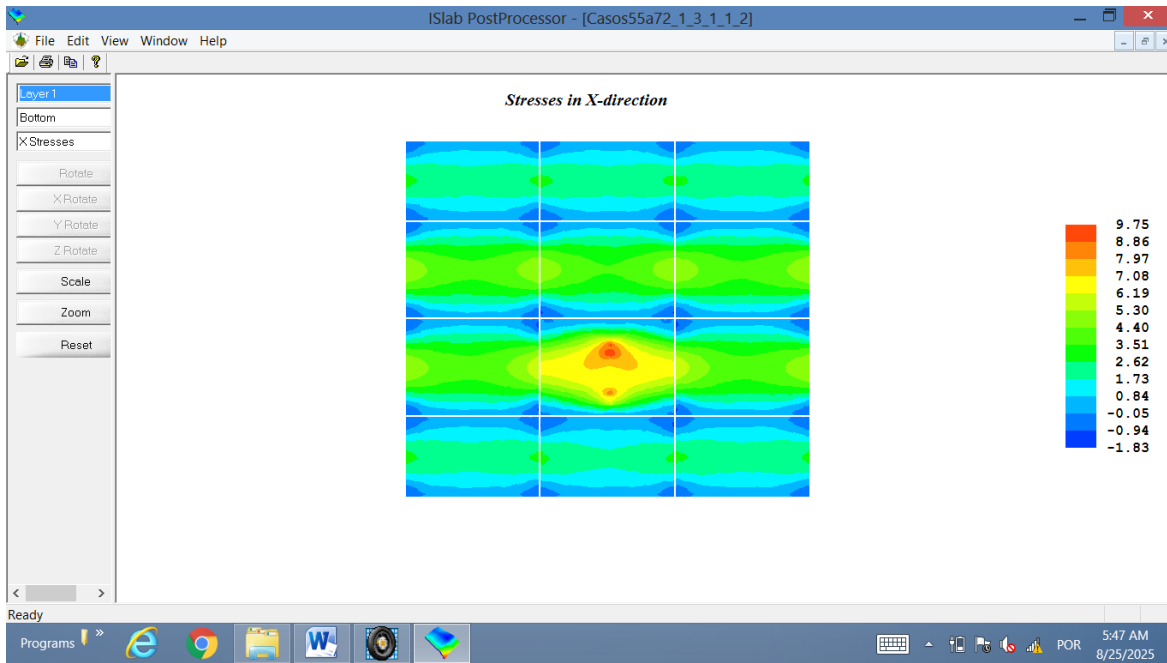


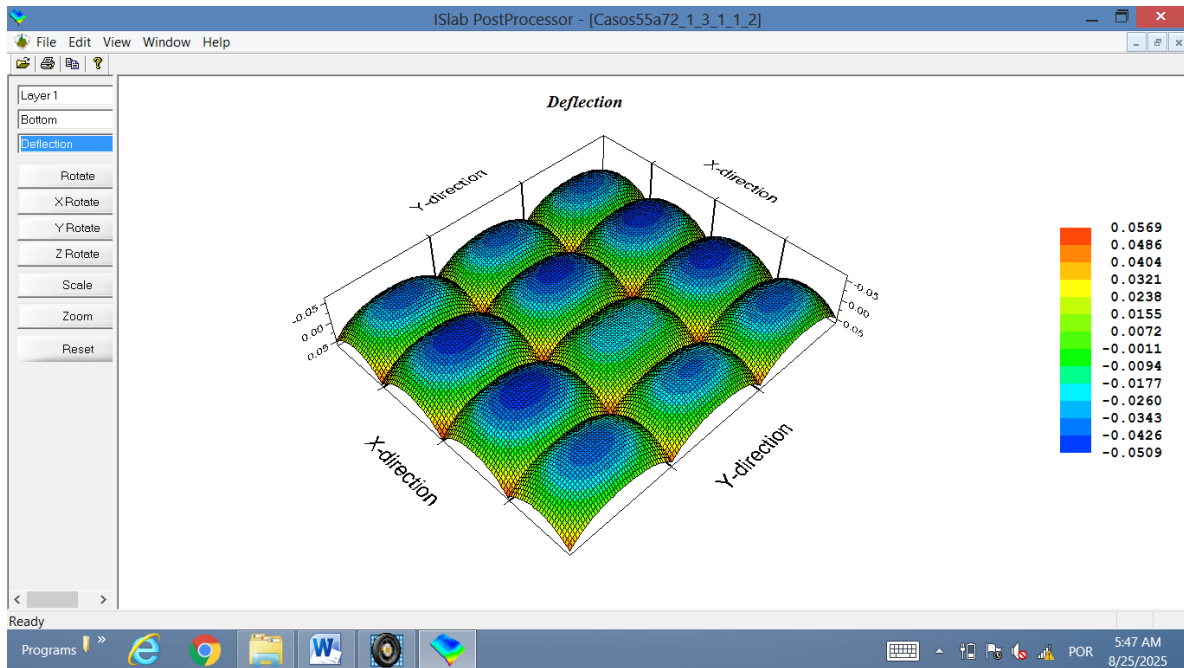
- Caso 168



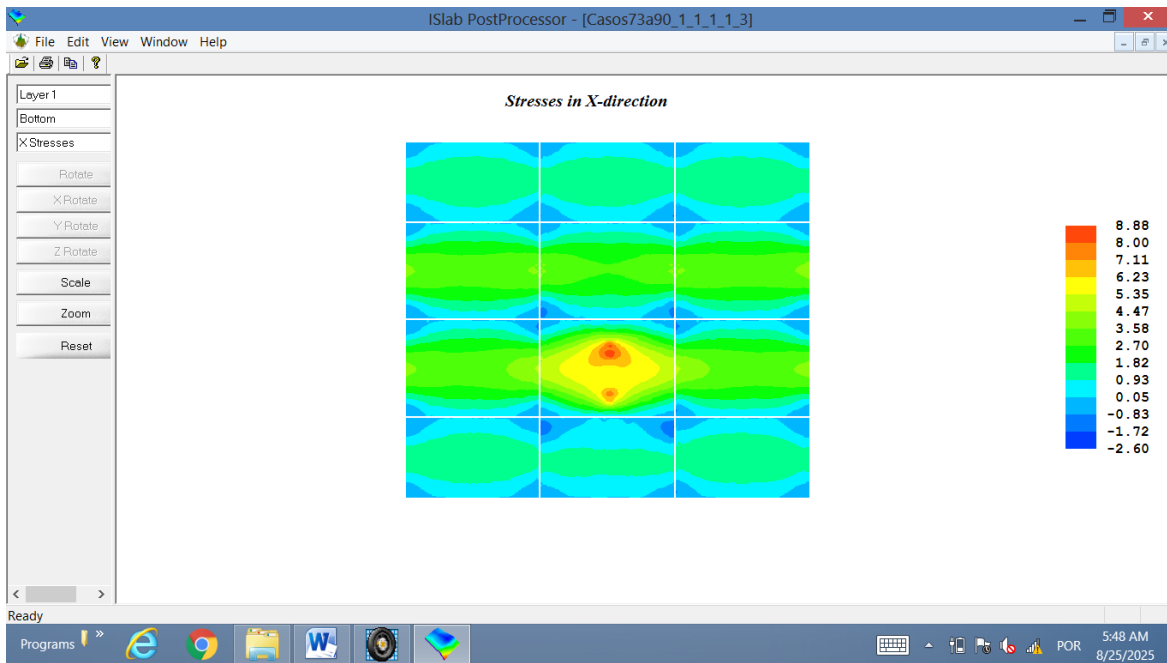


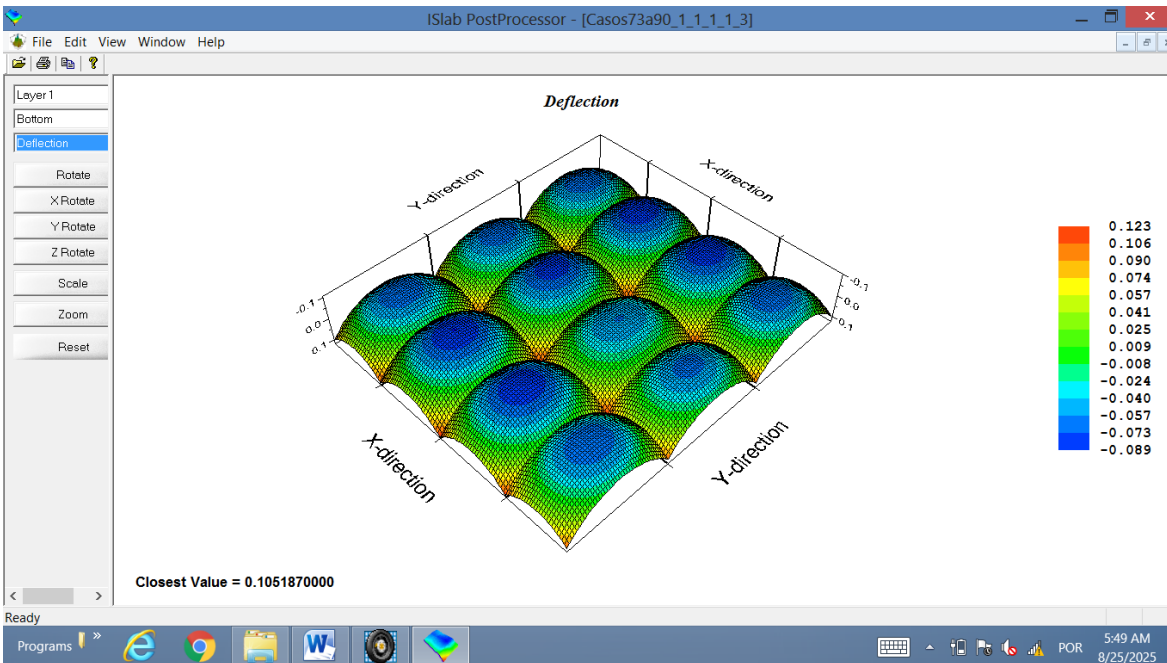
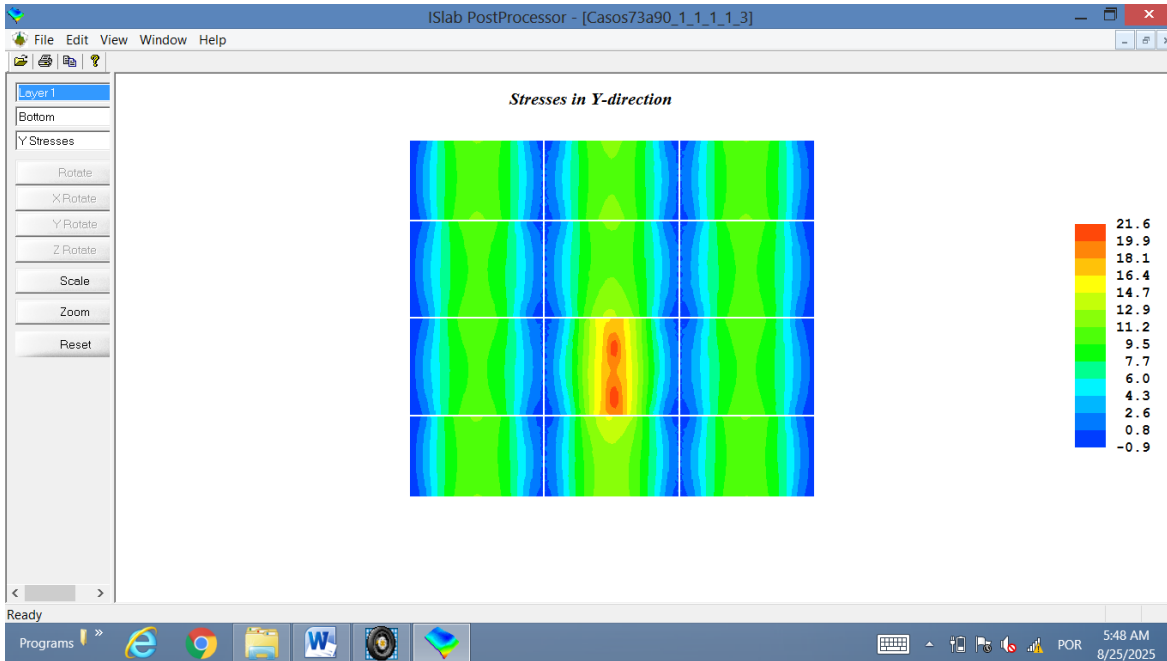
- Caso 171



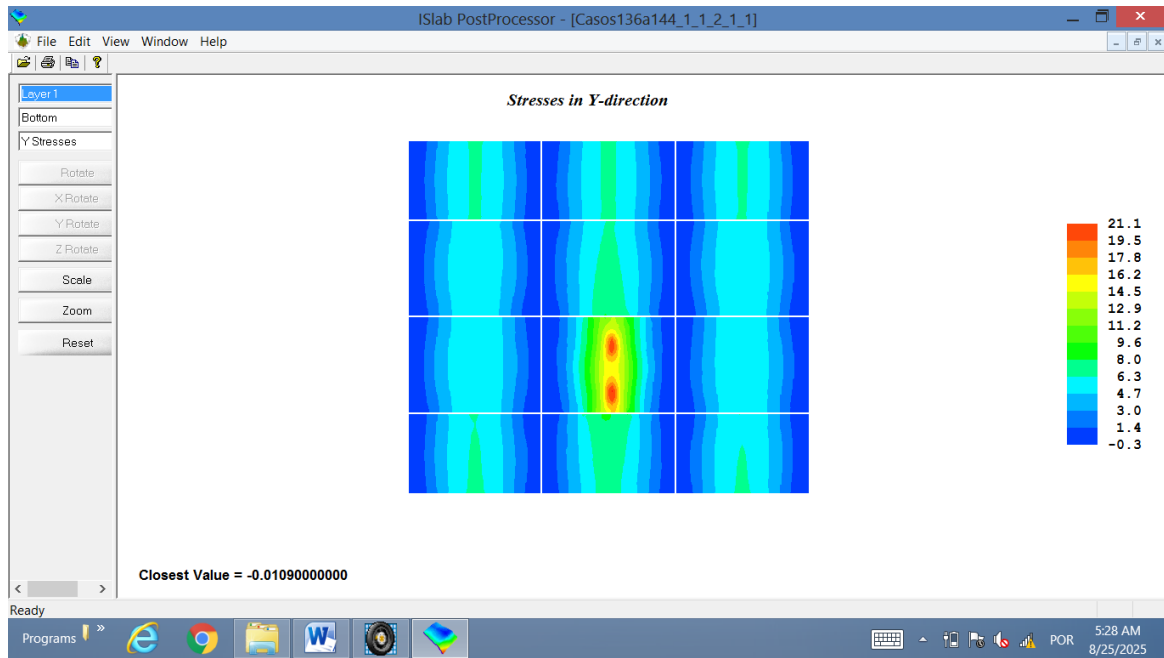
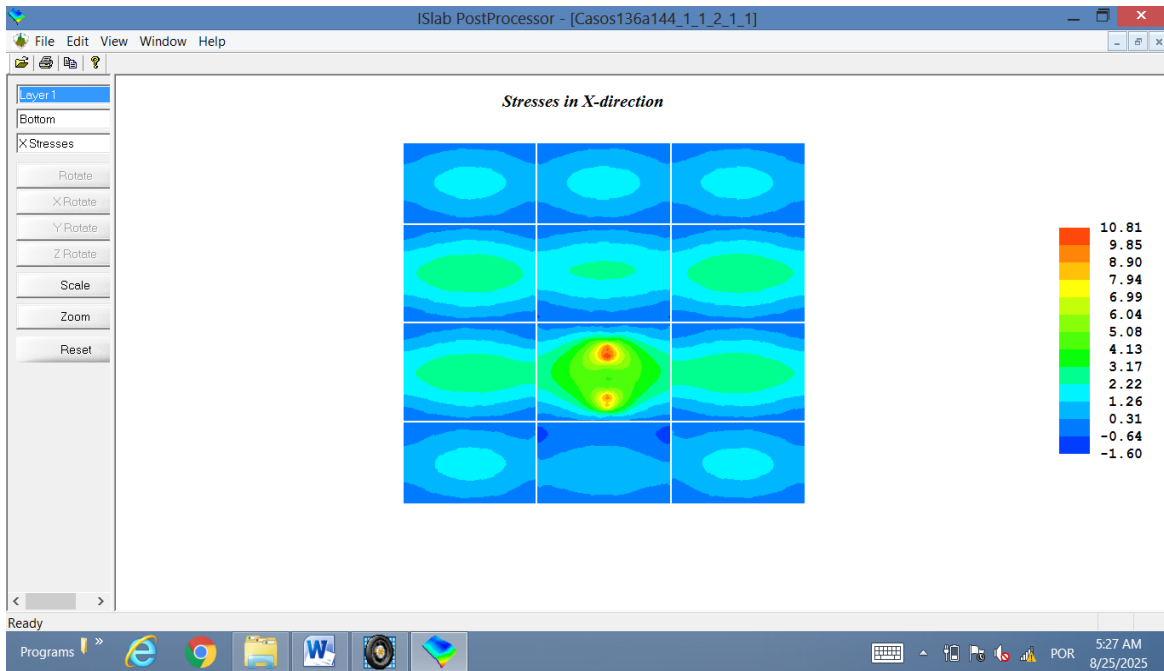


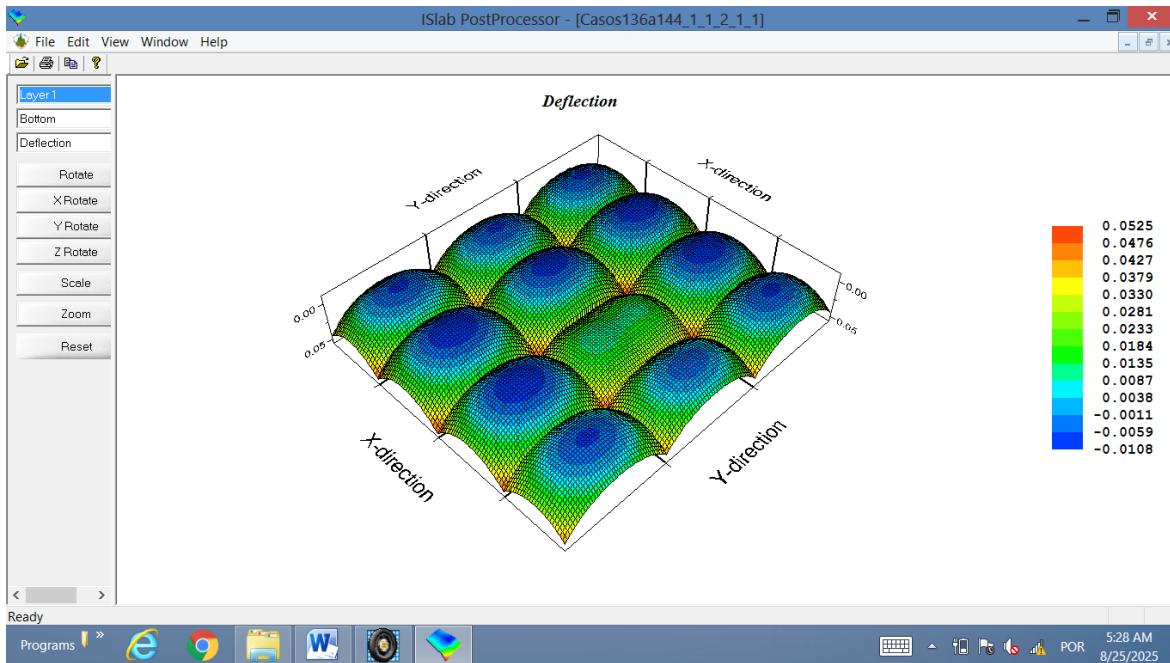
- Caso 191






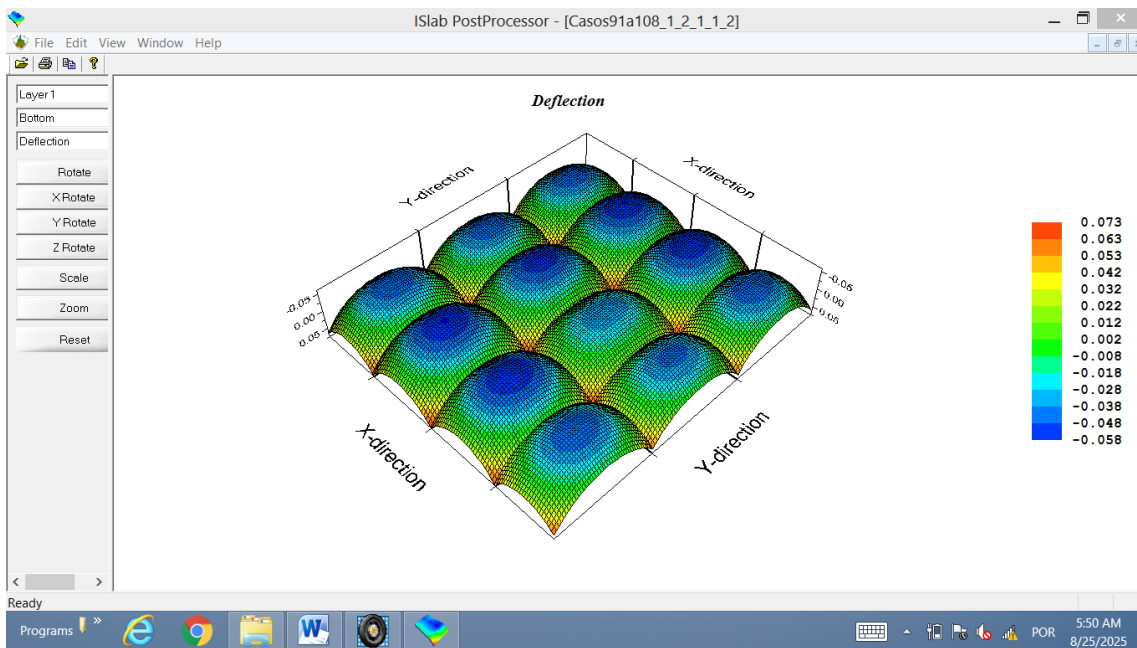
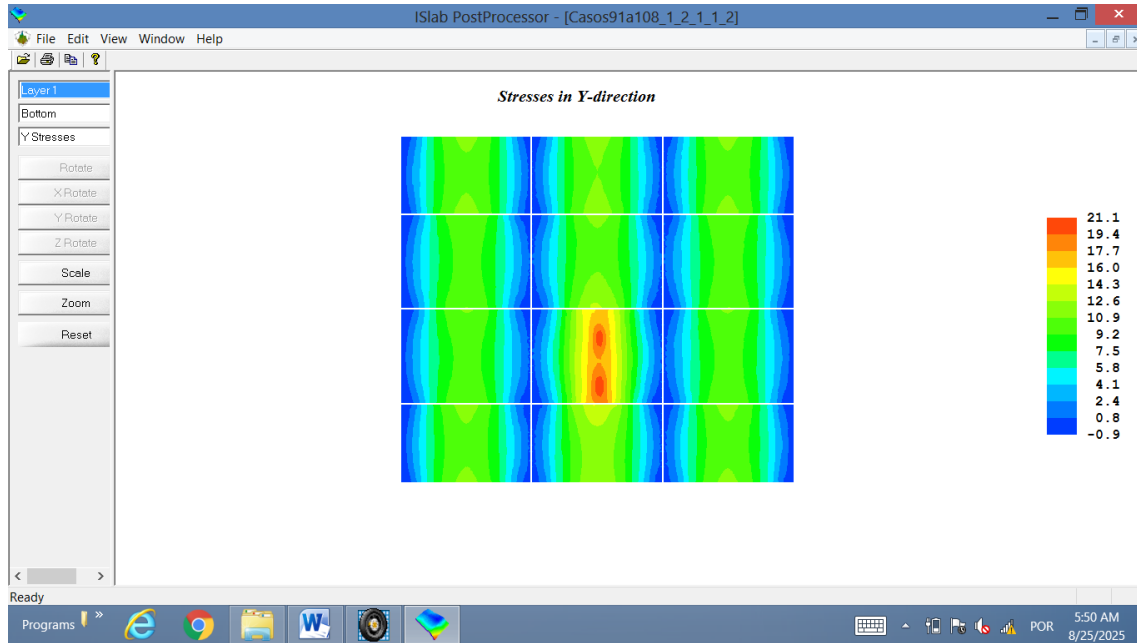
- Caso 228



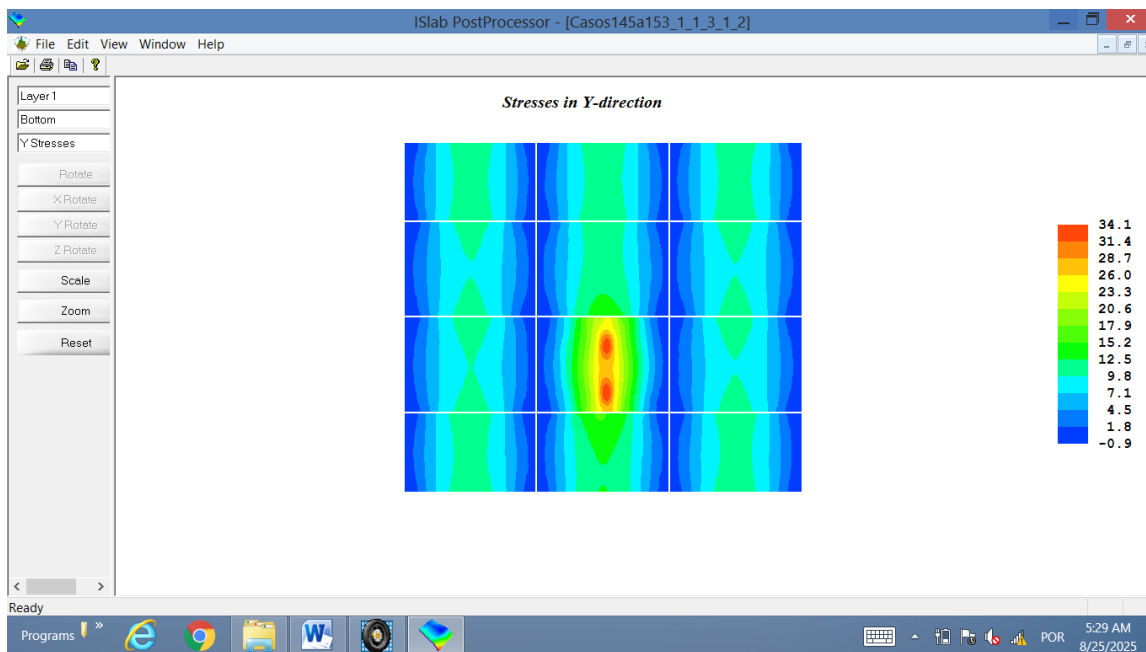
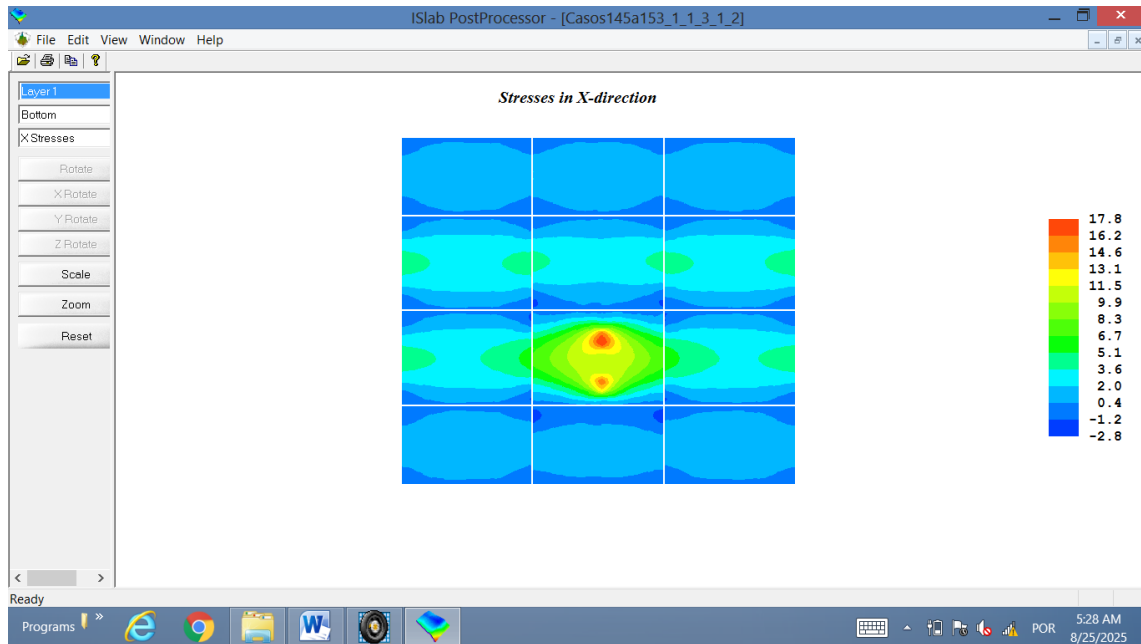


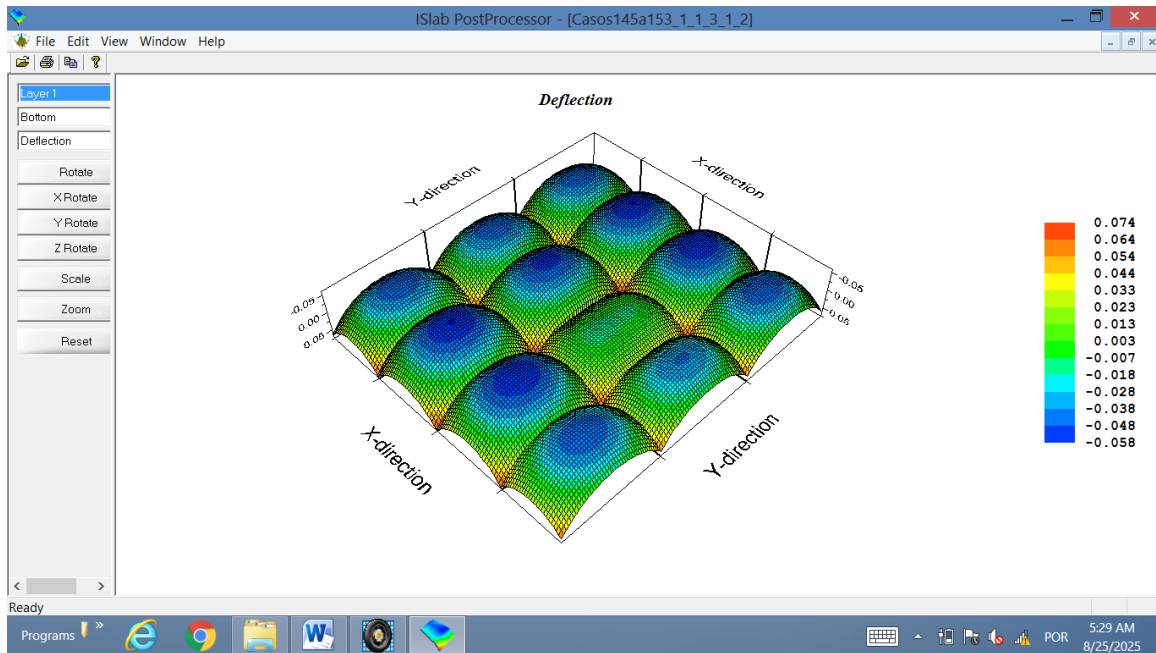
- Caso 246



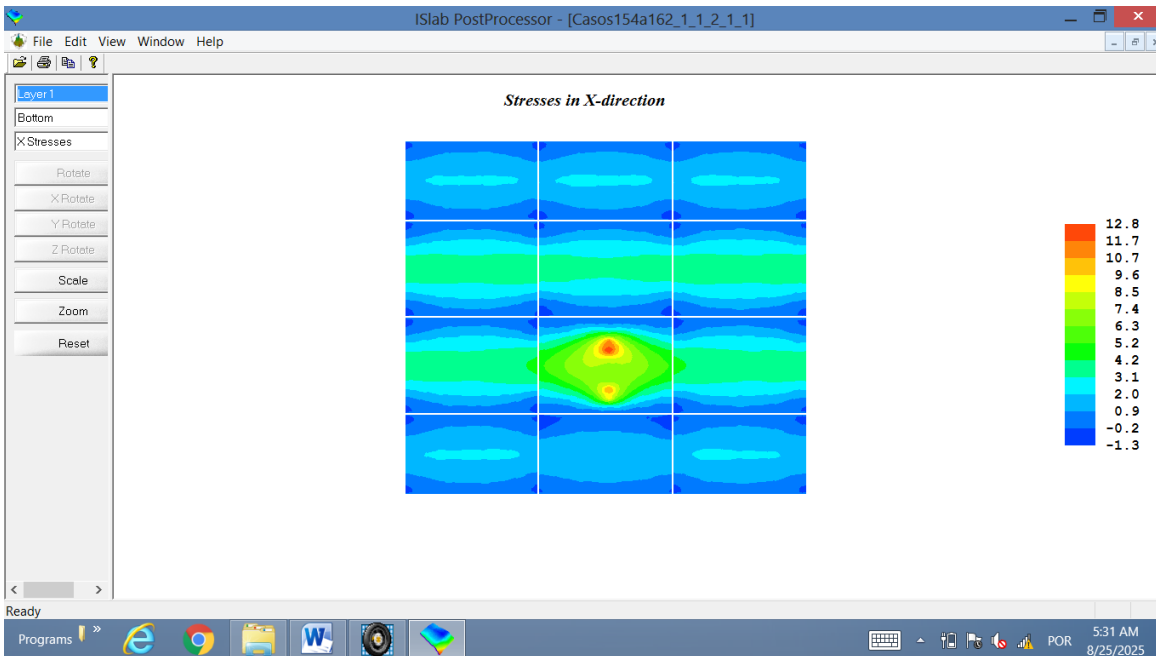


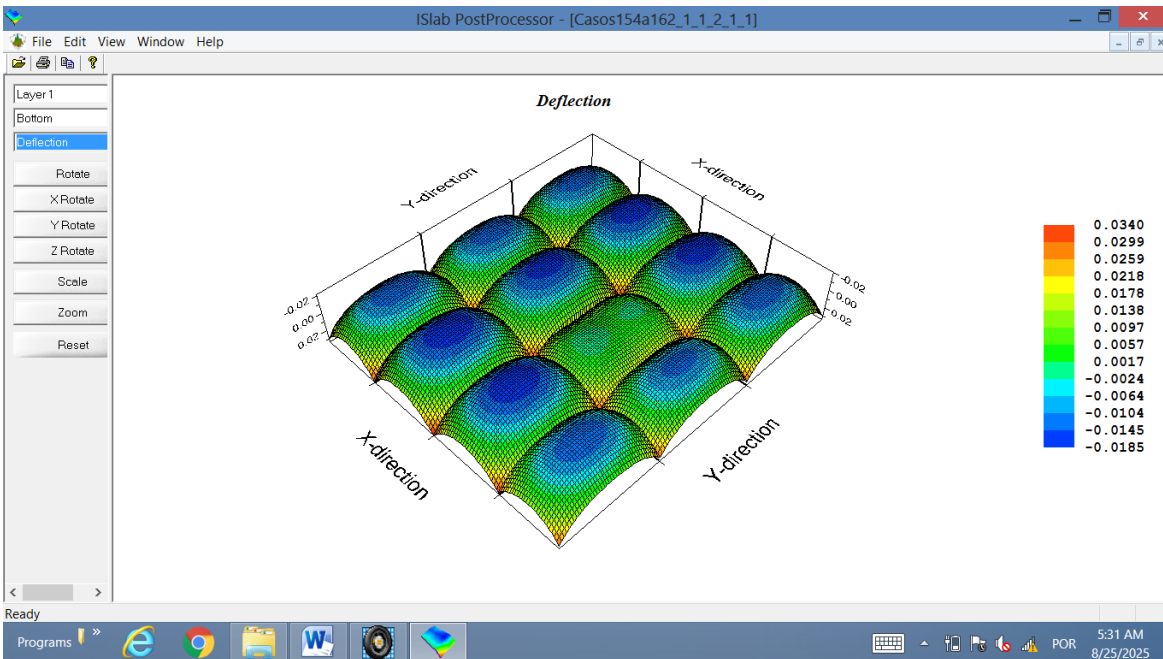
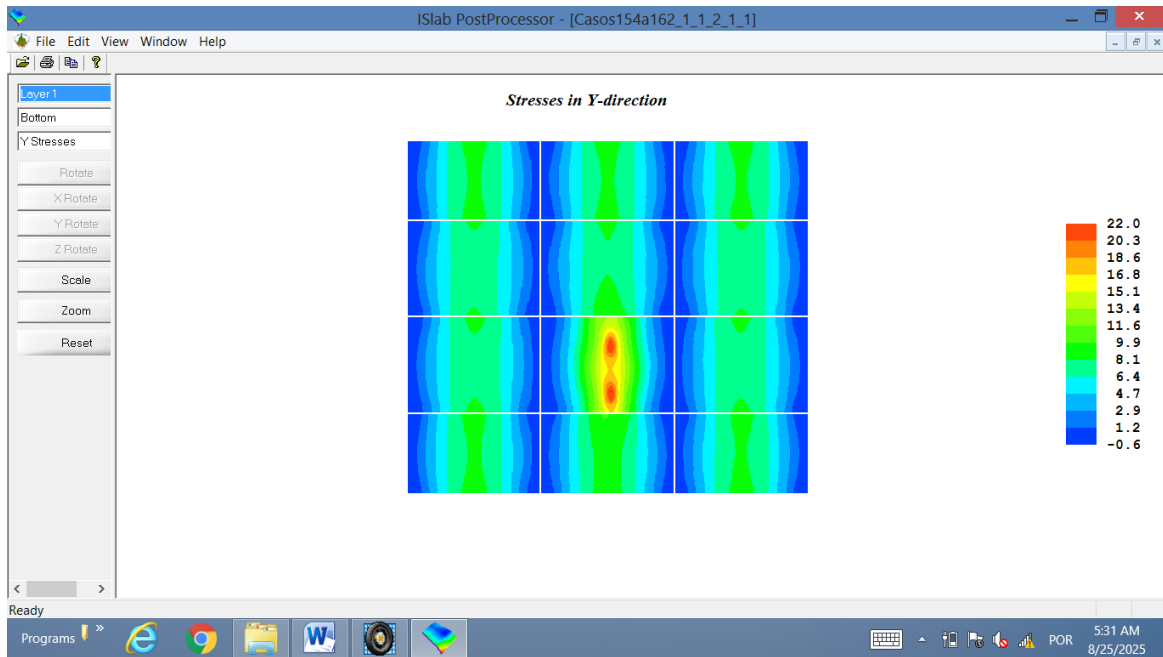
- Caso 250



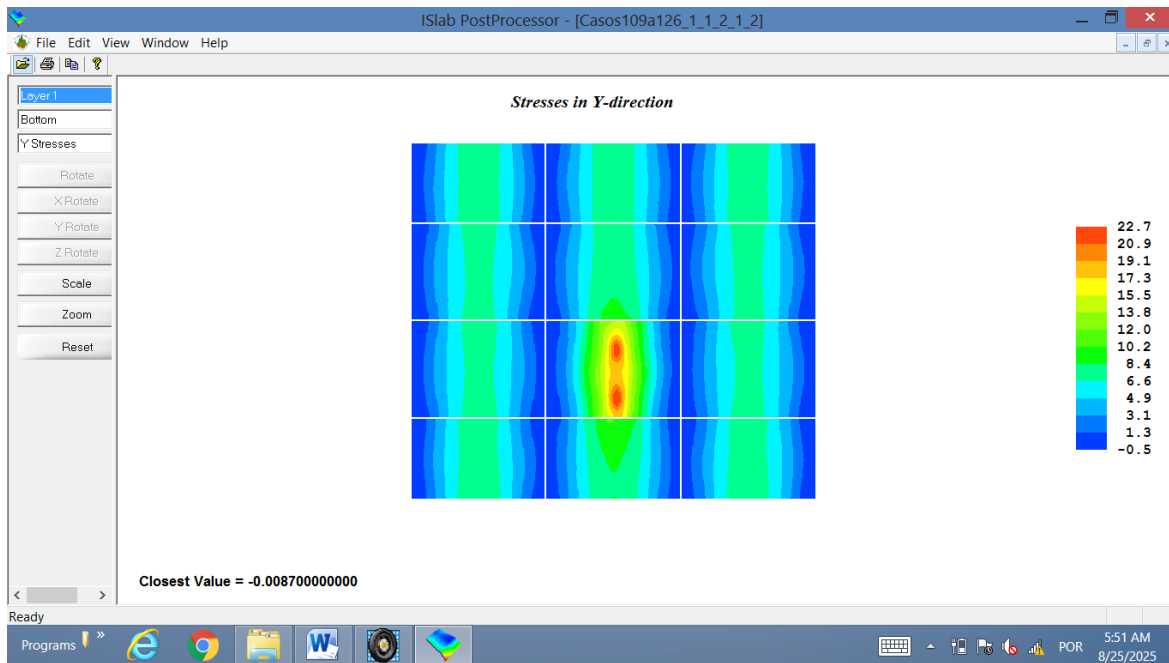
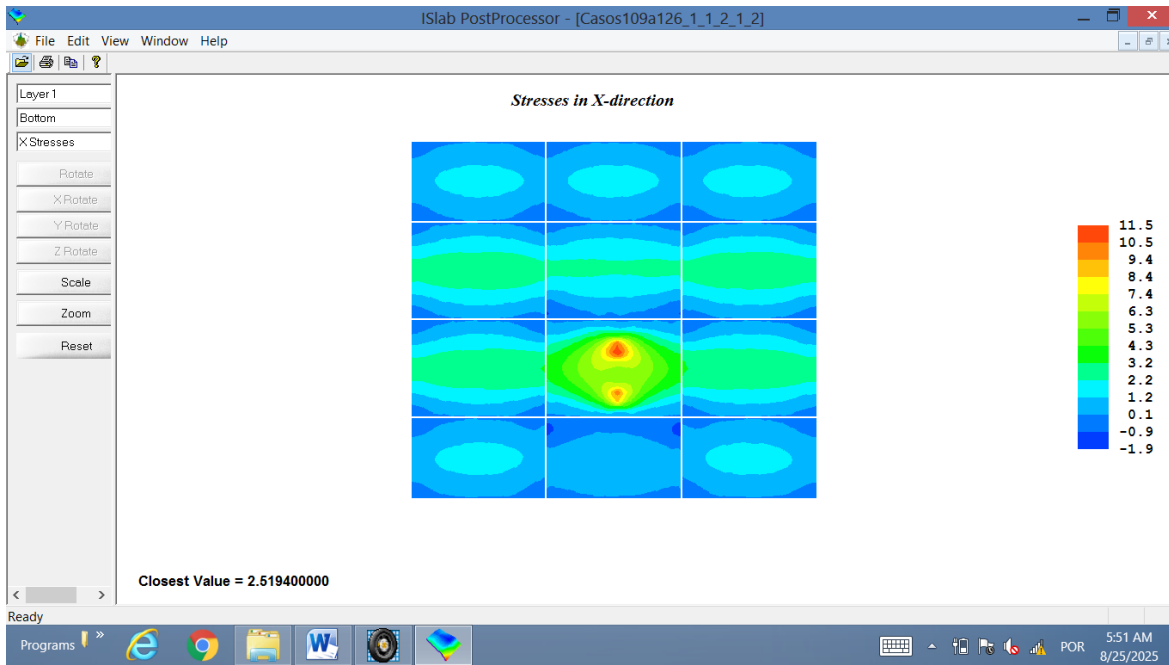


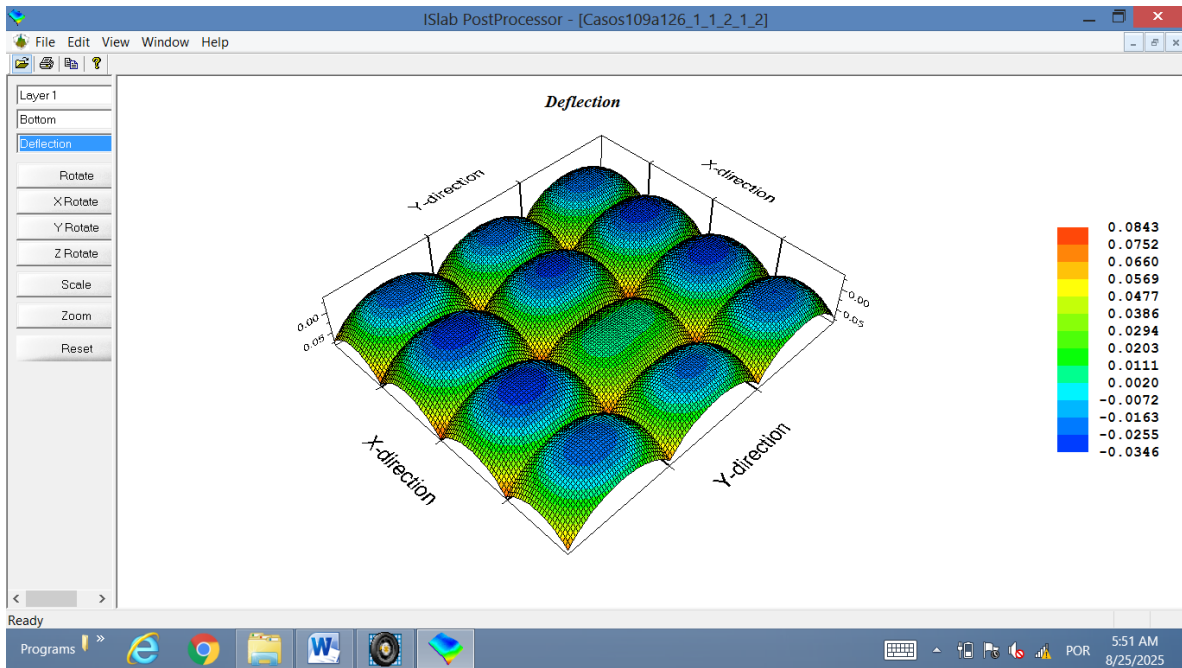
- Caso 258



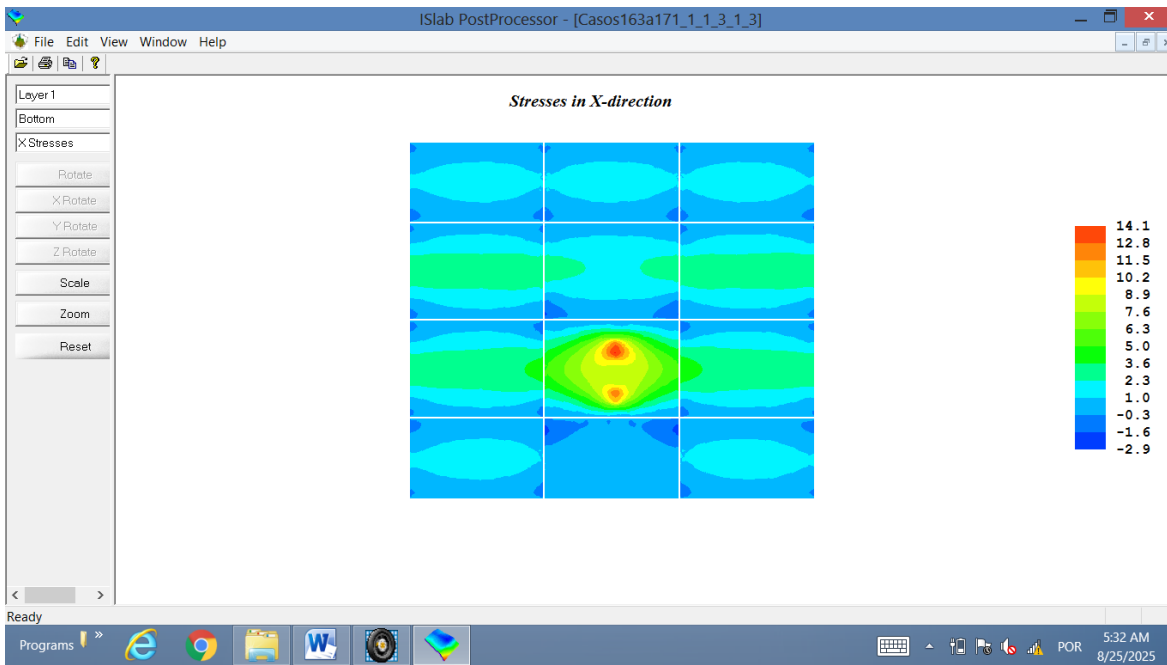


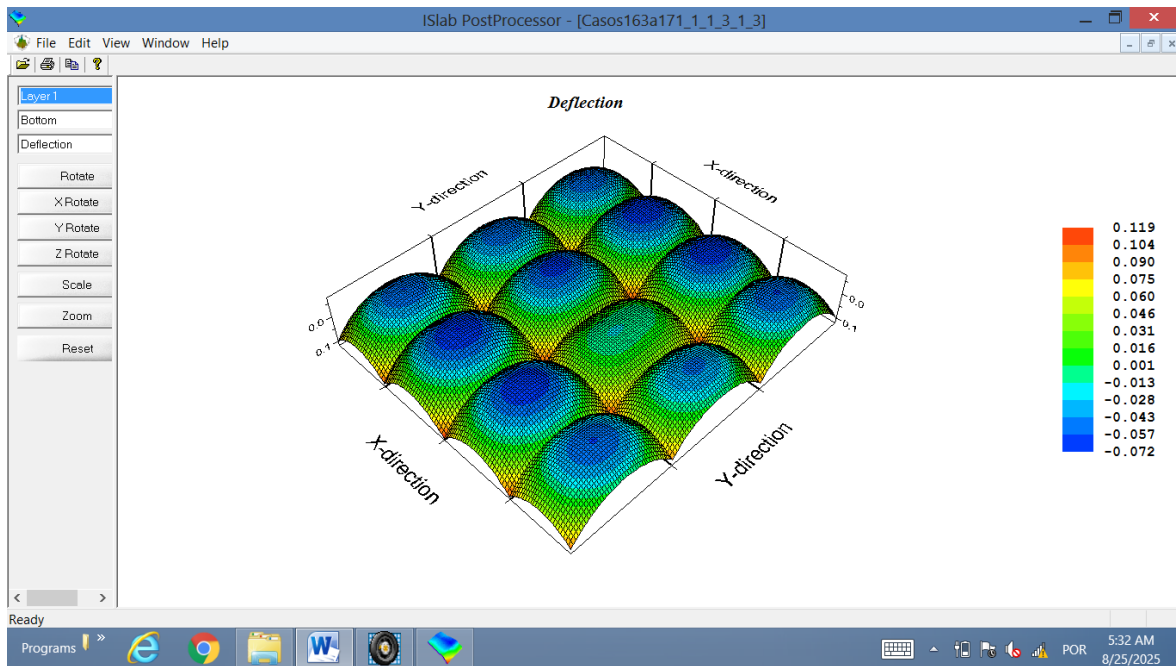
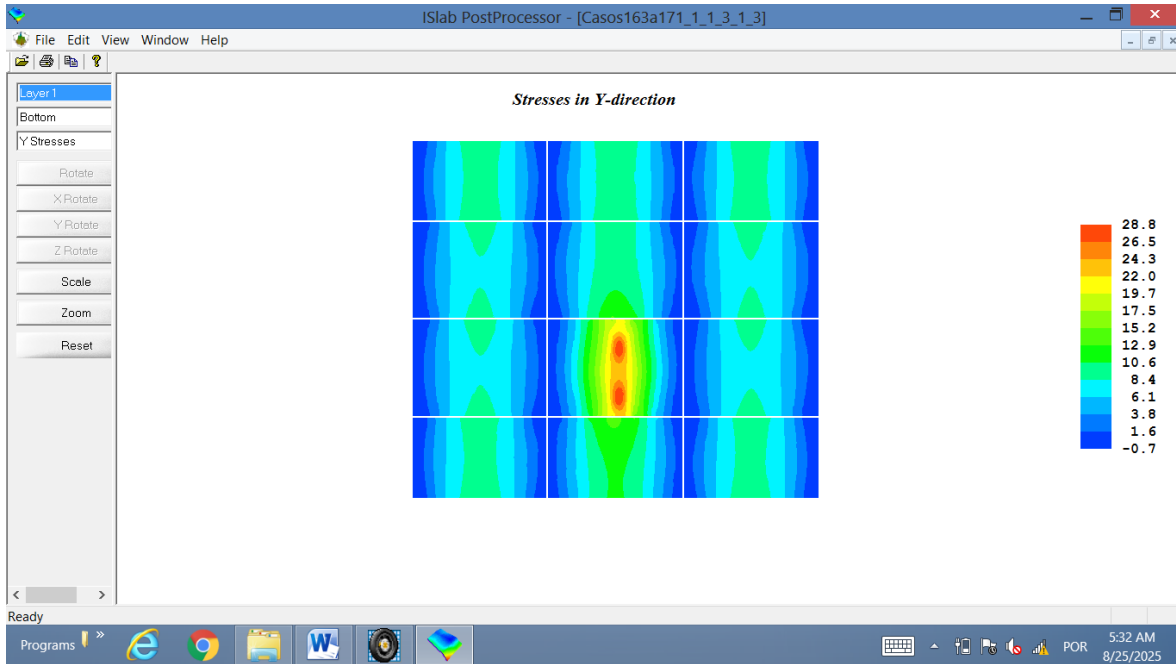
- Caso 279



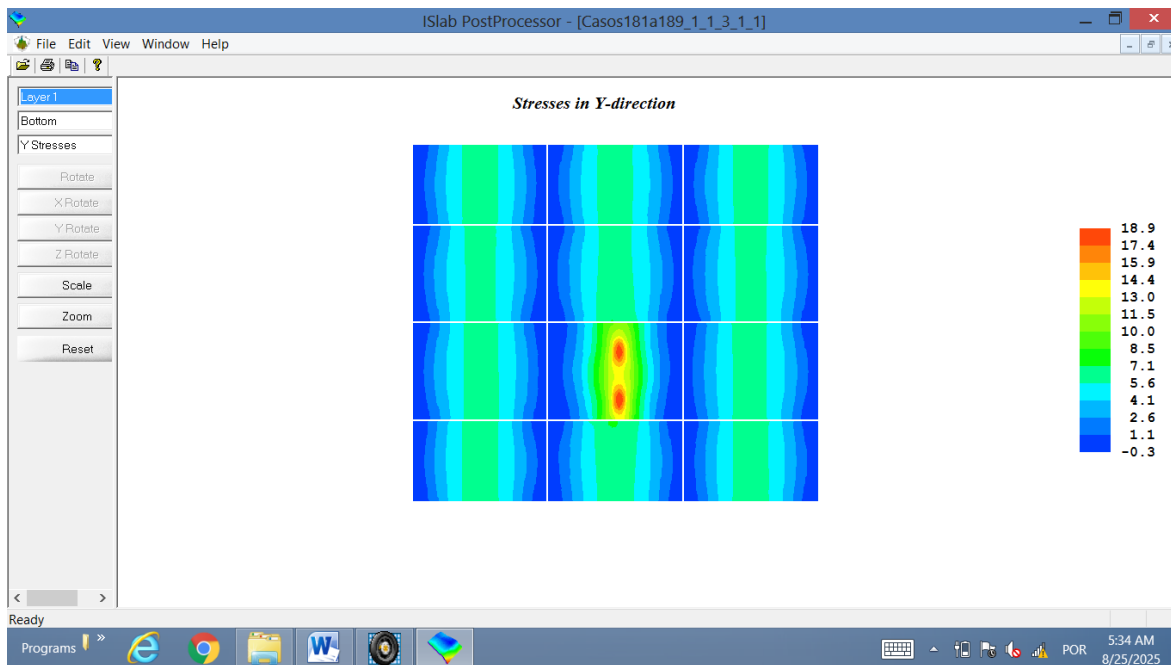
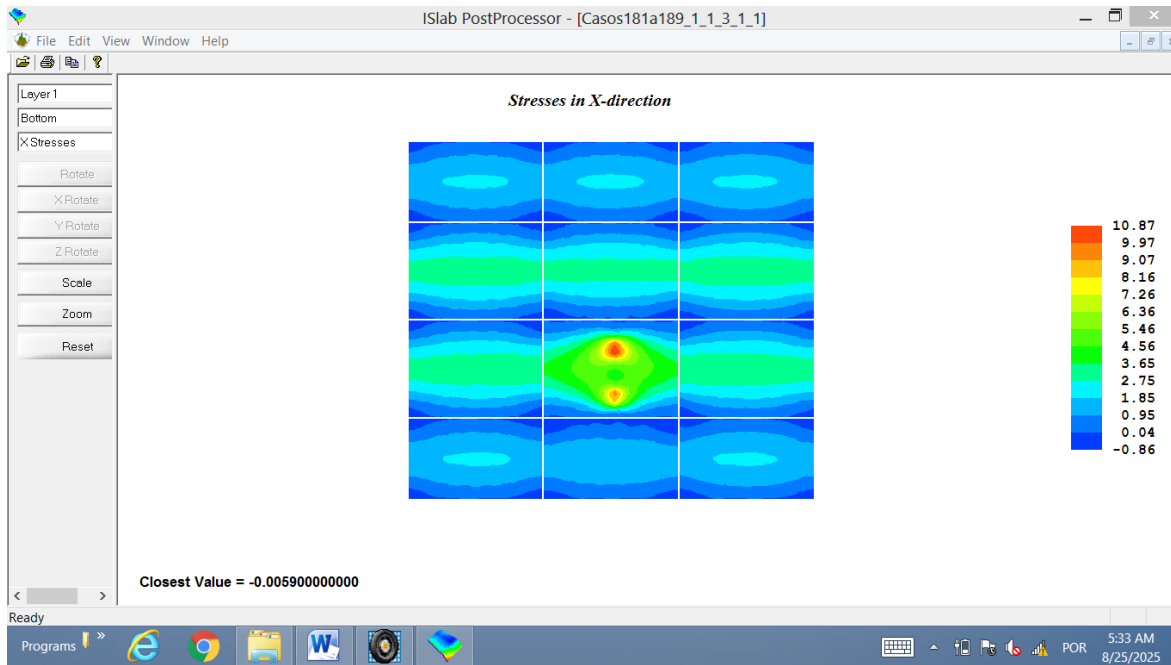


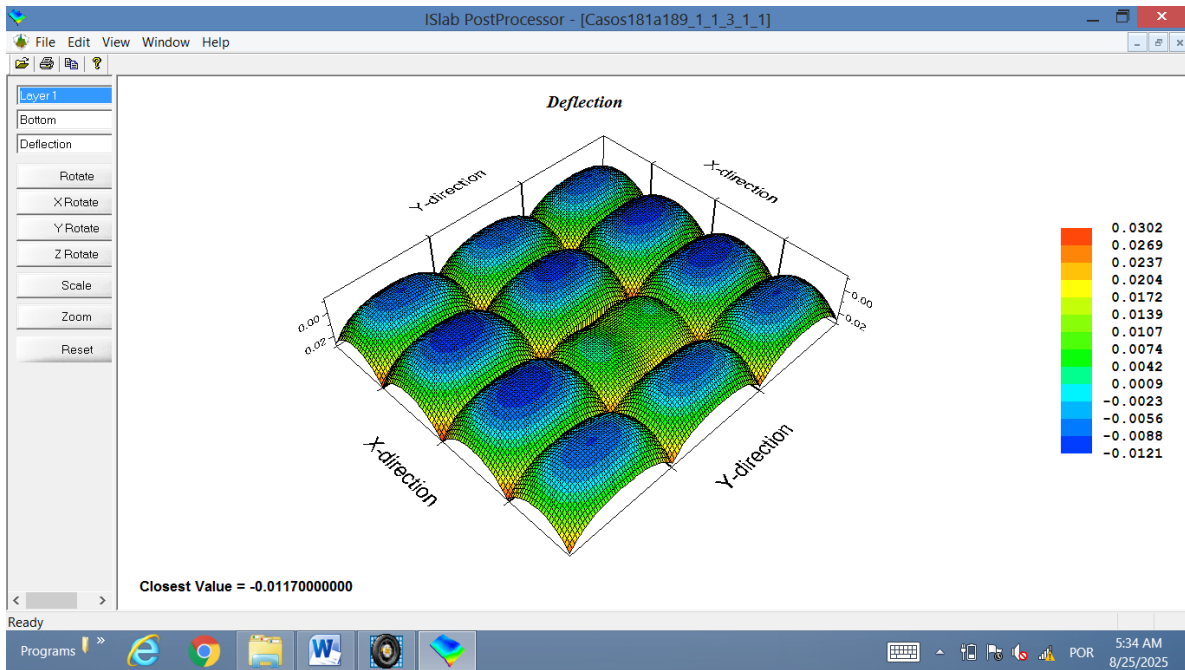
- Caso 285



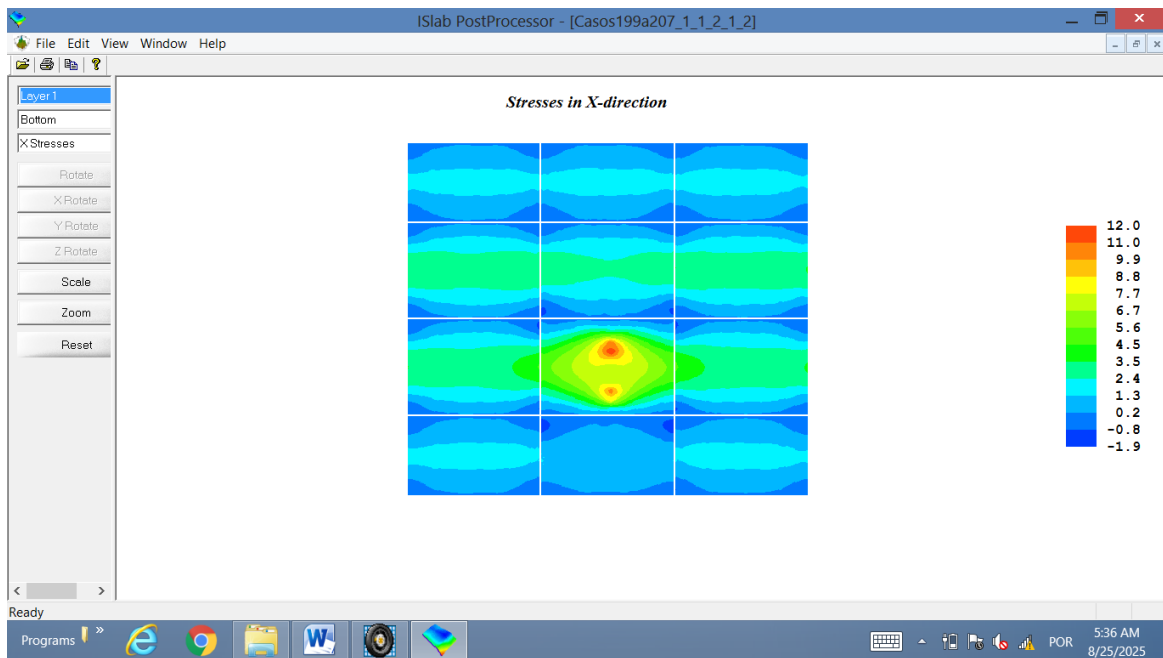


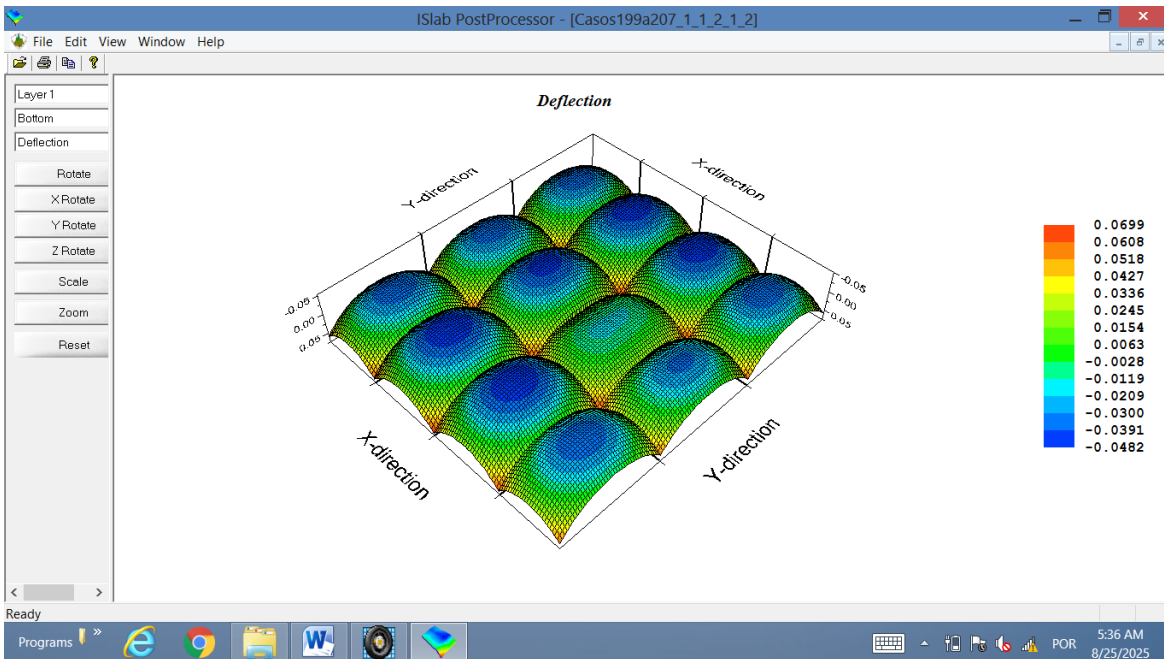
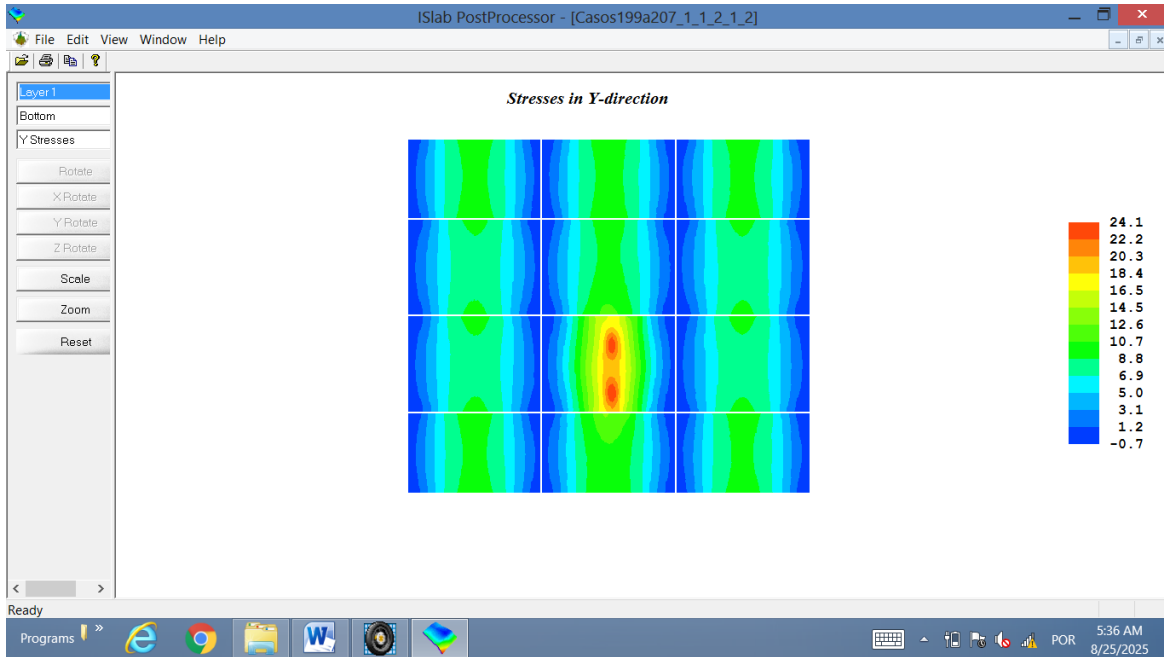
- Caso 305



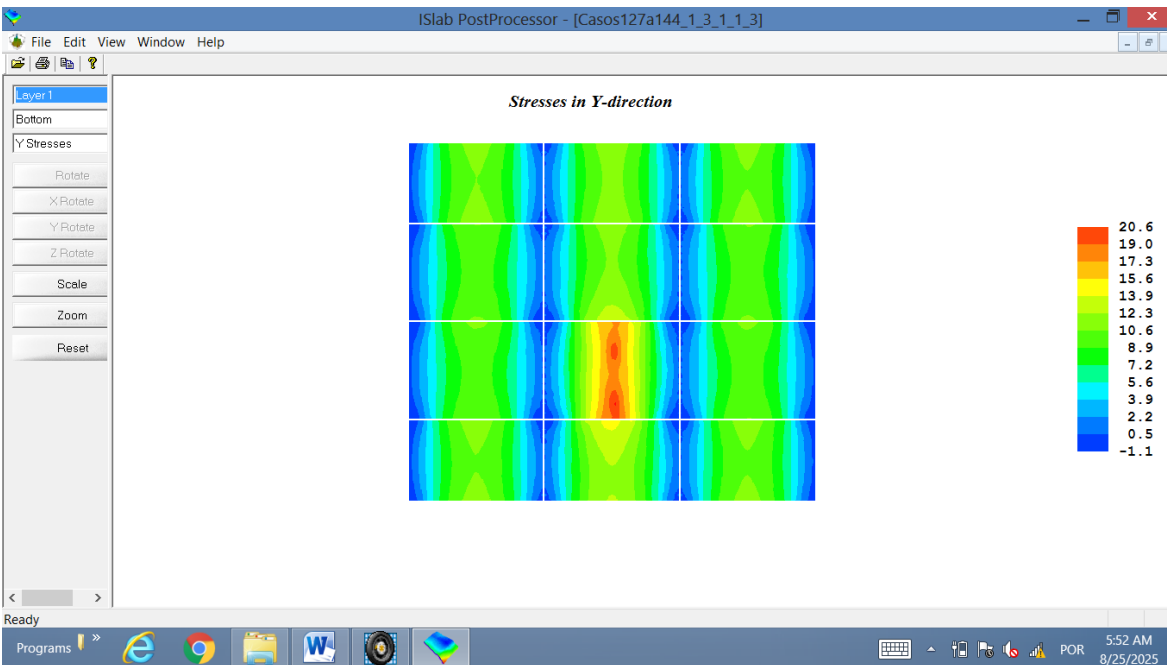
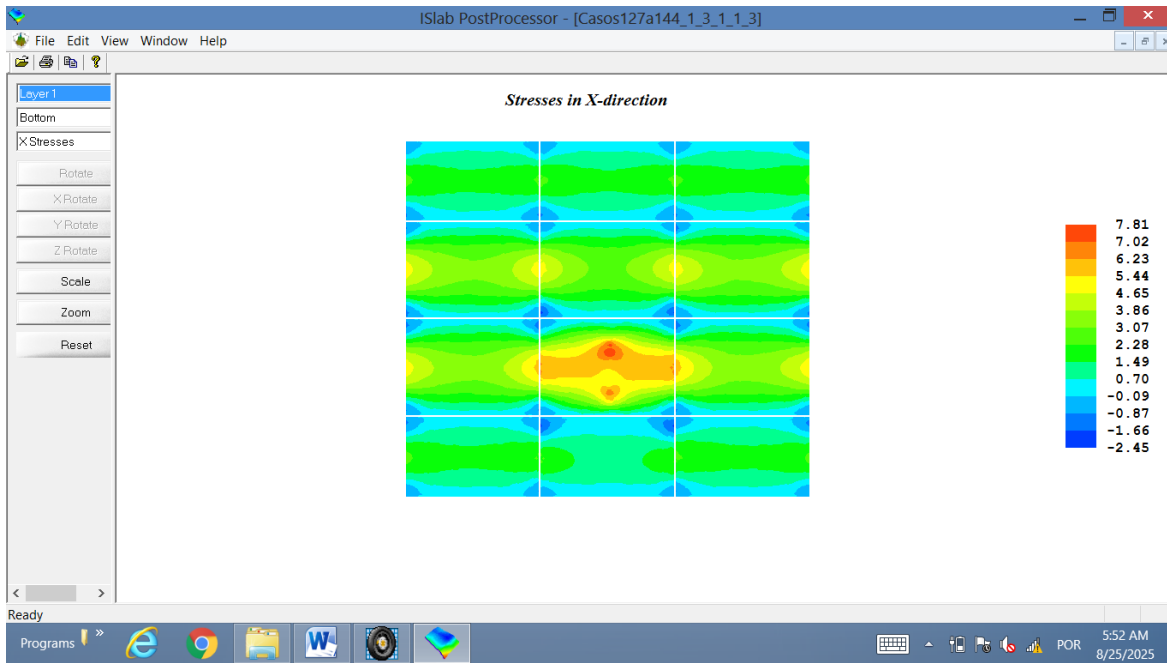


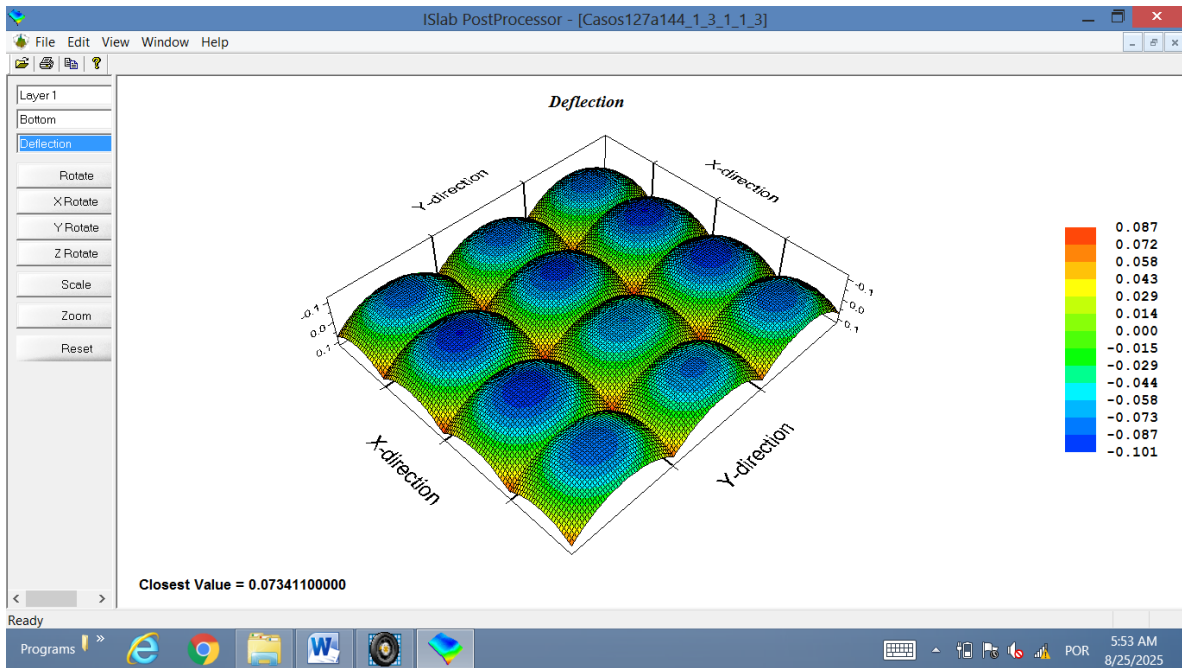
- Caso 338



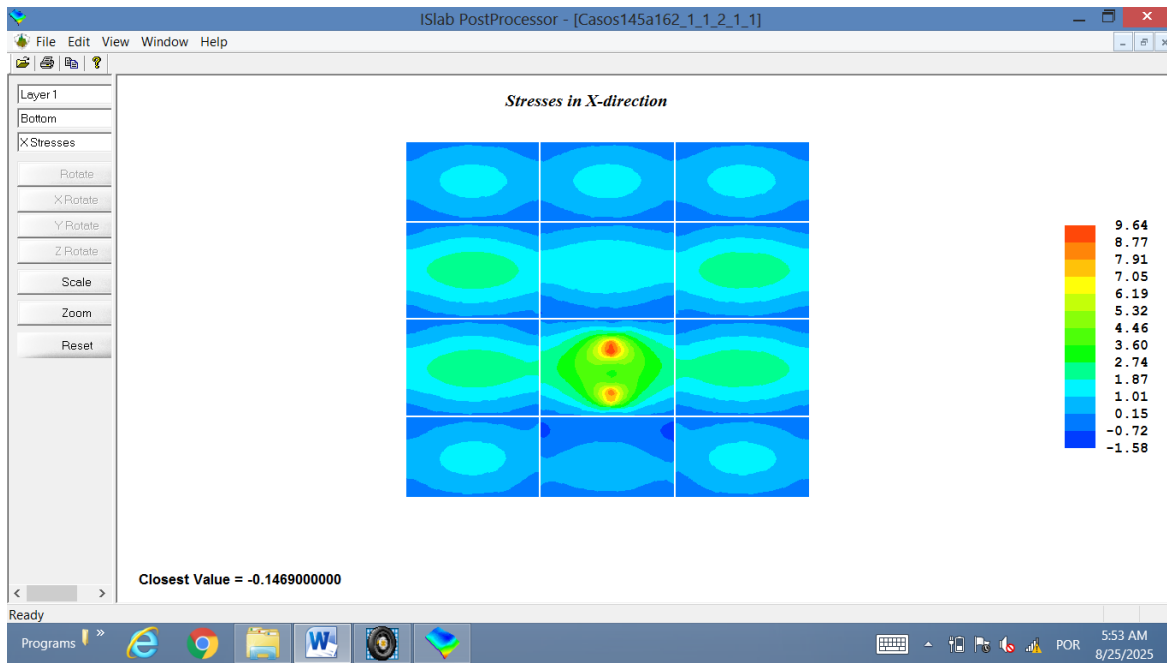


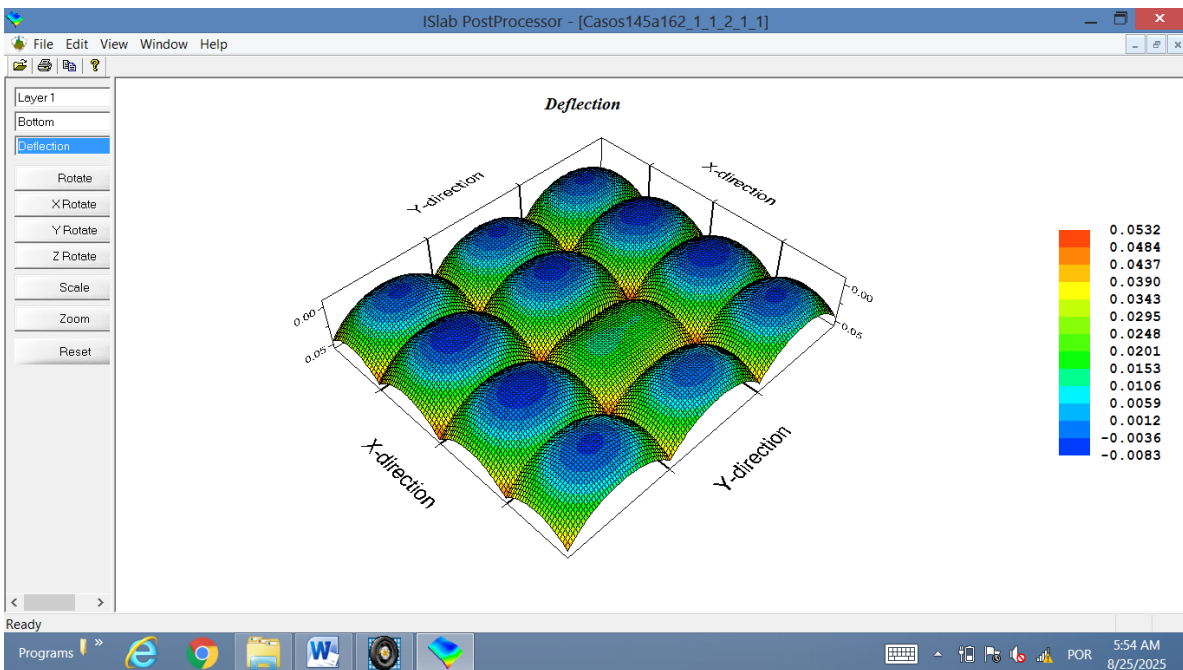
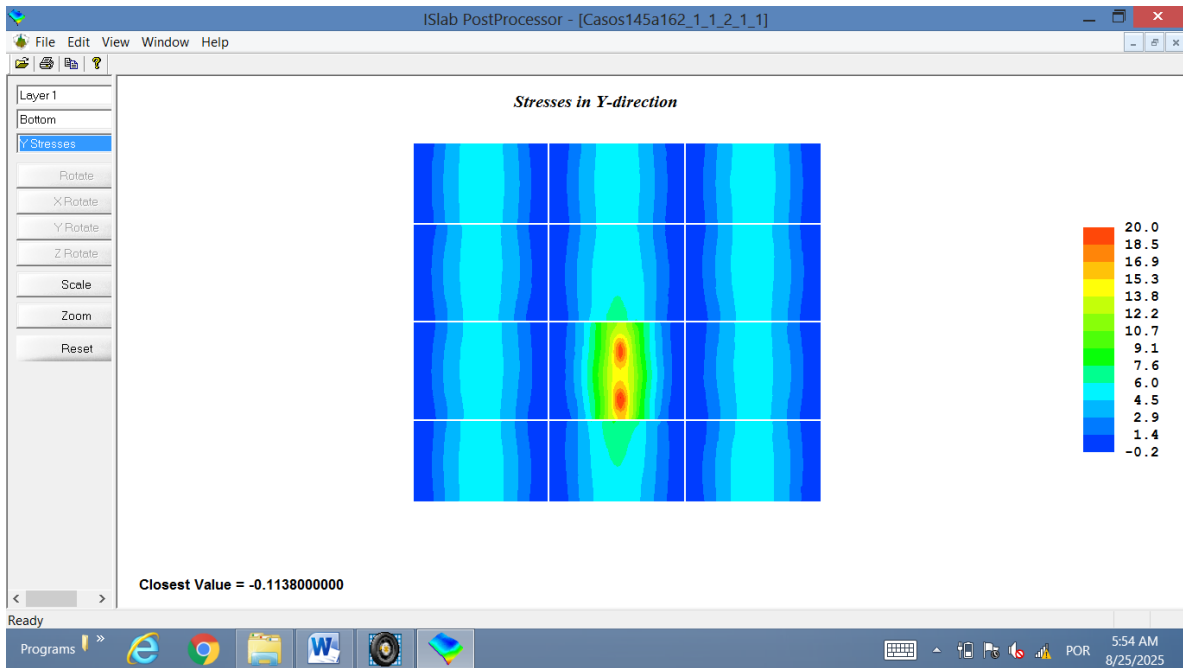
- Caso 356



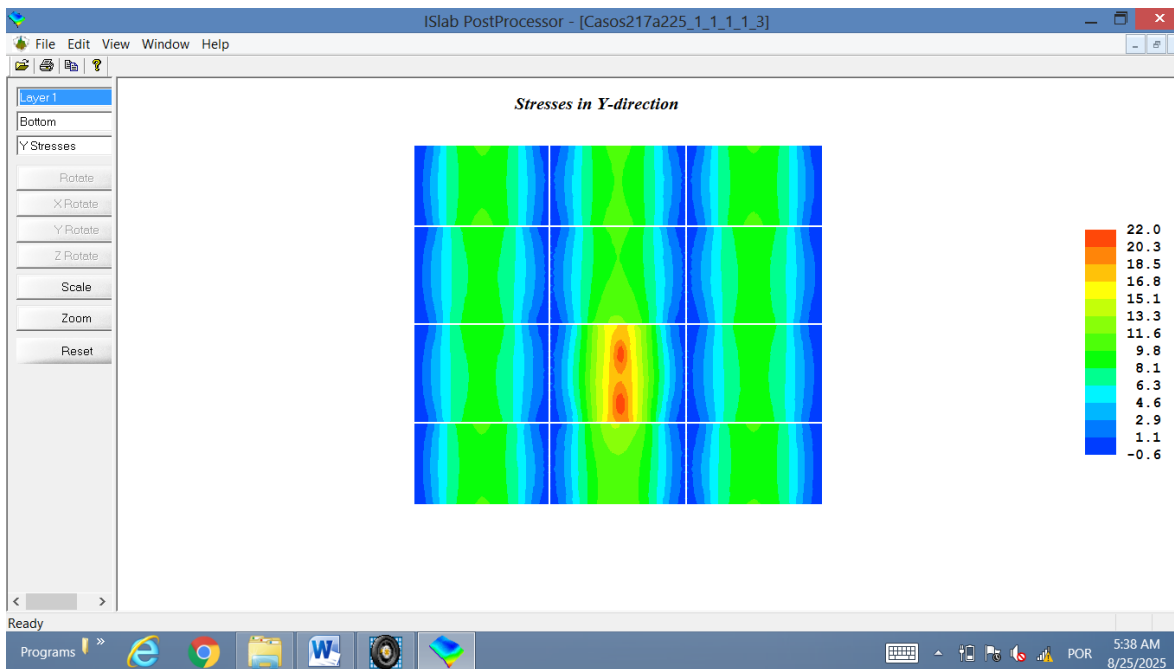
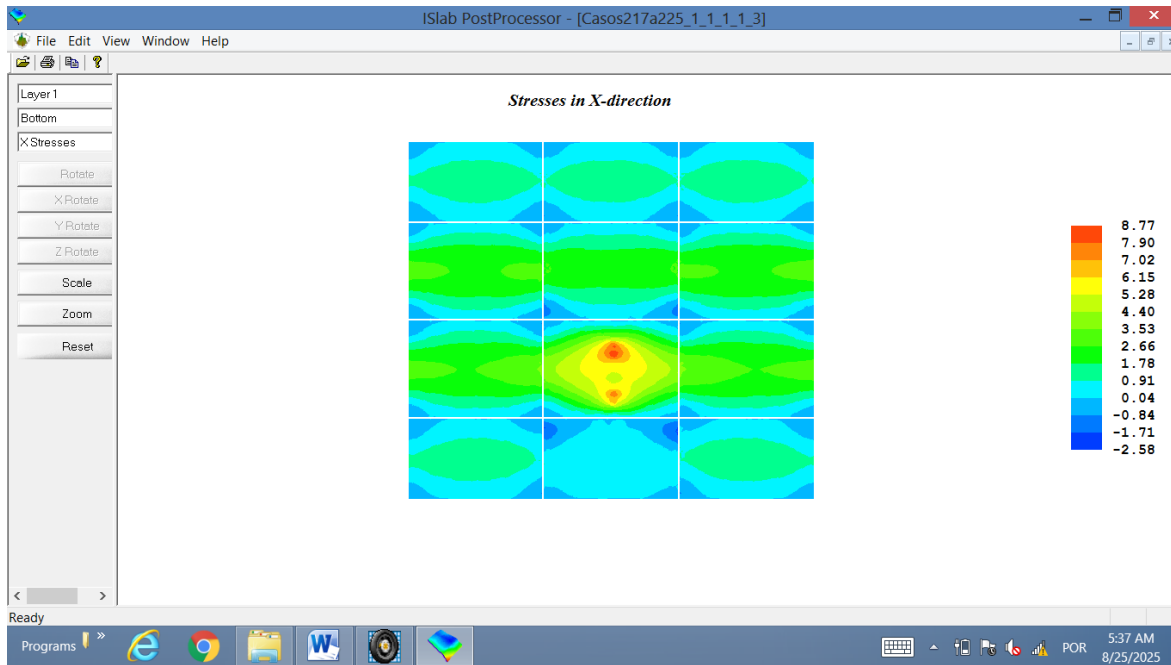


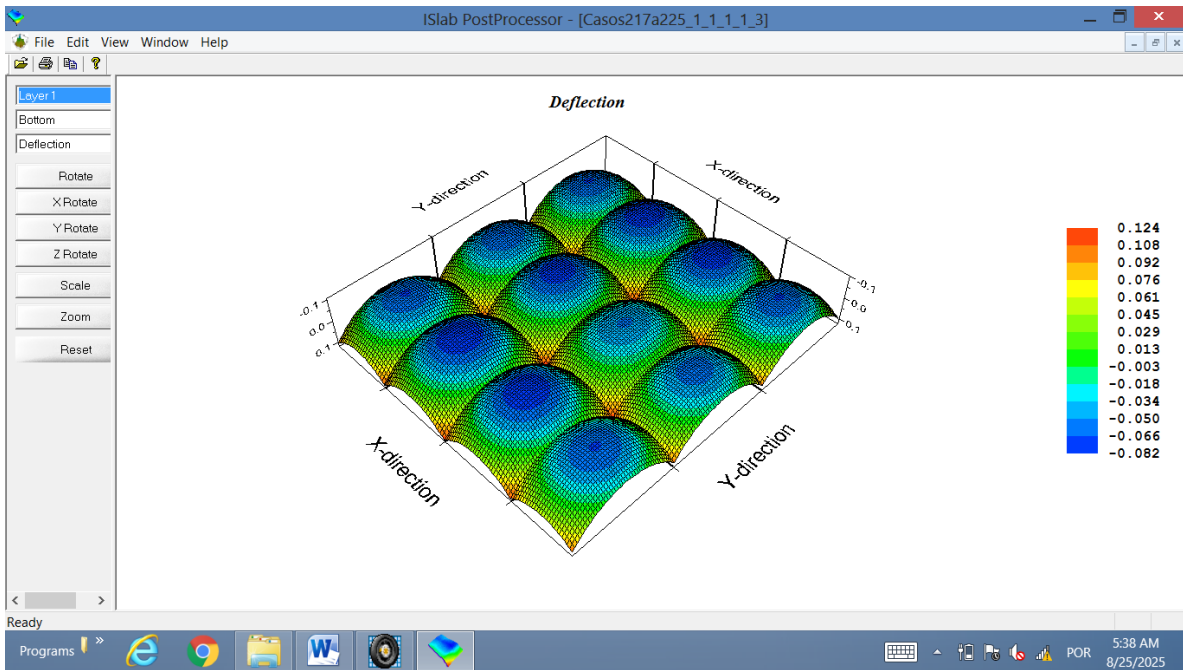
- Caso 364



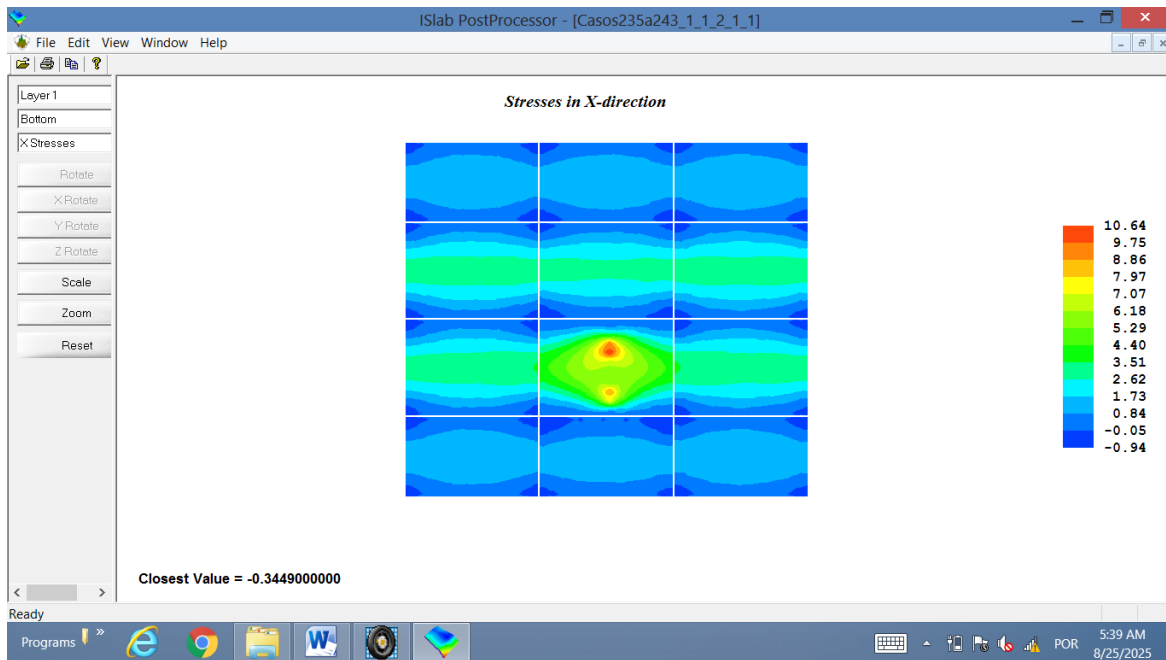


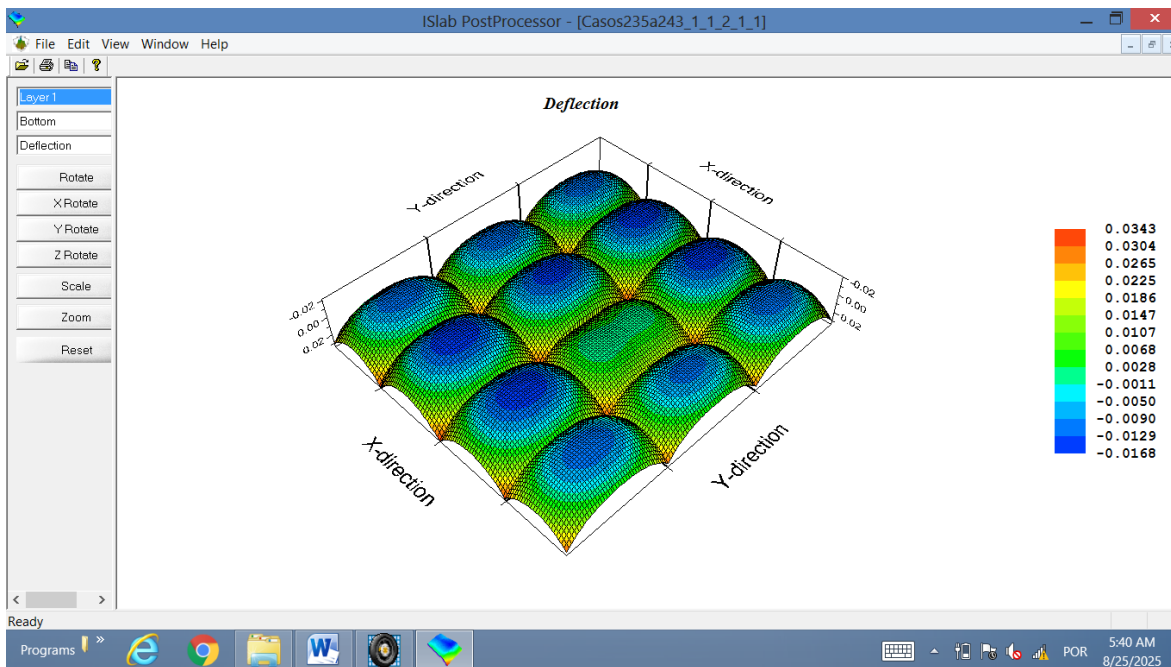
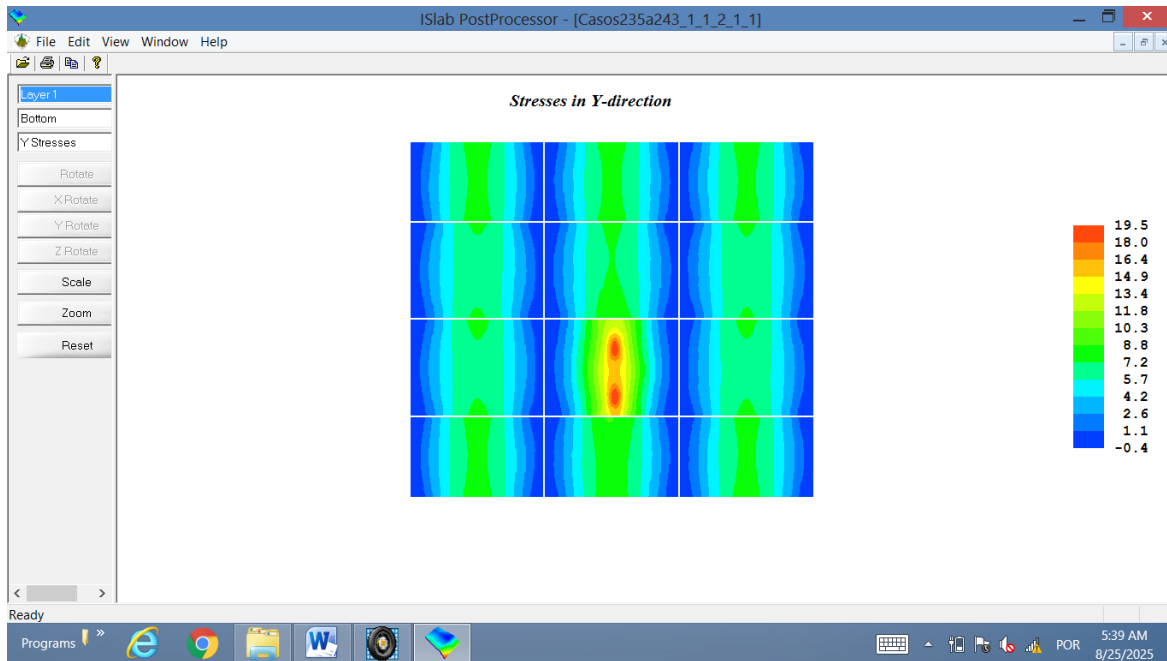
- Caso 372





- Caso 393





APÊNDICE B – MODELAGEM DE PLACA ISOLADA: IMAGENS DE SAÍDA GERADO PELOS PROGRAMAS ISLAB 2005 E ABAQUS

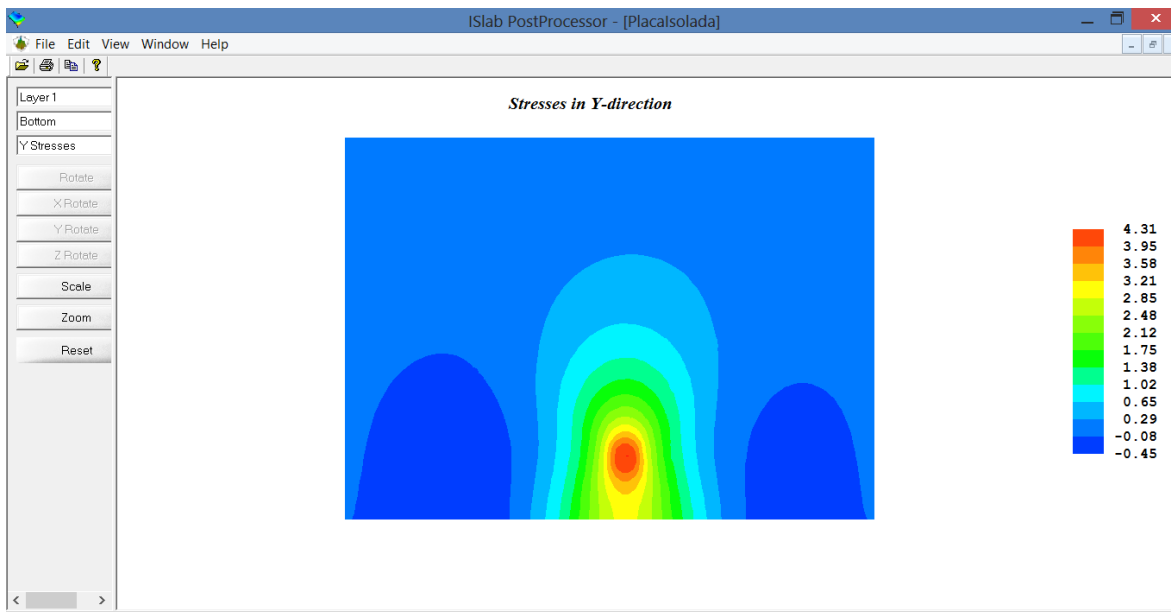

Com a finalidade de uma comparação inicial entre respostas mecânicas apresentadas por modelos numéricos muito diferenciados entre si, neste Apêndice B são apresentadas simulações de uma placa isolada, sem conexões de barras em juntas, para idênticas situações de pista e de análise (dimensões, módulos e cargas), empregando-se simultaneamente o programa em duas dimensões (que simula placas sobre molas) e em três dimensões (que simula elementos sólidos de blocos interconectados, formando uma superfície plana, sobre molas).


As simulações empregaram as seguintes condições de contorno:

- Superfícies de espessura de 23 cm, com dimensões planas de 5 m de comprimento e 3,6 m de largura;
- Módulo de elasticidade do concreto de 30 GPa;
- Coeficiente de Poisson do concreto de 0,2;
- Módulo de reação do subleito de 50 MPa/m;
- Diferencial térmico nulo;
- Carga de uma roda apenas, simulando 15 kN, centralizada no comprimento e posicionada tangenciando a borda longitudinal da placa.

Resultados oferecidos pelo Programa ISLAB 2005

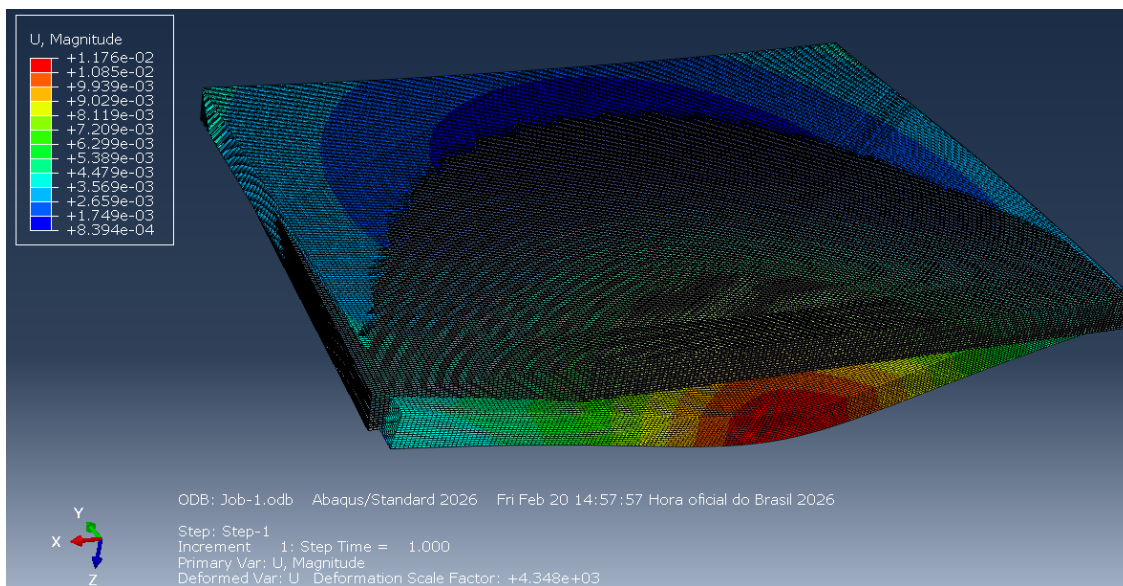
Na sequência são apresentados os resultados de deflexões e esforços máximos nas direções Y e X obtidos com o programa ISLAB ao modelar placa isolada com aplicação de uma carga isolada.







Resultados oferecidos pelo Programa ABAQUS

Na sequência são apresentados os resultados para deflexões e esforços máximos nas direções Y e X, obtidos com o programa ABAQUS, para as mesmas condições de placa com bordos livres simulada pelo ISLAB 2005.





REFERÊNCIAS BIBLIOGRÁFICAS

Escalonamento em juntas

AASHTO. Mechanistic-Empirical Pavement Design Guide (MEPDG): A manual of practice. American Association of State Highway and Transportation Officials, Washington D.C., 2008.

NCHRP. Guide for Mechanistic-Empirical Design of New and Rehabilitated Pavement Structures. Appendix JJ: Transverse Joint Faulting Model. Project 1-37A, National Cooperative Highway Research Program, Transportation Research Board, National Research Council, Washington D.C., 2003.

_____. Guide for Mechanistic-Empirical Design of New and Rehabilitated Pavement Structures. Final Report, Project 1-37A. National Cooperative Highway Research Program, Transportation Research Board, National Research Council, Washington D.C., 2003.

_____. Changes to the Mechanistic-Empirical Pavement Design Guide software through version 0.9. NCHRP Project 1-40D, National Cooperative Highway Research Program, Transportation Research Board, National Research Council, Washington D. C., 2006.

_____. Developing recalibrated concrete pavement performance models for the mechanistic-empirical pavement design. NCHRP 20-07, Research for AASHTO Standing Committee on Highways, National Cooperative Highway Research Program, Transportation Research Board, National Research Council, Washington D.C. 2014.

KHAZANOVICH, L; DARTER, M.; YU, H. T. Mechanistic-empirical model to predict transverse joint faulting. Transportation Research Record: Journal of the Transportation Research Board, no. 1896, pp. 34-45, TRB, National Research Council, Washington D.C, 2004.

MU, F.; MACK, J. W.; RODDEN, R. A. Review of national and state-level calibrations of AASHTOWare Pavement ME design for new jointed plain concrete pavement, International Journal of Pavement Engineering (online), 2016, DOI: 10.1080/10298436.2016.1210804.

SALLES, L. S.; KHAZANOVICH, L. Local calibration of pavement mechanistic-empirical faulting reliability using pavement management data. Transportation Research Record, vol. 2675(9), pp. 251-264, National Academy of Science, Transportation Research Board, Washington D.C., 2021.

YU, H. T.; SMITH, K. D.; DARTER, M. I.; JIANG, J.; KHAZANOVICH, L. Performance of concrete pavements Volume III – Improving concrete pavement performance. FHWA Report RD-95-111, Federal Highway Administration, Georgetown Pike, 1998.

Modelagem Numérica

ABDALLA, BASEL. Validation and calibration of finite element models for rigid pavement using in situ data: Selection of joint spacing. Ohio University, 2005.

BALBO, J. T. Pavimentos de concreto. Editora Signer, Oficina de Textos, São Paulo, 2009.

BALBO, J. T.; SEVERI, A. Thermal gradients in concrete pavements in tropical environment: experimental appraisal. Transportation Research Record: Journal of the Transportation Research Board, V. 1809, Issue 1. <https://doi.org/10.3141/1809-02>, 2002.

COLLEY, B. E.; HUMPHREY, H. A. Aggregate Interlock at Joints Concrete Pavements. Illinois, 1967.

COVARRUBIAS V., JUAN PABLO. Diseño de losas de hormigón con geometría optimizada. Revista ingeniería de construcción, v. 27, n. 3, p. 181–197, dez. 2012.

DE SALLES, LUCIO SALLES; KHAZANOVICH, LEV; BALBO, JOSÉ TADEU. Structural analysis of transverse cracks in short continuously reinforced concrete pavements. International Journal of Pavement Engineering, v. 21, n. 14, p. 1853–1863, 5 dez. 2019.

GUO, HUA; SHERWOOD, JAMES A.; SNYDER, MARK B. Component dowel-bar model for load-transfer system in PCC pavements. Journal of Transportation Engineering, v. 121, n. 3, p. 289–298, 1995.

JENSEN, ELIN A.; HANSEN, WILL. Mechanism of load transfer-crack width relation in JPCP: Influence of coarse aggregate properties. In: Florida: set. 2001.

KHAZANOVICH, LEV. Structural analysis of multi-layered concrete pavement systems. University of Illinois at Urbana-Champaign, 1994.

KHAZANOVICH, LEV; IOANNIDES. Anastasios M. Finite element analysis of slabs-on-grade using higher order subgrade soil models. In: Vicksburg, Mississippi, USA: 8 set. 1993.

KIM, SUNGHWAN; GOPALAKRISHNAN, KASTHURIRANGAN; CEYLAN, HALIL. A simplified approach for predicting early-age concrete pavement deformation. *Journal of Civil Engineering and Management*, v. 17, n. 1, p. 27–35, 2011.

KOH, YONGSUNG *et al.* Structural and Fatigue Analysis of Jointed Plain Concrete Pavement Top-Down and Bottom-Up Transverse Cracking Subjected to Superloads. *Transportation Research Record: Journal of the Transportation Research Board*, v. 2676, n. 9, p. 76–93, 21 set. 2022.

KOROVESIS, GEORGE THEOFANIS. Analysis of slab-on-grade pavement systems subjected to wheel and temperature loadings. University of Illinois at Urbana-Champaign, 1990.

MELOSH, ROBERT J. Basis for derivation of matrices for the direct stiffness method. *AIAA Journal*, v. 1, n. 7, p. 1631–1637, jul. 1963.

NASIM, MUHAMMAD A. *et al.* Behavior of a Rigid Pavement Under Moving Dynamic Loads. *Transportation Research Record*, v. 1307, 1991.

ROESLER, JEFFERY *et al.* Design and Concrete Material Requirements for Ultra-Thin Whitetopping Illinois Center for Transportation. 2008.

SACHS, STEVEN G. *et al.* Establishing the Interlayer Structural Response for Unbonded Concrete Overlays of Existing Concrete Pavements. *Transportation Research Record: Journal of the Transportation Research Board*, v. 2672, n. 40, p. 254–263, 8 dez. 2018.

SARGAND, SHAD M. Performance of dowel bars. Ohio, 2001.

SAVERI, A. A. Estudo dos gradientes térmicos em pavimentos de concreto de cimento Portland no ambiente tropical. Tese (Doutorado), PPGET, Universidade de São Paulo, São Paulo, 2002.

SHI, XIJUN *et al.* Performance evaluation of jointed plain concrete pavement made with Portland cement concrete containing reclaimed asphalt pavement. *Road Materials and Pavement Design*, v. 22, n. 1, p. 59–81, 2 jan. 2021.

SOUDER, NICOLE C. *et al.* Modeling the Development of Permanent Deformation in Asphalt Interlayers of Unbonded Concrete Overlays of Concrete Pavements. *Transportation Research Record: Journal of the Transportation Research Board*, v. 2674, n. 9, p. 489–499, 26 set. 2020.

TABATABAIE, AMIR M.; BARENBERG, ERNEST J. Finite-Element Analysis of Jointed or Cracked Concrete Pavements. *Transportation Research Record*, v. 671, 1978.

TABATABAIE-RAISSI, AMIR. *Structural Analysis of Concrete Pavement Joints*. Illinois: University of Illinois at Urbana-Champaign, 1978.

WANG, WEIJUN; BASHEER, IMAD; PETROS, KATHERINE. Jointed plain concrete pavement model evaluation. In: National Research Council, 2006.

Clima Brasileiro e Efeitos Térmicos

ABBASI, FAEZEH; BAZGEER, SAEED; KALEHBASTI, PARVIZ REZAZADEH; OSKOUE, EBRAHIM ASADI; HAGHIGHAT, MASOUD; E KALEHBASTI, POUYA REZAZADEH. New climatic zones in Iran: a comparative study of different empirical methods and clustering technique. *Theoretical and Applied Climatology*, [s. l.], v. 147, n. 1, p. 47–61, 1 Jan. 2022. ISSN 1434-4483. DOI 10.1007/s00704-021-03785-9.

BECK, HYLKE E.; ZIMMERMANN, NIKLAUS E.; MCVICAR, TIM R.; VERGOPOLAN, NOEMI; BERG, ALEXIS; E WOOD, ERIC F. Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Scientific Data*, [s. l.], v. 5, n. 1, p. 180214, 30 out. 2018. ISSN 2052-4463. DOI 10.1038/sdata.2018.214.

BELDA, MICHAL; HOLTANOVÁ, EVA; KALVOVÁ, JAROSLAVA; E HALENKA, TOMÁŠ. Climate classification revisited: from Köppen to Trewartha. *Climate Research*, [s. l.], v. 59, p. 1–13, 2014.

CARVALHO, M. J.; MELO-GONÇALVES, P.; TEIXEIRA, J. C.; e ROCHA, A. Regionalization of Europe based on a K-Means Cluster Analysis of the climate change of temperatures and precipitation. *Physics and Chemistry of the Earth, Parts A/B/C*, [s. l.], v. 94, p. 22–28, 2016. ISSN 1474-7065. DOI <https://doi.org/10.1016/j.pce.2016.05.001>.

CASSALHO, F.; DALELES RENNÓ, C.; BOSCO COURA DOS REIS, J.; CLÁUDIO DA SILVA, B. Hydrologic Validation of MERGE Precipitation Products over Anthropogenic Watersheds. *Water* 2020, 12, 1268. <https://doi.org/10.3390/w12051268>

EVERITT, B. S.; LANDAU, S.; LEESE, M.; STAHL, D. Miscellaneous Clustering Methods. In: *Cluster Analysis*. [S. l.]: John Wiley & Sons, Ltd, 2011. p. 215–255. ISBN 978-0-470-97781-1. DOI <https://doi.org/10.1002/9780470977811.ch8>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/9780470977811.ch8>.

GEIGER, RUDOLF. Klassifikation der klimate nach W. Köppen. Landolt-Börnstein–Zahlenwerte und Funktionen aus Physik, Chemie, Astronomie, Geophysik und Technik, [s. l.], v. 3, p. 603–607, 1954.

GEIGER, RUDOLF. Überarbeitete Neuauflage von Geiger, R. Köppen-Geiger/Klima der Erde. (Wandkarte 1: 16 Mill.) –Klett-Perthes, Gotha, [s. l.], v. 1, 1961.

HERSBACH H, BELL B, BERRISFORD P, *et al.* The ERA5 global reanalysis. *Q J R Meteorol Soc.* 2020; 146: 1999–2049. <https://doi.org/10.1002/qj.3803>

KONONENKO, IGOR; KUKAR, MATJAŽ. Chapter 12 - Cluster Analysis. *In:* KONONENKO, Igor; KUKAR, Matjaž (ed.). *Machine Learning and Data Mining.* [S. l.]: Woodhead Publishing, 1 jan. 2007. p. 321–358. ISBN 978-1-904275-21-3. DOI 10.1533/9780857099440.321. Disponível em: <https://www.sciencedirect.com/science/article/pii/B9781904275213500125>.

KÖPPEN, W. Das geographische System der Klimate (Handbuch der Klimatologie, Bd. 1, Teil C). Apud. Beck, C, [s. l.], 1936.

KOTTEK, MARKUS; GRIESER, JÜRGEN; BECK, CHRISTOPH; RUDOLF, BRUNO; E RUBEL, FRANZ. World Map of the Köppen-Geiger climate classification updated. *Meteorologische Zeitschrift*, Stuttgart, Germany, v. 15, n. 3, p. 259–263, jul. 2006. DOI 10.1127/0941-2948/2006/0130.

LASANTHA, VAJIRA; OKI, TAIKAN; E TOKUDA, DAISUKE. Data-Driven versus Köppen-Geiger Systems of Climate Classification. *Advances in Meteorology*, [s. l.], v. 2022, n. 1, p. 3581299, 2022. DOI <https://doi.org/10.1155/2022/3581299>.

LIMA, RAFAEL FAUSTO DE; APARECIDO, LUCAS EDUARDO DE OLIVEIRA; TORSONI, GUILHERME BOTEGA; E ROLIM, GLAUCO DE SOUZA. Climate Change Assessment in Brazil: Utilizing the Köppen-Geiger (1936) Climate Classification. *Revista Brasileira de Meteorologia*, [s. l.], v. 38, 2023. ISSN 0102-7786.

LYRA, GUSTAVO B.; OLIVEIRA-JÚNIOR, JOSÉ F.; E ZERI, MARCELO. Cluster analysis applied to the spatial and temporal variability of monthly rainfall in Alagoas state, Northeast of Brazil. *International Journal of Climatology*, [s. l.], v. 34, n. 13, p. 3546–3558, 2014. DOI <https://doi.org/10.1002/joc.3926>.

MACHADO, CAROLYNE BUENO; CAMPOS, THAMIRIS L. O. B.; ABOU RAFEE, SAMEH A.; MARTINS, JORGE ALBERTO; GRIMM, ALICE M.; E FREITAS, EDMÍLSON DIAS DE. Extreme Rainfall Events in the Macrometropolis of São Paulo: trends and Connection with Climate Oscillations. *Journal of Applied Meteorology and Climatology*, [s. l.], 2021. DOI 10.1175/JAMC-D-20-0173.1.

MADHULATHA, Tagaram Soni; WYLD, David C.; WOZNIAK, Michal; CHAKI, Nabendu; MEGHANATHAN, Natarajan; e NAGAMALAI, Dhinaharan (ed.). Comparison between K-Means and K-Medoids Clustering Algorithms. In: WYLD, David C.; WOZNIAK, Michal; CHAKI, Nabendu; MEGHANATHAN, Natarajan; NAGAMALAI, Dhinaharan (ed.). 2011, Berlin, Heidelberg. *Advances in Computing and Information Technology*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. p. 472–481. ISBN 978-3-642-22555-0.

MARTINS MONTEIRO, ANA FLÁVIA; E MARTINS, FABRINA BOLZAN. Global Solar Radiation Models in Minas Gerais, Southeastern Brazil. *Advances in Meteorology*, [s. l.], v. 2019, n. 1, p. 9515430, 2019. DOI <https://doi.org/10.1155/2019/9515430>.

MUÑOZ-SABATER, J., DUTRA, E., AGUSTÍ-PANAREDA, A., ALBERGEL, C., ARDUINI, G., BALSAMO, G., BOUSSETTA, S., CHOULGA, M., HARRIGAN, S., HERSBACH, H., MARTENS, B., MIRALLES, D. G., PILES, M., RODRÍGUEZ-FERNÁNDEZ, N. J., ZSOTER, E., BUONTEMPO, C., AND THÉPAUT, J.-N.: ERA5-Land: a state-of-the-art global reanalysis dataset for land applications, *Earth Syst. Sci. Data*, 13, 4349–4383, <https://doi.org/10.5194/essd-13-4349-2021>, 2021.

NETZEL, PAWEL; E STEPINSKI, TOMASZ. On Using a Clustering Approach for Global Climate Classification. *Journal of Climate*, Boston MA, USA, v. 29, n. 9, p. 3387–3401, 2016. DOI 10.1175/JCLI-D-15-0640.1.

PELLEG, DAN; MOORE, ANDREW W.; E OTHERS. X-means: Extending k-means with efficient estimation of the number of clusters. In: 2000. *ICML*. [S. l.]: Stanford, CA, 2000. v. 1, p. 727–734.

RAHIMI, JABER; LAUX, PATRICK; E KHALILI, ALI. Assessment of climate change over Iran: CMIP5 results and their presentation in terms of Köppen–Geiger climate zones. *Theoretical and Applied Climatology*, [s. l.], v. 141, n. 1, p. 183–199, 1 jul. 2020. ISSN 1434-4483. DOI 10.1007/s00704-020-03190-8.

ROZANTE, J. R., D. S. MOREIRA, L. G. G. DE GONCALVES, AND D. A. VILA, 2010: Combining TRMM and Surface Observations of Precipitation: Technique and Validation over South America. *Wea. Forecasting*, 25, 885–894, <https://doi.org/10.1175/2010WAF2222325.1>.

JOSÉ ROBERTO ROZANTE, ENVER RAMIREZ GUTIERREZ, ALEX DE ALMEIDA FERNANDES & DANIEL A. Vila (2020) Performance of precipitation products obtained from combinations of satellite and surface observations, *International Journal of Remote Sensing*, 41:19, 7585-7604, DOI: 10.1080/01431161.2020.1763504

SA'ADI, ZULFAQAR; SHAHID, SHAMSUDDIN; E SHIRU, MOHAMMED SANUSI. Defining climate zone of Borneo based on cluster analysis. *Theoretical and Applied Climatology*, [s. l.], v. 145, n. 3, p. 1467–1484, 1 ago. 2021. ISSN 1434-4483. DOI 10.1007/s00704-021-03701-1.

SOUZA, AMAURY de *et al.* Climate Regionalization in Mato Grosso do Sul: a Combination of Hierarchical and Non-hierarchical Clustering Analyses Based on Precipitation and Temperature. *Brazilian Archives of Biology and Technology*, [s. l.], v. 65, p. e22210331, 2022. ISSN 1516-8913. DOI 10.1590/1678-4324-2022210331.

WILKS, DANIEL S. CHAPTER 16 - CLUSTER ANALYSIS. IN: WILKS, DANIEL S. (ed.). *Statistical Methods in the Atmospheric Sciences (Fourth Edition)*. [S. l.]: Elsevier, 1 jan. 2019. p. 721–738. ISBN 978-0-12-815823-4. DOI 10.1016/B978-0-12-815823-4.00016. <https://www.sciencedirect.com/science/article/pii/B978012815823400016X>

YANG, YANHAI; QIAN, BAITONG; XU, QICHENG; E YANG, YE. Climate Regionalization of Asphalt Pavement Based on the K-Means Clustering Algorithm. *Advances in Civil Engineering*, [s. l.], v. 2020, n. 1, p. 6917243, 2020. DOI <https://doi.org/10.1155/2020/691>