




Universidade do Minho
Escola de Engenharia

Reus Salini

INTELLIPave
Uma Abordagem Baseada em
Inteligência Artificial para a
Modelagem de Pavimentos Asfálticos



Universidade do Minho
Escola de Engenharia

Reus Salini

INTELLIPave
Uma Abordagem Baseada em
Inteligência Artificial para a
Modelagem de Pavimentos Asfálticos

Tese de Doutoramento
Inteligência Artificial

Trabalho efectuado sob a orientação do
Professor Doutor José Carlos Ferreira Maia Neves

Co-Orientador:
Professor Doutor António Carlos da Silva Abelha

DECLARAÇÃO

Nome Reus Salini
Endereço electrónico: R.Salini@gmx.net
Telefone: -
Número do Passaporte: 795051
Título da tese: INTELLIPave, Uma abordagem baseada em inteligência artificial para a modelagem de pavimentos asfálticos
Orientadores: José Carlos Ferreira MAIA NEVES
Orientador
António Carlos da Silva ABELHA
Co-orientador
Ano de conclusão: 2010
Ramo de Conhecimento do Doutoramento: Inteligência Artificial

É AUTORIZADA A REPRODUÇÃO INTEGRAL DESTA TESE APENAS PARA EFEITOS DE INVESTIGAÇÃO, MEDIANTE DECLARAÇÃO ESCRITA DO INTERESSADO, QUE A TAL SE COMPROMETE.

Universidade do Minho, 29/NOV/2010



Reus Salini

TESE DE DOUTORADO

**Este trabalho foi redigido ao abrigo
do acordo ortográfico da Língua Portuguesa**

Este trabalho teve o apoio financeiro das seguintes entidades:

Fundação para a Ciência e a Tecnologia – FCT

Fundação Calouste Gulbenkian

Desenvolvido no âmbito do projeto

UT Austin | Portugal

UTAustin/CA/0012/2008

Resumo

Este trabalho apresenta o desenvolvimento de uma nova e inédita metodologia denominada INTELLIPave, onde são empregadas técnicas de inteligência artificial e métodos numéricos para a modelagem do comportamento de pavimentos asfálticos a partir de dados coletados em campo. A metodologia INTELLIPave é completa, tratando o problema desde a coleta de dados até a aplicação dos modelos no dimensionamento de pavimentos novos e avaliação de pavimentos existentes; sem simplificações nem concessões, trabalhando sempre em escala real e total. O modelo resultante da aplicação da metodologia INTELLIPave é denominado CUIA Model.

O CUIA Model é construído a partir de modelos especialistas que incluem dados climáticos (temperatura do ar, pluviosidade, etc.), assim como características do tráfego (quantidade e classes dos veículos, velocidades, cargas por eixo ou cargas totais por veículo, etc.) e, se disponíveis, dados a respeito da resposta estrutural do pavimento asfáltico (tensões, deformações e extensões em pontos relevantes das várias camadas do pavimento). Estes dados devem ser coletados em uma ou mais rodovias abertas ao tráfego real até que o pavimento atinja um determinado critério de falha.

Dentre as inovações introduzidas pela metodologia INTELLIPave estão: o emprego do critério de falha externo ao modelo (aside failure criteria) e critérios múltiplos de falha; Criação do índice relativo de dano ao pavimento (RPDI, no acrônimo em inglês); O acúmulo científico do conhecimento sobre a performance dos pavimentos e seu emprego na melhoria da acurácia das predições futuras de performance; Consideração do envelhecimento dos materiais e outros fenômenos que se distribuem ao longo do tempo (fenômeno de auto-reparação, etc.); A paralelização de modelos individuais para funcionarem como um modelo único (CUIA Model); e, A consideração implícita de variáveis de origem desconhecidas ou cujos dados não foram coletados em campo. Neste sentido, o INTELLIPave corresponde à primeira metodologia para pavimentos que não se baseia em procedimentos empíricos ou empírico-mecanísticos.

Abstract

This research is focused on the development of a new methodology called INTELLIPave, where are used artificial intelligence and numerical methods for model the asphalt pavement behavior based on data collected in the field. The INTELLIPave method is fully developed, including the procedures since the data is collected until the model application to design new pavements and evaluate existing pavements; without any simplification or concession, handling the subject in full scale. The model based on INTELLIPave method is called CUIA Model.

The CUIA Model é built over specialized models with data about the climate (air temperature, rainfall, et cetera) and traffic (quantity of vehicles, classification, weights, speed, et cetera) and, if available, data about the pavement structural response (stresses, strains, et cetera) can be included. For optimum results, the data must to be collected in a highway open to real traffic until the pavement fails according a chosen criteria.

Among the innovations of the INTELLIPave method are: the aside failure criteria and multiple failure criteria; the Relative Pavement Damage Index (RPDI); Scientific and rational knowledge accumulation and reuse for improve of the accuracy on future modeling; Consideration of materials aging and other pavement behaviors that change in the time (asphalt binder healing/self-recovery, et cetera); Unitarian model's parallelization to work as a single model (CUIA Model); and, Implicit consideration of unknown variables and variables without data.

INTELLIPave is the first method for asphalt pavement modeling not based on empiric or empiric-mechanistic approaches.

Sumário

1	INTRODUÇÃO	22
1.1	Contexto e motivação	27
1.2	Objetivos	28
1.3	Estrutura desta tese	29
2	MODELAGEM DE PAVIMENTOS ASFÁLTICOS.....	31
2.1	Introdução à pavimentação	31
2.1.1	Pavimentos flexíveis ou asfálticos.....	32
2.1.2	Pavimentos rígidos ou em concreto de cimento portland.....	33
2.1.3	Pavimentos em ladrilhos ou pedras.....	34
2.2	Defeitos dos pavimentos asfálticos.....	35
2.2.1	Trincas	37
2.2.2	Deformações permanentes.....	37
2.3	Modelagem de pavimentos asfálticos	39
2.3.1	Métodos empíricos	39
2.3.2	Métodos Empírico-mecanísticos.....	45
2.3.3	Método da AASHTO 2002	51
2.3.4	Pavimentos asfálticos perpétuos	54
3	INTELIGÊNCIA ARTIFICIAL APLICADA À PAVIMENTAÇÃO ASFÁLTICA	55
3.1	Introdução.....	55
3.2	Técnicas de inteligência artificial	56
3.2.1	Sistemas baseados em conhecimento	56
3.2.2	Redes neurais artificiais.....	56
3.2.3	Algoritmos genéticos.....	58
3.2.4	Sistemas Fuzzy.....	59
3.2.5	Modelagem baseada em agentes	60

3.2.6	Máquinas de Vetor de Suporte	61
3.3	Aplicação de técnicas de inteligência artificial em pavimentos.....	63
3.3.1	Introdução	63
3.3.2	Trabalhos relacionados	64
3.3.3	Estudos selecionados	68
3.4	Conclusões.....	87
4	INTELLIPave, UMA NOVA ABORDAGEM PARA A PAVIMENTAÇÃO ASFÁLTICA.....	89
4.1	Introdução	89
4.2	Premissas.....	89
4.3	Síntese e estrutura básica do método INTELLIPave	90
4.4	A base de dados e as variáveis	96
4.4.1	A resposta estrutural do pavimento	98
4.5	A construção do conhecimento e interpretação dos resultados.....	100
4.6	Determinação do índice relativo de dano ao pavimento (RPDI) de cada veículo.....	101
4.6.1	Cálculo dos RPDIs através da redução do número de variáveis.....	102
4.6.2	Cálculo dos RPDIs através do aumento do número de equações.....	104
4.6.3	Aplicação de restrições para identificar um bom modelo	106
4.7	Critério externo para determinar o fim da vida de serviço do pavimento	108
4.8	Contemplando variáveis desconhecidas	114
4.9	Contemplando o envelhecimento dos materiais e a não-linearidade do comportamento dos pavimentos ao longo do tempo	119
4.10	Acumulação e reutilização do conhecimento utilizando modelos paralelos.....	122
4.11	Utilizando modelos paralelos especialistas para efetuar previsões sem utilizar os dados sobre a resposta estrutural do pavimento	125
4.12	Emprego e utilização dos modelos para dimensionamento de pavimentos novos e avaliação de pavimentos existentes	127
4.13	Tratamento de erro para aperfeiçoar a acurácia do CUIA Model.....	130
4.13.1	O erro é dividido por ele mesmo	130
4.13.2	O erro remanescente é diluído	131

4.13.3	Em pavimentos asfálticos não existem modelos perfeitos.....	132
4.14	Avaliação da qualidade da informação	132
4.15	Comparação do método INTELLIPave com os métodos empírico-mecanísticos	133
5	EXEMPLO NUMÉRICO.....	134
5.1	Aplicação do CUIA Model.....	148
5.1.1	Cálculo das durabilidades anuais para as espessuras das matrizes de performance.....	148
5.1.2	Cálculo da durabilidade da estrutura C utilizando redes neurais	149
5.2	Discussão.....	150
5.2.1	Mecanismo de acúmulo do conhecimento, consideração do sub-leito e de diferentes materiais	150
5.2.2	Utilizando o princípio do CUIA Model para incluir outras informações	153
6	CONCLUSÕES E DESENVOLVIMENTOS FUTUROS.....	154
6.1	Conclusões.....	154
6.2	Sugestões para desenvolvimentos futuros	155
7	BIBLIOGRAFIA	156
8	Anexo A	164

Índice de Figuras

Figura 1-1 – Antes da construção das estradas os deslocamentos dependiam de guias que conhecessem o caminho	22
Figura 1-2 – Ponte construída pelos Romanos	23
Figura 1-3 – Dificuldade de trânsito em estrada não pavimentada (1920)	24
Figura 1-4 – Pista experimental da AASHO (1960).....	24
Figura 1-5 – Veículos de carga utilizados na pista experimental da AASHO	25
Figura 1-6 - Modelagem do pavimento utilizando sistema de equações	28
Figura 1-7 – Quanto mais parâmetros forem adicionados, maior será a diferença entre o número de variáveis e o número de equações.....	29
Figura 2-1 – Estrutura típica dos pavimentos	31
Figura 2-2 - Construção de pavimento rígido sobre pavimento asfáltico degradado (“ <i>whitertopping</i> ”)	32
Figura 2-3 – Construção de camada de concreto asfáltico	32
Figura 2-4 – Pavimento rígido em construção	33
Figura 2-5 - Pavimento em ladrilhos sextavados	34
Figura 2-6 – Seção típica de uma estrada dos antigos romanos com pavimento e drenagem lateral	34
Figura 2-7 – A Via Áppia em Roma é a estrada pavimentada mais antiga do mundo	35
Figura 2-8 – Trincas em pavimentos podem evoluir para buracos.....	36
Figura 2-9 – Buracos em pavimentos podem evoluir para problemas mais sérios	36
Figura 2-10 - Área trincada nas trilhas de roda.....	37
Figura 2-11 - Deformação permanente em rodovia	38
Figura 2-12 - Deformação permanente em rodovia	38
Figura 2-13 - Deformação permanente devido ao esmagamento da camada de concreto asfáltico	38
Figura 2-14 - Deformação permanente que se propaga desde as camadas inferiores	39

Figura 2-15 – Equação do método da AASHTO revisão 1993	41
Figura 2-16 – Dimensionamento do pavimento pelo método da AASHTO 1993	41
Figura 2-17 – Ábaco para o cálculo manual da equação da AASHTO	42
Figura 2-18 – Ábaco para cálculo do ESAL (DNER, 1979)	43
Figura 2-19 – Dimensionamento do pavimento utilizando o ábaco do método USACE (DNER, 1979)	44
Figura 2-20 - Coeficientes estruturais utilizados no método USACE (DNER, 1979)	44
Figura 2-21 – Tabela de espessuras de camadas asfálticas de acordo com o “N” (DNER, 1979)	45
Figura 2-22– Equação empírico-mecanística de fadiga para o dimensionamento de pavimentos	45
Figura 2-23 – Máquina de ensaio de fadiga para corpos de prova de concreto asfáltico cilíndricos utilizada na Universidade Federal do Rio de Janeiro (Salini, 2000)	46
Figura 2-24 – Máquina para ensaio de vida de fadiga para concretos asfálticos utilizando corpos de prova em formato de viga	46
Figura 2-25 – Equação de vida de fadiga de concreto asfáltico determinada em laboratório (Salini, 2000).....	47
Figura 2-26 – Simulador de tráfego circular da <i>Canterbury Accelerated Pavement Testing Indoor Facility</i> (Nova Zelândia)	48
Figura 2-27 - Simulador de tráfego móvel e linear desenvolvido pela Simular (Brasil) (Cifali, 2010)	48
Figura 2-28 – Estrutura do pavimento com as várias camadas	49
Figura 2-29 – Deformações específicas horizontais na face inferior da camada de concreto asfáltico	49
Figura 2-30 – Deformações específicas no plano vertical.....	50
Figura 2-31 – Aplicação prática da equação-modelo de fadiga por método empírico-mecanístico utilizando a equação apresentada na Figura 2-25.....	50
Figura 2-32 – Análise estrutural utilizando elementos finitos - tensões verticais	51
Figura 2-33 - Fluxograma do dimensionamento através do método da AASHTO 2002	52
Figura 2-34 – Somatório dos danos acumulados no método da AASHTO 2002	52
Figura 2-35 - Uma das dezenas de telas de calibração do software do método da AASHTO 2002 (AASHTO, 2004).....	53

Figura 2-36 - Valores críticos no método da AASHTO 2002 (AASHTO, 2004)	53
Figura 2-37 - Concepção típica de um pavimento asfáltico “perpétuo”	54
Figura 3-1 – Típica representação das redes neurais.....	57
Figura 3-2 - Típica representação de <i>clustering</i> com o agrupamento dos dados similares por redes neurais.....	58
Figura 3-3 – Exemplo de reprodução entre indivíduos.....	59
Figura 3-4 – Exemplo de recombinação (cross-over).....	59
Figura 3-5 - Representação simbólica com sistemas Fuzzy para volume de tráfego.....	60
Figura 3-6 – Interação dos agentes	61
Figura 3-7 – Fronteira de decisão (qual é a melhor, A ou B?).....	62
Figura 3-8 - Hiperplano ótimo para separação das classes.....	63
Figura 3-9 – SVM de margem não-linear	63
Figura 3-10 - Veículo equipado com câmeras para a coleta de imagens ortogonais de pavimentos.....	66
Figura 3-11 - Imagem ortogonal do pavimento com trincas identificadas	66
Figura 3-12 – Variáveis mais importantes para a perda de agregado (Miradi, 2009)	71
Figura 3-13 – Dados de SFC medidos em campo comparados com os preditos pelas redes neurais (Bosurgi et al., 2007)	72
Figura 3-14 - Número de acidentes ocorridos na rodovia A-18 comparados com número de acidentes preditos pelas ANN com dados de teste (Bosurgi & Trifirò, 2005).....	73
Figura 3-15 – Área trincada observada versus predita pelo HDM-4 versus predita pelas redes neurais artificiais (Thube et al., 2006).....	76
Figura 3-16 – Tela principal do ANN-Pro.....	77
Figura 3-17 – A Viga Benkelman é utilizada para medir as deformações do pavimento quando é aplicada uma carga conhecida (caminhão).....	77
Figura 3-18 - Falling Weight Deflectometer (FWD).....	78
Figura 3-19 – Operação do Falling Weight Deflectometer com mensuração das deformações	78
Figura 3-20 – Retroanálise da camada de concreto asfáltico (AC) (Gopalakrishna et al., 2007) 79	79
Figura 3-21 – Predição do parâmetro n_b da camada de base (Gopalakrishna et al., 2007).....	79
Figura 3-22 - Predição do parâmetro n_b da camada de sub-base (Gopalakrishna et al., 2007) .	80

Figura 3-23 - Correlação entre o CBR predito utilizando ANN e GEP e o CBR determinado experimentalmente em laboratório (Taskiran, 2010).....	81
Figura 3-24 – Análise de sensibilidade dos valores de CBR (Taskiran, 2010).....	81
Figura 3-25 - IRIs predito pelas ANN <i>versus</i> IRIs reais medidos nos pavimentos	84
Figura 3-26 - Equipamento para medir a profundidade da trilha de roda (<i>rutting</i>)	84
Figura 3-27 - Software Wisecrux para identificação e cálculo da área trincada dos pavimentos	85
Figura 4-1 - Símbolo do CUIA Model	91
Figura 4-2 – Diagrama geral de funcionamento do método INTELLIPave	92
Figura 4-3 - Exemplo esquemático de modelo baseado na matriz de performance e onde o critério de falha é 20% da área trincada	94
Figura 4-4 - Modelagem ou dimensionamento efetuado com base no modelo da Figura 4-3 onde verifica-se que o pavimento vai atingir o critério de falha antes de completar oito anos de serviço	95
Figura 4-5 – Variáveis climáticas desejáveis para a construção de um modelo de desempenho	96
Figura 4-6 – Variáveis que descrevem os veículos utilizando o peso por eixo	97
Figura 4-7 – Variáveis que descrevem os veículos utilizando a classificação do veículo e carga total	97
Figura 4-8 - Classes de veículos conforme recomendado pela FHWA (Federal Highway Administration, 2001)	97
Figura 4-9 – As variáveis relacionadas com a resposta estrutural do pavimento são de difícil determinação devido às limitações tecnológicas dos sensores para pavimentos.....	98
Figura 4-10 - Eixos com diferentes cargas que circulam em um determinado pavimento podem ser considerados equivalentes a um único eixo transitando em pavimentos com diferentes espessuras quanto ao dano produzido no concreto asfáltico	99
Figura 4-11 – Exemplo clássico de agrupamento (clustering) de pixels de cores iguais ou similares utilizando redes neurais tipo Kohonen (Self-Organizing Maps, SOM).....	102
Figura 4-12 – Base de dados com o histórico do pavimento para a construção de modelos com diferentes critérios de falha	110
Figura 4-13 – Base de dados com o histórico do pavimento para construir um modelo tendo como critério de falha a profundidade da trilha de roda em 10 mm	111

Figura 4-14 – Base de dados com o histórico do pavimento para construir um modelo tendo como critério de falha a área trincada em 10%	112
Figura 4-15 – Base de dados com o histórico do pavimento para construir um modelo tendo como critério de falha a área trincada em 20%	113
Figura 4-16 – Base de dados com o histórico do pavimento – (representação simbólica de) todas as variáveis conhecidas	116
Figura 4-17 - Eliminar parte das variáveis não modifica a posição onde o pavimento deixa de atender ao critério de falha	117
Figura 4-18 - Com a consideração de todas as variáveis conhecidas e desconhecidas o fim da vida de serviço do pavimento permanece na mesma posição	118
Figura 4-19- Sub-divisão adequada do modelo em sub-modelos com base anual	121
Figura 4-20 – Predição utilizando NN onde três modelos individuais são empregados no treinamento do CUIA Model	123
Figura 4-21 - Predição utilizando ANN onde seis modelos individuais são empregados no treinamento do CUIA Model	124
Figura 4-22 - Utilização de modelos paralelos sem dados sobre a resposta estrutural	127
Figura 4-23 - As variáveis utilizadas para descrever o pavimento em análise devem ser obrigatoriamente as mesmas utilizadas na construção do modelo	129
Figura 4-24 – Índice de dano ao pavimento multiplicado por um erro desconhecido	131
Figura 4-25 – O erro existente é dividido por ele mesmo e, então, eliminado	131
Figura 4-26 - Representação simbólica da diluição do erro remanescente.....	132
Figura 5-1 - A mudança nas unidades do tráfego e tempo não altera a modelagem.....	135
Figura 5-2 – Esquema de cálculo e avaliação para determinar a durabilidade da estrutura C.	138
Figura 5-3 – Inserção de generalização para outras características na metodologia INTELLIPave	153

Índice de Tabelas

Tabela 2-1 – Tabela de espessuras do método da AASHTO 1993.....	41
Tabela 3-1 - Resultados obtidos com redes neurais empregando histograma (Bray et al., 2006)	67
Tabela 3-2 – Estudos avaliados por Miradi (Miradi, 2009) (Parte A)	68
Tabela 3-3 – Estudos avaliados por Miradi (Miradi, 2009) (Parte B)	69
Tabela 3-4 – As cinco variáveis mais importantes para o trincamento do pavimento aos 11 anos após a construção (Miradi, 2009)	71
Tabela 3-5 - Alocação ótima das intervenções e melhorias no coeficiente de atrito pneu-pavimento (SFC) (Bosurgi & Trifirò, 2005)	74
Tabela 3-6 – Variáveis utilizadas nos modelos (Thube et al., 2006)	75
Tabela 3-7 – Modelos utilizados para a predição do CBR (Taskiran, 2010)	81
Tabela 3-8 – Acurácia do Modelo Neuro-Fuzzy comparada com um modelo multi-linear tradicional (Bianchini & Bandini, 2010).....	83
Tabela 3-9 - Algoritmos de <i>backpropagation</i> utilizados no treinamento das redes neurais (Tapkin et al., 2010).....	86
Tabela 3-10 – Resultados do ensaio Marshall para concretos asfálticos contendo 3% de polipropileno (Tapkin et al., 2010)	86
Tabela 4-1 – Interpretação do resultado da modelagem utilizando a metodologia INTELLIPave	93
Tabela 4-2 – Base de dados e RPDl antes do agrupamento contendo 20 equações e 27 variáveis	103
Tabela 4-3 – Base de dados e RPDl após o agrupamento (clustering) contendo 20 equações e as variáveis sendo reduzidas para 11	103
Tabela 4-4 – Base de dados e RPDl após o agrupamento aos pares.....	104
Tabela 4-5 – Escolha arbitrária do somatório dos RPDIs para a extração de equações adicionais que permitirão o cálculo dos RPDIs individuais	105
Tabela 4-6 – Número de equações e variáveis antes e depois da escolha de um valor arbitrário para o somatório dos RPDIs	106

Tabela 4-7 – Relação entre diversas variáveis com o RPDl quando o critério de falha é a área trincada	107
Tabela 4-8 - Exemplos de equações de restrições	108
Tabela 4-9 – Sub-divisão inadequada do modelo em sub-modelos diários	120
Tabela 4-10 - Comparação entre a metodologia INTELLIPave e o método empírico-mecânico	133
Tabela 5-1 – Quantidade de veículos por estrutura	135
Tabela 5-2 - Convenção de cores para identificar os <i>inputs</i> e <i>outputs</i> utilizado nas redes neurais	137
Tabela 5-3 - Estrutura A – Dados do clima e tráfego até atingir o critério de falha	139
Tabela 5-4 - Estrutura B – Dados do clima e tráfego até atingir o critério de falha.....	140
Tabela 5-5 - Estrutura C – Dados do clima e tráfego para determinação dos RPDIs	141
Tabela 5-6 - Estrutura A - Matriz de Performance	142
Tabela 5-7 - Estrutura B - Matriz de Performance	143
Tabela 5-8 - Determinação dos RPDIs para a Estrutura C com base na matriz de performance A para o ano 1 utilizando redes neurais	144
Tabela 5-9 - Determinação dos RPDIs para a Estrutura C com base na matriz de performance A para o ano 2	145
Tabela 5-10 - Determinação dos RPDIs para a Estrutura C com base na matriz de performance B para o ano 1	146
Tabela 5-11 - Determinação dos RPDIs para a Estrutura C com base na matriz de performance B para o ano 2	147
Tabela 5-12 - Cálculo da durabilidade no ano 1 utilizando o tráfego e o clima da estrutura C e as espessuras das estruturas A e B	148
Tabela 5-13 - Cálculo da durabilidade no ano 2 utilizando o tráfego e o clima da estrutura C e as espessuras das estruturas A e B	149
Tabela 5-14 - Cálculo da durabilidade no ano 1 utilizando as espessuras de camadas, o tráfego e o clima da estrutura C	149
Tabela 5-15 - Cálculo da durabilidade no ano 2 utilizando as espessuras de camadas, o tráfego e o clima da estrutura C	149
Tabela 5-16 - Cálculo da durabilidade total final para a estrutura C	150

Tabela 5-17 – CUIA Model - Cálculo da durabilidade da estrutura “L” utilizando as espessuras de camadas e o módulo do sub-leito e empregando redes neurais como máquina de cálculo	151
Tabela 5-18 – CUIA Model - Cálculo da durabilidade utilizando as espessuras das camadas e características do sub-leito e materiais empregando redes neurais	152

Índice de Equações

Equação 3-1 - Equação para estimar o módulo dinâmico do concreto asfáltico conforme o método da AASHTO 2002 (Zeghal, 2008).....	82
Equação 3-2 – Correlação dos defeitos do pavimento com o IRI	85
Equação 4-1 – O RPDI é sempre utilizado em conjunto com o somatório dos RPDIs	101
Equação 4-2 – Somatório dos RPDI igual a 20000	105
Equação 4-3 – Somatório dos RPDI igual a 10000	106
Equação 4-4 – Somatório dos RPDI igual a 5000.....	106
Equação 4-5 – Somatório dos RPDI igual a 15000 ocorre quando $\frac{3}{4}$ da vida útil total do pavimento (arbitrada em 20000) é consumida.....	106
Equação 5-1 – Estrutura A, ano 1 - Somatório dos RPDI igual a 8000	136
Equação 5-2 – Estrutura A, ano 2 - Somatório dos RPDI igual a 12000	136
Equação 5-3 – Estrutura B, ano 1 - Somatório dos RPDI igual a 7000	136
Equação 5-4 – Estrutura B, ano 2 - Somatório dos RPDI igual a 13000	136
Equação 5-5 – Cálculo da durabilidade do pavimento através da relação entre os somatórios dos RPDIs.....	148

Índice de abreviaturas, acrônimos e definições

AASHO	<i>American Association of State Highway Officials</i> Depois denominada <i>AASHTO</i>
AASHTO	<i>American Association of State Highway and Transportation Officials</i>
ABM	<i>Agent-based modeling</i> Modelagem baseada em agentes
AC	<i>Asphalt Concret</i>
ADOT	<i>Arizona Department of Transportation</i> Departamento de Transportes do Estado do Arizona
AFC	<i>Aside Failure Creteria</i> Critério de falha externo
AI	<i>Artificial Intelligence</i> Inteligência artificial
ANN	<i>Artificial Neural Networks</i> Redes neurais artificiais
ART	<i>Adaptive Resonance Theory</i>
CBR	<i>California Bearing Ratio</i> Índice de suporte Califórnia
CUIA Model	Combinação de Modelos Unitários baseada em Inteligência Artificial <i>Combination of Unity Models based on Artificial Intelligence</i>
DNN	<i>DENSITY-based neural network</i>
E	<i>Modulus</i> Módulo estrutural do material
ESAL	<i>Equivalent single axle loads</i> Eixo padrão equivalente
FHWA	<i>Federal Highway Administration</i>
FS	<i>Fuzzy Systems</i> Sistemas Fuzzy

FWD	<i>Falling Weight Deflectometer</i>
GA	<i>Genetic algorithms</i> Algoritmos genéticos
GEP	<i>Gene Expression Programming</i>
HDM-4	<i>Highway Development and Management Model revision 4</i> Software desenvolvido pelo Banco Mundial para rodovias
HWD	<i>Heavy Weight Deflectometer</i> Versão pesada do FWD
INTELLIPave	Metodologia para pavimentos baseada em inteligência artificial que introduz o CUIA Model e outras inovações
IRI	<i>International Roughness Index</i>
K	Coefficiente estrutural
KBS	<i>Knowledge-Based Systems</i> Sistemas baseados em conhecimento
Kohonen	Tipo de rede neural treinada sem supervisão
LM	<i>Levenberg–Marquardt</i>
LMS	<i>Least Mean Square</i>
LTPP	<i>Long Term Pavement Performance</i>
MADT	<i>Monthly average daily traffic</i> Média diária de veículos calculada em base mensal
N	Mesmo que ESAL (em dimensionamentos de pavimentos); ou, Número de ciclos (em ensaios de fadiga de laboratório)
NANN	<i>Nested adaptive neural network</i>
NCHRP	<i>National Cooperative Highway Research Program</i>
NN	<i>Neural Networks</i> Redes neurais
PMC	<i>Perceptron de múltipla camada</i>

PSI	<i>Present Serviceability Index</i> Índice presente de serventia utilizado no método de dimensionamento de pavimentos da AASHTO
RPDI	<i>Relative Pavement Damage Index</i>
SAMDM	<i>South African Mechanistic Design Method</i>
SF	<i>Shift-factor</i> Fator de ajuste campo-laboratório para equações de fadiga
SFC	<i>Sideway Force Coefficient</i> Coeficiente de atrito pneu-pavimento
SHRP	<i>Strategic Highway Research Program</i>
SHRP-NL	<i>The Strategic Highway Research Program in the Netherlands</i>
SN	<i>Structural Number</i> Número estrutural utilizado no método da AASHTO
SVM	<i>Support Vector Machines</i> Máquinas de vetor de suporte
SOM	<i>Self-Organizing Maps</i>
USACE	<i>U.S. Army Corps of Engineers</i>
W_{18}	O mesmo que ESAL
WIM	<i>Weight-in-motion</i> Equipamento automático que efetua a contagem, classificação, pesagem por eixo e determina a velocidade para cada veículo que transita na rodovia
ϵ_t	<i>Strain</i> Deformação específica de tração, ou extensão de tração

capítulo 1

1 INTRODUÇÃO

A necessidade do ser humano de viajar é tão antiga quanto a própria humanidade. Os deslocamentos eram difíceis, atravessando florestas e regiões inóspitas de forma precária e dependendo, sempre, de pessoas capazes de se orientar durante o percurso (os “guias”) para chegar ao destino desejado. Essa realidade ainda existe nas travessias do deserto do Sahara (Figura 1-1).



Figura 1-1 – Antes da construção das estradas os deslocamentos dependiam de guias que conhecessem o caminho

Diante de tal precariedade, o antigo Império Romano proporcionou uma das mais importantes contribuições para o desenvolvimento da humanidade: a construção de estradas pavimentadas. Planejadas para atravessarem as localidades e cursos de água, as estradas passaram a proporcionar pontos para descanso, aquisição de alimentos e água enquanto guiavam os viajantes ao destino desejado sem a necessidade de qualquer guia ou conhecimento prévio do caminho, e com pontes e outras obras de engenharia para facilitar a travessia de locais inóspitos (Figura 1-2).



Figura 1-2 – Ponte construída pelos Romanos

As estradas pavimentadas modernas permitem que qualquer pessoa, de dia ou de noite, em praticamente qualquer condição climática, se desloque entre duas localidades de forma eficiente, segura e confortável, permitindo o desenvolvimento das mais diversas atividades humanas, como o comércio, a indústria e a medicina, apenas para citar algumas. Por outro lado, a falta de pavimento acarreta as mais diversas dificuldades (Figura 1-3).



Figura 1-3 – Dificuldade de trânsito em estrada não pavimentada (1920)

Milhares de anos após os Romanos terem introduzido as estradas pavimentadas, os métodos utilizados na modelagem e predição do comportamento dos pavimentos permanecem em um inaceitável patamar de empirismo.

O estudo moderno dos pavimentos foram iniciados por volta de 1958, com a construção da pista experimental da AASHO (Figura 1-4), posteriormente denominada AASHTO, que era um segmento de rodovia de circuito fechado onde veículos (Figura 1-5) com cargas conhecidas transitavam até a ruína do pavimento (Carey & Irick, 1960) (Carey & Irick, 1962). Tais estudos, totalmente baseados em conceitos empíricos, eram adequados à realidade da época – limitações tecnológicas, baixo custo dos materiais e mão-de-obra, e pequeno tráfego nas estradas -, mas não são compatíveis com os desafios do século XXI.




Figura 1-4 – Pista experimental da AASHO (1960)



Figura 1-5 – Veículos de carga utilizados na pista experimental da AASHO

Nas últimas cinco décadas a quase totalidade dos estudos sobre o comportamento dos pavimentos asfálticos foram baseados em estudos empíricos e testes de fadiga em laboratório, também conhecidos como métodos “empírico-mecanísticos”, que não permitiram qualquer verdadeiro progresso no entendimento e modelagem do comportamento dos pavimentos asfálticos. Os métodos empíricos e empírico-mecanísticos, por serem extremamente simplistas e limitados, não permitem nem podem ser adaptados para descrever a grande complexidade do comportamento dos materiais asfálticos. Além disso, tais métodos não proporcionam qualquer forma de acumular o conhecimento, tornando difícil a utilização da experiência obtida em uma rodovia para o aperfeiçoamento das seguintes; o conhecimento sobre a performance dos pavimentos asfálticos é inferido em observações de rodovias abertas ao tráfego e é acumulado apenas na memória dos engenheiros de forma empírica, que são capazes somente de fazer adaptações básicas para novas situações, e pode ser facilmente perdido devido ao esquecimento, aposentadoria ou falecimento.

Em muitos casos este empirismo resulta em prematuras e elevadas taxas de falhas nos pavimentos, com prejuízos de bilhões de euros com custos prematuros de manutenção, enquanto em outros resulta em super-dimensionamento, com desperdício de fundos financeiros que acabam fazendo falta para custear outras obras e serviços de que a sociedade também necessita. Em ambos os casos, a relação custo-benefício dos recursos financeiros investidos é ruim.

Segundo Zimmerman (Zimmerman et al., 2000) a área de pavimentação “*está perdendo, ou já perdeu, a atenção dos gestores de topo*”, especulando que tais gestores parecem não

entender a importância da correta manutenção dos pavimentos e sua gestão. Zimmerman parece ter identificado corretamente o problema, mas a causa pode não ser a ignorância dos gestores, mas a limitação da engenharia de pavimentos e seu paradigma empírico. Ano após ano, os engenheiros de pavimentos apresentam as mesmas respostas, com pouca ou nenhuma evolução, para as necessidades e desafios crescentes que a área de rodovias impõe. Os gestores de topo identificaram corretamente esta fraqueza e eles provavelmente estão certos ao cortar custos em uma área que, na visão deles, parece não ter nada melhor para oferecer. Ao ser observada a evolução, ou falta de, nos métodos de pavimentação, é observada uma filosofia rígida. Segundo Salini, o principal problema na área de engenharia de pavimentos pode não ser técnico, mas cultural, onde os profissionais adotam os mesmos procedimentos, mas esperam, de alguma forma, obter resultados melhores, muito bem caracterizado na procura, que já se estende por cinco décadas, da correlação “perfeita” entre a vida de serviço dos pavimentos asfálticos e as deformações específicas (extensões) de tração do concreto asfáltico. (Salini et al., 2009)

Isso não significa que os atuais métodos empírico-mecanísticos para pavimentos sejam totalmente inúteis. Eles podem ser úteis se forem consideradas as limitações dos mesmos. Por exemplo, os estudos de vida de fadiga efetuados em laboratório, utilizando a deformação específica (extensões) como variável, pode ter vários usos, como a identificação do concreto asfáltico com melhor performance dentro de um conjunto de vários concretos asfálticos, mas não parecem adequados para prever ou mensurar a vida de serviço do concreto asfáltico em campo, em uma rodovia real, onde existe em grande conjunto de variáveis que não podem ser simuladas em laboratório, como as variações de temperatura, radiação solar, chuva, veículos com diferentes cargas e velocidades, e tipos de pneus, só para citar algumas (Salini et al., 2009).

Inegavelmente, a maioria dos engenheiros, profissionais e pesquisadores dos pavimentos asfálticos não possuem a menor idéia sobre como pode ser construído um mecanismo para armazenar e reutilizar a experiência com os pavimentos como forma de melhorar as previsões de comportamento em novas rodovias. Trabalhando com uma filosofia empírica esta tarefa é realmente muito difícil, ou mesmo impossível.

Os novos desafios do século XXI, com a crescente quantidade de veículos nas estradas, aumento da capacidade de carga dos caminhões, altos custos dos materiais utilizados nos pavimentos, elevados custos da mão-de-obra e as crescentes restrições ambientais à extração e uso de jazidas de materiais, como a extração de pedras para britagem, impõe a melhoria na qualidade das previsões da vida de serviço e modelagem dos pavimentos asfálticos (Flintsch, 2003).

Devido ao comportamento ultra-complexo dos pavimentos asfálticos, não é possível obter a desejada elevada qualidade nos modelos com o emprego de abordagens empíricas ou empírico-mecanísticas. Para isso são necessárias ferramentas robustas capazes de manusear todas as variáveis relevantes e suas praticamente infinitas combinações (Yang et al., 2003)(Bosurgi & Trifirò, 2005).

Técnicas avançadas de inteligência evolutiva, incluindo lógica multivariada, computação evolutiva e redes neurais, entre outras, tem sido utilizadas com grande sucesso para modelar

problemas complexos, dispersos ou de comportamento incerto, permitindo ultrapassar muitas das limitações das abordagens tradicionais no manuseio de grandes volumes de dados. Conforme Salini (Salini et al., 2008), ferramentas de *soft computing* podem proporcionar todos os recursos necessários para a modelagem dos pavimentos de uma forma científica, evitando a subjetividade, limitações e problemas dos métodos empíricos e empírico-mecanísticos, já que todas as variáveis podem ser contempladas sem concessões ou simplificações, criando um novo paradigma para a modelagem dos pavimentos asfálticos, em linha com os desafios técnico-econômicos do século XXI.

1.1 Contexto e motivação

Nas últimas décadas as estradas e ruas pavimentadas se tornaram parte do cotidiano das populações em todo o mundo. Vias precárias, cheias de buracos, enlameadas e intrafegáveis em dias de chuva, e fonte de intermináveis nuvens de pó em dias secos, foram substituídas por auto-estradas modernas e confortáveis, que permitem o trânsito em praticamente qualquer condição climática, reduziram os tempos de viagem de forma dramática e permitiram o início de um novo ciclo de desenvolvimento humano e econômico. As vias pavimentadas se tornaram, verdadeiramente, as artérias vitais da sociedade moderna.

O incremento contínuo (e talvez descontrolado) na quantidade de veículos em circulação, e aumentos sucessivos da velocidade e capacidade de carga dos mesmos, exige a ampliação e melhoria contínua da malha rodoviária, que há muito atingiu uma grande complexidade. Ao mesmo tempo em que os pavimentos precisam ser mais robustos e duráveis, os materiais construtivos aumentam de preço e, no caso dos ligantes asfálticos, os elevados preços do petróleo faz com que as refinarias aperfeiçoem seus processos de extração de elementos nobres, tais como gasolinas e naftas, tornando o sub-produto do petróleo denominado “asfalto” um material com qualidade decrescente, apesar do preço crescente, e ao qual seguidamente são acrescidos rejeitos que as refinarias não conseguem colocar no mercado e, por questões ambientais, não podem ser descartados, como é o caso da parafina. Do outro lado está a engenharia de pavimentos, que nas últimas décadas não produziu qualquer inovação real nos seus métodos e os poucos novos materiais desenvolvidos, tais como os ligantes asfálticos modificados com polímeros, permanecem com preços proibitivos para uso em larga escala.


A manutenção dos pavimentos em condições excelentes poderia ser facilmente obtida mediante a reabilitação de todas as rodovias em curtos intervalos como, por exemplo, a cada dois anos. Esta prática resolveria e relegaria a segundo plano os problemas relacionados com os métodos de pavimentos. Simples na teoria, mas impossível na prática, pois nenhum país é suficientemente rico para manter todas as rodovias com os pavimentos em condição excelente de forma continuada. Os recursos públicos de todas as demais áreas seriam totalmente drenados e ainda assim, insuficientes. Cabe citar que o pavimento asfáltico representa, em média, 60% dos custos de uma rodovia nova e seguidamente mais de 90% dos custos para reabilitar uma rodovia existente.

Assim, a motivação deste trabalho baseia-se na necessidade de desenvolvimento de novas metodologias que permitam aperfeiçoar a alocação dos sempre limitados recursos financeiros de tal forma a manter a malha rodoviária na melhor condição técnica possível; para isso, a predição cada vez mais acurada da performance dos pavimentos asfálticos tem uma função vital.

1.2 Objetivos

A abordagem mais lógica para a modelagem de forma científica do comportamento dos pavimentos asfálticos é o emprego de metodologias já consagradas em outras áreas, como os métodos baseados em sistemas de equações empregados nos projetos de estruturas de concreto armado. Assim, cada veículo (ou eixo) em circulação na rodovia seria transladado para compor uma linha de um sistema de equações, como exemplificado na Figura 1-6, onde cada veículo produz uma variável relativa ao dano ao pavimento (D1, D2 e D3), que precisa ser determinada, e cada parâmetro incluído no modelo (velocidade, carga, temperatura, etc.) também possui um coeficiente que precisa ser determinado (a1... a3 até e1...e3). Desta forma, o número de variáveis existentes na matriz sempre será igual ao número de equações acrescido do número de parâmetros, ou seja, mais variáveis do que equações, o que torna o sistema impossível de ser resolvido. Quanto mais parâmetros forem incluídos, maior será a diferença entre o número de equações e o número de variáveis, tornando a solução cada vez “mais” impossível (Figura 1-7). Na hipotética possibilidade de que fosse possível identificar e mensurar absolutamente todos os parâmetros com influência na vida de serviço dos pavimentos, a diferença entre o número de equações e variáveis seria a máxima, com a matriz de equações na máxima distância de uma solução.

Nº do veículo	Velocidade (km/h)	Carga eixo 1 (t)	Carga eixo 2 (t)	Temperatura do ar (°C)	Pluviosidade (mm)	...		Dano ao pavimento
1	80	2	3	25	0	...	=	D1
2	90	9	12	24	5	...	=	D2
3	88	3	5	28	17	...	=	D3



$$\begin{array}{rcl}
 80_{a1} & + & 2_{b1} & + & 3_{c1} & + & 25_{d1} & + & 0_{e1} & + & \dots & = & D1 \\
 90_{a2} & + & 9_{b2} & + & 12_{c2} & + & 24_{d2} & + & 5_{e2} & + & \dots & = & D2 \\
 88_{a3} & + & 3_{b3} & + & 5_{c3} & + & 28_{d3} & + & 17_{e3} & + & \dots & = & D3
 \end{array}$$

Figura 1-6 - Modelagem do pavimento utilizando sistema de equações

$$\begin{aligned}
 80_{a1} + 2_{b1} + 3_{c1} + 25_{d1} + 0_{e1} + 27_{f1} + 5_{g1} + \dots &= D1 \\
 90_{a2} + 9_{b2} + 12_{c2} + 24_{d2} + 5_{e2} + 22_{f2} + 4_{g2} + \dots &= D2 \\
 88_{a3} + 3_{b3} + 5_{c3} + 28_{d3} + 17_{e3} + 18_{f3} + 8_{g3} + \dots &= D3
 \end{aligned}$$

Figura 1-7 – Quanto mais parâmetros forem adicionados, maior será a diferença entre o número de variáveis e o número de equações

Se for analisada esta mesma situação sob outra perspectiva, quanto mais parâmetros e dados de variáveis estiverem disponíveis sobre o comportamento dos pavimentos, mais próximos devemos ficar de uma solução. E quando absolutamente todos os parâmetros estiverem disponíveis, necessariamente deve existir uma solução. (O que mais poderia ser necessário para solucionar o problema se “tudo” já está disponível?). É aqui que a matemática tradicional, ou *hard computing*, mostra suas limitações e as ferramentas de *soft computing* podem fazer diferença.

Adicionalmente ao problema matemático, não existem procedimentos metodológicos estabelecidos ou sequer rascunhados para as etapas sucessivas, ou seja, sobre como utilizar os resultados da resolução do sistema de equações para o dimensionamento de novos pavimentos ou avaliação de pavimentos existentes.

O objetivo desta pesquisa é, portanto, combinar o melhor da matemática tradicional e das técnicas de inteligência artificial para desenvolver uma metodologia nova, original e 100% inédita, que permita estabelecer um novo e mais elevado paradigma para a predição do comportamento dos pavimentos asfálticos, buscando superar definitivamente as limitações do paradigma empírico-mecânico atualmente em utilização.

Esta nova metodologia foi batizada de **INTELLIPave** e o modelo final gerado é denominado **CUIA** (CUIA Model).

1.3 Estrutura desta tese

Este trabalho é multidisciplinar, englobando conhecimentos de ciências da computação e engenharia de pavimentos, que são áreas extremamente distintas. Especialistas de uma área possuem pouco ou nenhum conhecimentos sobre a outra. Para facilitar a compreensão, neste trabalho buscou-se utilizar uma terminologia acessível para profissionais e pesquisadores da área de ciências da computação, quando o assunto abordado é referente a pavimentos ou estradas; e terminologia acessível para profissionais da área rodoviária, quando o assunto se refere a técnicas computacionais, empregando, sempre que possível, ilustrações e outros recursos visuais que facilitem o entendimento.

Este documento está estruturado em sete capítulos e um anexo. No **capítulo 1** deste trabalho é apresentada uma introdução ao assunto e os objetivos deste trabalho. No **capítulo 2** são apresentados e discutidos os principais métodos atualmente em utilização para o dimensionamento, modelagem e predição de comportamento de pavimentos asfálticos. No **capítulo 3** são descritas algumas topologias de inteligência artificial e é efetuada uma síntese de estudos publicados a respeito da sua aplicação na área de pavimentação asfáltica.

No **capítulo 4** é **descrito, discutido e detalhado o método INTELLIPave**, desenvolvido nesta pesquisa científica, para o acúmulo do conhecimento, modelagem e predição do comportamento dos pavimentos asfálticos mediante o emprego de técnicas de inteligência artificial, enquanto no **capítulo 5** é apresentado um **exemplo hipotético**, simplificado e numérico da aplicação da metodologia INTELLIPave, que pode ser utilizado como um guia passo-a-passo para a aplicação deste método.

No **capítulo 6** são apresentadas as conclusões e sugestões para desenvolvimentos futuros. No **capítulo 7** são listadas as **bibliografias** citadas neste trabalho e; finalmente, no **Anexo A** é apresentada e discutida a consideração da **qualidade da informação** como pré-processamento para a metodologia INTELLIPave.

capítulo 2

2 MODELAGEM DE PAVIMENTOS ASFÁLTICOS

2.1 Introdução à pavimentação

Os pavimentos são geralmente compostos de uma ou mais camadas granulares (base e sub-base) e uma camada de revestimento, como apresentado na Figura 2-1. Também são empregadas diversas combinações de pavimentos, tal como o emprego de (a) camada de base rígida com revestimento asfáltico, (b) base em concreto asfáltico com camada de revestimento em pavimento rígido (“whitetopping”) (Figura 2-2), ou (c) sub-base rígida, base granular e revestimento asfáltico (“pavimento invertido”).

Basicamente, os pavimentos podem ser agrupados basicamente em 3 tipos: (a) pavimentos flexíveis ou asfálticos; (b) pavimentos rígidos ou em concreto (de cimento portland); e, (c) pavimentos em ladrilhos ou pedras. Neste capítulo, centramo-nos na pesquisa que abordada apenas a modelagem de pavimentos asfálticos, mas a metodologia pode ser adaptada para outros tipos de pavimentos.



Figura 2-1 – Estrutura típica dos pavimentos




Figura 2-2 - Construção de pavimento rígido sobre pavimento asfáltico degradado (“whitetopping”)

2.1.1 Pavimentos flexíveis ou asfálticos

São os pavimentos onde a camada de revestimento é construída com a mistura de agregados (pedra britada) e ligante betuminoso; que pode ser fabricada em processo à quente ou frio.

Neste contexto dos pavimentos asfálticos, a mistura asfáltica é composta de agregado miúdo (areia ou pedra britada) e agregado graúdo (pedra britada), além do ligante asfáltico. Existem diversas técnicas para o uso dos ligantes asfálticos, tais como revestimentos e microrrevestimentos aplicados à frio com o emprego de emulsão asfáltica (asfalto diluído em água) e os concretos betuminosos usinados a quente, sendo os últimos os mais comuns. A espessura do revestimento asfáltico pode variar desde poucos centímetros até algumas dezenas de centímetros (DNER, 1979).




Figura 2-3 – Construção de camada de concreto asfáltico

O revestimento asfáltico tem como funções proporcionar conforto aos motoristas e receber as cargas dos veículos, transferindo-as para as camadas inferiores.

A Figura 2-3 apresenta a construção da camada de concreto asfáltico usinado a quente com o emprego de vibro-acabadora.

2.1.2 Pavimentos rígidos ou em concreto de cimento portland

Os pavimentos rígidos são construídos em concreto convencional, utilizando cimento tipo Portland. Podem possuir armadura metálica ou não.

Os pavimentos rígidos são pouco utilizados devido ao elevado custo de construção e manutenção, menor conforto dos usuários em função da presença de juntas de dilatação, que causam solavancos, e dificuldades de manutenção, já que o cimento normalmente requerer 28 dias de cura antes de receber cargas (DNER, 1979).

A Figura 2-4 mostra a construção do pavimento rígido onde é possível observar as barras de aço de transferência de esforços posicionadas no local onde haverá uma junta de dilatação.

O comportamento mecânico do pavimento rígido é diferente, e muito mais simples, daquele do pavimento asfáltico, e não é objeto neste trabalho.



Figura 2-4 – Pavimento rígido em construção

2.1.3 Pavimentos em ladrilhos ou pedras.

Pavimentos com revestimentos em pedras ou ladrilhos são os mais antigos, introduzidos pelos antigos construtores romanos há mais de dois mil anos. São utilizados principalmente em ruas urbanas; geralmente são construídos com pedras recortadas ou ladrilhos regulares moldados em concreto de cimento Portland.

A Figura 2-5 apresenta um pavimento em ladrilhos sextavados pré-fabricados em concreto, enquanto Figura 2-6 apresenta uma seção típica utilizada pelos antigos romanos, que construíram incríveis 100 mil quilômetros de estradas pavimentadas na Europa e Oriente Médio.

O conceito de pavimento desenvolvido pelos romanos constitui a base dos pavimentos modernos, onde são empregadas pedras de maior diâmetro na parte inferior, seguida de camadas com pedras de diâmetros cada vez menores, e uma superfície regular de acabamento; as pedras da superfície eram eventualmente cimentadas com o emprego de cinzas vulcânicas coletadas nas proximidades do Vesúvio, que são um tipo de cimento e eram muito empregadas na antiguidade.

A Figura 2-7 apresenta um trecho da Via Áppia, a estrada pavimentada mais antiga do mundo, construída pelos antigos romanos.



Figura 2-5 - Pavimento em ladrilhos sextavados




Figura 2-6 – Seção típica de uma estrada dos antigos romanos com pavimento e drenagem lateral



Figura 2-7 – A Via Áppia em Roma é a estrada pavimentada mais antiga do mundo

Estudos a respeito do comportamento de pavimentos em ladrilhos são muito raros, e o assunto não é objeto desta pesquisa.

2.2 Defeitos dos pavimentos asfálticos

Os defeitos dos pavimentos são o resultado da degradação ocasionada pelo trânsito dos veículos e dos fatores climáticos que, aliados ao envelhecimento do ligante asfáltico, ocasionam uma miscelânea de problemas. O manual de identificação de defeitos em pavimentos SHRP-P-338 - *Distress Identification Manual for the Long-Term Pavement Performance Project*, um dos mais utilizados no mundo, apresenta mais de 60 tipos e sub-tipos de defeitos em pavimentos asfálticos (Strategic Highway Research Program, 1993), mas que podem ser resumidos em dois tipos principais: trincas e deformações permanentes (ou deformações plásticas). Os defeitos em pavimentos que não receberem manutenção podem evoluir para problemas mais sérios (Figura 2-8, Figura 2-9).



Figura 2-8 – Trincas em pavimentos podem evoluir para buracos



Figura 2-9 – Buracos em pavimentos podem evoluir para problemas mais sérios

2.2.1 Trincas

As trincas geralmente ocorrem em onde o tráfego é mais concentrado, ou seja, nas trilhas de roda. Podem apresentar vários formatos, padrões de trincamento e diferentes níveis de severidade; geralmente são trincas de fadiga do concreto asfáltico, resultado da passagem contínua e repetitiva dos veículos (Figura 2-10), mas também pode ser ocasionadas por fatores climáticos em regiões de climas extremos. Além do desconforto causado aos motoristas, as trincas permitem a infiltração de água nas camadas inferiores, acelerando a degradação do pavimento (Strategic Highway Research Program, 1993).



Figura 2-10 - Área trincada nas trilhas de roda

2.2.2 Deformações permanentes

As deformações permanentes (Figura 2-11, Figura 2-12), também chamadas de deformações plásticas ou trilha de roda (em inglês, “*rutting*”), ocorrem nas trilhas onde passam os pneus dos veículos. Podem ser o resultado do esmagamento da camada de concreto asfáltico (Figura 2-13), ou de deformações que se propagam desde as camadas inferiores ou sub-leito (Figura 2-14). As deformações permanentes são particularmente perigosas em dias de chuva, pois a água acumulada neste locais pode ocasionar a aquaplanagem do veículo (Strategic Highway Research Program, 1993).



Figura 2-11 - Deformação permanente em rodovia




Figura 2-12 - Deformação permanente em rodovia




Figura 2-13 - Deformação permanente devido ao esmagamento da camada de concreto asfáltico




Figura 2-14 - Deformação permanente que se propaga desde as camadas inferiores

2.3 Modelagem de pavimentos asfálticos

Modelar e prever o comportamento dos pavimentos asfálticos estão entre os grandes desafios enfrentados pela engenharia. O consenso entre os pesquisadores é de que os pavimentos asfálticos possuem um comportamento visco-elasto-plástico, não linear, anisotrópico e variável no tempo; um conceito muito complexo, mas aparentemente não suficiente para explicar a performance, sugerindo a existência de outras parcelas de comportamento ainda não descobertas ou mesmo a inexistência de qualquer padrão de comportamento. Além do comportamento intrínseco aos materiais que o constituem, o pavimento ainda está sujeito à interferência de fatores externos, como as características dos veículos (velocidade, carga, etc.) e do clima (temperatura, precipitação, etc.) (Salini et al., 2009).

Há meio século foi construída a pista experimental da AASHO¹, nos Estados Unidos, que foi a primeira tentativa organizada de compreender o funcionamento estrutural e estabelecer uma metodologia (empírica) para o dimensionamento e predição do comportamento dos pavimentos asfálticos, utilizando a experiência obtida durante e após a Segunda Guerra Mundial. Logo após, ainda nos anos de 1960, apareceram os primeiros estudos empírico-mecanísticos (Carey & Irick, 1960) (Carey & Irick, 1962).

Estes estudos não buscaram a inclusão de todas ou a maioria das variáveis com influência na vida de serviço do pavimento asfáltico. Em termos gerais, estes métodos são extremamente simples, com a performance representada por duas ou três variáveis (Salini et al., 2009).

2.3.1 Métodos empíricos

Existe um grande conjunto de métodos empíricos, muitos países e agências de transportes possuem seus próprios métodos. A maioria destes métodos são derivados dos estudos da pista

¹ AASHO - American Association of State Highway Officials, posteriormente denominada AASHTO

experimental de testes da AASHO², construída e operada em Ottawa, Illinois (EUA), entre 1958 e 1960 (Carey & Irick, 1960) (Carey & Irick, 1962); os principais destes métodos são o da AASHTO³ e o do USACE⁴, dos quais são derivados a maioria dos outros. Estes métodos, apesar de compartilharem diversas características, proporcionam resultados muito diferentes. Ambos utilizam o índice de suporte Califórnia (*California Bearing Ratio, CBR*) e o conceito de eixo padrão equivalente (ESAL).

O CBR é determinado em laboratório para as amostras de solos recolhidas em campo no percurso onde será construída a rodovia, sendo um parâmetro totalmente empírico para a capacidade de suporte do material; seu valor é expresso em percentual (%) e significa x% da capacidade de um material de referência, geralmente brita de curva granulométrica contínua (que visa minimizar o volume de vazios), que, portanto, possui CBR de 100%.

O ESAL (também chamado de “número N”) é calculado com base na contagem dos veículos, para rodovias existentes, ou estimativas de tráfego, para rodovias novas, onde todos os tipos de eixos, dos diversos tipos de veículos, são convertidos em quantidade equivalente de eixos-padrão de 8,2 toneladas através de considerações empíricas (DNER, 1979).

Embora compartilhem a mesma nomenclatura e o mesmo eixo de referência de 8,2 toneladas, o ESAL do método da USACE é diferente do ESAL do método da AASHTO para os mesmos tipos e quantidades de veículos, pois empregam diferentes critérios de equivalência, o que seguidamente produz equívocos, com o dimensionamento efetuado pelo método da USACE utilizando-se o ESAL calculado pelo método da AASHTO, e vice-versa.

2.3.1.1 Método da AASHTO (1972, 1986 e 1993)

Em 1961 a AASHTO (*American Association of State Highway and Transportation Officials*) publicou um método empírico, na forma de rascunho e recomendações, que foi consolidado em 1972. O método foi desenvolvido para atender as necessidades dos Departamentos Estaduais de Transportes dos Estados Unidos e visa maximizar a durabilidade do pavimento. Adota os conceitos de ESAL, com um eixo padrão de 8,2 toneladas (18000 libras), também denominado W_{18} , e o CBR.

Este método foi atualizado em 1986, quando foi aprimorada a caracterização dos materiais, e em 1993, quando as diretrizes para reabilitação dos pavimentos foram melhoradas; em ambos os casos, no entanto, sem alteração de suas premissas empíricas básicas (AASHTO, 2004).

Este método utiliza o índice presente de serventia (*Present Serviceability Index, PSI*), que é um indicador empírico e subjetivo, variando de zero (muito ruim) a cinco (muito bom), da qualidade do pavimento. O dimensionamento, ou modelagem, é efetuado com uma complexa equação (Figura 2-15) na qual são introduzidas diversas informações e é calculado o SN (*Structural Number*), que por sua vez permite dimensionar o pavimento com o uso de outra equação (Figura 2-16) e uma tabela de espessuras de camadas (Tabela 2-1).

² Depois denominada AASHTO

³ Originalmente denominada AASHO

⁴ U.S. Army Corps of Engineers

$$\log_{10}(W_{18}) = Z_R S_o + 9.36 \log_{10}(SN + 1) - 0.20$$

$$+ \frac{\log_{10} \left[\frac{\Delta PSI}{4.2 - 1.5} \right]}{0.40 + \frac{1094}{(SN + 1)^{5.19}}} + 2.32 \log_{10}(M_R) - 8.07$$

Structural Number

W_{18} = design traffic (18-kip ESALs)
 Z_R = standard normal deviate
 S_o = combined standard error of traffic and performance prediction
 ΔPSI = difference between initial and terminal serviceability index
 M_R = resilient modulus (psi)
 SN = structural number

Figura 2-15 – Equação do método da AASHTO revisão 1993

$$SN = a_1 D_1 + \sum_{i=2}^n a_i D_i m_i$$

SN = structural number = f (structural capacity)
 a_i = i^{th} layer coefficient
 D_i = i^{th} layer thickness (inches)
 m_i = i^{th} layer drainage coefficient
 n = number of layers (3, typically)

Figura 2-16 – Dimensionamento do pavimento pelo método da AASHTO 1993

Tabela 2-1 – Tabela de espessuras do método da AASHTO 1993

Minimum Thickness (inches)		
Traffic, ESAL's	Asphalt Concrete	Aggregate Base
Less than 50,000	1.0 (or surface treatment)	4
50,001–150,000	2.0	4
150,001–500,000	2.5	4
500,001–2,000,000	3.0	6
2,000,001–7,000,000	3.5	6
Greater than 7,000,000	4.0	6

Atualmente a equação (Figura 2-15) pode ser resolvida com computadores ou calculadoras eletrônicas modernas, mas anteriormente era utilizado um ábaco (Figura 2-17).




Figura 2-17 – Ábaco para o cálculo manual da equação da AASHTO

2.3.1.2 Método do USACE

O método USACE é baseado em conceitos puramente empíricos e foi desenvolvido pelo Corpo de Engenheiros do Exército dos Estados Unidos (*US Army Corps of Engineers, USACE*) a partir da experiência adquirida durante e após a Segunda Guerra Mundial, para atender as necessidades das bases militares estadunidenses espalhadas pelo mundo. Naquela época se acreditava que uma nova guerra mundial era iminente, então o método visa minimizar os custos e agilizar a construção. Assim como o método da AASHTO, também utiliza o conceito de ESAL e CBR (DNER, 1979).

O cálculo do ESAL é efetuado com um conjunto de ábacos, como aquele apresentado na Figura 2-18, onde os eixos dos veículos, com as suas diversas cargas, são “convertidos” em eixos equivalentes ao eixo padrão de 8,2 toneladas.

O dimensionamento, ou modelagem, é efetuado através de um ábaco onde, a partir do ESAL e do CBR característico da rodovia, é verificada qual a espessura em material granular-equivalente é necessária (Figura 2-19) para “proteger” aquele CBR de sub-leito. O projetista, então, “monta” as camadas que farão parte do pavimento utilizando coeficientes estruturais (Figura 2-20), a tabela de espessuras de camadas asfálticas (Figura 2-21) e, subjetivamente, o histórico de comportamento de outros pavimentos que eventualmente existam na região onde a rodovia será construída (DNER, 1979).

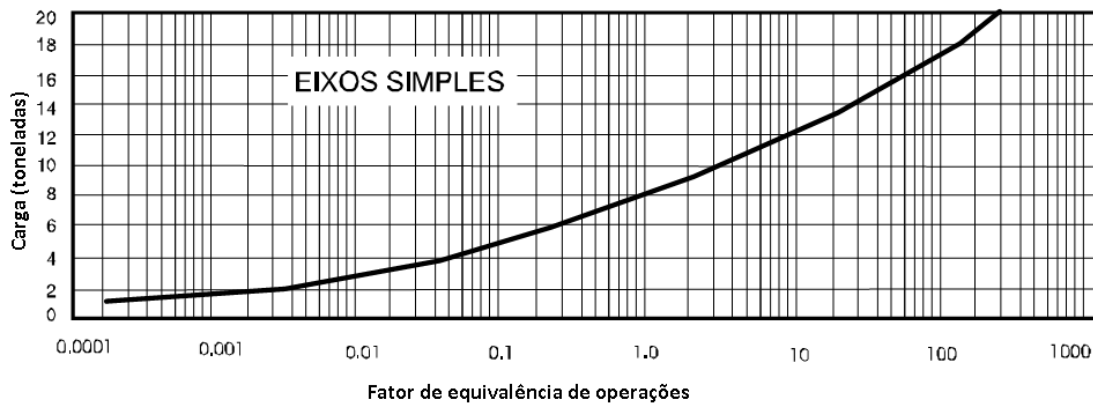


Figura 2-18 – Ábaco para cálculo do ESAL (DNER, 1979)




Figura 2-19 – Dimensionamento do pavimento utilizando o ábaco do método USACE (DNER, 1979)

Componentes do pavimento	Coefficiente K
Base ou revestimento de concreto betuminoso	2,00
Base ou revestimento pré-misturado a quente, de graduação densa	1,70
Base ou revestimento pré-misturado a frio, de graduação densa	1,40
Base ou revestimento betuminoso por penetração	1,20
Camadas granulares	1,00
Solo cimento com resistência à compressão a 7 dias, superior a 45 kg/cm ²	1,70
Idem, com resistência à compressão a 7 dias, entre 45 kg/cm ² e 28 kg/cm ²	1,40
Idem, com resistência à compressão a 7 dias, entre 28 kg/cm ² e 21 kg/cm ²	1,20

Figura 2-20 - Coeficientes estruturais utilizados no método USACE (DNER, 1979)

N	Espessura Mínima de Revestimento Betuminoso
$N \leq 10^6$	Tratamentos superficiais betuminosos
$10^6 < N \leq 5 \times 10^6$	Revestimentos betuminosos com 5,0 cm de espessura
$5 \times 10^6 < N \leq 10^7$	Concreto betuminoso com 7,5 cm de espessura
$10^7 < N \leq 5 \times 10^7$	Concreto betuminoso com 10,0 cm de espessura
$N > 5 \times 10^7$	Concreto betuminoso com 12,5 cm de espessura

Figura 2-21 – Tabela de espessuras de camadas asfálticas de acordo com o “N”⁵ (DNER, 1979)

2.3.2 Métodos Empírico-mecanísticos

Os métodos empírico-mecanísticos foram desenvolvidos a partir dos anos de 1960 e são os mais utilizados mundialmente, especialmente na Europa; adotam o conceito de eixo padrão (ESAL) presente nos métodos empíricos e a deformação específica de tração (ϵ_t), sendo que alguns pesquisadores também incluem na equação o módulo (E), conforme mostrado na Figura 2-22.

Neste método são moldados corpos de prova, geralmente com formato cilíndrico, de viga ou trapezoidal, que são ensaiados em laboratório para a determinação da equação da vida de fadiga (Figura 2-23, Figura 2-24). A Figura 2-25 apresenta um gráfico com um modelo real de laboratório onde não é empregado o módulo (E) (Salini, 2000). O número de ciclos (N) representa o número de cargas repetitivas a que o corpo de prova foi submetido no equipamento de ensaio; o número equivalente de eixos (ESAL) é calculado a partir da multiplicação do número de ciclos (N) pelo fator de ajuste campo-laboratório (*shift factor*). O *shift factor* depende do equipamento e parâmetros utilizados no ensaio de vida de fadiga; cada laboratório especifica seus próprios fatores, que podem variar de 1 a 100000 (Salini, 2000) (Pinto, 1991).

$$ESAL = (\text{shift factor}) \cdot (\epsilon_t)^{-f1} \cdot (E)^{-f2}$$

- ESAL = Equivalent single axle loads (standard axle)
- ϵ_t = Maximum strain
- E = Modulus
- f1, f2 = Adjusting factors
- shift factor = Laboratory-to-field adjusting factor

Figura 2-22– Equação empírico-mecanística de fadiga para o dimensionamento de pavimentos

⁵ N: Número de eixos padrão, também denominado ESAL

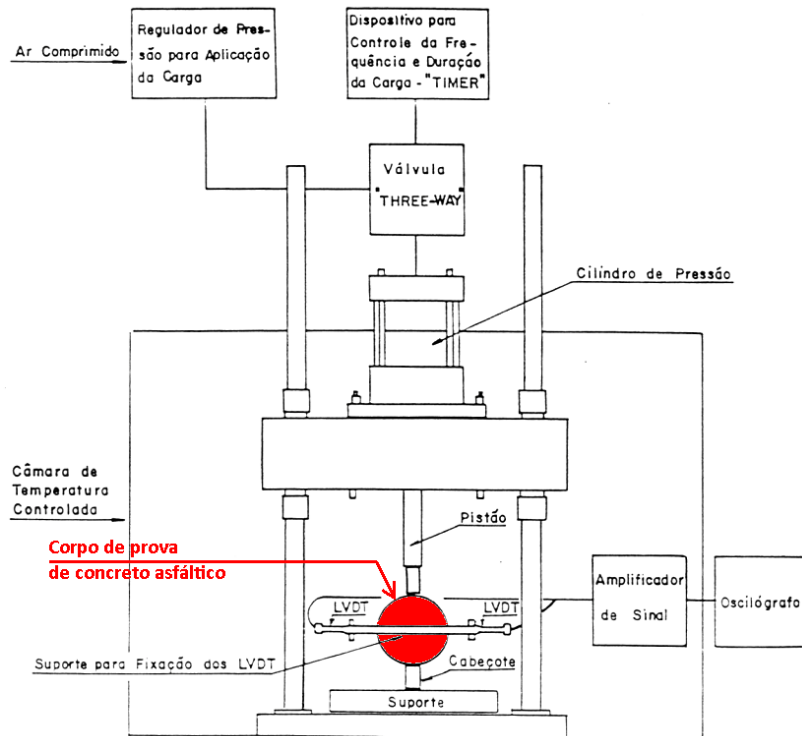


Figura 2-23 – Máquina de ensaio de fadiga para corpos de prova de concreto asfáltico cilíndricos utilizada na Universidade Federal do Rio de Janeiro (Salini, 2000)



Figura 2-24 – Máquina para ensaio de vida de fadiga para concretos asfálticos utilizando corpos de prova em formato de viga




Figura 2-25 – Equação de vida de fadiga de concreto asfáltico determinada em laboratório (Salini, 2000)

Além dos ensaios de laboratório, a vida de fadiga pode ser estudada com o emprego de simuladores de tráfego. Este tipo de teste é realizado com pavimentos em escala real ou próxima da real, construídos em grandes laboratórios (Figura 2-26) ou integrantes de uma rodovia, utilizando simuladores móveis (Figura 2-27). O tráfego é simulado com a passagem contínua de um conjunto de pneus, até o trincamento e/ou deformação da camada de concreto asfáltico. Este tipo de ensaio é mais próximo das condições reais de operação dos pavimentos rodoviários, mas apresentam elevado custo (Pinto, 1991).



Figura 2-26 – Simulador de tráfego circular da *Canterbury Accelerated Pavement Testing Indoor Facility* (Nova Zelândia)




Figura 2-27 - Simulador de tráfego móvel e linear desenvolvido pela Simular (Brasil) (Cifali, 2010)

2.3.2.1 Exemplo de modelagem e dimensionamento pelo método empírico-mecânico

Para dimensionar o pavimento através desta abordagem, o projetista escolhe uma estrutura inicial composta de sub-leito, uma ou mais camadas granulares e uma camada de concreto asfáltico (Figura 2-28). Com a utilização de um software de elementos finitos é aplicada uma carga padrão idêntica à do eixo padrão utilizado no cálculo do ESAL, geralmente 8,2 toneladas (2,05 t por pneu), e é calculada a deformação específica máxima de tração (ϵ_t) (Figura 2-30, Figura 2-29) que ocorre na camada asfáltica, que neste caso é 0,000189 (adimensional); esta

deformação é inserida na equação de fadiga apresentada na Figura 2-25 onde é verificado se o ESAL admissível em tal estrutura é igual ou maior que o ESAL de projeto (Figura 2-31). Neste dimensionamento também são apresentadas as tensões verticais (Figura 2-32).




Figura 2-28 – Estrutura do pavimento com as várias camadas

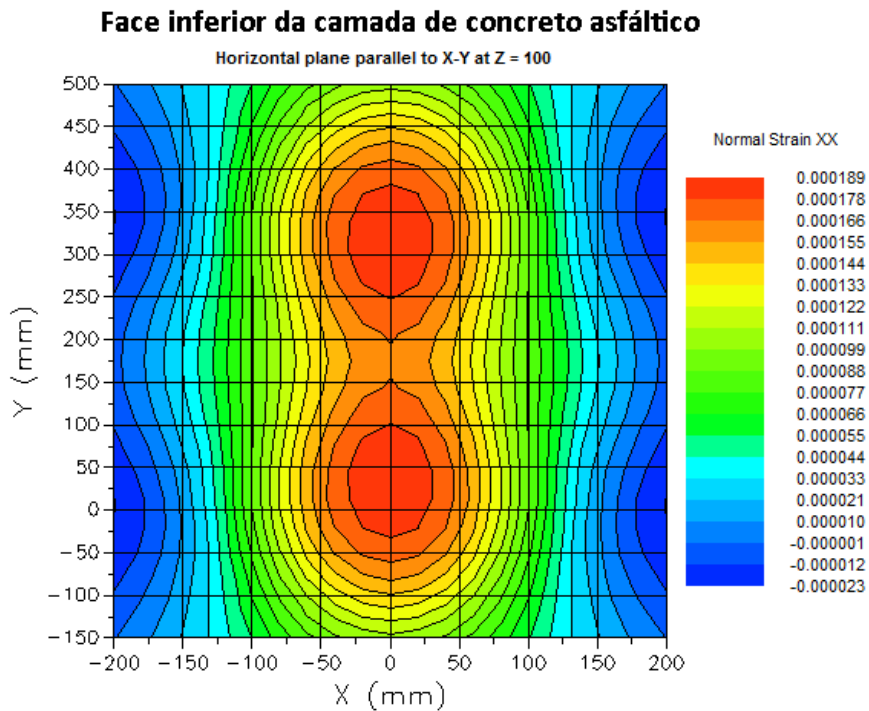


Figura 2-29 – Deformações específicas horizontais na face inferior da camada de concreto asfáltico

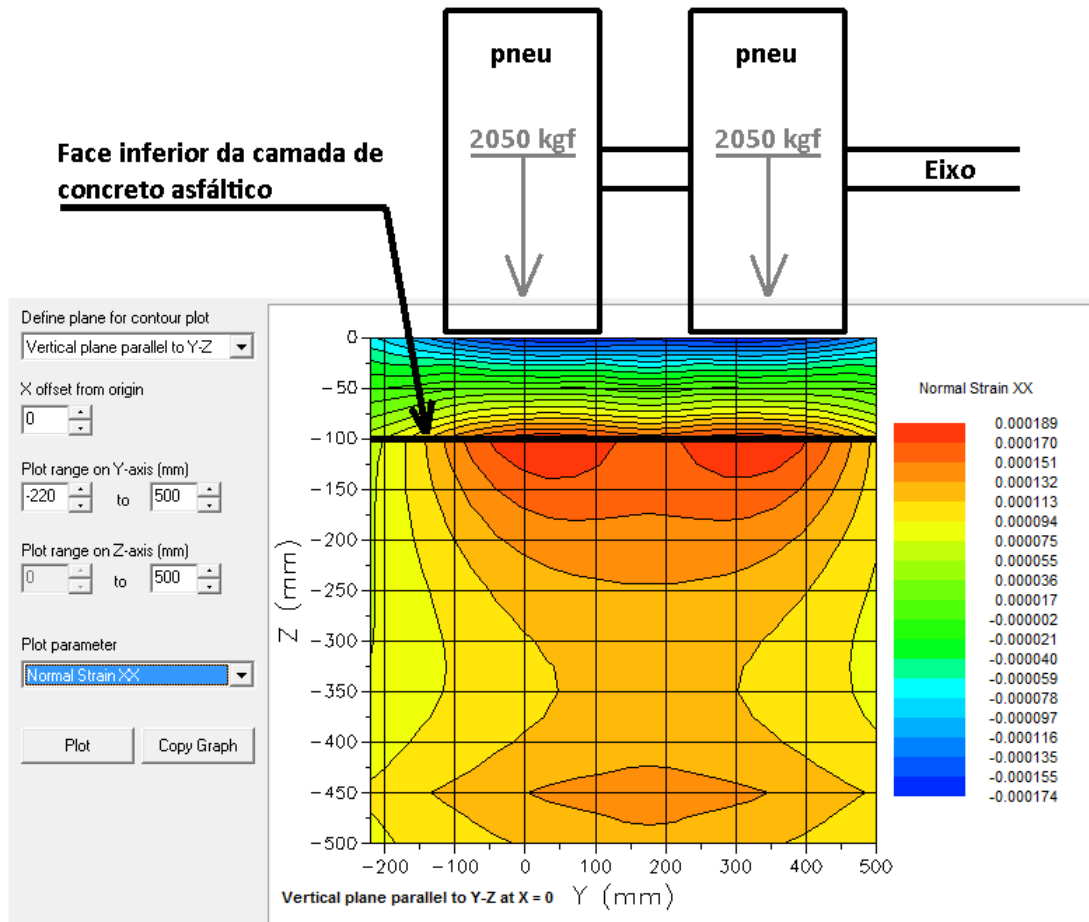


Figura 2-30 – Deformações específicas no plano vertical

$$ESAL_{\text{ADMISSÍVEL}} = (\text{shift factor}) \cdot (\epsilon_t)^{-f1}$$

$$ESAL_{\text{ADMISSÍVEL}} = (100000) \cdot (8,21 \cdot 10^{-13}) \cdot (0,000189)^{-3,62}$$

$$ESAL_{\text{ADMISSÍVEL}} = 2,4 \cdot 10^6$$

Figura 2-31 – Aplicação prática da equação-modelo de fadiga por método empírico-mecânico utilizando a equação apresentada na Figura 2-25




Figura 2-32 – Análise estrutural utilizando elementos finitos - tensões verticais

2.3.3 Método da AASHTO 2002

Na década de 1990 foi iniciado o desenvolvimento de um novo método para a modelagem e dimensionamento de pavimentos asfálticos, conhecido como AASHTO 2002. Diferente das versões anteriores, empíricas, este novo método da AASHTO adota uma abordagem empírico-mecanística para a análise do tráfego, terreno natural (“fundação” do pavimento), clima e materiais (Figura 2-33); é acompanhado de um software específico e introduz algumas inovações, como a eliminação do conceito de eixo padrão (ESAL) e a consideração da sazonalidade climática e do tráfego; mas não inclui variáveis como a velocidade dos veículos, de reconhecida importância. A modelagem é efetuada através do somatório dos danos acumulados resultantes do cruzamento dos dados do tráfego, do clima e das propriedades dos materiais (Figura 2-34) (National Cooperative Highway Research Program, 2004).

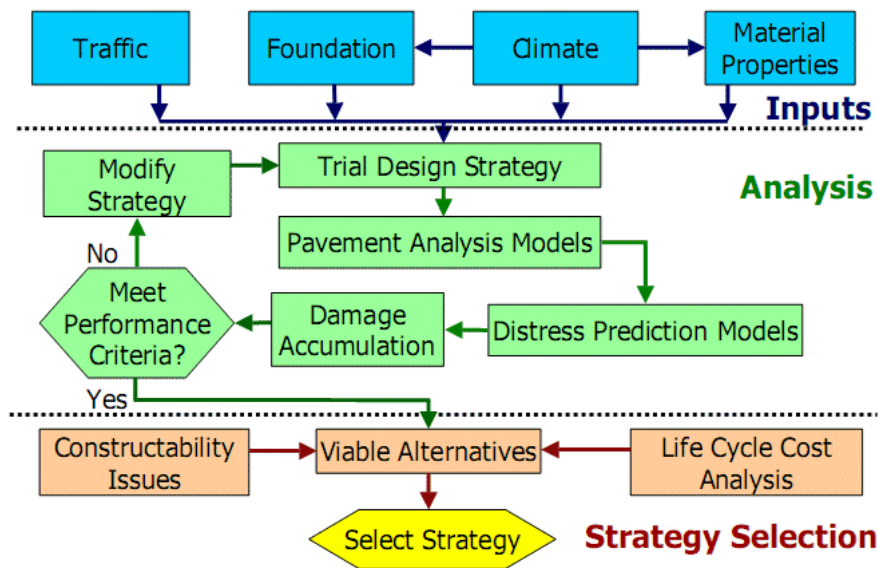


Figura 2-33 - Fluxograma do dimensionamento através do método da AASHTO 2002

Fracture:

$$\Delta DI = \sum_{k=1}^m \sum_{i=1}^j \left[\frac{n_i}{N_{(\epsilon_r)_i}} \right]_k$$

Distortion:

$$\Delta RD = \sum_{k=1}^m \sum_{i=1}^j \sum_{d=1}^l \left[\epsilon_{P(d)}(h_d) \right]_{k,i}$$

k = load level
i = time/season
d = sublayer

Figura 2-34 – Somatório dos danos acumulados no método da AASHTO 2002

Os modelos (equações) deste método requerem uma calibração complexa com base em dezenas de equações e centenas de dados (Figura 2-35) de trechos experimentais que existem apenas em alguns poucos Estados dos Estados Unidos (Programa *Long Term Pavement Performance, LTPP*), motivo pelo qual é pouco utilizado (AASHTO, 2004).

Assim como nos demais métodos empírico-mecanísticos, os valores críticos analisados são a deformação específica máxima de tração na camada de concreto asfáltico, para avaliação da vida de fadiga, e as deformações específicas no topo do sub-leito, para avaliação das deformações permanentes (Figura 2-36).

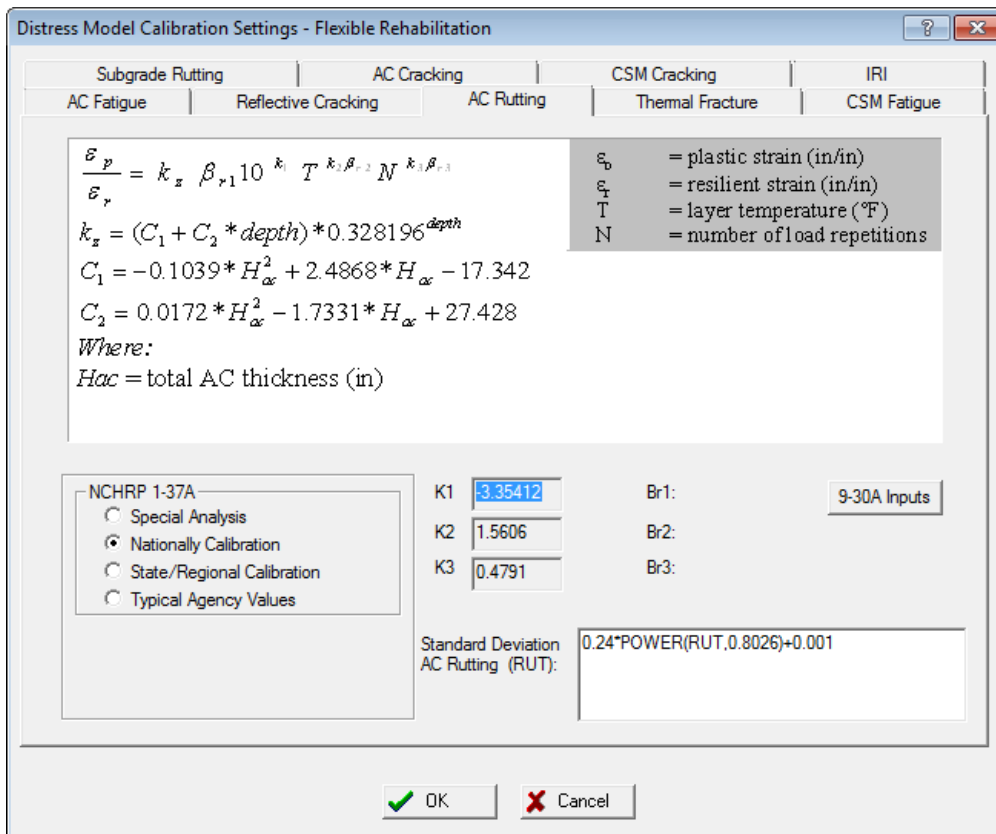


Figura 2-35 - Uma das dezenas de telas de calibração do software do método da AASHTO 2002 (AASHTO, 2004)




Figura 2-36 - Valores críticos no método da AASHTO 2002 (AASHTO, 2004)

O método da AASHTO 2002 contempla o emprego de redes neurais, mas apenas no projeto de pavimentos rígidos de concreto (excluídos os pavimentos asfálticos), entretanto há grande resistência por parte dos Departamentos de Transporte no seu uso. Esta dificuldade deve-se à dificuldade de integrar as redes neurais (NN) com os procedimentos atuais para pavimentos, dificuldade do entendimento das NN por parte dos engenheiros de estradas, falta de dados para o desenvolvimento de modelos confiáveis utilizando NN e falta de demonstrações do benefício proporcionado pelas NN em situações práticas para gestão e projeto de pavimentos (Gopalakrishna et al., 2007) (Bosurgi et al., 2007).

2.3.4 Pavimentos asfálticos perpétuos

O conceito de pavimentos asfálticos “perpétuos” ou de “grande durabilidade” não é novo, remonta aos anos 1960, mas seu emprego é raro, permanecendo em um patamar praticamente teórico.

Trata-se de uma combinação de materiais que supostamente permitiria maximizar a durabilidade, atingindo uma vida de serviço da ordem de 50 anos. Geralmente é constituído de uma camada superficial impermeável, resistente às deformações permanentes e ao desgaste, uma camada intermediária, também resistente às deformações permanentes, e uma camada inferior com grande vida de fadiga. A Figura 2-37 apresenta uma seção conceitual deste tipo de pavimento (Huddleston et al., 2001).

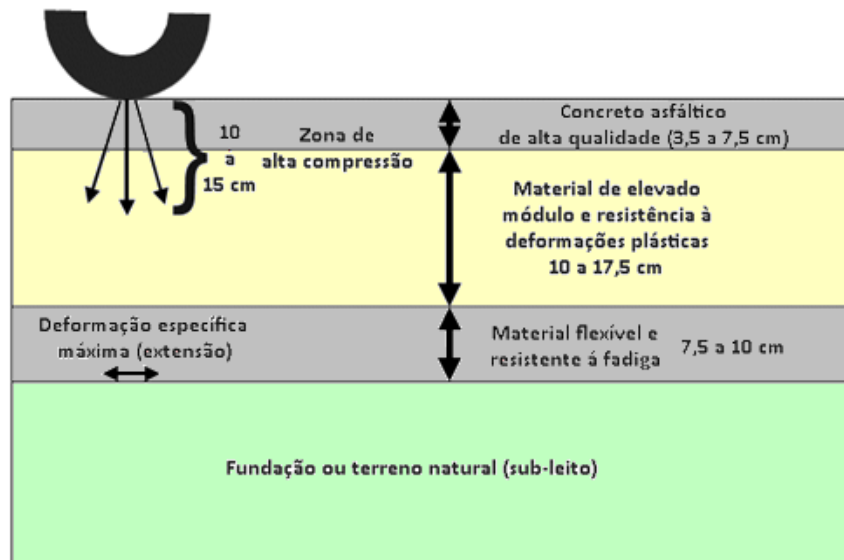


Figura 2-37 - Concepção típica de um pavimento asfáltico “perpétuo”

capítulo 3

3 INTELIGÊNCIA ARTIFICIAL APLICADA À PAVIMENTAÇÃO ASFÁLTICA

3.1 Introdução

A história da Inteligência Artificial remonta ao ano de 1956 quando John McCarthy propôs o termo como tema para a conferência na *Dartmouth College in New Hampshire*. As expectativas em torno do assunto eram grandes, mas os primeiros resultados foram frustrantes. Nas décadas de 1960 e 1970 as iniciativas de aplicação de técnicas de inteligência artificial estavam centradas em sistemas baseados em conhecimento e sistemas especialistas, e aplicadas em uma grande gama de assuntos, desde diagnóstico médico até a estrutura molecular que permite a compreensão da linguagem. Na mesma época foram iniciados os primeiros estudos com redes neurais (NN). As redes neurais só foram efetivamente desenvolvidas e exploradas a partir do final da década de 1980, quando as técnicas de retro-propagação (*backpropagation*) foram aperfeiçoadas.

Na década de 1990 houve uma evolução dramática nas técnicas de inteligência artificial, com a implementação de sólidas bases matemáticas, desenvolvimento de sistemas híbridos, que utilizam diferentes técnicas ou abordagens de forma integrada, e aplicações em problemas reais. Os sistemas híbridos também passaram a utilizar novos paradigmas, reproduzindo o comportamento biológico, como no caso dos algoritmos genéticos.

Os métodos de inteligência artificial (*Artificial Intelligence, AI*) podem ser divididos em duas categorias básicas: (a) AI simbólica, com foco no desenvolvimento de sistemas baseados em conhecimento (*Knowledge-Based Systems, KBS*), e inteligência computacional, que inclui métodos como redes neurais (NN), sistemas fuzzy (FS) e computação evolutiva (Sadek, 2007) (Minsky & Papert, 1969) (Russel & Norvig, 2002) (Zadeh, 1965).

Devido a grande quantidade de topologias na área de inteligência artificial, neste trabalho serão descritas apenas aquelas que, segundo Sadek (Sadek, 2007), tem atraído mais atenção dos pesquisadores da área de estradas: (a) sistemas baseados em conhecimento, (b) redes neurais, (c) algoritmos genéticos, (d) sistemas fuzzy, (e) modelagem baseada em agentes, além da topologia de máquinas de vetor de suporte (SVM) que, embora ainda não tenha se popularizado, apresenta grande potencial para o estudo dos problemas da pavimentação.

3.2 Técnicas de inteligência artificial

3.2.1 Sistemas baseados em conhecimento

Sistemas baseados em conhecimento (*Knowledge-based Systems, KBS*) podem ser descritos como a habilidade de um sistema computacional proporcionar “conselhos” em uma determinada área, alimentado por conhecimento produzido por especialistas (humanos).

O conhecimento é representado de diversas formas, como regras ou casos, enquanto as conclusões, ou conselhos, são inferidos através de algoritmos; assim, possuem três componentes básicos:

- Base de conhecimento, que consiste de um conjunto de fatos, definições, procedimentos ou regras heurísticas retiradas diretamente do conhecimento humano, que permite que o software se comporte como um “solucionador” de problemas;
- Mecanismos de aquisição; e,
- Mecanismos de inferência, que são os componentes do sistema encarregado de controlar o processo dedutivo, implementando a estratégia mais adequada para resolver um determinado problema.

Alguns autores afirmam que redes neurais e outras topologias são casos particulares de sistemas baseados em conhecimento, mas não há consenso (Sadek, 2007) (Akerkar & Sajja, 2009).

3.2.2 Redes neurais artificiais

As redes neurais (*Neural Networks, NN*) são inspiradas em sistemas biológicos e consistem em uma rede de pseudo-neurônios interconectados de forma massiva. Estes neurônios, ou nós, são interligados para formar uma rede, sendo esta a origem do termo “redes neurais”. A inspiração original para essa técnica advém das estruturas do cérebro, em particular dos neurônios e suas conexões.

As redes neurais são “treinadas” através do ajuste dos pesos da rede para que se aproximem ou reproduzam funções não-lineares. Cada neurônio possui ligações com outros neurônios, através das quais enviam e recebem sinais. Somam-se as entradas e se retorna uma saída, caso esta seja maior que o valor da soma.

Uma rede neural pode possuir uma ou múltiplas camadas. Exemplificando com três camadas, poderíamos ter a *camada de entrada*, em que as unidades recebem os padrões; a *camada intermediária*, onde é feito processamento e a extração de características; e a *camada de saída*, que conclui e apresenta o resultado final (Figura 3-1). Quanto maior o número de camadas, melhor a capacidade de aprendizado. A *camada de entrada* deve possuir uma unidade especial conhecida como *bias*, usada para aumentar os graus de liberdade, permitindo uma melhor adaptação, por parte da rede neural ao conhecimento a ela fornecido.

De forma mais técnica, a quantidade de camadas define a capacidade de representação das relações entre as entradas e as saídas. Se não houvesse nenhuma camada intermediária seria possível representar bem somente relações linearmente independentes; o emprego de camadas intermediárias, característica do modelo *perceptron de múltipla camada* (PMC), elimina esta limitação. Se houver apenas uma *camada intermediária*, o PMC pode representar (com qualquer grau de aproximação, por menor que seja) qualquer função contínua. Duas ou mais camadas ampliam o as possibilidades de representação a qualquer função, contínua ou não.

Tipicamente são empregados dois conjuntos de dados, *inputs* e *outputs*. Um algoritmo de aprendizado, como retro-propagação (*backpropagation*), é utilizado para ajustar o peso da rede até que sejam obtidos os *outputs* desejados; neste caso, através do treinamento *supervisionado*.

A aprendizagem também pode ser *por reforço*, onde para cada entrada apresentada é produzida uma indicação (reforço) sobre a adequação das saídas correspondentes produzidas pela rede, ou *não-supervisionada*, onde a rede atualiza seus pesos sem o uso de pares entrada-saídas (*inputs-outputs*) desejados e sem indicações sobre a adequação das saídas produzidas, podendo efetuar, por exemplo, o agrupamento dos dados (*clustering*), como representado na Figura 3-2 (Barone, 2003) (Haykin, 2001).




Figura 3-1 – Típica representação das redes neurais




Figura 3-2 - Típica representação de *clustering* com o agrupamento dos dados similares por redes neurais

3.2.3 Algoritmos genéticos

Os algoritmos genéticos (*Genetic Algorithms, GA*) são algoritmos estocásticos baseados no princípio da sobrevivência do melhor, utilizando técnicas inspiradas na biologia evolutiva como hereditariedade, mutação, seleção natural e recombinação; e tem sido utilizados para a resolução de problemas onde a matemática tradicional não se apresenta adequada.

Utilizam um princípio simples, com a geração randômica de uma população de “indivíduos” (ou cromossomo), onde cada indivíduo representa uma solução potencial para o problema em estudo e é avaliado em função da adaptação para tal tarefa. Uma nova população é gerada com os indivíduos que mais se adaptam. Alguns indivíduos são transmutados através de “mutações genéticas” para formarem novas soluções. Este processo de avaliação, seleção e transmutação é repetido um certo número de vezes, ou “gerações”, quando espera-se que as soluções apresentem convergência para uma solução otimizada do problema.

Este tipo de algoritmo são normalmente fáceis de serem implementados e simples, sendo que um dos pontos fortes dos algoritmos genéticos está no fato de que não é necessário saber como funciona a função-objetivo, mas apenas tê-la disponível para ser utilizada nos indivíduos e comparados os resultados.

O indivíduo é apenas um portador da informação genética, que é a representação do espaço de busca do problema que precisa ser resolvido. O código genético, tipicamente representado através de notação binária, deve ter um tamanho finito e ser capaz de representar todo o conjunto dos valores no espaço de busca. Problemas com entradas múltiplas podem ter suas entradas combinadas em uma única seqüência de bits ou serem descritas através de vários “cromossomos”.

A etapa de seleção também é crítica neste tipo de algoritmo. Tipicamente é utilizada uma seleção por roleta, onde os indivíduos são ordenados e recebem probabilidades decrescentes de serem selecionados. A seleção é efetuada de forma aleatória com base nestas probabilidades. Assim, são selecionados como “pais” os mais bem adaptados, mas aproveitando a diversidade dos menos adaptados. Também podem ser empregados outros tipos de seleções.

A reprodução (Figura 3-3) dos “indivíduos” é normalmente dividida em acasalamento, recombinação e mutação. O acasalamento é a seleção de dois indivíduos que irão se reproduzir. A recombinação (*cross-over*) (Figura 3-4) imita a reprodução humana, onde os descendentes recebem parte do código genético da mãe e do pai, e permite que os melhores indivíduos recombinem as informações que os levaram a ser os mais aptos a sobreviver, gerando descendentes ainda mais aptos. As mutações possuem como objetivo permitir maior diversidade genética na população de indivíduos, prevenindo que a busca fique confinada (Goldberg, 1989).

Indivíduo pai	Indivíduo mãe	Indivíduo filho
100101010010100101	101011011101010101	100101010010100101
101010101110100011	100100111000111101	100100111000111101

Figura 3-3 – Exemplo de reprodução entre indivíduos

Indivíduo pai	Indivíduo mãe	Indivíduo filho 1	Indivíduo filho 2:
100101010010100101	101011011101010101	100101010010111101	100100110010100101
101010101110100011	100100111000111101	100100111000100101	100101011000111101

Figura 3-4 – Exemplo de recombinação (cross-over)

Os algoritmos genéticos diferem dos algoritmos tradicionais de otimização por (a) basearem-se em uma codificação do conjunto das soluções possíveis, e não nos parâmetros da otimização em si; (b) seus resultados serem apresentados como uma população de soluções e não como uma solução única; (c) não necessitarem de nenhum conhecimento derivado do problema, mas apenas uma forma de avaliação do resultado; e (d) usarem transições probabilísticas e não regras determinísticas (Sadek, 2007) (Goldberg, 1989).

3.2.4 Sistemas Fuzzy

Os Sistemas Fuzzy foram propostos por Zadeh (Zadeh, 1965) como uma forma de trabalhar a ambigüidade que normalmente estão presentes nos problemas. Conjuntos Fuzzy proporcionam uma forma de avaliar um objeto que pertence parcialmente a um grupo. Enquanto a teoria clássica define que um objeto pertence a um determinado grupo enquanto

não pertence a outro grupo, os sistemas Fuzzy permitem uma transição gradual entre dois grupos utilizando índices entre 0 e 1 (zero e um), onde 0 significa que não pertence ao grupo (ou “falso”) e 1 significa que está totalmente inserido dentro do grupo (ou “verdadeiro”), enquanto 0,5 significa parcialmente no grupo (ou “talvez”). A teoria Fuzzy não minimiza ou elimina a ambigüidade das informações, mas proporciona uma forma de mensurá-la.

A lógica Fuzzy, ou lógica difusa, deve ser vista como uma área de investigação sobre o tratamento das incertezas, ou modelos de tratamento da incerteza utilizando a matemática, do que propriamente uma *lógica*.

Permite avaliar, por exemplo, se a temperatura está quente, fria, morna, etc. A Figura 3-5 apresenta outro exemplo sobre volume médio de tráfego (veículos) em rodovias, onde rodovias com volumes entre 800 e 1000 veículos por hora (vph) pertencem totalmente à média; rodovias com volumes menores que 400 e maiores que 1400 vph não pertencem à média; e rodovias com volumes entre 400 e 800 vph ou entre 1000 e 1400 vph pertencem parcialmente à média de volumes de tráfego.

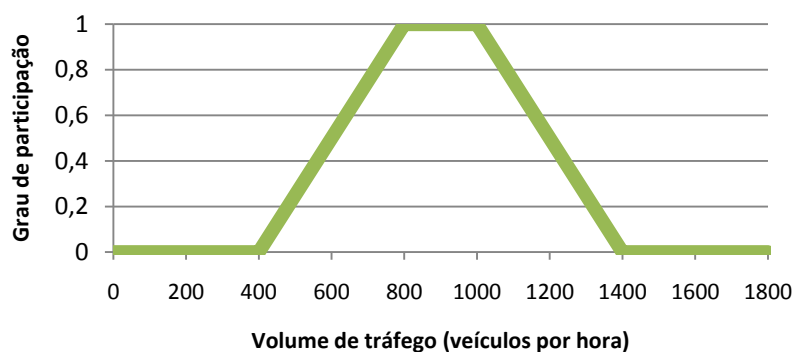


Figura 3-5 - Representação simbólica com sistemas Fuzzy para volume de tráfego

3.2.5 Modelagem baseada em agentes

Adicionalmente às topologias já citadas, nos últimos anos tem sido crescente o interesse pela modelagem baseada em agentes (*Agent-based modeling, ABM*), também chamada de simulação baseada em indivíduos (*multi-agent simulation*), entre outras denominações. A idéia por trás do ABM é a descrição de um sistema baseado desde uma perspectiva de suas unidades constituintes e é particularmente adequado para a modelagem de sistemas complexos cujos comportamentos dependem do resultado das interações das unidades que compõe o próprio sistema (Sarker & Ray, 2010).

A modelagem baseada em agentes combina a teoria dos jogos, sistemas complexos, sociologia computacional, sistemas multi-agentes e programação evolutiva. A modelagem simula operações e interações simultâneas entre múltiplos agentes (Figura 3-6), em uma tentativa de

recriar e prever comportamentos ou fenômenos complexos. Evolui de sistemas micro para sistemas macro, partindo da consideração que regras simples produzem comportamentos complexos. Esta premissa, chamada de K.I.S.S. ("*Keep it simple stupid*"), é extensivamente adotada na modelagem. Outra premissa é de que o conjunto é maior que a soma das partes (sinergia).

Os agentes são caracterizados como racionais na presunção de que irão agir com base em seus próprios interesses, como reprodução, benefícios econômicos ou status social, usando regras holísticas ou decisões simples. Os agentes podem aprender, se adaptar e reproduzir (Sadek, 2007) (Axtell et al., 2003) (Bonabeau, 2002).

Modelos baseados em agentes tem sido utilizados desde meados da década de 1990 para resolver uma série de problemas na área de tecnologia e negócios. Exemplos de aplicações incluem otimização de canais de distribuição de produtos e logística, previsão do comportamento de consumidores, computação distribuída, gerenciamento de equipes e portfólios, e problemas de engarrafamento do tráfego (Erol et al., 2007), entre outros. Nestas e demais aplicações, o problema ou sistema é simulado pela captura do comportamento do indivíduo e suas interconexões, permitindo testar, por exemplo, como que as alterações de comportamento de um indivíduo em particular irão afetar o comportamento de todo o sistema. Outros modelos tem sido utilizados para analisar questões tão diversas como a ocorrência de epidemias, aplicações biomédicas (Siddiqah et al., 2009), a ascensão e declínio de civilizações antigas e as migrações (Edwards, 2010).




Figura 3-6 – Interação dos agentes

3.2.6 Máquinas de Vetor de Suporte

As Máquinas de Vetor de Suporte (*Support Vector Machines, SVM*) têm recebido uma crescente atenção por parte dos pesquisadores e usuários de sistemas automáticos de

aprendizado (Mitchell, 1997). As SVM produzem resultados similares, ou mesmo superiores, aos proporcionados por outros algoritmos de aprendizado, tais como as redes neurais artificiais (Haykin, 1999) (Braga et al., 2000), podendo ser empregado em inúmeras áreas, tais como classificação de textos, análise de imagens e bioinformática (Joachims, 2002) (Kim et al., 2002) (Noble, 2004).

As SVM foram desenvolvidas a partir da teoria de aprendizado estatístico de Vapnik (Vapnik, 1995), que estabelece um conjunto de premissas que devem ser observadas para a obtenção de classificadores com boa generalização, capazes de prever a classe de novos dados a partir do conjunto de dados utilizado no aprendizado.

Para a aprendizagem é empregado o princípio de indução, onde são obtidas conclusões generalizáveis a partir de um conjunto de exemplos, e pode ser do tipo supervisionado ou não-supervisionado.

No caso do aprendizado supervisionado são utilizados conjuntos de exemplos contendo *inputs* e *outputs* para alimentar o algoritmo de treinamento que, treinado, deverá ser capaz de produzir *outputs* corretos a partir de novos *inputs* (Haykin, 1999).

No caso de aprendizado não supervisionado, ou seja, não existem *outputs* para o treinamento, o algoritmo aprende a classificar os *inputs* a partir de alguma medida de qualidade. Estas técnicas são particularmente adequadas na busca por padrões ou melhor compreensão dos dados (Souto et al., 2003), apresentando grande potencial para a modelagem de problemas na área de estradas, especialmente no desenvolvimento de modelos de desempenho.

Em termos práticos, o objetivo desta técnica é classificar os dados em grupos (Figura 3-7) através de uma fronteira de decisão ou hiperplano, de tal forma que a separação dos grupos seja a máxima (Figura 3-8). Os problemas encontrados no mundo real normalmente não podem ser separados linearmente (margens rígidas); neste caso a SVM pode ser aplicada com margens suaves (*soft margin*) com a utilização de *variáveis de folga*. As SVM também podem ser aplicadas a problemas que apresentem margem não-linear (Figura 3-9).




Figura 3-7 – Fronteira de decisão (qual é a melhor, A ou B?)




Figura 3-8 - Hiperplano ótimo para separação das classes




Figura 3-9 – SVM de margem não-linear

3.3 Aplicação de técnicas de inteligência artificial em pavimentos

3.3.1 Introdução

Nas últimas décadas, com o advento dos computadores e desenvolvimento de técnicas de *soft computing*, tem sido publicado um número crescente de estudos que utilizam ferramentas de inteligência artificial na solução de problemas de engenharia de pavimentos, especialmente de redes neurais artificiais (*Artificial Neural Network, ANN*). Esta importância crescente pode ser facilmente identificada pelo fato da *Transportation Research Board*, uma das mais respeitadas instituições de pesquisas na área de rodovias dos Estados Unidos (TRB, 2010), ter criado um comitê específico sobre o assunto, o *Artificial Intelligence and Advanced Computing*

Applications Committee, e outro sub-comitê ainda mais especializado, denominado *Neural Nets and Other Computational Intelligence–Based Modeling Systems Subcommittee*.

3.3.2 Trabalhos relacionados

Os primeiros usos de ANN em rodovias foram nas áreas de planejamento, controle e operação de tráfego, construção e manutenção, e gerenciamento de instalações (Faghri et al., 1997) (Dougherty, 1995). Nos últimos anos tem sido considerável o interesse no uso de ANN nas áreas de geotecnia e pavimentos, incluindo análise de estruturas e predição de performance. ANN tem sido utilizadas com sucesso num grande espectro de atividades como caracterização de materiais, engenharia de fundações, liquefação de solos e modelagem (Toll, 1996), não sendo difícil encontrar publicações baseadas no uso de técnicas de inteligência artificial nos congressos técnicos (Attoh-Okine, 1998).

Inicialmente, a maioria dos estudos estavam concentrados na área de geomecânica, com menor ênfase em pavimentos. Tutumluer e Seyhan (Tutumluer & Seyhan, 1998) treinaram redes neurais utilizando algoritmo de retro-propagação (*backpropagation*) para prever o comportamento de materiais granulares submetidos ao ensaio triaxial. Penumadu e outros (Penumadu et al., 1994) desenvolveram um modelo para solos argilosos utilizando ANN. Penumadu e Zhao (Penumadu & Zhao, 1999) utilizaram *feedback* para modelar o comportamento de areias e pedregulhos quanto à relação tensão-deformação em ensaios triaxiais. Zhu e Zaman (Zhu & Zaman, 1997) utilizaram redes neurais para prever o comportamento de tensão-deformação de areias submetidas a cargas repetitivas. Basheer e Najjar (Basheer, 1998) (Basheer & Najjar, 1998) também utilizaram uma abordagem baseada em *feedback* para simular a relação tensão-deformação em solos finos utilizando vários tipos de carga. Utilizando retro-propagação seqüencial (*feedback*), Ellis e outros (Ellis et al., 1995) desenvolveram um modelo para areias baseado na curva granulométrica e tensões. Ghaboussi e Sidarta (Sidarta & Ghaboussi, 1998) (Ghaboussi & Sidarta, 1998) utilizaram redes neurais (do tipo *nested adaptive neural network, NANN*) para modelar o comportamento de solos arenosos drenados e não-drenados testados em ensaios triaxiais.

Apesar dos avanços na velocidade dos computadores, a modelagem estrutural dos pavimentos empregando redes neurais pode ser até três vezes mais rápida do que empregando métodos tradicionais, baseados em softwares de análise elástica, e muitas vezes mais rápida se comparada com softwares sofisticados que empregam elementos finitos, o que tem despertado interesse de alguns pesquisadores para o emprego de ANN como formas aproximativas para análise de estruturas de pavimentos. Meier e outros (Meier et al., 1997) utilizaram redes neurais (*backpropagation*) como substituto do programa WESLEA para a retroanálise (*backcalculation*) de pavimentos, obtendo um ganho de velocidade significativo.

Meier e Rix (Meier & Rix, 1994) (Meier & Rix, 1995) utilizaram o algoritmo de *backpropagation* para treinar as redes neurais no cálculo dos valores modulares de pavimentos de concreto asfáltico a partir da retroanálise de deflexões medidas com o FWD, obtendo melhoras de velocidade de incríveis 4500 vezes. Khazanovich e Roesler (Khazanovich & Roesler, 1997) utilizaram um algoritmo proprietário para treinar as redes neurais para efetuar retroanálise

em pavimentos compostos. Ceylan e outros (Ceylan et al., 1998) (Ceylan et al., 1999) demonstraram o treinamento de ANN com modelos para o cálculo de tensões e deflexões em juntas de pavimentos aeroportuários de concreto em função da espessura do pavimento, tipo de base e eficiência das juntas; os dados para treinamento foram calculados utilizando o software de elementos finitos ILLI-SLAB. Ioannides e outros (Ioannides et al., 1996) utilizaram redes neurais com um algoritmo de *backpropagation* para determinar a eficiência da transferência de cargas em juntas de pavimentos rígidos utilizando dados do FWD. Apesar de que as ANN jamais substituirão os versáteis softwares de análise por elementos finitos, estas podem ser empregadas em diversas situações em que são efetuadas análises preliminares ou em situações específicas, e quando existirem dados adequados para o treinamento das redes neurais.

As redes neurais possuem grande potencial para a predição de deterioração em pavimentos, um problema tradicionalmente complexo. Najjar e Basheer (Najjar & Basheer, 1997) desenvolveu um modelo de predição da durabilidade dos agregados utilizados em pavimentos de concreto utilizando redes neurais (*backpropagation*); as ANN foram treinadas com o uso da base de dados do Departamento de Transporte do Kansas (Estados Unidos) e efetuaram a predição com grande acurácia a durabilidade e expansão a partir de cinco propriedades físicas básicas dos agregados. Os mesmos autores (Basheer & Najjar, 1996) também desenvolveram modelos baseados em ANN para prever a deterioração de juntas longitudinais em pavimentos de concreto, também no Kansas. Estes modelos foram posteriormente empregados com sucesso no controle de qualidade de pavimentos em construção.

Roberts e Attoh-Okine (Roberts & Attoh-Okine, 1998) empregaram ANN com uma função quadrática para predizer a rugosidade de pavimentos; ANN de funções quadráticas são generalizáveis e combinam aprendizado supervisionado e auto-organizado. Em termos gerais, quaisquer redes neurais que empreguem funções de aproximação (*backpropagation, radial basis function, counterpropagation, etc.*) apresentam potencial para serem utilizadas no desenvolvimento de modelos ou correlações entre variáveis relacionadas com a estrutura e defeitos dos pavimentos; o sucesso não depende exatamente do tipo de redes neurais utilizadas, mas principalmente da quantidade e qualidade dos dados disponíveis para o treinamento.

Banan e Hjelmstad (Banan & Hjelmstad, 1996) demonstraram o potencial das ANN para a análise de dados coletados em pavimentos de testes ao reexaminarem os dados da pista experimental da AASHO (Carey & Irick, 1960) (Carey & Irick, 1962). Utilizando um algoritmo de rede proprietário, similar à uma função de base radial, que subdivide o espaço de entrada (*input*) e aprende uma resposta média para cada sub-divisão (Banan & Hjelmstad, 1995), os pesquisadores foram capazes de obter correlações muito melhores que as obtidas por regressão, que ajusta os dados globalmente a uma única função matemática.

São necessários diversos e grandes conjuntos de informações para que seja possível desenvolver bons modelos de predição de deterioração em pavimentos. Nesta área as redes neurais também se mostram promissoras. Kaseko e outros (Kaseko et al., 1994) utilizaram *backpropagation* enquanto Lo e Bavarian (Lo & Bavarian, 1991) utilizaram um algoritmo proprietário para detectar e classificar defeitos a partir de vídeos de pavimentos asfálticos

(Figura 3-10, Figura 3-11). Chou e outros (Chou et al., 1994) (Chou et al., 1995) utilizaram algoritmo de *backpropagation* para classificar áreas trincadas utilizando imagens extraídas de vídeos de pavimentos asfálticos. Wang e outros (Wang, 1995) (Wang et al., 1998) propuseram o uso de um chip de redes neurais, o Intel Ni1000, para detectar, classificar e quantificar diferentes tipos de defeitos em pavimentos a partir de imagens dos pavimentos coletadas a velocidades típicas de trânsito dos veículos.

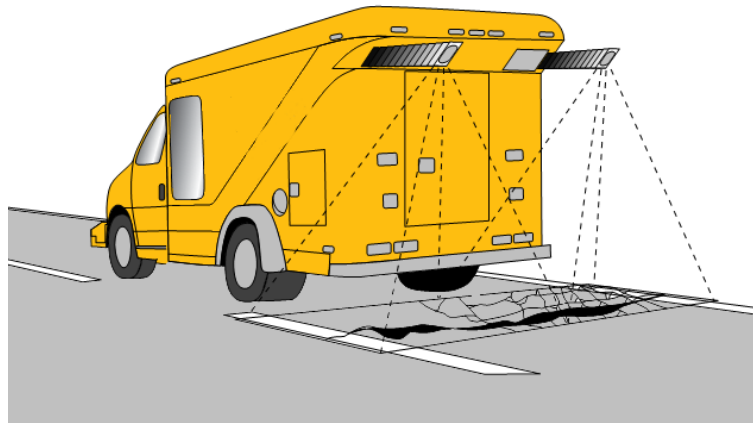


Figura 3-10 - Veículo equipado com câmeras para a coleta de imagens ortogonais de pavimentos



Figura 3-11 - Imagem ortogonal do pavimento com trincas identificadas

A identificação de defeitos em imagens também foi estudada por Xiao e outros (Xiao et al., 2006), que desenvolveram um algoritmo que denominaram redes neurais baseadas em densidades (*DENSITY-based neural network, DNN*) que, de acordo com os autores, em testes realizados com 83 imagens reais de pavimentos, proporcionou acurácia de 97,5% na detecção. Trabalho similar foi desenvolvido por Bray e outros (Bray et al., 2006) utilizando duas redes neurais de forma hierárquica, uma para detectar a existência ou não de defeitos, e a segunda para classificar os defeitos existentes, trabalhando com propriedades das imagens, como os histogramas. Como pode ser visto na Tabela 3-1, apesar da aprendizagem das redes ter sido eficiente, a aplicação prática em dados de testes apresenta resultados pobres; esta situação é comum para a ampla maioria dos algoritmos já desenvolvidos, baseados em técnicas de *soft computing* ou não, para identificação de defeitos em pavimentos a partir de imagens.

Tabela 3-1 - Resultados obtidos com redes neurais empregando histograma (Bray et al., 2006)

# of hidden units	# of epochs	Training Set Classification Rate [%]				Test Set Classification Rate [%]			
		Alligator	Block	Horizontal	Vertical	Alligator	Block	Horizontal	Vertical
6	10e5	100	80	70	80	40	20	70	50
6	10e6	100	100	70	70	30	50	30	10
12	10e5	100	100	100	90	40	50	60	10
12	10e6	100	100	100	90	30	50	60	20
24	10e5	100	90	100	90	40	30	80	20
24	10e6	100	80	90	100	40	60	50	10
36	10e5	100	80	100	90	30	60	70	30
36	10e6	100	100	100	100	30	50	20	60

Outra área onde as redes neurais tem sido empregadas é para a classificação do tráfego (veículos). Diversas agências de rodovias possuem estações fixas de contagem e classificação de veículos, em pontos estratégicos, para continuamente registrar o tráfego visando identificar os padrões de tráfegos para diferentes tipos de rodovias. Estas bases de dados possuem, geralmente, arquivadas as variações da média diária de veículos calculada em base mensal (*monthly average daily traffic, MADT*) em cada posto de contagem. Em rodovias onde não há qualquer registro, mas são necessários dados do tráfego, são efetuadas contagens manuais de curta duração – geralmente de três dias. Estas contagens manuais podem ser cruzadas com as bases de dados das estações fixas de contagem e classificação para estimar o tráfego anual sazonalizado mensalmente. A identificação de qual estação fixa de contagem apresenta o tráfego mais adequado para ser utilizado na estimativa de tráfego anual, para a rodovia onde foi efetuada a contagem de curta duração, é outra aplicação em que as ANN tem apresentado bons resultados. Faghri e Hua (Faghri & Hua, 1995) utilizaram redes tipo ART (*Adaptive Resonance Theory*) para agrupar rodovias de acordo com o MADT, com resultados muito melhores que os obtidos por métodos tradicionais, como regressão ou análise de grupo. Lingras (Lingras, 1995) utilizou redes neurais tipo *Kohonen* para uma aplicação similar que se

mostrou melhor que os métodos hierárquicos tradicionais na classificação de padrões de tráfegos completos e incompletos.

Na University of Texas at El Paso (Abdallah et al., 1998) (Abdallah et al., 1999) (Abdallah et al., 2000) foi desenvolvida uma metodologia baseada em ANN tipo *backpropagation* para computar a vida remanescente de pavimentos asfálticos quanto à trincas de fadiga e trilha de roda a partir de dados deflectométricos obtidos com o FWD e espessuras de camadas. As predições se mostraram similares àquelas obtidas com o uso do simulador de tráfego móvel lá existente (Abdallah et al., 1999). Os desenvolvimentos deste grupo de pesquisadores (Abdallah et al., 2001) foram posteriormente ampliados, com o desenvolvimento de quatro modelos para predição dos valores modulares dos pavimentos para deflexões medidas com o FWD, e o desenvolvimento de um software; o relatório final foi publicado em 2001.

3.3.3 Estudos selecionados

Miradi (Miradi, 2009) efetuou a avaliação de 60 estudos científicos (Tabela 3-2, Tabela 3-3) onde são empregadas técnicas de inteligência artificial no estudo de vários aspectos dos pavimentos, publicados entre 1995 e 2007, por pesquisadores da área de pavimentos.

Tabela 3-2 – Estudos avaliados por Miradi (Miradi, 2009) (Parte A)

Autores	Ano	Assunto
Hoffman and Chou	1994	Trincamento, Deformação permanente, Rugosidade
Eldin and Senouci	1996	Trincamento, Deformação permanente, Rugosidade
Hsu and Tsai	1997	Trincamento, Deformação permanente, Rugosidade
Roberts and Attoh-Okine	1998	Trincamento, Deformação permanente, Rugosidade
Loia et al.	2000	Trincamento, Deformação permanente, Rugosidade
Attoh-Okine	2002	Trincamento, Deformação permanente, Rugosidade
Chang et al.	2003	Trincamento, Deformação permanente, Rugosidade
Mu-yu and Shao-yi	2003	Trincamento, Deformação permanente, Rugosidade
Yang et al.	2003	Trincamento, Deformação permanente, Rugosidade
Chang et al.	2004	Trincamento, Deformação permanente, Rugosidade
Nakatsuji et al.	2005	Trincamento, Deformação permanente, Rugosidade
Karlaftis & Loizos	2006	Trincamento, Deformação permanente, Rugosidade
Terzi	2006	Trincamento, Deformação permanente, Rugosidade
Bosurgi et al.	2007	Trincamento, Deformação permanente, Rugosidade
Terzi	2007	Trincamento, Deformação permanente, Rugosidade
Kaur and Pulugurta	2007	Trincamento, Deformação permanente, Rugosidade

Tabela 3-3 – Estudos avaliados por Miradi (Miradi, 2009) (Parte B)

Autores	Ano	Assunto
Meier and Rix	1995	Módulo
Ferregut et al.	1999	Módulo
Kaur and Chou	1999	Módulo
Kim et al.	2000	Módulo
Abdallah et al.	2001	Módulo
Saltan et al.	2002	Módulo
Terzi et al.	2003	Módulo
Bredenhann and van de Ven	2004	Módulo
Goktepe et al.	2004	Módulo
Reddy et al.	2004	Módulo
Ceylan et al.	2005a	Módulo
Ceylan et al.	2005b	Módulo
Chang et al.	2006	Módulo
Goktepe and Altun	2006	Módulo
Gopalakrishnan et al.	2006	Módulo
Rakesh et al.	2006	Módulo
Saltan and Sezgin	2006	Módulo
Burak and Altun	2007	Módulo
Ceylan et al.	2007	Módulo
Demir	2007	Módulo
Guclu and Ceylan	2007	Módulo
Lee et al.	2007	Módulo
Loizos et al.	2007	Módulo
Ozashin and Oruc	2007	Módulo
Saltan and Terzi	2007	Módulo
Pekcan et al.	2007	Módulo
Thube and Thube	2007	Perda de agregado
Kaur and Tekkedil	2000	Deformação permanente
Tarefder et al.	2005	Deformação permanente
Chou et al.	1994	Trincamento
Meignen et al.	1997	Trincamento
Lou et al.	1999	Trincamento
Lee and Lee	2003	Trincamento
Avila et al.	2004	Trincamento
Lea and Harvey	2004	Trincamento
Mei et al.	2004	Trincamento
Rababaah et al.	2005	Trincamento
Bray et al.	2006	Trincamento
Xiao et al.	2006	Trincamento
Huang et al.	2007	Trincamento
Ozbay and Laub	2001	Rugosidade
Aultman-hall et al.	2004	Rugosidade
Bayrak et al.	2004	Rugosidade
Choi et al.	2004	Rugosidade

Destes, 2% (um estudo) abordavam a perda de agregados na camada asfáltica (*raveling*); 18% referiam-se a trincamento; 3% sobre deformações plásticas (trilha de roda); 7% sobre a rugosidade da superfície do pavimento; 27% abordavam simultaneamente a combinação de trincamento, trilha de roda e rugosidade; enquanto 43% eram referentes a estudos modulares/estrutura das camadas do pavimento. Do total, 12% empregaram técnicas de classificação, enquanto 88% empregaram técnicas de regressão. A maioria utilizaram redes neurais como ferramenta (35 estudos). Nenhum dos 60 estudos efetuou o estudo simultâneo ou combinação das características dos materiais, tráfego e fatores climáticos (Miradi, 2009).

Segundo Miradi, embora a maioria dos pesquisadores estejam satisfeitos com os resultados obtidos, foram poucos os estudos que identificaram padrões de comportamento (*data mining*), a parametrização foi a mais simples possível na maior parte dos casos, e técnicas robustas como SVM sequer foram tentadas, sugerindo que os pesquisadores em pavimentação possuem conhecimentos limitados sobre o emprego das ferramentas de inteligência artificial.

Utilizando dados dos Países Baixos, Miradi (Miradi, 2009) desenvolveu um interessante estudo visando identificar os fatores mais importantes para a degradação dos pavimentos asfálticos utilizando redes neurais (ANN), SVM (*Support Vector Machine*), algoritmos genéticos, árvores de decisão e teoria *Rough Sets* para a análise da ocorrência de trincamento, deformação permanente e perda de agregado na camada asfáltica para diversas épocas (anos) após a construção do pavimento. Foi utilizada a base de dados do *The Strategic Highway Research Program in the Netherlands* (SHRP-NL), contendo registros efetuados entre 1990 e 2000.

As variáveis consideradas no processo de descoberta do conhecimento foram baseadas substancialmente nas características físicas do concreto asfáltico, nas condições climáticas e no tráfego:

- Densidade do concreto asfáltico;
- Teor de ligante asfáltico no concreto asfáltico;
- Volume de vazios do concreto asfáltico;
- Tipo de agregado (pedra britada) utilizado, dividido em 4 tipos;
- Percentual de agregado passante na peneira de 2 mm;
- Coeficiente de uniformidade do agregado;
- Diâmetro da peneira no qual 50% do agregado passa;
- Número acumulado de dias com tempo bom/quente;
- Número acumulado de dias frios;
- Número acumulado de horas de radiação solar;
- Número acumulado de dias de chuva;
- Tráfego acumulado (veículos).

A Figura 3-12 apresenta as variáveis mais importantes para a degradação do pavimento quanto à perda de agregado (*raveling*) aos 8 anos utilizando a técnica de redes neurais (Miradi, 2009).

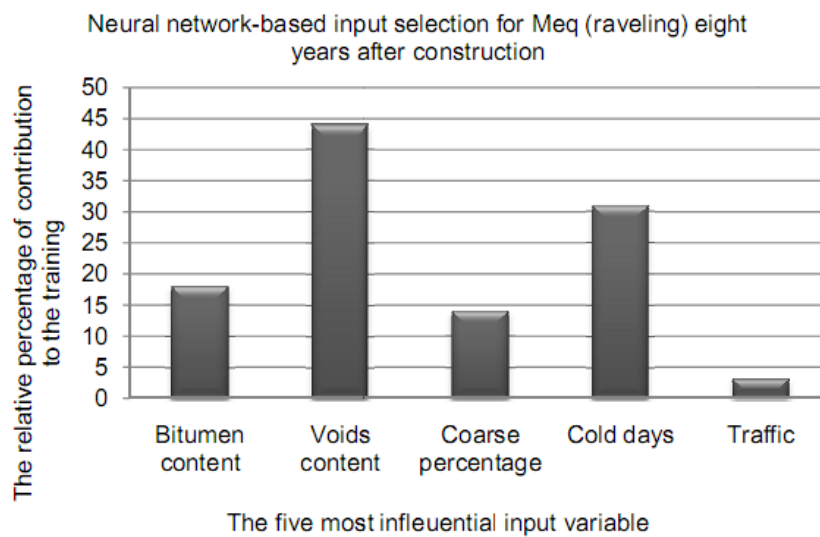


Figura 3-12 – Variáveis mais importantes para a perda de agregado (Miradi, 2009)

A Tabela 3-4 apresenta as cinco variáveis mais importantes para o trincamento do pavimento aos 11 anos após a construção do mesmo, utilizando diversas técnicas de inteligência artificial. Pode-se observar que, dependendo da técnica utilizada, os resultados são ligeiramente diferentes.

Tabela 3-4 – As cinco variáveis mais importantes para o trincamento do pavimento aos 11 anos após a construção (Miradi, 2009)

Method	Setting	Variable 1	Variable 2	Variable 3	Variable 4	Variable 5
Regression trees	Leave-one-out cross validation	Cold days	Traffic	Voids content	Bitumen content	
Genetic polynomial	Polynomial degree = 3	Cold days	Traffic	Bitumen content	Voids content	Rain
Artificial neural network (WWF)	Leave-one-out cross validation	Traffic	Cold days	Voids content	Bitumen content	Rain
Rough sets	2-class output	Voids content	Bitumen content	Traffic		
Correlation-based subset selection (bidirectional search)	Greedy stepwise search Leave-one-out cross validation	Cold days	Voids content	Bitumen content		
Correlation-based subset selection (genetic search)	Genetic Search Leave-one-out cross validation	Cold days	Bitumen content	Voids content		
Wrappers of ANN (genetic search)	Genetic Search Leave-one-out cross validation	Voids content				
Relief ranking filter	K=20 Nearest neighbor (equal influence) Leave-one-out cross validation	Cold days	Traffic	Bitumen content	Voids content	

Apesar das limitações e problemas, ignorando fatores extremamente críticos para a determinação da degradação dos pavimentos asfálticos, como a espessura das camadas, características do sub-leito, a velocidade dos veículos, ou a combinação da sazonalidade clima *versus* tráfego, entre outras, o trabalho de Miradi representa um substancial avanço na forma de abordar o problema mesmo quando comparado com outras pesquisas que também empregaram técnicas de inteligência artificial; talvez até por ter formação na área de ciências da computação, e não em pavimentos, a autora evita vários vícios tão comuns em outras pesquisas, que empregam *soft computing* preponderantemente como uma nova ferramenta para obter velhos resultados.

Na Itália, Bosurgi e outros (Bosurgi et al., 2007) obtiveram bons resultados no desenvolvimento de modelo para a predição do coeficiente de atrito pneu-pavimento (*Sideway Force Coefficient, SFC*) em rodovias italianas empregando redes neurais artificiais (ANN). O modelo foi desenvolvido utilizando-se como variáveis as mensurações em campo (na rodovia) do SFC, nos anos de 1997, 2001, 2002 e 2003, e o tráfego dos veículos no mesmo período. As redes neurais foram treinadas utilizando um conjunto de dados para treinamento. Os resultados das predições efetuadas pelas redes neurais foram comparados com os resultados obtidos em campo, utilizando um conjunto de dados para testes (Figura 3-13), e comparadas com um método tradicional de predição do SFC, o *Least Mean Square (LMS)*. Segundo Bosurgi, as redes neurais são adequadas para predições de comportamentos de pavimentos, tendo demonstrado, neste estudo, sua eficácia e potencial.




Figura 3-13 – Dados de SFC medidos em campo comparados com os preditos pelas redes neurais (Bosurgi et al., 2007)

Bosurgi e outros (Bosurgi et al., n.d.) também estudaram o emprego de redes neurais na gerência da infra-estrutura rodoviária, ou seja, dos pavimentos, utilizando dados do Departamento de Transportes do Estado do Arizona (*Arizona Department of Transportation*,

ADOT). A gerência de pavimentos otimiza a distribuição dos recursos financeiros pela malha rodoviária do Arizona, recomendando os trechos de rodovias que devem receber manutenção, bem como o tipo de manutenção, visando manter a malha rodoviária na melhor condição possível com o emprego dos recursos financeiros disponíveis. As redes neurais foram treinadas utilizando dados de otimizações efetuadas anteriormente (utilizando técnicas tradicionais) pelo ADOT, apresentando como resultados uma lista de segmentos de rodovias que devem ser consideradas para reabilitação do pavimento. De acordo com o autor, o estudo demonstrou o potencial das redes neurais no desenvolvimento de ferramentas analíticas para gestão de pavimentos, além de outras aplicações correlatas.

Também na Itália, Bosurgi e Trifirò (Bosurgi & Trifirò, 2005) empregaram ANN para a predição de acidentes na rodovia A-18, na província da Sicília, e algoritmos genéticos para a otimização das atividades de manutenção da rodovia considerando os acidentes. As variáveis utilizadas estão relacionadas com a geometria da rodovia (curvas, etc.), clima, presença de túneis e viadutos, quantidade de veículos em circulação na rodovia, coeficiente de atrito do pavimento asfáltico e número de acidentes ocorridos no período de três anos considerado no estudo, de 1996 a 1999; foram considerados 172 acidentes atribuídos às falhas na infra-estrutura da rodovia, tendo sido excluídos os demais, tais como os causados por alcoolismo do motorista. O estudo também englobou a sub-divisão da rodovia em segmentos homogêneos, prática comum na engenharia rodoviária.

As redes neurais foram treinadas utilizando o algoritmo LM e um conjunto de dados para aprendizado; então, foram avaliadas utilizando um conjunto de dados para testes, cujos resultados são apresentados na Figura 3-14.




Figura 3-14 - Número de acidentes ocorridos na rodovia A-18 comparados com número de acidentes preditos pelas ANN com dados de teste (Bosurgi & Trifirò, 2005)

Considerando o modelo desenvolvido com as redes neurais para acidentes, foi escrito um algoritmo genético para otimizar as atividades de manutenção do pavimento asfáltico. Novamente a rodovia foi avaliada com base na divisão em segmentos homogêneos. Para a codificação de todos os segmentos foram necessários 462 genes; as atividades de manutenção foram divididas em três categorias: (a) não-intervenção; (b) construção de camada de 5 cm de espessura de pavimento drenante (*porous asphalt*); e (c) camada de micro-revestimento com 1,5 cm de espessura (*slurry seal*). O total de soluções possíveis é de 3^{462} .

O resultado da otimização é apresentado na Tabela 3-5, onde é possível observar uma redução de 16% (otimização 1) e de 25% (otimização 2) no número de acidentes quando comparado com a não realização de qualquer intervenção de melhoria no pavimento.

De acordo com os autores, intervenções bem planejadas no pavimento permitem a redução no número de acidentes mediante a melhoria do coeficiente de atrito pneu-pavimento (SFC), permitindo uma melhor utilização dos recursos financeiros disponíveis.

Segundo os autores, o modelo desenvolvido pode servir de base para o desenvolvimento de outros, melhores e aperfeiçoados, com a inclusão de outras variáveis importantes para a ocorrência de acidentes, como a velocidade, condições de visibilidade e a distância (de segurança) entre os veículos.

Tabela 3-5 - Alocação ótima das intervenções e melhorias no coeficiente de atrito pneu-pavimento (SFC) (Bosurgi & Trifirò, 2005)

	Total number of accidents estimated	Average SFC	Sum not spent (Euro)
No intervention	188.75	32.75	4.000.000
Optimization problem 1	159.64	42.48	793
Optimization problem 2	143.04	42.15	793

Na África do Sul, Venayagamoorthy e outros (Venayagamoorthy et al., 2004) empregaram redes neurais para classificar diferentes tipos de estruturas de pavimentos de acordo com a categoria da rodovia, classe do tráfego e tipo de (camada de) base. Nos 30 casos do estudo, as redes neurais foram capazes de efetuar a classificação sem qualquer erro.

Posteriormente, Venayagamoorthy e Allopi (Venayagamoorthy & Allopi, 2007) empregaram redes neurais para a predição da capacidade de suporte de pavimentos. Foram utilizados pavimentos com estruturas granulares típicas de rodovias de primeira classe com a simulação de diversos tipos de cargas. Os resultados obtidos pelas redes neurais foram comparados com aqueles especificados pelo método de dimensionamento de pavimentos da África do Sul (*South African Mechanistic Design Method, SAMDM*). De acordo com os autores, as redes neurais conseguiram prever com sucesso as capacidades de suporte das estruturas avaliadas, apresentando potencial para serem utilizadas de forma mais ampla na área de pavimentação.

Na Índia, Thube e outros (Thube et al., 2006) desenvolveram um estudo sobre o emprego de redes neurais para a predição da deterioração de pavimentos em estradas de pequeno volume de veículos. Segundo os autores, de acordo com o HDM-4, um software desenvolvido pelo Banco Mundial para a gerência de pavimentos, a deterioração do pavimento ocorre devido a quatro fatores básicos: (a) tráfego, (b) envelhecimento do pavimento, (c) condições climáticas e (d) capacidade estrutural. Entre os anos de 2004 e 2006 foram coletados dados de 61 estradas de baixo tráfego para compor a base de dados utilizada no estudo. Foram desenvolvidos modelos para área trincada (*cracking*), deformações permanentes (*rut depth, rutting*) e perda de agregado (*ravelling*). Como variáveis de entrada (*inputs*) foi utilizado um amplo conjunto de parâmetros, seguindo os modelos do HDM-4, e como variáveis de saída (*outputs*) a área trincada, a área com perda de agregado e a profundidade da trilha de roda (Tabela 3-6).

Tabela 3-6 – Variáveis utilizadas nos modelos (Thube et al., 2006)

Model Description	ANN Input variable		ANN Output variable
	No.	Description of variables	
Cracking progression Model	26	Age in months; Initial cracking area ;sub grade properties-LL, PL, PI, Field moisture content, OMC,CBR(soaked),MDD;CRP; AADT details-MT,NMT,% of Truck volume; composition of commercial vehicles; Environmental factors-% duration of dry season, mean monthly precipitation, mean temperature degrees, average temperature range, no of days having temperature > 32 degrees; Geometric properties - R+F (m/km),horizontal curvature (degree/km), speed limit, no. of R+F per km; other parameters-CDS,CDB and CRP (as defined in HDM-4 Models)	Total cracking (% area)
Ravelling progression Model	26	Age in months; Initial ravelling area ;sub grade properties-LL,PL,PI,Field moisture content, OMC,CBR(soaked),MDD;CRP; AADT details-MT,NMT,% of Truck volume; composition of commercial vehicles; Environmental factors-% duration of dry season, mean monthly precipitation, mean temperature degrees, average temperature range, no of days having temperature > 32 degrees; Geometric properties - R+F (m/km),horizontal curvature (degree/km), speed limit, no of R+F per km ; other parameters-CDS,CDB and CRP (as defined in HDM-4 Models)	Total ravelling (% area)
Rut depth progression Model	29	Age in months, observed cracking, ravelling, edge break and pothole area during analysis period ,sub grade properties-LL, PL, PI, Field moisture content, OMC, CBR(soaked), MDD; CRP; AADT details-MT,NMT,% of Truck volume; composition of commercial vehicles; Environmental factors -% duration of dry season, mean monthly precipitation, mean temperature degrees, average temperature range, no of days having temperature > 32 degrees; Geometric properties-R+F (m/km), horizontal curvature(degree/km), speed limit, no of R+F per km ; Other parameters-CDS,CDB and CRP (as defined in HDM-4 Models)	Total Rut depth (in mm)

De acordo com os autores, as previsões obtidas através do emprego de redes neurais, para os três tipos de defeitos de pavimentos, são melhores e mais convenientes que aquelas obtidas mediante o uso dos modelos do HDM-4, uma vez que o software desenvolvido pelo Banco Mundial requer uma complexa calibração utilizando parâmetros locais. Os resultados obtidos na modelagem da área trincada são apresentados na Figura 3-15.

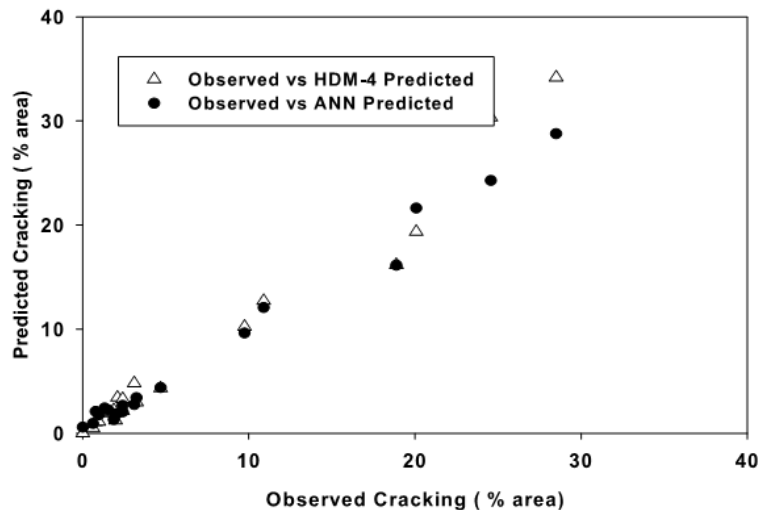


Figura 3-15 – Área trincada observada versus prevista pelo HDM-4 versus prevista pelas redes neurais artificiais (Thube et al., 2006)

No Estado de Illinois, Estados Unidos, foi efetuada uma pesquisa sobre o emprego de redes neurais e algoritmos genéticos na avaliação estrutural de pavimentos através de métodos não-destrutivos, mais especificamente para retroanálises (*backcalculation*) (Pekcan et al., 2008). Como resultado do estudo foram desenvolvidos, e validados com dados de campo, dois softwares que empregam técnicas de *soft computing*. O primeiro foi denominado ANN-Pro (Figura 3-16) e efetua a retroanálise de dados obtidos com o FWD e utilizando as espessuras (conhecidas) das diversas camadas do pavimento; caso as espessuras não sejam conhecidas, então são estimadas com o uso do segundo software, denominado SOFTSYS (*Soft Computing Based Pavement and Geomaterial System Analyzer*).

A retroanálise permite calcular os valores modulares e valores estruturais críticos (deformações e tensões) para as diversas camadas do pavimento e sub-leito a partir da aplicação de cargas conhecidas e mensuração das deformações produzidas. Possui grande importância para a avaliação da capacidade estrutural de pavimentos em serviço, pois os valores calculados são informações críticas para o dimensionamento do reforço ou reabilitação dos pavimentos asfálticos quando é utilizada uma abordagem empírico-mecanística.

Os dados de campo necessários para alimentar o software ANN-Pro são levantados com o emprego de Viga Benkelman (Figura 3-17) ou deflectômetros (*Falling Weight Deflectometer*, FWD) (Figura 3-18, Figura 3-19). São ensaios convenientes, baratos e rápidos; dispensam a coleta ou retirada de amostras e produzem pequena perturbação para o tráfego dos veículos.

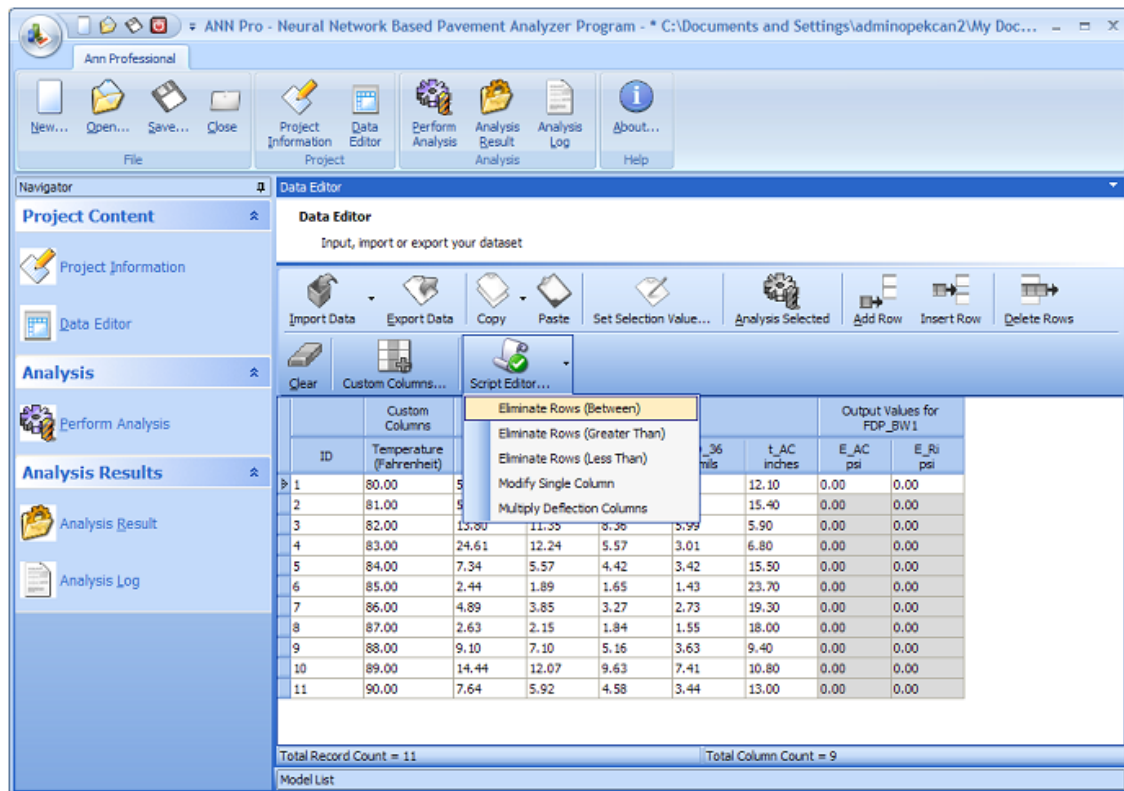


Figura 3-16 – Tela principal do ANN-Pro

Esta pesquisa é interessante e seus autores relatam plena satisfação com os resultados obtidos, mas de fato as ferramentas de *soft computing* foram utilizadas meramente como substitutas de soluções que utilizam elementos finitos e proporcionam resultados similares ou melhores.



Figura 3-17 – A Viga Benkelman é utilizada para medir as deformações do pavimento quando é aplicada uma carga conhecida (caminhão)



Figura 3-18 - Falling Weight Deflectometer (FWD)

Também em Illinóis, Estados Unidos, foi estudada a aplicação de redes neurais na predição de valores modulares de pavimentos asfálticos de aeroportos utilizando dados de campo levantados com o uso do HWD (*Heavy Weight Deflectometer*), que é um equipamento idêntico ao FWD, mas capaz de aplicar cargas maiores. (Gopalakrishna et al., 2007)




Figura 3-19 – Operação do Falling Weight Deflectometer com mensuração das deformações

As redes neurais foram treinadas utilizando os dados do HWD (*inputs*) e os valores modulares calculados com o software ILLI-PAVE (*outputs*), que utiliza elementos finitos para a retroanálise. Os resultados obtidos com o emprego das ANN foram comparados com os proporcionados pelo próprio ILLI-PAVE, onde observou-se que as predições para o módulo da camada asfáltica (*Asphalt Concret, AC*) foram muito similares (Figura 3-20), mas na predição do parâmetro n_b para as camadas de base (Figura 3-21) e sub-base (Figura 3-22) houveram diferenças significativas.

Os autores justificam o emprego de redes neurais em substituição ao ILLI-PAVE pelo fato de, na opinião deles, as redes neurais serem mais rápidas e proporcionarem resultados em tempo real, argumento que é questionável face ao poder computacional atualmente disponível.




Figura 3-20 – Retroanálise da camada de concreto asfáltico (AC) (Gopalakrishna et al., 2007)




Figura 3-21 – Predição do parâmetro n_b da camada de base (Gopalakrishna et al., 2007)

Previamente ao desenvolvimento do ANN-Pro, Ceylan e outros (Ceylan et al., 2004) já haviam utilizado com sucesso redes neurais artificiais (ANN) na análise estrutural de pavimentos asfálticos de Illinois, incluindo a predição de valores estruturais críticos (tensões e deformações) e perfis deflectométricos, com o treinamento das redes igualmente efetuado com dados produzidos pelo software ILLI-PAVE, que é capaz de considerar a não-linearidade dos materiais de pavimentação.




Figura 3-22 - Predição do parâmetro n_s da camada de sub-base (Gopalakrishna et al., 2007)

Na China, Cal (Cal, 1995) empregou redes neurais para a classificação de solos utilizando três fatores básicos - (a) o índice de plasticidade, (b) o limite de liquidez e o (c) teor de argila – para classificar seis diferentes tipos de solos argilosos. As redes neurais foram treinadas com o emprego do algoritmo de *backpropagation* e, nas predições efetuadas pelo autor, as ANN apresentaram 100% de acurácia.


Na Turquia foi desenvolvido outro estudo para solos. Taskiran (Taskiran, 2010) utilizou ANN (*Artificial Neural Network*) e GEP (*Gene Expression Programming*) para a predição dos valores de CBR (*California Bearing Ratio*) para solos turcos. Foram desenvolvidos sete modelos (Tabela 3-7) treinados a partir de uma base de dados contendo os valores de CBR (*outputs*) e diferentes variáveis de entrada (*inputs*), selecionadas dentre sete propriedades básicas dos solos - limite de liquidez (LL), índice de plasticidade (PI), peso unitário seco (γ_d), umidade ótima (W_{opt}), percentual passante na peneira #200 (clay + silt; C + S), percentual de areia (S) e percentual de pedregulho (G).

Segundo o autor, tanto os modelos desenvolvidos com ANN quando aqueles com GEP conseguem prever com sucesso os valores de CBR (Figura 3-23), tendo apresentado melhor correlação ($R^2 = 0,91$) que a proporcionada por outras metodologias de predição, tais como o método do *NCHRP* e o método *Agarwal and Ghanekar*, que apresentaram R^2 de 0,74 e 0,50, respectivamente, para o mesmo conjunto de dados. Os modelos podem ser utilizados no controle de qualidade deste tipo de ensaio de laboratório.


Adicionalmente, foi efetuada a análise de sensibilidade onde se constatou que o peso unitário seco (γ_d) é a variável com mais influência nos valores de CBR (Figura 3-24).

Tabela 3-7 – Modelos utilizados para a predição do CBR (Taskiran, 2010)

Model	Inputs	Structure (ANN)	Transfer function (ANN)
I	(LL), (PI), γ_k , w_{opt} , (C+S), S, G	7-4-1	logsig–logsig
II	(LL), (PI), γ_k , w_{opt} , (C+S), S,	6-5-1	tansig–tansig
III	(PI), γ_k , w_{opt} , (C+S), S	5-4-1	logsig–logsig
IV	(PI), γ_k , w_{opt} , (C+S)	4-4-1	tansig–tansig
V	(PI), γ_k , (C+M), S	4-5-1	logsig–logsig
VI	(PI), γ_k , (C+M)	3-4-1	logsig–logsig
VII	γ_k , (C+M), w_{opt}	3-5-1	logsig–logsig

**Figura 3-23 - Correlação entre o CBR predito utilizando ANN e GEP e o CBR determinado experimentalmente em laboratório (Taskiran, 2010)**

No Canadá, Zeghal (Zeghal, 2008) considerou promissores os resultados da aplicação de redes neurais (ANN) para estimar o módulo dinâmico do concreto asfáltico a partir da granulometria do agregado, volume de vazios e tipo de ligante asfáltico. O módulo dinâmico é necessário para o dimensionamento de pavimentos através do método da AASHTO 2002; a sua determinação requer equipamentos especiais e técnicos altamente especializados, demanda tempo e implica em custos elevados.

**Figura 3-24 – Análise de sensibilidade dos valores de CBR (Taskiran, 2010)**

Em rodovias de menor importância, onde tais custos não se justificam, o método da AASHTO 2002 permite que o módulo dinâmico seja estimado através de uma equação-modelo (Equação 3-1).

$$\log |E^*| = -1.249937 + 0.029232P_{200} - 0.001767(P_{200})^2 + 0.002841P_4 - 0.058097V_a - 0.802208 \frac{V_{beff}}{(V_{beff} + V_a)} + \frac{[3.871977 - 0.0021P_4 + 0.00395P_{38} - 0.000017(P_{38})^2 + 0.00547P_{34}]}{1 + e^{(-0.603313 - 0.313351 \log f - 0.393532 \log \eta)}}$$

where

$|E^*|$ = Asphalt mix dynamic modulus, in 10^5 psi,

η = Bitumen viscosity, in 10^6 poise,

f = Loading frequency, in Hz,

V_a = Percent air voids in the mix, by volume,

V_{beff} = Percent effective bitumen content, by volume,

P_{34} = Percent retained on 3/4-inch sieve, by total aggregate weight (cumulative),

P_{38} = Percent retained on 3/8-inch sieve, by total aggregate weight (cumulative),

P_4 = Percent retained on No. 4 sieve, by total aggregate weight (cumulative), and

P_{200} = Percent passing No. 200 sieve, by total aggregate weight.

Equação 3-1 - Equação para estimar o módulo dinâmico do concreto asfáltico conforme o método da AASHTO 2002 (Zeghal, 2008)

Conforme Zeghal (Zeghal, 2008) constatou em seu estudo, as predições efetuadas com o modelo do método da AASHTO 2002 (Equação 3-1) apresentou um erro relativo absoluto de 77% em relação aos valores modulares determinados em laboratório, enquanto as predições efetuadas pelas redes neurais apresentaram um erro relativo absoluto muito inferior, de 25%.

Bianchini e Bandini (Bianchini & Bandini, 2010) estudaram o emprego de *Neuro-Fuzzy Reasoning* na predição do comportamento de pavimentos asfálticos a partir de deflexões coletadas com FWD e levantamentos de defeitos na superfície do pavimento, informações rotineiramente coletadas e utilizadas pelos departamentos de transportes para seus sistemas de gerência de pavimentos.

Mais especificamente, foram utilizados como variáveis de entrada (*inputs*) sete parâmetros:

1. Índice de curvatura da superfície, calculado a partir das deflexões medidas com FWD nas distâncias de zero e 30, 48 cm do ponto de aplicação da carga;
2. Deflexão a 91, 44 cm;
3. Área sob o perfil do pavimento (*Area Under the Pavement Profile, AUPP*), calculado a partir das deflexões;
4. Profundidade da trilha de roda;
5. Percentual da área trincada com alta severidade;

6. Espessura da camada de concreto asfáltico;
7. Número equivalente de eixos-padrão (ESAL) que trafegaram no pavimento no período de tempo considerado.

Como variável de saída (*output*) foi utilizado o índice presente de serventia (PSI) modificado por Hall e Muñoz (Hall & Muñoz, 1999), baseado no IRI (*International Roughness Index*) e não aquele tradicionalmente empregado nas versões do método da AASHTO até 1993. A base de dados utilizada no estudo foi a do *Mn/Road Test Facility*, dos Estados Unidos.

Conforme as autoras, os cinco modelos desenvolvidos, um para cada condição climática identificada, foram capazes de prever as alterações no PSI de forma mais acurada que a metodologia tradicional, baseada em regressão multi-linear, quando avaliado o R^2 (Tabela 3-8).

Bayrak e outros (Bayrak et al., 2004) utilizaram ANN para prever o IRI (*International Roughness Index*) em pavimentos rígidos. Foram empregados dados de 83 seções de pavimentos existentes na base de dados do Programa LTPP (*Long Term Pavement Performance*). As variáveis empregadas (*inputs*) incluíram o IRI inicial, idade do pavimento, tráfego e trincas transversais para três níveis de severidade (baixa, média e alta); como variável de saída (*output*) foi utilizado o IRI medido nos pavimentos.

Os modelos, desenvolvidos com algoritmo de *backpropagation*, foram capazes de prever o IRI com boa acurácia, apresentando R^2 de 0,84 e 0,81 para os conjuntos de dados de treinamento (Figura 3-25) e de testes, respectivamente.

Tabela 3-8 – Acurácia do Modelo Neuro-Fuzzy comparada com um modelo multi-linear tradicional (Bianchini & Bandini, 2010)

<i>Season</i>	<i>Model</i>	R^2	<i>rmse</i>	μ_{err}
I	Neuro-fuzzy	0.9872	0.0599	0.0464
	Multiple linear regression	0.8766	0.2570	0.204
II	Neuro-fuzzy	0.9604	0.1261	0.0876
	Multiple linear regression	0.8022	0.3790	0.268
III	Neuro-fuzzy	0.9697	0.1107	0.0787
	Multiple linear regression	0.9196	0.2496	0.187
IV	Neuro-fuzzy	0.8745	0.1529	0.102
	Multiple linear regression	0.8088	0.2535	0.186
V	Neuro-fuzzy	0.9349	0.1213	0.0766
	Multiple linear regression	0.8724	0.2272	0.177

Aultman-Hall e outros (Aultman-Hall et al., 2004) empregaram redes neurais e outras técnicas estatísticas para o estudo de correlações entre o IRI e a área trincada e profundidade da trilha de roda a partir de dados de pavimentos asfálticos de rodovias do Estado de Connecticut abertas ao tráfego real e com extensão de 650 km. O objetivo da pesquisa foi explorar a possibilidade de utilizar o IRI na estimativa dos defeitos dos pavimentos.




Figura 3-25 - IRIs predito pelas ANN versus IRIs reais medidos nos pavimentos

Os defeitos dos pavimentos, incluindo área trincada e profundidade de trilha de roda, foram verificados através de imagens ortogonais dos pavimentos (Figura 3-10) e sensores ultrassônicos (Figura 3-26), respectivamente, coletadas com veículo apropriado. A área trincada foi calculada com o software Wisecrux (Figura 3-27).




Figura 3-26 - Equipamento para medir a profundidade da trilha de roda (*rutting*)

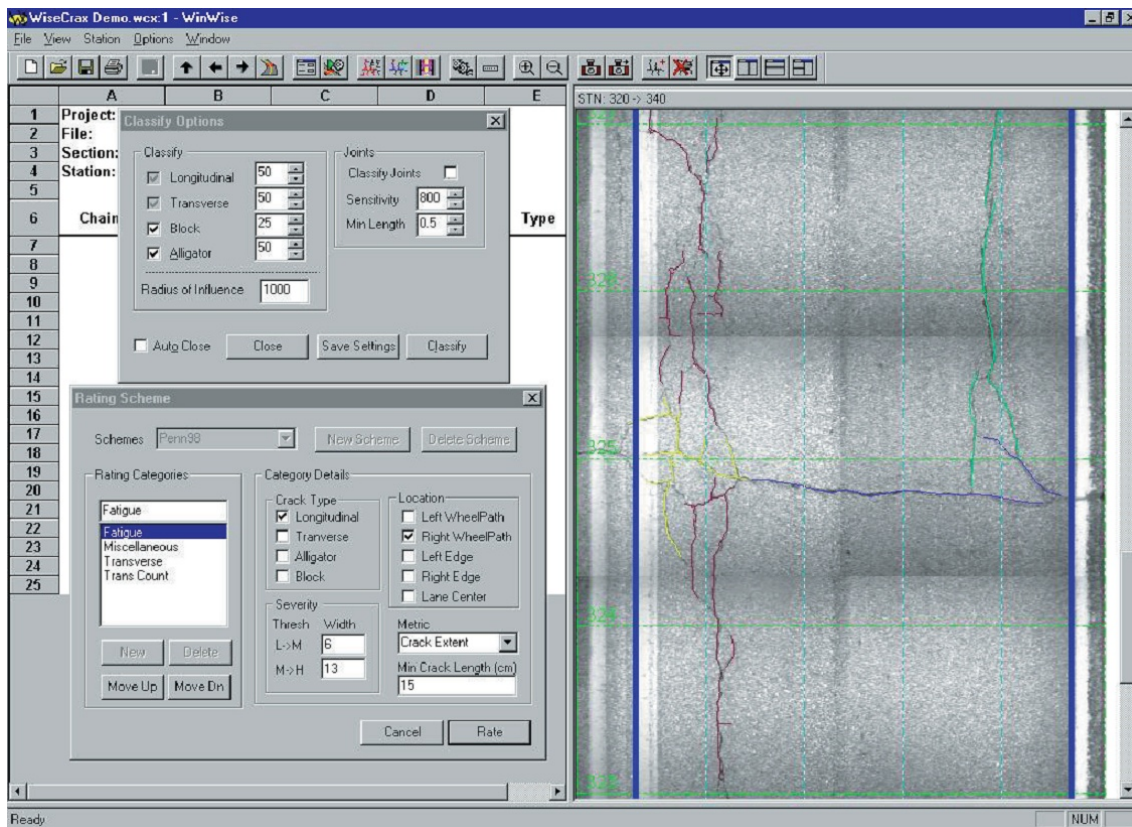


Figura 3-27 - Software Wisecrux para identificação e cálculo da área trincada dos pavimentos

Os resultados foram comparados com aqueles obtidos na pista de testes Westrack, onde foi verificada boa correlação ($R^2 = 0,71$) entre o IRI e os defeitos do pavimento (Equação 3-2), mas também indica forte dependência do IRI em relação ao IRI inicial (IRI_{init}).

$$IRI = 0.597(IRI_{init}) + 0.0094(Fatigue \%) + 0.00847(RutDepth) + .0382$$

$$R^2 = 0.71$$

Equação 3-2 – Correlação dos defeitos do pavimento com o IRI

Empregando redes neurais, através da análise de sensibilidade os autores (Aultman-Hall et al., 2004) identificaram que o IRI depende muito mais da profundidade de trilha de roda do que da área trincada, mas que a correlação entre eles não é suficientemente significativa para que o IRI possa ser utilizado para estimar a severidade dos defeitos dos pavimentos em rodovias abertas ao tráfego real.

Dosagens de concretos asfálticos, ou seja, a determinação das proporções adequadas de agregado pétreo brigado, nas suas diversas granulometrias, e de ligante asfáltico são tradicionalmente efetuadas utilizando o método Marshall. Na Turquia, Tapkin e outros (Tapkin

et al., 2010) desenvolveram um interessante estudo para a predição das propriedades Marshall em corpos de concreto asfáltico modificados com fibras de polipropileno empregando redes neurais treinadas com algoritmo de *backpropagation* (Tabela 3-9).

Tabela 3-9 - Algoritmos de *backpropagation* utilizados no treinamento das redes neurais (Tapkın et al., 2010)

MATLAB function name	Algorithm
trainbfg	BFGS quasi-Newton back propagation
traincgf	Fletcher–Powell conjugate gradient back propagation
traincgp	Polak–Ribiere conjugate gradient back propagation
traingd	Gradient descent back propagation
traingda	Gradient descent with adaptive linear back propagation
traingdx	Gradient descent w/momentum and adaptive linear back propagation
trainlm	Levenberg–Marquardt back propagation
trainoss	One step secant back propagation
trainrp	Resilient back propagation (Rprop)
trainscg	Scaled conjugate gradient back propagation

As redes neurais foram alimentadas (*inputs*) com o tipo de fibra de polipropileno, percentual de fibras de polipropileno, teor de ligante asfáltico, espessura do corpo de prova (o diâmetro é padronizado em 10 cm), densidade, vazios do agregado mineral (V.M.A.), volume de vazios (*air void*) e volume de ligante asfáltico para predizer (*outputs*) a estabilidade Marshall, fluência (*flow*) e quociente Marshall obtidos em ensaios mecânicos, conforme previsto no método Marshall (Tabela 3-10).

Tabela 3-10 – Resultados do ensaio Marshall para concretos asfálticos contendo 3% de polipropileno (Tapkın et al., 2010)

Bitumen content (%)	V.M.A. (%)	Air void (%)	Unit weight (kg/m ³)	Stability (kg)	Flow (mm)	Marshall Quotient
3.5	17.275	9.168	2361	1455	3.44	423.0
4.0	17.029	7.787	2379	1394	3.69	377.8
4.5	16.463	6.038	2407	1492	4.62	323.0
5.0	15.913	4.294	2434	1471	3.61	407.5
5.5	15.634	2.845	2454	1273	3.75	339.5
6.0	16.114	2.275	2452	973	4.53	241.8
6.5	17.105	2.319	2434	829	5.72	144.9
7.0	18.109	2.298	2418	725	7.19	100.8

Segundo os autores, os modelos desenvolvidos conseguem predizer os valores de estabilidade, fluência e quociente Marshall com excelente acurácia, apresentando R² de 0,97, 0,81 e 0,87,

respectivamente, para as amplitudes de valores testados. Os modelos podem ser utilizados para o controle de qualidade de futuros ensaios Marshall ou para estimar tais valores em projetos de pequena responsabilidade, evitando-se ensaios de laboratórios que demandam tempo e custos.

3.4 Conclusões

A análise dos métodos atualmente em uso para pavimentos asfálticos empíricos e empírico-mecanísticos permite concluir que tais metodologias provavelmente eram adequadas à realidade técnica e econômica da época em que foram criados, há meio século, mas desde então a realidade se modificou e as necessidades técnico-econômicas aumentaram.

Atualmente o número de veículos nas rodovias aumentou exponencialmente, os veículos de carga são muito mais pesados, tendo evoluído da capacidade de 9 toneladas nos anos 1960s para mais de 80 toneladas atualmente, e o custo da mão-de-obra e dos materiais de construção dos pavimentos aumentaram muitas vezes. Paralelamente surgiram outros fatores que pressionam e impõe maiores dificuldades, tais como as crescentes restrições de natureza ambiental, que dificultam ou impedem a exploração de jazidas e seguidamente impõe que rochas e outros materiais sejam transportados por grandes distâncias; queda e irregularidade na qualidade dos produtos asfálticos e; redução dos recursos públicos para a área rodoviária.

As limitações dos métodos empíricos e empírico-mecanísticos tem ocasionado elevadas taxas de falha prematura e custos de manutenção maiores, devido aos sub-dimensionamentos, ou custos iniciais superiores ao ideal, devido ao super-dimensionamento, em ambos os casos proporcionando relações custo-benefício ruins (University of Minnesota, 1999). A introdução e uso de novos e melhores materiais de pavimentação também fica prejudicada (Brown, 1978).

O método da AASHTO 2002, anunciado com grande euforia, tem se mostrado de difícil aplicação prática e não proporciona praticamente nenhum avanço técnico real na compreensão ou modelagem do comportamento dos pavimentos. A suposta melhor acurácia deste método está baseada em uma complexa calibragem dos seus modelos de desempenho, que são empírico-mecanísticos; tal calibragem depende de trechos experimentais de pavimentos que existem apenas em poucos estados dos Estados Unidos, inviabilizando a utilização do método em larga escala. Mesmo onde tais trechos experimentais existem, como no caso do Texas, a calibragem tem se mostrado difícil e o método da AASHTO 2002 sequer é aceito para dimensionamentos de rodovias a serem construídas ou reabilitadas. O software que acompanha o método, cuja última versão é de agosto de 2009, permanece em versão beta com a advertência expressa de que não deve ser utilizado para dimensionamentos, mas apenas para avaliação.

Dos estudos avaliados e que empregam técnicas de inteligência artificial como ferramentas de apoio à engenharia de pavimentos, todos utilizaram tais ferramentas em substituição a outros tipos de métodos ou softwares que já são utilizados, se traduzindo uma nova forma de obter velhos resultados. Basicamente são empregadas as mesmas variáveis de entrada (*inputs*) com vistas à obtenção dos mesmos resultados (*outputs*). Embora possam haver melhorias na

acurácia, correlações e mesmo velocidade de processamento devido ao emprego de redes neurais e outras técnicas de *soft computing*, não houve qualquer mudança de paradigma ou real progresso na compreensão ou modelagem dos comportamentos estudados.

O único estudo que fugiu a esta regra foi desenvolvido por Miradi (Miradi, 2009) e, apesar do avanço na abordagem e paradigma empregados, foram ignorados fatores importantes para a degradação dos pavimentos tais como os efeitos da combinação do tráfego (velocidade, carga, etc.) e clima (temperatura, condições pluviométricas, etc.) e mesmo variáveis extremamente importantes como a espessura das camadas dos pavimentos na avaliação da deterioração da camada asfáltica, além de se tratar de um estudo visando identificar padrões de comportamento, e não desenvolver modelos de predição desempenho.

Talvez a principal conclusão que se pode obter a partir dos estudos aqui avaliados é de que uma engenheira de software (Miradi, (Miradi, 2009)), sem qualquer conhecimento aprofundado sobre os pavimentos asfálticos, foi capaz de efetuar uma avaliação melhor que aquela efetuada por (pretensos) especialistas de pavimentos, o que sugere que os problemas relacionados com a engenharia de pavimentos podem ser muito mais de ordem cultural do que propriamente tecnológica.

capítulo 4

4 INTELLIPave, UMA NOVA ABORDAGEM PARA A PAVIMENTAÇÃO ASFÁLTICA

4.1 Introdução

O Método INTELLIPave foi elaborado a partir do zero, desde seus mais profundos conceitos teóricos, e não se baseia nem utiliza partes de nenhum outro método ou trabalho desenvolvido nesta área. Este novo método visa utilizar a capacidade das redes neurais e outras topologias de *soft computing* de replicar conhecimentos complexos para a predição da performance de pavimentos asfálticos, empregando uma abordagem totalmente desconectada dos métodos empíricos e empírico-mecanísticos atualmente em uso.

Embora tenha sido desenvolvida para pavimentos asfálticos, esta nova abordagem pode ser facilmente adaptada para outros tipos de pavimentos, como os rígidos ou em ladrilhos, e mesmo para outros tipos problemas não vinculados à engenharia de pavimentos.

4.2 Premissas

O método desenvolvido nesta pesquisa segue algumas premissas básicas que buscam superar ou evitar problemas e limitações encontrados em outras metodologias e estudos.

1. Tráfego: os veículos que circulam pela rodovia, ou seja, **o tráfego, é considerado em escala real**, com o abandono de qualquer tipo de simplificação ou eixos-padrão (ESAL).
2. Clima: **o clima é considerado em escala real**, com a eliminação dos conceitos de temperatura padrão ou de referência. São consideradas todas as variáveis climáticas

relevantes, com os dados recolhidos com estações meteorológicas automatizadas e dados registrados, preferencialmente, em intervalos não superiores a uma hora.

3. Período de tempo e envelhecimento dos materiais: **comportamento do pavimento em escala real**, contemplando toda a vida de serviço do mesmo, o que inclui o **envelhecimento dos materiais asfálticos** e o **fenômeno da auto-reparação**, sem qualquer simplificação, extrapolação ou ajuste; sem reduzir o comportamento aos chamados valores críticos (extensão na última fibra da camada asfáltica e deformação no topo do sub-leito). Devem ser empregados exclusivamente dados de campo e os materiais devem atender a determinadas normas ou especificações que precisam ser suficientemente rigorosas para que, pavimentos diferentes construídos com base nas mesmas especificações, possam ser considerados iguais.
4. Condições reais de operação: devem **ser contempladas todas as combinações de tráfego** (velocidade, carga por eixo, etc.) e **clima** (temperatura do ar, temperatura do pavimento, pluviosidade, etc.) em **escala real**, veículo por veículo, para toda a vida de serviço do pavimento.
5. Acúmulo do conhecimento: a nova metodologia deve permitir que o **conhecimento seja acumulado de forma científica e racional** para posterior reutilização, de tal forma que quanto mais conhecimento estiver acumulado, mais acuradas serão as predições de comportamento dos pavimentos efetuadas posteriormente.
6. Tolerante às limitações dos dados: deve contemplar o fato de que é virtualmente impossível identificar e mensurar absolutamente todas as variáveis com influência na durabilidade dos pavimentos; o método INTELLIPave **deve ser tolerante às limitações dos dados disponíveis e ser capaz** de considerar, mesmo que de forma indireta, **as variáveis desconhecidas ou sem dados disponíveis**.
7. Critérios de falha do pavimento: a metodologia deve estar em linha com as observações de campo onde verifica-se que o pavimento falha em tempos diferentes para diferentes critérios de falha, contemplando a possibilidade de que **seja adotado como critério de falha, qualquer tipo de parâmetro**.

4.3 Síntese e estrutura básica do método INTELLIPave

A estrutura do método é relativamente simples. Os dados coletados em campo, contendo informações a respeito dos veículos, do clima e, se disponíveis, da resposta estrutural do pavimento, são armazenados em uma base de dados unificada, organizada *por veículo* que circulou no pavimento, até que o pavimento seja considerado inadequado (falhe) de acordo com o critério de falha considerado, formando uma matriz de números. O critério de falha é melhor discutido no item “4.7” enquanto os problemas relacionados à coleta de dados sobre a resposta estrutural dos pavimentos são discutidos no item “4.4.1”.

A matriz de números é, então, *carbotizada* (ou otimizada) com o emprego de técnicas de *soft computing* (redes neurais, *particle swarm*, SVM, etc.) e métodos numéricos de tal forma a determinar a importância relativa de cada veículo para a degradação do pavimento (RPDI, na sigla em inglês), ou seja, a importância relativa de cada veículo em relação a todos os demais veículos.

A matriz de números contendo os respectivos RPDIs é denominada matriz de performance (ou modelo unitário) e possui o conhecimento completo a respeito do comportamento e performance do pavimento para um determinado conjunto de situações. Duas ou mais matrizes de performance trabalhando de forma integrada em paralelo constituem um CUIA Model (Figura 4-1).

O processo de carboteamento também permite a análise de sensibilidade, identificando a importância de cada variável para a degradação do pavimento. Estas informações são muito úteis para a compreensão do comportamento do pavimento e atividades como o desenvolvimento de materiais de pavimentação melhores, entre outras, mas não são necessárias para a modelagem e previsão de comportamento através do CUIA Model, que requer somente os RPDIs.

A matriz de performance é então utilizada como fonte de conhecimento na previsão da performance dos pavimentos asfálticos. Esta previsão pode ser efetuada com o emprego de várias técnicas de *soft computing*, tais como redes neurais treinadas com a matriz de performance, como exemplificado na Figura 4-2, outras técnicas como *árvore de decisões*, ou mesmo *sistemas híbridos* (árvores de decisão + redes neurais, *et cetera*).

A Figura 4-2 mostra o diagrama geral do método INTELLIPave com os vários passos para transformar a base de dados “bruta” em uma fonte de conhecimento; neste diagrama são utilizadas redes neurais como ferramenta de replicação do conhecimento armazenado na matriz de performance, mas poderiam ser outras.



Figura 4-1 - Símbolo do CUIA Model



Figura 4-2 – Diagrama geral de funcionamento do método INTELLIPave

A forma como o método INTELLIPave é utilizado para as predições dos pavimentos asfálticos em nada lembra os métodos empíricos ou empírico-mecanísticos. O pavimento que será avaliado ou dimensionado precisa ser descrito com as mesmas informações existentes no próprio modelo, ou seja, dados sobre os veículos, clima e pavimento. O sistema irá, então, com base no modelo, avaliar a importância relativa de cada veículo (RPDI) que transitará pelo pavimento em análise.

O somatório dos danos relativos no pavimento em análise é comparado com o somatório dos danos relativos do modelo (RPDIs) que, então, determinará se o pavimento em análise atende ou não ao critério de falha do modelo, seguindo a interpretação da Tabela 4-1. Obviamente, parte-se do pressuposto de que o pavimento utilizado como modelo apresenta uma relação custo-benefício ótima.

Tabela 4-1 – Interpretação do resultado da modelagem utilizando a metodologia INTELLIPave

Se			Significa que
O somatório dos RPDIs do pavimento em análise é	maior que o	somatório dos RPDIs do modelo	O pavimento está sub-dimensionado e terá durabilidade inferior ao modelo. As espessuras precisam ser aumentadas para evitar manutenção onerosa e prematura
	similar ao		O pavimento proposto está bem dimensionado e apresentará durabilidade similar àquela do modelo
	menor que o		O pavimento está super-dimensionado e terá durabilidade superior ao modelo. As espessuras podem ser diminuídas para evitar custos iniciais superiores ao ideal

A Figura 4-3 apresenta um exemplo esquemático de modelo para predição da performance de pavimentos asfálticos (matriz de performance) onde o critério de falha é 20% da área superficial do pavimento trincada. Para facilitar a compreensão, neste modelo esquemático, simplificado e hipotético o critério de falha é atingido exatamente aos 10 anos de idade do pavimento e a questão do envelhecimento dos materiais é omitida (ver item “4.9”).

A Figura 4-4 traz um exemplo esquemático e hipotético de aplicação do modelo apresentado na Figura 4-3, onde verifica-se que o pavimento falha, de acordo com o critério de falha utilizado, após 7 anos, 10 meses e 7 dias; ou 7,85 anos.

A interpretação do resultado é simples. Se a modelagem refere-se ao dimensionamento de um pavimento novo, significa que será atingida a área trincada de 20% após 7,85 anos. Caso seja um pavimento existente, os 7,85 anos começam a contar na data em que o pavimento foi aberto ao tráfego; a vida útil remanescente pode ser calculada a partir da vida útil estimada (7,85 anos) subtraída da idade atual do pavimento.

Neste exemplo (Figura 4-3) são empregadas redes neurais como máquina de cálculo para aplicação do modelo, mas poderiam ser outras ferramentas.

Nos itens apresentados na seqüência deste trabalho são discutidos em detalhes cada um dos aspectos que compõe o método INTELLIPave.

Nº Veículo	Data	Clima			Veículos			Índice relativo de dano ao pavimento (RPDI)	Critério de falha: área trincada do pavimento
		Temperatura do ar	Pluviosidade	...	Velocidade	Carga no eixo 1	...		
1	01/JAN/1991	25	0	...	77	7	...	84,5	0
2	01/JAN/1991	25	0	...	66	13	...	97,0	0
3	01/JAN/1991	25	0	...	87	8	...	92,5	0
4	01/JAN/1991	25	0	...	94	0,6	...	73,8	0
5	01/JAN/1991	25	0	...	99	3	...	83,5	0
6	01/JAN/1991	25	0	...	88	5	...	84,0	0
7	01/JAN/1991	25	0	...	62	11	...	89,0	0
8	01/JAN/1991	26	0	...	93	9	...	99,5	0
9	01/JAN/1991	26	0	...	97	0,6	...	76,3	0
10	01/JAN/1991	26	0	...	110	4	...	93,0	0
11	01/JAN/1991	26	0	...	75	6	...	81,5	0
12	01/JAN/1991	26	88	3	0
13	01/JAN/1991	26	82	2	0
14	01/JAN/1991	26	84	5	0
15	01/JAN/1991	26	95	7	0
16	01/JAN/1991	26	0	...	93	9	0
...
5666997	31/DEZ/2000	12	32	...	82	2	...	123,0	20
5666998	31/DEZ/2000	13	33	...	84	5	...	136,0	20
5666999	31/DEZ/2000	13	33	...	62	11	...	143,0	20
5667000	31/DEZ/2000	13	33	...	66	13	...	151,0	20
5667001	01/JAN/2001	13	33	...	77	11	...	Σ 26.136.620.157,0	21

BASE DE DADOS PARA CRIAÇÃO DO MODELO

MATRIZ DE PERFORMANCE

Figura 4-3 - Exemplo esquemático de modelo baseado na matriz de performance e onde o critério de falha é 20% da área trincada

Nº Veículo	Data	Clima			Veículos			Índice relativo de dano ao pavimento (RPDI)	Índice relativo de dano ao pavimento (RPDI) acumulado
		Temperatura do ar	Pluviosidade	...	Velocidade	Carta no eixo 1	...		
1	01/JAN/2011	23	0	...	79	11	...	84,5	84,5
2	01/JAN/2011	23	0	...	71	9	...	97,0	181,5
3	01/JAN/2011	23	0	...	66	5	...	92,5	274
4	01/JAN/2011	23	0	...	88	8	...	73,8	347,8
5	01/JAN/2011	23	0	83,5	431,3
6	01/JAN/2011	23	0	84,0	515,3
7	01/JAN/2011	23	0	89,0	604,3
8	01/JAN/2011	24	0	99,5	703,8
9	01/JAN/2011	24	0	76,3	780,1
10	01/JAN/2011	24	0	93,0	873,1
11	01/JAN/2011	24	0	81,5	954,6
12	01/JAN/2011	24	0	79,0	1033,6
13	01/JAN/2011	24	0	...	83	4	...	73,0	1106,6
14	01/JAN/2011	24	0	...	85	2	...	83,0	1189,6
15	01/JAN/2011	24	0	...	87	0,3	...	94,5	1284,1
16	01/JAN/2011	24	0	...	92	0,9	...	99,5	1383,6
...
11353883	07/OUT/2017	9	19	...	83	2	26.136.619.727,0
11353884	07/OUT/2017	10	20	...	85	4	...	136,0	26.136.619.863,0
11353885	07/OUT/2017	10	20	...	71	5	...	143,0	26.136.620.006,0
11353886	07/OUT/2017	10	20	...	71	2	...	151,0	26.136.620.157,0
11353887	07/OUT/2017	11	20	...	88	13

O pavimento em análise (ou dimensionamento) terá uma vida útil de 7 anos, 10 meses e 7 dias, data em que atingirá 20% da área trincada.
 O final da vida útil é atingido quando o somatório dos índices relativos de dano ao pavimento (\sum RPDI) do pavimento em análise for igual ao somatório dos RPDI do modelo.

BASE DE DADOS PARA APLICAÇÃO DO MODELO

Determinado pelas redes neurais com base no modelo da Figura 4-3

Figura 4-4 - Modelagem ou dimensionamento efetuado com base no modelo da Figura 4-3 onde verifica-se que o pavimento vai atingir o critério de falha antes de completar oito anos de serviço

4.4 A base de dados e as variáveis

O conhecimento sobre a performance dos pavimentos asfálticos está intrinsecamente armazenado na combinação de variáveis identificadas ao longo de décadas de observações empíricas. Estas variáveis podem ser classificadas em três grupos: (a) clima, (b) veículos e (c) resposta estrutural/funcional dos pavimentos asfálticos (Salini et al., 2008). Embora as observações empíricas tenham permitido identificar as principais variáveis associadas com a durabilidade dos pavimentos, não permitiram qualificar nem quantificar a influência de cada variável nem o resultado das suas combinações.

A Figura 4-5 apresenta um esquema com as variáveis climáticas desejáveis. A Figura 4-6 apresenta as variáveis que descrevem as cargas que atuam sobre a estrutura do pavimento, ou seja, os veículos; a Figura 4-7 apresenta um arranjo alternativo, mais simples, onde a carga por eixo é removida e são adicionados o peso total e a classificação (Figura 4-8).

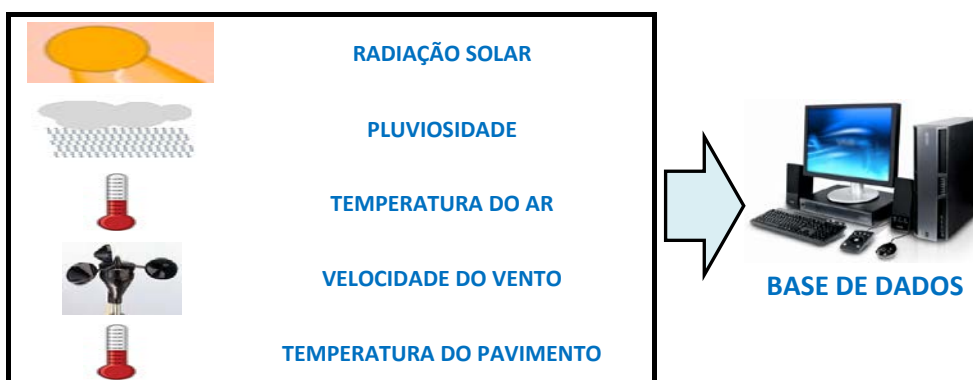


Figura 4-5 – Variáveis climáticas desejáveis para a construção de um modelo de desempenho

A Figura 4-9 traz a relação das variáveis associadas à resposta estrutural do pavimento asfáltico; os problemas relacionados aos sensores eletrônicos que praticamente inviabilizam da leitura em campo da resposta estrutural do pavimento são discutidos no item “4.4.1”, e a forma de superar esta limitação é discutida no “4.11”.

Todos os dados (clima, veículos e, na improvável hipótese de existirem disponível, também a resposta estrutural do pavimento) devem ser armazenados em uma única base de dados onde os valores são registrados no momento da passagem de cada um dos veículos que transitam pela rodovia.

A vida de serviço do pavimento não se reduz de forma linear ou constante, então é necessário coletar os dados até que seja atingido o fim da vida útil do pavimento segundo algum critério pré-estabelecido, o que implica em coletar dados por vários anos. O critério de falha é melhor

discutido no item “4.7” enquanto a consideração da não-linearidade da degradação e o envelhecimento dos materiais são discutidos no item “4.9”.

Weight-in-motion system



DATA/HORA
CONTAGEM
VELOCIDADE
TIPO DE PNEU

CARGA EIXO 1
CARGA EIXO 2
CARGA EIXO “n”
(Outras)



BASE DE DADOS

Figura 4-6 – Variáveis que descrevem os veículos utilizando o peso por eixo

Weight-in-motion system



DATA/HORA
CONTAGEM
VELOCIDADE

CLASSIFICAÇÃO
CARGA TOTAL
(Outras)



BASE DE DADOS

Figura 4-7 – Variáveis que descrevem os veículos utilizando a classificação do veículo e carga total

A Figura 4-8 apresenta as treze classificações de veículos recomendadas pela FHWA em seu guia de monitoramento do tráfego (Federal Highway Administration, 2001).


(1) Motorcycle	(2) Passenger Car	(3) Two Axle, 4-Tire Unit	(4) Buses	(11) Five or Less Axles, Multi-Trailer
(5) Two Axle, 6-Tire Unit	(6) Three Axle Single Unit	(7) Four or More Axles Unit	(8) Three or four Axles Trailer	(13) Seven or More Axles, Multi-Trailer
(9) Five Axle Single Trailer	(10) Six or More Axles, Single Trailer			(12) Six Axles, Multi-Trailer

Figura 4-8 - Classes de veículos conforme recomendado pela FHWA (Federal Highway Administration, 2001)

4.4.1 A resposta estrutural do pavimento

A construção do modelo com o emprego da resposta estrutural do pavimento propicia uma riqueza gigantesca de situações, pois ao circular em veículos com diferentes cargas, cria-se uma situação equivalente ao trânsito de um veículo com carga padrão em uma ampla diversidade de diferentes estruturas de pavimento (diferentes espessuras de camadas), situação também análoga ao trânsito de veículos com múltiplas cargas sobre pavimentos com diferentes estruturas. Com o emprego de uma base de dados de um único pavimento seria possível modelar tais materiais (concreto asfáltico, camadas granulares, sub-leito) para praticamente quaisquer tipo de espessuras e suas combinações, como demonstrado na Figura 4-10. É, definitivamente, a situação ideal. Entretanto, o emprego de dados da resposta estrutural do pavimento é inviável devido às limitações tecnológicas dos sensores eletrônicos atualmente disponíveis para serem instalados (embutidos) nos pavimentos.

A impossibilidade do uso de dados da resposta estrutural dos pavimentos, e como ultrapassar este obstáculo, é melhor discutido no item “4.11”.



NÍVEL DO LENÇOL FREÁTICO
EXTENSÕES HORIZONTAIS NA CAMADA GRANULAR
EXTENSÕES VERTICAIS NO CONCRETO ASFÁLTICO
DEFORMAÇÕES TOTAIS
PRESSÕES
UMIDADE NA CAMADA GRANULAR
ALTERAÇÕES NA COMPACTAÇÃO DAS CAMADAS
EXTENSÕES HORIZONTAIS NO CONCRETO ASFÁLTICO
(OUTRAS)

Figura 4-9 – As variáveis relacionadas com a resposta estrutural do pavimento são de difícil determinação devido às limitações tecnológicas dos sensores para pavimentos

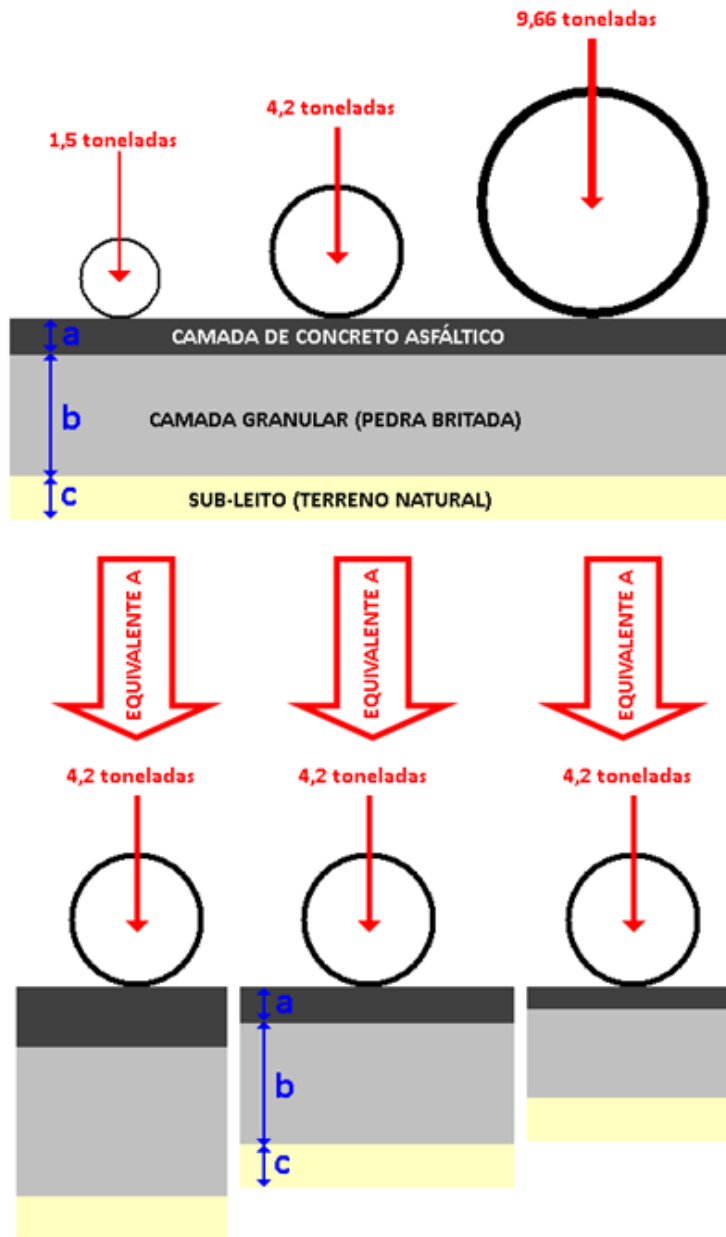


Figura 4-10 - Eixos com diferentes cargas que circulam em um determinado pavimento podem ser considerados equivalentes a um único eixo transitando em pavimentos com diferentes espessuras quanto ao dano produzido no concreto asfáltico

4.5 A construção do conhecimento e interpretação dos resultados

A base de dados disponível com informações relativas à passagem de cada veículo no pavimento deve conter a descrição de todos os eventos em linguagem puramente numérica, veículo por veículo, até que o critério de falha seja atingido (ver item “4.7” para mais informações sobre o critério de falha); esta etapa é relativamente simples já que os dados coletados em campo já são, tipicamente, referenciados apenas de forma numérica. A consistência desta descrição matemática é importante para o cálculo dos RPDIs.

O cálculo da importância relativa de cada veículo para a vida de serviço do pavimento (RPDIs), a carbotização, pode ser efetuada com a utilização de uma ou mais topologias baseadas em inteligência evolutiva que, combinada com métodos numéricos, pode proporcionar os melhores resultados (Mendes et al., 2004)(Rocha et al., 2005)(Rocha et al., 2006).

Quando esta tarefa estiver concluída, cada linha da matriz de dados, ou seja, cada veículo, receberá um índice relativo de dano ao pavimento (*Relative Pavement Damage Index, RPDI*), representando a relativa importância daquele veículo em relação aos demais veículos. A importância de cada variável, útil para a compreensão do mecanismo de degradação do pavimento, pode ser determinada através da *análise de sensibilidade*, mas não necessita ser calculada para o emprego da abordagem INTELLIPave no dimensionamento de pavimentos novos ou avaliação de pavimentos existentes. O CUIA Model utiliza somente os RPDIs.

A criação, cálculo, interpretação e correto emprego do CUIA Model foi uma das principais dificuldades (superadas) da metodologia INTELLIPave. Foram tentadas diversas abordagens buscando a identificação de um **índice absoluto de dano ao pavimento** até a conclusão de que o cálculo de um índice absoluto parece inviável sem dados detalhados da resposta estrutural do pavimento (cuja determinação é inviável, conforme discutido nos itens “4.4.1” e 4.11”), que por sua vez depende das características dos materiais (cujo comportamento não é adequadamente compreendido) e do sub-leito. Então optou-se pelo desenvolvimento de um **índice relativo de dano ao pavimento** (RPDI), onde os danos ao pavimento nunca são absolutos, mas sempre relativos ao pavimento (espessuras, materiais, etc.) utilizado na construção do modelo. Esta mudança de enfoque, de índice absoluto para relativo, eliminou todo um conjunto complexo de problemas associado aos materiais, mas “engessou” o modelo (matriz de performance) de tal forma que ele só é válido para os tipos de materiais e espessuras de camadas existentes no pavimento cujas informações foram utilizadas na montagem da base de dados utilizada na construção do modelo, dificultando ou mesmo impedindo que o modelo seja “generalizado” para outros materiais e espessuras. Este limitação é superada através de outra engenhosa solução desenvolvida para este método: a paralelização dos modelos, que é melhor discutida no item “4.11”.

Adicionalmente, a paralelização dos modelos também permite outra importante e longamente aguardada inovação para a área de pavimentos asfálticos: o acúmulo e reutilização do conhecimento sobre a performance dos pavimentos de forma metódica e racional. Este acúmulo permite a melhoria contínua na acurácia dos resultados e amplia o leque de situações (combinações de variáveis e amplitude de valores de cada variável) em que os modelos podem ser empregados com acurácia. Quanto mais modelos forem colocados para funcionar em paralelo, alimentando o CUIA Model, mais robustas e confiáveis serão as predições. O acúmulo e reutilização do conhecimento é melhor discutido no item “4.10”.

Por ser um índice que representa o peso relativo da linha (veículo) em relação às demais linhas (aos demais veículos), o índice relativo de dano ao pavimento (RPDI) não pode ser utilizado de forma isolada, mas sempre em conjunto com o somatório dos RPDI, de tal forma que o RPDI individual dividido pelo somatório dos RPDI e multiplicado por 100 representa o percentual da vida do pavimento que foi utilizado ou consumido pela passagem do veículo em questão, e de acordo com o critério de falha em uso (Equação 4-1).

$$\left(\begin{array}{c} \text{Consumo percentual} \\ \text{da vida} \\ \text{do pavimento} \\ \text{devido à passagem} \\ \text{do veículo "x"} \end{array} \right) = \left(\frac{RPDI_{\text{veículo "x"}}}{\sum RPDI} \right) \cdot 100$$

Equação 4-1 – O RPDI é sempre utilizado em conjunto com o somatório dos RPDI

A problemática relacionada ao erro que eventualmente existirá nos RPDI calculados é melhor discutida no item “4.13”.

4.6 Determinação do índice relativo de dano ao pavimento (RPDI) de cada veículo

Determinar a importância de cada veículo, devidamente combinado com a respectiva condição climática, para a destruição do pavimento é a etapa mais crítica deste método; sem a determinação confiável dos índices relativos de dano ao pavimento (RPDI) a metodologia INTELLIPave, tal como concebida e descrita neste trabalho, não seria efetiva. As dificuldades de cálculo dos RPDI já foram discutidas no item “1.2”.

Neste item são abordadas duas formas de calcular os RPDI, através da (a) redução do número de variáveis e do (b) aumento do número de equações, mas outras abordagens são possíveis.

4.6.1 Cálculo dos RPDIs através da redução do número de variáveis

Quando se trabalha com dados em escala real, a quantidade de veículos que transitam pelo pavimento é tão grande que muitos deles possuem características (velocidade, peso, etc.) muito similares e transitam em condições climáticas muito parecidas, ou mesmo idênticas, como no caso de veículos que transitam com poucos segundos de distância. Com isso pode-se assumir que tais veículos produzem no pavimento um dano tão similar que pode ser considerado igual.

Este agrupamento pode ser efetuado com o emprego de redes neurais tipo Kohonen através de treinamento não supervisionado, também conhecido como *Self-Organizing Maps* (SOM), entre outros nomes. A Figura 4-11 apresenta um exemplo clássico onde pixels de cores iguais ou similares são agrupados.

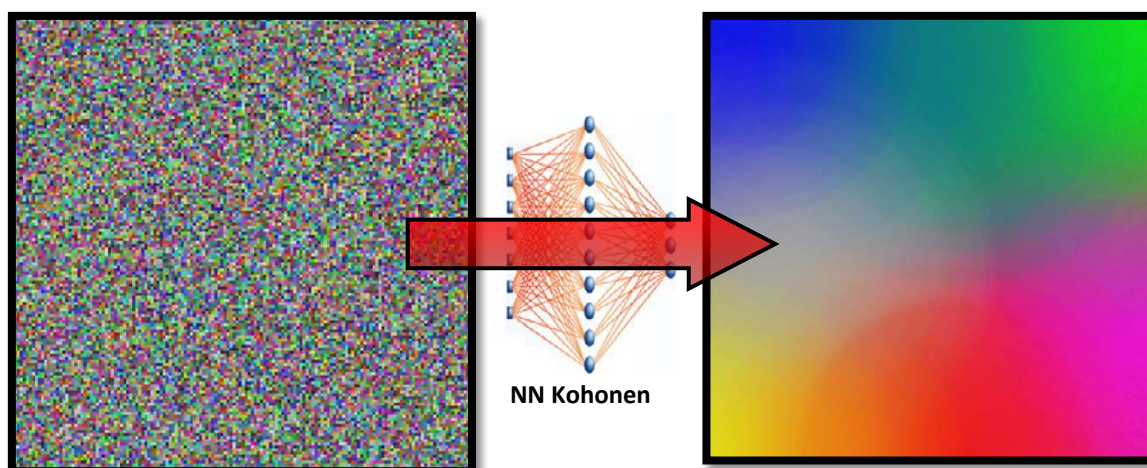


Figura 4-11 – Exemplo clássico de grupamento (clustering) de pixels de cores iguais ou similares utilizando redes neurais tipo Kohonen (Self-Organizing Maps, SOM)

A Tabela 4-2 apresenta um exemplo hipotético de dados de veículos que transitam pelo pavimento onde pode-se observar que existem 20 equações (20 linhas) e 27 variáveis (C1..C3; V1..V4; RPD1..RPDI20). A Tabela 4-3 apresenta o mesmo exemplo, mas onde os veículos similares foram agrupados em 4 diferentes grupos onde os RPDIs são considerados iguais, com isso o número de equações permanece o mesmo (20), mas o número de variáveis é reduzido para 11 (C1..C3; V1..V4; RPD1..RPDI4), permitindo que o sistema de equações seja resolvido através do método dos mínimos quadrados.

Tabela 4-2 – Base de dados e RPDI antes do agrupamento contendo 20 equações e 27 variáveis

Nº Veículo	Clima			Veículos					RPDI
1	C1	C2	C3	V1	V2	V3	V4	=	RPDI1
2	C1	C2	C3	V1	V2	V3	V4	=	RPDI2
3	C1	C2	C3	V1	V2	V3	V4	=	RPDI3
4	C1	C2	C3	V1	V2	V3	V4	=	RPDI4
5	C1	C2	C3	V1	V2	V3	V4	=	RPDI5
6	C1	C2	C3	V1	V2	V3	V4	=	RPDI6
7	C1	C2	C3	V1	V2	V3	V4	=	RPDI7
8	C1	C2	C3	V1	V2	V3	V4	=	RPDI8
9	C1	C2	C3	V1	V2	V3	V4	=	RPDI9
10	C1	C2	C3	V1	V2	V3	V4	=	RPDI10
11	C1	C2	C3	V1	V2	V3	V4	=	RPDI11
12	C1	C2	C3	V1	V2	V3	V4	=	RPDI12
13	C1	C2	C3	V1	V2	V3	V4	=	RPDI13
14	C1	C2	C3	V1	V2	V3	V4	=	RPDI14
15	C1	C2	C3	V1	V2	V3	V4	=	RPDI15
16	C1	C2	C3	V1	V2	V3	V4	=	RPDI16
17	C1	C2	C3	V1	V2	V3	V4	=	RPDI17
18	C1	C2	C3	V1	V2	V3	V4	=	RPDI18
19	C1	C2	C3	V1	V2	V3	V4	=	RPDI19
20	C1	C2	C3	V1	V2	V3	V4	=	RPDI20

Através de uma abordagem particularizada à apresentada na Tabela 4-4, as linhas da base de dados (veículos) podem ser agrupadas aos pares (*clusters* de duas linhas) de acordo com os dados (climáticas e relacionadas aos veículos) que descrevem a passagem de cada veículo, sendo que cada *cluster* terá os dois veículos que possuem os dados mais parecidos; então, assume-se que o RPDI é o mesmo para os dois veículos do cluster. Isso reduz o número de RPDIs individuais (variáveis) que precisam ser calculados pela metade, sem alterar o número de equações (Tabela 4-4).

Tabela 4-3 – Base de dados e RPDI após o agrupamento (clustering) contendo 20 equações e as variáveis sendo reduzidas para 11

Nº Veículo	Clima			Veículos					RPDI
1	C1	C2	C3	V1	V2	V3	V4	=	RPDI1
13	C1	C2	C3	V1	V2	V3	V4	=	
15	C1	C2	C3	V1	V2	V3	V4	=	
4	C1	C2	C3	V1	V2	V3	V4	=	RPDI2
17	C1	C2	C3	V1	V2	V3	V4	=	
6	C1	C2	C3	V1	V2	V3	V4	=	
11	C1	C2	C3	V1	V2	V3	V4	=	
19	C1	C2	C3	V1	V2	V3	V4	=	
9	C1	C2	C3	V1	V2	V3	V4	=	RPDI3
20	C1	C2	C3	V1	V2	V3	V4	=	
16	C1	C2	C3	V1	V2	V3	V4	=	
12	C1	C2	C3	V1	V2	V3	V4	=	
2	C1	C2	C3	V1	V2	V3	V4	=	
14	C1	C2	C3	V1	V2	V3	V4	=	
8	C1	C2	C3	V1	V2	V3	V4	=	RPDI4
5	C1	C2	C3	V1	V2	V3	V4	=	
7	C1	C2	C3	V1	V2	V3	V4	=	
18	C1	C2	C3	V1	V2	V3	V4	=	
10	C1	C2	C3	V1	V2	V3	V4	=	
3	C1	C2	C3	V1	V2	V3	V4	=	

A agrupação em pares, em vez de clusters contendo um número variável de veículos, pode eventualmente ser útil para que o um erro fique melhor distribuído dentro da matriz de performance, o que facilita a sua eliminação, como discutido no item “4.13”.

Tabela 4-4 – Base de dados e RPDI após o agrupamento aos pares

Nº Veículo	Clima			Veículos					RPDI
1	C1	C2	C3	V1	V2	V3	V4	=	RPDI1
15	C1	C2	C3	V1	V2	V3	V4	=	
13	C1	C2	C3	V1	V2	V3	V4	=	RPDI2
4	C1	C2	C3	V1	V2	V3	V4	=	
9	C1	C2	C3	V1	V2	V3	V4	=	RPDI3
17	C1	C2	C3	V1	V2	V3	V4	=	
11	C1	C2	C3	V1	V2	V3	V4	=	RPDI4
19	C1	C2	C3	V1	V2	V3	V4	=	
6	C1	C2	C3	V1	V2	V3	V4	=	RPDI5
20	C1	C2	C3	V1	V2	V3	V4	=	
16	C1	C2	C3	V1	V2	V3	V4	=	RPDI6
8	C1	C2	C3	V1	V2	V3	V4	=	
2	C1	C2	C3	V1	V2	V3	V4	=	RPDI7
14	C1	C2	C3	V1	V2	V3	V4	=	
12	C1	C2	C3	V1	V2	V3	V4	=	RPDI8
5	C1	C2	C3	V1	V2	V3	V4	=	
7	C1	C2	C3	V1	V2	V3	V4	=	RPDI9
3	C1	C2	C3	V1	V2	V3	V4	=	
10	C1	C2	C3	V1	V2	V3	V4	=	RPDI10
18	C1	C2	C3	V1	V2	V3	V4	=	

4.6.2 Cálculo dos RPDIs através do aumento do número de equações

O incremento no número de equações é viável pelo fato de que cada RPDI é analisado e considerado sempre em relação ao somatório dos RPDIs, portanto, seus valores absolutos não são importantes, mas apenas a relação entre o RPDI e o somatório dos RPDIs (Equação 4-1). Isso permite que seja adotado um valor arbitrário para o somatório dos RPDIs e assim extrair equações adicionais que facilitarão o cálculo dos RPDIs individuais através de uma abordagem essencialmente matemática.

Um exemplo simplificado é demonstrado na Tabela 4-5, onde o critério de falha do pavimento é 20% da área trincada. Originalmente existem 1 milhão de equações, que representam a passagem de 1 milhão de veículos; o número de variáveis é de 1 milhão de RPDIs individuais mais 4 variáveis (temperatura do ar, pluviosidade, velocidade e peso total do veículo), totalizando 1000004 variáveis, ou seja, 4 variáveis a mais que o número de equações, o que torna o sistema impossível de ser resolvido.

Tabela 4-5 – Escolha arbitrária do somatório dos RPDIs para a extração de equações adicionais que permitirão o cálculo dos RPDIs individuais

Nº veículo	Clima		Veículos		RPDI	Área Trincada (%)
	Temperatura do ar (°C)	Pluviosidade (mm/h)	Velocidade (km/h)	Peso total (t)		
1	C1	C2	V1	V2	RPDI ₁	0
2	C1	C2	V1	V2	RPDI ₂	0
3	C1	C2	V1	V2	RPDI ₃	0
...
349999	C1	C2	V1	V2	RPDI ₃₄₉₉₉₉	
350000	C1	C2	V1	V2	RPDI₃₅₀₀₀₀	5
350001	C1	C2	V1	V2	RPDI ₃₅₀₀₀₁	6
350002	C1	C2	V1	V2	RPDI ₃₅₀₀₀₂	6
...
599999	C1	C2	V1	V2	RPDI ₅₉₉₉₉₉	10
600000	C1	C2	V1	V2	RPDI₆₀₀₀₀₀	10
600001	C1	C2	V1	V2	RPDI ₆₀₀₀₀₁	11
600002	C1	C2	V1	V2	RPDI ₆₀₀₀₀₂	11
...
799999	C1	C2	V1	V2	RPDI ₇₉₉₉₉₉	15
800000	C1	C2	V1	V2	RPDI₈₀₀₀₀₀	15
800001	C1	C2	V1	V2	RPDI ₈₀₀₀₀₁	16
800002	C1	C2	V1	V2	RPDI ₈₀₀₀₀₂	16
...
999998	C1	C2	V1	V2	RPDI ₉₉₉₉₉₈	20
999999	C1	C2	V1	V2	RPDI ₉₉₉₉₉₉	20
1000000	C1	C2	V1	V2	RPDI₁₀₀₀₀₀₀	20
1000001	C1	C2	V1	V2	Σ = 20000	21

Ao ser arbitrado que o somatório dos RPDIs é igual a 20 mil é criada outra equação (Equação 4-2) e a vida útil total do pavimento passa a ser representado por este número (20000, adimensional). A partir da análise das verificações em campo da área trincada (*surveys*), pode-se identificar em que momento o pavimento atingiu 10% da área trincada, ou seja, após a passagem de quantos veículos houve o consumo de metade da vida útil do pavimento; o somatório dos RPDIs até tal momento será igual a metade do valor que representa a vida útil total do pavimento, ou seja, será igual a 10 mil (Equação 4-3). O mesmo raciocínio se aplica para o pavimento quando a área trincada é de 5% e 15%, permitindo gerar duas equações adicionais (Equação 4-4 e Equação 4-5). Assim, são extraídas da base de dados 4 novas equações e o problema passa a ter 1000004 equações e 1000004 variáveis, sendo portanto solucionável e permitindo o cálculo dos RPDIs individuais (Tabela 4-6).

$$\left(\sum_{\text{Veiculo} = 1}^{1000000} RPD I \right) = 20000$$

Equação 4-2 – Somatório dos RPD I igual a 20000

$$\left(\sum_{\text{Veículo} = 1}^{600000} RPD I \right) = 10000$$

Equação 4-3 – Somatório dos RPD I igual a 10000

$$\left(\sum_{\text{Veículo} = 1}^{350000} RPD I \right) = 5000$$

Equação 4-4 – Somatório dos RPD I igual a 5000

$$\left(\sum_{\text{Veículo} = 1}^{800000} RPD I \right) = 15000$$

Equação 4-5 – Somatório dos RPD I igual a 15000 ocorre quando ¼ da vida útil total do pavimento (arbitrada em 20000) é consumida

Tabela 4-6 – Número de equações e variáveis antes e depois da escolha de um valor arbitrário para o somatório dos RPDs

	Equações	Variáveis
Antes do arbítrio do valor do somatório dos RPDs	1000000	1000004
Depois do arbítrio do valor do somatório dos RPDs	1000004	1000004

4.6.3 Aplicação de restrições para identificar um bom modelo

No atual estágio desta metodologia, ou seja, sem a utilização de dados reais de campo, é difícil avaliar o nível de validade e eventuais dificuldades para o cálculo dos RPDs com base nas metodologias discutidas nos itens “4.6.1” e “4.6.2”. Neste item são discutidas algumas hipóteses e possíveis soluções.

É possível que sejam identificadas múltiplas soluções matemáticas para os sistemas de equações montados, ou seja, dependendo da forma de abordar e resolver o problema, sejam obtidas soluções ligeiramente diferentes. O fato é que em engenharia de pavimentos, dada a heterogeneidade dos materiais empregados na construção dos pavimentos e da complexa combinação de fatores que interferem com a sua durabilidade, não existem modelos perfeitos;

existem apenas bons modelos que, eventualmente, terão diversos modelos “equivalentes”, ou seja, diferentes combinações de clima e tráfego que levarão à mesma evolução do critério de falha. O fato é que qualquer bom modelo ou seus equivalentes são totalmente adequados, pois proporcionarão resultados equivalentes.

Para auxiliar na redução do número de eventuais soluções possíveis e a identificação de um bom modelo, pode-se utilizar equações de restrição. O incremento do número de equações de restrição onde é arbitrado um valor para o somatório dos RPDIs com base nos levantamentos de campo do critério de falha, como demonstrado na Equação 4-2, Equação 4-3, Equação 4-4 e Equação 4-5 é uma boa forma de implementar restrições, confinando o número de eventuais soluções possíveis.

Outra possibilidade é demonstrada na Tabela 4-7, onde os veículos são hierarquizados segundo a ordem de grandeza dos RPDIs. Observações empíricas permitiram identificar qual o tipo de impacto na durabilidade do pavimento asfáltico que cada variável climática ou relacionada com os veículos apresenta para os critérios de falha mais comuns, como a área trincada (Momm, 1999). Por exemplo: rodovias onde os veículos trafegavam a velocidades médias elevadas (~100 km/h) tiveram o pavimento degradado rapidamente após a velocidade média ter sido reduzida (~30 km/h), ou seja, a velocidade baixa (tecnicamente chamada de “tráfego lento”) implica em um dano maior ao pavimento (maior RPD) porque o veículo “permanece” sobre o mesmo ponto do pavimento por mais tempo.

Assim, quando o critério é a área trincada, se espera que o menor RPD seja aquele do veículo que transitou em dia ensolarado (pluviosidade = 0), com a mais elevada temperatura do ar e do pavimento, a menor radiação solar, a menor velocidade do vento, a maior velocidade do veículo e a menor carga. Na ponta oposta, o veículo que apresentará o mais elevado RPD é aquele transitou com máxima pluviosidade, menor temperatura do ar e do pavimento, maior radiação solar, maior velocidade do vento, menor velocidade do veículo, e a mais elevada carga (Tabela 4-7) (Momm, 1999). Outros exemplos de restrições são apresentados na Tabela 4-8.

Tabela 4-7 – Relação entre diversas variáveis com o RPD quando o critério de falha é a área trincada

Pluvi- osidade	Tempe- ratura do ar	Radia- ção solar	Tempe- ratura do pavi- mento	Veloci- dade do vento	Veloci- dade do veículo	Carga no eixo 1	Carga no eixo “n”	...	RPDI
menor	maior	menor	maior	menor	maior	menor	menor	...	menor
...
maior	menor	maior	menor	maior	menor	maior	maior	...	maior

Tabela 4-8 - Exemplos de equações de restrições

Restrição	Descrição
$RPDI \geq 0$	Os valores de RPDIs nunca são negativos
$\frac{RPDI_{INDIVIDUAL}}{\sum RPDI} \cdot 100 \leq 0,01$	Um RPDI individual nunca pode contribuir em mais que, por exemplo, 0,01% da destruição do pavimento

Devem ser aplicadas restrições até que seja obtida a acurácia desejada, sendo importante salientar que para aplicação do CUIA Model não é necessário determinar os coeficientes de importância para cada uma das variáveis consideradas, mas apenas o RPDI do respectivo veículo.

Este problema também é discutido no item “4.13”.

4.7 Critério externo para determinar o fim da vida de serviço do pavimento

O critério de falha para a modelagem de pavimentos asfálticos dentro de uma abordagem empírica é extremamente vago e subjetivo, podendo até se afirmar que inexistente. Já na abordagem empírico-mecânica é incorporado no modelo um parâmetro mecânico ao qual se atribui empiricamente a (sabidamente inverídica) capacidade de prever a durabilidade dos pavimentos; o critério de falha é precursor e ao mesmo tempo parte do modelo, sendo que a extensão máxima na última fibra da camada asfáltica é o critério de falha mais utilizado.

Qualquer motorista sabe, intuitivamente, que um pavimento está ruim quando apresenta trincas, deformações, buracos e outros problemas que interferem com o conforto e/ou fluência do tráfego. Nenhum motorista jamais afirmou que o pavimento encontrava-se ruim porque as extensões (*strains*) eram maiores do que determinado valor, ou seja, existe um descompasso entre o que a engenharia de pavimentos utiliza como critério de falha e os defeitos que constituem as falhas identificáveis ao se observar os pavimentos.

Na metodologia INTELLIPave o critério de falha não é inserido dentro do modelo; é utilizado de uma forma mais próxima da realidade observável em campo. O critério é posicionado ao lado do modelo, sendo simplesmente um sinalizador de quando o pavimento não mais atende ao requisito de qualidade, e onde a base de dados deve ser cortada para a construção do modelo. Os dados que estiverem após o ponto de corte são eliminados pois, de acordo com o critério de falha, o pavimento não mais atende ao requisito de qualidade.

Desta forma são resolvidos ou evitados muitos dos problemas encontrados em abordagens empírico-mecânicas e é aberto um novo mundo de possibilidades para construir modelos

melhores e a adoção de critérios múltiplos de falha. Todas as variáveis, conhecidas ou desconhecidas, passam a ser incorporadas no modelo de forma explícita (variáveis com dados disponíveis) ou implícita (variáveis desconhecidas ou sem dados disponíveis), como é discutido no item “4.8”

Esta é uma importante mudança de paradigma porque permite criar modelos de alta qualidade sem a necessidade de explicar o comportamento dos materiais, inserindo o comportamento destes de forma implícita, e não explícita, onde a predição do comportamento é obtida através da reprodução do comportamento registrado na base de dados.

O fato de ser considerado de forma externa ao modelo proporciona total flexibilidade na escolha do critério de falha, pois ele pode ser avaliado através de qualquer tipo de parâmetro, objetivo ou subjetivo, técnico, financeiro ou mesmo exótico ou esotérico. A única necessidade é indicar em qual momento o pavimento não mais atende ao critério de falha, para o corte da base de dados. Após o corte na base de dados, todo o procedimento de construção do modelo é rigorosamente idêntico.

É possível construir inúmeros modelos, com diferentes critérios de falha, utilizando uma única base de dados, pois cada critério é atingido em um momento diferente para o mesmo pavimento. Em um sistema de gerência de pavimentos isso permite a previsão e avaliação de diferentes cenários para o bom planejamento financeiro. Para cada critério a base de dados é cortada em um ponto diferente e novos RPDIs precisam ser calculados.

A Figura 4-12 apresenta um exemplo onde uma única base de dados é utilizada para a construção de três diferentes modelos que atendem a três critérios de falha:

1. Profundidade de trilha de roda em 10 mm (Figura 4-13);
2. Área trincada do pavimento em 10% (Figura 4-14); e,
3. Área trincada do pavimento em 20% (Figura 4-15).

Nestes casos a área trincada do pavimento e a profundidade da trilha de roda precisam ser metódica e periodicamente verificadas em campo.

Outros exemplos de critérios de falha que podem ser utilizados:

- Área trincada em 5%
- Área trincada em 10%
- Área trincada em 15%
- Trilha de roda com profundidade de 10 mm
- Trilha de roda com profundidade de 20 mm
- Custo de manutenção do pavimento superior a 100 mil euros por ano
- Custo de manutenção do pavimento superior a 105 mil euros por ano
- IRI ⁽⁶⁾ maior que 2 m/km
- IRI maior que 5 m/km

⁶ International Roughness Index

Veículos	Dados do clima						Dados dos veículos				Área trincada	Profundidade da trilha de roda (mm)
1	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
2	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
3	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
4	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
5	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
...
2.663.322	C1	C2	C3	C4	C5	...	V1	V2	V3	...	6%	10
2.663.323	C1	C2	C3	C4	C5	...	V1	V2	V3	...	6%	10
2.663.324	C1	C2	C3	C4	C5	...	V1	V2	V3	...	6%	11
...
3.333.332	C1	C2	C3	C4	C5	...	V1	V2	V3	...	10%	13
3.333.333	C1	C2	C3	C4	C5	...	V1	V2	V3	...	10%	13
3.333.334	C1	C2	C3	C4	C5	...	V1	V2	V3	...	11%	13
...
5.666.998	C1	C2	C3	C4	C5	...	V1	V2	V3	...	20%	21
5.666.999	C1	C2	C3	C4	C5	...	V1	V2	V3	...	20%	21
5.667.000	C1	C2	C3	C4	C5	...	V1	V2	V3	...	20%	21
5.667.001	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	21
5.667.002	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	21
5.667.003	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	21
5.667.004	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	21
...

Ponto de corte para o critério de falha escolhido

Critério de falha: trilha de roda até 10 mm

Critério de falha: área trincada em 10%

Critério de falha: área trincada em 20%

C1..C5; V1..V4: variáveis lidas em campo

Figura 4-12 – Base de dados com o histórico do pavimento para a construção de modelos com diferentes critérios de falha

Veículos	Dados do clima						Dados dos veículos				Área trincada	Profundidade da trilha de roda (mm)
1	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
2	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
3	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
4	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
5	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
...
2.663.322	C1	C2	C3	C4	C5	...	V1	V2	V3	...	6%	10
2.663.323	C1	C2	C3	C4	C5	...	V1	V2	V3	...	6%	10
2.663.324	C1	C2	C3	C4	C5	...	V1	V2	V3	...	6%	11
...
3.333.332	C1	C2	C3	C4	C5	...	V1	V2	V3	...	10%	13
3.333.333	C1	C2	C3	C4	C5	...	V1	V2	V3	...	10%	13
3.333.334	C1	C2	C3	C4	C5	...	V1	V2	V3	...	11%	13
...
5.666.998	C1	C2	C3	C4	C5	...	V1	V2	V3	...	20%	17
5.666.999	C1	C2	C3	C4	C5	...	V1	V2	V3	...	20%	17
5.667.000	C1	C2	C3	C4	C5	...	V1	V2	V3	...	20%	17
5.667.001	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	17
5.667.002	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	17
5.667.003	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	17
5.667.004	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	17
...

**Base de dados para construir o modelo com critério de falha:
Profundidade da trilha de roda em 10 mm**

Dados eliminados

C1..C5; V1..V3: variáveis lidas em campo

Figura 4-13 – Base de dados com o histórico do pavimento para construir um modelo tendo como critério de falha a profundidade da trilha de roda em 10 mm

Veículos	Dados do clima						Dados dos veículos				Área trincada	Profundidade da trilha de roda (mm)
1	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
2	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
3	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
4	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
5	C1	C2							V3	...	0%	0
...
2.663.322	C1	C2							V3	...	6%	10
2.663.323	C1	C2							V3	...	6%	10
2.663.324	C1	C2	C3	C4	C5	...	V1	V2	V3	...	6%	11
...
3.333.332	C1	C2	C3	C4	C5	...	V1	V2	V3	...	10%	13
3.333.333	C1	C2	C3	C4	C5	...	V1	V2	V3	...	10%	13
3.333.334	C1	C2	C3	C4	C5	...	V1	V2	V3	...	11%	13
...
5.666.998	C1	C2	C3	C4	C5	...	V1	V2	V3	...	20%	17
5.666.999	C1	C2	C3	C4	C5	...	V1	V2	V3	...	20%	17
5.667.000	C1	C2	C3	C4	C5	...	V1	V2	V3	...	20%	17
5.667.001	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	17
5.667.002	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	17
5.667.003	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	17
5.667.004	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	17
...

Base de dados para construir o modelo com critério de falha: Área trincada em 10% da superfície do pavimento

Dados eliminados

C1..C5; V1..V3: variáveis lidas em campo

Figura 4-14 – Base de dados com o histórico do pavimento para construir um modelo tendo como critério de falha a área trincada em 10%

Veículos	Dados do clima						Dados dos veículos				Área trincada	Profundidade da trilha de roda (mm)
1	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
2	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
3	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
4	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
5	C1	C2	C3	C4	C5	...	V1	V2	V3	...	0%	0
...
2.663.322	C1	C2	V3	6%	10
2.663.323	C1	C2	V3	6%	10
2.663.324	C1	C2	V3	6%	11
...
3.333.332	C1	C2	C3	C4	C5	...	V1	V2	V3	...	10%	13
3.333.333	C1	C2	C3	C4	C5	...	V1	V2	V3	...	10%	13
3.333.334	C1	C2	C3	C4	C5	...	V1	V2	V3	...	11%	13
...
5.666.998	C1	C2	C3	C4	C5	...	V1	V2	V3	...	20%	17
5.666.999	C1	C2	C3	C4	C5	...	V1	V2	V3	...	20%	17
5.667.000	C1	C2	C3	C4	C5	...	V1	V2	V3	...	20%	17
5.667.001	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	17
5.667.002	C1	C2	C3	C4	C5	...	V1	V2	V3	...	21%	17
5.667.003	C1	C2	C3	C4	C5	...	V3	21%	17
5.667.004	C1	C2	C3	C4	C5	...	V3	21%	17
...

Base de dados para construir o modelo com critério de falha: Área trincada em 20% da superfície do pavimento

Dados eliminados

C1..C5; V1..V3: variáveis lidas em campo

Figura 4-15 – Base de dados com o histórico do pavimento para construir um modelo tendo como critério de falha a área trincada em 20%

4.8 Contemplando variáveis desconhecidas

Quando o critério de falha do pavimento é externo ao modelo, como discutido no item “4.7”, um grande leque de possibilidades se abre. Uma das mais interessantes é o fato de que as variáveis (do modelo) proporcionam orientação sobre onde o modelo de desempenho pode ser utilizado com acurácia, e para isso não é necessário conhecer todas as variáveis; a orientação precisa ser boa, mas não precisa ser perfeita. De fato, provavelmente é impossível identificar absolutamente todas as variáveis com influência na vida útil do pavimento.

A abordagem INTELLIPave, por possuir critério de falha externo, é tolerante a erros devido à má escolha, limitações ou falta de acurácia das variáveis utilizadas no modelo, pois o critério de falha do pavimento nasce em outra raiz, que não está conectada com a raiz onde nascem as variáveis. A quantidade de variáveis para construir o modelo pode ser aumentada ou diminuída que isso não altera a identificação do momento em que ocorre a falha do pavimento. Se, por exemplo, o critério de falha é 20% da área trincada, esta informação será verificada através mensuração área trincada na superfície do pavimento (*surveys*); não será medida pelos instrumentos utilizados para identificar e mensurar o tráfego ou o clima.

Em teoria, o modelo INTELLIPave poderia ser construído com pouquíssimas ou mesmo sem nenhuma variável, mas neste caso seria produzido um modelo rígido, válido somente para as condições específicas de clima, tráfego, sub-leito, materiais e espessuras do pavimento onde o critério de falha foi verificado; e não poderia ser “generalizado” para nenhuma outra situação; e como as variáveis são desconhecidas, sequer seria possível identificar em qual situação o modelo (sem variáveis) poderia ser utilizado, a não ser por inferência empírica.

Quando uma variável é removida do modelo, ou seus dados não são conhecidos, é assumido que os pavimentos dimensionados ou avaliados com base em tal modelo serão objeto das mesmas condições que ocorreram no pavimento cujos dados foram utilizados na construção do modelo (matriz de performance), no que se refere àquela variável. Por exemplo: foi construído um modelo com os dados coletados na rodovia A33, incluindo dados completos dos veículos e, dos dados climáticos, apenas a pluviosidade é conhecida, sendo que a temperatura do ar não é conhecida; neste caso o modelo da A33 é perfeito para ser utilizado em qualquer projeto onde a temperatura do ar for similar àquela da A33, cujos valores são desconhecidos; se houver necessidade de projetar o pavimento para outra rodovia que se encontra na mesma região da A33, e por isso possui um perfil climático similar, é possível utilizar a A33 como modelo sem qualquer degradação considerável na acurácia da modelagem. Isso não significa que a temperatura do ar foi removida do modelo, pois sua importância e influência na durabilidade do pavimento está perfeitamente registrada no critério de falha utilizado; assim, a variável temperatura do ar está inclusa no modelo de forma implícita, mas não explícita.

A mesma lógica é aplicada a todas as demais variáveis, cujos valores são desconhecidos e mesmo àquelas variáveis que sequer se suspeita que possuam influência na durabilidade do pavimento. Todas as variáveis, conhecidas e desconhecidas, independentemente da sua natureza, complexidade ou relevância, são consideradas com perfeição no modelo através do critério de falha do pavimento que, por ser externo ao modelo, não é contaminado pelas limitações e problemas que possam existir nas variáveis e dados utilizados na construção do modelo.

A Figura 4-16 apresenta um modelo utilizando a área trincada em 20% como critério de falha para o pavimento asfáltico onde são utilizadas, simbolicamente, todas as variáveis conhecidas e que possuem influência para a vida útil do pavimento. O pavimento é considerado bom e aceitável até a passagem do veículo número 5667000.

A Figura 4-17 apresenta o mesmo pavimento, mas com duas variáveis eliminadas. Novamente, o pavimento é considerado bom até a passagem do veículo número 5667000. Uma das variáveis eliminadas é a velocidade, mas a importância desta variável permanece no modelo de forma implícita, porque o pavimento foi objeto da passagem de veículos com diferentes velocidades; apenas não existem os registros das velocidades. Neste caso o modelo pode ser utilizado com acurácia para a predição da performance do pavimento em rodovias onde as velocidades estão no mesmo patamar das velocidades que ocorreram no pavimento que foi fonte de informações para a construção do modelo.

Na Figura 4-18 estão inseridas, simbolicamente, todas as variáveis conhecidas e desconhecidas com influência na vida de serviço do pavimento. Como o critério de falha é externo, o fim da vida útil do pavimento permanece na mesma posição, com todas as variáveis desconhecidas incluídas no modelo de forma implícita.

Veículos	Dados do clima						Dados dos veículos				Área trincada
1	C1	C2	C3	C4	C5	C6	V1	V2	V3	V4	0%
2	C1	C2	C3	C4	C5	C6	V1	V2	V3	V4	0%
3	C1	C2	C3	C4	C5	C6	V1	V2	V3	V4	0%
4	C1	C2	C3	C4	C5	C6	V1	V2	V3	V4	0%
5	C1	C2	C3	C4	C5	C6	V1	V2	V3	V4	0%
...
5666998	C1	C2	C3	C4	C5	C6	V1	V2	V3	V4	20%
5666999	C1	C2	C3	C4	C5	C6	V1	V2	V3	V4	20%
5667000	C1	C2	C3	C4	C5	C6	V1	V2	V3	V4	20%
5667001	C1	C2	C3	C4	C5	C6	V1	V2	V3	V4	21%
5667002	C1	C2	C3	C4	C5	C6	V1	V2	V3	V4	21%
5667003	C1	C2	C3	C4	C5	C6	V1	V2	V3	V4	21%
5667004	C1	C2	C3	C4	C5	C6	V1	V2	V3	V4	21%
...

Linha de corte para o critério de falha escolhido

Dados utilizados na construção do modelo

Critério de falha: área trincada em 20%

Dados eliminados

C1 = Radiação solar
 C2 = Temperatura do ar
 C3 = Pluviosidade
 C4 = Velocidade do vento

C5 = Umidade relativa do ar
 C6 = Temperatura do pavimento

V1 = Tipo de pneu
 V2 = Velocidade
 V3 = Peso do eixo 1
 V4 = Classificação do veículo

Figura 4-16 – Base de dados com o histórico do pavimento – (representação simbólica de) todas as variáveis conhecidas

Veículos	Dados do clima					Dados dos veículos			Área trincada
1	C1	C2	C3	C4	C5	V1	V3	V4	0%
2	C1	C2	C3	C4	C5	V1	V3	V4	0%
3	C1	C2	C3	C4	C5	V1	V3	V4	0%
4	C1	C2	C3	C4	C5	V1	V3	V4	0%
5	C1	C2	C3	C4	C5	V1	V3	V4	0%
...
5666998	C1	C2	C3	C4	C5	V1	V3	V4	20%
5666999	C1	C2	C3	C4	C5	V1	V3	V4	20%
5667000	C1	C2	C3	C4	C5	V1	V3	V4	20%
5667001	C1	C2	C3	C4	C5	V1	V3	V4	21%
5667002	C1	C2	C3	C4	C5	V1	V3	V4	21%
5667003	C1	C2	C3	C4	C5	V1	V3	V4	21%
5667004	C1	C2	C3	C4	C5	V1	V3	V4	21%
...

C1 = Radiação solar
 C2 = Temperatura do ar
 C3 = Pluviosidade
 C4 = Velocidade do vento

C5 = Umidade relativa do ar
~~C6 = Temperatura do pavimento~~

V1 = Tipo de pneu
~~V2 = Velocidade~~
 V3 = Peso do eixo 1
 V4 = Classificação do veículo

Figura 4-17 - Eliminar parte das variáveis não modifica a posição onde o pavimento deixa de atender ao critério de falha

Veículos	Dados do clima									Dados dos veículos							Área trincada
1	C1	C2	C3	C4	C5	C6	C7	...	Cn	V1	V2	V3	V4	V5	...	Vn	0%
2	C1	C2	C3	C4	C5	C6	C7	...	Cn	V1	V2	V3	V4	V5	...	Vn	0%
3	C1	C2	C3	C4	C5	C6	C7	...	Cn	V1	V2	V3	V4	V5	...	Vn	0%
4	C1	C2	C3	C4	C5	C6	C7	...	Cn	V1	V2	V3	V4	V5	...	Vn	0%
5	C1	C2	C3	C4	C5	C6	C7	...	Cn	V1	V2	V3	V4	V5	...	Vn	0%
...
5666998	C1	C2	C3	C4	C5	C6	C7	...	Cn	V1	V2	V3	V4	V5	...	Vn	20%
5666999	C1	C2	C3	C4	C5	C6	C7	...	Cn	V1	V2	V3	V4	V5	...	Vn	20%
5667000	C1	C2	C3	C4	C5	C6	C7	...	Cn	V1	V2	V3	V4	V5	...	Vn	20%
5667001	C1	C2	C3	C4	C5	C6	C7	...	Cn	V1	V2	V3	V4	V5	...	Vn	21%
5667002	C1	C2	C3	C4	C5	C6	C7	...	Cn	V1	V2	V3	V4	V5	...	Vn	21%
5667003	C1	C2	C3	C4	C5	C6	C7	...	Cn	V1	V2	V3	V4	V5	...	Vn	21%
5667004	C1	C2	C3	C4	C5	C6	C7	...	Cn	V1	V2	V3	V4	V5	...	Vn	21%
...

- | | | | |
|--------------------------|-------------------------------|---------------------|-------------------------------|
| C1 = Radiação solar | C5 = Umidade relativa do ar | V1 = Tipo de pneu | V4 = Classificação do veículo |
| C2 = Temperatura do ar | C6 = Temperatura do pavimento | V2 = Velocidade | V5 = Unknown variable |
| C3 = Pluviosidade | C7 = Unknown variable | V3 = Peso do eixo 1 | Vn = Unknown variable "n" |
| C4 = Velocidade do vento | Cn = Unknown variable "n" | | |

Figura 4-18 - Com a consideração de todas as variáveis conhecidas e desconhecidas o fim da vida de serviço do pavimento permanece na mesma posição

4.9 Contemplando o envelhecimento dos materiais e a não-linearidade do comportamento dos pavimentos ao longo do tempo

Quando o pavimento asfáltico é objeto da passagem de um veículo (com determinada carga, velocidade, etc.) sob uma determinada condição climática (temperaturas, pluviosidade, etc.), ocorre um dano no pavimento, cujo acúmulo causará a sua ruína. Se o pavimento é novo (ex.: construído há um ano), este dano terá determinada magnitude; se o pavimento for velho (ex.: construído há 8 anos), este dano será diferente, e maior. Assim, temos danos diferentes para situações absolutamente idênticas em função, sobretudo, do envelhecimento dos materiais asfálticos.

Na metodologia INTELLIPave, contemplar o envelhecimento dos materiais, assim como todos os demais fatores inerentes ao tempo (fenômeno da auto-reparação, etc.), passa pela divisão do modelo em sub-modelos de preferência com base em dados anuais, como apresentado esquematicamente na Figura 4-19, que permite o registro do tráfego dentro de um ciclo completo da sazonalidade climática (um ano).

Assim, para capturar o efeito do envelhecimento dos materiais, o processo de carbotização precisa ser, preferencialmente, efetuado com os dados do respectivo ano. Exemplo: No caso da divisão em 10 sub-modelos, seria necessário efetuar 10 carboteamentos (ou otimizações). O dano relativo ao pavimento é, assim, calculado a partir do dano individual do veículo (RPDI) dividido pelo somatório dos RPDIs no respectivo ano.

Cabe salientar que quando se refere à modelos de base anual, não significa que o início do ciclo de anualização precisa ser iniciado em 01 de janeiro, mas pode ser iniciado em qualquer época. Por exemplo: se uma nova rodovia foi aberta ao tráfego no mês de outubro, significa que o seu ciclo anual se completa todo mês de setembro dos anos sucessivos.

A Tabela 4-9 descreve um exemplo inadequado e inconsistente, onde o modelo foi subdividido com base diária e o critério de falha é a área trincada. Nesta situação a área trincada precisa ser medida em campo todos os dias, o que é inviável, pois a variação na área trincada de um dia para o outro é praticamente nula, imperceptível a olho nu ou mesmo com utilização de fotografias de alta resolução.

A situação ideal seria aquela em que a variação da área trincada fosse coincidente com a sazonalidade adotada, o que não é difícil de se obter pois, para isso, basta agendar a realização de uma verificação de campo (exemplo: mensuração da área trincada) coincidente com o fim do período da sazonalidade (exemplo: todos os anos no mês de setembro).

Independentemente do tipo de sazonalidade empregada – dias, anos, etc. – é necessário possuir disponível e utilizar o valor correspondente ao critério de falha para o final de cada ciclo da sazonalidade considerada, como indicado na Figura 4-19 e também na Tabela 4-9. Por

exemplo: Se o critério de falha é 20% da área trincada e o modelo foi dividido em sazonalidades anuais, é necessário conhecer o valor da área trincada ao final de cada ano para calcular os RPDI, como discutido no item “4.6”.

Se ocorrer a situação também indicada na Figura 4-19, onde os sub-modelos anuais 1 e 2 não apresentam qualquer área trincada, faz-se necessário agrupar tais sub-modelos com o subsequente, assim os sub-modelos 1, 2 e 3 precisam ser integrados para compor um único sub-modelo de sazonalidade. A mesma integração precisa ser efetuada quando, de um sub-modelo para o subsequente, não houver variação no valor numérico que descreve o critério de falha.

Tabela 4-9 – Sub-divisão inadequada do modelo em sub-modelos diários

Nº Veículo	Clima			Veículos			RPDI	Área trincada (%)	Idade do pavimento (dias)
	C1	C2	C3	V1	V2	V3			
1	C1	C2	C3	V1	V2	V3	= RPDI	0,0	1
2	C1	C2	C3	V1	V2	V3	= RPDI	0,0	1
3	C1	C2	C3	V1	V2	V3	= RPDI	0,0	1
4	C1	C2	C3	V1	V2	V3	= RPDI	0,0	1
...
449994	C1	C2	C3	V1	V2	V3	= RPDI	9,0	1277
449995	C1	C2	C3	V1	V2	V3	= RPDI	9,0	1277
449996	C1	C2	C3	V1	V2	V3	= RPDI	9,0	1277
449997	C1	C2	C3	V1	V2	V3	= RPDI	9,0	1277
449998	C1	C2	C3	V1	V2	V3	= RPDI	9,0	1278
449999	C1	C2	C3	V1	V2	V3	= RPDI	9,0	1278
450000	C1	C2	C3	V1	V2	V3	= RPDI	9,0	1278
...
999994	C1	C2	C3	V1	V2	V3	= RPDI	20,0	2555
999995	C1	C2	C3	V1	V2	V3	= RPDI	20,0	2555
999996	C1	C2	C3	V1	V2	V3	= RPDI	20,0	2555
999997	C1	C2	C3	V1	V2	V3	= RPDI	20,0	2555
999998	C1	C2	C3	V1	V2	V3	= RPDI	20,0	2555
999999	C1	C2	C3	V1	V2	V3	= RPDI	20,0	2555
1000000	C1	C2	C3	V1	V2	V3	= RPDI	20,0	2555

Nº Veículo	Data	Clima			Veículos			RPDI	Dano anual ao pavimento	Dano acumulado ao pavimento	Percentual da vida de serviço utilizado	Critério de falha: área trincada (%)	Sub-modelo anual
		Temperatura do ar	Pluviosidade	...	Velocidade	Carga eixo 1	...						
1	01/01/1991	25	0	...	77	7	...	84,5					
...					
489.000	31/12/1991	14	0	...	87	8	...	81,5	81.173.834	81.173.834	0,3106%	0,0	1
489.001	01/01/1992	14	0	...	77	4	...	64,5					
...					
999.876	31/12/1992	19	0	...	97	5	...	82,5	153.234.855	234.408.689	0,8969%	0,0	2
999.877	01/01/1993	19	0	...	56	6	...	65					
...					
1.145.000	31/12/1993	33	2	...	113	3	...	102,5	257.153.214	491.561.903	1,8807%	1,9	3
1.145.001	01/01/1994	33	2	...	111	1	...	95,5					
...					
1.568.000	31/12/1994	23	0	...	90	3	...	77	919.761.173	1.411.323.076	5,3998%	4,9	4
1.568.001	01/01/1995	23	0	...	83	2	...	70,5					
...					
2.107.467	31/12/1995	32	15	...	93	12	...	144,5	1.948.755.109	3.360.078.185	12,8558%	7,9	5
2.107.468	01/01/1996	32	15	...	95	11	...	142,5					
...					
2.867.000	31/12/1996	31	87	...	110	13	...	299	2.183.039.160	5.543.117.345	21,2082%	9,9	6
2.867.001	01/01/1997	31	86	...	86	2	...	252					
...					
3.323.000	31/12/1997	32	0	...	83	3	...	82,5	3.000.356.171	8.543.473.515	32,6878%	12,9	7
3.323.001	01/01/1998	32	0	...	98	4	...	93					
...					
4.309.000	31/12/1998	33	0	...	99	8	...	106,5	4.566.796.958	13.110.270.474	50,1605%	14,9	8
4.309.001	01/01/1999	33	0	...	66	12	...	102					
...					
5.015.000	31/12/1999	34	0	...	13	1	...	43,5	5.387.920.186	18.498.190.660	70,7750%	16,9	9
5.015.001	01/01/2000	34	0	...	88	11	...	111					
...					
5.667.000	20/09/2000	13	33	...	66	13	...	151	7.638.429.497	26.136.620.157	100,0000%	20,9	10
5.667.001	20/09/2000	13	33	...					26.136.620.157			21,0	

BASE DE DADOS

DETERMINADO ATRAVÉS DE CARBOTIZAÇÃO

CALCULADO COM BASE NOS RPDIs

MATRIZ DE PERFORMANCE

Figura 4-19- Sub-divisão adequada do modelo em sub-modelos com base anual

4.10 Acumulação e reutilização do conhecimento utilizando modelos paralelos

Devido às limitações das abordagens empíricas e empírico-mecanísticas, o atual estado-da-arte em modelos para pavimentos asfálticos não proporciona nenhuma forma de acumular e reutilizar o conhecimento sobre a performance dos pavimentos de forma metódica, racional e sistematizada. Este conhecimento permanece apenas na memória dos engenheiros e pode ser facilmente perdido devido ao esquecimento, aposentadoria ou morte.

O método INTELLIPave foi desenhado de forma a permitir o acúmulo e reutilização do conhecimento no aperfeiçoamento das predições de performance subseqüentes, criando uma espiral virtuosa onde, quanto mais informações estiverem disponíveis, mais confiáveis e robustas serão as predições futuras.

O mecanismo que suporta o acúmulo e reutilização do conhecimento é baseado na paralelização de modelos individuais de performance. Cada modelo (matriz de performance), possui o conhecimento da performance do pavimento para um determinado conjunto de situações (espessuras de materiais, perfil climático, perfil do tráfego e características do subleito). Na medida em que dois ou mais modelos individuais são organizados em paralelo para funcionarem como um conjunto, formando um CUIA Model, o conhecimento e experiências acumulados nas matrizes de performance passam a se complementar, gerando sinergias e permitindo que o resultado – o CUIA Model – seja capaz de efetuar predições mais acuradas e para um conjunto maior de situações, tais como espessuras de camadas diferentes daquelas dos modelos individuais. De fato, não há limite na quantidade de modelos que podem ser integrados de forma paralela, permitindo que a qualidade das predições seja melhorada de forma contínua.

A Figura 4-20 e a Figura 4-21 apresentam uma simulação simplificada com dados hipotéticos onde o treinamento das redes neurais foi efetuado com a utilização do software NeuroSolutions. Os modelos (individuais) 1, 2, 3, 4, 5 e 6 são acurados para proporcionar resultados (*outputs*) quando os valores (*inputs*) são 10, 11, 12, 14, 15 e 16, respectivamente. Estes *inputs* com os respectivos *outputs* são utilizados para alimentar o CUIA Model que, por sua vez, fará a predição do *output* quando o *input* é 13. Na primeira simulação (Figura 4-20) o CUIA Model foi alimentado com apenas três modelos individuais, enquanto que na segunda simulação (Figura 4-21) o CUIA Model foi alimentado com seis modelos individuais. O treinamento das redes neurais foi efetuado para 10000 ciclos (*epochs*) em ambas as situações e utilizando os mesmos parâmetros. Estas duas simulações foram efetuadas para uma situação simples de comportamento linear para um melhor entendimento; quando o *input* é 13 o valor perfeito para o *output* será 23. A simulação demonstra que o erro é reduzido de 0,985, quando são utilizados três modelos individuais, para apenas 0,033, quando são utilizados seis modelos individuais.

Esta simulação demonstra a adequação e potencial representado pelos modelos paralelos para a modelagem de pavimentos. De fato, redes neurais, e outras topologias de *soft computing*, são excelentes ferramentas para a acumulação e reutilização de dados descrevendo a performance de pavimentos asfálticos, permitindo a melhora contínua das previsões, na medida em que mais conhecimento é acrescentado.

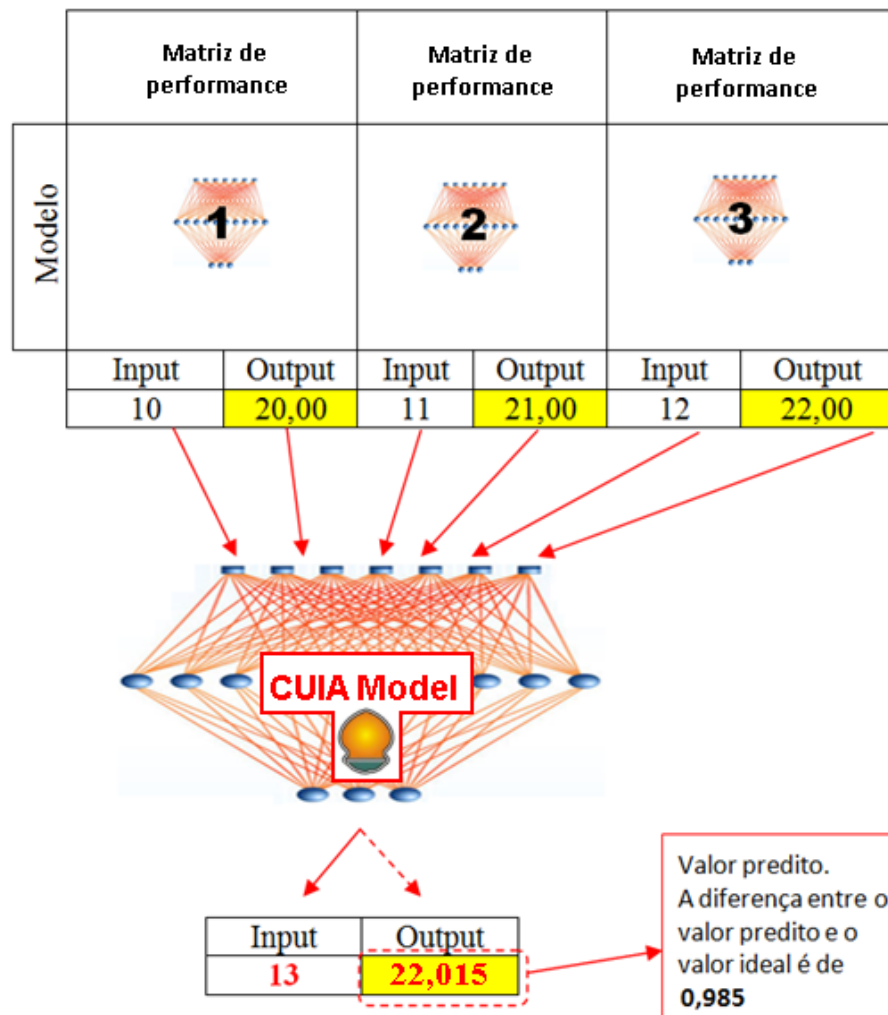


Figura 4-20 – Predição utilizando NN onde três modelos individuais são empregados no treinamento do CUIA Model

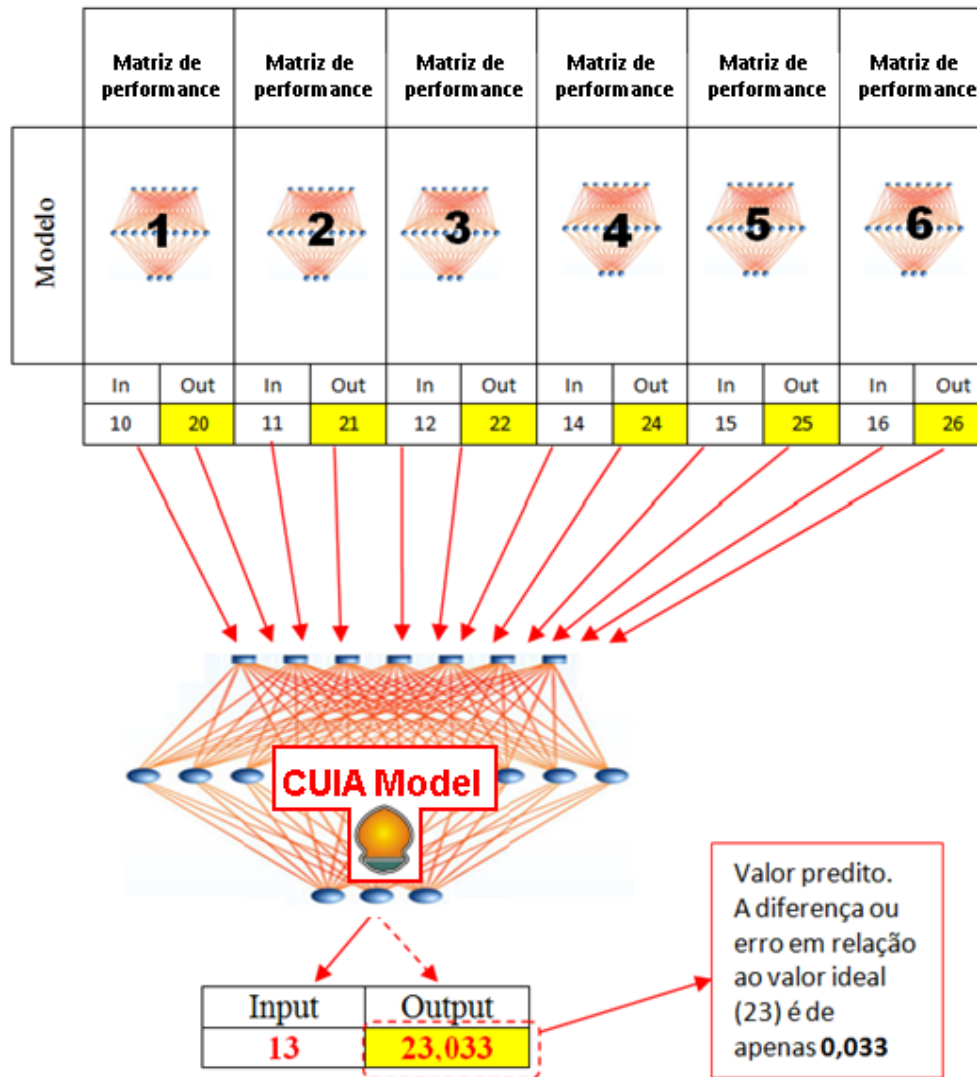


Figura 4-21 - Predição utilizando ANN onde seis modelos individuais são empregados no treinamento do CUIA Model

4.11 Utilizando modelos paralelos especialistas para efetuar predições sem utilizar os dados sobre a resposta estrutural do pavimento

A leitura das variáveis associadas com a resposta estrutural do pavimento (Figura 4-9) depende substancialmente de sensores inseridos dentro da camada asfáltica e demais camadas que constituem o pavimento. Embora em teoria o uso de tais sensores seja simples, a utilização prática se mostra difícil e, em praticamente 100% dos casos, inviável devido à pequena vida útil de tais sensores, impossibilidade de efetuar calibrações confiáveis, perda de acurácia dos elementos eletro-eletrônicos e mecânicos ao longo do tempo, movimentação (lenta) dos sensores dentro do pavimento e grande volume de dados, entre outras dificuldades.

Sensores como *strain gages*, para medir as extensões (deformações específicas) raramente resistem a mais de dois ou três anos de utilização; são como uma espécie de lâmpada incandescente que, com o uso, tem seu filamento degradado e simplesmente “queimam”. Outro fator agravante é a temperatura de construção dos pavimentos, que em alguns casos são executados com o concreto asfáltico a 190°C, o que danifica irremediavelmente parte dos sensores já na fase de construção.

Os dados dos sensores precisariam ser coletados até que o critério de fim da vida útil seja atingido, mas enquanto o pavimento tem uma vida útil média de 10 anos, os sensores resistem poucos anos ou meses e, por estarem inseridos no pavimento, não podem ser substituídos nem receberem manutenção, pois qualquer intervenção implicaria em dano, e por conseqüência, alteração, da estrutura do pavimento. A instrumentação de pavimentos também é dificultada pelos elevados custos e por requer equipes de profissionais com dedicação permanente.

Ainda há o não menos importante fato de que, ao se construir o modelo utilizando dados de sensores dos pavimentos (*strains*, tensões, etc.), no momento de utilizar tal modelo será necessário fornecer as mesmas informações sobre o pavimento que se deseja simular, dimensionar ou modelar. Obter dados como deformações e tensões de um pavimento que está sendo projetado, ou seja, que ainda não existe, pode ser efetuado utilizando-se elementos finitos (Figura 2-29), mas seria necessário efetuar uma simulação (por elementos finitos) para cada veículo e suas respectivas combinações climáticas que interferem no módulo do concreto asfáltico, especialmente a temperatura e o envelhecimento do ligante asfáltico. Embora o cálculo deste mix de milhões de combinações entre veículos e módulos possa ser amplamente automatizado via software, esta seria uma prática inconveniente e questionável, pois a própria simulação por elementos finitos seria simplificada e aproximada, pois as interações entre veículos, clima e pavimentos não são adequadamente compreendidas. Não se deve confundir simulação da capacidade estrutural do pavimento (por elementos finitos) com

modelagem da vida de serviço, que são coisas muito distintas, embora interdependentes. Em qualquer das hipóteses, a simulação por elementos finitos apresentaria uma relação custo-benefício ruim.

Desta forma, a obtenção de dados caracterizando a resposta estrutural do pavimento para uma vida de serviço completa é difícil e mesmo impossível, devido às limitações dos sensores, e seu emprego é inconveniente, devido à necessidade de ter as mesmas informações para os pavimentos em análise ou dimensionamento.

Este problema é contornado pelo fato da metodologia INTELLIPave possuir critério de falha externo ao modelo e contemplar variáveis desconhecidas. Quando os dados sobre a resposta estrutural do pavimento não estão disponíveis, o modelo pode ser construído apenas com dados climáticos e do tráfego. Neste caso a resposta estrutural é incluída no modelo de forma implícita, e não explícita. Isso significa que o modelo é totalmente confiável, mas apenas para previsões de comportamento onde as espessuras das camadas e tipos de materiais (camada de concreto asfáltico, camadas granulares, etc.) e tipo de subleito forem os mesmos daqueles existentes na rodovia onde os dados para a construção do modelo foram coletados. Este é o preço que se paga pela remoção de variáveis, o modelo perde flexibilidade e fica engessado com relação àqueles parâmetros.

Entretanto, é inconveniente utilizar modelos excessivamente engessados ou rígidos. Uma metodologia consistente precisa empregar modelos generalizáveis para outras situações, e a generalização das espessuras das camadas é de grande importância para maximizar a amplitude de validade do modelo.

A solução deste problema passa pela paralelização de dois ou mais modelos individuais, cujos materiais (tipo de concreto asfáltico e tipo de material da camada granular) sejam os mesmos do pavimento cuja performance se deseja modelar, mas tenham espessuras de materiais diferentes. Como já foi mencionado, esta integração em paralelo de dois ou mais modelos (ou matrizes de performance) é chamada de CUIA Model.

A Figura 4-22 mostra como modelos contendo apenas dados climáticos e do tráfego, e cujas espessuras e tipos de materiais são conhecidos, podem ser integrados de forma paralela para a construção do CUIA Model, que é capaz de efetuar previsões de performance para uma gama de espessuras. O comportamento mecânico dos materiais está incluído no modelo de forma implícita, mas não explícita.

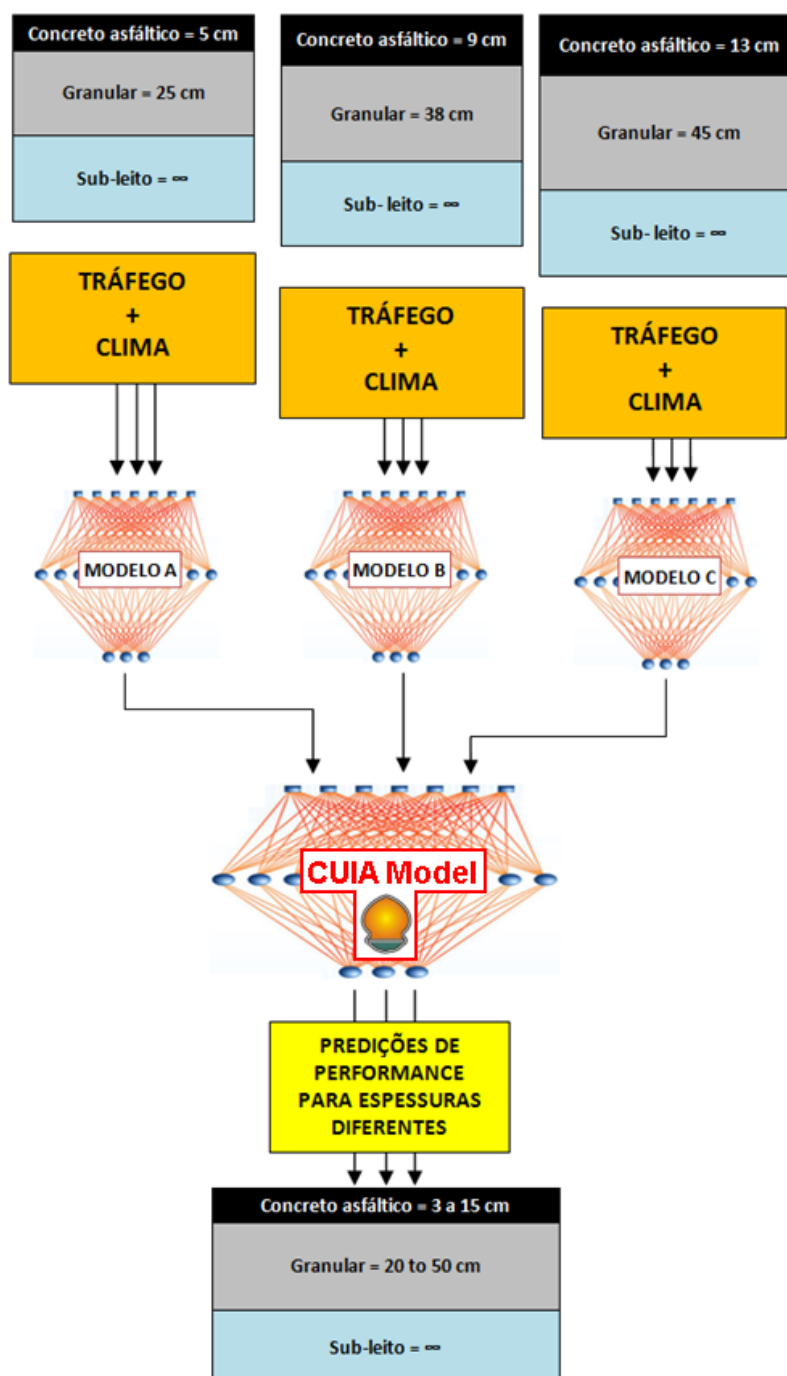


Figura 4-22 - Utilização de modelos paralelos sem dados sobre a resposta estrutural

4.12 Emprego e utilização dos modelos para dimensionamento de pavimentos novos e avaliação de pavimentos existentes

A forma como o método INTELLIPave é utilizado para fins práticos, ou seja, para a modelagem e dimensionamento de pavimentos novos ou avaliação dos existentes é totalmente diferente dos métodos empíricos e empírico-mecanísticos. Não existem eixo padrão ou temperatura de referência, nem outras simplificações comuns nas atuais abordagens para pavimentos asfálticos.

É necessário descrever o pavimento que se deseja dimensionar ou avaliar com as mesmas informações que foram utilizadas para construir o próprio modelo, ou seja, informações a respeito do clima e tráfego, como demonstrado na Figura 4-23.

O tráfego pode ser descrito a partir de um perfil diário, semanal, mensal, trimestral ou mesmo anual, conforme a importância da sazonalidade do tráfego, e a respectiva taxa anual de crescimento do tráfego. No caso de um perfil mais simples, adequado para rodovias sem grandes variações no tráfego ao longo do ano, pode-se utilizar um perfil diário, indicando quantos veículos de cada classe transitam (ou transitarão) no pavimento a cada hora, para as 24 horas do dia, num total de 24 grupos de tráfego; se necessário, para a fiel caracterização do tráfego, cada classe de veículos pode ser sub-dividida de acordo com as cargas nos eixos. Em rodovias sujeitas à grande sazonalidade do tráfego, como nas rodovias que recebem elevado tráfego na época de escoamento de safras agrícolas, é conveniente utilizar um perfil mais completo, como o perfil anual, onde são descritas as quantidades de veículos que transitam no pavimento a cada hora durante os 365 dias do ano, totalizando 8760 grupos de tráfego. As classes dos veículos são apresentadas na Figura 4-8.

O clima precisa, necessariamente, ser descrito através de um perfil anual com dados, preferencialmente, a cada hora, ou seja, para descrever o perfil anual são necessárias 24 leituras diárias para cada um dos 365 dias do ano, ou 8760 leituras contendo, cada uma, todas as variáveis climáticas consideradas no modelo (temperatura do ar, temperatura do pavimento, velocidade do vento, pluviosidade, etc.).

Os dados referentes ao perfil climático podem ser obtidos junto aos institutos de meteorologia que normalmente operam estações meteorológicas automatizadas que produzem dados de hora em hora.

Os dados referentes ao tráfego podem ser obtidos através de contagens, em rodovias existentes, ou através de estimativas, para rodovias novas. Equipamentos totalmente automatizados de *weight-in-motion* (WIM) podem ser instalados (em rodovias existentes) e efetuam a leitura de todas as variáveis para uma completa caracterização do tráfego, inclusive velocidade, classificação e peso por eixo, sem interferir com a fluência do tráfego nem obrigar os motoristas a reduzirem a velocidade.

As informações que descrevem o pavimento que será modelado serão geradas a partir do cruzamento dos perfis de tráfego e climático, veículo por veículo. Este cruzamento vai produzir um grande volume de dados e precisa ser efetuado através de software.

A forma de emprego e interpretação do modelo são discutidas no item “4.3” e exemplificadas na Figura 4-3 e na Figura 4-4.

		Características do tráfego e do clima									Índice relativo de dano ao pavimento		
		A	B	C	D	E	F	G	H	I	...	=	
Modelo		100,27	41,60	34,36	67,88	11313,91	97,34	56,74	265,62	188,32	...	=	119,49
		94,76	37,00	28,39	97,56	14077,49	101,14	60,77	272,30	199,93	...	=	134,25
		146,09	45,29	39,14	57,78	15346,01	102,83	67,06	279,08	208,52	...	=	136,48
		158,79	53,98	17,99	77,59	6073,19	72,26	50,44	232,01	179,40	...	=	108,80
		142,40	52,30	49,74	110,83	10285,04	89,31	61,57	256,26	188,18	...	=	114,34
		70,74	39,39	33,59	54,85	1005,54	77,45	63,24	263,89	190,37	...	=	126,91
		91,82	47,59	10,43				61,48	278,02	197,26	...	=	119,21
		118,81	43,23	20,91				51,23	227,70	168,57	...	=	97,17
		150,41	41,67	27,67				62,77	273,97	200,21	...	=	131,27
		135,68	42,58	45,28				56,13	246,05	183,62	...	=	110,50
		72,83	49,69	37,13				44,44	222,71	168,16	...	=	84,77
		143,11	39,23	31,39				48,84	232,71	168,16	...	=	105,57
		74,47	48,74	30,07				34,51	222,71	168,16	...	=	86,02
		134,35	51,40	13,81	109,36	9565,80	86,03	57,35	222,71	168,16	...	=	113,75
		77,92	43,80	46,04	75,92	1861,60	64,75	46,59	222,71	168,16	...	=	87,67
	131,46	45,23	23,60	57,77	5577,87	76,31	49,40	234,54	176,52	...	=	103,96	
	124,89	45,96	30,11	116,78	13153,89	94,42	60,91	266,18	196,73	...	=	132,62	
	=	...	
Pavimento que está sendo analisado ou dimensionado		49,59	13,88	67,92	14593,78	100,47	62,29	292,89	202,60	136,03	...	=	?
		53,98	10,87	75,37	4114,10	64,04	50,39	235,75	173,41	100,18	...	=	?
		38,82	12,09	73,77	14054,19	102,33	67,10	288,88	200,13	135,66	...	=	?
		54,84	33,33	63,36	3739,18	65,22	45,93	223,23	167,39	101,62	...	=	?
		42,59	22,67	112,37	15155,50	109,79	69,71	276,82	201,66	134,65	...	=	?
		35,83	18,05	57,32	11278,92	96,32	63,96	273,92	196,32	127,48	...	=	?
	=	...	

As variáveis que descrevem o pavimento em avaliação devem ser exatamente as mesmas existentes no modelo, veículo por veículo.

Informações que serão geradas a partir do modelo

Figura 4-23 - As variáveis utilizadas para descrever o pavimento em análise devem ser obrigatoriamente as mesmas utilizadas na construção do modelo

4.13 Tratamento de erro para aperfeiçoar a acurácia do CUIA Model

O erro, ou acurácia reduzida, está sempre presente na engenharia, sobretudo quando se trabalha com materiais de origem natural e, assim, intrinsecamente heterogêneos. Um método de engenharia consistente sempre irá tratar da questão do erro e sua minimização, em vez de ignorá-lo ou negar sua existência.

No caso do CUIA Model o erro pode ocorrer por vários motivos, desde falhas ou inconsistências nos dados coletados em campo para a construção dos modelos até imprecisões no cálculo dos RPDIs, causadas por uma *clusterização* deficiente ou mesmo resultante da natureza intrínseca dos métodos matemáticos utilizados, conforme discutido no item “4.6”.

Na metodologia INTELLIPave a problemática do erro é abordada em duas fases. Primeiro, pela consideração sempre relativa dos RPDIs individuais, que são divididos pelo somatório dos RPDIs, eliminando a parcela do erro que pode ser considerada como relativamente bem distribuída dentro da matriz de performance. Segundo, o erro é diluído através da massificação da construção do problema (descrição matemática do pavimento que será avaliado pelo CUIA Model).

4.13.1 O erro é dividido por ele mesmo

Independentemente das ferramentas de *soft computing* utilizadas na carbotização, haverá algum nível de erro no índice relativo de dano ao pavimento (RPDI). Este índice é denominado “relativo” porque se refere à importância de um veículo em relação aos demais veículos, ou seja, em relação ao somatório dos índices relativos de dano ao pavimento, como discutido no item “4.5”.

O resultado obtido com a carbotização, o índice relativo de dano ao pavimento (RPDI), deve ser compreendido como sendo o resultado do RPDI “verdadeiro” multiplicado por um erro desconhecido (Figura 4-24).

Este erro, mesmo sendo desconhecido, pode ser eliminado se estiver razoavelmente bem distribuído dentro da matriz de performance, em outras palavras, se o erro existente em cada linha da matriz for similar ao erro das demais linhas. Quando isso ocorre, o erro existente no RPDI individual de cada linha também será similar ao erro existente no somatório dos RPDIs.

Por ser relativo, o índice de dano ao pavimento individual é sempre dividido pelo somatório dos índices de dano ao pavimento (ver item “4.5”); como o erro existe em ambos, ao efetuarmos a divisão destes números, o erro é dividido por ele mesmo, e então eliminado (Figura 4-25).

Quanto melhor distribuído o erro estiver dentro da matriz de performance, mais facilmente ele será eliminado através desta abordagem.

$$(\text{RPDI}_{\text{VERDADEIRO}}) = (\text{RPDI}_{\text{CALCULADO}}) \cdot \text{Erro}$$

Figura 4-24 – Índice de dano ao pavimento multiplicado por um erro desconhecido

$$\frac{\text{RPDI}_{\text{VERDADEIRO}}}{(\sum (\text{RPDI}_{\text{VERDADEIRO}}))} = \frac{\text{RPDI}_{\text{CALCULADO}} \cdot \cancel{\text{Erro}}}{(\sum (\text{RPDI}_{\text{CALCULADO}})) \cdot \cancel{\text{Erro}}}$$

∴

$$\frac{\text{RPDI}_{\text{VERDADEIRO}}}{(\sum (\text{RPDI}_{\text{VERDADEIRO}}))} \cong \frac{\text{RPDI}_{\text{CALCULADO}}}{(\sum (\text{RPDI}_{\text{CALCULADO}}))}$$

Figura 4-25 – O erro existente é dividido por ele mesmo e, então, eliminado

4.13.2 O erro remanescente é diluído

Ao tratar da problemática do erro, a metodologia INTELLIPave se beneficia do fato do problema (pavimento a ser avaliado com base no modelo) ser construído de forma completa, sem simplificações, onde cada veículo que transitará pelo pavimento é descrito e tem a sua importância avaliada individualmente através da determinação de um RPDI; isso significa que o problema é descrito através de milhões de linhas (veículos).

Se uma destas linhas (veículos) apresentar um erro qualquer, que não foi eliminado quando da divisão do RPDI individual pelo somatório dos RPDIs - vamos chamá-lo de “erro remanescente” -, será apenas uma linha problemática dentre milhões, e sua importância relativa será muito pequena. Adicionalmente, o erro remanescente em uma linha fará com quem o resultado do RPDI seja superior ao verdadeiro, mas o erro remanescente em outra linha fará com que o resultado do RPDI seja inferior ao verdadeiro, produzindo uma espécie de equilíbrio quando é efetuado o somatório dos RPDIs; quanto mais completa for a descrição do problema, melhor será a diluição do erro remanescente. Como o pavimento em análise é sempre avaliado com base no somatório dos RPDIs, e não nos seus valores individuais, o erro remanescente apresentará, estatisticamente falando, tendência à zero, como representado na Figura 4-26.




Figura 4-26 - Representação simbólica da diluição do erro remanescente

4.13.3 Em pavimentos asfálticos não existem modelos perfeitos

Todo o trabalho sobre modelagem e previsão de pavimentos asfálticos visa o desenvolvimento de modelos que efetuem previsões confiáveis, mas sem esquecer que devido à heterogeneidade dos materiais utilizados na construção dos pavimentos, da grande variabilidade das características e capacidade de suporte do sub-leito (terreno natural), das limitações das previsões do comportamento futuro do clima e da incerteza sobre a quantidade de veículos que transitarão pelo pavimento, em se tratando de pavimentos asfálticos, não existem nem nunca existirão modelos perfeitos.


4.14 Avaliação da qualidade da informação

No anexo A é demonstrada uma metodologia adicional e complementar, que pode ser utilizada como pré-processamento para a metodologia INTELLIPave, para mensuração da qualidade da informação e tratamento de informações incompletas.

4.15 Comparação do método INTELLIPave com os métodos empírico-mecanísticos

A Tabela 4-10 apresenta uma comparação da metodologia INTELLIPave e do método empírico-mecanístico, o mais utilizado a nível mundial para a predição e dimensionamento de pavimentos asfálticos. Não se trata de uma comparação completa, mas apenas sintética e limitada aos pontos-chave visando proporcionar uma visão geral sobre o assunto.

Tabela 4-10 - Comparação entre a metodologia INTELLIPave e o método empírico-mecanístico

<p style="text-align: center;">INTELLIPave</p> 	<p style="text-align: center;">Método empírico-mecanístico</p> $ESAL = SF \cdot (\epsilon_t)^{-f_2} \cdot E^{-f_3}$
<p>Metodologia que utiliza dados de campo analisados através de técnicas científicas e matemáticas amplamente aceitas</p>	<p>Abordagem obsoleta baseada em dados de laboratório</p>
<p>Todas as variáveis são consideradas na exata proporção das suas importâncias</p>	<p>Possui apenas uma variável (ϵ_t) e uma constante (E)</p>
<p>Modelo rico em informações que descrevem os eventos físicos associados aos pavimentos</p>	<p>Possui três fatores de ajuste (SF, f2 e f3)</p>
<p>Utiliza milhões de equações que proporcionam modelagens robustas e confiáveis</p>	<p>Possui uma única equação</p>
<p>Contempla o perfil do tráfego completo</p>	<p>Utiliza de forma inaceitável de fatores de equivalência de eixo (ESAL) de outros métodos</p>
<p>Consideração do perfil climático completo</p>	<p>O clima é reduzido à utilização de uma temperatura (fixa) de referência (geralmente 20°C)</p>
<p>É escalável, permitindo o acúmulo contínuo do conhecimento sobre a performance dos pavimentos e sua reutilização para aperfeiçoamento da acurácia e amplitude de validade das predições futuras</p>	<p>Não proporciona qualquer forma de acumular ou reutilizar o conhecimento</p>
<p>Todos os fatores conhecidos e desconhecidos são considerados na modelagem, de forma explícita ou implícita (visco-elasto-plasticidade, anisotropia, não-linearidade, etc.)</p>	<p>Avaliação simplificada para estrutura elástica e linear</p>
<p>Um novo paradigma para a modelagem e predição de comportamento de pavimentos asfálticos, com amplo espaço para aperfeiçoamentos e em linha com as necessidades do século XXI</p>	<p>Apresentou pouca ou nenhuma evolução desde a sua criação e possui pouco espaço para melhorias.</p>

capítulo 5

5 EXEMPLO NUMÉRICO

Neste capítulo é apresentado um exemplo simplificado e hipotético de aplicação da metodologia INTELLIPave. O objetivo deste exemplo é facilitar a compreensão e servir de guia prático para a construção, passo-a-passo, de modelos, desde a organização dos dados de campo (clima e tráfego) até a aplicação do CUIA Model na modelagem de um pavimento hipotético. Houve a preocupação de manter o exemplo o mais simples possível.

São utilizados dados artificiais e hipotéticos em uma escala muito reduzida para que, mesmo a maior das tabelas de dados, possa ser impressa em uma única folha A4, facilitando a visualização dos parâmetros calculados e de como são utilizados nas etapas sucessivas.

As variáveis que devem ser utilizadas na construção das matrizes de performance são discutidas no item “0”. Neste exemplo são utilizadas apenas quatro variáveis, duas climáticas (temperatura do ar e pluviosidade) e duas de tráfego (velocidade dos veículos e carga total), mas que são totalmente suficientes para demonstração de cálculo que se pretende.

O cálculo dos RPDIs, discutido no item “4.6”, não faz parte do exemplo pelo fato das metodologias para isso – *clusterização* e sistemas de equações – não constituírem nenhuma novidade metodológica; seu emprego tornaria o exemplo desnecessariamente complexo. Os RPDIs utilizados são artificiais.

O critério de falha, discutido no item “4.7”, foi estabelecido em 20% da área trincada, ou seja, quando a superfície do pavimento asfáltico apresentar 20% da área trincada considera-se que o pavimento perdeu a qualidade ou funcionalidade mínima aceitável. Para facilitar a compreensão, a “falha” dos modelos das Estruturas A e B foram ajustadas para “ocorrerem” exatamente após dois anos (Tabela 5-1).

Tabela 5-1 – Quantidade de veículos por estrutura

Estrutura	Vida útil do pavimento até atingir o critério de falha	Critério de falha para a ruína do pavimento
A	2 anos	20% da área superficial trincada
B	2 anos	20% da área superficial trincada
C	(resultado a ser calculado utilizando o CUIA model)	20% da área superficial trincada

São empregadas apenas duas sazonalidades, ano 1 e ano 2, que são suficientes para demonstrar a consideração e cálculo do envelhecimento dos materiais e outros fatores discutidos no item “4.9”. A utilização de um número maior de sazonalidades apenas aumentaria a complexidade numérica do exemplo, dificultando a sua compreensão, sem agregar nenhum benefício metodológico.

Neste exemplo, o acúmulo de conhecimento, discutido no item “4.10”, é efetuado através da paralelização de duas matrizes de performance, que também proporcionam suporte para a predição da performance para pavimentos com diferentes espessuras de camadas, como discutido no item “4.11”. Duas matrizes são suficientes para demonstrar o funcionamento do CUIA Model.

Este exemplo **não** tem como objetivo a construção de um modelo com dados reais. São utilizados poucos veículos e dois anos, mas as informações podem ser entendidas como *clusters* de veículos, e décadas. Isso não altera o cálculo e aplicação do modelo, que é puramente numérica (Figura 5-1).

Um veículo = um *cluster* de 1.000.000 de veículos

Um ano = uma década

Figura 5-1 - A mudança nas unidades do tráfego e tempo não altera a modelagem

A eliminação do erro distribuído na matriz de desempenho (discutido no item “4.13.1”) é efetuada no item “5.1.1”, juntamente com o cálculo das durabilidades anuais. Adicionalmente, o erro é diluído pela construção do problema (pavimento em análise) de forma completa, como discutido no item “4.13.2”.

A Figura 5-2 apresenta o esquema dos pavimentos utilizados na construção das duas matrizes de performance (estruturas A e B) e do pavimento em análise (estrutura C), o fluxo de cálculo e o número das respectivas tabelas.

A Tabela 5-3, a Tabela 5-4 e a Tabela 5-5 apresentam os dados de tráfego e clima para as estruturas A, B e C, respectivamente, e a evolução do critério de falha.

A Tabela 5-6 e a Tabela 5-7 apresentam as matrizes de performance (clima e tráfego + RPDIs), juntamente com a análise dos RPDIs; esta análise constitui informação adicional e não é requerida nas etapas posteriores. Em ambos os casos os RPDIs foram determinados considerando a evolução do critério de falha (área trincada) no final do respectivo ano, ou seja, os RPDIs já estão balanceados de acordo com os fatores discutidos no item “4.9”. Foram utilizadas as seguintes equações de apoio: Equação 5-1, Equação 5-2, Equação 5-3 e Equação 5-4; os valores aos quais as equações são igualadas (8000, 12000, 7000 e 13000, respectivamente) foram arbitrados com base na evolução do critério de falha (área trincada de 8%, 12%, 7% e 13%, respectivamente).

$$\left(\sum_{\text{Veículo} = 1}^5 RPD I \right) = 8000$$

Equação 5-1 – Estrutura A, ano 1 - Somatório dos RPD I igual a 8000

$$\left(\sum_{\text{Veículo} = 6}^{10} RPD I \right) = 12000$$

Equação 5-2 – Estrutura A, ano 2 - Somatório dos RPD I igual a 12000

$$\left(\sum_{\text{Veículo} = 1}^{10} RPD I \right) = 7000$$

Equação 5-3 – Estrutura B, ano 1 - Somatório dos RPD I igual a 7000

$$\left(\sum_{\text{Veículo} = 11}^{20} RPD I \right) = 13000$$

Equação 5-4 – Estrutura B, ano 2 - Somatório dos RPD I igual a 13000

A Tabela 5-8 e Tabela 5-9 apresentam o cálculo dos RPDIs para a combinação de tráfego e clima da estrutura C com base nos valores da matriz de performance da estrutura A (matriz de performance A) empregando redes neurais, para os anos 1 e 2. As redes foram treinadas com base na matriz de performance A através de aprendizado supervisionado e empregando a pluviosidade, temperatura do ar, velocidade e carga total como *inputs*, e os respectivos RPDIs

como *outputs*. Treinadas, as redes neurais calcularam os valores de RPDIs para a estrutura C utilizando como *inputs* os mesmos parâmetros (*inputs*) utilizados no treinamento. A Tabela 5-10 e a Tabela 5-11 apresentam idêntico procedimento, mas utilizando a matriz de performance B para treinamento das redes neurais, também para os anos 1 e 2.

Neste ponto do cálculo é conhecida a durabilidade da estrutura C, utilizando o respectivo tráfego e clima (previstos para a estrutura C), mas considerando que as espessuras de camadas da estrutura C são as mesmas da estrutura A ou da estrutura B; entretanto, suas espessuras são diferentes. Isso é equacionado no passo seguinte, com a aplicação do CUIA Model, que permite “generalizar” a metodologia expandindo o leque de espessuras que podem ser avaliadas.

Para facilitar a compreensão, as tabelas que apresentam dados que foram utilizados no treinamento, ou produção, empregando redes neurais utilizam a convenção de cores indicada na Tabela 5-2.

Tabela 5-2 - Convenção de cores para identificar os *inputs* e *outputs* utilizado nas redes neurais

<i>input</i> para treinamento das redes neurais	<i>output</i> para treinamento das redes neurais
<i>input</i> para produção utilizando redes neurais	Resultado (<i>output</i>) calculado pelas redes neurais

O cálculo empregando o CUIA Model é apresentado no item “5.1”.

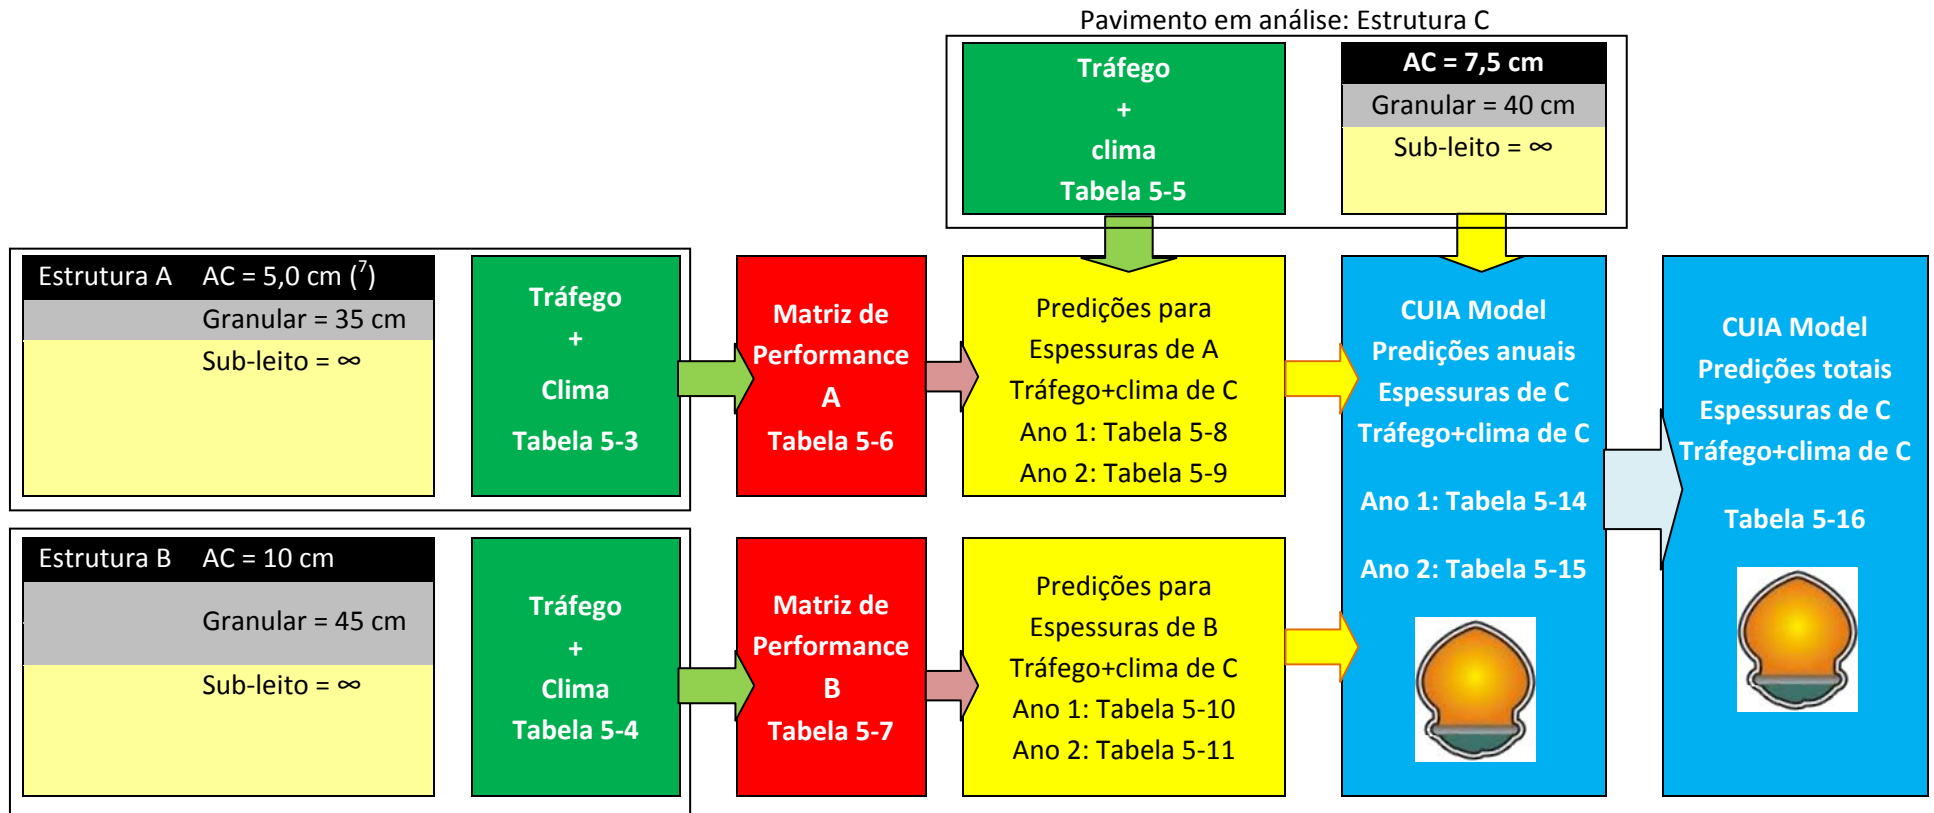


Figura 5-2 – Esquema de cálculo e avaliação para determinar a durabilidade da estrutura C

⁷ AC = Asphalt Concret (concreto asfáltico)

Tabela 5-3 - Estrutura A – Dados do clima e tráfego até atingir o critério de falha

Contagem dos veículos	Ano	Pluviosidade (mm/h)	Temperatura do ar (°C)	Velocidade (km/h)	Carga total (t)	Critério de falha Área trincada %
1	1	3	15	71	25,3	0,0
2	1	29	25	101	5,9	0,0
3	1	13	24	83	22,8	2,0
4	1	13	30	111	25,3	5,0
5	1	15	21	84	34,8	8,0
6	2	13	16	75	1,0	9,0
7	2	27	21	110	52,7	10,0
8	2	25	22	108	45,0	13,0
9	2	0	18	106	11,2	17,0
10	2	0	25	107	8,7	20,0

Tabela 5-4 - Estrutura B – Dados do clima e tráfego até atingir o critério de falha

Contagem dos veículos	Ano	Pluviosidade (mm/h)	Temperatura do ar (°C)	Velocidade (km/h)	Carga total (t)	Critério de falha Área trincada %
1	1	18	22	79	25,5	0,0
2	1	17	20	116	1,4	0,0
3	1	20	25	105	1,0	0,0
4	1	15	26	86	30,6	0,0
5	1	10	27	109	0,3	1,0
6	1	22	13	75	32,1	2,0
7	1	8	20	101	27,7	4,0
8	1	28	25	97	1,3	5,0
9	1	0	29	100	48,6	6,0
10	1	0	14	108	34,0	7,0
11	2	0	19	103	43,4	8,0
12	2	0	32	90	1,2	8,5
13	2	0	25	86	21,9	9,0
14	2	0	16	102	0,8	10,0
15	2	0	18	94	18,0	12,0
16	2	0	15	79	60,6	15,0
17	2	0	27	66	19,1	15,9
18	2	0	25	120	50,9	17,0
19	2	0	13	95	42,5	18,0
20	2	0	10	101	45,8	20,0

Tabela 5-5 - Estrutura C – Dados do clima e tráfego para determinação dos RPDIs

Contagem dos veículos	Ano	Pluviosidade (mm/h)	Temperatura do ar (°C)	Velocidade (km/h)	Carga total (t)	RPDI
1	1	16	10	105	8,6	?
2	1	3	19	110	1,5	?
3	1	21	10	75	0,3	?
4	1	17	23	95	10,2	?
5	1	28	14	113	32,6	?
6	1	29	18	114	42,7	?
7	1	11	29	95	23,0	?
8	1	6	24	106	0,9	?
9	1	0	28	75	20,5	?
10	1	0	11	79	24,7	?
11	1	0	10	82	16,5	?
12	1	0	24	95	25,9	?
13	2	0	15	92	0,8	?
14	2	0	32	100	16,9	?
15	2	0	16	69	4,7	?
16	2	0	16	107	41,9	?
17	2	0	24	85	1,5	?
18	2	0	24	80	44,0	?
19	2	0	29	95	2,0	?
20	2	0	11	77	40,2	?
21	2	0	17	87	10,2	?
22	2	0	16	82	1,2	?
23	2	0	20	88	37,9	?

Tabela 5-6 - Estrutura A - Matriz de Performance

Contagem dos veículos	Ano	Clima		Veículos		Critério de falha Área trincada (%)	RPDI ⁸	Calculado com base no RPDI		
		Pluviosidade (mm/h)	Temperatura do ar (°C)	Velocidade (km/h)	Carga total (t)			Σ RPDI	Vida de serviço consumida	
									%	Σ
1	1	3	15	71	25,3		1.715,59		8,6%	8,6%
2	1	29	25	101	5,9		542,40		2,7%	11,3%
3	1	13	24	83	22,8		1.591,25		8,0%	19,2%
4	1	13	30	111	25,3		1.782,08		8,9%	28,2%
5	1	15	21	84	34,8	8,0	2.368,68	8.000,00	11,8%	40,0%
6	2	13	16	75	1,0		239,69		1,2%	41,2%
7	2	27	21	110	52,7		5.155,32		25,8%	67,0%
8	2	25	22	108	45,0		4.429,89		22,1%	89,1%
9	2	0	18	106	11,2		1.198,31		6,0%	95,1%
10	2	0	25	107	8,7	20,0	976,79	12.000,00	4,9%	100,0%
							20.000,00	20.000,00		

⁸ Os RPDIs estão balanceados de acordo com a evolução anual do critério de falha (área trincada)

Tabela 5-7 - Estrutura B - Matriz de Performance

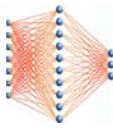
Contagem dos veículos	Ano	Clima		Veículos		Critério de falha Área trincada (%)	RPDI ⁹	Calculado com base no RPDI			
		Pluviosidade (mm/h)	Temperatura do ar (°C)	Velocidade (km/h)	Carga total (t)			Σ RPDI	Vida de serviço consumida		
									%	Σ	
1	1	18	22	79	25,5		861,60		4,31%	4,31%	
2	1	17	20	116	1,4		115,14		0,58%	4,88%	
3	1	20	25	105	1,0		103,46		0,52%	5,40%	
4	1	15	26	86	30,6		1.024,47		5,12%	10,52%	
5	1	10	27	109	0,3		75,92		0,38%	10,90%	
6	1	22	13	75	32,1		1.066,69		5,33%	16,24%	
7	1	8	20	101	27,7		929,76		4,65%	20,89%	
8	1	28	25	97	1,3		116,76		0,58%	21,47%	
9	1	0	29	100	48,6		1.585,40		7,93%	29,40%	
10	1	0	14	108	34,0	7,0	1.120,80	7.000,00	5,60%	35,00%	
11	2	0	19	103	43,4		1.832,69		9,16%	44,16%	
12	2	0	32	90	1,2		116,40		0,58%	44,75%	
13	2	0	25	86	21,9		952,57		4,76%	49,51%	
14	2	0	16	102	0,8		95,36		0,48%	49,99%	
15	2	0	18	94	18,0		793,07		3,97%	53,95%	
16	2	0	15	79	60,6		2.518,18		12,59%	66,54%	
17	2	0	27	66	19,1		829,72		4,15%	70,69%	
18	2	0	25	120	50,9		2.150,83		10,75%	81,44%	
19	2	0	13	95	42,5		1.787,89		8,94%	90,38%	
20	2	0	10	101	45,8	20,0	1.923,29	13.000,00	9,62%	100,00%	
							20.000,00	20.000,00			

⁹ Os RPDIs estão balanceados de acordo com a evolução anual do critério de falha (área trincada)

Tabela 5-8 - Determinação dos RPDIs para a Estrutura C com base na matriz de performance A para o ano 1 utilizando redes neurais

	Contagem dos veículos	Ano	Clima		Veículos		RPDI
			Pluviosidade (mm/h)	Temperatura do ar (°C)	Velocidade (km/h)	Carga total (t)	
Matriz de Performance A	1	1	3	15	71	25,3	1715,6
	2	1	29	25	101	5,9	542,4
	3	1	13	24	83	22,8	1591,2
	4	1	13	30	111	25,3	1782,1
	5	1	15	21	84	34,8	2368,7

Σ 8000,0

Estrutura C 	1	1	16	10	105	8,6	542,8
	2	1	3	19	110	1,5	472,0
	3	1	21	10	75	0,26	482,5
	4	1	17	23	95	10,2	596,1
	5	1	28	14	113	32,6	2339,7
	6	1	29	18	114	42,7	2442,9
	7	1	11	29	95	23	1542,9
	8	1	6	24	106	0,9	472,5
	9	1	0	28	75	20,5	1124,6
	10	1	0	11	79	24,7	1539,9
	11	1	0	10	82	16,5	739,5
	12	1	0	24	95	25,9	1660,5

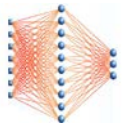
Σ 13955,9

Obs.: Cálculo efetuado com o emprego de redes neurais

Tabela 5-9 - Determinação dos RPDIs para a Estrutura C com base na matriz de performance A para o ano 2

	Contagem dos veículos	Ano	Clima		Veículos		RPDI
			Pluviosidade (mm/h)	Temperatura do ar (°C)	Velocidade (km/h)	Carga total (t)	
Matriz de Performance A	6	2	13	16	75	1	239,7
	7	2	27	21	110	52,7	5.155,3
	8	2	25	22	108	45	4.429,9
	9	2	0	18	106	11,2	1.198,3
	10	2	0	25	107	8,7	976,8

Σ 12.000,0

Estrutura C 	13	2	0	15	92	0,8	538,3
	14	2	0	32	100	16,9	1.205,2
	15	2	0	16	69	4,7	345,6
	16	2	0	16	107	41,9	4.889,4
	17	2	0	24	85	1,5	395,6
	18	2	0	24	80	44	2.585,0
	19	2	0	29	95	2	565,2
	20	2	0	11	77	40,2	5.091,0
	21	2	0	17	87	10,2	758,3
	22	2	0	16	82	1,2	397,5
23	2	0	20	88	37,9	2.982,5	

Σ 19.215,3

Obs.: Cálculo efetuado com o emprego de redes neurais

Tabela 5-10 - Determinação dos RPDIs para a Estrutura C com base na matriz de performance B para o ano 1

	Contagem dos veículos	Ano	Clima		Veículos		RPDI
			Pluviosidade (mm/h)	Temperatura do ar (°C)	Velocidade (km/h)	Carga total (t)	
Matriz de Performance B	1	1	18	22	79	25,5	861,6
	2	1	17	20	116	1,4	115,1
	3	1	20	25	105	1	103,5
	4	1	15	26	86	30,6	1024,5
	5	1	10	27	109	0,32	75,9
	6	1	22	13	75	32,1	1066,7
	7	1	8	20	101	27,7	929,8
	8	1	28	25	97	1,3	116,8
	9	1	0	29	100	48,6	1585,4
	10	1	0	14	108	34	1120,8

Σ 7000,0

Estrutura C	1	1	16	10	105	8,6	452,4
	2	1	3	19	110	1,5	129,6
	3	1	21	10	75	0,26	413,0
	4	1	17	23	95	10,2	295,4
	5	1	28	14	113	32,6	1005,5
	6	1	29	18	114	42,7	1230,0
	7	1	11	29	95	23	735,1
	8	1	6	24	106	0,9	100,2
	9	1	0	28	75	20,5	700,2
	10	1	0	11	79	24,7	945,0
	11	1	0	10	82	16,5	752,2
	12	1	0	24	95	25,9	916,4

Σ 7675,0

Obs.: Cálculo efetuado com o emprego de redes neurais

Tabela 5-11 - Determinação dos RPDIs para a Estrutura C com base na matriz de performance B para o ano 2

	Contagem dos veículos	Ano	Clima		Veículos		RPDI
			Pluviosidade (mm/h)	Temperatura do ar (°C)	Velocidade (km/h)	Carga total (t)	
Matriz de Performance B	11	2	0	19	103	43,4	1.832,7
	12	2	0	32	90	1,2	116,4
	13	2	0	25	86	21,9	952,6
	14	2	0	16	102	0,8	95,4
	15	2	0	18	94	18	793,1
	16	2	0	15	79	60,6	2.518,2
	17	2	0	27	66	19,1	829,7
	18	2	0	25	120	50,9	2.150,8
	19	2	0	13	95	42,5	1.787,9
	20	2	0	10	101	45,8	1.923,3
							Σ 13.000,0
Estrutura C	13	2	0	15	92	0,8	149,7
	14	2	0	32	100	16,9	677,0
	15	2	0	16	69	4,7	218,6
	16	2	0	16	107	41,9	1.756,9
	17	2	0	24	85	1,5	124,8
	18	2	0	24	80	44	2.098,3
	19	2	0	29	95	2	127,8
	20	2	0	11	77	40,2	1.850,8
	21	2	0	17	87	10,2	403,4
	22	2	0	16	82	1,2	145,4
	23	2	0	20	88	37,9	1.754,8
							Σ 9.157,8

Obs.: Cálculo efetuado com o emprego de redes neurais

5.1 Aplicação do CUIA Model

5.1.1 Cálculo das durabilidades anuais para as espessuras das matrizes de performance

O cálculo das durabilidades anuais é efetuado através da divisão do somatório dos RPDIs da matriz de desempenho (estruturas A e B) dividido pelo somatório dos RPDIs da estrutura em análise. Nesta etapa o erro de cálculo dos RPDIs que está distribuído de forma homogênea na matriz de desempenho é eliminado através da divisão do erro por ele próprio, como foi discutido no item "4.13.1". Como o somatório dos RPDIs das matrizes de desempenho é anualizado, o resultado será em anos (Equação 5-5).

$$Durabilidade = \left(\frac{\sum RPD\text{I Referência} \cdot \text{Erro}}{\sum RPD\text{I Calculado} \cdot \text{Erro}} \right) = \left(\frac{\sum RPD\text{I Referência}}{\sum RPD\text{I Calculado}} \right)$$

Equação 5-5 – Cálculo da durabilidade do pavimento através da relação entre os somatórios dos RPDIs

A Tabela 5-12 e Tabela 5-13 apresentam o cálculo da durabilidade das estruturas para os anos 1 e 2, respectivamente. Esta durabilidade refere-se à situação onde são utilizados os dados do clima e do tráfego da estrutura C modelados com base nas espessuras de camadas das estruturas A e B.

Tabela 5-12 - Cálculo da durabilidade no ano 1 utilizando o tráfego e o clima da estrutura C e as espessuras das estruturas A e B

	Somatório dos RPDIs no Ano 1		Durabilidade (anos)
	Referência	Calculado	
Estrutura A	8000,0	13955,9	0,57
Estrutura B	7000,0	7675,0	0,91

Tabela 5-13 - Cálculo da durabilidade no ano 2 utilizando o tráfego e o clima da estrutura C e as espessuras das estruturas A e B

	Somatório dos RPDI no Ano 2		Durabilidade (anos)
	Referência	Calculado	
Estrutura A	12000,0	19215,3	0,62
Estrutura B	13000,0	9157,8	1,42

5.1.2 Cálculo da durabilidade da estrutura C utilizando redes neurais

A Tabela 5-14 e Tabela 5-15 apresentam o cálculo da durabilidade da estrutura C para os anos 1 e 2, respectivamente. É nesta etapa em que a problemática das espessuras é equacionada, ou seja, que é efetuado o cálculo da durabilidade para uma combinação de espessuras de camadas (estrutura C) que não ocorre em nenhuma das matrizes de performance (A e B).

O cálculo é efetuado com redes neurais e a Tabela 5-2 apresenta a convenção de cores utilizada para identificar os conjuntos de dados (*inputs* e *outputs*) para treinamento supervisionado e aplicação do resultado destas redes.

Tabela 5-14 - Cálculo da durabilidade no ano 1 utilizando as espessuras de camadas, o tráfego e o clima da estrutura C

Ano	Estrutura	Espessuras		Durabilidade (anos)
		AC (cm)	Granular (cm)	
1	A	5	35	0,57
1	B	10	45	0,91
1	C	7,5	40	0,74

Obs.: Cálculo efetuado com o emprego de redes neurais

Tabela 5-15 - Cálculo da durabilidade no ano 2 utilizando as espessuras de camadas, o tráfego e o clima da estrutura C

Ano	Estrutura	Espessuras		Durabilidade (anos)
		AC (cm)	Granular (cm)	
2	A	5	35	0,62
2	B	10	45	1,42
2	C	7,5	40	0,89

Obs.: Cálculo efetuado com o emprego de redes neurais

A Tabela 5-16 apresenta o somatório das durabilidades anuais estimadas pelas redes neurais para a estrutura C (Tabela 5-14, Tabela 5-15) de acordo com o critério de falha considerado. Como pode-se ver, o CUIA Model estima que a estrutura vai atingir 20% da área trincada após 1,63 anos. Cabe ao projetista do pavimento avaliar se esta durabilidade é adequada ou não para a rodovia em estudo, considerando a durabilidade desejada, a disponibilidade financeira e outros fatores. Caso a durabilidade seja considerada inadequada, será necessário modificar as espessuras das camadas da estrutura C e repetir todo o processo de cálculo iniciado na Tabela 5-8.

Tabela 5-16 - Cálculo da durabilidade total final para a estrutura C

Ano	Estrutura	AC (cm)	Granular (cm)	Durabilidade (anos)
1	C	7,5	40	0,74
2	C	7,5	40	0,89
A estrutura C atingirá 20% de área trincada após				Σ 1,63

5.2 Discussão

A metodologia INTELLIPave, tal como apresentada nos capítulos anteriores, não contempla as características do sub-leito e materiais utilizados na construção dos pavimentos asfálticos. Esta foi uma escolha premeditada para evitar que o método seja visto como de extrema complexidade.

Neste capítulo é discutida a consideração de diferentes subleitos e diferentes materiais e é demonstrado onde e como são empregados os modelos paralelos para reutilizar o conhecimento acumulado.

5.2.1 Mecanismo de acúmulo do conhecimento, consideração do sub-leito e de diferentes materiais

A Tabela 5-17 apresenta como seria o cálculo da durabilidade da estrutura em avaliação, neste caso denominada estrutura "L", caso houvessem 11 matrizes de performance disponíveis. Este cálculo não faz parte do exemplo apresentado no capítulo anterior, mas visa melhor demonstrar o funcionamento do mecanismo de acúmulo de conhecimento. Também é demonstrada como seria a consideração da capacidade estrutural do sub-leito (terreno natural), representada pelo módulo do mesmo.

Neste caso as redes neurais são submetidas a treinamento supervisionado utilizando as espessuras e módulos do sub-leito (*inputs*) e a durabilidade (*outputs*) das matrizes de

desempenho A até K. As espessuras da estrutura “L” e respectivo módulo do sub-leito são utilizados como inputs para a determinação da durabilidade. A convenção de cores utilizada é a mesma indicada na Tabela 5-2.

Como se trata de uma demonstração de funcionamento do mecanismo, o cálculo foi efetuado apenas para o primeiro ano, mas em uma situação real a durabilidade final seria aquela resultante do acúmulo das durabilidades anuais, como foi efetuado para o exemplo do capítulo anterior na Tabela 5-16.

Tabela 5-17 – CUIA Model - Cálculo da durabilidade da estrutura “L” utilizando as espessuras de camadas e o módulo do sub-leito e empregando redes neurais como máquina de cálculo

Ano	Estrutura	Espessuras		Módulo do sub-leito (MPa)	Durabilidade (anos)
		AC (cm)	Granular (cm)		
1	A	5	35	89	0,32
1	B	6	30	100	0,54
1	C	7,5	42	56	0,65
1	D	8	37	75	0,79
1	E	9,5	50	32	0,86
1	F	10	45	85	0,95
1	G	11	55	56	1,30
1	H	12	43	96	1,48
1	I	13	43	160	1,33
1	J	14	39	49	2,04
1	K	15	48	25	2,16
1	L	9	42,5	88	0,72

A Tabela 5-18 apresenta uma versão ainda mais sofisticada, onde é demonstrado como podem ser inseridas as características dos materiais de pavimentação. Neste caso são incluídas apenas três características do concreto asfáltico: o volume de vazios, o teor de ligante asfáltico e o volume de vazios do agregado mineral. Outros parâmetros para caracterizar o concreto asfáltico e também as camadas granulares poderiam ser empregados da mesma forma.

Como regra geral na metodologia INTELLIPave, as matrizes de performance oferecem suporte para o registro, acúmulo e utilização de informações e parâmetros que são diferentes em função da passagem de cada veículo (velocidade, temperatura do ar, etc.), enquanto o CUIA Model incorpora os parâmetros que não se modificam devido à passagem de cada veículo, mas são diferentes de um pavimento para o outro (espessuras de camadas, características de materiais, etc.).

Tabela 5-18 – CUIA Model - Cálculo da durabilidade utilizando as espessuras das camadas e características do sub-leito e materiais empregando redes neurais

Ano	Estrutura	Espessuras		Módulo do sub-leito (MPa)	Características do concreto asfáltico (AC)			Durabilidade (anos)
		AC (cm)	Granular (cm)		Volume de vazios (%)	Teor de ligante (%)	Vazios do agregado mineral (%)	
1	A	5	35	89	5,0	3,8	15,3	0,32
1	B	6	30	100	4,8	5,4	16,5	0,54
1	C	7,5	42	56	3,9	4,7	17,9	0,65
1	D	8	37	75	6,4	5,3	14,6	0,79
1	E	9,5	50	32	7,1	3,9	15,7	0,86
1	F	10	45	85	5,5	5,7	16,3	0,95
1	G	11	55	56	4,3	4,9	16,9	1,30
1	H	12	43	96	6,0	4,1	14,8	1,48
1	I	13	43	160	4,8	5,1	17,2	1,33
1	J	14	39	49	4,7	6,1	17,4	2,04
1	K	15	48	25	4,4	4,6	15,9	2,16
1	L	9	42,5	88	5,3	5,7	16,6	0,80

5.2.2 Utilizando o princípio do CUIA Model para incluir outras informações

Caso no futuro sejam identificados conjuntos de informações que não possam ser acomodados nas matrizes de performance nem no CUIA Model, pode-se criar uma nova “camada” dentro da metodologia INTELLIPave, que poderia ficar no topo da metodologia tal como apresentada até aqui. Esta utilização é demonstrada na Figura 5-3 onde a nova camada é denominada simbolicamente de GUAPO Model.

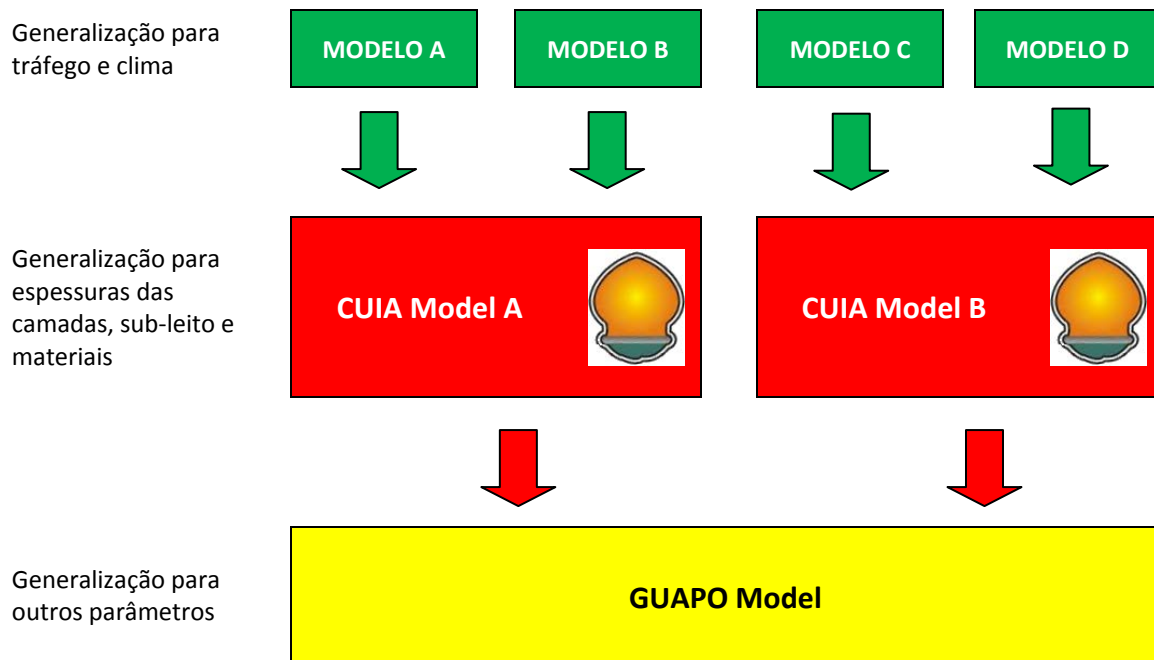


Figura 5-3 – Inserção de generalização para outras características na metodologia INTELLIPave

capítulo 6

6 CONCLUSÕES E DESENVOLVIMENTOS FUTUROS

6.1 Conclusões

A metodologia INTELLIPave demonstra a viabilidade do emprego de abordagens racionais para a pavimentação asfáltica, em substituição às atuais abordagens empíricas e empírico-mecanísticas.

A metodologia INTELLIPave proporciona uma forma robusta, racional e científica para o registro e reutilização de eventos relacionados com a performance e durabilidade dos pavimentos asfálticos. Eventos que se modificam com a passagem de cada veículo (velocidade, carga, temperatura do ar, etc.) são registrados nas matrizes de performance, enquanto que fatores que se alteram apenas de um pavimento para o outro (espessuras de camadas, tipos de materiais, etc.) são considerados no CUIA Model.

As matrizes de performance estruturam informações altamente mutáveis para serem consideradas no CUIA Model, proporcionando modularização e robustez à metodologia.

Os índices relativos de dano ao pavimento (RPDIs) proporcionam uma forma racional e matemática de avaliar o dano que cada veículo produz no pavimento.

A utilização do critério de falha externo ao modelo flexibiliza e potencializa a metodologia, permitindo a adoção de múltiplos critérios de falhas e a consideração de variáveis desconhecidas.

A consideração sazonalizada (anual, *et cetera*) do critério de falha permite a incorporação e consideração do envelhecimento dos materiais asfálticos.

A paralelização de modelos individuais (paralelização de matrizes de performance) proporciona um mecanismo robusto para acúmulo e reutilização do conhecimento sobre a performance dos pavimentos asfálticos.

Por utilizar gigantescas quantidades de informações a metodologia INTELLIPave pode parecer complexa, quando comparada com métodos empíricos e empírico-mecanísticos, mas permite quase total automação através de softwares, o que inclui a coleta automatizada de dados de campo (clima e tráfego) através de sensores eletrônicos (estações meteorológicas automáticas e sistemas de *weight-in-motion*) para a construção de matrizes de performance.

É digno de nota que o emprego da metodologia INTELLIPave utiliza milhões de informações como dados de entrada para, ao final, ter como resultado um único e singelo número, como mostrado na Tabela 5-16.

6.2 Sugestões para desenvolvimentos futuros

O passo seguinte natural no desenvolvimento da metodologia INTELLIPave é a **construção de um modelo pioneiro com dados reais** que permitirá a melhor compreensão do método bem como propiciará uma nova base para outros aperfeiçoamentos.

Sendo nova e construída desde suas mais profundas bases, a metodologia INTELLIPave apresenta grande espaço para aperfeiçoamentos. Dentre os aspectos que podem ser melhor desenvolvidos incluem-se:

- A identificação da melhor, mais rápida e mais confiável abordagem para o cálculo e validação dos RPDIs (discutido no item “4.6”);
- Avaliação do impacto produzido pela paralelização de matrizes de performance construídas com variáveis diferentes;
- Inclusão da consideração da influência das condições de drenagem da rodovia;
- Melhor desenvolvimento e identificação das melhores variáveis para as:
 - Propriedades do sub-leito; e,
 - Características dos materiais empregados na construção das camadas do pavimento asfáltico.

capítulo 7

7 BIBLIOGRAFIA

AASHTO, 2004. *Pavement Design Guide*. Memorandum. Frankfort, Kentucky: American Association of State Highway and Transportation Officials.

Abdallah, I., Ferregut, C. & Melchor-Lucero, O., 2001. *Stiffness Properties of Composite Pavements Using Artificial Neural Network-Based Methodologies*. Research Report 1711-3F. El Paso: The University of Texas at El Paso. Sponsors: Texas Department of Transportation and Federal Highway Administration.

Abdallah, I., Ferregut, C. & Nazarian, S., 1998. Nondestructive Integrity Evaluation of Pavements Using Artificial Neural Networks. *First International Conference on New Information Technologies for Decision Making in Civil Engineering*, p.539–550.

Abdallah, I., Ferregut, C., Nazarian, S. & Melchor-Lucero, O., 1999. Prediction of Remaining Life of Flexible Pavements with Artificial Neural Networks Models. *Nondestructive Testing of Pavements and Backcalculation of Moduli*, 3.

Abdallah, I., Melchor-Lucero, O., Ferregut, C. & Nazarian, S., 2000. *Development of a Comprehensive, Rational Method for Determination of Remaining Life of an Existing Pavement*. Research Report 1711-2. El Paso, Texas, United States of America: The University of Texas at El Paso. Sponsor: Texas Department of Transportation.

Abdallah, I., Nazarian, S., Melchor-Lucero, O. & Ferregut, C., 1999. Validation of Remaining Life Models Using Texas Mobile Load Simulator. *Proceedings of the First Accelerated Pavement Testing Conference*.

Akerkar, R. & Sajja, P., 2009. *Knowledge-Based Systems*. Estados Unidos: Jones & Bartlett Publishers. ISBN-13: 9780763776473.

- Attoh-Okine, N.O., 1998. Artificial Intelligence and Mathematical Methods in Pavement and Geomechanical Systems. *Proceedings of the Workshop at Florida International University*.
- Aultman-Hall, L., Jackson, E., Dougan, C.E. & Choi, S.-N., 2004. Models Relating Pavement Quality Measures. *Transportation Research Record 1869*.
- Axtell, R.L., Andrews, C.J. & Small, M.J., 2003. *Agent-Based Models of Industrial Ecosystems*. [Online] Available at: <http://policy.rutgers.edu/andrews/projects/abm/abmarticle.htm> [Accessed 13 October 2010].
- Banan, M.R. & Hjelmstad, K.D., 1995. A Monte Carlo Strategy for Data-Based Mathematical Modeling. *Journal of Mathematical and Computer Modeling*, 22(8), pp.73-90.
- Banan, M.R. & Hjelmstad, K.D., 1996. Neural Networks and the AASHO Road Test. *Journal of Transportation Engineering*, 122(5), p.358– 366.
- Barone, D.A.C., 2003. *Sociedades Artificiais: a nova fronteira da inteligencia nas máquinas*. Porto Alegre: Bookman.
- Basheer, I.A., 1998. Neuromechanistic-Based Modeling and Simulation of Constitutive Behavior of Fine-Grained Soils. *Ph. D. dissertatio*.
- Basheer, I.A. & Najjar, Y.M., 1996. Neural Network–Based Distress Model for Kansas JPCP Longitudinal Joints. *Intelligent Engineering Systems through Artificial Neural Networks*, 6, p.983–988.
- Basheer, I.A. & Najjar, Y.M., 1998. Modeling Cyclic Constitutive Behavior by Neural Networks: Theoretical and Real Data. *Proceedings of the 12th Engineering Mechanics Conference*, p.952– 955.
- Bayrak, M.B., Teomete, E. & Agarwal, M., 2004. Use of Artificial Neural Networks for Predicting Rigid Pavement Roughness. *Midwest Transportation Consortium*.
- Bianchini, A. & Bandini, P., 2010. Prediction of Pavement Performance through Neuro-Fuzzy Reasoning. *Computer-Aided Civil and Infrastructure Engineering*, January. pp.39-54. <http://onlinelibrary.wiley.com/doi/10.1111/j.1467-8667.2009.00615.x/full>.
- Bonabeau, E., 2002. Agent-based modeling: Methods and techniques for simulating human systems. *Proceedings of the National Academy of Sciences*.
- Bosurgi, G., Flintsch, G.W. & Trifirò, F., n.d. Artificial Neural Network Applications in Transportation Infrastructure Asset. p.8.
- Bosurgi, G. & Trifirò, F., 2005. A Model Based on Artificial Neural Networks and Genetic Algorithms for Pavement Maintenance Management. *International Journal of Pavement*, p.201–209.
- Bosurgi, G., Trifirò, F. & Xibilia, M.G., 2007. Artificial Neural Networks for Predicting Road Pavement Conditions. *4th INTERNATIONAL SIIV CONGRESS*, p.12.

- Braga, A., Carvalho, A.C.P.L.F. & Ludermir, T.B., 2000. *Redes Neurais Artificiais: Teoria e Aplicações*. LTC.
- Bray, J., Verma, B., Li, X. & He, W., 2006. A Neural Network based Technique for Automatic Classification of Road Cracks. *International Joint Conference on Neural Networks*, p.6.
- Brown, S.F., 1978. Material Characteristics for Analytical Pavement Design. *Developments in Highway Pavement Engineering, Chapter II P.S. Pell ed.*
- Cal, Y., 1995. Soil Classification by Neural Network. *Advances in Engineering Software*, (22), p.3.
- Carey, W. & Irick, P., 1960. The pavement serviceability performance concept. *Highway Research Board Record Bulletin 250*.
- Carey, W. & Irick, P., 1962. The Pavement Serviceability Performance Concept. *Highway Research Board Special Report 61E, AASHO Road Test*.
- Ceylan, H., Guclu, A., Tutumluer, E. & Thompson, M.R., 2004. Use of Artificial Neural Networks for Backcalculation of Pavement Layer Moduli. *2004 FWD Users Group Meeting*, p.22.
- Ceylan, H., Tutumluer, E. & Barenberg, E.J., 1998. Artificial Neural Networks As Design Tools in Concrete Airfield Pavement Design. *Proceedings of the International Air Transportation Conference*.
- Ceylan, H., Tutumluer, E. & Barenberg, E.J., 1999. Artificial Neural Network Analyses of Concrete Airfield Pavements Serving the Boeing B-777 Aircraft. *Transportation Research Record 1684*, p.110–117.
- Chou, J., O'Neill, W.A. & Cheng, H.D., 1994. Pavement Distress Classification Using Neural Networks. *IEEE International Conference on Systems, Man, and Cybernetics*, 1, p.397–401.
- Chou, J., O'Neill, W.A. & Cheng, H.D., 1995. Pavement Distress Evaluation Using Fuzzy Logic and Moment Invariants. *Transportation Research Record 1505*, p.39–46.
- Cifali, E., 2010. *Simular Ensaios Acelerados*. [Online] Available at: <http://www.simular.eng.br/site/empresa.php> [Accessed 13 October 2010].
- DNER, 1979. *Método de Dimensionamento de Pavimentos Flexíveis*. Rio de Janeiro, Brasil: Departamento Nacional de Estradas de Rodagem.
- Dougherty, M., 1995. A Review of Neural Networks Applied to Transport. *Transportation Research — C*, 3(4), p.247–260.
- Edwards, S., 2010. *The Chaos of Forced Migration: A Modeling Means to an Humanitarian End*.
- Ellis, G.W., Yao, C., Zhao, R. & Penumadu, D., 1995. Stress-Strain Modeling of Sands Using Artificial Neural Networks. *Journal of Geotechnical Engineering*, 121(5), p.429–435.
- Erol, K., Levy, R. & Wentworth, J., 2007. Application of Agent Technology to Traffic Simulation. *United States Department of Transportation*. <http://www.tfhrc.gov/advanc/agent.htm>.

- Faghri, A. & Hua, J., 1995. Roadway Seasonal Classification Using Neural Networks. *Journal of Computing in Civil Engineering*, 9(3), p.209–215.
- Faghri, A., Martinelli, D. & Demetsky, M.J., 1997. Chapter 7: Neural Network Applications in Transportation Engineering. In N. Kartam, I. Flood & J.H. Garrett, eds. *Artificial Neural Networks for Civil Engineers— Fundamentals and Applications*. Expert Systems and Artificial Intelligence Committee ed. ASCE.
- Federal Highway Administration, 2001. *Traffic Monitoring Guide*. Washington, D.C.
- Flintsch, G.W., 2003. Soft Computing Applications in Pavement and Infrastructure Management: State-of-the-Art. *Transportation Research Board Annual Meeting*.
- Ghaboussi, J. & Sidarta, D.E., 1998. New Nested Adaptive Neural Networks (NANN) for Constitutive Modeling. *Computers and Geotechnics*, 22(1), p.29–52.
- Goldberg, D.E., 1989. *Genetic Algorithms in Search, Optimization, and Machine Learning*.
- Gopalakrishna, K., Thompson, M.R. & Manik, A., 2007. Rapid Finite-Element Based Airport Pavement Moduli Solutions using Neural Networks. *International Journal of Computational Intelligence*, (Winter 2007), p.9. www.waset.org.
- Hall, K.T. & Muñoz, C.E., 1999. Estimation of present serviceability index from international roughness index. *Transportation Research Record 1655*, pp.93-99.
- Haykin, S., 1999. *Haykin. Neural Networks - A Comprehensive Foundation*. 2nd ed. New Jersey: Prentice-Hall.
- Haykin, S., 2001. *Redes neurais: princípios e prática*. Porto Alegre: Bookman.
- Huddleston, J., Buncher, M. & Newcomb, D., 2001. Perpetual Pavements.
- Ioannides, A.M., Alexander, D.R., Hammons, M.I. & Davis, C.M., 1996. Application of Artificial Neural Networks to Concrete Pavement Joint Evaluation. *Transportation Research Record No. 1540*, p.56–64.
- Joachims, T., 2002. *Learning to classify texts using support vector machines: methods, theory and algorithms*. Kluwer Academic Publishers.
- Kaseko, M.S., Lo, Z.P. & Ritchie, S.G., 1994. Comparison of Traditional and Neural Classifiers for Pavement Crack Detection. *Journal of Transportation Engineering*, 120(4), p.552–569.
- Khazanovich, L. & Roesler, J., 1997. DIPLOBACK: A Neural-Networks–Based Backcalculation Program for Composite Pavements. *Transportation Research Record No. 1570*, p.143–150.
- Kim, K.I., Jung, K., Park, S.H. & Kim, H.J., 2002. Support vector machines for texture classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, (24(11)), p.1542–1550.
- Lingras, P., 1995. Classifying Highways: Hierarchical Grouping Versus Kohonen Neural Networks. *Journal of Transportation Engineering*, 121, No. 4, p.364– 368.

- Lo, Z.P. & Bavarian, B., 1991. A Neural Piecewise Linear Classifier for Pattern Classification. *IEEE International Joint Neural Network Conference*, 1, p.264– 268.
- Meier, R.W., Alexander, D.R. & Freeman, R.B., 1997. Using Artificial Neural Networks As A Forward Approach to Backcalculation. *Transportation Research Record 1570*, p.126–133.
- Meier, R.W. & Rix, G.J., 1994. Backcalculation of Flexible Pavement Moduli Using Artificial Neural Networks. *Transportation Research Record No. 1448*, p.75–82.
- Meier, R.W. & Rix, G.J., 1995. Backcalculation of Flexible Pavement Moduli from Dynamic Deflection Basins Using Artificial Neural Networks. *Transportation Research Record No. 1473*, p.72–81.
- Mendes, R., Kennedy, J. & Neves, J., 2004. The Fully Informed Particle Swarm: Simpler, Maybe Better. *Journal of the IEEE Transactions of Evolutionary Computation*.
- Minsky, M.L. & Papert, S., 1969. *Perceptrons: An Introduction to Computational Geometry*. Cambridge, Massachusetts: MIT Press.
- Miradi, M., 2009. Knowledge Discovery and Pavement Performance - Intelligent Data Mining. *Delft University of Technology - Section of Road and Railway Engineering*, (PhD Thesis), p.324. ISBN 978-90-8570-278-8.
- Mitchell, T., 1997. *Machine Learning*. McGraw Hill.
- Momm, L., 1999. *Misturas de Concreto Asfáltico e seu Comportamento Mecânico (Notas de Aula)*. Florianópolis, Brasil: Universidade Federal de Santa Catarina - UFSC.
- Najjar, Y.M. & Basheer, I.A., 1997. *Modeling the Durability of Aggregate Used in Concrete Pavement Construction: A Neuro-Reliability-Based Approach*. Final Report KS-97-3. Topeka: Kansas Department of Transportation.
- National Cooperative Highway Research Program, 2004. *NCHRP 1-37A - Guide for Mechanistic-empirical Design of New and Rehabilitated Pavement Structures (AASHTO 2002)*. Illinois: Transportation Research Board.
- Neves, J. et al., 2007. The Halt Condition in Genetic Programming. *Lecture Notes in Artificial Intelligence 4874 – Progress in Artificial Intelligence*.
- Noble, W.S., 2004. Support vector machine applications in computational biology. *Kernel Methods in computational biology*, p.71–92.
- Pekcan, O., Tutumluer, E. & Thompson, M., 2008. *Nondestructive Pavement Evaluation Using ILLI-PAVE Based Artificial Neural Network Models*. Research Report FHWA-ICT-08-022. Illinois: Illinois Center for Transportation.
- Penumadu, D., Jin-Nan, L., Chameau, J.L. & Arumugam, S., 1994. Rate-Dependent Behavior of Clays Using Neural Networks. *Proceedings of the 13th Conference of the International Society for Soil Mechanics and Foundation Engineering*, 4, p.1445–1448.

- Penumadu, D. & Zhao, R., 1999. Triaxial Compression Behavior of Sand and Gravel Using Artificial Neural Networks (ANN). *Computers and Geotechnics*, 24, pp.207-30.
- Pinto, S., 1991. Estudo do Comportamento à Fadiga de Misturas Betuminosas e Aplicação na Avaliação Estrutural de Pavimentos. *Tese de Doutorado*.
- Roberts, C.A. & Attoh-Okine, N.O., 1998. Comparative Analysis of Two Artificial Neural Networks using Pavement Performance Prediction. *Computer Aided Civil and Infrastructure Engineering*, 13(5), p.339–343.
- Rocha, M., Cortez, P. & Neves, J.M., 2005. Simultaneous Evolution of Neural Network Topologies and Weights for Classification and Regression. *Lecture Notes in Computer Science 3512, Proceedings of the IWANN Conference*.
- Rocha, M., Cortez, P. & Neves, J., 2006. Evolution of Neural Networks for Classification and Regression. *Neurocomputing*.
- Russel, S.J. & Norvig, P., 2002. *Artificial Intelligence: A Modern Approach*. New Jersey: Prentice-Hall.
- Sadek, A.W., 2007. Artificial Intelligence Applications in Transportation. *Transportation Research Circular E-C113*.
- Salini, R., 2000. Utilização de Borracha Reciclada de Pneus em Misturas Asfálticas. *Tese de Mestrado*, p.138.
- Salini, R., Abelha, A. & Neves, J.M., 2008. The Road Map to Apply Evolutionary Intelligence to Asphalt Pavement Modelling. *22nd European Conference on Modelling and Simulation (ECMS 2008)*, pp.573-79.
- Salini, R., Abelha, A. & Neves, J., 2009. INTELLIPave - Considering Aside Failure Criteria and Unknown Variables in Evolutionary Intelligence Based Models for Asphalt Pavement. *23rd European Conference on Modelling and Simulation*, pp.624-29.
- Sarker, R. & Ray, T., 2010. Agent based Evolutionary Approach: An Introduction, Agent Based Evolutionary Search. *Springer series in Evolutionary Learning and Optimization*, pp.1-12.
- Sidarta, D.E. & Ghaboussi, J., 1998. Constitutive Modeling of Geomaterials from Non-uniform Material Tests. *Computers and Geotechnics*, 22(1), p.53–71.
- Siddiqah, A. et al., 2009. A new hybrid agent-based modeling decision support system for breast cancer research. *IEEE ICICT*.
- Souto, M.C.P., Lorena, A.C., Delbem, A.C.B. & Carvalho, A.C.P.L.F., 2003. Técnicas de Aprendizado de Máquina para problemas de Biologia Molecular. *XXIII Congresso da Sociedade Brasileira de Computação*, p.103–152.
- Strategic Highway Research Program, 1993. *SHRP-P-338 - Distress Identification Manual for the Long-Term Pavement Performance Project*. First Edition ed. Washington, DC: National Academy of Sciences.

- Tapkın, S., Çevik, A. & Usar, Ü., 2010. Prediction of Marshall test results for polypropylene modified dense bituminous mixtures using neural networks. *Expert Systems with Applications*, p.11.
- Taskiran, T., 2010. Prediction of California bearing ratio (CBR) of fine grained soils by AI methods. *Advances in Engineering Software*, (41), pp.886-92. www.elsevier.com/locate/advengsoft.
- Thube, D.T., Parida, M. & Jain, S.S., 2006. Application of Artificial Neural Network (ANN) for Prediction of Pavement Derioration for Low Volume Roads in India. *22nd ARRB Conference - Research Into Practice*, p.11.
- Toll, D., 1996. Artificial Intelligence Applications in Geotechnical Engineering. *Electronic Journal of Geotechnical Engineering*, 1.
- TRB, 2010. *Transportation Research Board*. [Online] Available at: <http://www.trb.org> [Accessed 14 October 2010].
- Tutumluer, E. & Seyhan, U., 1998. Neural Network Modeling of Anisotropic Aggregate Behavior From Repeated Load Triaxial Tests. *Transportation Research Record 1615*, pp.86-93.
- University of Minnesota, 1999. *Load testing of instrumented pavement sections - literature review*. Minnesota.
- Vapnik, V.N., 1995. *The nature of Statistical learning theory*. New York: Springer-Verlag.
- Venayagamoorthy, V. & Allopi, D., 2007. Use of Neural Network in the Prediction of Bearing Capacity of Pavement Structure. *26th South African Transport Conference (SATC 2007)*, p.8.
- Venayagamoorthy, V., Allopi, D. & Venayagamoorthy, G.K., 2004. Neural Network Based Classification of Roads Pavement Structures. *IEEE ICISIP 2004*, p.4.
- Wang, K.C.P., 1995. Feasibility of Applying Embedded Neural Net Chip to Improve Pavement Surface Image Processing. *Journal of Computing in Civil Engineering*, 1, p.589–595.
- Wang, K.C.P., Nallamothe, S. & Elliot, R.P., 1998. Classification of Pavement Surface Distress with An Embedded Neural Net Chip. *Manuals and Reports on Engineering Practice*, p.131–161.
- Xiao, W., Yan, X. & Zhang, X., 2006. Pavement Distress Image Automatic Classification Based on DENSITY-Based Neural Network. *RSKT 2006, LNAI 4062*, p.685–692.
- Yang, J., Lu, J.J., Gunaratne, M. & Xiang, Q., 2003. Overall Pavement Condition Forecasting Using Neural Networks: Application to Florida Highway Network. *82nd Annual Meeting of the Transportation Research Board*.
- Zadeh, L.A., 1965. Fuzzy Set. *Information and Control*, 8, pp.338-53.
- Zeghal, M., 2008. *Visco-elastic portrayal of bituminous materials: artificial neural network approach*. NRCC-50056. Canada: National Research Council Canada.

Zhu, J.H. & Zaman, M.M., 1997. Neural Network Modeling for a Cohesionless Soil. *76th Meeting of the Transportation Research Board*.

Zimmerman, K.A., Botelho, F. & Clark, D., 2000. Taking Pavement Management into the Next Millennium. *Transportation Research Board. A2B01: Committee on Pavement Management Systems*.

anexo A

8 Anexo A

Avaliação da qualidade da
informação e tratamento da
informação incompleta

Evolutionary Intelligence in Asphalt Pavement Modelling

Reus Salini¹, José Neves², Jorge Ribeiro³, José Machado², António Abelha² and Manuel Fernández-Delgado⁴

¹ Informatics Department of the CCTC of the University of Minho, Portugal, (e-mail (R.Salini@gmx.net)

² Informatics Department of the CCTC of the University of Minho, Portugal, (e-mail {jmac, abelha, jneves}@di.uminho.pt)

³ School of Technology and Management, Viana do Castelo Polytechnic Institute, Portugal (e-mail: jribeiro@estg.ipv.pt).

⁴ Department of Electronic and Computation, University of Santiago de Compostela, Santiago de Compostela, Spain, (e-mail: manuel.fernandez.delgado@usc.es)

Abstract. Construct a complete and trustable method for asphalt pavement modelling, able to attend the need of predict failure according to many technical and non-technical criteria at the same time, is a hard task. The current state-of-the-art for service-life prediction is at empiric and empiric-mechanistic levels, and do not provide any suitable answer even for one single failure criteria. It is important to achieve qualitative models and qualitative reasoning, in particular due the growing need to offer good methods in environments with defective information. This paper presents a framework oriented to fulfill the task of making predictions for multi-failure criteria, in particular in scenarios with incomplete information. The framework uses the Evolutionary Intelligence approach to generate quantified scenarios from the defective knowledge (or knowledge with incomplete information). The connectionist paradigm (i.e. The Artificial Neural Networks) is used to create the model to perform the prediction for the different pavement thicknesses, traffic and climate. In this sense, under the Extended Logic Programming paradigm to knowledge representation and reasoning in environments with incomplete information, we present a computational model to generate scenarios of the Matrix of Performance where the asphalt pavement behavior is based on the Quality-of-Information that stems from all the parameters used at the asphalt pavement under observation. In this work, the Quality-of-Information is based on the assessment (in terms of a process of quantification) of the list of characteristics presented by a asphalt pavement, where each variable problem is linked to a particular parameter and takes a truth value on the range 0...1, a measure of the confidence on the information being used in the modulation of the asphalt pavement process.

Keywords: Evolutionary Intelligence, Logic Programming, Incomplete Information, Knowledge Representation, Artificial Intelligence.

Aknowledgements: This work was developed under the project UTAustin/CA/0012/2008.

1 Introduction

The asphalt pavement performance prediction is essential to design new pavements as well as to manage the existing ones, keeping the highway network in a good condition and to select the best cost-effective maintenance/rehabilitation solutions over an extended timeframe, planning the financial money-flow must and the engineering activities (Cook and Clark, 2002). Model the asphalt pavement are among the biggest challenges of the engineering. The consensus tell about an intrinsic viscous-elasto-plastic non-linear and anisotropic behaviour; very complex indeed, but not sufficient to explain the performance, suggesting the existence of more undiscovered parcels of the behaviour or the inexistence of any kind of pattern. Aside of the intrinsic ones, the asphalt pavement behaviour is subject to the interference of many external factors, as the characteristics of the vehicles (speed, loads, etc.) and the environmental (temperatures, rainfall, etc.) (Cook and Clark, 2002) (Salini, Neves and Abelha, 2009).

In the half century, some methods and tools have been developed (Jansen, 1994) (Bandara, 2001) (Zimmerman, 2000) (AASHTO, 2002) based, in general, on simplistic approaches based on empiric or empiric-mechanistic, with the performance represented by two or three empiric variables. On the other hand, due the ultra-complex behaviour of the asphalt pavement, quality modelling cannot be achieved with empirical or *dogmatic* approaches. A strong tool, able to handling all the necessary variables and its near infinite combinations need to be used. The soft computing approach to modelling may be in line to provide the necessary power to this task (Yang et al. 2003) (Bosurgi and Trifirò 2005). Another fact is that the modeling of the asphalt pavement practice is difficult to judge, once it is based on the assessment of the list of characteristics presented by the environmental, vehicles and structural behaviour of the pavement, which in itself is a very complex task specially on environments with defective information. It is important to achieve qualitative models in order to offer support in decision-making processes.

Besides that, in the last decades qualitative models and qualitative reasoning (Forbus, 1996) (Kuipers, 1994) have been around in Artificial Intelligence research for some time. In the last decades, a small, but growing number of studies have been made to apply some artificial intelligence technique to asphalt pavements, looking for performance prediction, pavement management and evaluation, and some specific subjects (Bredenhann, 2004) (Liu, 2007) (Terzi, 2007). However, intelligent systems require the ability to reason with unknown and/or incomplete information, by the fact that in the real world complete information is hard to obtain, even in the most controlled situation. The information is not always exact, but indeed imperfect, in the sense that we handle estimated values, probabilistic measures, or degrees of uncertainty (Sheridan, 1991). In the past few decades, Logic and Logic programs (Kakas, 1998) (Kowalski, 2006) (Neves et al. 2007), have emerged as attractive knowledge representation formalism and an approach to solving search problems in environments with defective information. Many non-classical techniques for modeling the universe of discourse and reasoning procedures of intelligent systems have been proposed (Shafer, 1992) (Subrahmanian, 2001) (Zadeh, 2001) (Loyer, 2003). One promising approach for knowledge representation, reasoning and quantify the knowledge, in particular in scenarios with defective information is the Quality-of-

Information concept (Analide, 2006) (Neves, 2007) which has been applied with success in many areas (Machado and Andrade, 2006) (Lima, 2008)(Machado and Miranda, 2009) (Ribeiro, 2009) (Lima, 2009) (Machado and Abelha, 2010) (Novais and Salazar, 2010) (Novais and Andrade, 2010).

In this work we present an extension of the INTELLIPave (Salini, 2009), a computational artificial intelligence-based approach to model and predict the asphalt pavement behaviour and service-life for multi-failure criteria, in particular when applied to scenarios with incomplete information (Salini, 2008). In order to model the knowledge of asphalt pavement performance, the computational model is preprocessed in terms of an extension to the logic programming language based on an evaluation of the Quality-of-Information that stems out from those logic programs or theories (Neves, 2007). In this sense, we quantify the knowledge of the asphalt pavement modeling based on the assessment of the list of variables presented by the pavements and for all parameters involved in the modulation process. Each variable problem is linked to a particular scenario and takes a truth value on the range 0...1, not presenting a probability value, but a truth value, which is a measure of the confidence on the information being used in the modulation process. With this approach we are able to map the defective information associated to this problematic in to a quantified knowledge in order to submit information to an Artificial Intelligence-based model called CUIA Model (in this case using Artificial Neural Network) in order to predict the asphalt pavement performance for a range of situations in terms of traffic, environment, pavement thicknesses and its combinations.

The rest of the paper is structured as follows. In the next section we present the problematic of the Asphalt Pavement Modelling. In the section three we present the semantic of the Extended Logic Programming for knowledge representation and reasoning, as well as the Quality-of-Information concept. In the section four it is presented the computational model of the framework as well as the Evolutionary Intelligence and Logic Programming approaches which the preprocessing module of the framework is based. Finally, we present the conclusions and future work.

2. Asphalt Pavement Modelling

Modelling the service life for asphalt pavements is widely made with base on empirical methods, developed half-century ago, with poor results. The new reality of the XXI century, with high construction costs (for both, materials and labor), environmental restrictions and growing volumes of vehicles in the highways, enforce the shift to a new level of quality and accuracy to predict the service life of the pavements in order to have better cost-effective solutions (Flintsch 2003).

2.1 The Pavement Challenge

There is consensus that to have success in the task of have better, the managers and engineers needs to know or predict the asphalt pavement surface condition and

performance with years in advance. That is critical to plan or estimate the budget, money-flow and engineering activities, but predict the pavement serviceability is hard and complex and in many cases is made with recourse to subjective and exotic methods, once the current technology do not provide any suitable solution. The task became even more hard because, to make compatible the engineering activities (preventive or corrective maintenance, or major pavement rehabilitations) and the available budget, the managers needs to be able to define and set priorities, and this imply in predict the pavement condition for many criteria, and not just for one. In other words, the pavement failure scheme is a highly variable event depending not only on layer's material properties and sub-grade, environmental conditions, and traffic loading, but also on the specific definition of failure adopted by the highway agencies. Failure may be defined in terms of amount of cracking, rut depth, surface roughness, or combinations of these or other indicators of performance (Madanat, 2002). In fact, the XXI century's pavement manager needs to work with alongside many failure criteria, including non-technical criteria, like the (highway) property value, driver security and comfort, maintenance costs per kilometre and surface cracked area, among many others, and not for just one highway, but for all highways in the network under his responsibility, and trying to maximize the efficiency for every used monetary unit. Constructing a complete and trustable system for asphalt pavement management, able to predict failure according technical and non-technical criteria at the same time, is a hard task.

$$\log_{10}(W_{18}) = Z_R S_o + 9.36 \log_{10}(SN + 1) - 0.20 + \frac{\log_{10} \left[\frac{\Delta PSI}{4.2 - 1.5} \right]}{0.40 + \frac{1049}{(SN + 1)^{5.19}}} + 2.32 \log_{10}(M_R) - 8.07$$

which

W_{18} = design traffic (18-kip ESALs)

Z_R = standard normal deviate

ΔPSI = difference between initial and terminal serviceability index

M_R = resilient modulus (PSI)

SN = structural Number

$$SN = a_1 D_1 + \sum_{i=2}^n a_i D_i m_i$$

Where, SN = structural number = f (structural capacity)

a_i = i^{th} layer coefficient

D_i = i^{th} layer thickness (inches)

m_i = i^{th} layer drainage coefficient

n = number of layers (typically 3)

Fig 1. – Asphalt pavement design under the AASHTO 1993 empiric method

During the last half-century some methods have been developed for asphalt pavement modelling (Carey, 1962) (Salini, 2000), as the AASHTO - American Association of State Highway and Transportation Officials (AASHTO, 2004) (National, 2004), the USACE – US Army Corps of Engineers – and a kind of “generic” widely spread method known as empiric-mechanistic, where some consideration about the pavement mechanic is included in an empiric way. In general terms these methods are very simplistic and based on empiric or empiric-mechanistic approaches, with the

performance represented by two or three empiric variables, like the ESAL (Equivalent Single Axle Loads), CBR (California Bearing Ratio) or the maximum strain in the asphalt concrete layer (Salini, 2009). However, these approaches do not provide any suitable answer even for one single pavement failure criteria.

Fracture:

$$\Delta DI = \sum_{k=1}^m \sum_{i=1}^j \left[\frac{n_i}{N(\varepsilon_i)_k} \right]$$

where $k = \text{load level}$
 $i = \text{time/season}$
 $d = \text{sublayer}$

Distortion:

$$\Delta RD = \sum_{k=1}^m \sum_{i=1}^j \sum_{d=1}^l \left[\varepsilon_{P(d)}(h_d) \right]_{k,i}$$

Fig 2. – Accumulated damage in AASHTO 2002 method for asphalt pavements.

In the 1990s was started the development of a new method for asphalt pavement modeling and design known as AASHTO 2002, with the promise of by-pass many of the limitations of the existing methods. Different of the previous empiric versions, this new method is based on an empiric-mechanistic approach to evaluate the traffic, climate, sub-grade and materials; the ESAL concept is removed and all vehicles with the respective climatic combination must to be evaluated. The built-in empiric-mechanistic models are not really new, but those used at decades. The supposed better accuracy in fact depends on a complex model's calibration based on-field test sections that exist only in few States in USA, constructed under the LTPP Program (*Long Term Pavement Performance Program*). Due its complicated calibration and not proven better accuracy the AASHTO 2002 method didn't became common even in United States (AASHTO, 2004) (National 2004).

2.2 Related Work

In the last decades, a small but growing number of studies have been made applying some Artificial Intelligence (AI) based techniques to asphalt pavements, namely looking at performance prediction, pavement management and evaluation. Initially, the majority of the studies were centered in the field of geomechanics, with less emphasis on pavements. *Tutumluer and Seyhan* (Tutumluer and Seyhan 1998) used the ANN (the *backpropagation method*) to predict the behaviour of the granular materials submitted to triaxial test. *Penumadu et al.* (Penumadu et al. 1994) developed a model for argillaceous soils using ANN. *Penumadu and Zhao* (Penumadu and Zhao 1999) used the *feedback* approach to model the behaviour of the sands and gravels on the stress-strain relationship in triaxial. *Basheer and Najjar* (Basheer and Najjar 1998) also used the *feedback* approach to simulate the relation between stress-strain in fine soils using various types of loads. Using the sequential backpropagation approach (*feedback*) *Ellis et al.* (Ellis et al. 1995) developed a model for sands based on the grading curve and tensions. *Ghaboussi and Sidarta* (Ghaboussi and Sidarta 1998) used the ANN (of the type *nested adaptive neural network, NANN*) to model the

behaviour of the drained sandy soils and non-drained in triaxial tests. *Meier et al.* (Meier, Alexander, and Freeman 1997) used the ANN (*backpropagation approach*) as substitute of the WESLEA software for the *backcalculation* of pavements, achieving a significant improvement of the performance. *Ceylan et al.* (Ceylan, et al. 2004) demonstrated ANN training with models for the calculation of the stresses and deflections in joints of airport pavements as function of pavement thickness, base type and efficiency of the joints. *Roberts and Attoh-Okine* (Roberts and Attoh-Okine 1998) used the ANN with a quadratic function to predict the roughness of the pavements; the ANN of quadratic functions are generalizable combining the supervised and self-organized learning. *Faghri and Hua* (Faghri and Hua 1995) used the ART Networks (*Adaptive Resonance Theory*) to group highways according with the *monthly average daily traffic* (MADT), with much better results over the achieved by the traditional methods, as the regression and group analysis. *Lingras* (Lingras 1995) used the *Kohonen* networks for a similar application demonstrated better performance than the traditional hierarchical methods in the classification of patterns of traffic.

The recognition of pavement defects in images was studied by *Xiao et al.* (Xiao, Yan, and Zhang 2006) that developed an algorithm called *DENSITY-based neural network*, *DNN* which, according with the authors, in tests realized with 83 real pavement images, achieved the accuracy of 97,5% in the detection. A similar work was developed by *Bray et al.* (Bray et al. 2006) using two ANN in hierarchical fashion, one to detect the existence (or not) of defects, and the second to classify the existing defects, working with properties of images as the histograms.

In the University of Texas at El Paso (Abdallah et al. 2000) it was developed a methodology based on ANN of the *backpropagation* type to compute the remaining service-life of the asphalt pavements on the fatigue cracking and rutting using deflection data of the FWD (*Falling Weight Deflectometer*) and layer thicknesses as inputs.

Miradi (Miradi 2009) evaluated 60 scientific studies which employed artificial intelligence techniques to study the various aspects of the pavements between 1995 and 2007. Of these, 2% addressed the loss of aggregates in the asphalt layer (raveling); 18% reported to the cracking; 3% about plastic deformations (rutting); 7% about the surface roughness of the pavement, 27% described the combination of cracking, rutting and roughness; while 43% were related structural modulus of the pavement layers. Of the total, 12% used the classification method, while 88% used the regression technique. However, none of the 60 studies made the simultaneous study or combination of the characteristics of the materials, as traffic and climatic factors (Miradi 2009). Using information about The Netherlands country, *Miradi* (2009) developed an interesting work to identify the most important factors for the degradation of the asphalt pavement using ANN, SVM (*Support Vector Machine*), Genetic Algorithms, Decision trees and *Rough Sets* theory, for the prediction of the occurrence of cracking, rutting and loss of aggregate for asphalt layers with different ages.

In China, *Cal* (Cal, 1995) used the ANN to classify the pavements using three basic factors – the plasticity index, the liquid limit and the clay content, in order to classify six different types of soils. The ANN were trained using the *backpropagation* algorithm and in the predictions the ANN presented 100% of accuracy. In Italy, *Bosurgi et al.* achieved good results in the development of a model to predict the tire-

pavement friction force (*Sideway Force Coefficient, SFC*) in Italian highways using ANN (Bosurgi, Trifirò, and Xibilia 2007) as well as in models to predict the highways accidents (Bosurgi, Trifirò, 2005). In South Africa Venayagamoorthy *et al.* (Venayagamoorthy, Allopi, and Venayagamoorthy 2004) used the ANN to classify different type of pavement structures according with the highway category, class of traffic and type of base layer; in the 30 studies, the ANN were able to realize the classification without any error. In India Thube *et al.* (Thube, Parida, and Jain 2006) developed a work about the use of ANN for the prediction in the deterioration of road pavements with small volume of vehicles. In USA (state of Illinois), was realized a research using ANN and Genetic Algorithms to evaluate the pavement structure through non-destructive tests, with special emphasis on *backcalculation* (Pekcan, Tutumluer, and Thompson 2008). Again in the Illinois state, was studied the application of ANN to predict the modulus for airport asphalt pavements using data sets acquired with HWD (Heavy Weight Deflectometer) which is an equipment similar to the FWD, however, able to apply heavier loads (Gopalakrishna, Thompson, and Manik 2007).

Bianchini and Bandini (Bianchini and Bandini 2010) used *Neuro-Fuzzy Reasoning* to predict the asphalt pavements behavior using deflection data read with FWD and the pavement surface distresses. In Turkey, Taskiran (Taskiran 2010) used the ANN and the GEP (Gene Expression Programming) to predict the values of the CBR (California Bearing Ratio). Also in Turkey, Tapkin *et al.* (Tapkın, Çevik, and Usar 2010) developed an interesting study for the prediction of the Marshall properties in cores of asphalt concret modified with polypropylene fiber using ANN trained with the *backpropagation* algorithm. Bayrak *et al.* (Bayrak, Teomete, and Agarwal 2004) used the ANN to predict the IRI (International Roughness Index) in rigid pavements; they used 83 datasets from LTPP (Long Term Pavement Performance Program). The variables used include (on the input layer) the initial IRI, the age of the pavement, the traffic and the transverse cracks for three levels of severity (low, medium and high); as output variable was used the IRI measured in the pavements. The developed model was able to predict the IRI values with a high accuracy. Aultman-Hall *et al.* (Aultman-Hall *et al.* 2004) used ANN and other statistical techniques to study the correlations between the IRI and the cracked area and rutting based on data collected on 650 km of highways. The objective was verify the possibility to use the IRI to estimate the pavement distresses.

2.3 Handling uncertainty information for asphalt pavement modelling

Almost all of the studies applying artificial intelligence-based tools for asphalt pavements use the same inputs with the objective to have the same outputs as available using traditional methods, for the same problems, in other words, a new way to get old results.

Looking to construct a new paradigm for asphalt pavement modeling was developed the INTELLIPave method (Salini, 2008) (Salini, 2009), where are used very large amounts of field data in order to build the CUIA Model. That data is collected using sensors over large periods of time (10+ years). The data have all kinds of problems,

since lack of data to unreal data due a large set of problems, like sensors failure, sensor loss of accuracy, sensor replacement or miscalibration, hardware and software failure to register the data, *et cætera*. Those problems have negative impact in any built model. The INTELLIPave method itself was built with ways for error handling and consideration of unknown variables, or (known) variables without data.

In this paper it is presented and discussed a method that can be used as a preprocessing layer to the INTELLIPave method as an aid to handle the uncertainty, unknown and quality of the information available to construct models for asphalt pavements, contributing to improve its accuracy. This preprocessing phase will be made using the evolutionary Intelligence approach (Ribeiro et al. 2010) using the Extended Logic Programming and Quality-of-Information formalism (Neves 2007) in order to quantify the unknown information and by this way, submit to the model known knowledge.

3. Knowledge Representation and Quality-of-Information

We can observe that in the past few decades, the applicability of Logic and Logic programs have emerged as attractive knowledge representation formalism and an approach to solving search problems in particular, in environments with defective information (Halpern, 2005) (Neves et al, 2007). Many non-classical techniques for modeling the universe of discourse and reasoning procedures of intelligent systems have been proposed (Sheridan, 1991) (Denecker and Kakas, 2002) (Kowalski, 2006) (Neves, Machado et al., 2007). The Extended Logic Programming proved to be a suitable and flexible tool oriented for knowledge representation and reasoning tasks, particularly when one intends to contemplate situations where the information is incomplete, imperfect or error sensitive.

3.1 Knowledge Representation and Reasoning

In this context and with respect to the computational model in our approach it was considered an extension to the language of Logic Programming being a finite collection of rules of the form (Neves, 2007):

$$q \leftarrow p_1 \wedge \dots \wedge p_m \wedge \text{not } p_{m+1} \wedge \dots \wedge \text{not } p_{m+n}$$

$$? p_1 \wedge \dots \wedge p_m \wedge \text{not } p_{m+1} \wedge \dots \wedge \text{not } p_{m+n}$$

where ? is a domain atom denoting falsity, and q and every p_i are literals, i.e., formulas like a or $\neg a$, being a an atom, for $m, n \in N_0$. In this sense, the ELP introduces another kind of negation: strong negation, represented by the classical negation sign \neg . In most situations, it is useful to represent $\neg A$ as a literal, if it is possible to prove $\neg A$. In EPL, the expressions A and $\text{not } A$, being A a literal, are extended literals, while A or $\neg A$ are simple literals. Intuitively, $\text{not } p$ is true whenever there is no reason to believe p , whereas $\neg p$ requires a proof of the negated literal. On

the other hand, every ELP program is associated with a set of abducibles (Denecker and Kakas). Abducibles can be seen as hypotheses that provide possible solutions or explanations of given queries, being given here in the form of exceptions to the extensions of the predicates that make the program. To reason about the body of knowledge presented in a particular program or theory, set on the base of the formalism referred to above, let us consider a procedure given in terms of the extension of a predicate called *demo*, using ELP. This predicate allows one to reason about the body of knowledge presented in a particular domain, set on the formalism referred to above. Thus, given a question it returns a solution based on a set of assumptions. This meta predicate will be defined as a meta theorem-solver to handle incomplete information, and it will be represented by the signature $demo:T,V \rightarrow \{true,false,unknown\}$, i.e., it infers the valuation V of a theorem T in terms of the truth value *false* (or 0), truth value *true* (or 1) and *unknown*, with truth values in the interval $]0,1[$, according to the following set of productions:

```
demo(T, true) ← T.
demo(T, false) ← ¬ T.
demo(T, unknown) ← not T, not ¬ T.
```

As a simple example, let us represent the knowledge using the ELP considering the extensions of the predicates that denote some properties of asphalt pavement modelling. This may be formally stated in terms of the predicates *pavement*, *climate*, *vehicles* and *pavement_condition*. This may be stated as follows:

```
pavement: Highway_ID x Pavement_Type x Thickness_Value
climate: Highway_ID x Pavement_Type x Air_Temperature_Value
vehicles: Highway_ID x Pavement_Type x vehicles_per_day_Value
pavement_condition: Highway_ID x Pavement_Type x cracked_area_Value
```

where the first argument denotes the identification of the highway, the second the type of the pavement and the third the value of the attribute of the predicate, namely, the thickness (in millimeters), the average of the air temperature, the value of vehicles per day, and the percentage of cracked area. For example, let us suppose that the knowledge is given in terms of the logic program:

Program 1 - The extended logic program for predicate *pavement*

```
{
  ¬ pavement(X,Y,Z) ← not pavement(X,Y,Z),
                    not abducible_pavement(X,Y,Z).
  pavement(2,asphalt_concrete_B,120).
  pavement(3,asphalt_concrete_C,85).
  abducible_pavement(1,asphalt_concrete_A,100).
  abducible_pavement(1,asphalt_concrete_A,150).
  abducible_pavement(1,asphalt_concrete_A,200).
}
```

In the program 1 the first clause denotes the closure of the predicate *pavement*. The second and third clause denotes that the thickness value for the highway with the identification “2” and “3” and for the type of pavement “*asphalt_concrete_B*” and

“*asphalt_concrete_C*” is known and it is 120 and 85 respectively. The fourth and fifth clause denotes that the thickness value for the highway with the identification “1” and pavement type “*asphalt_concrete_A*” is unknown with the truth value 100 or 150 or 200, or even both.

Program 2 - The extended logic program for predicate *climate*

```
{
  ¬ climate(X,Y,Z) ← not climate(X,Y,Z),
                    not abducible_climate(X,Y,Z).
  climate(2,asphalt_concrete_B, ⊥).
  abducible_climate(X,Y,Z) ← climate(X,Y,⊥).
  climate(1,asphalt_concrete_A,25).
  climate(3,asphalt_concrete_C, 43).
}
```

In the program 2, the first clause denotes the closure of the predicate *climate*. In the second and third clauses the symbol ‘ \perp ’ stands for a null value, in the sense that it subsumes that Z may take any truth value in the interval $[0,1]$. The fourth and fifth clauses denote that the truth value of *climate* for the highway with the identification 1 and 3 and for the type of pavement “*asphalt_concrete_A*” and “*asphalt_concrete_C*” is 25 and 43.

Program 3 - The extended logic program for predicate *vehicles*

```
{
  ¬ vehicles(X,Y,Z) ← not vehicles(X,Y,Z),
                     not abducible_vehicles(X,Y,Z).
  vehicles(1,asphalt_concrete_A,12000).
  vehicles(2,asphalt_concrete_B,15000).
  abducible_vehicles(3,asphalt_concrete_C,11000).
  abducible_vehicles(3,asphalt_concrete_A,14000).
}
```

Program 4 - The extended logic program for predicate *pavement_condition*

```
{
  ¬ pav_condition(X,Y,Z) ←
    not pav_condition(X,Y,Z),
    not abducible_pav_condition(X,Y,Z).
  pav_condition(1,asphalt_concrete_A,55).
  pav_condition(3,asphalt_concrete_C,66).
  abducible_pav_condition(2,asphalt_concrete_B,33).
  abducible_pav_condition(2,asphalt_concrete_B,42).
  ?((abducible_pav_condition(X1,Y1,Z1) ∨
    abducible_pav_condition(X2,Y2,Z2)) ∧
    ¬(abducible_pav_condition(X1,Y1,Z1) ∧
    abducible_pav_condition(X2,Y2,Z2)))
}
```

In the program 4 the fourth and fifth clauses denote that the fact that the truth value of the *cracked area* of the *pav_condition* for the highway with the identification 2 and type of pavement “*asphalt_concrete_B*” is either 33 or 42, or even both. However, the sixth clause stands for the invariant that implements the XOR operator, i.e., it states that the truth value of *cracked area* is either 33 or 42, but not both.

In this sense, under the Extended Logic Programming paradigm to knowledge representation and reasoning in environments with incomplete information the first aim is to discover which theories (or logical programs) are able to solve a problem and with the set of those theories, which one's is the best to solve a specific problem. Following the inference mechanism it will be generated all the possible scenarios based on the programs 1, 2 3 and 4, in order to represent all the available knowledge from the unknown information presented in the initial scenario. For example two of the possible scenarios can be expressed as follows:

Program 5 - The extended logic program, theory 1 or scenario 1

```
{ (⊥ pavement(X,Y,Z) ← not pavement(X,Y,Z),
    not abduciblepavement(X,Y,Z)),
  pavement(2,asphalt_concrete_B,120),
  pavement(3,asphalt_concrete_C,85),
  abduciblepavement(1,asphalt_concrete_A,100),
  (⊥ climate(X,Y,Z) ← not climate(X,Y,Z),
    not abducibleclimate(X,Y,Z)),
  climate(2,asphalt_concrete_B, ⊥),
  abducibleclimate(X,Y,Z) ← climate(X,Y, ⊥),
  climate(1,asphalt_concrete_A,25),
  climate(3,asphalt_concrete_C, 43),
  (⊥ vehicles(X,Y,Z) ← not vehicles(X,Y,Z),
    not abduciblevehicles(X,Y,Z)),
  vehicles(1,asphalt_concrete_A,12000),
  vehicles(2,asphalt_concrete_B,15000),
  abduciblevehicles(3,asphalt_concrete_C,11000),
  (⊥ pav_condition(X,Y,Z) ← not pav_condition(X,Y,Z),
    not abduciblepav_condition(X,Y,Z)),
  pav_condition(1,asphalt_concrete_A,55),
  pav_condition(3,asphalt_concrete_C,66),
  abduciblepav_condition(2,asphalt_concrete_B,33)
}
```

Program 6 -The extended logic program, theory 2 or scenario 2 {

```
( ⊥ pavement(X,Y,Z) ← not pavement(X,Y,Z),
  not abduciblepavement(X,Y,Z)),
  pavement(2,asphalt_concrete_B,120),
  pavement(3,asphalt_concrete_C,85),
  abduciblepavement(1,asphalt_concrete_A,100),
  abduciblepavement(1,asphalt_concrete_A,150),
  (⊥ climate(X,Y,Z) ← not climate(X,Y,Z),
    not abducibleclimate(X,Y,Z)),
  climate(2,asphalt_concrete_B, ⊥),
  abducibleclimate(X,Y,Z) ← climate(X,Y, ⊥),
  climate(1,asphalt_concrete_A,25),
  climate(3,asphalt_concrete_C, 43),
  (⊥ vehicles(X,Y,Z) ← not vehicles(X,Y,Z),
    not abduciblevehicles(X,Y,Z)),
  vehicles(1,asphalt_concrete_A,12000),
  vehicles(2,asphalt_concrete_B,15000),
  abduciblevehicles(3,asphalt_concrete_C,11000),
```



```

    abduciblevehicles(3, asphalt_concrete_A, 14000),
    (¬ pav_condition(X, Y, Z) ← not pav_condition(X, Y, Z),
     not abduciblepav_condition(X, Y, Z)),
    pav_condition(1, asphalt_concrete_A, 55),
    pav_condition(3, asphalt_concrete_C, 66),
    abduciblepav_condition(2, asphalt_concrete_B, 33)
}

```

3.2 Quality-of-Information

Based on the knowledge representation presented, the objective of the reasoning process is to build a quantification process of the Quality-of-Information (QoI) (Analide and Novais, 2006) (Neves, 2007) that stems from a logic program or theory during an evolutive process that aims to solve a problem in environments with incomplete information. The *QoI* with respect to a generic predicate P can be analyzed in four situations and can be measure from the interval [0-1], when the information is positive and negative, when the information is unknown, when the information is unknown but can be selected from one or more values, and when the information is unknown but can be derived from a set of values, but only one can be selected. If the information is know (positive) or false (negative) the quality of the information for the predicate is “1” (1) corresponding to the max value from the known knowledge. For situations where the value is unknown the formula of the quality of information is given by:

$$QoI_p = \lim_{N \rightarrow \infty} \frac{1}{N} = 0 (N \gg 0) \quad (2)$$

For situations when the information is unknown but can be derived from a set of values the *QoI* is therefore given by $QoI_p = 1/Card$ (6), where *Card* denotes the cardinality of the abducibles set for p , if the abducibles set is disjoint. If the abducibles set is not disjoint, the quality-of-information is given by:

$$QoI_p = \frac{1}{C_1^{Card} + \dots + C_{Card}^{Card}} \quad (3)$$

where C_{Card}^{Card} is a card-combination subset, with *Card* elements.

The next element of the model to be considered is the *relative importance* that a predicate assigns to each of its attributes under observation, i.e. w_{ij} stands for the relevance of attribute j for predicate i . It is also assumed that the weights of all predicates are normalized, that is:

$$\forall i \sum_{j=1}^n w_{ij} = 1 \quad (4)$$

It is now possible to define a predicate's *scoring function*, i.e., for a value $x = (x_1, \dots, x_n)$ in the multi dimensional space defined by the attributes domains, which is given in the form:

$$V_i(x) = \sum_{j=1}^n w_{ij} * V_{ij}(x_j) \quad (5)$$

it is viable to measure the *QoI* that occurs as a result of invoking a logic program

to prove a theorem (e.g. Theorem), by posting the $V_i(x)$ values into a multi-dimensional space and projecting it onto a four dimensional one (figure 4).




Fig 4. – Measure of the Quality-of-Information for the highways with the identification 1, 2 and 3 respectively.

Using this procedure, it is defined a circle, as the one given in Figure 2. Here, the dashed n-slices of the circle (in this example built on the extensions of three predicates, named as *pavement*, *vehicles*, *pav_condition*, *climate*) denote the *QoI* that is associated with each of the predicate extensions that make the logic program.




Fig. 5 - Measure of the Quality-of-Information for the Logic Program or Theory *P* with respect to the evaluation of the asphalt pavement modeling.

In our approach, in particular in the evolutionary intelligence module to evaluate the theories (section 4.3) we use the quantification of the quality-of-information that stems out from those theories. The selection of the best theory will be based on the relation order of its *QoI* value. In practical terms, in the end of the creation of the model we will achieve a set of theories (or scenarios) that corresponds to the best quantification of the universe of discourse in order to submit to the connectionist module known information from defective information presented in the initial knowledge.

4. INTELLIPave Computational Approach

4.1 Introduction

The INTELLIPave method (Salini, 2008) (Salini, 2009) was built from the ground in order to provide a scientific and rational way to predict and accumulate the knowledge on the asphalt pavement performance in a system where as more experiences are available, better and stronger will become the predictions, creating a virtuous spiral to improve the models in a non-stop way. The mechanic supporting the knowledge accumulation is the matrixes of performance parallelization based on neural networks, called CUIA Model. Every individual model (matrix of performance) provides experiences and knowledge about the asphalt pavement performance for specific material's thicknesses in a range of traffic and climate characteristics, but when two or more models are integrated in parallel, creating the CUIA Model, they are able, sinergically, to provide performance prediction for much more situations than individually, larger traffic and climate characteristics ranges, and different thicknesses. In fact, have no limit about how many individual models can be "attached" to the CUIA Model, allowing the system to grow forever accumulating more knowledge and experiences.

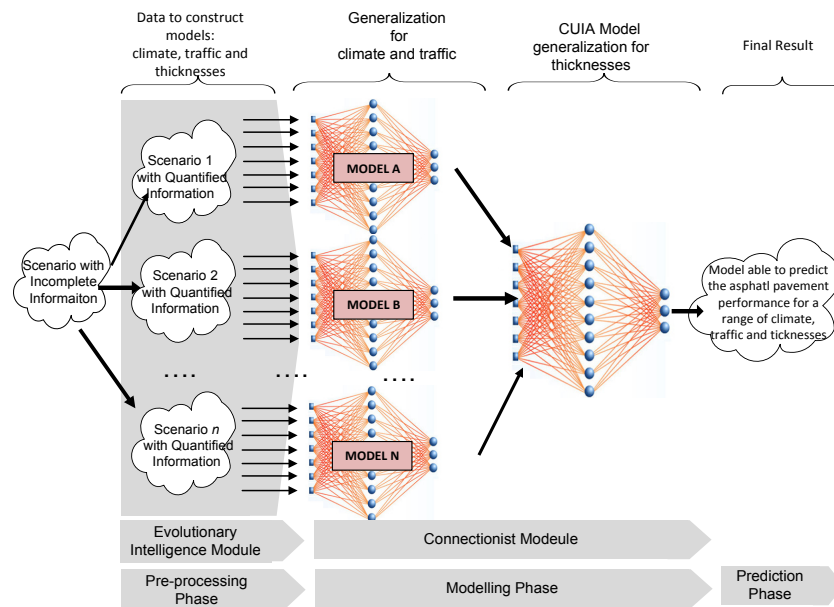


Fig.6 – Example where Many Models Working in Parallel provide the necessary experience and intelligence to neural networks predict the performance for different thicknesses

The Figure 6 presents the architectural structure of the CUIA Model. It is structured in two parts: evolutionary Intelligence module, responsible for the pre-processing phase, and the connectionist module centred on the modelling phase. As mentioned, the pavement can be subject to many different deficiencies, as well as scenarios with imperfect information. In this sense, the first module has the objective to generate all possible scenarios from the initial knowledge in order to map the defective information in the initial knowledge in to a set of scenarios with unknown knowledge quantified. With the generation of those scenarios the information is submitted to the first layer of the connectionist module.

4.2 Source Data

In order to be able to use and reuse the available knowledge is necessary, first, to generate and organize the information about the performance of the pavement. The initial step, and the first challenge, is collect data about the traffic and climate in a highway open to live traffic until the pavement fails according some, or many, failure criteria. As its service life do not decrease in a linear or constant rate, the database need to register the information for one full cycle of the asphalt pavement service life, or in another words, to get data all along several (10+) years. The climatic data can be collected with automatic weather stations and the traffic, with automatic *weight-in-motion* systems.

Areas	Variables
Environmental	Air temperature, rainfall, solar radiation, pavement temperature and wind speed
Vehicles	Date/time, count, speed, tire type, axle 1 load, axle 2 load, ..., axle n load, others

Fig. 7: Desirable Variables to a Database Suitable for Asphalt Pavement Modelling Using Artificial Intelligence

The Figure 7 illustrates the desirable variables presented in the asphalt pavement environment. Every time a vehicle crosses the instrumented highway all sensors are read and the generated data is recorded in the database. The recording is only stopped when the pavement meets the end of the service life. The criteria to the end of the service life can be anything, technical, financial, functional or any other nature. Also a multiple criteria can be used with the INTELLIPave method and, in this case, the data need to be recorded until the last criteria is meeting. For each criteria the database will be “cuted” in a different point and a new model is created. This information is submitted to the processing phase, in particular, to the evolutionary model in order to generate scenarios with quantified information from a database which can reflect the characteristic of unknown, ambiguous or error sensitive information.

4.3 The Dynamic Generation of Scenarios

The combination of Artificial Intelligence techniques such as the symbolic and evolutionary systems allows to combine the advantages of each of these approaches, in particular for solving complex problems. The Evolutionary Algorithms (Paz, 2005) are models of the natural evolution presented by *Charles Darwin* have been applied with success in tasks for solving optimization problems and search solutions. These algorithms are based on the collective adaptation and learning ability of individuals. Through a dynamic process applying genetic operators, individuals are being generated and tested through an evaluation function, trying to find the best individual, which corresponds to the best solution to solve the problem in observation. The ANN (Haykin, 2008) is a computational paradigm for information processing inspired by the way of how the human brain processes information on the biological level.

However, in this paper the scope of use and interconnection of the three paradigms is quite different. We are not interested only in the automatic generation of logic programs, but rather the generation of logic programs based on the context measured by quantification processes associated to these logic programs (or theories). On the other hand, the ANN architecture will be used as a general evolutionary process of nature (evolutionary network) (Floreano, Durr et al., 2008), being created different dynamic network topologies. With this evolutionary module, we will generate and quantify all the possible scenarios from the knowledge with unknown information. In our approach, instead of assigning a probability to the unknown information, is assigned a truth value associated with this information, thereby enabling the network to submit information known.




Fig. 8 – Schematic of the Evolutionary Intelligence Module.

The architecture of the evolutionary module (Ribeiro, 2010) is illustrated in the figure 8 and is structured by a set of entities called neurons. To each neuron is associated with the context that models the universe of discourse represented by the extensions of the logic program (or theory). The input of the system corresponds to the initial description of the universe of discourse. At the input of each neuron it is

presented the list of problems corresponding to the problem to solve. The context is given in terms of the reality associated to a given sub-problem. In this environment no amount of evolutionary optimization can create a network of neurons ideally suited for all types of intellectual tasks. In this sense, the artificial neurons have the ability to modify their own circuits when necessary. The evolutionary process starts with an approximate representation of the universe of discourse and the progress is based on the measured of the quality-of-information. Associated with a theory or logic program, until there isn't any improvement through a condition (or threshold) previously defined. In this sense, and as similar with the human brains, neurons automatically destroy unneeded connections creating new ones. Thus, the evolutionary process begins with the approximate representation of the universe of discourse and progress based on the measurement of the quality-of-information until no significant improvement occurs, based always on the synthesis and analysis of the approach to the representation using logic programs (or theories). When the virtual intellect is created, the last group of neurons is called output neurons, corresponding to the best set of logical mathematical theories founded to solve an initial problem

In this sense, the new representation of the knowledge can be expressed as follows: considering the "scoring" function or relative importance for the predicates presented in (5) and given, for the relevance of 0.30, 0.20, 0.15 and 0.15 for the predicates *pavement*, *climate*, *vehicles* and *pavement_condition*, we can represent the possible solutions of the following form:

$$\text{PredicateID}(\text{relevance}, \text{QoI}, [\text{arg}_1, \text{arg}_2, \dots, \text{arg}_n]) \quad (6)$$

where the *predicateID* corresponds to the identification of the predicate, or name of the predicate. The *QoI* corresponds to the *Quality of Information* (section 3.2) associated to each predicate founded in the inference process mentioned in the section 3.1. The set of arguments (i.e. $\text{arg}_1, \text{arg}_2, \dots, \text{arg}_n$) corresponds to the value of the arguments of the predicate. Following this representation, and as two of the possible solutions (programs 5 and 6) and the confidence degrees are presented in the programs 7 and 8. In this sense, being in consideration this representation and the obtained theories through the inference process, it is possible to transform the unknown information in quantified information.

Program 7 -The new logic program with the quantification of the QoI for the extended logic program, theory 1 or scenario 1

```
{
  ¬ pavement(X,Y,Z) ← not pavement(X,Y,Z),
  pavement(0.3, 1, 2, asphalt_concrete_B,120),
  pavement(0.3, 1, 3, asphalt_concrete_C,85),
  pavement(0.3, 0.035, 1, asphalt_concrete_A,100),
  ¬ climate(X,Y,Z) ← not climate(X,Y,Z),
  climate(0.20, 1, 2, asphalt_concrete_B, 1),
  climate(0.20, 1, 1, asphalt_concrete_A,25),
  climate(0.20, 1, 3, asphalt_concrete_C, 43),
  ¬ vehicles(X,Y,Z) ← not vehicles(X,Y,Z),
  vehicles(0.15, 1, 1, asphalt_concrete_A,12000),
  vehicles(0.15, 1, 2, asphalt_concrete_B,15000),
  vehicles(0.15, 0.083, 3, asphalt_concrete_C,11000),
  ¬ pav_condition(X,Y,Z) ← not pav_condition(X,Y,Z),
```

```

    pav_condition(0.35, 1, 1, asphalt_concrete_A,55),
    pav_condition(0.35, 1, 3, asphalt_concrete_C,66),
    pav_condition(0.35, 0.125, 2, asphalt_concrete_B,33)
}

```

Program 8 -The new logic program with the quantification of the QoI for the extended logic program, theory 2 or scenario 2

```

{
    ¬ pavement(X,Y,Z)← not pavement(X,Y,Z),
    pavement(0.3, 1, 2, asphalt_concrete_B,120),
    pavement(0.3, 1, 3, asphalt_concrete_C,85),
    pavement(0.3, 0.018, 1, asphalt_concrete_A,100),
    pavement(0.3, 0.018, 1, asphalt_concrete_A,150),
    ¬ climate(X,Y,Z)← not climate(X,Y,Z),
    climate(0.20, 1, 2, asphalt_concrete_B, ⊥),
    climate(0.20, 1, 1, asphalt_concrete_A,25),
    climate(0.20, 1, 3, asphalt_concrete_C, 43),
    ¬ vehicles(X,Y,Z)← not vehicles(X,Y,Z),
    vehicles(0.15, 1, 1, asphalt_concrete_A,12000),
    vehicles(0.15, 1, 2, asphalt_concrete_B,15000),
    vehicles(0.15, 0.083, 3, asphalt_concrete_C,11000),
    vehicles(0.15, 0.083, 3, asphalt_concrete_A,14000),
    ¬ pav_condition(X,Y,Z)← not pav_condition(X,Y,Z),
    pav_condition(0.35, 1, 1, asphalt_concrete_A,55),
    pav_condition(0.35, 1, 3, asphalt_concrete_C,66),
    pav_condition(0.35, 0.125, 2, asphalt_concrete_B,33)
}

```

Thus, based on the Extended Logic Programming paradigm for knowledge representation and reasoning formalisms, we present a simple example in order to illustrate the inference process of each neuron of the virtual intellect (Ribeiro, Machado et al., 2010).

4.4 The Construction of the Knowledge

With the database ready, the next step is to compile the information available to another language, a math language (Figure 10). This is a fundamental step in order to make easy to handle with the data in order to weight the importance of each variable, its interaction to the pavement durability, and calculate the RPDI (Relative Pavement Damage Index), the contribution of each vehicle to destruct the pavement, according the chosen failure criteria.

The data need be organized in a form of a matrix, with one row per vehicle. Now, one has to calculate the relative relevance of each vehicle for the pavement service life in a consistent way, which is the second challenge in the INTELLIPave method. This can be solved using matrix of equations combined, or not, with artificial intelligence based tools, like clustering, done with unsupervised NN or SVM, as a way to reduce the number of RPDIs to be calculated by grouping together those vehicles with very similar characteristics (air temperature, rainfall, speed, weight,

etc.); as a database describing a pavement have million of rows (vehicles), any reduction in the number of variables will provide important reduction in the processing time to solve the equation system (Rocha et al. 2006) (Ribeiro et al. 2010). Once this task have been solved, every row in the matrix of data receives a “relative pavement damage” index representing the relative importance of the row in relation to the other ones (Figure 11), the RPDIs.

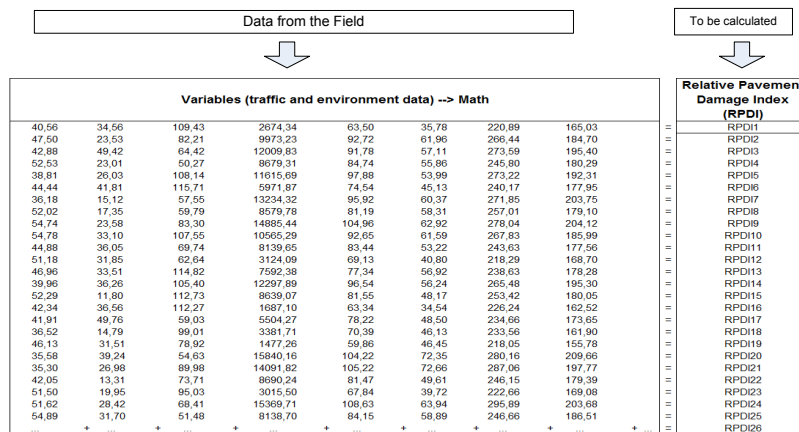


Fig. 10 - Field Data Organized in Form of a Matrix of Numbers

With the RPD calculated this becomes a matrix of performance for the asphalt pavement, with inputs (data collected in the field) and outputs (the RPDIs), suitable to supervised neural network training, creating an individual model to be attached to the CUIA Model.

Variables (traffic and environment data) -> Math										RPDI (°)
164.1800144	40.8500302	25.5966057	94.9264302	10741.3168803	89.6066930	64.8368234	256.5648779	195.3544620	...	118.2968887
100.2736005	41.5997626	34.3589193	67.8844469	11313.9104777	97.3408360	56.7421923	265.6232226	188.3150188	...	119.4879974
91.7562444	37.0023341	38.3933596	97.5291902	14077.4882752	101.1370999	60.7690223	272.3011737	199.9286455	...	134.2539785
145.0848500	45.2868755	39.4418070	57.7732418	15346.0127916	102.8311465	67.0577716	279.0847217	208.5175367	...	136.4838557
158.7917714	53.9775755	17.9889557	77.3901746	6073.1879542	72.2602559	50.4377571	232.0124465	179.3978964	...	108.8044536
142.4026631	52.2970516	49.7393155	110.8279495	10285.0399188	89.9084566	61.5668896	256.2580471	188.1763770	...	114.5022265
70.7416699	39.3872894	33.5933655	51.8482933	11235.5095338	97.4515216	63.2358072	263.0884587	190.3691975	...	126.9134297
91.8164851	47.5935563	10.4312840	59.8965404	11715.7029863	94.9280198	61.4800889	278.0187559	197.2642468	...	119.2092507
118.8143423	43.2321337	20.9074608	114.3741045	44.19.4412017	67.9545769	51.2316187	227.6979320	168.5657457	...	97.17430704
150.4081661	41.6734196	27.6694608	112.1941768	14682.8646941	104.5009071	62.7714966	273.9713921	200.2078172	...	131.2716887
135.6812535	42.5782093	45.2778012	102.5896439	8322.1481062	79.3491815	56.1293652	246.0527499	183.6222671	...	110.5011919
72.8296150	49.6925000	37.1345044	51.7088432	1296.4475390	60.5123504	44.4368134	223.7109577	163.1884266	...	84.77453419
143.1071484	39.2301760	31.3913961	104.0625313	4701.7780208	66.7784933	48.8412535	235.4607423	168.0413715	...	105.5733689
74.4707994	48.7373341	30.0683827	64.1236388	1137.5918147	62.2548752	34.5074877	221.5268225	162.9271095	...	86.01666424
134.3524072	51.4003554	13.8089480	109.3604118	9565.8022852	86.0262015	57.3514461	250.4608398	188.4774162	...	113.7541042
77.9150449	43.7964863	46.0379568	75.9236775	1851.6023977	64.7284724	48.5839858	214.3817219	159.9688527	...	87.6710322
131.4629274	45.2263725	23.6018045	57.7712198	5577.8688832	76.3090912	49.3971031	234.5392493	176.5206345	...	103.9563734
92.1356253	46.2765655	36.5874388	55.8601272	11938.3865416	94.2668963	59.7577032	259.7085520	196.7723897	...	124.2395434
126.5206031	41.7373297	11.3907336	59.5288657	8436.3195091	78.1278137	49.1960007	245.9137528	185.9455745	...	117.7526602
107.8795734	46.2452776	45.5594519	52.7485736	4696.5143246	66.5051349	42.4839056	236.1162194	174.6396434	...	99.52567913
124.8854374	45.9601426	36.1142282	116.7817101	13153.8944023	94.4151750	60.9096744	266.1809566	196.7309938	...	132.6186304
98.8092320	35.7284491	13.7132563	69.0147113	9991.7396408	87.2441255	53.9883427	258.5194924	186.2908365	...	118.9209173
158.6986996	38.8647449	42.8677265	97.7556600	6782.7769595	77.5597502	46.5009556	243.3932007	180.0689043	...	106.204281
107.3076956	44.3974199	17.7598296	101.3556766	2419.1869759	67.3697787	38.6479549	220.3457147	166.7302876	...	91.78466017
164.3352762	45.0938439	22.9209446	68.1587398	9623.8208081	86.4041692	63.0531738	265.8239784	183.5888840	...	120.6520766

(*) RPD Calculated With the Equation System + Soft Computing Tools

Fig. 11 - The Relative Pavement Damage Index (RPDI) Calculated

It must be pointed out that the importance, or weight, for the individual variables in the row (air temperature, rainfall, speed, axle weight, et cetera) are useful to better understanding of the asphalt pavement behaviour, but it is not critical information for the INTELLIPave method.

The Figure 12 shows the diagram with the tasks to transform the source “brute” data to an information fine to train a neural network system. The knowledge can be easily accumulated just adding new matrixes of performance to the CUIA Model. The accumulation allows continuous improvement in the accuracy and usability.




Fig. 12: The Database With the History of the Pavement is “Handled” to Become a Matrix of Performance to Train the Neural Network System

4.5 Handling Errors

Regardless the tools’ combination to calculate the RPDIs, some level of error will remain in the final pavement damage indexes. The third challenge is to handle this error in an efficient way. The data obtained in the previous tasks that lead to the pavement damage index, is to be understood as the result of the “true” RPDi multiplied by an unknown error, as presented in the following formula:

$$(RPDI_{TRUE}) = (RPDI_{CALCULATED}) \cdot Error$$

In fact, the error may have any size since it is well distributed inside the matrix of performance, or in another words, if the error in the RPDi in the row 1 is similar to the error in the row 2, and so on. As the result, the sum of the RPDIs for the full matrix will have the same similar error.

Instead to use the pavement damage index as an absolute value, in the INTELLIPave approach it is used in a comparative way, with the individual RPDi divided by the sum of the RPDIs; as the error exists in both, the error is divided by itself and eliminated, presented in the following formula:

$$\frac{RPDI_{TRUE}}{(\sum(RPDI_{TRUE}))} = \frac{RPDI_{CALCULATED} \cdot Error}{(\sum(RPDI_{CALCULATED})) \cdot Error}$$

∴

$$\frac{RPDI_{TRUE}}{(\sum(RPDI_{TRUE}))} \cong \frac{RPDI_{CALCULATED}}{(\sum(RPDI_{CALCULATED}))}$$

If the error is not well distributed inside the matrix of performance, the division will remove just the part that can be considered as well distributed.




Fig. 13: Error dilution.

In addition to divide the error by itself, in the INTELLIPave method the pavement to be modeled must to be described in the same way as the model is described in the matrix of performance, with information about traffic and climate over extended timeframes. For practical purposes, the pavement to be modeled must to be described, vehicle-by-vehicle, over the desired pavement service-life, this means a matrix with million vehicles over periods of time around 10 years. If the pavement to be modeled is described using one single vehicle, the error probability will be the maximum (100% of the error), but when described in million rows, the error is subject of a massive dilution, as shown in the Figure 13. When the pavement is described with 1000 or more vehicles, the diluted error is statistically reduced to almost zero.

4.6 Training The Artificial Neural Network

The “matrix of performance” is the source of “intelligence” to supervised training of the neural network system, using the field data as input, and the RPDIs as output. The only challenge in this step is the computer power to train a so big matrix of data, with dozen of millions of data items.

The Figure 13 shows a chart with the matrix of performance (also referred as “individual model”) and the proposed pavement design. The trained neural network do evaluates the RPDIs for the proposed pavement. The sum of the RPDIs in the

model is compared with the sum of the RPDIs of the proposed pavement and allow a conclusion, as shown in the Figure 14.

Variables (traffic and environment data) -> Math															RPDI (°)
164.1800144	40.8500302	25.5866577	94.9264302	10741.3168803	89.6066930	64.8388231	256.5648779	195.3544620	=	118.2968897					
100.2736205	41.5997626	34.3589193	67.8844469	11313.9104777	97.3408360	56.7421923	265.8232226	188.3150188	=	119.4879974					
94.7624444	37.0023441	38.3803566	97.5621920	14077.4889759	101.1370999	60.7690223	272.3111137	159.3026455	=	134.2539785					
146.0948500	45.2868755	39.4418970	57.7773418	15346.0127916	102.8311465	67.0577716	279.0847217	208.5175367	=	136.4838527					
158.7917714	53.9775755	17.9889557	77.3901746	6073.1879462	72.2602559	50.4377571	232.0124655	179.3978964	=	168.8044536					
142.0206311	52.2907616	49.1931551	110.9279495	10295.0399188	89.5044661	63.5668996	256.2520471	188.1763770	=	114.3402265					
70.7416699	39.3872894	33.5835365	51.8429233	11235.5095338	97.4515216	63.2358072	263.8894587	190.3691975	=	126.9134297					
81.8144851	47.5355653	10.4312840	59.8965404	11715.7029863	94.5280198	61.4800889	278.9187559	197.2642488	=	119.2029207					
118.5143423	43.2321337	20.9074608	114.3741045	4479.4412017	67.9545789	51.2318181	227.8197920	168.5651451	=	97.17430704					
150.4081661	41.6734196	27.6694608	112.1941768	14682.8646841	104.5009071	62.7714968	273.9713921	200.2078172	=	131.2716887					
135.8825535	42.5762091	45.2778012	100.5896429	8322.1481082	79.3491815	56.1293652	246.9527499	183.6226781	=	110.5011919					
72.8296150	49.8929000	37.1345434	51.7098420	1296.4417390	60.8123044	44.4361814	223.7199971	163.1864296	=	84.7743419					
143.1071484	39.2301760	31.3913861	104.0625313	4701.7782008	66.7784933	48.8412534	235.4607423	168.0413716	=	105.5733689					
74.4101594	48.1373341	30.6808227	64.1236380	1137.5918147	62.2549152	38.5074877	221.5086225	162.9271099	=	86.0166624					
134.5624072	51.4003541	13.8988490	109.3694110	8565.8022652	88.0262076	77.3514461	259.4608398	188.4774162	=	113.7841042					
77.9150449	43.7964893	45.0373958	79.9236775	1891.6023917	64.7264724	46.5853854	214.3817219	159.8888527	=	87.6710322					
151.4020724	45.2263726	23.6018040	57.7721080	1057.8688832	76.3090912	49.3971631	234.5302453	176.2202445	=	103.9837334					
92.1356253	45.2765555	36.5874388	55.8601272	11938.3885416	84.2668963	59.7577032	259.7085520	195.7723897	=	124.2384534					
126.5266031	41.7373297	11.3907336	59.5288857	8436.3195091	78.1279137	49.7196007	245.9137528	185.9455745	=	117.7526602					
107.9787341	45.2420776	45.4944919	62.7489738	4098.5143246	66.5051349	42.4029053	236.1162194	174.6396434	=	99.52629713					
124.8854374	45.9501426	36.1142282	116.7817101	13153.8944023	94.4151750	60.9096744	266.1809566	196.7309336	=	132.6196304					
88.8092300	36.7284913	13.7132563	69.0174713	9991.7386408	67.2441255	53.8883427	268.5194524	186.2909365	=	118.9209173					
158.0286296	39.8617449	42.8872051	97.7556600	8782.7789295	77.6597502	46.5006564	243.3932007	190.0690443	=	106.204481					
107.3076956	44.3974199	17.7598296	101.3556766	2419.1889759	67.3697787	38.6478549	220.3457147	166.7302876	=	91.78466017					
164.3327262	45.9538429	22.5029446	68.1587398	9623.8208081	86.4041632	63.0531738	265.8239784	183.5888840	=	120.6520766					

(*) RPDI Calculated With the Equation System + Soft Computing Tools

Matrix of Performance – Source of "Intelligence" to train the network

Proposed Pavement Design: traffic and environment data															RPDI
49.58528479	13.88054472	67.91984921	14593.77643	100.4731813	82.28931206	292.8947851	202.6007099	136.0275909	=	RPDI1					
53.9750667	10.8663723	75.37396882	4114.096763	64.03622904	69.38619233	235.1546202	177.4128898	100.7189908	=	RPDI2					
39.81551186	12.88978717	13.77096651	14054.18952	67.0933378	288.8813795	201.3088989	175.5554542	115.6545442	=	RPDI3					
54.84367296	33.28815281	63.35716014	3739.180773	65.2208525	45.92704983	223.2346932	167.3867687	101.6173612	=	RPDI4					
42.5738881	22.66654387	112.371068	15155.49968	109.1871239	69.79945511	276.8227133	201.6662637	134.6461111	=	RPDI5					
35.831665315	18.05148446	57.31985079	11278.91738	96.32438362	83.94529689	273.6240191	196.2006881	127.479034	=	RPDI6					
45.54931595	17.06907356	59.91619904	2010.461369	63.27629022	41.20373394	217.5069794	164.6476378	92.26266157	=	RPDI7					

(**) Made by the trained neural network system

Fig. 13: The Matrix of Performance (field data + RPDIs) Will be Able to Do Predictions for Problems Proposed in the Exact Same Way it was Described the Initial Database Used to Generated the Matrix of Performance

In this sense, the sum of the proposed pavement RPDIs divided by the sum of the model's RPDIs provides the relation between the service-life of both pavements, as the service-life of the model is known, the estimated service-life for the proposed pavement can be calculated, typically in years.

The sum of the RPDIs of the proposed pavement	is larger than	the sum of the RPDIs of the model	The proposed pavement is underdesigned and will last less than the model's pavement. Thicknesses must be increased to avoid earlier and expensive maintenance
	is similar to		The proposed pavement is well designed and will have a service-life similar to the model's pavement.
	is smaller than		The proposed pavement is overdesigned and will last more than the model's pavement. Thicknesses can be reduced to save money.

Fig. 14: Interpretation of the artificial intelligence based modeling done under the INTELLIPave method.

The prediction done by the matrix of performance is always to the same thicknesses and materials of those existing in the pavement used to build the model. If the proposed pavement have thicknesses different of those of the matrix of performance – and this happens in most of the cases - the procedure is different. In this case, the

proposed pavement must to be evaluated against at least two matrixes of performance; both matrixes must to be constructed with same materials, but different thicknesses; the result provided by both matrixes is, then, evaluated by a third and small neural network set.

Structure	Asphalt concrete thickness (cm)	Granular layer thickness (cm)	Service-life for the proposed pavement
Matrix of Performance A	5	35	5.7 years
Matrix of performance B	10	45	9.1 years
Proposed pavement	7.5	40	7.4 years

Fig. 15: CUIA Model provides prediction for different thicknesses

This parallel evaluation is called CUIA Model and is shown in the Figure 15, where the asphalt concrete and granular layer thicknesses of the pavement used to built the matrixes of performance are used as input, and the respective estimated service-life as output to train the small network set. The proposed pavement thicknesses are used as input for the problem; the neural networks will evaluate the service-life for the proposed pavement. As more matrixes of performance are available and used to train the NN, the predictions strength will grow (continuously).

4.7 Discussion

The objective of this paper focuses on the creation of an artificial intelligence based model to predict the asphalt pavement performance and evaluate the quality of the information. The presented framework combines the advantages associated with the symbolic, connectionist and evolutionary paradigms in order to optimize the universe when handling incomplete information. In the figure 16 we present a brief review of the comparison between the modelling using the INTELLIPave method against the current state-of-the-art empiric-mechanistic approach.

Most of the problems solved by the evolutionary computation techniques are well defined and the performance comparisons of the individuals involved are easy to understand (Paz, 2005) (Rocha et al. 2006). In our approach, the learning process is based on the evolution of individuals, being built through the process of quantifying the quality of information associated with the logic program (or theory). These extended logic programs represent the population of candidate solutions in order to model the universe of discourse. The combination of GP and Extended Logic Programming will not get a solution to a particular problem, but rather a logical representation (or program) of the possible scenarios from unknown information presented in the database of the pavement management environments.

With this computational model to deal with incomplete information in an evolutionary environment, some advantages can be presented:

- (i) Evaluating and classifying the knowledge of each scenario that models the universe of discourse and maximizes the quality-of-information associated with the all knowledge;
- (ii) The selection of the most promising scenario based on the quality-of-information that each one carries out;
- (iii) Improving the computational task in an evolutionary environment, in order to solve problems by selecting the best scenarios based on the quality-of-information;
- (iv) Through a new representation (6) it is possible use quantified information of the unknown knowledge normally discarded in the traditionally Artificial Intelligence techniques.

INTELLIPave Method	vs	Empiric-mechanistic approach
		$ESAL = SF \cdot (\epsilon_t)^{-f2} \cdot E^{-f3}$
Full scientific and rational field data based approach constructed using proven scientific tools		Obsolete laboratory-based approach
All variables considered in its exact importance		One variable (ϵ_t) and one constant (Modulus, E)
Each equation in the matrix of performance is rich in information		Have three adjusting factors (SF, f2, f3)
Millions of equations to support robust and accurate modelling		One equation good for “everything”
Full traffic profile consideration		Unacceptable use of ESAL from other methods
Full climate consideration		Fixed Temperature
Scalable, allow accumulate the knowledge just adding new matrix of performance to the CUIA Model, improving strength and accuracy in a continuous way		No way to accumulate knowledge
All know and unknown factors are considered in the modeling (visco-plasticity, nonlinearity, anisotropy, etc)		Simplified to elastic and isotropic
A new paradigm for asphalt pavement modeling, with large space to be improved and in line with the XXI century challenges		Small changes since its creation, decades ago; simple method, do not allow any important improvement.

Figure 16: Comparison Between the Modelling Using the INTELLIPave Method Against the Current State-of-the-art Empiric-mechanistic Approach

In this sense, it was presented some insights either theoretical or experimental into the making from the ground INTELLIPave approach to predict and model the asphalt pavement performance using soft computing tools and numerical methods and, at the same time, create a way to accumulate the knowledge in this engineering field. The knowledge about the asphalt pavement life cycle is organized in a hierarchical way in order to be reused in a formal way, leading to an evolutionary process of adaptation and construction.

5 Conclusions and Future Work

The empiric paradigm used to predict the long-term performance for asphalt pavements remain almost untouched, at an unsustainable level, do not providing accurate or acceptable predictions for the XXI century challenges. In the last decades, a small but growing number of studies have been made applying some Artificial Intelligence (AI) based techniques to asphalt pavements, namely looking at performance prediction, pavement management and evaluation. However, qualitative and quantitative models have been around in Artificial Intelligence research for some time, in particular due the growing need to offer support in decision-making processes in particular in environments with defective information. The integrated use of numerical, evolutionary and artificial intelligence based methods allow to create a scientific and rational method for pavement modeling, by-passing most of the problems in the area and improving the accuracy's prediction in order to better use of the limited financial funds.

In this paper we present a framework based on the symbolic, evolutionary and connectionist paradigms for asphalt pavements. Under the Extended Logic Programming paradigm for knowledge representation and reasoning using the evolutionary programming paradigm, the candidate solutions are seen as evolutionary logic programs or theories, being the test whether a solution is optimal based on a measure of the quality-of-information carried out by those logical theories or programs.

References

1. Cook, S. and J. Clark.: City of Denton White Paper Street Maintenance and Pavement Management Systems, Denton, 2002.
2. Salini, R., J. Neves and A. Abelha.: The Road Map to Apply Evolutionary Intelligence to Asphalt Pavement Modelling, 22nd European Conference on Modelling and Simulation (ECMS 2008). Nicosia, Cyprus, 2008.
3. AASHTO, Transportation Asset Management Guide, *American Association of State Highway and Transportation Officials*. National Cooperative Highway Research Program (NCHRP), 2002.
4. Zimmerman, K., F. Botelho and D. Clark.: Taking Pavement Management into the Next Millennium, Transportation Research Board. A2B01: Committee on Pavement Management Systems. 2000.
5. Jansen, J. and B. Schmidt.: Performance models and prediction of increase overlay need in Danish state highway performance management system, Third International Conference on Managing Pavements, San Antonio, pp.74–84, 1994.
6. Bandara, N. and M. Gunaratne, Current and future pavement maintenance prioritization based on rapid visual condition evaluation, *J Transport Eng*, 127(2):116–23, 2001.
7. Yang, J, J J. Lu, M Gunaratne, and Q Xiang. 2003. "Overall Pavement Condition Forecasting Using Neural Networks: Application to Florida Highway Network." *82nd Annual Meeting of the Transportation Research Board*.
8. Bosurgi, G. and Trifirò, F. A Model Based on Artificial Neural Networks and Genetic Algorithms for Pavement Maintenance Management. *International Journal of Pavement*, Vol. 6, No. 3, pp. 201–209, 2005.

9. Forbus, K. D.: Qualitative reasoning. CRC Handbook of Computer Science and Engineering: 715-733, 1996.
10. Kuipers, B.: Qualitative reasoning: modeling and simulation with incomplete knowledge, MIT press, 1994.
11. Bredenhann, S. and M.F.C. van de Ven. Application of artificial neural networks in the back-calculation of flexible pavement layer moduli from deflection measurements. Proceedings of the 8th Conference on Asphalt Pavements for Southern Africa (CAPSA'04), Sun City, South Africa
12. Liu, Y. and M. Sun, Fuzzy Optimization BP Neural Network Model for Pavement Performance Assessment, 2007 IEEE International Conference on Grey Systems and Intelligent Services, Nanjing, China, 18-20, 2007.
13. Terzi, Modeling the pavement serviceability ratio of flexible highway pavements by artificial neural networks, Construction and Building Materials 21, p. 590–593, 2007.
14. Sheridan, F.: A Survey of techniques for inference under uncertainty. Artificial Intelligent Review 5(1):89, 1991.
15. Kowalski, R.: The logical way to be artificially intelligent. In: Toni, F., Torroni, O. (eds), Proceedings of the CLIMA VLLNCS (LNAI), pp.1-22, Springer, Heidelberg, 2006.
16. Kakas, A., Kowalski, R. and Toni, F.: The role of abduction in logic programming. In Gabbay, D., Hogger, C., and Robinson, I., editors, Handbook of Logic in Artificial Intelligence and Logic Programming, volume 5, pages 235-324, Oxford U.P., 1998.
17. Neves, J.; Machado, J.; Analide, C.; Abelha, A. and Brito, L. The Halt Condition in Genetic Programming. In Lecture Notes in Artificial Intelligence 4874 – Progress in Artificial Intelligence – Springer, 2007.
18. Shafer, G.: The Dempster-Shafer theory. Encyclopedia of Artificial Intelligence, Second Edition. S. C. Shapiro, Wiley, 1992.
19. Subrahmanian, V.: Probabilistic databases and logic programming, In Proc. of the 17th International Conference of Logic Programming, 2001.
20. Zadeh, L. A. Fuzzy Logic. The MIT Encyclopedia of the Cognitive Sciences. R. A. Wilson and F. C. Keil, MIT Press, 2001.
21. Loyer, Y., Spyrtos, N. and Stamate, D.: Parametrised Semantics for Logic Programs - a unifying framework. Theoretical Computer Science, 308 (1-2), 2003.
22. Analide, C., P. Novais, J. Machado and J. Neves. Quality of Knowledge in Virtual Entities, in Encyclopedia of Communities of Practice in information and Knowledge Management, Idea Group Inc, pp. 436-442, 2006.
23. Machado, J., F. Andrade, J. Neves, P. Novais and C. Analide. Formal Models in Web Based Contracting. The 2006 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology, (WI-IAT 2006 Workshop Proceedings), Hong Kong, pp 548-551, 2006.
24. Lima, L., R. Costa, P. Novais, et al. Quality of Information in the Context of Ambient Assisted Living. In Advances in Soft Computing, Springer-Verlag. vol. 50: pp. 624-633, 2008.
25. Machado, J., M. Miranda, G. Pontes, D. Santos, M. Santos, A. Abelha and J. Neves. Intelligent Agents and Medical Moral Dilemmas. In Proceedings of the 8th WSEAS International Conference on Applied Computer & Applied Computational Science (ACACOS '09), Hangzhou, China, 2009.
26. Ribeiro, J., P. Novais, J. Neves J., M Fernandez-Delgado. Quality of the Information: The application in the winification process in wine production, in Proceedings of the 2009 European Computing Conference of the World Scientific and Engineering Academy and Society, Tbilisi, Georgia, June 26-28, pp. 62-70, ISBN:978-960-474-088-8, 2009.
27. Lima, L., P. Novais, J. Bulas Cruz. A Process Model For Group Decision Making With Quality Evaluation. In Distributed

28. Computing, Artificial Intelligence, Bioinformatics, Soft Computing and Ambient Assisted Living, Omatiu S., et al. (Eds.) LNCS 5518, Springer-Verlag, pp. 566-573, 2009.
29. Machado, J., A. Abelha, P. Novais, J. Neves and J. Neves. Quality of service in healthcare units. *Int. J. Computer Aided Engineering and Technology*, vol. 2, No. 4, pp. 436-449, 2010.
30. Novais, P., M. Salazar, J. Ribeiro, C. Analide, J. Neves. Decision Making and Quality-of-Information. In *Soft Computing Models in Industrial and Environmental Applications*, 5th International Workshop (SOCO 2010), Corchado E., Novais P., Analide C., Sedano J., (Eds.) Springer – Series Advances in Intelligent and Soft Computing, vol. 73, ISBN 978-3-642-13160-8, pp 187-195, (International Workshop on Soft Computing Models in Industrial Applications, Guimarães, 2010).
31. Novais, P., F. Andrade, J. Machado and J. Neves. Agents, Trust and Contracts. In *Information Communication Technology Law, Protection and Access Rights: Global Approaches and Issues*, Portela I., Cunha M. (Eds), IGI Global, 2010.
32. Salini, Reus, António Abelha, and José Neves. 2009. "INTELLIPave - Considering Aside Failure Criteria and Unknown Variables in Evolutionary Intelligence Based Models for Asphalt Pavement." In *Proceedings of the 23rd European Conference on Modelling and Simulation*. 9-12 June 2009. Pages 624-629. ISBN: 978-0-9553018-8-9 / ISBN: 978-0-9553018-9-6 (CD). Madrid, Spain.
33. Salini, Reus, António Abelha, and José M. Neves. 2008. "The Road Map to Apply Evolutionary Intelligence to Asphalt Pavement Modelling." In *Proceedings of the 22nd European Conference on Modelling and Simulation (ECMS 2008)*. 3-6 June 2008. Pages 573-579. ISBN: 978-0-9553018-5-8 / ISBN: 978-0-9553018-6-5 (CD). Nicosia, Chipre.
34. Flintsch, G.W. "Soft Computing Applications in Pavement and Infrastructure Management: State-of-the-Art". *Transportation Research Board Annual Meeting*, 2003.
35. Madanat, S., J.A. Prozzi & M. Han, Effect of performance model accuracy on optimal pavement design, *Comput-Aided Civ Inf Eng*, pp.17:22–30, 2002
36. Carey, W and P Irick. "The Pavement Serviceability Performance Concept." *Highway Research Board Special Report 61E*, AASHO Road Test, 1962.
37. AASHTO. 2004. "Pavement Design Guide." Memorandum, American Association of State Highway and Transportation Officials, Frankfort, Kentucky.
38. National Cooperative Highway Research Program. 2004. "NCHRP 1-37A - Guide for Mechanistic-empirical Design of New and Rehabilitated Pavement Structures (AASHTO 2002)." Illinois.
39. Salini, Reus. 2000. "Utilização de Borracha Reciclada de Pneus em Misturas Asfálticas." Tese de Mestrado 138.
40. Tutumluer, E and U Seyhan. "Neural Network Modeling of Anisotropic Aggregate Behavior From Repeated Load Triaxial Tests." *Transportation Research Record* 1615, pp.86-93, 1998.
41. Penumadu, D, L Jin-Nan, J L. Chameau, and S Arumugam. 1994. "Rate-Dependent Behavior of Clays Using Neural Networks." *Proceedings of the 13th Conference of the International Society for Soil Mechanics and Foundation Engineering* 4, pp.1445–1448, 1994.
42. Penumadu, D and R Zhao. "Triaxial Compression Behavior of Sand and Gravel Using Artificial Neural Networks (ANN)." *Computers and Geotechnics* 24:207-230, 1999.
43. Zhu, J H. and M M. Zaman. "Neural Network Modeling for a Cohesionless Soil." 76th Meeting of the Transportation Research Board, 1997.
44. Basheer, I A. and Y M. Najjar. 1998. "Modeling Cyclic Constitutive Behavior by Neural Networks: Theoretical and Real Data." *Proceedings of the 12th Engineering Mechanics Conference* 952–955.
45. Ellis, G W., C Yao, R Zhao, and D Penumadu. 1995. "Stress-Strain Modeling of Sands Using Artificial Neural Networks." *Journal of Geotechnical Engineering* 121(5):429–435.

46. Meier, R W., D R. Alexander, and R B. Freeman. 1997. "Using Artificial Neural Networks As A Forward Approach to Backcalculation." *Transportation Research Record* 1570 126–133.
47. Ceylan, Halil, Alper Guclu, Erol Tutumluer, and Marshall R. Thompson. 2004. "Use of Artificial Neural Networks for Backcalculation of Pavement Layer Moduli." 2004 FWD Users Group Meeting 22.
48. Roberts, C A. and N O. Attoh-Okine. 1998. "Comparative Analysis of Two Artificial Neural Networks using Pavement Performance Prediction." *Computer Aided Civil and Infrastructure Engineering* 13(5):339–343.
49. Banan, M R. and K D. Hjelmstad. 1996. "Neural Networks and the AASHO Road Test." *Journal of Transportation Engineering* 122(5):358– 366.
50. Faghri, A and J Hua. 1995. "Roadway Seasonal Classification Using Neural Networks." *Journal of Computing in Civil Engineering* 9(3):209–215.
51. Lingras, P. 1995. "Classifying Highways: Hierarchical Grouping Versus Kohonen Neural Networks." *Journal of Transportation Engineering* 121, No. 4:364– 368.
52. Xiao, Wangxin, Xinping Yan, and Xue Zhang. 2006. "Pavement Distress Image Automatic Classification Based on DENSITY-Based Neural Network." *RSKT 2006, LNAI 4062* 685–692.
53. Bray, Justin, Brijesh Verma, Xue Li, and Wade He. 2006. "A Neural Network based Technique for Automatic Classification of Road Cracks." *International Joint Conference on Neural Networks* 6.
54. Abdallah, Imad, Octavio Melchor-Lucero, Carlos Ferregut, and Soheil Nazarian. 2000. "Development of a Comprehensive, Rational Method for Determination of Remaining Life of an Existing Pavement." *Research Report 1711-2*, The Center for Highway Materials Research, The University of Texas at El Paso, El Paso, Texas, United States of America. Sponsor: Texas Department of Transportation.
55. Miradi, M. 2009. "Knowledge Discovery and Pavement Performance - Intelligent Data Mining." *Delft University of Technology - Section of Road and Railway Engineering (PhD Thesis):324*. ISBN 978-90-8570-278-8.
56. Cal, Yudong. 1995. "Soil Classification by Neural Network." *Advances in Engineering Software* (22):3.
57. Bosurgi, G. and F. Trifirò. 2005. "A Model Based on Artificial Neural Networks and Genetic Algorithms for Pavement Maintenance Management." *International Journal of Pavement* 201–209.
58. Bosurgi, G, F Trifirò, and M G. Xibilia. 2007. "Artificial Neural Networks for Predicting Road Pavement Conditions." 4^o INTERNATIONAL SIIV CONGRESS 12.
59. Venayagamoorthy, V and D Allopi. 2007. "Use of Neural Network in the Prediction of Bearing Capacity of Pavement Structure." 26th South African Transport Conference (SATC 2007) 8.
60. Thube, D T., M Parida, and S S. Jain. 2006. "Application of Artificial Neural Network (ANN) for Prediction of Pavement Derioration for Low Volume Roads in India." 22nd ARRB Conference - Research Into Practice 11.
61. Pekcan, Onur, Erol Tutumluer, and Marshall Thompson. 2008. "Nondestructive Pavement Evaluation Using ILLI-PAVE Based Artificial Neural Network Models." *Research Report FHWA-ICT-08-022*, Illinois Center for Transportation, Illinois.
62. Gopalakrishna, Kasthurirangann, Marshall R. Thompson, and Anshu Manik. 2007. "Rapid Finite-Element Based Airport Pavement Moduli Solutions using Neural Networks." *International Journal of Computational Intelligence (Winter 2007):9*. www.waset.org.
63. Taskiran, T. 2010. "Prediction of California bearing ratio (CBR) of fine grained soils by AI methods." *Advances in Engineering Software* (41):886-892. www.elsevier.com/locate/advengsoft.

64. Zeghal, M. 2008. "Visco-elastic portrayal of bituminous materials: artificial neural network approach." NRCC-50056, Institut for Research in Construction, National Research Council Canada, Canada.
65. Bianchini, Alessandra and Paola Bandini. 2010. "Prediction of Pavement Performance through Neuro-Fuzzy Reasoning." *Computer-Aided Civil and Infrastructure Engineering*, January, pp. 39-54. <http://onlinelibrary.wiley.com/doi/10.1111/j.1467-8667.2009.00615.x/full>.
66. Bayrak, Mustafa B., Egemen Teomete, and Manish Agarwal. 2004. "Use of Artificial Neural Networks for Predicting Rigid Pavement Roughness." *Midwest Transportation Consortium*.
67. Aultman-Hall, Lisa, Eric Jackson, Charles E. Dougan, and Soon-Nam Choi. 2004. "Models Relating Pavement Quality Measures." *Transportation Research Record* 1869.
68. Tapkın, Serkan, Abdulkadir Çevik, and Ün Usar. 2010. "Prediction of Marshall test results for polypropylene modified dense bituminous mixtures using neural networks." *Expert Systems with Applications* 11.
69. Halpern, J. (2005). *Reasoning about uncertainty*. MIT Press.
70. M. Denecker e A. Kakas. *Abduction in logic programming*. *Computational Logic: Logic Programming and Beyond, Essays in Honour of Robert A. Kowalski, Part I*. A. Kakas and F. Sadri, Springer Verlag. 2407 : pp. 402-436, 2002.
71. Paz, E. and C. Kamath (2005). *An Empirical Comparison of Combinations of Evolutionary Algorithms and Neural Networks for Classification Problems*. *IEEE Transactions on Systems, Man, and Cybernetics – Part B: Cybernetics*.
72. S. Haykin. *Neural Networks and Learning Machines*. Prentice Hall, Hardcover, 3rd edition, Published 2008.
73. D. Floreano, P. Durr and C. Mattiussi. *Neuroevolution: from architectures to learning*. *Evol. Intell.* 1(1), pp.47-62, 2008.
74. Ribeiro, J., Machado, J., Abelha, A., Fernández-Delgado, M., Neves, J. *Handling Incomplete Information in an Evolutionary Environment*. In *procs of the WCCI 2010 IEEE World Congress on Computational Intelligence*, pp: 2786-2793, CCIB, Barcelona, Spain, 2010.
75. Rocha, M.; Cortez, P. and Neves, J. *Evolution of Neural Networks for Classification and Regression*. *Neurocomputing*, Elsevier, 2006.