Campus de São Carlos

A utilização de redes neurais artificiais em
um sistema de gerência de pavimentos

José Remo Ferreira Brega

UNIVERSIDADE DE SÃO PAULO

**ESCOLA DE ENGENHARIA
DE SÃO CARLOS**

A UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS EM UM SISTEMA DE GERÊNCIA DE PAVIMENTOS

JOSÉ REMO FERREIRA BREGA

Tese apresentada à Escola de Engenharia de São Carlos, da Universidade de São Paulo, como parte dos requisitos para obtenção do Título de Doutor em Transportes.

ORIENTADOR: Prof. Dr. Manoel Henrique Alba Sória

DEDALUS - Acervo - EESC

31100115954

**São Carlos
1996**

Class.	TESE
Curr.	0958
Tombo	T059/97

Área : Transportes

0746033

Brega, José Remo Ferreira Brega
B843a A utilização de redes neurais artificiais em um sistema de gerência de pavimentos / José Remo Ferreira Brega.
São Carlos, 1996
234p.

Tese (Doutorado) -- Escola de Engenharia de São Carlos - Universidade de São Paulo, 1996
Orientador: Prof. Dr. Manoel Henrique Alba Sória

1.Sistemas de Gerência de Pavimentos. 2.Redes Neurais Artificiais
I. Título

À Jacilene

AGRADECIMENTOS

Ao Professor Manoel Henrique Alba Sória pela excelente orientação fornecida durante a elaboração deste trabalho.

Coordenadoria de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, pela bolsa deslocamento concedida.

Aos prestativos colegas, professores e funcionários do Departamento de Transportes da EESC/USP pela colaboração.

Ao professor Antônio Carlos Sementille por toda a sua ajuda durante a execução deste trabalho.

Ao professor João Fernando Marar, pela transmissão dos conhecimentos de redes neurais.

A Dona Leonilda, sempre prestativa com os problemas burocráticos.

Ao Dr. César Augusto Vieira de Queiroz pelo fornecimento dos dados da pesquisa PICR.

“Primeiramente, o mestre nos mostrou os arcos japoneses e nos explicou que sua extraordinária elasticidade era resultado de sua construção peculiar e das características do bambu, ou seja, do material de que eram construídos. Depois, ele nos chamou a atenção para a forma nobre que possui o arco, de quase dois metros de comprimento, quando armado com a corda, e que se manifesta de maneira surpreendente quanto mais é tensionado. “Quando estiramos a corda ao máximo”, disse-nos o mestre, “o arco abarca o universo, e por isso é importante saber curv-lo adequadamente”. HERRIGUEL (1994)

SUMÁRIO

1 INTRODUÇÃO.....	1
1.1 Motivação.....	1
1.2 Objetivos	2
1.3 Organização do Trabalho.....	3
 2 SISTEMAS DE GERÊNCIA DE PAVIMENTOS	 5
2.1 Introdução.....	5
2.2 Avaliação da Condição de um Pavimento.....	8
2.3 Estratégia de Manutenção.....	12
 3 REDES NEURAIIS	 17
3.1 Introdução.....	17
3.2 Uma Breve Visão Sobre Redes Neurais	19
3.3 Arquiteturas de Redes Neurais	23
3.4 Perceptron.....	24
3.5 Arquitetura de uma Rede Neural do tipo Multi Layer Perceptron (MLP)	24
3.6 Aprendizagem em Redes Neurais.....	26
3.7 Fase de Uso.....	30
 4 DESCRIÇÃO DA BASE DE DADOS UTILIZADAS NO	
PROBLEMA	31
4.1 Introdução.....	31
4.2 Arquivos da Pesquisa PICR	32
4.3 Variáveis Utilizadas.....	41

5 DESCRIÇÃO DO PROCEDIMENTO PARA AVALIAÇÃO DA CONDIÇÃO DO PAVIMENTO	45
5.1 Introdução.....	45
5.2 Avaliação da Condição do Pavimento.....	46
 6 RESULTADOS DA AVALIAÇÃO DA CONDIÇÃO DO PAVIMENTO.....	 52
6.1 Introdução.....	52
6.2 Análise da Avaliação da Condição por IGG Comparada com RN.....	53
6.3 Análise da Avaliação da Condição por Irregularidade Comparada com RN	102
6.4 Análise da Avaliação da Condição com IGG adicionado a Irregularidade Comparada com RN	150
 7 DESCRIÇÃO DO PROCEDIMENTO PARA PROJETO DE RESTAURAÇÃO DE PAVIMENTOS.....	 156
7.1 Introdução.....	156
7.2 Projeto de Restauração do Pavimento	156
 8 ANÁLISE DO PROJETO DE RESTAURAÇÃO UTILIZANDO REDES NEURAIS	 161
8.1 Introdução.....	161
8.2 Análise do Projeto de Restauração Utilizando RN.....	162
 9 ASSOCIAÇÃO DE REDES NEURAIS COM UM BANCO DE DADOS GRÁFICO.....	 206
9.1 Introdução.....	206
9.2 A Utilização de Redes Neurais Treinadas	206

10 CONCLUSÕES E TRABALHOS FUTUROS.....	215
10.1 Aspectos Gerais	215
10.2 Aspectos da Avaliação da Condição do Pavimento	217
10.3 Aspectos do Projeto de Restauração.....	217
10.4 Aspectos da Utilização das RN	218
 ANEXO 1	 219
 ANEXO 2	 222
 REFERÊNCIAS BIBLIOGRÁFICAS.....	 231

LISTA DE FIGURAS

- FIGURA 3.1 - Esquema de um neurônio biológico
- FIGURA 3.2 - Estrutura básica de um neurônio artificial
- FIGURA 3.3 - Alguns modelos de funções para neurônios
- FIGURA 3.4 - Arquitetura com muitas camadas
- FIGURA 5.1 - Esquema de RN proposto para avaliar a condição do pavimento
- FIGURA 5.2 - Esquema para treinamento
- FIGURA 6.1 - Efeito da idade na avaliação da condição por IGG
- FIGURA 6.2 - Efeito do tráfego na avaliação da condição por IGG
- FIGURA 6.3 - Influência do número de eixos equivalentes, calculados com diferentes expoentes do fator de equivalência de operações, na avaliação por IGG
- FIGURA 6.4 - Efeito do número estrutural na avaliação da condição por IGG
- FIGURA 6.5 - Efeito da inclusão de novos parâmetros na avaliação por IGG
- FIGURA 6.6 - Efeito da eliminação dos parâmetros de IGG na avaliação
- FIGURA 6.7 - Efeito dos parâmetros intrínsecos ao pavimento para avaliar a condição
- FIGURA 6.8 - Efeito da eliminação dos dados de ensaios para avaliação
- FIGURA 6.9 - Variação do peso da irregularidade na avaliação
- FIGURA 6.10 - Tipo de base na avaliação
- FIGURA 6.11 - Tipo de capa na avaliação
- FIGURA 6.12 - Comparação da avaliação com tipos de cobertura de acostamento
- FIGURA 6.13 - Erro de treinamento para avaliação
- FIGURA 6.14 - Validação dos resultados para avaliação
- FIGURA 6.15 - Número de nós na camada oculta
- FIGURA 6.16 - Alteração na quantidade de camadas ocultas para avaliação
- FIGURA 6.17 - Tamanho da amostra para avaliação
- FIGURA 6.18 - Efeito da idade na avaliação da condição por irregularidade

- FIGURA 6.19 - Efeito do tráfego na avaliação da condição por irregularidade
- FIGURA 6.20 - Influência do número de eixos equivalentes, calculados com diferentes expoentes do fator de equivalência de operações, na avaliação por irregularidade
- FIGURA 6.21 - Efeito do número estrutural na avaliação da condição por irregularidade
- FIGURA 6.22 - Efeito da inclusão de novos parâmetros na avaliação por irregularidade
- FIGURA 6.23 - Efeito da eliminação dos parâmetros de IGG na avaliação por irregularidade
- FIGURA 6.24 - Efeito dos parâmetros intrínsecos ao pavimento para avaliar a condição
- FIGURA 6.25 - Efeito da eliminação dos dados de ensaios para avaliação por irregularidade
- FIGURA 6.26 - Variação do peso da irregularidade na avaliação
- FIGURA 6.27 - Tipo de base na avaliação por irregularidade
- FIGURA 6.28 - Tipo de capa na avaliação por irregularidade
- FIGURA 6.29 - Comparação da avaliação com tipos de cobertura de acostamento
- FIGURA 6.30 - Erro de treinamento para avaliação
- FIGURA 6.31 - Validação dos resultados para avaliação
- FIGURA 6.32 - Número de nós na camada oculta
- FIGURA 6.33 - Alteração na quantidade de camadas ocultas para avaliação
- FIGURA 6.34 - Tamanho da amostra para avaliação
- FIGURA 6.35 - Piores casos de somatório de IGG e irregularidade
- FIGURA 6.36 - Melhores casos de somatório de IGG e irregularidade
- FIGURA 7.1 - Esquema de RN proposto para o projeto de reconstrução do pavimento
- FIGURA 7.2 - Esquema para treinamento
- FIGURA 8.1 - Efeito da idade na recuperação
- FIGURA 8.2 - Efeito do tráfego na recuperação

- FIGURA 8.3 - Influência do número de eixos equivalentes, calculados com diferentes expoentes do fator de equivalência de operações para recuperação
- FIGURA 8.4 - Efeito do número estrutural na recuperação
- FIGURA 8.5 - Inclusão de novos parâmetros na recuperação
- FIGURA 8.6 - Efeito da eliminação dos parâmetros de IGG na recuperação
- FIGURA 8.7 - Efeito dos parâmetros intrínsecos ao pavimento para recuperação
- FIGURA 8.8 - Efeito da eliminação dos dados de ensaios para recuperação
- FIGURA 8.9 - Tipo de base na restauração
- FIGURA 8.10 - Tipo de capa na restauração
- FIGURA 8.11 - Tipo de recobrimento do acostamento na recuperação
- FIGURA 8.12 - Erro de treinamento para recuperação
- FIGURA 8.13 - Validação dos resultados para recuperação
- FIGURA 8.14 - Número de nós na camada oculta
- FIGURA 8.15 - Alteração na quantidade de camadas ocultas
- FIGURA 8.16 - Tamanho da amostra para avaliação
- FIGURA 9.1 - Exemplo de mapa no SAGP
- FIGURA 9.2 - Janelas para entrada dos dados dos trechos
- FIGURA 9.3 - Introduzindo os valores dos pesos
- FIGURA 9.4 - Resultado da avaliação da condição
- FIGURA A.1 Fase de preparação dos dados
- FIGURA A.2 Método adotado para o reconhecimento

LISTA DE TABELAS

TABELA 4.1	- Descrição dos arquivos de dados
TABELA 4.2	- Definições das variáveis nos arquivos
TABELA 4.3	- Valores mínimos, máximos, médios e desvios padrões das variáveis utilizadas
TABELA 4.4	- Variável BASE
TABELA 4.5	- Variável SURF
TABELA 4.6	- Variável SHSU
TABELA 5.1	- Variáveis para a camada de entrada
TABELA 5.2	- Variáveis para a camada de saída
TABELA 6.1	- Solução inicial para IGG
TABELA 6.2	- Substituição de AGE0 por AGER
TABELA 6.3	- Substituição de AGE0 por AGES
TABELA 6.4	- Inserção de AGER
TABELA 6.5	- Inserção de AGES
TABELA 6.6	- Sem AGE0
TABELA 6.7	- Inserção de NHX
TABELA 6.8	- Inserção de NLV
TABELA 6.9	- Inserção de NHX e NLV
TABELA 6.10	- Inserção de PVL
TABELA 6.11	- Inserção de PV2
TABELA 6.12	- Inserção de PV4
TABELA 6.13	- Inserção de PV5
TABELA 6.14	- Inserção de PV6
TABELA 6.15	- Inserção de PVL, PV2, PV4, PV5 e PV6
TABELA 6.16	- Inserção de EPA2
TABELA 6.17	- Inserção de EPA4
TABELA 6.18	- Inserção de EPA2 e EPA4

TABELA 6.19	- Inserção de SNA
TABELA 6.20	- Inserção de SND
TABELA 6.21	- Inserção de SNA e SND
TABELA 6.22	- Sem SN
TABELA 6.23	- Inserção de CP (sem MP)
TABELA 6.24	- Inserção de WIDTH
TABELA 6.25	- Inserção de SHWIDE
TABELA 6.26	- Inserção de CRX
TABELA 6.27	- Sem CR1
TABELA 6.28	- Sem CR2
TABELA 6.29	- Sem CR3
TABELA 6.30	- Sem CR4
TABELA 6.31	- Sem CROC
TABELA 6.32	- Sem POT
TABELA 6.33	- Sem RAV
TABELA 6.34	- Sem SPAT
TABELA 6.35	- Sem RDMN
TABELA 6.36	- Sem MP
TABELA 6.37	- Sem SURF
TABELA 6.38	- Sem H1
TABELA 6.39	- Sem BASE
TABELA 6.40	- Sem SHSU
TABELA 6.41	- Sem DEFS
TABELA 6.42	- Sem RQI
TABELA 6.43	- Sem SGCBR
TABELA 6.44	- Nomes parametrizados
TABELA 6.45	- $RQI * 10$
TABELA 6.46	- $RQI * 5$
TABELA 6.47	- $RQI * 1,5$
TABELA 6.48	- Sem DEFS e inserindo SHWIDE
TABELA 6.49	- Base = 'GRAVEL'

TABELA 6.50	- Base = 'CRSTONE'
TABELA 6.51	- Base = 'CEMENTD'
TABELA 6.52	- Base = 'LIMETD'
TABELA 6.53	- Capa = 'AC'
TABELA 6.54	- Capa = 'DST'
TABELA 6.55	- Capa = 'ACOVL'
TABELA 6.56	- Capa = 'DSTOVL'
TABELA 6.57	- SHSU = 'GRAV'
TABELA 6.58	- SHSU = 'SST'
TABELA 6.59	- Erro de treinamento 0,09
TABELA 6.60	- Erro de treinamento 0,045
TABELA 6.61	- Erro de treinamento 0,0045
TABELA 6.62	- Erro de treinamento 0,0009
TABELA 6.63	- Erro de verificação 0,20
TABELA 6.64	- Erro de verificação 0,30
TABELA 6.65	- Erro de verificação 0,40
TABELA 6.66	- Erro de verificação 0,50
TABELA 6.67	- Erro de verificação 0,60
TABELA 6.68	- Erro de verificação 0,70
TABELA 6.69	- Erro de verificação 0,80
TABELA 6.70	- Erro de verificação 0,90
TABELA 6.71	- 12 nós na camada oculta
TABELA 6.72	- 13 nós na camada oculta
TABELA 6.73	- 15 nós na camada oculta
TABELA 6.74	- 16 nós na camada oculta
TABELA 6.75	- 17 nós na camada oculta
TABELA 6.76	- 2 camadas ocultas (14,11)
TABELA 6.77	- 2 camadas ocultas (14,10)
TABELA 6.78	- 2 camadas ocultas (14,9)
TABELA 6.79	- 3 camadas ocultas (14,11,9)
TABELA 6.80	- Amostra menor

TABELA 6.81	-	Amostra maior
TABELA 6.82	-	Melhores casos de IGG
TABELA 6.83	-	Piores casos de IGG
TABELA 6.84	-	Solução inicial para QI
TABELA 6.85	-	Substituição de AGE0 por AGER
TABELA 6.86	-	Substituição de AGE0 por AGES
TABELA 6.87	-	Inserção de AGER
TABELA 6.88	-	Inserção de AGES
TABELA 6.89	-	Sem AGE0
TABELA 6.90	-	Inserção de NHX
TABELA 6.91	-	Inserção de NLV
TABELA 6.92	-	Inserção de NHX e NLV
TABELA 6.93	-	Inserção de PVL
TABELA 6.94	-	Inserção de PV2
TABELA 6.95	-	Inserção de PV4
TABELA 6.96	-	Inserção de PV5
TABELA 6.97	-	Inserção de PV6
TABELA 6.98	-	Inserção de PVL, PV2, PV4, PV5 e PV6
TABELA 6.99	-	Inserção de EPA2
TABELA 6.100	-	Inserção de EPA4
TABELA 6.101	-	Inserção de EPA2 e EPA4
TABELA 6.102	-	Inserção de SNA
TABELA 6.103	-	Inserção de SND
TABELA 6.104	-	Inserção de SNA e SND
TABELA 6.105	-	Sem SN
TABELA 6.106	-	Inserção de CP (sem MP)
TABELA 6.107	-	Inserção de WIDTH
TABELA 6.108	-	Inserção de SHWIDE
TABELA 6.109	-	Inserção de CRX
TABELA 6.110	-	Sem CR1
TABELA 6.111	-	Sem CR2

TABELA 6.112	- Sem CR3
TABELA 6.113	- Sem CR4
TABELA 6.114	- Sem CROC
TABELA 6.115	- Sem POT
TABELA 6.116	- Sem RAV
TABELA 6.117	- Sem SPAT
TABELA 6.118	- Sem RDMN
TABELA 6.119	- Sem MP
TABELA 6.120	- Sem SURF
TABELA 6.121	- Sem H1
TABELA 6.122	- Sem BASE
TABELA 6.123	- Sem SHSU
TABELA 6.124	- Sem DEFS
TABELA 6.125	- Sem RQI
TABELA 6.126	- Sem SGCBR
TABELA 6.127	- Nomes parametrizados
TABELA 6.128	- $RQI * 10$
TABELA 6.129	- $RQI * 5$
TABELA 6.130	- $RQI * 1,5$
TABELA 6.131	- Sem DEFS e inserindo SHWIDE
TABELA 6.132	- Base = 'GRAVEL'
TABELA 6.133	- Base = 'CRSTONE'
TABELA 6.134	- Base = 'CEMENTD'
TABELA 6.135	- Base = 'LIMETD'
TABELA 6.136	- Capa = 'AC'
TABELA 6.137	- Capa = 'DST'
TABELA 6.138	- Capa = 'ACOVL'
TABELA 6.139	- Capa = 'DSTOVL'
TABELA 6.140	- SHSU = 'GRAV'
TABELA 6.141	- SHSU = 'SST'
TABELA 6.142	- Erro de treinamento 0,09

TABELA 6.143	- Erro de treinamento 0,045
TABELA 6.144	- Erro de treinamento 0,0045
TABELA 6.145	- Erro de treinamento 0,0009
TABELA 6.146	- Erro de verificação 0,20
TABELA 6.147	- Erro de verificação 0,30
TABELA 6.148	- Erro de verificação 0,40
TABELA 6.149	- Erro de verificação 0,50
TABELA 6.150	- Erro de verificação 0,60
TABELA 6.151	- Erro de verificação 0,70
TABELA 6.152	- Erro de verificação 0,80
TABELA 6.153	- Erro de verificação 0,90
TABELA 6.154	- 12 nós na camada oculta
TABELA 6.155	- 13 nós na camada oculta
TABELA 6.156	- 15 nós na camada oculta
TABELA 6.157	- 16 nós na camada oculta
TABELA 6.158	- 17 nós na camada oculta
TABELA 6.159	- 2 camadas ocultas (14,11)
TABELA 6.160	- 2 camadas ocultas (14,10)
TABELA 6.161	- 2 camadas ocultas (14,9)
TABELA 6.162	- 3 camadas ocultas (14,11,9)
TABELA 6.163	- Amostra menor
TABELA 6.164	- Amostra maior
TABELA 6.165	- Melhores casos de QI
TABELA 6.166	- Piores casos de QI
TABELA 6.167	- Comparação de IGG com Irregularidade
TABELA 6.168	- Somatório com os piores casos
TABELA 6.169	- Somatório com os melhores casos
TABELA 7.1	- Variáveis para a camada de entrada
TABELA 7.2	- Variáveis para a camada de saída
TABELA 8.1	- Solução inicial para recuperação
TABELA 8.2	- Substituição de AGE0 por AGER

TABELA 8.3	- Substituição de AGE0 por AGES
TABELA 8.4	- Inserção de AGER
TABELA 8.5	- Inserção de AGES
TABELA 8.6	- Sem AGE0
TABELA 8.7	- Inserção de NHX
TABELA 8.8	- Inserção de NLV
TABELA 8.9	- Inserção de PVL
TABELA 8.10	- Inserção de PV2
TABELA 8.11	- Inserção de PV4
TABELA 8.12	- Inserção de PV5
TABELA 8.13	- Inserção de PV6
TABELA 8.14	- Inserção de NHX e NLV
TABELA 8.15	- Inserção de PVL, PV2, PV4, PV5 e PV6
TABELA 8.16	- Inserção de EPA2
TABELA 8.17	- Inserção de EPA4
TABELA 8.18	- Inserção de EPA2 e EPA4
TABELA 8.19	- Inserção de SNA
TABELA 8.20	- Inserção de SND
TABELA 8.21	- Sem SN
TABELA 8.22	- Inserção de WIDTH
TABELA 8.23	- Inserção de SHWIDE
TABELA 8.24	- Inserção de CRX
TABELA 8.25	- Sem CR1
TABELA 8.26	- Sem CR2
TABELA 8.27	- Sem CR3
TABELA 8.28	- Sem CR4
TABELA 8.29	- Sem CROC
TABELA 8.30	- Sem POT
TABELA 8.31	- Sem RAV
TABELA 8.32	- Sem SPAT
TABELA 8.33	- Sem RDMN

TABELA 8.34	- Sem MP
TABELA 8.35	- Sem SURF
TABELA 8.36	- Sem H1
TABELA 8.37	- Sem BASE
TABELA 8.38	- Sem SHSU
TABELA 8.39	- Sem DEFS
TABELA 8.40	- Sem RQI
TABELA 8.41	- Sem SGCBR
TABELA 8.42	- Base = 'GRAVEL'
TABELA 8.44	- Base = 'CRSTONE'
TABELA 8.45	- Capa = 'AC'
TABELA 8.46	- Capa = 'DST'
TABELA 8.47	- Capa = 'ACOVL'
TABELA 8.48	- Capa = 'DSTOVL'
TABELA 8.49	- SHSU = 'GRAV'
TABELA 8.50	- SHSU = 'SST'
TABELA 8.51	- Erro de treinamento 0,0045
TABELA 8.52	- Erro de treinamento 0,045
TABELA 8.53	- Erro de treinamento 0,09
TABELA 8.54	- Erro de verificação 0,20
TABELA 8.55	- Erro de verificação 0,30
TABELA 8.56	- Erro de verificação 0,40
TABELA 8.57	- Erro de verificação 0,50
TABELA 8.58	- Erro de verificação 0,60
TABELA 8.59	- Erro de verificação 0,70
TABELA 8.60	- Erro de verificação 0,80
TABELA 8.61	- Erro de verificação 0,90
TABELA 8.62	- 11 nós na camada oculta
TABELA 8.63	- 12 nós na camada oculta
TABELA 8.64	- 14 nós na camada oculta
TABELA 8.65	- 15 nós na camada oculta

TABELA 8.66	- 2 camadas ocultas (14,9)
TABELA 8.67	- 2 camadas ocultas (14,10)
TABELA 8.68	- 2 camadas ocultas (14,11)
TABELA 8.69	- 3 camadas ocultas (14,11,9)
TABELA 8.70	- Amostra menor
TABELA 8.71	- Amostra maior
TABELA 8.72	- Piores testes para projeto de restauração
TABELA 8.73	- Melhores testes para projeto de restauração
TABELA A.1	Conjunto de casos para treinamento
TABELA A.2	Conjunto de casos para reconhecimento
TABELA A.3	Resultado comparativo

LISTA DE ABREVIATURAS E SIGLAS

AASHTO	- American Association of State Highway and Transportation Officials
DNER	- Departamento Nacional de Estradas de Rodagem
IA	- Inteligência Artificial
MLP	- Multi Layer Perceptron
PICR	- Pesquisa do Inter-relacionamento dos Custos de Construção, Conservação e Utilização de Rodovias
RN	- Redes Neurais
IBM	- International Business Machines
SAS	- Statistical Analysis System
MIT	- Massachusetts Institute Technology
TRRL	- British Transport and Road Research Laboratory
LCPC	- Laboratoire Central des Ponts et Chaussées
SGP	- Sistemas de Gerência de Pavimentos
SAGP	- Sistema de Ajuda a Gerência de Pavimentos

Lista de Símbolos

AADT	-	Tráfego anual médio diário em ambas direções na data de observação
AADT1	-	AADT representativo na 1ª. data de observação
ACTION	-	Descrição da atividade de manutenção empreendida em uma data dada
AGE0	-	Idade do pavimento original na data de observação
AGEF	-	Idade da última superfície completa por selagem ou tratamento
AGER	-	Idade da última reabilitação por recape ou reconstrução
AGES	-	Idade da última superfície por selagem parcial ou total
BASE	-	Descrição do material da camada de base
CKPA	-	Área de remendos rompidos, em proporção a área da subseção
CP	-	Chuva acumulada na data de observação desde 01/01/76
CQ	-	Fator de Qualidade de Construção para tratamentos superficiais
CR1	-	Soma das áreas com trincamento de classe 1 ($< 1\text{ mm}$)
CR2	-	Soma das áreas com trincamento de classe 2 ($1\text{-}3\text{ mm}$)
CR3	-	Soma das áreas com trincamento de classe 3 ($> 3\text{ mm}$)
CR4	-	Soma das áreas com trincamento de classe 4 (usualmente 3 mm de largura e bordas desagregadas)
CROC	-	Soma de área de jacarés na subseção
CRX	-	Média ponderada de área de trincas por subseção para as classes de CR1 a CR4
CSLU	-	Área de aplicação de selante acumulada durante a fase de reabilitação até a data de observação
DATE	-	Data da observação na condição de vistoria
DEF	-	Deflexão de Viga Benkelman
DEFM	-	Deflexão representativa na seção (média das subseções para o período de estudo)

DEFPR	- Razão das deflexões de Benkelman na trilha de roda externa e interna
DEFS	- Deflexão ajustada para data e estação do clima
DIR	- Direção de tráfego
DPAT	- Soma de áreas de remendos fundos (base e capa) por subseção
DRG	- Codificação da condição de drenagem estimada
E0	- Razão média de medida de teor de umidade / mistura ótima (Proctor) do subleito
EPA1 a	
EPA6	- Número de eixos equivalentes, calculados com diferentes expoentes do fator de equivalência de operações
GRA GRB	- Média do gradiente longitudinal da seção
H0	- Espessura de capa atual
H1	- Espessura de capa no começo do estudo, média por seção
IM	- Índice de umidade Thornthwaite's
ISCBR	- CBR para amostras indeformadas do subleito para condições in situ
MAP	- Média anual de precipitação por seção
MP	- Precipitação mensal na data de observação
NHV	- Somatória de veículos pesados por faixa na data da observação, em milhões, desde a mais recente reabilitação
NHX	- Somatória de eixos de veículos pesados por faixa de observação, em milhões, desde a mais recente reabilitação, para veículos de classes 2,4,5 e 6
NVL	- Somatória de veículos leves < 3500 Kg, em milhões, na data de observação
PDF	- Fator de precipitação de chuva
POT	- Soma de áreas de painéis abertas na data da observação
PSTA	- Identificação da estação de chuva
PV2, PV4,	
PV5, PV6	- Frações de eixos acumulados por categoria, desde a mais recente reabilitação

PVL	-	Fração do tráfego anual composta por veículos leves
PVLI	-	Valor de PVL, na primeira data da observação
RAV	-	Soma das áreas de desagregação (ou desgaste) em relação à área de observação (em porcentagem)
RDMN	-	Média de afundamento de trilhas
RDSO	-	Desvio padrão de RDMN
RHA	-	Tipo de ação de reabilitação
RHT	-	Identificação da reabilitação
RQI	-	Irregularidade da seção na data de observação
RSA	-	Tipo de ação de recapeamento
RSF	-	Identificação do recapamento
RST	-	Identificação de total ou parcial fase de recape
SEC	-	Identificação do trecho de teste de pavimento
SF	-	Categorias de tratamentos da superfície
SGCBR	-	CBR com Proctor modificado
SGDEP	-	Profundidade da superfície até o subleito
SHSU	-	Superfície do acostamento
SHWIDE	-	Largura do acostamento
SN	-	Número estrutural do pavimento
SNSD	-	Desvio padrão do SN nos três pontos da seção
SNISD	-	Desvio padrão do SNC nos três pontos da seção
SNA	-	Numero estrutural na data da observação, com seção reabilitada
SNC	-	Numero estrutural corrigido, na data da observação
SND	-	Número estrutural corrigido, ajustado pela deflexão local
SNS	-	SNC sazonal na data da observação
SPAT	-	Soma de áreas de remendos em relação a área da seção
SUBS	-	Identificação das seções COM com rotinas de manutenção e SEM sem rotinas de manutenção só fechamento de painelas
SURF	-	Descrição do tipo de capa na primeira data de observação
WIDTH	-	Largura da capa sem os acostamentos
YE41CC		

YE4ISD	-	Número anual de eixos equivalentes
YR	-	Data da observação
YRCON	-	Ano de construção
YROVL	-	Ano da primeira reabilitação

RESUMO

BREGA, J. R. F. *A utilização de redes neurais artificiais em um sistema de gerência de pavimentos*. São Carlos, 1996. 234p. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo.

Esta tese apresenta o estudo para utilização de Redes Neurais Artificiais para avaliar o estado do pavimento e apoiar as decisões dentro de um Sistema de Gerência de Pavimentos. É apresentado um método para a avaliação da condição em pavimentos flexíveis, utilizando redes neurais MLP backpropagation. Neste caso para a extração das características dos pavimentos são utilizados dois métodos muito empregados pelos órgãos rodoviários: o "Índice de Gravidade Global" e a "irregularidade". Os experimentos demonstraram que as redes neurais simulam satisfatoriamente o estado dos pavimentos. Para se verificar a possibilidade de utilização em outros problemas, o processo foi empregado para o projeto de restauração de pavimentos flexíveis. Foi utilizada a DNER-PRO 159/85 para a extração das características dos pavimentos. Os experimentos demonstraram que as redes neurais também simulam convenientemente as características do pavimento. Como exemplo de ferramenta de apoio à gerência foi desenvolvido um protótipo computacional em ambiente gráfico, onde o critério de decisão baseia-se nas redes neurais estudadas. São descritas todas as suas funções e forma de funcionamento.

Palavras-chave: sistemas de gerência de pavimentos, redes neurais artificiais.

ABSTRACT

BREGA, J. R. F. *Use of artificial neural networks in a management pavement system*. São Carlos, 1996. 234p. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo

A study of artificial neural networks for evaluating the pavement condition and for supporting decisions within a Pavement Management System is presented. The method for condition evaluation of flexible pavements using the MLP backpropagation technique is described. Two of the most used procedures for detecting the pavement conditions were applied: the “overall severity index” (Brazilian IGG) and the “irregularity index”. The experiments demonstrated that the neural networks satisfactorily simulated the state of the pavement. In order to test the applications in other problems, the method was used for pavement overlay design through neural network, using the same MLP backpropagation technique. For detecting the pavement conditions the DNER-PRO 159/85 was applied. Tests with the model also demonstrated that the neural networks appropriately simulate the pavement characteristics. A computational prototype developed in a graphical computer environment, where the decision criteria are based on the neural networks studied, is presented as an example. All the functions and working details of such prototype are described.

Keywords: management pavement system, artificial neural networks

CAPÍTULO 1

INTRODUÇÃO

1.1. Motivação

A necessidade de um processo racional para a programação de investimentos para manutenção e recuperação de rodovias decorre da extensão da rede e da deterioração contínua a que o pavimento é submetido. Os sistemas que organizam as informações sobre a rede e fornecem aos órgãos de gestão as estratégias de ataque aos problemas de manutenção, planejamento, construção e projeto são chamados de Sistemas de Gerência de Pavimentos.

Os sistemas em uso atualmente foram idealizados há algum tempo, e foram projetados de forma a serem aperfeiçoados pelos organismos rodoviários, a medida que isto se fizesse necessário. A melhoria nos sistemas de gerência de pavimentos poderia estar ligada a utilização de novas técnicas não disponíveis naquele período de implantação.

Existem problemas na utilização destes sistemas, como por exemplo:

- A grande quantidade de técnicas existentes para a avaliação da condição do pavimento, uma vez que os resultados obtidos a partir da aplicação de cada uma delas podem não coincidir, dificultando o julgamento.
- A adoção da estratégia de manutenção adequada para a rede viária.

Para resolver estes problemas existem atualmente muitos sistemas que, baseados no fator custo, auxiliam o Engenheiro de Pavimentos na escolha dos critérios de decisão para a obtenção da melhoria da condição de um pavimento.

Para a adequada utilização desses sistemas, muitos dos quais atualmente automatizados, é necessária uma grande quantidade de informações. Soma-se a isso o fato dos recursos disponíveis não acompanharem o crescimento da malha rodoviária.

Portanto, a busca por abordagens onde se obtenha um melhor aproveitamento dos recursos é bem-vinda, e deve ser incentivada (HUDSON e HASS 1994). Normalmente novas abordagens necessitam de mais recursos computacionais para serem adequadamente implementadas.

Esta necessidade de aumento na capacidade de processamento leva à pesquisa de novas tecnologias, com o objetivo de conseguir um sistema de gerência mais simples e mais eficiente, com menor quantidade de dados coletados.

Por outro lado, tem-se a grande evolução da Informática permitindo acesso a equipamentos com razoável capacidade de processamento, associado às facilidades de comunicação, permitindo o emprego de técnicas matemáticas mais sofisticadas e facilitando sua operação pelos engenheiros rodoviários, a custo mais baixo.

Essa maior capacidade de processamento, integrada com diversos centros de dados, pode ser utilizada facilitando a visualização, com o emprego de algumas ferramentas de auxílio baseadas em Sistemas de Informação Geográficas. Atualmente, estes sistemas são muito exigentes quanto a coordenadas, o que dificulta o cadastramento, e portanto a agilidade de operação.

1.2. Objetivos

Os principais objetivos deste trabalho são os seguintes:

- Verificar a possibilidade de utilização de nova técnica matemática, no caso as redes neurais artificiais ou simplesmente redes neurais (RN), para um melhor

reconhecimento e classificação das características do pavimento que influenciam no problema de gerência de pavimentos. Estas novas técnicas permitiriam também selecionar as principais variáveis relacionadas ao problema, tais como: idade, composição, estrutura e utilização.

- Testar uma forma alternativa para o projeto de restauração em pavimentos baseada nas redes neurais.
- Propor a união desta técnica de redes neurais com uma base de dados gráfica, resultando um sistema mais simples.
- Desenvolver um sistema simples que faz a associação de mapas com os dados coletados por peritos de pavimentação, que possa ser utilizado como uma ferramenta de decisão ou de apoio ao ensino.

1.3. Organização do Trabalho

O trabalho está dividido nos capítulos descritos a seguir.

O Capítulo 2 apresenta a definição de sistemas de gerência de pavimentos, seus problemas principais, os elementos envolvidos e os conceitos que serão utilizados no decorrer do trabalho.

No terceiro capítulo é apresentada uma visão geral das redes neurais artificiais e seu funcionamento.

No Capítulo 4 são descritos os dados de entrada utilizados na composição do conhecimento e no treinamento da RN. É apresentado um glossário de variáveis utilizadas neste trabalho.

São descritas no Capítulo 5: a modelagem dos dados do Capítulo 4, para a sua utilização dentro da técnica de redes neurais para o problema da avaliação da condição do pavimento; as variáveis iniciais introduzidas; a escolha da forma de treinamento e outras dificuldades relacionadas.

No Capítulo 6 são apresentados os resultados da avaliação da condição dos pavimentos, obtidos através da nova técnica com o conhecimento do Índice de

Gravidade Global (IGG) e a irregularidade. É apresentada, também, uma análise paramétrica com as variáveis passíveis de composição.

Como outra aplicação da técnica de redes neurais é descrita, no Capítulo 7, a modelagem dos dados do Capítulo 4, para a sua utilização no problema da estratégia de recuperação de trechos. Como para a avaliação da condição são mostradas: as variáveis iniciais introduzidas; a escolha da forma de treinamento e outras dificuldades relacionadas.

Os resultados de um projeto de restauração são mostrados no Capítulo 8, bem como a análise paramétrica das variáveis relacionadas.

Para mostrar a utilidade dos procedimentos elaborados, no Capítulo 9, é apresentado um protótipo de um sistema que faz a associação das redes neurais geradas com um banco de dados gráfico.

No Capítulo 10 são apresentadas as considerações finais, com as principais conclusões e sugestões para a continuidade deste trabalho.

CAPÍTULO 2

SISTEMAS DE GERÊNCIA DE PAVIMENTOS

Com a finalidade de apresentar o contexto em que este trabalho está inserido, são expostos neste capítulo: uma definição de sistemas de gerenciamento de pavimentos e suas partes constituintes. Devido a grande quantidade de procedimentos envolvidos são destacados dois: a avaliação da condição do pavimento e o projeto de recuperação de trechos.

2.1. Introdução

Segundo DOMINGUES (1993a), o Brasil possui mais de 1 milhão e 500 mil quilômetros de estradas, dos quais 260 mil quilômetros pavimentadas. Estas rodovias representam um patrimônio de mais de 15 bilhões de dólares.

Devido ao fato deste patrimônio ser muito valioso e como a rede viária tem crescido em uma velocidade maior que os recursos disponíveis para a sua manutenção, surgiu o interesse em se desenvolver gerências de pavimentos, dentro dos organismos rodoviários responsáveis. Estas gerências, por sua vez, começaram a

buscar soluções que trouxessem benefício para um conjunto maior de usuários (PETERSON 1987).

Segundo HAAS e HUDSON (1978) este estudo foi iniciado a partir da pesquisa da American Association of State Highway Officials (AASHO), realizada em Ottawa Illinois durante o período de 1958 até 1961. Esta pesquisa foi chamada de *AASHO Road Test*, e teve como finalidade obter subsídios para novos métodos de projeto e construção.

PETERSON (1987) afirma que em 1966, a AASHO através da *National Cooperative Highway Research Program* iniciou um estudo para projeto de pavimentos. Os esforços envolveram a aproximação sistemática entre projeto, construção e manutenção.

Esforços semelhantes foram desenvolvidos no Canadá e Texas. Nesta época, final dos anos 60 e início dos anos 70, surgiu o termo Sistemas de Gerência de Pavimentos (SGP) para descrever o conjunto inteiro de atividades envolvidas em prover pavimentos.

Um SGP coordena as atividades necessárias para planejar, projetar, construir e manter pavimentos, para que o público usuário seja servido de maneira segura, eficiente e econômica. Este controle, efetuado por um órgão responsável em uma malha rodoviária, indica os trechos prioritários para aplicação dos recursos disponíveis para manutenção ou de investimento (QUEIROZ et al 1994).

Segundo HUDSON e HAAS (1984), estes SGPs tiveram um significativa taxa de implantação a partir dos anos 80, com previsão de um crescimento ainda maior para o ano 2000.

Como estes sistemas são projetados para funcionar de forma iterativa, onde os resultados obtidos podem ser utilizados para se considerar novas estratégias alternativas, conclui-se que os SGP devem ser flexíveis e mutáveis.

O método empregado indica que a estrada não pode ser analisada isoladamente, sendo necessário o estudo de toda a malha gerenciada por um determinado órgão. Este processo de trabalho utiliza, portanto, uma metodologia sistêmica.

Segundo QUEIROZ (1994), estes sistemas dependem do pessoal envolvido, quanto mais sofisticados forem os métodos maior será a necessidade material. Para se implementar um SGP deve-se considerar 3 etapas:

Etapa 1: Pré-implementação, onde são revistos os métodos dos procedimentos existentes e é elaborado um plano de implementação;

Etapa 2: Implementação do banco de dados, onde é introduzido um mecanismo de coleta e realizado o cadastramento dos dados; e

Etapa 3: Implementação das estratégias e técnicas de otimização dos recursos. onde devem ser empregadas ferramentas computacionais desenvolvidas para este fim.

QUEIROZ (1994) avalia que a primeira etapa é essencial para o sucesso da implantação. Para o desenvolvimento do plano de implementação são fundamentais estudos realizados pelo órgãos rodoviários. Devem ser feitos cursos, seminários, palestras e etc., pelos gerentes e pelo pessoal técnico.

A implantação do SGP é altamente dependente da organização que o elaborou e onde será utilizado. Um SGP deve conter quatro subsistemas:

- Subsistema de Informação: contém os dados da estrada, tráfego e custos. Deve ser sempre atualizado, com dados coletados pelo órgão responsável.
- Subsistema de Estratégia de Manutenção: deve ser capaz de simular o ciclo de vida e o custo total para os vários tipos de estradas componentes da malha local. Deve permitir novas ligações e determinar as necessidades atuais e futuras.
- Subsistema de Otimização: é responsável por encontrar a melhor alternativa para a quantidade de recursos disponíveis.
- Subsistema de Relatórios: deve ser capaz de informar aos engenheiros sobre o estado da rede e programas prioritários.

Portanto pela forma de implantação e pela estrutura que o SGP deve possuir, tem-se que as principais tarefas são:

- a) Avaliação periódica dos pavimentos, que será utilizada para fornecer dados para o subsistema de informação;
- b) Estimativa das condições futuras, utilizando para isso modelos de previsão de desempenho;
- c) Determinação da época e estratégia de manutenção mais oportuna; e
- d) Preparação de programas de manutenção e novas pavimentações em função dos recursos disponíveis.

Como se pode observar a avaliação da condição dos pavimentos da rede é o ponto inicial de qualquer SGP, sendo que a partir dela é que se definem todas as políticas para utilização de recursos.

O segundo ponto importante é a estimativa das condições futuras, e para isso QUEIROZ (1984) desenvolveu extensa pesquisa de campo para quantificar o comportamento dos pavimentos. Este comportamento pode ser previsto com a utilização de regressões matemáticas. Estimando a condição futura é possível definir qual estratégia tomar com o objetivo de melhorar a condição do pavimento.

Para um melhor entendimento destes dois pontos importantes, a avaliação da condição do pavimento e as estratégias de manutenção possíveis, estes são analisados a seguir.

2.2. Avaliação da Condição de um Pavimento

2.2.1. Introdução

A avaliação da condição do pavimento é o problema central da gerência de pavimentos. Isto porque é muito importante que os projetistas e pessoal ligados a manutenção considerem a condição do pavimento em suas atividades (HAAS e HUDSON 1978).

Esta avaliação pode contemplar diversos aspectos do pavimento, podendo ser analisado o conforto, a capacidade de carga, a segurança e a estética. O resultado obtido é a união dos fatores e seria comum tanto aos engenheiros quanto aos usuários.

Para se proceder a avaliação é necessário o conceito de serventia, que é a capacidade de um trecho específico de pavimentos proporcionar, na opinião do usuário, rolamento suave e confortável em determinado momento para quaisquer condições de tráfego.

A forma original de obtenção, que foi desenvolvida durante o teste *AASHO Road Test*, é subjetiva: um grupo de avaliadores treinados percorre o trecho em um veículo com velocidade determinada e atribui um conceito (de 0 até 5), que será transformado em uma categoria (de Péssimo a Ótimo).

Sendo uma forma subjetiva, e de execução impraticável, começou-se a procurar soluções onde esta avaliação poderia ser feita através de outros processos mais objetivos.

A serventia passou a ser medida de diversas formas, como cálculo de porcentagens de vida através dos seus defeitos; geração de índices, calculados em função de outros dados; e até o desenvolvimento de equipamentos ou processos para obtenção de medidas relacionadas a serventia.

A avaliação pode ser obtida de diversas formas. Estas podem variar até dentro de um mesmo país. A obtenção desta avaliação pode estar relacionada diretamente a alguns defeitos da estrutura, ou a funcionalidade de um trecho.

No Brasil são muito utilizados, pelos órgãos rodoviários, o Índice de Gravidade Global (IGG), calculado em função da medida dos defeitos da estrutura; e a Irregularidade, que mede a funcionalidade da via. Os motivos são a aparente simplicidade de execução e o baixo custo.

2.2.2. O Índice de Gravidade Global

O Índice de Gravidade Global (IGG) avalia objetivamente a superfície de pavimentos, utilizando a contagem e a classificação de ocorrências aparentes, e a medida das deformações nas trilhas de roda. Segundo HAAS e HUDSON (1978) este tipo de índice, calculado em função de vários parâmetros, pode ser utilizado para classificar as estradas.

O IGG pode ser obtido segundo o procedimento de norma DNER PRO 008-94. Este foi elaborado a partir de um método apresentado por PEREIRA (1972) chamado Método de Avaliação de Pavimentos Flexíveis e Semi-Rígidos. Segundo FORTES (1994), este método foi a primeira tentativa de se correlacionar dados do Brasil com a serventia adotada em outros países.

Dependendo da rodovia a ser analisada, é definida uma área para estudo, e são anotados todos os defeitos existentes. São considerados os seguintes defeitos: as fissuras, as trincas isoladas ou interligadas, os afundamentos plásticos ou de consolidação, as corrugações ou ondulações, os escorregamentos, as exsudações, a desagregação do revestimento, as panelas e os remendos existentes. Além dos defeitos, são medidos também, os afundamentos das trilhas de roda interna e externa.

São calculados, inicialmente, as frequências de ocorrência de cada defeito, e após isto, estes defeitos são ponderados com pesos definidos para cada ocorrência, levando em consideração a média das trilhas de roda externa e interna. Obtém-se, então, o Índice de Gravidade Individual (IGI) para cada defeito.

Estes IGI's são somados, conseguindo-se um índice final (IGG) que indica o estado daquele pavimento. Este índice final pode variar de 0 a 500, com valores aumentando segundo o grau de deterioração do pavimento. Portanto, quanto maior o valor menor a serventia.

Dependendo do IGG obtido, a norma associa ao índice um conceito que retrata o grau de deterioração atingido. Os limites de IGG são : de 0 a 20 (bom), de 20 a 80 (regular), de 80 a 150 (mau) e de (150 a 500) péssimo.

Para se conseguir uma melhor padronização de classificação foi utilizado neste trabalho a divisão em cinco conjuntos. Segundo FORTES (1994) apud

BOTTURA (1989) são aconselhados os seguintes limites: 0 a 10 para ótimo, 10 a 30 para bom, 30 a 80 para regular, 80 a 150 para ruim e 150 a 500 para péssimo.

2.2.3. A Irregularidade

Segundo a DNER PRO 007-94, outra forma de se avaliar um pavimento é através da definição subjetiva do conceito de serventia, mas como esta medida é impraticável, passou-se a medir outro parâmetro, a irregularidade.

A irregularidade já era conhecida desde o *AASHO Road Test* (HAAS e HUDSON 1978) e é definida por DOMINGUES (1993a) como: “o conjunto dos desvios da sua superfície, ao longo das trilhas de roda, em relação à superfície ideal projetada, com características tais que, afetam o movimento dos veículos, a qualidade do rolamento, as cargas dinâmicas que atuam sobre a via e, a drenagem da superfície”.

De acordo com QUEIROZ (1984), a serventia de um pavimento depende, em grande parte, de sua irregularidade, e segundo AUTRET et al. (1991) é possível obter a serventia, através dos valores da irregularidade.

Existem diversos equipamentos de campo que medem a irregularidade, e por este motivo, existem diversas escalas padronizadas. Uma escala muito utilizada é o *QI quarter-car index*, denominada no Brasil de quociente de irregularidade, expressa em contagens por quilômetro.

O modo de obtenção dos valores de irregularidade depende do equipamento. Um processo para a obtenção destes valores, sem equipamentos, é o Método de Nível e Mira (DNER-PRO 164/94 (1994)), desenvolvido por QUEIROZ (1984). Este processo obtém bons resultados, mas a produtividade é baixa.

Outros métodos permitem uma maior produtividade, a maioria utilizando equipamentos do tipo resposta. O *Maysmeter* e o Integrador do IPR - USP são exemplos disso. Estes equipamentos, na sua maioria, são montados sobre estruturas veiculares e, portanto, sujeitas a alteração nos resultados, de acordo com o desgaste dos veículos.

Estes equipamentos geralmente são constituídos de três partes principais: um sensor, que mede o movimento do eixo traseiro em relação ao chassi; um odômetro, para medir a distância percorrida; e uma unidade acumuladora, que combina as duas informações, indicando o resultado para uma distância percorrida.

Para evitar a variação nos resultados, os veículos equipados com aparelhos deste tipo, podem ser calibrados com trechos levantados através do método de nível e mira.

Um outro equipamento utilizado para obtenção da irregularidade é o Perfilômetro Dinâmico. Este permite, além da obtenção do QI, o perfil das rodovias por onde trafega. A obtenção deste perfil está ligada, diretamente, a introdução de outros elementos de leitura no veículo. Por este motivo, seu custo é maior. Também é muito utilizado para levantar trechos de calibração de *Maysmeters*. Em sua pesquisa, QUEIROZ (1984) utilizou o perfilômetro para fazer a calibração e o *Maysmeter* para levantar as irregularidades dos trechos.

Juntamente com este levantamento foi desenvolvido o método de nível e mira, normalizado posteriormente pelo DNER. Para o mesmo trecho de calibração foram utilizados o perfilômetro e o levantamento topográfico, obtendo-se a relação entre eles.

2.3. Estratégia de Manutenção

Outro problema importante para ser resolvido pelos SGPs, é a estratégia de manutenção. Existem diversas formas de se encontrar esta estratégia. A nível de rede poderiam ser utilizadas ferramentas computacionais existentes, do tipo do HDM III. Para um trecho isolado a solução mais simples seria analisar os serviços através de normas como a DNER-PRO 159/85.

2.3.1. O Modelo HDM III

Um SGP, sendo um sistema integrado, necessita de muitos dados para o seu funcionamento. Estes dados fazem parte de um subsistema de informações e foram cadastrados a partir dos levantamentos realizados na etapa de implementação dos bancos de dados.

Ao final da etapa de implementação, passa-se ao estudo ou análise com uso de modelos prontos, tais como o HDM - III (*Highway Design and Maintenance Standards Model*) (WATANADA 1987).

Este e outros modelos tentam resolver problemas ao nível de rede, obtendo: o custo final para o contribuinte, o elenco de prioridades, o tempo em que a manutenção pode ser negligenciada sem prejuízo, a alteração no tipo de pavimento para encontrar novas soluções e o benefício obtido em função dos recursos investidos na manutenção.

Os problemas acima não são atuais. O Banco Mundial iniciou em 1969, um programa para desenvolver um método de análise econômica das normas e investimentos rodoviário, capaz de fornecer os custos e benefícios ao longo da vida útil da rodovia.

Este estudo foi chamado de HDMSS (Estudo das Normas de Projeto e Manutenção de Rodovias), e estabeleceu uma nova metodologia, capaz de quantificar e analisar diferentes opções e, dessa forma, determinar as prioridades técnico-econômicas.

O estudo se estendeu até 1971, desenvolveu a estrutura conceitual e criou um primeiro protótipo. Nesta primeira fase, da qual participaram o MIT, o TRRL, o LCPC e o Banco Mundial, só foram colocados dados do *AASHO Road Test*.

Nos anos seguintes foram pesquisados outros tipos de pavimentos sob as mais diversas condições, conforme será descrito a seguir.

Uma segunda etapa foi realizada no Kenya, de 1971 a 1975, estudando o custo operacional dos veículos. De 1977 até 1982, no Caribe, foram também estudados os custos operacionais dos veículos e de 1977 até 1983, na Índia.

No Brasil, este estudo, foi realizado de 1975 até 1982 pelo GEIPOT. Os modelos resultantes foram incorporados à terceira versão do HDM, sendo lançada a versão HDM III em 1987. O sistema computacional para microcomputadores foi lançado em 1989.

Segundo HUDSON e FERNANDES JR. (1994), o sistema possui, em suas rotinas de programação, as seguintes diretrizes para a análise dos dados:

1) As normas de construção e manutenção são estabelecidas em função de requisitos estruturais, níveis de serviço para os usuários e níveis orçamentários (que seguem, geralmente, tendências históricas). Este tipo de procedimento é chamado metodologia condição-ação.

2) Uma outra forma é a metodologia orientada por crises, onde as rodovias são operadas com pouca ou nenhuma manutenção, até que ocorra um estado de deterioração, que obstrua ou interrompa o tráfego. Então, são feitos onerosos trabalhos de restauração e reconstrução, sob programas especiais de financiamento.

3) Existe, ainda a forma econômica ou metodologia da eficiência técnico-econômica, onde as normas são selecionadas para minimizar os custos do transporte rodoviário. É avaliado o benefício líquido final, considerando-se os gastos e retornos aplicados no projeto e suas alternativas. O custo é composto por cinco parcelas, que interagem entre si: construção, manutenção de rotina, operação do sistema (gerenciamento do tráfego, segurança), usuários (operação dos veículos, atrasos) e sociedade (poluição ambiental, custo social dos acidentes).

O modelo HDM atende os requisitos anteriores, ele não é só um programa capaz de realizar extensos cálculos, mas também é o resultado da mais extensa pesquisa empírica sobre os custos da modalidade rodoviária. O modelo compara estimativas de custos e faz avaliações econômicas de diferentes alternativas de construção e manutenção, incluindo diferentes estratégias de intervenções ao longo do tempo, seja para um determinado projeto ou para um grupo de ligações.

O modelo possui deficiências, como exemplo, não inclui tráfego sob condição de congestionamento, não inclui pavimentos rígidos, não inclui condições de congelamento, não pode ser alterada a manutenção de rotina, os custos dos acidentes e impactos ambientais são estimados fora do programa. Outro problema é a

utilização com outros dados, sendo que para isto, alguns ajustes devem ser feitos de forma a levar em consideração as diferenças sócio-econômicas e o desenvolvimento da tecnologia rodoviária.

2.3.2. A DNER PRO 159/85

A norma DNER PRO 159/85 define um procedimento a ser utilizado no projeto de restauração de pavimentos flexíveis e semi-rígidos, apresentando diferentes alternativas.

Inicialmente é feito um levantamento junto aos órgãos rodoviários do pavimento existente, como a data de entrega ao tráfego, informações do projeto, histórico do tráfego e outros dados que se julgar procedentes. Feito isso, é necessário um levantamento de campo, onde são coletados os dados de trechos, tais como: deflexões recuperáveis, trincamentos, irregularidade, sondagens para coleta de amostras.

A seguir, são feitos ensaios de laboratório para a obtenção do CBR e do módulo de resiliência.

Os trechos devem ser divididos em subtrechos homogêneos, ou seja, os que apresentam valores semelhantes da constituição do pavimento, do tráfego médio diário (TMD) e valores da deflexão recuperável. Analisam-se os valores de trincamento e irregularidade, eliminando-se os dados que estão em limites definidos. A maior extensão para um subtrecho homogêneo deve ser de 3000 metros.

Para cada subtrecho homogêneo devem ser obtidos, através de medições e ensaios, os seguintes parâmetros:

- Idade do Pavimento;
- Tipo e espessura do pavimento existente;
- Deflexão característica;
- Trincamento;
- Desagregação;
- Irregularidade; e

- Número estrutural corrigido.

Devem ser estabelecidos parâmetros de projeto, tais como:

- Período de análise;
- Taxa de crescimento de tráfego;
- Tráfego;
- Restrições de construção;
- Restrições de desempenho;
- Restrições econômicas; e
- Custos unitários de restauração.

A norma apresenta um conjunto de equações, com previsão de desempenho para: a irregularidade, o trincamento e a desagregação. Esta previsão pode ser feita para pavimentos recobertos com lama asfáltica, tratamento superficial duplo e concreto asfáltico.

É feita uma análise do pavimento existente, onde são possíveis três situações:

- (I) Não são atingidos os valores limites das restrições, então, com equações de desempenho são previstos trincamento, irregularidade e desagregação (se for o caso de TSD), para o último ano da análise. Caso não sejam atingidos os valores limites, não haverá necessidade de restauração do pavimento.
- (II) Quaisquer valores de restrições podem ser alcançados ao longo do período da análise. Deve-se determinar o ano que acontece a ultrapassagem do valor previsto pelo limitante. A partir deste ano deve-se proceder a alternativa de restauração.
- (III) Quaisquer valores de restrições podem ser ultrapassados no início do período da análise, portanto é necessária atividade imediata da restauração.

As alternativas de restauração devem ser analisadas, da mais simples e barata, para a mais custosa. Partindo-se da lama asfáltica, depois tratamento superficial duplo e a seguir recuperação em concreto asfáltico. Encontrando-se a alternativa viável, com a verificação das restrições de desempenho e de construção para período de análise, esta será mais econômica.

CAPÍTULO 3

REDES NEURAIS

3.1. Introdução

Desde o aparecimento do computador os seres humanos questionam-se sobre a possibilidade destas máquinas poderem pensar. Estudos das atividades, onde as máquinas poderão trabalhar e pensar melhor que os homens, continuam sendo desenvolvidos. O ramo da Ciência da Computação que trata este problema é chamado Inteligência Artificial (IA).

Tomando como base a inteligência humana, a IA como ciência, dividiu-se em duas linhas de pesquisa: a linha simbólica onde são colocados em prática os estudos em psicologia, baseadas na lógica, e a linha conexionista que visa a modelagem da inteligência humana através da simulação dos componentes do cérebro.

A parte ligada à psicologia estuda como o ser humano poderia pensar, como seria possível a representação de objetos dentro do cérebro humano. Segundo FILHO et al (1994) Marvin Minsky, já por volta de 1966, estudava formas de representação do conhecimento, com o intuito de implementar os mesmos processos em robôs, que seriam as novas máquinas inteligentes.

Até os dias atuais pesquisas neste sentido estão sendo feitas, como nos jogos de xadrez, e outros onde existe um processo de transformação do conhecimento por um especialista e este indica como a máquina deve proceder. A inteligência artificial então, neste caso, é uma forma de pensamento de um ou mais profissionais que elaboraram o processo.

Com relação à linha conexionista uma das técnicas mais representativas é a das redes neurais (RN). Estas são biologicamente inspiradas na medida em que são formadas por unidades que imitam as mais elementares funções do neurônio biológico. Estas unidades são organizadas, na maioria das vezes, com base na anatomia do cérebro. O problema é que o conhecimento atual sobre o funcionamento do cérebro é tão restrito que fica muito difícil emular o seu comportamento. Em muitos casos, torna-se necessário descartar a plausibilidade biológica, fazendo do cérebro uma metáfora e construindo modelos organicamente não prováveis à luz dos conhecimentos correntes. Apesar desta semelhança superficial, redes neurais exibem um surpreendente número de propriedades típicas do cérebro. Por exemplo, elas aprendem a partir da experiência, generalizam novos exemplos a partir de exemplos prévios e abstraem-se de características de entradas contendo dados irrelevantes.

O estudo de redes neurais pode ser dirigido a três grupos de atividades, que são: modelagem, aplicações e implementações. O processo de modelagem de redes neurais abrange três níveis: neurônio, arquitetura e algoritmo de aprendizagem. O neurônio (também conhecido como unidade de processamento, nó ou processador) estabelece a unidade computacional básica da rede. A arquitetura (ou topologia) define a estrutura de conexões entre os neurônios. O algoritmo de aprendizagem descreve um método para alterar o estado individual dos neurônios e as conexões entre eles, objetivando atingir um comportamento global para a rede.

As principais características que tornam os métodos de RN interessantes do ponto de vista para a solução de problemas são segundo BITTENCOURT (1996) as seguintes:

- Capacidade de “aprender” através de exemplos e de generalizar este aprendizado de maneira a reconhecer instâncias similares que nunca haviam sido apresentadas como exemplo;
- Bom desempenho em tarefas mal definidas, onde falta conhecimento explícito sobre como encontrar uma solução;
- Não requer conhecimento a respeito de eventuais modelos matemáticos dos domínios de aplicação; e
- Elevada imunidade ao ruído, isto é, o desempenho de uma rede neural não entra em colapso em presença de informações falsas ou ausentes, como é para o caso de programas convencionais, mas piora de maneira gradativa.

3.2. Uma Breve Visão Sobre Redes Neurais

Para um melhor entendimento desta linha de IA é interessante conhecer-se uma definição de RN. Dentre as várias definições existentes destaca-se como uma das mais consagradas a de HECHT-NIELSEN (1989).

“Uma rede neural artificial é uma estrutura de processamento de informação distribuída e paralela, consistindo de unidades de processamento (que podem processar uma memória local e transportar operações de processamento de informação localizada) interconectadas através de canais de comunicação de sinais unidirecionais. Cada unidade de processamento tem uma única conexão de saída com capacidade de se ramificar em tantas conexões colaterais quantas forem desejadas (cada qual transportando o mesmo sinal - o sinal de saída da unidade de processamento). O sinal de saída da unidade de processamento pode ser de um tipo matemático qualquer. Todo o processamento que se dá em cada unidade de processamento deve ser completamente local, isto é, deve depender apenas dos valores correntes do sinal de entrada que chega através das conexões de entrada e dos valores locais armazenados na unidade de processamento.”

Grande parte dos modelos de redes neurais têm seus neurônios divididos em subconjuntos denominados camadas ou campos, definindo-se desta

forma a arquitetura da rede. Nos tópicos subsequentes os conceitos de neurônios, arquitetura e aprendizagem serão vistos.

3.2.1. Neurônio Biológico e o Artificial

Não se compreende completamente como funcionam todos os processos envolvidos no sistema nervoso e será ainda necessário muita investigação para se concluir como o modelo natural funciona. Entretanto um modelo simplificado, baseado no mecanismo fundamental, pode ser adotado (HAYKIN 1994). O neurônio, célula básica do cérebro, com as seguintes estruturas: soma, dendritos e axônio, representados na FIGURA 3.1.

FIGURA 3.1: Esquema de um neurônio biológico

Como pode ser observado pela figura anterior, o corpo da célula possui diversas ramificações chamadas dendritos, que são responsáveis por levar a informação para a célula. Neste mesmo corpo existe um filamento comprido que é o axônio. Este, em sua extremidade, possui uma ramificação que pode ser chamada de arborização axonal. Suas extremidades são chamadas de terminais.

Os terminais de um neurônio estão situados próximos a dendritos de outros neurônios. A ligação ou conexão entre os neurônios é feita quimicamente e é chamada de sinapse. No corpo humano estas ligações são específicas e não mudam com o tempo.

O axônio transmite em ambas as direções, mas o fluxo de informações parte dos dendritos para o axônio. Chegam várias informações para o corpo da célula, onde é feita uma análise da entrada, e a partir desta pode-se gerar um outro estímulo para o axônio. Pode-se entender o processo como uma somatória de impulsos que chega ao corpo: se esta somatória for maior que um determinado valor produz-se estímulo para os próximos axiônios.

FIGURA 3.2: Estrutura básica de um neurônio artificial

Uma representação (modelo artificial) simplificada para o neurônio biológico, como mostrada na FIGURA 3.2, seria uma unidade que computa a função limiar, uma unidade de processamento que coleta suas entradas e produz uma saída apenas se a soma das entradas exceder um valor de limiar interno. Assim como uma unidade de processamento tipo limiar, o neurônio biológico coleta sinais em suas sinapses e o soma computa o efeito de todas elas juntas. Se o efeito global dos sinais coletados exceder um limiar interno, o sinal é propagado pelo axônio em direção a outros neurônios. E foi justamente esta idéia a utilizada por McCulloch-Pitts quando formularam um dos modelos de neurônios mais fundamentais.

3.2.2. O Neurônio de McCulloch-Pitts

Este neurônio proposto é um modelo simplificado de neurônios biológicos. Para um dado instante de tempo o neurônio está disparando ou inativo. O

neurônio recebe e produz um valor booleano (0 ou 1). Existem conexões excitatórias e inibitórias representadas através de um peso com sinal, o qual reforça ou dificulta a geração de um impulso. Como para um neurônio biológico, o impulso só será executado se a quantidade de entradas se aproximar de um limiar (HAYKIN 1994, BITTENCOURT 1996).

A partir do modelo de McCulloch e Pitts foram derivados outros modelos que permitem outras saídas (não apenas 0 ou 1). A equação 3.1 define a função de saída de um neurônio de McCulloch-Pitts:

$$o_i(x) = 1 \text{ se } x = \sum_j w_{ij} i_{ij} - \theta_i \geq 0$$

$$0 \text{ se } x = \sum_j w_{ij} i_{ij} - \theta_i < 0$$
(3.1)

Onde

o_i = Função de saída do neurônio

w_{ij} = Peso da conexão associado com a entrada de um neurônio

i_{ij} = Entrada para um neurônio

θ_i = Limiar de ativação de um neurônio

Esta função de saída, que pode ser chamada de função de ativação, pode ser determinada por outros modelos que permitem saídas quaisquer, não necessariamente zeros ou uns (FIGURA 3.3). Pode-se utilizar funções lineares (a), função rampa (b), função passo (c) e a função sigmoide (d):

FIGURA 3.3: Alguns modelos de funções para neurônios

3.3. Arquiteturas de Redes Neurais

Grande parte das redes neurais são formadas pela organização dos neurônios em camadas ou campos. Uma camada deve agrupar neurônios com funções ou propriedades semelhantes. As características das arquiteturas incluem os tipos de conexões, os esquemas de conexões, e as configurações das camadas.

3.3.1. Tipos de Conexões

Há basicamente dois tipos de conexões: as excitatórias e as inibitórias. Conexões excitatórias incrementam uma ativação de um neurônio e são representadas por sinais positivos. Conexões inibitórias decrementam uma ativação de um neurônio e são representadas por sinais negativos. Estas conexões não precisam ser mutuamente exclusivas; ao invés disto, uma porção das conexões chegando em um neurônio tem pesos negativos e o restante pesos positivos. Esta classificação é interessante quando os neurônios das redes possuem uma estrutura derivada do modelo McCulloch-Pits.

3.3.2. Esquemas de Interconexão

Os três esquemas básicos de interconexão são: intra-camada, inter-camada e recorrentes. Conexões intra-camada, também referidas como conexões colaterais, são conexões entre neurônios da mesma camada. Conexões inter-camadas são conexões entre neurônios de diferentes camadas. Conexões recorrentes são conexões que partem e chegam a um mesmo neurônio. Os sinais de conexão inter-camada se propagam de duas maneiras: alimentação para frente ou alimentação para trás. Sinais de alimentação para frente permitem que a informação flua entre neurônios em apenas uma direção. Sinais de alimentação para trás possibilitam a informação fluir em uma direção e/ou recursivamente.

3.3.3. Configurações de Camada

As configurações de camada combinam neurônios, fluxo de informação e esquemas de conexão em uma arquitetura coerente. Configurações de camada incluem alimentação para trás e a alimentação para frente. Uma camada que recebe sinais externos do ambiente é chamada de camada de entrada. Uma camada que emite sinais para o ambiente é chamada de uma camada de saída. Quaisquer camadas que não sejam nem de entrada nem de saída, são denominadas camadas ocultas e não se conectam diretamente com o ambiente.

3.4. Perceptron

Segundo RICH (1994), um dos primeiros modelos de redes neurais foi desenvolvido por Roseblatt em 1958 e foi chamado de perceptron. Este modela um neurônio calculando uma soma ponderada de suas entradas. O resultado obtido pelo cálculo é a saída e pode ser um (se o cálculo obtido for maior ou igual a um valor inicial ajustável) ou zero (se o valor inicial ajustável não for atingido).

Um perceptron computa uma função binária de suas entradas. Vários perceptrons podem ser combinados para computar funções mais complexas. Tal grupo de perceptrons pode ser treinado em pares de amostra de entrada-saída até aprenderem a computar a função correta. No Anexo 1 tem-se um exemplo de utilização de uma rede do tipo Perceptron.

3.5. Arquitetura de uma Rede Neural do tipo Multi Layer Perceptron (MLP)

Depois do aparecimento do modelo de McCulloch e Pitts, o desenvolvimento do trabalho com os neurônios artificiais propostos, tornou-se o grande desafio.

Segundo BITTENCOURT (1996), a maioria dos algoritmos de treinamento de redes neurais é inspirada diretamente na Lei de Hebb (HEBB 1949) que basicamente diz que se um fator é determinante para o estímulo de saída ser produzido, o peso da conexão daquela informação deve ser incrementado.

Com isso, a capacidade de aprendizagem em redes neurais, pode ser conseguida através da ajuste dos pesos das conexões entre os neurônios.

Segundo FILHO et al (1994), o problema geral foi resolvido por Rumelhart, Hinton e Williams em 1986. A solução encontrada ficou conhecida como *Backpropagation Error Correction Algorithm*, para redes perceptron de multi camadas de neurônios com entradas e saídas analógicas. As funções de ativação utilizadas foram do tipo sigmóide.

A arquitetura multi-camadas MLP onde este algoritmo pode ser aplicado está representada na FIGURA 3.4.

FIGURA 3.4: Arquitetura com muitas camadas

O padrão de entrada é colocado na camada de entrada (FIGURA 3.4). Sobre estes neurônios desta camada não são efetuadas nenhuma operação. O número de neurônios da entrada é igual ao número de entradas.

A última camada chamada camada de saída, produz a saída para o usuário. Como esta saída não é necessariamente a desejada, existirá um erro da saída

calculada pela rede com a saída desejada. Este erro é reutilizado para avaliar uma nova distribuição de pesos entre os diversos neurônios.

Entre as duas camadas existe uma ou mais camadas escondidas, que como seu próprio nome diz, não podem ser utilizadas pelo usuário pois a saída de seus neurônios não podem ser acessadas por procedimentos externos.

3.6. Aprendizagem em Redes Neurais

O objetivo da aprendizagem (ou treinamento) é fazer com que a aplicação de um conjunto de entradas na rede neural produza um conjunto de saídas desejado (ou no mínimo consistente). Cada um destes conjuntos de entrada ou saída será referido como um vetor. Normalmente, a aprendizagem se dá através da aplicação sequencial de vetores de entradas e o ajuste do estado interno da rede de acordo com um algoritmo pré-determinado. Todos os métodos de aprendizagem podem ser classificados em duas categorias: aprendizagem supervisionada e aprendizagem não supervisionada.

3.6.1. Aprendizagem Supervisionada

A aprendizagem supervisionada é um processo que incorpora um instrutor externo ou uma informação global. São fornecidos à rede pares de treinamento, representando os vetores de entrada e as saídas desejadas. Um vetor de entrada é aplicado à rede, a saída correspondente é calculada e comparada com o correspondente vetor de saída desejado. O erro é propagado através da rede e os pesos são alterados por um algoritmo que tende a minimizar este erro. As técnicas de aprendizagem supervisionada incluem: decidir quando desativar a aprendizagem; decidir como apresentar, e por quanto tempo, os pares de treinamento; e suprir informação de erro e performance.

3.6.2. Aprendizagem Não Supervisionada

A aprendizagem não supervisionada, também conhecida como auto-organização (*self-organization*), é um processo que não incorpora instrutor externo e se baseia apenas em informação local e controle interno. Um método não supervisionado auto-organiza os dados apresentados e descobre suas propriedades coletivas. O conjunto de treinamento consiste apenas de vetores de entrada. O algoritmo de treinamento modifica a rede de forma a produzir vetores de saída que são consistentes (tanto a aplicação de um dos vetores de treinamento quanto a de um vetor suficientemente similar irão produzir o mesmo padrão de saídas). O processo de treinamento extrai propriedades estatísticas do conjunto de treinamento e agrupa vetores similares em classes.

3.6.3. O Algoritmo de Aprendizagem em uma Rede Neural MLP-Backpropagation

As pesquisas com redes multi camadas foram reiniciadas na metade da década de 80, mostrando que estas redes MLP do tipo alimentação para frente totalmente conectadas podem ser amplamente utilizadas, através do algoritmo *Backpropagation* desenvolvido por RUMELHART et al (1986).

Segundo BITTENCOURT (1986), este modelo é aconselhado por ser um modelo de larga aplicação, simples e eficiente. Tem como desvantagens a necessidade de um treinamento supervisionado e uma quantidade razoável de casos para treinamento.

Este algoritmo é um método de gradiente decrescente, e que não garante chegar ao mínimo erro global, e pode ser dividido em 5 passos segundo FILHO et al (1984):

- **Passo 1: Apresente um padrão de entrada e saída desejada**

Utilizando uma determinada estratégia de apresentação coloque um dos padrões de entradas na camada de entrada e a saída desejada nas suas respectivas camadas, então ative o passo **calcule saída**.

- **Passo 2: Calcule saída**

A partir da primeira camada, permita que cada camada produza os valores da saída até atingir a camada de saída e, então ative o passo **ajuste pesos da camada de saída**.

- **Passo 3: Ajuste pesos da camada de saída**

Para cada neurônio j da camada de saída, atualize todos os pesos w_{ij} conforme equação 3.2 e, então ative o passo **ajuste pesos das camadas escondidas**.

$$\Delta w_{ij} = \eta \delta_j o_i \quad (3.2)$$

Onde

η : Taxa de aprendizagem

o_i : Saída do neurônio i

δ_j : Erro entre saída computada e a saída desejada do neurônio j , que pode ser calculada segundo a equação 3.3:

$$\delta_j = o_j(d_j - o_j)(1 - o_j) \quad (3.3)$$

Onde

d_j : Saída desejada de n_j

- **Passo 4: Ajuste pesos das camadas escondidas**

Para ajustar o peso de todas as camadas escondidas, atualize o peso w_{ki} de um neurônio i de uma camada escondida que está ligado a outro neurônio k na camada anterior conforme equação 3.4

$$\Delta w_{ki} = \eta \delta_i o_k \quad (3.4)$$

Onde

η : Taxa de aprendizagem

o_k : Saída de n_k , que estimula n_i via w_{ki}

δ_i : erro relativo do neurônio n_i dado pela equação 3.5

$$\delta_i = o_i(1-o_i)\sum w_{ij}\delta_j \quad (3.5)$$

Depois que todas as conexões tenham sido ajustadas ative o passo **cheque magnitude do erro**.

- **Passo 5: Cheque magnitude do erro**

Para se checar a magnitude do erro, podem-se adotar várias estratégias diferenciadas quanto a forma de aceitar o erro como desprezível. Uma regra muito comum é ver se o erro global de saída da rede em relação a saída desejada é menor que um dado erro. Se a condição adotada é satisfeita, então a rede aprendeu o conjunto de treinamento, caso contrário volte a ativar o passo **apresente um padrão de entrada e a saída desejada**.

- **Fim do algoritmo.**

Este algoritmo pode ser utilizado em uma arquitetura com qualquer número de camadas. O passo 4 deve ser ativado recursivamente até chegar na camada de entrada. Para se aumentar a velocidade de convergência é possível introduzir um multiplicador na equação 3.3 chamado momento, onde este valor representa o efeito dos ajustes anteriores no ajuste atual.

3.7. Fase de Uso

Consiste em colocar um padrão de entrada nos neurônios de entrada já treinados, que já sofreram aprendizagem, e deixar a rede produzir a saída que melhor represente a aprendizagem realizada. Neste estado os neurônios estão em estado de uso.

Neste caso, para o estado de uso, o padrão a ser testado deve possuir as mesmas variáveis do conjunto de treinamento. Quando a rede produzir a saída (normalmente um valor numérico), o maior valor encontrado entre todos os valores da saída é adotado e diz-se que houve o reconhecimento do padrão.

Para que este reconhecimento de padrão seja o mais real possível, quando os números da camada de saída são muito próximos e pequenos, (não havendo uma tendência a uma classe), pode-se colocar um limite a ser atingido para que ocorra o reconhecimento, que neste trabalho é chamado valor para validação dos resultados.

CAPÍTULO 4

DESCRIÇÃO DA BASE DE DADOS UTILIZADA NO PROBLEMA

4.1. Introdução

Os arquivos de dados descritos aqui, foram criados durante a análise financiada pelo Banco Mundial de 1982 até 1984. Este estudo foi feito no Brasil durante o período de 1975-1982, dentro da Pesquisa do Inter-relacionamento dos Custos de Construção, Conservação e Utilização de Rodovias (PICR).

Essa pesquisa realizou uma revisão dos arquivos de dados e inspeções de campo, em alguns trechos do Brasil como também usou todos os dados disponíveis. Para geração de uma documentação final, os dados (compostos em arquivos) foram compilados, com tarefas de revisão, condensação e codificação de alguns campos, correção de erros, adição de dados perdidos.

Foram impressas listagens com estes dados dos arquivos. Para execução deste trabalho foi fornecida, pelo Dr. César Augusto Vieira de Queiroz, a listagem que trata das estradas pavimentadas. São aproximadamente 300 páginas de relatórios, gerados por um programa estatístico da IBM chamado SAS.

Estas listagens foram fotocopiadas e montadas em forma de um livro, sendo que uma cópia deste é que foi fornecida (ROAD DETERIORATION STUDY: LISTING OF PAVED ROAD DATA FILES 1985). Para a transformação destas listagens em dados foi necessária sua digitalização.

Esta digitalização foi feita utilizando um equipamento para leitura digital (*Scanner*) e um programa de reconhecimento de caracteres (WORDSCAN da Microsoft). Este reconhecimento foi feito por páginas, com grande quantidade de erros, pois a cópia fornecida também estava em fotocópia.

Foram reconhecidas 266 páginas e conferidas número a número, para se obter o formato inicial do documento original. Concluída esta tarefa, os arquivos foram montados como o trabalho inicial feito pelo Banco Mundial. Foram verificados através de programas de validação todos os campos, tipos dos dados, tamanho e seus valores limites.

Dentro deste programa estatístico SAS, existem procedimentos para a geração de relatórios, e estes contém títulos, totais e outras informações que não são mais úteis. Todas estas informações foram excluídas do reconhecimento.

Foram então recriados os mesmos arquivos de dados relacionados aos pavimentos, utilizados na pesquisa PICR, e o resultado foi convertido para arquivos de formato texto, devido à portabilidade deste padrão para a maioria dos sistemas.

4.2. Arquivos da Pesquisa PICR

Os dados foram divididos em 7 arquivos que contemplam determinados aspectos (TABELA 4.1), podendo possuir campos repetidos entre eles. Estes campos foram ordenados por trechos.

Todos os dados, dentro destes arquivos, são identificados segundo esta divisão por trechos, num total de 116, dos quais 74 são considerados trechos principais e 42 trechos especiais (identificados por "T"). Os trechos principais são divididos em quatro com dois níveis de manutenção e duas direções de tráfego. Os trechos especiais só possuem um nível de manutenção e duas direções de tráfego.

O arquivo SECTINFO, contém os dados principais dos trechos; MATPROP2 e MATLAYR1 contém os dados detalhados das propriedades das camadas dos pavimentos nos trechos; STRESP2 contém dados da resposta estrutural do pavimento, com dados de ensaio de viga Benkelman, deflexões do Dynaflect e parâmetros de tensão e deformação; MAINTINT contém dados de manutenção, as quais foram executadas nos trechos.

Os mais importantes são os arquivos CONDPC9, que contém principalmente dados de condição do pavimento e ENVIRES8, que contém principalmente dados de tráfego. Estes arquivos contém medições de intervalos aproximados de semestres. Para os 116 trechos foram obtidos 3149 medidas, com uma média de 8,3 medidas por trecho. Nestes dois arquivos ainda existem dados da manutenção executada durante as medições naquele pavimento.

TABELA 4.1: Descrição dos arquivos de dados

Arquivo	Número de Observações	Número de Variáveis
SECTINFO	116	32
MAINTINT	307	14
CONDPC9	3149	29
ENVIRES8	3149	37
STRESP2	180	40
MATPROP2	116	33
MATLAYR1	445	15
		174

Neste trabalho foram utilizados apenas os arquivos SECTINFO, CONDPC9, ENVIRES8 e MAINTINT. Os números que aparecem no final do nome dos arquivos indicam sua geração no trabalho original.

Os nomes das variáveis dos arquivos foram mantidos. As definições, apresentadas a seguir, encontram-se no relatório das estradas pavimentadas da pesquisa.

TABELA 4.2: Definições das variáveis nos arquivos

Nome	Tipo	Formato	Definição	Arquivo
AADT	Num	Veic/dia	Tráfego anual médio diário em ambas direções na data de observação	ENVIRES8
AADT1	Num	Veic/dia	AADT representativo na 1a. data de observação	SECTINFO
ACTION	Caracter	MAINT8	Descrição da atividade de manutenção empreendida em uma data dada	MAINTINT SECTINFO
AGE0	Num	Anos	Idade do pavimento original na data de observação YR-YRCON - 0.5	CONDPC9
AGEF	Num	Anos	Idade da última superfície completa por selagem ou tratamento	CONDPC9
AGER	Num	Anos	Idade da última reabilitação por recape ou reconstrução	CONDPC9 ENVIRES8
AGES	Num	Anos	Idade da última superfície por selagem parcial ou total	CONDPC9 ENVIRES8
BASE	Caracter	BASE6	Descrição do material da camada de base	SECTINFO
CKPA	Num	%	Área de remendos rompidos, em proporção a área da subseção	CONDPC9
CP	Num	mm	Chuva acumulada na data de observação desde 01/01/76	ENVIRES8
CQ	Num	Inteiro	Fator de Qualidade de Construção para tratamentos superficiais 0: sem defeitos evidentes, 1 com defeitos evidentes	SECTINFO

TABELA 4.2: Definições das variáveis nos arquivos

CONTINUAÇÃO

Nome	Tipo	Formato	Definição	Arquivo
CR1	Num	%	Soma das áreas com trincamento de classe 1 ($< 1\text{mm}$)	CONDPC9
CR2	Num	%	Soma das áreas com trincamento de classe 2 (1-3 mm)	CONDPC9
CR3	Num	%	Soma das áreas com trincamento de classe 3 ($> 3\text{mm}$)	CONDPC9
CR4	Num	%	Soma das áreas com trincamento de classe 4 (usualmente 3mm de largura e bordas desagregadas)	CONDPC9
CROC	Num	%	Soma de área de jacarés na subseção	CONDPC9
CRX	Num	%	Média ponderada de área de trincas por subseção para as classes de CR1 a CR4	CONDPC9
CSLU	Num	%	Área de aplicação de selante acumulada durante a fase de reabilitação até a data de observação	CONDPC9
DATE	Num	aammdd	Data da observação na condição de vistoria	CONDPC9
DEF	Num	mm	Deflexão de Viga Benkelman	STRESP ENVIRES8
DEFM	Num	mm	Deflexão representativa na seção (média das subseções para o período de estudo)	ENVIRES8

TABELA 4.2: Definições das variáveis nos arquivos

CONTINUAÇÃO

Nome	Tipo	Formato	Definição	Arquivo
DEFPR	Num	Fração	Razão das deflexões de Benkelman na trilha de roda externa e interna	ENVIRES8
DEFS	Num	mm	Deflexão ajustada para data e estação do clima	ENVIRES8
DIR	Caracter		Direção de tráfego com SUBS designa subseção. CS (COM para SEM) SC (SEM para COM) CR manutenção crescente DE decrescente	CONDPC9 ENVIRES8 MAINTINT STRESP2
DPAT	Num	%	Soma de áreas de remendos fundos (base e capa) por subseção	CONDPC9
DRG	Num	Inteiro	Codificação da condição de drenagem estimada 0- Bem drenada, 1- regular, 2 Saturação potencial (valores são incompletos)	SECTINFO
E0	Num	Fração	Razão média de medida de teor de umidade / mistura ótima (Proctor) do subleito	ENVIRES8
EPA1 até EPA6	Num	Fração	Número de eixos equivalentes, calculados com diferentes expoentes do fator de equivalência de operações	ENVIRES8

TABELA 4.2: Definições das variáveis nos arquivos

CONTINUAÇÃO

Nome	Tipo	Formato	Definição	Arquivo
GRA GRB	Num	%	Média do gradiente longitudinal da seção (A refere-se a “COM”, B refere-se a “SEM”) por seção	SECTINFO
H0	Num	mm	Espessura de Capa atual (. - nada , 0 - menos que 1mm)	MAINTINT MATPROP2
H1	Num	mm	Espessura de capa no começo do estudo, média por seção	MATPROP2 SECTINFO
IM	Num	Inteiro	Índice de umidade Thornthwaite's	ENVIRES8
ISCBR	Num	%	CBR para amostras indeformadas do subleito para condições in situ	MATPROP2 SECTINFO
MAP	Num	mm	Média anual de precipitação por seção	SECTINFO
MP	Num	mm	Precipitação mensal na data de observação	ENVIRES8
NHV	Num	10 ⁶	Somatória de veículos pesados, por faixa na data da observação, em milhões desde a mais recente reabilitação	ENVIRES8
NHX	Num	10 ⁶	Somatória de eixos de veículos pesados por faixa de observação, em milhões, desde a mais recente reabilitação, para veículos de classes 2,4,5 e 6	ENVIRES8
NVL	Num	10 ⁶	Somatória de veículos leves < 3500 Kg, em milhões, na data de observação	ENVIRES8

TABELA 4.2: Definições das variáveis nos arquivos

CONTINUAÇÃO

Nome	Tipo	Formato	Definição	Arquivo
PDF	Num	Fração	Fator de precipitação de chuva	SECTINFO
POT	Num	%	Soma de áreas de painéis abertas na data da observação	CONDPC9
PSTA	Caracter	\$3.	Identificação da estação de chuva	SECTINFO
PV2, PV4, PV5, PV6	Num	Fração	Frações de eixos acumulados por categoria, desde a mais recente reabilitação	ENVIRES8
PVL	Num	Fração	Fração do tráfego anual composta por veículos leves	ENVIRES8
PVL1	Num	Fração	Valor de PVL, na primeira data da observação	SECTINFO
RAV	Num	%	Soma das áreas de desagregação (ou desgaste) em relação à área de observação (em porcentagem)	CONDPC9
RDMN	Num	mm	Média de afundamento de trilhas	CONDPC9
RDSD	Num	mm	Desvio padrão de RDMN	CONDPC9
RHA	Caracter	\$4.	Tipo de ação de reabilitação	CONDPC9
RHT	Num	Inteiro	Identificação da reabilitação (0-original, 1- depois da primeira reabilitação.....)	CONDPC9 MAINTINT ENVIRES8
RQI	Num	QI	Irregularidade da seção na data de observação	CONDPC9
RSA	Caracter	\$3.	Tipo de ação de recapeamento	CONDPC9 ENVIRES8

TABELA 4.2: Definições das variáveis nos arquivos

CONTINUAÇÃO

Nome	Tipo	Formato	Definição	Arquivo
RSF	Num	Inteiro	Identificação do recapamento (0 - original, 1- depois do primeiro recapeamento....)	CONDPC9 ENVIRES8
RST	Num	Inteiro	Identificação de total ou parcial fase de recape	CONDPC9 ENVIRES8
SEC	Caracter	\$3.	Identificação do trecho de teste de pavimento	SECTINFO CONDPC9 ENVIRES8 MAINTINT
				MATLAYR1 MATPROP2 STRESP2
SF	Num	Inteiro	Categorias de tratamentos da superfície	SECTINFO
SGCBR	Num	%	CBR com Proctor modificado	MATPROP2 SECTINFO
SGDEP	Num	mm	Profundidade da superfície até o subleito	MATPROP2 SECTINFO
SHSU	Num	\$4.	Superfície do acostamento	SECTINFO
SHWIDE	Num	m	Largura do acostamento	SECTINFO
SN	Num	F4.2	Número estrutural do pavimento	SECTINFO
SNSD	Num	F4.2	Desvio padrão do SN nos três pontos da seção	SECTINFO
SN1SD	Num	F4.2	Desvio padrão do SNC nos três pontos da seção	SECTINFO

TABELA 4.2: Definições das variáveis nos arquivos

CONTINUAÇÃO

Nome	Tipo	Formato	Definição	Arquivo
SNA	Num	F4.2	Numero estrutural na data da observação, com seção reabilitada	ENVIRES8
SNC	Num	F4.2	Numero estrutural corrigido, na data da observação	ENVIRES8
SND	Num	F4.2	Número estrutural corrigido, ajustado pela deflexão local	ENVIRES8
SNS	Num	F4.2	SNC sazonal na data da observação	ENVIRES8
SPAT	Num	%	Soma de áreas de remendos em relação a área da seção	CONDPC9
SUBS	Caracter	\$3.	Identificação das seções COM com rotinas de manutenção e SEM sem rotinas de manutenção só fechamento de painelas	CONDPC9 ENVIRES8 MAINTINT STRESP2
SURF	Caracter	\$6.	Descrição do tipo de capa na primeira data de observação	SECTINFO
WIDTH	Num	m	Largura da capa sem os acostamentos	SECTINFO
YE41CC YE41SD	Num	10 ⁺⁶ ESA	Número anual de eixos equivalentes	SECTINFO
YR	Num	F6.3	Data da obsevação (em milésimos)	CONDPC9 ENVIRES8
YRCON	Num	Inteiro	Ano de construção	SECTINFO
YROVL	Num	F6.3	Ano da primeira reabilitação	SECTINFO

(c) O conteúdo deste campo pode variar, em função da variável.

4.3. Variáveis Utilizadas

Para o treinamento das RN, não devem ser escolhidos dados que representem uma média no tempo, como exemplo trinca média da seção em uma determinada época, pois o objetivo é reconhecer este tipo de transição.

Com isso, a utilização deverá se concentrar nos arquivos que trazem os dados no tempo, o CONDPC9 e o ENVIRE8. O arquivo SECTINFO, continua sendo necessário, para saber tipos de base, capa e outros dados que não se alteraram durante a pesquisa.

Com o objetivo de dar uma sensibilidade dos dados utilizados, estes foram listados abaixo, como também, seus valores mínimos, máximos e média.

TABELA 4.3: Valores mínimos, máximos, médios e desvios padrões das variáveis utilizadas

Nome	Mínimo	Máximo	Média	Desvio padrão	Arquivo
AGE0	0,57	23,06	9,88	5,33	CONDPC9
AGER	0,00	23,05	7,66	4,68	CONDPC9 ENVIRE8
AGES	0,00	23,05	5,38	4,40	CONDPC9 ENVIRE8
BASE*					SECTINFO
CP	958,00	9605,00	4892,95	2128,56	ENVIRE8
CR1	0,00	108,60	18,03	29,59	CONDPC9
CR2	0,00	108,60	16,11	28,59	CONDPC9
CR3	0,00	100,30	11,32	25,10	CONDPC9
CR4	0,00	100,30	7,62	21,36	CONDPC9
CROC	0,00	100,00	12,36	26,04	CONDPC9
CRX	0,00	100,20	13,25	24,71	CONDPC9

TABELA 4.3: Valores mínimos, máximos, médios e desvios padrões das variáveis utilizadas

CONTINUAÇÃO

Nome	Mínimo	Máximo	Média	Desvio padrão	Arquivo
DEF	0,00	2,02	0,63	0,34	ENVIRES8
DEFPR	0,58	3,63	1,20	0,25	ENVIRES8
DEFS	0,00	2,02	0,62	0,34	ENVIRES8
EPA2	0,00	1,05	0,54	0,18	ENVIRES8
EPA4	0,00	2,46	0,66	0,36	ENVIRES8
H1	10,00	233,00	52,97	41,12	SECTINFO
MAP	1000,00	1786,00	1459,89	135,94	SECTINFO
MP	0,00	395,00	110,20	96,59	ENVIRES8
NHV	0,00	6,89	0,63	0,67	ENVIRES8
NHX	0,00	12,31	1,57	1,70	ENVIRES8
POT	0,00	11,80	0,03	0,43	CONDPC9
PV2	0,00	0,31	0,05	0,037	ENVIRES8
PV4	0,00	0,39	0,17	0,073	ENVIRES8
PV5	0,00	0,35	0,10	0,066	ENVIRES8
PV6	0,00	0,15	0,03	0,025	ENVIRES8
PVL	0,00	0,88	0,65	0,11	ENVIRES8
RAV	0,00	100,00	5,67	17,75	CONDPC9
RDMN	0,00	15,75	3,33	2,21	CONDPC9
RDSD	0,00	14,60	2,06	1,35	CONDPC9
RQI	0,00	122,38	39,07	15,88	CONDPC9
SGCBR	0,00	54,00	23,12	11,46	SECTINFO
SHSU*					SECTINFO
SHWIDE	1,00	4,00	2,38	0,42	SECTINFO
SN	0,83	6,21	2,49	0,98	SECTINFO
SNA	0,00	6,26	2,49	1,01	ENVIRES8

TABELA 4.3: Valores mínimos, máximos, médios e desvios padrões das variáveis utilizadas

CONTINUAÇÃO

Nome	Mínimo	Máximo	Média	Desvio padrão	Arquivo
SND	0,00	8,10	4,10	1,24	ENVIRES8
SPAT	0,00	100,00	2,54	9,85	CONDPC9
SURF*					SECTINFO
WIDTH	7,00	7,50	7,01	0,057	SECTINFO

Na Tabela anterior, os campos marcados por *, são cadeias de caracteres com os nomes empregados por categoria. Os possíveis valores que as variáveis podem assumir estão nas tabelas a seguir.

TABELA 4.4: Variável BASE

Valores	Significado
GRAVEL	Pedregulho
CRSTONE	Pedra britada
CEMENT	Cimentada
LIMETD	Solo-cal

TABELA 4.5: Variável SURF

Valores	Significado
AC	Concreto Asfáltico Original
DST	Tratamento Superficial Duplo Original
ACOVL	Concreto Asfáltico sobre Concreto Asfáltico Original
DSTOVL	Concreto Asfáltico sobre Tratamento Superficial Duplo

TABELA 4.6: Variável SHSU

Valores	Significado
GRAV	Natural ou Pedra Britada
SST	Tratamento Superficial Simples

Finalmente, após esta visão geral dos arquivos e tipos de dados utilizados, procedeu-se a modelagem das RN. Este processo, e o seu emprego, estão descritos nos capítulos a seguir.

CAPÍTULO 5

DESCRIÇÃO DO PROCEDIMENTO PARA AVALIAÇÃO DA CONDIÇÃO DO PAVIMENTO

5.1. Introdução

No Capítulo 2 foram discutidas a estrutura de um sistema de gerência de pavimentos, seus componentes principais, e quais dados eram os mais importantes. Já no Capítulo 3, apresentou-se o conceito de redes neurais, e o método de se identificar características em um conjunto de dados. Utilizando o conjunto de dados descrito no Capítulo 4, é proposta neste capítulo uma forma de reconhecimento de padrões utilizando redes neurais.

Para se mostrar que as RN podem ser aplicadas em pavimentos, foram identificadas as características necessárias para montagem de uma rede neural, tendo como objetivo avaliação da condição do pavimento.

5.2. Avaliação da Condição do Pavimento

Neste item apresentam-se: o tipo de rede neural utilizada no trabalho, a proposta para treinamento da rede e outros fatores importantes para o reconhecimento adequado da avaliação.

5.2.1. Rede Neural Proposta

Para a obtenção da avaliação da condição do pavimento, foram utilizadas redes do tipo Multi-Camadas Perceptrons com algoritmo de aprendizagem *Backpropagation* (MLP-*Backpropagation*), descritas no Capítulo 3.

Este tipo de modelo foi escolhido por ser amplamente aceito e pelos excelentes resultados que tem produzido na área de reconhecimento de padrões (HAYKIN 1984), (PHAN e LIU 1995), (FREEMAN e SKAPURA 1992), (HECHT-NIELSEN 1989) e (PANT 1994). Além disso por se tratar de um problema de aproximação de funções não lineares, e por se tratar de um modelo de regressão não paramétrica, segundo HAYKIN (1984) e PHAN e LIU 1995, é o mais aconselhável.

A função a ser aproximada, que é limitada e decrescente, pode ser definida no domínio das 174 variáveis descritas no capítulo anterior. Como não se sabe o comportamento de uma RN, a melhor rede foi obtida por tentativas. De acordo com a implementação proposta por MARAR (1996), foram geradas aproximadamente 300 redes e testadas com o conjunto dos dados. É apresentada a solução detalhada de um problema linear no Anexo 2.

Inicialmente foi pensado em utilizar as 174 variáveis disponíveis, segundo os arquivos existentes.

Para se obter melhor reconhecimento, quanto mais dados no tempo existirem para treinar a rede menor se torna o ruído. Por isso dados isolados no tempo que não representariam o comportamento do pavimento durante a realização da pesquisa não seriam interessantes, atrapalhando o resultado.

Os arquivos STRESP2 e MAINTINT foram eliminados da análise, pois seus registros possuíam pequena quantidade de medidas dos trechos, além do que estas medidas foram realizadas, na maioria, em épocas diferentes das medidas do arquivo de defeitos (CONDPC9) e do arquivo de tráfego (ENVIRES8).

Existia uma dificuldade complementar de ajustar a data de todos os registros para que pudessem ser levados as RN. Para fazer parte da rede e identificar um ponto do comportamento no tempo, todas as medidas deveriam ser de mesma data.

Foram montados os bancos de treinamento, e posteriormente o banco para testes na fase de uso. Neste ponto houve a dificuldade computacional de limitação de memória. Caso se desejasse um conjunto grande de neurônios na camada de entrada, o conjunto de treinamento deveria ser reduzido.

Devido a esta limitação computacional, e para que se aumentasse o arquivo com as amostras para o treinamento, foram excluídas do teste os dados secundários da estrutura do pavimento. Grande parte dos arquivos MATLAYR1 e MATPROP2 foram retirados. Os dados principais continuavam no arquivo SECTINFO. Com esta eliminação permitindo que o banco de treinamento fosse aumentado conseguiu-se obter melhores resultados.

Na procura de melhores resultados diversas composições de entrada foram testadas. Um dos objetivos seria a redução máxima de variáveis, para isso foi testada a eliminação do conjunto de variáveis relativas ao tráfego, que existiam em bom número. Eliminando-se da análise os parâmetros de tráfego, observou-se uma melhora na porcentagens de casos reconhecidos.

Com isso chegou-se a um conjunto de variáveis de entrada que se obtinha bom reconhecimento dos padrões para a avaliação. Esta configuração final neste trabalho é chamada solução inicial. Para esta solução inicial, foram utilizadas apenas 18 entradas mostradas na tabela a seguir:

TABELA 5.1: Variáveis para a camada de entrada	
1	ano de construção
2	média anual de chuva
3	trincas de classe 1
4	trincas de classe 2
5	trincas de classe 3
6	trincas de classe 4
7	jacaré
8	panelas
9	desgregação
10	viga Benkelman
11	afundamento da trilha de roda
12	irregularidade
13	CBR
14	tipo da capa;
15	espessura da capa do pavimento
16	tipo da base do pavimento
17	tipo do acostamento
18	número estrutural

As saídas foram escolhidas de modo a representar a serventia do pavimento. Foram adotadas 5 saídas mostradas na TABELA 5.2. A modelagem final obtida está representada pelo esquema mostrado na FIGURA 5.1.

TABELA 5.2: Variáveis para a camada de saída	
1	Ótimo
2	Bom
3	Regular
4	Ruim
5	Péssimo

FIGURA 5.1: Esquema de RN proposto para avaliar a condição do pavimento

5.2.2. Esquema de Treinamento

No item anterior, foi proposto um modelo para que as RN pudessem ser utilizadas para o reconhecimento da avaliação da condição. Este modelo foi adotado em função de um conjunto de treinamento. Este conjunto de treinamento necessita de informações que representem as saídas.

Foi necessário a adoção de critérios de decisão para as classes. Foram escolhidos 2, que são os mais utilizados, e que estão descritos no Capítulo 2. Outro motivo para a escolha, são os dados disponíveis descritos no Capítulo 4. Na escolha de uma amostra foram selecionados, aleatoriamente, casos onde os dois métodos especialistas concordavam (FIGURA 5.2).

Nesta etapa foi desenvolvido um conjunto de programas, que calculava o IGG, classificava o valor da Irregularidade (retirado do arquivo

CONDPC9), e se os dados fossem da mesma classe, aleatoriamente alguns destes, onde ocorriam a concordância de classes, eram incorporados a um outro arquivo, que seria entrada para o programa de treinamento das RN.

FIGURA 5.2: Esquema para treinamento

Pelo motivo do arquivo de treinamento necessitar de processo(s) especialista(s) de escolha, é que, foi escolhida a divisão do IGG em 5 classes conforme o item 2.2.2. Com a adoção desta escala, permitiu-se uma padronização com a escala de Irregularidade (AUTRET et al 1991) que também dividida em 5 classes.

5.2.3. Outros Fatores Importantes

Foram realizados testes com a utilização de mais um critério de decisão, a saber o processo definido por COELHO e MAGALHÃES (1986), chamado Índice de Suficiência. Experimentou-se também o estabelecimento de classes para o índice. Os resultados obtidos não foram bons. Conclui que este índice não é um bom avaliador da condição do pavimento.

Uma vez feita a classificação, todas as variáveis (18) do conjunto de treinamento foram normalizadas, isto é convertidas em valores entre zero e um.

Foi montado então, o “conjunto de treinamento”, através de outros programas desenvolvidos, um arquivo de forma seqüencial com aproximadamente

3% da base de dados, sendo que em cada registro foi anexado um novo campo para a indicação da categoria da classificação, coincidente pelos métodos de IGG e irregularidade.

O programa de treinamento foi acionado. Com este conjunto, as RN eram montadas em aproximadamente um minuto. O equipamento utilizado para este fim, foi um do tipo microcomputador PC 486DX4-100.

Com a rede montada passa-se agora a verificação de toda a base. O conjunto de teste foi a base inteira, também com suas variáveis convertidas para valores entre zero e um. O tempo para verificação de toda a base é por volta de 5 segundos.

A verificação do método foi feita com a RN concordando com o máximo de resultados, em relação ao seu método de classificação, no caso IGG e irregularidade. O total de casos, que a rede reconhece de maneira igual aos métodos de classificação, é discutido no capítulo 6.

O resultado da rede, agora na fase de uso, é um valor para cada categoria (5) em forma de um vetor. Valores entre zero e um indicam quanto seria reconhecido por categoria. A porcentagem maior é considerada como a categoria identificada.

O exemplo de um resultado poderia ser: 0,01 para péssimo, 0,20 para ruim, 0,40 para regular, 0,15 para bom e 0,03 para ótimo. A soma deve ser próxima da unidade. O maior valor é considerado como correto, pois este terá o maior peso no calculo feito pela rede neural. Neste trecho exemplificado é classificado como regular.

Um limite numérico deve ser adotado como limiar de aceitação de respostas. Neste trabalho, foi chamado de validação dos resultados.

CAPÍTULO 6

ANÁLISE DA AVALIAÇÃO DA CONDIÇÃO DO PAVIMENTO UTILIZANDO REDES NEURAIS

6.1. Introdução

Foram vistas no Capítulo 2, duas formas de se avaliar a condição de um pavimento. Estas podem produzir resultados diferentes, pois uma está relacionada a estrutura do pavimento e outra com funcionalidade de utilização da via. No Capítulo 5 foi proposto um método que poderia compor as duas formas de avaliação, através da montagem de um treinamento para as RN.

A partir do modelo proposto no capítulo anterior, o problema consiste refinar a solução e encontrar a melhor forma para a composição destas RN.

Uma tentativa para melhorar o reconhecimento da RN é alterar as variáveis que fazem parte da camada de entrada da rede, na fase de treinamento.

Para a verificação de cada novo caso gerado para o treinamento, deve-se gerar novo banco de teste com as variáveis de entrada correspondentes.

Neste capítulo são apresentados os resultados de diversas redes que depois de treinadas foram testadas com os todos os dados da base a que estão relacionados.

Este capítulo está dividido em 3 partes principais, onde na primeira parte estão os dados relativos ao IGG, na segunda os dados relativos a Irregularidade e uma terceira, onde os dois métodos estão comparados com as RN.

Todos os resultados estão apresentados em tabelas onde os dados calculados pelos processos estão em linha e os resultados obtidos pelas RN em colunas. Existe uma coluna onde são mostrados os dados que não foram classificados. Devido a grande quantidade de possibilidades de variáveis de entrada, foi feita uma divisão em conjuntos relacionados. Quando um tema é encerrado, os valores totais são mostrados em gráficos.

Como a análise é comparativa, foi proposta uma amostra inicial, com 94 casos, onde 6 foram classificados como péssimos, 12 ruins, 21 regulares, 26 bons e 29 ótimos. O tempo de treinamento médio das RN foi de aproximadamente 50 segundos.

6.2. Análise da Avaliação da Condição por IGG Comparada com RN

Para se demonstrar a aplicabilidade de RN na avaliação da condição do pavimentos, os dados foram agrupados por assunto e estes foram comparados, com os valores calculados para IGG, nos itens a seguir.

6.2.1. Análise Paramétrica

Na análise foi utilizada a seguinte solução inicial:

TABELA 6.5 : Inserção de AGES

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	1	117	39	1	0	0	74,1
Regular	0	21	310	155	0	0	63,8
Bom	0	1	36	619	149	0	76,9
Ótimo	0	0	2	241	1451	0	85,7
% Total de Acerto							79,5

TABELA 6.6 : Sem AGE0

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	1	121	35	1	0	1	76,6
Regular	0	20	314	152	0	0	64,6
Bom	0	1	39	663	102	0	82,4
Ótimo	0	0	2	288	1404	0	82,9
% Total de Acerto							79,6

Todos os valores totais relativos a idade foram colocados em um gráfico, para uma melhor visualização (FIGURA 6.1).

FIGURA 6.1: Efeito da idade na avaliação da condição por IGG

Os resultados obtidos, mostrados na figura acima, indicam que a idade de restauração influencia mal a RN, obtendo-se os piores resultados. Os melhores resultados foram obtidos com a introdução da idade da última selagem ou até sem idade alguma onde foi o maior valor obtido.

6.2.1.2. Análise do Tráfego na Avaliação da Condição por IGG

Com o objetivo de verificar se o tráfego influenciaria na montagem da rede, foram introduzidos inicialmente os parâmetros de veículos leves e pesados (TABELAS 6.7 e 6.8):

TABELA 6.7 : Inserção de NHX

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	0	133	24	1	0	0	84,2
Regular	0	47	287	152	0	0	59,1
Bom	0	3	46	657	99	0	81,6
Ótimo	0	0	2	337	1355	0	80,0
% Total de Acerto							77,4

TABELA 6.8 : Inserção de NLV

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	0	124	33	1	0	0	78,5
Regular	0	33	316	137	0	0	65,0
Bom	0	1	50	652	102	0	81,0
Ótimo	0	0	2	330	1362	0	80,4
% Total de Acerto							78,1

Como os resultados pioraram em relação a solução inicial, foi introduzida a composição com os dois tipos (TABELA 6.9).

TABELA 6.14 : Inserção de PV6

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	1	86	70	1	0	0	54,4
Regular	0	43	311	132	0	0	64,0
Bom	0	3	50	653	99	0	81,1
Ótimo	0	0	3	251	1440	0	85,0
% Total de Acerto							79,3

Uma vez que os resultados obtidos não melhoraram os anteriores, tentou-se a composição de todas as frações de tráfego (TABELA 6.15).

TABELA 6.15 : Inserção de PVL, PV2, PV4, PV5 e PV6

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	2	64	91	1	0	0	40,5
Regular	0	30	341	112	1	2	70,2
Bom	0	3	60	623	116	3	77,4
Ótimo	0	0	4	390	1299	1	76,7
% Total de Acerto							78,1

Em quase todos os testes, os dados de tráfego inseridos, estão atrapalhando o reconhecimento. Para uma melhor comparação entre os testes para o tráfego, os dados totais foram colocados em um gráfico o qual é apresentado na figura a seguir (FIGURA. 6.2) :

TABELA 6.17 : Inserção de EPA4

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	0	114	43	1	0	0	72,2
Regular	0	15	353	118	0	0	72,6
Bom	0	1	84	669	49	2	83,1
Ótimo	0	0	3	661	1030	0	60,8
% Total de Acerto							69,0

TABELA 6.18 : Inserção de EPA2 e EPA4

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	2	108	47	1	0	0	68,4
Regular	0	41	275	170	0	0	56,6
Bom	0	1	33	652	119	0	81,0
Ótimo	0	0	1	359	1334	0	78,7
% Total de Acerto							75,4

Nota-se que com a introdução das variáveis para eixos equivalentes não há influência positiva para a avaliação, visto que esta evolução está muito distante da solução inicial, como é mostrado na FIGURA 6.3.

FIGURA 6.3: Influência do número de eixos equivalentes, calculados com diferentes expoentes do fator de equivalência de operações, na avaliação por IGG

6.2.1.3. Análise do Número Estrutural

Esta análise dos RN foi feita seguindo-se os seguintes critérios:

- inserindo-se apenas o número estrutural corrigido;
- inserindo-se apenas o número estrutural corrigido ajustado;
- inserindo-se o número estrutural corrigido e estrutural corrigido ajustado; e
- retirando-se o número estrutural.

Os dados obtidos com os testes das RN estão respectivamente nas tabelas a seguir:

TABELA 6.22 : Sem SN

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	0	126	30	2	0	0	79,7
Regular	0	26	336	124	0	0	69,1
Bom	0	1	32	670	102	0	83,2
Ótimo	0	0	0	289	1405	0	82,9
% Total de Acerto							80,8

Os resultados totais foram colocados em um gráfico e são exibidos na figura a seguir (FIGURA 6.4).

FIGURA 6.4: Efeito do número estrutural na avaliação da condição por IGG

O melhor resultado foi obtido com a eliminação do número estrutural como parâmetro de entrada para reconhecimento por RN, no caso da avaliação por IGG.

FIGURA 6.5: Efeito da inclusão de novos parâmetros na avaliação por IGG

O parâmetro largura do pavimento é significativo para o reconhecimento das classes de IGG pela rede neural. A inclusão do parâmetro largura da pista melhora a coincidência entre as classes calculadas pela rede neural e pelo IGG. O trincamento médio melhorou a solução inicial, e a chuva acumulada realmente deve ter pouca relação com a avaliação por IGG.

6.2.1.5. Exclusão dos Parâmetros Relativos a IGG

Com o intuito de observar a influência das variáveis que serviram para calcular o IGG, estas foram separadas neste item. Os resultados obtidos são mostrados nas tabelas a seguir:

Os resultados totais de reconhecimento estão representados na figura a seguir:

FIGURA 6.6: Efeito da Eliminação dos Parâmetros de IGG na avaliação

Como pode ser observado através da figura, a desagregação é o fator que não pode ser esquecido e portanto deve pertencer sempre a rede neural em uma análise. Os valores de remendos poderiam ser excluídos, pois sem SPAT conseguiu-se resultados melhores. Isso pode ser explicado pela pouca quantidade de dados de remendos na base de teste.

Os trincamentos de classes 1,2 e 3 não podem ser desprezados, já o de classe 4 poderia não pertencer a RN.

6.2.1.6. Efeito da Exclusão dos Parâmetros Intrínsecos ao Pavimento para Avaliação

Foram considerados para este item aqueles parâmetros que independem do estado do pavimento, sendo dados de projeto ou do clima. Estão

A comparação com os resultados totais está representada na figura a seguir (FIGURA 6.7).

FIGURA 6.7: Efeito dos parâmetros intrínsecos ao pavimento para avaliar a condição

Como pode ser observado, para os dados analisados, a espessura da capa poderia ser eliminada da análise e a cobertura do acostamento não deve ser desprezada. Esta, sendo considerada, deve levar o pavimento a ter comportamento semelhante, facilitando o seu reconhecimento.

6.2.1.7. Efeito da Retirada dos Dados de Ensaio na Avaliação

Neste item estão relacionados os dados de ensaios do banco de dados: deflexão da viga corrigida, irregularidade e o CBR do subleito. Os dados obtidos da RN estão a seguir. Na FIGURA 6.9 estão representados os resultados totais de reconhecimento.

FIGURA 6.8: Efeito da eliminação dos dados de ensaios para avaliação

A irregularidade e a viga Benkelman realmente não contribuem para definir o padrão de IGG, talvez porque o IGG pondere apenas os defeitos enquanto a irregularidade reflete a qualidade do rolamento e a viga, características estruturais. Quanto ao CBR do subleito, a colocação deste parâmetro na rede neural pouco altera o resultado. Isso deve dar-se pelo fato que cada pavimento tem a espessura compatível com o CBR do subleito. Fato similar pode ser observado também para a irregularidade (mais adiante, FIGURA 6.25).

6.2.1.8. Mudando a Base de Dados

Na montagem das redes, os dados numéricos foram introduzidos com valores entre zero e um. Notou-se que os dados produziam resultados melhores utilizando deste recurso. Isso não era permitido para os campos onde os textos eram escritos.

Neste item, para a montagem dos bancos para treino e teste, foram codificadas as descrições dos tipos de capa, base e acostamento. O teste a seguir permite verificar que tal informação não atrapalha o funcionamento da rede, pois a

TABELA 6.46 : RQI * 5

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	2	70	83	3	0	0	44,3
Regular	0	24	212	227	23	0	43,6
Bom	0	7	55	502	241	0	62,4
Ótimo	0	4	18	587	1085	0	64,0
% Total de Acerto							59,5

TABELA 6.47 : RQI * 1.5

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	0	116	41	1	0	0	73,4
Regular	0	60	317	109	0	0	65,2
Bom	0	3	52	615	135	0	76,4
Ótimo	0	0	2	395	1297	0	76,6
% Total de Acerto							74,7

FIGURA 6.9 : Variação do peso da irregularidade na avaliação

Nota-se que com a entrada de valores de irregularidade maiores proporcionalmente, a sua influência não está nos padrões para IGG e a partir disto a RN consegue reconhecer uma quantidade menor de casos.

Um outro teste possível seria melhorar o resultado com outros dois mais significativos, como exemplo a introdução da largura do acostamento e a eliminação do ensaio de viga. Como pode ser observado pela tabela a seguir, a informação não é válida. A combinação dos dois não melhorou o resultado em relação a introdução isolada de cada um. Mesmo assim a solução é melhor que a solução inicial.

TABELA 6.48 : Sem DEFS e Inserindo SHWIDE

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	1	129	27	1	0	0	81,6
Regular	0	33	328	125	0	0	67,5
Bom	0	1	80	608	113	3	75,5
Ótimo	0	0	3	242	1443	6	85,2
% Total de Acerto							79,8

6.2.2. Alteração no Conjunto de Treinamento

Outra possibilidade, com a mudança da base de treino e teste, seria a separação dos dados em conjuntos com mesmo comportamento. Para isso foram escolhidos: tipo de base, tipo de capa e tipo de acostamento.

6.2.2.1. Tipo de Base

Os dados foram separados em: por pedregulho (2033 casos), pedra britada (668 casos), cimentada (434 casos) e solo-cal (17 casos). Os resultados obtidos estão nas tabelas a seguir:

TABELA 6.52 : Base = 'LIMETD'

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	0	0	0	0	0	0	
Ruim	0	0	0	0	0	0	
Regular	0	0	0	0	0	0	
Bom	0	0	0	2	1	0	66,7
Ótimo	0	0	0	0	14	0	100,0
% Total de Acerto							94,1

FIGURA 6.10: Tipo de base na avaliação

Para quase todos os casos não há uma melhora no reconhecimento feito pela RN, a não ser no caso da base tratada com cal. Esta melhoria não pode ser considerada, pois sua amostra foi muito grande (em relação ao conjunto de teste). Foram utilizadas 6 casos para o conjunto de treino num total de 17 pertencentes ao conjunto de teste.

TABELA 6.55 : Capa = 'ACOVL'

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	0	0	0	0	0	0	
Ruim	0	0	0	0	0	0	
Regular	0	0	10	3	0	0	76,9
Bom	0	0	0	23	16	0	59,0
Ótimo	0	0	0	19	160	0	89,4
% Total de Acerto							83,5

TABELA 6.56 : Capa = 'DSTOVL'

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	0	0	0	0	0	0	
Ruim	0	0	2	0	0	0	0,0
Regular	0	0	32	27	0	0	53,3
Bom	0	0	0	97	11	0	89,8
Ótimo	0	0	0	15	236	0	94,0
% Total de Acerto							86,7

Nos pavimentos restaurados há uma maior homogeneização da superfície no início e um menor tempo decorrido desde a recuperação até o momento da observação. Isto está traduzido nas TABELAS 6.55 e 6.56 onde o número de ótimos e bons é grande. Por este motivo o acerto das RN é maior. Para melhor comparação, os dados totais estão na figura a seguir (FIGURA 6.11).

TABELA 6.58 : SHSU = 'SST'

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	0	63	7	0	0	0	90,0
Regular	0	8	121	43	0	0	70,3
Bom	0	0	31	353	69	0	77,9
Ótimo	0	0	0	95	1018	0	91,5
% Total de Acerto							86,1

Para uma melhor comparação, os resultados totais foram colocados no gráfico a seguir.

FIGURA 6.12: Comparação da avaliação com tipos de cobertura de acostamento

Existe um grande reconhecimento para o caso do acostamento ser de tratamento superficial simples. Deve estar relacionado a uma melhor proteção da base e a partir disso um comportamento semelhante.

TABELA 6.61 : Erro de treinamento 0,0045

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	0	118	39	1	0	0	74,7
Regular	0	46	330	110	0	0	67,9
Bom	0	2	49	671	83	0	83,4
Ótimo	0	0	3	349	1342	0	79,2
% Total de Acerto							78,3

TABELA 6.62 : Erro de treinamento 0,0009

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	0	103	54	1	0	0	65,2
Regular	0	35	342	106	0	3	70,4
Bom	0	2	49	642	112	0	79,8
Ótimo	0	0	2	286	1406	0	83,0
% Total de Acerto							79,4

FIGURA 6.13: Erro de treinamento para avaliação

Valores para o erro de treinamento até 0,009 produzem resultados próximos, e neste caso para a avaliação da condição por IGG, devem ser empregados.

6.2.3.2. Validação dos Resultados

Para a validação dos dados a solução inicial utilizou o valor de 0,1. Quando um valor chegasse a 10% do total como parâmetro máximo, era considerado como o correto. Os valores para validação foram tomados de 0,1 até 0,9 e estão nas tabelas a seguir.

TABELA 6.63 : Erro de verificação 0,20

[illegible]

TABELA 6.64 : Erro de verificação 0,30

[illegible]

FIGURA 6.14: Validação dos resultados para avaliação

Como pode ser observado pela figura, os valores menores que 0,4 estão próximos e portanto, qualquer um menor que ele pode ser empregado, obtendo-se os resultados de avaliação por IGG esperados.

6.2.3.3. Alteração na Estrutura da Rede Neural

A solução inicial proposta continha 18 entradas e 5 saídas. Entre estas camadas externas foi colocada uma camada com 14 nós. Este valor foi adotado para verificar o comportamento. A quantidade de camadas ocultas também poderia ser alterada.

6.2.3.3.a. Número de Nós na Camada Oculta

Foram testados desde 12 até 17 nós na camada oculta. Estes valores estão entre os limitantes dos extremos. Os resultados obtidos estão nas tabelas a seguir:

TABELA 6.74 : 16 nós na camada oculta

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	1	136	20	1	0	0	86,1
Regular	0	33	356	97	0	0	73,3
Bom	0	1	40	679	84	1	84,3
Ótimo	0	0	1	333	1360	0	80,3
% Total de Acerto							80,6

TABELA 6.75 : 17 nós na camada oculta

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	4	113	40	1	0	0	71,5
Regular	0	50	262	163	0	11	53,9
Bom	0	1	34	675	95	0	83,9
Ótimo	0	0	1	340	1353	0	79,9
% Total de Acerto							76,5

Para uma comparação, os resultados totais foram colocados em um gráfico (FIGURA 6.12).

FIGURA 6.15: Número de nós na camada oculta

Observa-se que não existe uma tendência para escolha da quantidade de nós. O maior valor obtido 16 pode ser um valor isolado. O modelo de RN, discutido no capítulo 3, aconselha valores intermediários entre o número de entradas e o número de saídas.

6.2.3.3.b. Alteração no Número de Camadas Ocultas

Pode-se introduzir mais camadas além da única oculta. Os números devem ser proporcionais aos extremos. Nas tabelas a seguir estão mostrados os resultados para 2 camadas com variação de nós e para mais camadas.

TABELA 6.79 : 3 camadas ocultas (14,11,9)

IGGxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	0	0	0	0	0	100,0
Ruim	1	102	54	1	0	0	64,6
Regular	0	24	352	106	0	4	72,4
Bom	0	1	39	650	115	0	80,7
Ótimo	0	0	1	280	1413	0	83,4
% Total de Acerto							80,1

Os resultados totais são apresentados na figura a seguir (FIGURA 6.16)

FIGURA 6.16: Alteração na quantidade de camadas ocultas para avaliação

Esta melhora no reconhecimento com mais camadas, deve estar relacionada a grande quantidade de fatores que devem influenciar no IGG. Segundo CYBENKO (1989), não necessariamente deveria acontecer.

FIGURA 6.17: Tamanho da amostra para avaliação

A alteração, com diminuição, no tamanho da amostra, realmente não contribuiu, pois a grande parte dos casos necessários para o reconhecimento, não está contemplada no conjunto de treinamento. O aumento não trouxe melhoria ao resultado, e pode ser explicado pela composição inadequada da seleção aleatória.

6.2.4. Melhores e Piores Casos na Análise por IGG

São apresentados agora os casos considerados os melhores e piores no reconhecimento do IGG pela RN. Para esta seleção, o critério de escolha, foi o total em porcentagem de acerto.

Na TABELA 6.82 estão os melhores casos:

TABELA 6.82 : Melhores casos de IGG

Caso	Valor total encontrado (em porcentagem)
Inserção de CRX	79,7
Sem MP	79,7
Inserção de SHWIDE	79,9
Inserção de WIDTH	80,6
Sem SN	80,8
Sem H1	80,9
Sem DEFS	81,6
Sem RQI	84,9

Pode ser observado que os dados de ensaios de irregularidade e viga Benkelman, podem ser esquecidos. A espessura da capa e o número estrutural não influem no conjunto das variáveis que representam a avaliação do pavimento por IGG.

Não podem ser esquecidos na análise a largura do pavimento e a cobertura do acostamento. Já a inclusão dos valores para a média de chuva, poderiam ser desprezados. Na TABELA 6.83 estão os piores casos:

TABELA 6.83 : Piores casos de IGG

Caso	Valor total encontrado (em porcentagem)
Inserção de EPA4	69
Sem RAV	71,7
Inserção de PVL	73,3
Substituição de MP por CP	74,2
Inserção de EPA2 e EPA4	75,4
Sem RDMN	76,3
Sem SHSU	76,6
Inserção de EPA2	76,8
Inserção de PV5	76,8

Quando se introduz algum dado de tráfego, aos quais, o IGG não está relacionado, o reconhecimento é pior. Por outro lado, não se deve esquecer a desagregação e o afundamento das trilhas de roda, dados importantes para o IGG.

A capa do acostamento também deve trazer comportamento padrão nos defeitos analisados por IGG.

6.3. Análise da Avaliação da Condição por Irregularidade Comparada com RN

No item 6.2, as RN foram comparadas com a avaliação feita por IGG. Neste item a comparação é com a medida da irregularidade do trecho.

6.3.1. Análise Paramétrica

Para se encontrar a melhor forma de compor uma rede neural são necessários vários testes. Os resultados serão comparados com a seguinte solução inicial:

TABELA 6.83 : Solução inicial para QI

QIxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	4	0	0	0	0	60,0
Ruim	1	52	38	76	0	0	31,1
Regular	0	54	144	277	6	0	29,9
Bom	0	37	145	466	200	0	55,0
Ótimo	0	6	102	338	1197	0	72,9
% Total de Acerto							59,2

A rede neural reconhece corretamente 59,2% dos casos das respostas da irregularidade.

6.3.1.1. Analise da Idade

Na solução inicial, a rede neural foi montada com apenas a variável idade de construção. Neste item esta idade foi substituída e colocada em conjunto com outras medidas de tempo da base de dados.

Inicialmente, a idade inicial foi substituída pela idade de reconstrução e idade da última selagem. Os resultados estão nas tabelas a seguir.

TABELA 6.84 : Substituição de AGE0 por AGER

QIxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	7	3	0	0	0	0	70,0
Ruim	1	54	39	73	0	0	32,3
Regular	0	57	133	271	19	1	27,7
Bom	0	35	137	417	259	0	49,2
Ótimo	0	7	91	345	1199	1	73,0
% Total de Acerto							57,5

TABELA 6.85: Substituição de AGE0 por AGES

QIxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	4	0	0	0	0	60,0
Ruim	0	57	40	70	0	0	34,1
Regular	0	49	146	261	25	0	30,4
Bom	0	31	139	372	306	0	43,9
Ótimo	0	6	86	313	1238	0	75,3
% Total de Acerto							57,8

Para estas duas tentativas, o resultado obtido pelas RN, reconheceu uma quantidade de casos menor que a solução inicial. Introduziu-se então novamente a idade inicial no conjunto. A seguir são exibidas as tabelas com os resultados.

TABELA 6.86: Inserção de AGER

QIxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	3	1	0	0	0	60,0
Ruim	1	59	24	83	0	0	35,3
Regular	0	69	129	255	28	0	26,8
Bom	0	62	115	399	271	1	47,1
Ótimo	0	12	83	339	1202	7	73,2
% Total de Acerto							57,0

TABELA 6.87 : Inserção de AGES

QIxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	4	0	0	0	0	60,0
Ruim	1	49	38	77	2	0	29,3
Regular	0	48	142	246	45	0	29,5
Bom	0	32	132	359	325	0	42,3
Ótimo	0	6	75	334	1228	0	74,7
% Total de Acerto							59,2

Os resultados também não melhoraram. A seguir é apresentado o resultado com uma rede neural sem nenhum fator tempo. A porcentagem de acerto também é inferior a solução inicial.

TABELA 6.88 : Sem AGE0

QIxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	4	0	0	0	0	60,0
Ruim	0	46	36	84	0	1	27,5
Regular	0	50	141	271	19	0	29,3
Bom	0	38	128	419	263	0	49,4
Ótimo	0	4	85	330	1224	0	74,5
% Total de Acerto							58,3

Para uma melhor comparação, os dados totais foram colocados em um gráfico. (FIGURA 6.18)

FIGURA 6.18: Efeito da idade na avaliação da condição por irregularidade

Pelos resultados descritos acima, a irregularidade é melhor compreendida quando está associada a idade de construção.

TABELA 6.96 : Inserção de PV6

QI x RN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	4	0	0	0	0	60,0
Ruim	1	54	45	67	0	0	32,3
Regular	0	48	138	272	23	0	28,7
Bom	0	23	149	387	289	0	45,6
Ótimo	0	3	102	311	1227	0	74,7
% Total de Acerto							57,5

TABELA 6.97 : Inserção de PVL, PV2, PV4, PV5 e PV6

QI x RN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	4	0	0	0	0	60,0
Ruim	2	53	42	70	0	0	31,7
Regular	0	30	169	265	15	2	35,1
Bom	0	10	177	443	218	0	52,2
Ótimo	0	0	108	348	1183	4	72,0
% Total de Acerto							58,9

Os resultados mostram que não houve maior reconhecimento por parte das RN. A FIGURA 6.19 mostra uma comparação dos resultados totais dos testes com fatores de tráfego.

TABELA 6.99 : Inserção de EPA4

QI x RN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	3	1	0	0	0	60,0
Ruim	0	40	49	78	0	0	24,0
Regular	0	46	159	273	3	0	33,1
Bom	0	34	156	540	118	0	63,7
Ótimo	0	7	118	558	958	2	58,3
% Total de Acerto							54,1

TABELA 6.100 : Inserção de EPA2 e EPA4

QI x RN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	4	0	0	0	0	60,0
Ruim	2	53	27	85	0	0	31,7
Regular	0	46	137	276	22	0	28,5
Bom	0	44	104	441	259	0	52,0
Ótimo	0	3	88	380	1172	0	71,3
% Total de Acerto							57,4

As porcentagens finais de acerto diminuíram em relação a solução inicial proposta, portanto não existe uma influência positiva para este caso. O gráfico com a comparação é ilustrado pela FIGURA 6.20.

Os resultados totais obtidos foram colocados em um gráfico, o qual é exibido a seguir (FIGURA 6.21).

FIGURA 6.21: Efeito do número estrutural na avaliação da condição por irregularidade

A solução inicial apresenta melhores resultados no reconhecimento da irregularidade, que as outras soluções criadas.

6.3.1.4. Inclusão de Novos Parâmetros na Análise

Outros parâmetros pertencentes a base de dados foram introduzidos. Os resultados obtidos estão nas tabelas a seguir:

TABELA 6.108 : Inserção de CRX

QIxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	4	0	0	0	0	60,0
Ruim	2	59	24	82	0	0	35,3
Regular	0	65	121	270	25	0	25,2
Bom	0	49	113	397	289	0	46,8
Ótimo	0	3	84	327	1229	0	74,8
% Total de Acerto							57,5

Os valores totais obtidos estão comparados com a solução inicial na figura a seguir:

FIGURA 6.22: Efeito da inclusão de novos parâmetros na avaliação por irregularidade

Como podemos observar pela figura, nenhum dos parâmetros ajudou a melhorar o reconhecimento nas novas RN propostas.

TABELA 6.117 : Sem RDMN

QIxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	3	1	0	0	0	60,0
Ruim	0	43	37	86	0	1	25,7
Regular	0	57	131	286	7	0	27,2
Bom	0	39	121	466	222	0	55,0
Ótimo	0	8	84	333	1218	0	74,1
% Total de Acerto							59,2

FIGURA 6.23: Efeito da eliminação dos parâmetros de IGG na avaliação por irregularidade

Pela observação da figura, conclui-se que a desagregação é o fator que produz pior reconhecimento pelas RN, portanto, para este caso, poderia ser desprezado. Os fatores que devem sempre ser analisados são o jacaré e os remendos.

As painéis constantes na base utilizada estavam em pequeno número e por isso não influenciaram tanto. Observa-se também que as medidas que não alteram o perfil de rolamento, não tem muita influência.

Para uma melhor visualização, a comparação com a solução inicial, está representada na figura a seguir.

FIGURA 6.24: Efeito dos parâmetros intrínsecos ao pavimento para avaliar a condição

Como é possível se observar, a espessura, a base e a cobertura do acostamento poderiam ser consideradas para melhorar o resultado. A chuva não deve ter relação alguma e o tipo de capa não influencia no reconhecimento pelas RN.

6.3.1.7. Efeito da Retirada dos Dados de Ensaio na Avaliação

Neste item estão incluídos: deflexão da viga corrigida, irregularidade e o CBR do Subleito. Os resultados obtidos estão nas tabelas a seguir. Na FIGURA 6.25 estão representados os resultados totais de reconhecimento.

FIGURA 6.25: Efeito da eliminação dos dados de ensaios para avaliação por irregularidade

Como é esperado, sem os valores de irregularidade o reconhecimento realmente diminuiu. Para o caso do CBR do subleito, o reconhecimento melhorou, pois observando o pavimento como um conjunto, dependente dos valores de CBR, o pavimento foi projetado e executado para conseguir um determinado desempenho, e este é que está sendo reconhecido pelas RN.

6.3.1.8. Mudando a Base de Dados

Na montagem das redes, foi feita uma normalização dos dados. Esta produzia resultados melhores. Isso não foi feito para os campos onde as variáveis eram textos escritos.

Neste item estes campos de textos não numéricos foram codificados com valores entre zero e um. O teste a seguir permite verificar se a base poderia ser alterada com a codificação dos campos.

3

2

5

1

TABELA 6.128 : RQI * 5

QI x RN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	8	2	0	0	0	0	80,0
Ruim	0	74	55	38	0	0	44,3
Regular	0	27	183	271	6	0	38,0
Bom	0	2	109	701	36	0	82,7
Ótimo	0	0	21	309	1313	0	79,9
% Total de Acerto							72,4

TABELA 6.129 : RQI * 1.5

QI x RN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	4	0	0	0	0	60,0
Ruim	0	52	53	62	0	0	31,1
Regular	0	56	152	273	0	0	31,6
Bom	0	32	147	513	156	0	60,5
Ótimo	0	35	60	272	1276	0	77,7
% Total de Acerto							63,5

FIGURA 6.26: Variação do peso da irregularidade na avaliação

FIGURA 6.27: Tipo de base na avaliação por irregularidade

Para o caso da base tratada com cal, a melhoria no reconhecimento pela RN é explicada pelo tamanho da amostra em relação ao conjunto de teste. Observa-se, também, que a base de pedra britada produz melhor reconhecimento. Deve estar relacionado a uma melhor padronização da base.

6.3.2.2. Tipo da Capa

Foram separados os conjuntos com tipos de capas iguais: concreto asfáltico (866 casos), tratamento superficial duplo (1634 casos), recobrimento com concreto asfáltico (231 casos) e recobrimento com tratamento superficial duplo (421 casos). Os resultados obtidos estão nas tabelas a seguir.

TABELA 6.137 : Capa = 'DSTOVL'

QIxRN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	0	0	0	0	0	0	
Ruim	0	0	1	1	0	0	0,0
Regular	0	0	5	9	0	0	35,7
Bom	0	0	10	42	2	0	77,8
Ótimo	0	0	18	87	246	0	70,1
% Total de Acerto							69,6

FIGURA 6.28: Tipo de capa na avaliação por irregularidade

Observa-se, pela figura, um melhor reconhecimento pela RN. Um dos motivos do reconhecimento é que o conjunto de treino é maior proporcionalmente à solução inicial. Outro motivo é o comportamento semelhante destes conjuntos para a irregularidade.

2

2

FIGURA 6.29: Comparação da avaliação com tipos de cobertura de acostamento

O acostamento sendo recoberto por tratamento simples deve contribuir para a base ficar mais protegida, evitando assim muitas mudanças no seu comportamento. Com isso o seu reconhecimento torna-se facilitado.

6.3.3. Análise dos Parâmetros da Rede Neural para Avaliação

São analisados neste item os parâmetros possíveis de serem modificados por um usuário de RN. São possíveis de modificação: o erro de treinamento, a validação dos resultados, o número de camadas ocultas e o tamanho da amostra.

6.3.3.1. Erro de Treinamento

Os erros de treinamento utilizados variaram de 0,0009 a 0,09. A solução inicial foi treinada com erro de 0,009. Os resultados obtidos estão nas tabelas a seguir.

TABELA 6.143 : Erro de treinamento 0,0009

QI _x RN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	4	0	0	0	0	60,0
Ruim	0	54	45	68	0	0	32,3
Regular	0	52	147	269	12	1	30,6
Bom	0	27	146	410	265	0	48,3
Ótimo	0	3	109	288	1241	2	75,5
% Total de Acerto							59,0

FIGURA 6.30: Erro de treinamento para avaliação

Observa-se, pela FIGURA 6.30 que valores menores que 0,009 devem ser utilizados.

6.3.3.2. Validação dos Resultados

Para se obter a validação dos dados, a solução inicial utilizou o valor de 0,1. Quando um valor chegasse a 10% do total como parâmetro máximo, era considerado como correto. Os valores para validação foram tomados de 0,2 até 0,9 e

FIGURA 6.31: Validação dos resultados para avaliação

Valores até 0,4 para a validação se mantêm muito próximos e portanto devem ser os utilizados.

6.3.3.3. Alteração na Estrutura da Rede Neural

A solução inicial proposta continha 19 entradas e 5 saídas. Entre as camadas externas foi colocada uma camada com 14 neurônios artificiais. Este valor foi adotado para a verificação do comportamento. A quantidade de camadas ocultas também pode ser alterada.

6.3.3.3.a. Número de Nós na Camada Oculta

Foram testados desde 12 até 17 nós na camada oculta. Os resultados estão nas tabelas a seguir.

TABELA 6.155 : 16 nós na camada oculta

QI x RN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	4	0	0	0	0	60,0
Ruim	1	48	53	65	0	0	28,7
Regular	0	63	136	267	15	0	28,3
Bom	0	48	124	445	231	0	52,5
Ótimo	0	7	104	333	1198	1	72,9
% Total de Acerto							58,2

TABELA 6.156 : 17 nós na camada oculta

QI x RN	Péssimo	Ruim	Regular	Bom	Ótimo	N Ident.	%Acerto
Péssimo	6	4	0	0	0	0	60,0
Ruim	3	54	35	75	0	0	32,3
Regular	1	51	134	290	5	0	27,9
Bom	0	42	101	486	214	5	57,3
Ótimo	0	13	67	328	1229	6	74,8
% Total de Acerto							60,6

Para uma melhor comparação, os resultados totais de reconhecimento foram colocados em um gráfico.

Para uma melhor visualização da comparação entre os valores totais, estes estão representados na figura a seguir.

FIGURA 6.33: Alteração na quantidade de camadas ocultas para avaliação

O melhor caso de reconhecimento foi obtido para duas camadas ocultas, sendo que a primeira continha 14 nós e a segunda 9 nós.

6.3.3.3.c. Alteração na Quantidade de Casos na Amostra

Outra alteração possível é a mudança no conjunto de treinamento, com a redução e o incremento de casos.

Para uma nova amostra menor, as quantidades adotadas foram as seguintes: 6 para péssimo, 10 para ruim, 18 para regular, 24 para bom e 27 para ótimo. O tempo de treinamento foi de 48 segundos. O resultados estão nas tabelas a seguir.

FIGURA 6.34: Tamanho da amostra para avaliação

Como para item 6.2.3.3.c, tais mudanças no tamanho da amostra não contribuíram para o incremento na quantidade de casos reconhecidos.

6.3.4. Melhores e Piores Casos na Análise por Irregularidade

São apresentados a seguir, os casos considerados os melhores e piores no reconhecimento da irregularidade pela RN. Para esta seleção o critério escolhido foi o total em porcentagem de reconhecimento.

Na TABELA 6.163 estão os melhores casos:

TABELA 6.163 : Melhores casos para irregularidade

Caso	Valor total encontrado (em porcentagem)
Sem CR4	59,4
Sem SGCBR	59,4
Sem MP	59,5
Inserção de NHX	59,7
Sem CR1	60,2
Sem CR3	61,5
Sem RAV	64,3

Muitos dos dados relacionados a IGG podem ser excluídos, como também a média de chuva que mais uma vez não contribuiu com o reconhecimento.

O CBR do subleito não deve ter relação com a irregularidade pois o pavimento calculado permite rolamento independente dele.

Possivelmente os dados de desagregação (RAV) não estão contribuindo de maneira significativa para o reconhecimento, pois seu valor médio na base utilizada é de apenas 5,67% (TABELA 4.3).

Os piores casos estão na TABELA 6.164

TABELA 6.164 : Piores casos de irregularidade

Caso	Valor Total encontrado (em porcentagem)
Inserção de EPA4	54,1
Sem RQI	54,2
Inserção de AGES e AGE0	56,7
Inserção de AGER	57
Inserção de SNA e SND	57,3
Inserção de EPA2 e EPA4	57,4
Substituição de AGE0 por AGER	57,5

Como deve ser esperado a falta do RQI medido não favorece o reconhecimento. A idade do pavimento não tem influência alguma, como também a relação com o número de eixos equivalentes que já passaram pelo pavimento. A colocação na rede neural dos valores dos números estruturais pioram o reconhecimento da irregularidade.

6.4. Análise da Avaliação da Condição por IGG e Irregularidade Comparada com RN

Para se demonstrar outra aplicabilidade das RN na avaliação da condição do pavimentos, os dados foram agrupados e estes foram comparados pelos dois métodos combinados, com o objetivo de compor o conhecimento de especialistas.

Os dados foram comparados, inicialmente, pelos métodos de IGG e irregularidade, e depois disso, com o somatório de acerto de IGG e irregularidade, com a RN.

6.4.1. Análise da avaliação da condição do pavimento de IGG e irregularidade

Para o caso da classificação dos trechos da malha viária, foram usadas duas formas de avaliação: o IGG empregado na avaliação das superfícies dos pavimentos, e a irregularidade dos pavimentos (para avaliação da funcionalidade da via).

Nestas duas formas de avaliação da condição, os trechos analisados (3149) foram classificados, obtendo-se os resultados apresentados na TABELA 6.165:

TABELA 6.165 : Comparação de IGG com irregularidade

IGGxQI	Péssimo	Ruim	Regular	Bom	Ótimo	%Acerto
Péssimo	6	0	0	0	0	100,0
Ruim	3	50	52	41	12	31,6
Regular	1	53	151	147	134	31,1
Bom	0	41	163	267	334	33,2
Ótimo	0	23	115	393	1163	68,7
% Total de Acerto						52,0

Como pode ser observado, os dois métodos especialistas não produzem resultados exatos, pois cada método analisa o pavimento segundo um aspecto. O IGG analisa o pavimento através da sua estrutura, e a irregularidade através da sua funcionalidade ou conforto da utilização da via por um veículo.

Conforme a Tabela acima a porcentagem de acerto de IGG em relação a irregularidade, é de apenas 52,0%, apesar dos casos Péssimos (6 para o IGG e 10

para o QI) estarem próximos em sua quantidade total, a sua parte em relação ao conjunto é pequena.

Observa-se, pela tabela acima, que a rede neural proposta consegue reconhecer melhor o IGG (TABELA 6.1), que o outro método especialista existente (no caso a irregularidade), onde 78,4% dos casos são reconhecidos corretamente.

Pode-se, também, analisar a rede neural com o critério do segundo método especialista (irregularidade mostrada na TABELA 6.83) onde são reconhecidos 59,2% dos casos. Neste caso existe maior reconhecimento que os 52,0% de concordância entre os métodos de avaliação da condição de IGG e irregularidade.

6.4.2. Análise de IGG somado com irregularidade comparado com RN

Com os resultados dos itens 6.2 e 6.3, foram separados neste item, os totais de acertos somados para irregularidade e IGG com o objetivo de verificar, no conjunto de critérios de avaliação, quais variáveis melhoram ou pioram o comportamento.

6.4.2.1. Piores casos

Os valores somados são menores que a solução inicial proposta, e então conclui-se que estas variáveis no conjunto, não deveriam ser incluídas na análise de avaliação da condição do pavimento.

TABELA 163: Somatório com os piores casos

	IGG x RN	QI x RN
Inserção de EPA4	69	54,1
Inserção de PVL	73,3	58,9
Inserção de EPA2 e EPA4	75,4	57,4
Substituição de MP por CP	74,2	58,7
Inserção de SNA e SND	77,2	57,3
Inserção de EPA2	76,8	58
Sem SHSU	76,6	58,2

Pelos resultados tabelados acima, 4 dessas variáveis são dados de tráfego, como por exemplo, eixos equivalentes no trecho e a porcentagem de veículos leves. Como se trata de uma avaliação da condição, que é um dado num determinado tempo, a influência localizada deste tipo de informação deve ser pequena.

Outra medida é a substituição da média de chuva anual pela acumulada, a qual não é muito significativa, o que também não tem muita razão pois além de os dados serem medidos semestralmente, a chuva acumulada não tem influência na avaliação.

A inserção de mais dois números estruturais (SNA e SND) na rede neural, aumentando a influência destes dados, também não trouxe benefício.

O dado mais importante é que não se pode desprezar a cobertura do acostamento pois, se isso for feito, os resultados pioram sensivelmente.

FIGURA 6.35 : Piores casos de somatório de IGG e irregularidade

6.4.2.2. Melhores casos

TABELA 6.166: Somatório com os melhores casos

	IGG x RN	QI x RN
Sem SGCBR	78,9	59,4
Inserção de WIDTH	80,6	57,8
Sem CR3	77,2	61,5
Sem SN	80,8	58,1
Sem RQI	84,9	54,2
Sem MP	79,7	59,5
Sem H1	80,9	58,3
Sem DEFS	81,6	58

Na tabela acima, observa-se que a retirada dos dados de ensaios, CBR, RQI, MP e DEFS, trazem benefícios ao reconhecimento.

O reconhecimento para o IGG aumentou sensivelmente devido ao RQI. Efeito contrário, com a diminuição, aconteceu para a irregularidade.

A largura WIDTH realmente deve ser analisada em conjunto, representando o segundo melhor caso. Pode ser resultado de um confinamento melhor na base, trazendo um comportamento mais uniforme na capa, facilitando o reconhecimento.

O número estrutural SN, não colabora para o reconhecimento para a avaliação da condição.

A eliminação do trincamento classe 3 poderia ser usado, nas RN, pelo grande quantidade de casos reconhecidos pela da irregularidade.

A MP (precipitação mensal), pode ser desprezada, pois sem suas medidas os resultados melhoraram. O valor médio de uma variável, não identifica o comportamento dos trechos no tempo, não se pode utilizar MAP.

FIGURA 6.36 : Melhores casos de somatório de IGG e irregularidade

CAPÍTULO 7

DESCRIÇÃO DO PROCEDIMENTO PARA PROJETO DE RESTAURAÇÃO DE PAVIMENTOS

7.1. Introdução

No Capítulo 5 foi proposto um procedimento para se utilizar as RN no processo de avaliação da condição do pavimento. Com o intuito de se mostrar que as RN podem ser aplicadas de diversas formas em pavimentos, é proposto neste capítulo uma outra forma de emprego das redes, no projeto de restauração do pavimento.

7.2. Projeto de Restauração do Pavimento

São apresentadas a rede neural proposta, o esquema de treinamento e alguns fatores que definem um melhor resultado para aplicação do método.

7.2.1. Rede Neural Proposta

Foram utilizadas redes do tipo Multi-Camadas Perceptrons com algoritmo de aprendizagem *Backpropagation* (MLP-*Backpropagation*), pelos mesmos motivos do item 5.2.1.

Para se comparar os resultados com os obtidos para a avaliação da condição do pavimento, foi utilizada a mesma estrutura do modelo de rede neural. Para isso, empregou-se no processo as mesmas 18 entradas:

TABELA 7.1: Variáveis para a camada de entrada	
1	ano de construção
2	média anual de chuva
3	trincas de classe 1
4	trincas de classe 2
5	trincas de classe 3
6	trincas de classe 4
7	jacaré
8	panelas
9	desagregação
10	viga Benkelman
11	afundamento da trilha de roda
12	irregularidade
13	CBR
14	tipo da capa;
15	espessura da capa do pavimento
16	tipo da base do pavimento
17	tipo do acostamento
18	número estrutural

Utilizando a norma de projeto de restauração, as saídas foram escolhidas de modo a representar as tarefas a serem executadas no pavimento, conforme a tabela a seguir:

TABELA 7.2: Variáveis para a camada de saída	
1	Nada a fazer
2	Selar
3	Tratar
4	Recapar com Concreto Asfáltico
5	Reconstruir

O esquema proposto é ilustrado pela FIGURA 7.1.

FIGURA 7.1: Esquema de RN proposto para o projeto de reconstrução do pavimento

7.2.2. Esquema de Treinamento

O projeto de restauração dos pavimentos, utilizados neste procedimento, segue o critério da DNER-PRO 159/85. Entre os 3149 casos, foram selecionados aleatoriamente, alguns casos (por volta de 100) calculados pela mesma norma (FIGURA 7.2).

Estes casos foram calculados através de um conjunto de programas desenvolvidos, que a partir dos resultados obtidos, que já selecionavam os casos para o arquivo de treinamento.

FIGURA 7.2: Esquema para treinamento

O arquivo MAINTINT, definido no Capítulo 4, foi utilizado também como critério de classificação, mas os resultados divergiam da norma. A manutenção realmente executada e contida no arquivo não deve ter seguido realmente as indicações da norma.

7.2.3. Outros Fatores Importantes

Como para o item 5.2.3, feita a classificação, todas as variáveis (18) do conjunto de treinamento foram convertidas em valores entre zero e um, fazendo uma proporção entre os valores máximos e mínimos do conjunto inteiro.

Foi montado também um “conjunto de treinamento”, com ordenação seqüencial e aproximadamente 3% da base de dados, e em cada registro foi anexado

um novo campo, para indicação da categoria da classificação da atividade a ser realizada no pavimento, conforme descrição apresentada na TABELA 7.2.

Utilizando o mesmo equipamento, um microcomputador PC 486DX4 100, o programa de treinamento foi acionado com o conjunto criados e as RN eram montadas em aproximadamente um minuto, como para a avaliação. Com a base já convertida entre zero e um, o tempo de verificação não se alterou, por volta de 5 segundos.

A verificação do método é feita com os resultados da RN concordando com o máximo de resultados em relação ao seu método de classificação, no caso o cálculo feito pelas regras da norma. A quantidade de casos concordantes estão no Capítulo 8.

O resultado da rede é um valor para cada categoria em forma de um vetor. Os valores são valores entre zero e um e indicam quanto seria encaixado por categoria. A porcentagem maior é encarada como a categoria identificada. Um possível exemplo, poderia ser: 0,03 para nada a fazer, 0,10 para selar, 0,15 para tratar, 0,45 para recapear e 0,15 para reconstruir. A soma deve ser próxima da unidade. O maior valor é encarado como correto, então este trecho deve ser recapeado.

Como para a avaliação da condição, o limiar de aceitação de respostas foi identificado neste trabalho como validação do resultado.

CAPÍTULO 8

ANÁLISE DO PROJETO DE RESTAURAÇÃO UTILIZANDO REDES NEURAIS

8.1. Introdução

No Capítulo 2 foi apresentado um método para projeto de restauração de um pavimento. Como foi descrito, o processo não é simples e podem ser necessárias várias fases para se chegar a um resultado final. No Capítulo 7 foi descrito um processo de aprendizagem adotado neste trabalho.

Como para a avaliação da condição é necessário um refinamento da rede. Utilizando os métodos de aprendizagem e projeto de restauração, foram montadas diversas RN. A dificuldade é selecionar os parâmetros que deverão pertencer a esta rede, quais são as formas de resposta.

São apresentados, neste capítulo, os resultados de diversas RN, que após terem sido montadas, foram testadas com a totalidade dos dados a que se identificam, mantendo as mesmas variáveis para o conjunto de entrada.

O capítulo foi dividido em 2 partes principais, onde na primeira parte são analisados os parâmetros da estrada e, na segunda, os parâmetros das RN.

A apresentação é feita através de 2 tipos de representação: a) tabelas, onde estão agrupados os dados calculados pela norma (em linhas) e o valor encontrado pela RN (em colunas); b) as tabelas; relativas a determinados temas, foram agrupadas e os resultados comparativos são exibidos em gráficos.

Para o início da análise paramétrica foi proposta uma amostra padrão, com 123 casos, 18 entradas (descritas no Capítulo 7) e 5 saídas as quais são: Nada a Fazer, Selar, Tratar, Recapear e Reconstruir. Os resultados da rede neural para os 3149 casos está mostrado na TABELA 8.1.

TABELA 8.1 : Solução inicial para recuperação

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1907	56	60	283	2	82,6
Selar	0	108	0	1	0	99,1
Tratar	0	0	69	7	0	90,8
Recapear	23	37	121	475	0	72,4
% Total de Acerto						81,3

8.2. Análise dos Parâmetros de Pavimentação

Para demonstrar a aplicabilidade de RN em problemas de projeto de pavimentos, os dados foram agrupados, e para cada grupo as variáveis do problema foram sendo retiradas e inseridas, na intenção de se identificar a influência das mesmas com relação ao conjunto.

8.2.1. Análise da Idade na Recuperação

Na primeira solução, apenas a idade inicial do pavimento foi utilizada, e neste caso desejava-se saber se ela proporcionava um melhor acerto do que os outros.

Para se identificar quais os parâmetros, referentes a idade, coletados deveriam ser utilizados, estes foram testados pertencendo ou não as RN. Os resultados são apresentados a seguir. Inicialmente, foram feitas as substituições da idade de construção pelas idades de recuperação e selagem.

TABELA 8.2 : Substituição de AGE0 por AGER

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1951	48	46	262	1	84,5
Selar	2	105	0	2	0	96,3
Tratar	1	0	67	8	0	88,2
Recapear	23	37	115	480	1	73,2
% Total de Acerto						82,7

TABELA 8.3 : Substituição de AGE0 por AGES

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1965	65	85	183	10	85,1
Selar	0	107	0	1	1	98,2
Tratar	0	0	68	8	0	89,5
Recapear	23	40	145	446	2	68,0
% Total de Acerto						82,1

Nota-se um resultado melhor para a rede na qual a data de construção foi substituída pela idade de reconstrução. A seguir foram introduzidas as mesmas datas na rede, e o resultado é exibido a seguir (TABELAS 8.4 e 8.5).

TABELA 8.4 : Inserção de AGER

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1980	66	58	199	5	85,8
Selar	1	106	0	2	0	97,2
Tratar	0	0	71	5	0	93,4
Recapear	32	38	146	437	3	66,6
% Total de Acerto						82,4

TABELA 8.5 : Inserção de AGES

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1983	46	41	218	20	85,9
Selar	0	107	0	0	2	98,2
Tratar	0	0	69	7	0	90,8
Recapear	37	41	115	448	15	68,3
% Total de Acerto						82,8

Foi verificado, também, se a presença da idade inicial não estaria influenciando o resultado de maneira negativa. Conforme a tabela a seguir, a presença da variável AGE0 - idade inicial, é necessária para o projeto de recuperação.

TABELA 8.6 : Sem AGE0

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1982	52	118	143	13	85,9
Selar	0	106	0	1	2	97,2
Tratar	1	0	67	8	0	88,2
Recapear	32	41	156	407	20	62,0
% Total de Acerto						80,7

Os resultados totais são apresentados pela figura a seguir, FIGURA

8.1.

FIGURA 8.1: Efeito da idade na recuperação

Os melhores resultados foram conseguidos nos testes com a inserção da idade de selagem e com a substituição da idade de construção pela idade de recuperação.

8.2.2. Análise do Tráfego para Recuperação

Para se verificar a necessidade de introdução de parâmetros relativos a tráfego, foram introduzidos na rede os dados relativos ao número de veículos leves e pesados, TABELAS 8.7 e 8.8.

TABELA 8.7 : Inserção de NHX

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1936	63	48	222	39	83,9
Selar	1	108	0	0	0	99,1
Tratar	0	0	76	0	0	100,0
Recapear	52	39	120	441	4	67,2
% Total de Acerto						81,3

TABELA 8.8 : Inserção de NLV

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1858	79	56	270	45	80,5
Selar	0	108	1	0	0	99,1
Tratar	0	0	73	3	0	96,1
Recapear	23	40	123	464	6	70,7
% Total de Acerto						79,5

Nos dois casos anteriores, não houve uma melhoria no resultado da solução inicial. Com a intenção de verificar se uma determinada categoria de tráfego influenciaria no resultado, foram sendo introduzidas as categorias.

TABELA 8.9 : Inserção de PVL

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1975	39	43	250	1	85,6
Selar	3	106	0	0	0	97,2
Tratar	0	0	69	7	0	90,8
Recapear	35	41	130	450	0	68,6
% Total de Acerto						82,6

TABELA 8.10 : Inserção de PV2

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1995	54	52	207	0	86,4
Selar	0	108	0	1	0	99,1
Tratar	0	0	68	8	0	89,5
Recapear	44	41	95	471	5	71,8
% Total de Acerto						83,9

TABELA 8.11 : Inserção de PV4

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2020	48	34	199	7	87,5
Selar	2	107	0	0	0	98,2
Tratar	1	0	70	5	0	92,1
Recapear	38	39	132	442	7	67,4
% Total de Acerto						83,8

TABELA 8.12: Inserção de PV5

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1981	53	47	220	7	85,8
Selar	1	108	0	0	0	99,1
Tratar	0	0	71	5	0	93,4
Recapear	17	42	165	429	3	65,4
% Total de Acerto						82,2

TABELA 8.13: Inserção de PV6

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2010	71	40	187	0	87,1
Selar	0	109	0	0	0	100,0
Tratar	0	0	74	2	0	97,4
Recapear	34	42	127	453	0	69,1
% Total de Acerto						84,0

Os melhores resultados foram conseguidos com a introdução das categorias PV2 e PV6, onde estas devem ser mais representativas do processo de restauração.

Foram também introduzidas as categorias em grupos, conforme mostram as TABELAS 8.14 e 8.15.

TABELA 8.14 : Inserção de NHX e NLV

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1990	24	108	158	28	86,2
Selar	5	103	1	0	0	94,5
Tratar	0	0	70	6	0	92,1
Recapear	38	32	182	377	27	57,5
% Total de Acerto						80,7

TABELA 8.15 : Inserção de PVL, PV2, PV4, PV5 e PV6

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2003	90	34	100	81	86,8
Selar	0	106	0	0	3	97,2
Tratar	1	0	72	2	1	94,7
Recapear	51	40	85	412	68	62,8
% Total de Acerto						82,3

Os resultados totais são mostrados no gráfico a seguir:(FIGURA 8.2)

FIGURA 8.2: Efeito do tráfego na recuperação

Nota-se pela figura anterior, a grande influência dos parâmetros de tráfego, com grande parte de seus valores influenciando a porcentagem de acerto positivamente, como na norma.

Outro fator que poderia ser relativo ao tráfego, é o número de eixos equivalentes que estão tabelados a seguir:

TABELA 8.16 : Inserção de EPA2

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2007	79	59	160	3	87,0
Selar	2	106	1	0	0	97,2
Tratar	0	0	73	3	0	96,1
Recapear	44	46	161	403	2	61,4
% Total de Acerto						82,2

TABELA 8.17 : Inserção de EPA4

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1853	48	56	331	20	80,3
Selar	4	105	0	0	0	96,3
Tratar	0	0	75	1	0	98,7
Recapear	34	33	176	412	1	62,8
% Total de Acerto						77,6

A inclusão dos dois tipos de eixos equivalentes resultou a tabela a seguir:

TABELA 8.18 : Inserção de EPA2 e EPA4

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1983	53	41	215	16	85,9
Selar	1	106	0	2	0	97,2
Tratar	0	0	67	8	1	88,2
Recapear	27	37	84	482	26	73,5
% Total de Acerto						83,4

Nota-se uma grande influência maior do tipo EPA4, principalmente quando ele é combinado com o tipo EPA2. Para melhor visualização, os dados totais foram representados no gráfico a seguir (FIGURA 8.3):

FIGURA 8.3: Influência do número de eixos equivalentes, calculados com diferentes expoentes do fator de equivalência de operações para recuperação

8.2.3. Análise do Número Estrutural

Para este caso, foram colocados tanto o número estrutural corrigido quanto o número estrutural corrigido ajustado. Também foi analisado o caso da

retirada do número estrutural da RN. Os resultados conseguidos estão nas tabelas a seguir:

TABELA 8.19 : Inserção de SNA

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1950	104	57	176	21	84,5
Selar	0	109	0	0	0	100,0
Tratar	0	0	73	2	1	96,1
Recapear	40	40	143	426	7	64,9
% Total de Acerto						81,2

TABELA 8.20 : Inserção de SND

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1911	158	44	160	35	82,8
Selar	0	109	0	0	0	100,0
Tratar	0	0	74	2	0	97,4
Recapear	42	46	120	439	9	66,9
% Total de Acerto						80,4

TABELA 8.21 : Sem SN

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2038	91	22	151	6	88,3
Selar	0	108	0	1	0	99,1
Tratar	0	0	72	4	0	94,7
Recapear	33	44	80	498	1	75,9
% Total de Acerto						86,2

O gráfico com os valores totais está na FIGURA 8.4, a seguir:

FIGURA 8.4 - Efeito do número estrutural na recuperação

Com um aumento considerável na porcentagem de acerto da RN, a variável SN deveria ser excluída da análise.

8.2.4. Inclusão de Novos Parâmetros na Análise

Outros parâmetros, que pertencem a base de dados descrita no Capítulo 4, podem ser importante na montagem das RN e são apresentadas nas tabelas que seguem.

TABELA 8.22 : Inserção de WIDTH

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1961	56	40	246	5	85,0
Selar	1	106	0	2	0	97,2
Tratar	0	0	68	8	0	89,5
Recapear	22	40	103	490	1	74,7
% Total de Acerto						83,4

TABELA 8.23 : Inserção de SHWIDE

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2030	79	44	145	10	88,0
Selar	2	107	0	0	0	98,2
Tratar	0	0	66	10	0	86,8
Recapear	81	47	102	417	9	63,6
% Total de Acerto						83,2

TABELA 8.24 : Inserção de CRX

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1990	24	108	158	28	86,2
Selar	5	103	1	0	0	94,5
Tratar	0	0	70	6	0	92,1
Recapear	38	32	182	377	27	57,5
% Total de Acerto						80,7

O valor médio do trincamento não tem influência positiva no reconhecimento dos padrões, para o projeto de restauração.

Conforme pode ser observado através das TABELAS 8.22 e 8.23 os valores medidos das larguras da capa e do acostamento, auxiliam a RN a perceber as características do projeto de restauração do pavimento. Os dados totais são apresentados na figura a seguir:

FIGURA 8.5: Inclusão de novos parâmetros na recuperação

8.2.5. Exclusão dos Parâmetros Relativos a IGG

Por se tratarem de parâmetros simples, utilizados para análise estrutural, eles foram agrupados e são mostrados nas tabelas a seguir:

TABELA 8.25 : Sem CR1

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1985	60	76	177	10	86,0
Selar	0	108	0	0	1	99,1
Tratar	1	0	61	12	2	80,3
Recapear	54	41	172	377	12	57,5
% Total de Acerto						80,4

TABELA 8.26 : Sem CR2

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1892	41	69	259	47	82,0
Selar	0	108	0	0	1	99,1
Tratar	0	0	66	8	2	86,8
Recapear	42	38	135	413	28	63,0
% Total de Acerto						78,7

TABELA 8.27 : Sem CR3

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1999	56	43	199	11	86,6
Selar	0	108	0	1	0	99,1
Tratar	0	0	69	7	0	90,8
Recapear	43	38	126	449	0	68,4
% Total de Acerto						83,4

TABELA 8.28 : Sem CR4

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1985	55	75	154	39	86,0
Selar	0	109	0	0	0	100,0
Tratar	0	0	66	10	0	86,8
Recapear	28	47	112	438	31	66,8
% Total de Acerto						82,5

TABELA 8.29 : Sem CROC

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2063	66	82	71	26	89,4
Selar	0	106	0	1	2	97,2
Tratar	0	0	70	5	1	92,1
Recapear	64	37	118	429	8	65,4
% Total de Acerto						84,7

TABELA 8.30 : Sem POT

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1973	75	56	184	20	85,5
Selar	2	107	0	0	0	98,2
Tratar	0	0	65	11	0	85,5
Recapear	18	54	83	492	9	75,0
% Total de Acerto						83,7

TABELA 8.31 : Sem RAV

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1504	524	51	171	58	65,2
Selar	25	83	0	1	0	76,1
Tratar	0	0	65	8	3	85,5
Recapear	27	47	121	437	24	66,6
% Total de Acerto						66,3

TABELA 8.32 : Sem SPAT

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2035	67	41	158	7	88,2
Selar	0	109	0	0	0	100,0
Tratar	0	0	70	6	0	92,1
Recapear	66	46	113	421	10	64,2
% Total de Acerto						83,7

TABELA 8.33 : Sem RDMN

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1972	35	90	161	50	85,4
Selar	1	107	0	1	0	98,2
Tratar	0	0	63	11	2	82,9
Recapear	32	39	116	414	55	63,1
% Total de Acerto						81,2

FIGURA 8.6: Efeito da eliminação dos parâmetros de IGG na recuperação

Pela análise da figura, os trincamentos de classes 1 e 2 produzem resultados menores que o inicial, portanto não podem ser excluídos. Já os trincamentos de classe 3 e 4, poderiam ser excluídos, pois eles atrapalham o reconhecimento da rede.

Os valores para panelas, jacaré e remendos, uma vez eliminados, produzem uma porcentagem de acerto maior. Isso deve-se ao fato de não existir na base de dados uma grande variedade destes valores ocorrendo isoladamente. A seleção aleatória não deve ter encontrado um número suficiente de casos, e portanto, os resultados não influenciaram a montagem das RN.

Uma variável que não pode ser desprezada, de forma alguma, é a desagregação, pois sua porcentagem de acerto caiu para 66,3%.

8.2.6. Efeito da Exclusão dos Parâmetros Intrínsecos ao Pavimento para Recuperação

Neste item foram relacionados a retirada dos seguintes dados:

- média de chuva;
- tipo de capa do pavimento;
- espessura da capa;
- tipo de base e
- capa do acostamento.

Os resultados obtidos para a base de dados estão nas tabelas a seguir:

TABELA 8.34 : Sem MP

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1993	73	71	116	55	86,4
Selar	0	106	0	3	0	97,2
Tratar	0	0	69	7	0	90,8
Recapear	46	47	89	450	24	68,6
% Total de Acerto						83,1

TABELA 8.35 : Sem SURF

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2010	52	40	132	74	87,1
Selar	0	109	0	0	0	100,0
Tratar	0	2	67	4	3	88,2
Recapear	70	41	113	388	44	59,1
% Total de Acerto						81,7

TABELA 8.36 : Sem H1

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1980	72	59	176	21	85,8
Selar	0	109	0	0	0	100,0
Tratar	0	0	67	9	0	88,2
Recapear	48	48	147	407	6	62,0
% Total de Acerto						81,4

TABELA 8.37 : Sem BASE

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1994	78	48	175	13	86,4
Selar	0	109	0	0	0	100,0
Tratar	0	0	68	8	0	89,5
Recapear	24	41	167	421	3	64,2
% Total de Acerto						82,3

TABELA 8.38 : Sem SHSU

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2004	28	100	158	18	86,8
Selar	0	107	0	1	1	98,2
Tratar	1	0	69	6	0	90,8
Recapear	24	38	174	408	12	62,2
% Total de Acerto						82,2

Para uma melhor visualização dos dados, os valores totais estão representados na figura a seguir (FIGURA 8.7):

FIGURA 8.7: Efeito da eliminação dos parâmetros intrínsecos ao pavimento para recuperação

Através da observação da figura, os valores estão muito próximos, mas um valor que poderia ser eliminado é a média de chuva.

8.2.7. Análise da Retirada dos Dados de Ensaios para Recuperação

Foram separados, neste item, a deflexão de viga corrigida, a irregularidade e o CBR do subleito. Os dados obtidos com a alimentação das RN para recuperação estão tabelados a seguir:

TABELA 8.39 : Sem DEFS

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1954	38	61	249	6	84,7
Selar	2	106	0	0	1	97,2
Tratar	0	0	66	10	0	86,8
Recapear	31	39	99	462	25	70,4
% Total de Acerto						82,2

TABELA 8.40 : Sem RQI

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1782	79	95	169	183	77,2
Selar	0	104	1	2	2	95,4
Tratar	1	1	64	10	0	84,2
Recapear	73	50	85	418	30	63,7
% Total de Acerto						75,2

TABELA 8.41 : Sem SGCBR

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2036	70	20	177	5	88,2
Selar	0	108	0	1	0	99,1
Tratar	0	0	70	6	0	92,1
Recapear	53	40	93	469	1	71,5
% Total de Acerto						85,2

Os dados totais podem ser observados na figura a seguir (FIGURA 8.8):

FIGURA 8.8: Efeito da eliminação dos dados de ensaios para recuperação

Conclui-se pela figura acima que o dado da irregularidade é importante e que o CBR do subleito poderia ser eliminado.

8.2.2. Alteração no Conjunto de Treinamento

Com o intuito de se analisar a tendência para o reconhecimento, os grupos de dados foram separados por tipo de base, tipo de capa e tipo de cobertura do acostamento.

8.2.2.1. Tipo de Base

Os dados foram separados em pedregulho (2033 casos), pedra britada (668 casos) e base cimentada (434 casos). Os resultados obtidos estão nas tabelas a seguir:

TABELA 8.42 : Base = 'GRAVEL'

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1331	36	64	57	17	88,4
Selar	0	74	0	1	0	98,7
Tratar	0	0	50	0	0	100,0
Recapear	35	27	139	196	6	48,6
% Total de Acerto						81,2

TABELA 8.43 : Base = 'CRSTONE'

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	426	24	14	64	4	80,1
Selar	0	20	0	0	0	100,0
Tratar	0	0	20	0	0	100,0
Recapear	0	4	32	57	3	59,4
% Total de Acerto						78,2

TABELA 8.44 : Base = 'CEMENTD'

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	242	5	1	10	0	93,8
Selar	0	13	0	0	0	100,0
Tratar	0	0	5	1	0	83,3
Recapear	14	8	12	123	0	78,3
% Total de Acerto						88,2

Para uma melhor visualização, os resultados totais foram colocados na figura a seguir (FIGURA 8.9)

FIGURA 8.9: Tipo de base na restauração

Pela figura anterior, pode ser observado que a separação não produziu resultado melhor que a solução inicial, não sendo necessária a divisão em tipos de base.

8.2.2.2. Tipo de Capa

Foram criados conjuntos com tipos de capas iguais, Concreto Asfáltico (866 casos), Tratamento Superficial Duplo (1634 casos), Recobrimento com Concreto Asfáltico (231 casos) e Recobrimento com Tratamento Superficial Duplo (421 casos). Os resultados obtidos estão nas tabelas a seguir:

TABELA 8.45 : Capa = 'AC'

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	557	0	36	4	0	93,3
Selar	3	0	0	0	0	0,0
Tratar	0	0	35	0	0	100,0
Recapear	29	0	58	140	0	60,6
% Total de Acerto						84,5

TABELA 8.46 : Capa = 'DST'

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	903	70	49	127	5	78,2
Selar	0	100	1	0	0	99,0
Tratar	0	0	32	0	0	100,0
Recapear	18	37	49	243	0	70,0
% Total de Acerto						78,2

TABELA 8.47 : Capa = 'ACOVL'

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	207	0	0	0	0	100,0
Selar	0	0	0	0	0	0,0
Tratar	0	0	0	0	0	0,0
Recapear	10	0	0	14	0	58,3
% Total de Acerto						95,7

TABELA 8.48 : Capa = 'DSTOVL'

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	327	0	26	0	0	92,6
Selar	3	0	0	2	0	0,0
Tratar	0	0	9	0	0	100,0
Recapear	5	0	9	40	0	74,1
% Total de Acerto						89,3

Para uma comparação entre os grupos os resultados finais foram representados através da figura a seguir (FIGURA 8.10).

FIGURA 8.10: Tipo de capa na restauração

Através da figura, pode ser observado que existe um maior reconhecimento nos casos de recobrimento por concreto asfáltico e por tratamento superficial duplo. O tratamento superficial duplo produz resultados piores que a solução inicial.

8.2.2.3. Tipo de Acostamento

Os casos foram divididos, para análise, segundo o tipo de cobertura do acostamento: os casos onde o acostamento foi construído por pedregulho (total de 1336 casos) e por tratamento superficial simples (1814 casos). Os resultados obtidos estão a seguir:

TABELA 8.49 : SHSU = 'GRAV'

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	700	21	69	46	3	83,4
Selar	0	54	0	0	0	100,0
Tratar	0	0	53	0	0	100,0
Recapear	41	30	74	242	3	62,1
% Total de Acerto						78,5

TABELA 8.50 : SHSU = 'SST'

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1372	25	41	29	3	93,3
Selar	3	51	1	0	0	92,7
Tratar	0	0	23	0	0	100,0
Recapear	54	12	33	166	1	62,4
% Total de Acerto						88,9

Os resultados foram colocados no gráfico a seguir (FIGURA 8.11).

FIGURA 8.11: Tipo de recobrimento do acostamento na recuperação

Observa-se pela figura, que o tratamento superficial simples produz casos mais claros de reconhecimento pelas RN.

8.2.3. Análise dos Parâmetros da Rede Neural para Pavimentação

Neste tópico são analisados, os parâmetros possíveis de serem modificados pelo usuário de uma RN.

8.2.3.1. Erro de Treinamento

Os erros de treinamento adotados para a RN foram de 0,0045 a 0,09. Os valores conseguidos com a RN estão nas tabelas a seguir. A solução inicial descrita no item 8.1 utilizou um erro de 0,009.

TABELA 8.51 : Erro de treinamento 0,0045

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2065	42	41	136	24	89,5
Selar	0	109	0	0	0	100,0
Tratar	1	0	68	6	1	89,5
Recapear	31	37	170	411	7	62,7
% Total de Acerto						84,2

TABELA 8.52 : Erro de treinamento 0,045

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2032	81	135	57	3	88,0
Selar	0	108	0	1	0	99,1
Tratar	1	0	70	5	0	92,1
Recapear	106	40	228	281	1	42,8
% Total de Acerto						79,1

TABELA 8.53 : Erro de treinamento 0,09

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1227	945	119	17	0	53,2
Selar	0	109	0	0	0	100,0
Tratar	8	0	68	0	0	89,5
Recapear	53	105	480	18	0	2,7
% Total de Acerto						45,2

Os resultados finais são apresentados na FIGURA 8.12.

FIGURA 8.12: Erro de treinamento para recuperação

Valores menores que 0,0045 devem ser empregados como erro de treinamento.

8.2.3.2. Validação dos Resultados

Como foi descrito no item 7.2.3, é necessário especificar um limitante, será um valor que feito o reconhecimento é considerado como o resultado correto. Para quantificar estes valores, foram colocados números de 0,1 até 0,9, para se notar a tendência de convergência dos resultados. Na solução inicial foi adotado limitante 0,1.

Os valores para os dados desde 0,2 até 0,9 estão a seguir:

TABELA 8.54 : Erro de verificação 0,20

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1901	56	58	278	15	82,4
Selar	0	108	0	1	0	99,1
Tratar	0	0	69	7	0	90,8
Recapear	20	37	120	472	7	72,0
% Total de Acerto						81,0

TABELA 8.55 : Erro de verificação 0,30

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1898	54	53	274	29	82,2
Selar	0	108	0	1	0	99,1
Tratar	0	0	68	7	1	89,5
Recapear	16	37	117	468	18	71,3
% Total de Acerto						80,7

TABELA 8.56 : Erro de verificação 0,40

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1888	53	45	265	57	81,8
Selar	0	108	0	1	0	99,1
Tratar	0	0	68	7	1	89,5
Recapear	15	37	114	466	24	71,0
% Total de Acerto						80,3

TABELA 8.57 : Erro de verificação 0,50

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1882	52	44	256	74	81,5
Selar	0	108	0	1	0	99,1
Tratar	0	0	68	7	1	89,5
Recapear	15	37	110	459	35	70,0
% Total de Acerto						79,9

TABELA 8.58 : Erro de verificação 0,60

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1866	51	40	236	115	80.8
Selar	0	108	0	1	0	99.1
Tratar	0	0	67	6	3	88.2
Recapear	12	37	103	446	58	68.0
% Total de Acerto						79,0

TABELA 8.59 : Erro de verificação 0,70

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1844	46	33	218	167	79,9
Selar	0	108	0	1	0	99,1
Tratar	0	0	64	5	7	84,2
Recapear	10	37	93	429	87	65,4
% Total de Acerto						77,6

TABELA 8.60 : Erro de verificação 0,80

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1812	45	29	188	234	78,5
Selar	0	108	0	1	0	99,1
Tratar	0	0	60	4	12	78,9
Recapear	6	36	85	397	132	60,5
% Total de Acerto						75,5

TABELA 8.61 : Erro de verificação 0,90

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1725	39	23	145	376	74,7
Selar	0	108	0	1	0	99,1
Tratar	0	0	47	3	26	61,8
Recapear	5	36	65	354	196	54,0
% Total de Acerto						70,9

Para se notar a tendência dos valores totais, estes foram colocados na figura a seguir (FIGURA 8.13).

FIGURA 8.13: Validação dos resultados para recuperação

Como os valores estão se alterando demais dependendo do limiar adotado, o parâmetro melhor aconselhado é o da solução inicial, 0,10.

8.2.3.3. Alteração na Estrutura da Rede Neural

A RN montada inicialmente tinha 18 entradas e 5 saídas. Os valores das saídas foram definidas por norma e as entradas, foram obtidas por testes, chegando-se aos melhores resultados.

Na montagem da RN, que reconhece o comportamento do projeto de pavimentação, foi escolhido o valor de 13 para a camada oculta. Deveria ser um valor entre os dois extremos. Este valor não é necessariamente o correto. É possível obter outros, dependendo dos relacionamentos entre as variáveis de entrada. Para isso, foram testadas outras configurações para a rede que foi sendo alterada, inicialmente em suas camadas ocultas e, depois, na quantidade de camadas.

8.2.3.3.a. Número de Nós na Camada Oculta

Foram testados desde 11 até 15 nós na camada oculta. Os valores estão entre os limitantes dos extremos. Os resultados obtidos estão nas tabelas a seguir.

TABELA 8.62 : 11 nós na camada oculta

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1904	61	184	131	28	82,5
Selar	0	109	0	0	0	100,0
Tratar	1	0	65	10	0	85,5
Recapear	21	43	158	424	10	64,6
% Total de Acerto						79,5

TABELA 8.63 : 12 nós na camada oculta

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2023	51	83	141	10	87,7
Selar	2	104	1	1	1	95,4
Tratar	1	0	67	8	0	88,2
Recapear	69	38	127	418	4	63,7
% Total de Acerto						82,9

TABELA 8.64 : 14 nós na camada oculta

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2001	64	75	152	16	86,7
Selar	1	107	0	1	0	98,2
Tratar	1	0	62	13	0	81,6
Recapear	36	41	132	411	36	62,7
% Total de Acerto						82,0

TABELA 8.65 : 15 nós na camada oculta

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2013	40	36	196	23	87,2
Selar	0	105	0	2	2	96,3
Tratar	0	0	70	6	0	92,1
Recapear	21	39	104	479	13	73,0
% Total de Acerto						84,7

Os resultados totais estão na figura a seguir (FIGURA 8.14):

FIGURA 8.14: Número de nós na camada oculta

Conforme a figura, não existe uma tendência para escolha da quantidade de nós. O valor maior obtido (15) deve ser um valor isolado. O modelo teórico proposto aconselha valores intermediários entre os limites.

8.2.3.3.b. Alteração no Número de Camadas Oculta

Na solução inicial proposta, foi colocada apenas 1 camada oculta, mas existe a possibilidade de alteração com aumento no número de camadas. São apresentados a seguir, os resultados com testes feitos, inicialmente com incremento de 1 camada e depois com mais de 2 camadas oculta.

TABELA 8.66 : 2 camadas ocultas (14, 9)

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1995	85	41	185	2	86,4
Selar	1	108	0	0	0	99,1
Tratar	1	1	63	11	0	82,9
Recapear	53	40	106	457	0	69,7
% Total de Acerto						83,3

TABELA 8.67 : 2 camadas ocultas (14, 10)

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1987	102	57	162	0	86,1
Selar	3	105	0	1	0	96,3
Tratar	0	0	65	11	0	85,5
Recapear	55	40	161	400	0	61,0
% Total de Acerto						81,2

TABELA 8.68 : 2 camadas ocultas (14, 11)

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1991	72	91	154	0	86,3
Selar	0	109	0	0	0	100,0
Tratar	2	0	62	7	5	81,6
Recapear	43	44	141	426	2	64,9
% Total de Acerto						82,2

TABELA 8.69 : 3 camadas ocultas (14, 11, 9)

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	1950	72	68	218	0	84,5
Selar	2	106	1	0	0	97,2
Tratar	0	0	70	6	0	92,1
Recapear	69	36	163	388	0	59,1
% Total de Acerto						79,8

Os resultados totais obtidos foram colocados na FIGURA 8.15.

FIGURA 8.15: Alteração na quantidade de camadas ocultas

Observa-se que a melhor opção para o modelo de rede são duas camadas ocultas a primeira com 14 nós e a segunda com 9.

8.2.3.3.c. Alteração na Quantidade de Casos na Amostra

Outra alteração possível, é a mudança na quantidade de valores que serviram para fazer o treinamento da RN. Na solução inicial foi utilizada uma amostra com valores de 32 para Nada, 27 para Selar, 37 para Tratar e 33 para Recapear, num total de 129 casos. Nesta solução inicial, o tempo de treinamento foi de 82 segundos.

Para uma nova amostra foram alteradas as quantidades: 28 para Nada, 21 para Selar, 25 para Tratar e 30 para Recapear, num total de 104 casos. O tempo de treinamento para montagem da rede, diminuiu para 47 segundos. O resultado obtido está na tabela a seguir:

TABELA 8.70 : Amostra menor

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2067	27	82	113	19	89,6
Selar	3	96	0	7	3	88,1
Tratar	0	0	67	9	0	88,2
Recapear	55	11	145	433	12	66,0
% Total de Acerto						84,6

Outra possibilidade seria a de aumentar o número de casos da amostra e, portanto, melhorar os resultados. A amostra maior seria 38 para Nada, 36 para Selar, 75 para Tratar e 37 para Recapear. O tempo de treinamento aumentou para 743 segundos. O resultado é exibido através da tabela a seguir.

TABELA 8.71 : Amostra maior

RECxRN	Nada	Selar	Tratar	Recapear	N Ident.	%Acerto
Nada	2171	17	42	78	0	94,1
Selar	3	102	1	1	2	93,6
Tratar	0	0	74	2	0	97,4
Recapear	43	7	179	410	17	62,5
% Total de Acerto						87,6

Para uma comparação entre o tamanho das amostras, os valores totais foram colocados na figura a seguir, FIGURA 8.16:

FIGURA 8.16: Tamanho da amostra para recuperação

Através da observação do gráfico, o aumento da amostra realmente melhora a porcentagem de acerto. Infelizmente o tempo de treinamento para montagem da RN aumenta muito, o que pode ser prejudicial para os testes. A amostra com a solução inicial não é a mais interessante.

8.2.4. Melhores e Piores Casos no Projeto de Restauração

Neste item estão listados ordenados os piores e melhores resultados totais, em ordem crescente.

TABELA 8.72. Piores testes para projeto de restauração

Caso	Valor
Sem RAV	66,3
Sem RQI	75,2
EPA4	77,6
Sem CR2	78,7
NHV	79,5

Observa-se pela tabela anterior que a desagregação, a irregularidade, e o trincamento de classe 2 não devem ser desconsiderados numa análise de restauração.

Já o número de eixos equivalentes e a quantidade de veículos que transitaram pela rodovia, não devem ser considerados na análise.

TABELA 8.72. Melhores testes para projeto de restauração

Caso	Valor
PV4	83,8
PV2	83,9
PV6	84
Sem CROC	84,7
Sem SGCBR	85,2
Sem SN	86,2

Para a obtenção dos melhores resultados, aconselha-se a desconsiderar o número estrutural, o CBR do subleito, o trincamento em forma de jacaré. Já as frações de tráfego (PV6, PV2 e PV4) devem ser consideradas.

CAPÍTULO 9

ASSOCIAÇÃO DE REDES NEURAIS COM UM BANCO DE DADOS GRÁFICO

9.1. Introdução

Neste capítulo é apresentado o protótipo desenvolvido que associa as RN com um banco de dados gráfico. No final é mostrado o resultado final de uma simulação executada pelo sistema protótipo.

9.2. A Utilização das Redes Neurais Treinadas

Para a utilização das RN modeladas, é necessário um processamento auxiliar, para facilitar o acesso dos bancos de dados. Para isso foi desenvolvido um sistema auxiliar chamado Sistema de Ajuda a Gerência de Pavimentos - SAGP.

Este protótipo é classificado, segundo CÂMARA e outros (1996), como um Sistema de Informações Geográficas, que garante o gerenciamento de dados geográficos, para uma aplicação sócio-econômica, voltada ao gerenciamento e a tomada de decisões.

O sistema em questão, também é um tipo de Sistema de Gerência de Pavimentos, onde o usuário pode cadastrar mapas rodoviários e manter uma base de dados sobre a malha rodoviária de uma região. Estes mapas e a base de dados interessam especialmente ao usuário Engenheiro de Pavimentos que poderá consultá-los e, através do SAGP, simular a situações de avaliação, de recuperação e custos de rodovias para um tempo futuro.

O usuário de um SAGP é o profissional que trabalha diretamente com a conservação de estradas e rodovias, como o Engenheiro de Pavimentos, e profissionais ligados à pavimentação em órgãos públicos como o DNER e prefeituras municipais.

O SAGP foi desenvolvido utilizando a ferramenta DELPHI da Borland Internacional, utilizando a programação orientada a objetos e baseada em eventos. Seu objetivo é suprir certa carência de *softwares* aplicativos, na área de Gerência de Pavimentos.

O projeto do SAGP está sendo elaborado levando-se em consideração o projeto PICR citado no item 4.1.

O SAGP ainda possui a função de servir como ferramenta de gerenciamento de malhas rodoviárias através dos mapas e banco de dados.

O sistema poderá ser utilizado, não só pelas instituições governamentais brasileiras, bem como, com a atual tendência de privatização dos serviços públicos, por empresas da iniciativa privada.

O SAGP permite através da introdução da RN conveniente:

- 1) A avaliação do pavimento, onde para cada trecho cadastrado é atribuída uma classificação;
- 2) Identifica onde e quando deverão ser efetuados serviços de manutenção; e
- 3) Avalia o custo final dos serviços.

9.2.1. Estrutura do SAGP

Projetado para ser um sistema de fácil utilização, o usuário se comporta no SAGP, da mesma forma que o faria se estivesse trabalhando no papel: primeiro escreve os dados e depois faz sua análise. A interface do módulo principal é mostrada abaixo (FIGURA 9.1).

Figura 9.1: Exemplo de mapa no SAGP

Basicamente o sistema possui todos os recursos para o desenho, a saber:

a) Acesso a arquivos

São permitidos: acessos a arquivos em disco, nova área de trabalho, salvar, salvar como, impressão (onde são ajustados a impressora e seus parâmetros e tamanho de papel, permite também definir a qualidade da impressão), sair para o sistema operacional.

b) Edição de mapas

As funções para mapas prontos, introduzidos por leitura digital em formato BMP, são: Recortar, Copiar e Colar. Utiliza para os três casos a área de transferência do *Windows* versão 3.11.

Existem outras opções, tais como:

- Caneta - nesta opção é possível escolher entre vários tipos de espessura de caneta.
- Borracha - através desta opção, escolhe-se entre vários tamanhos de borracha.

As opções “Caneta” e “Borracha” comportam-se como na maioria de Editores Gráficos existentes atualmente: enquanto o botão estiver pressionado, o usuário pode fazer qualquer tipo de modificação simplesmente apertando o botão do *mouse*.

Durante a edição de um mapa, é necessária a identificação tanto de estradas, como também de cidades, regiões, rios, etc. Para cada uma destas é necessária sua identificação com a introdução de um texto correspondente.

Nesta edição deve-se apertar o botão do texto, e observar a mudança no formato do cursor para edição de texto. Enquanto o botão permanece apertado, podemos percorrer o mapa. Escolhe-se o ponto onde será inserido o primeiro caracter. Aparecerá uma caixa de diálogo, onde o usuário entrará com o texto (é permitido mudar todo o estilo do texto, tais como : estilo de letra, tamanho, cor) . Para isso basta selecionar o botão com o nome Fonte.

Do mesmo modo que o usuário insere um texto no mapa, ele pode também inserir símbolos de cidade e capital. Escolhendo-se um determinado ponto com o *mouse* (o cursor se apresenta em forma de “jarra de tinta”), o usuário pode escolher a figura que deseja inserir.

O delimitador tem função importante na definição do trecho a ser analisado.

A utilização do *zoom* também é permitida, sendo muito importante no SAGP, pois através dele fica muito mais fácil ao usuário modificar uma estrada, visualizando-a com maior nitidez.

Quando o usuário selecionar essa opção, o cursor se transformará em uma “mira”. O usuário então posiciona o cursor na região da estrada que ele deseja modificar. Com isso a região será ampliada e estarão habilitadas as opções de caneta e borracha. As opções de mudança de tamanho e grossura da borracha e caneta, respectivamente, também poderão ser alteradas.

Qualquer alteração feita pelo usuário na região ampliada, também será feita no mapa original.

c) Banco de Dados associado ao mapa

Depois de definido um trecho da estrada (botão de edição Defina trecho) , se o usuário entrar na opção do banco de dados, o SAGP automaticamente criará um registro na base de dados, onde ele entrará com todos os dados necessários para o trecho (FIGURA 9.2).

Os nomes dos campos seguem os mesmos padrões utilizados na pesquisa desenvolvida citada no Capítulo 4. Para atribuir um valor a um determinado campo, basta selecionar o campo com o *mouse* e fazer a inserção ou alteração. Existem os botões de inclusão e remoção de registros.

d) Seleciona Trecho

Depois que o usuário editar um determinado trecho de estrada (o trecho não pode apresentar falhas de continuidade), ele insere dois delimitadores (botão de edição Inserir figuras). Mantendo o botão pressionado, o cursor se transformará em uma “ jarra de tinta “. Com o *mouse*, o usuário escolhe qualquer ponto do trecho. O trecho escolhido mudará de cor (verde), dessa forma o trecho já se apresenta definido.

Outra função ocorre depois do trecho já estar definido e a sua base de dados preenchida. O usuário pode perceber um ponto de cor diferente no trecho. Este ponto faz a ligação direta com a sua respectiva base de dados. O usuário pode selecionar o ponto através da “mira” na parte inferior do cursor.

e) Ajuda (*Help*)

A Ajuda do SAGP contém informações sobre todas as funções do sistema, sobre o equipamento, onde ele é executado e todo o contexto em que foi projetado.

Base de Dados referente a cada Trecho rodoviário

Trecho : 001

TRECHO	AADT1	YE41CC	PVL1	YRCON	YROVL	ACTION	SURF	H1	CQ
001	73	0,0001	0,7	72	0	-	AC	30	
002	303	0,044	0,665	70	0	-	DST	23	
003	5336	0,208	0,768	65	82,3	AC/OVLAY	AC	80	
004	104	0,001	0,703	75	0	-	DST	20	
006	5590	0,761	0,668	60	76,5	AC/OVLAY	ACOV	153	
007	1127	0,034	0,736	66	0	-	DST	20	
008	1053	0,039	0,736	66	0	-	DST	20	
009	3970	0,889	0,544	58	68,5	AC/OVLAY	DSTOVL	93	
010	1404	0,033	0,749	68	0	-	DST	20	

Dados coletados referentes ao Trecho de estrada em destaque :

TRECHO	SUBS	DIR	YR	AGER	AGES	NHX	NHV	AADT	PVL	PV2
001	COM	CS	76,796	4,296	4,296	0,036	0,017	73	0,7	
001	COM	CS	77,93	5,43	0,7	0,046	0,022	73	0,7	
001	COM	CS	78,832	6,332	1,602	0,053	0,025	73	0,7	
001	COM	CS	79,549	7,049	2,319	0,059	0,028	73	0,7	
001	COM	CS	80,713	8,213	3,483	0,069	0,033	73	0,7	
001	COM	CS	81,263	8,763	4,033	0,074	0,035	73	0,7	
001	COM	SC	76,796	4,296	4,296	0,036	0,017	73	0,7	
001	COM	SC	77,93	5,43	0,7	0,046	0,022	73	0,7	

Figura 9.2: Janelas para entrada dos dados dos trechos

f) Seção transversal do pavimento

Nessa opção podemos ver as camadas que compõem o pavimento. As duas camadas superiores, revestimento e base, estão relacionadas com a base de dados referente ao trecho. Para cada trecho, existe um tipo de material de que é feita cada camada. Para visualizar o esquema, basta selecionar a opção e depois com a “cruz” selecionar um trecho no mapa.

g) Manual de defeitos

O manual de defeitos relaciona todos os defeitos de revestimentos asfálticos do pavimento existentes no Brasil. Todos os tipos e suas respectivas causas de ocorrência são explicados no campo texto. Para lê-los, basta utilizar a barra de rolagem vertical.

Na lista de defeitos do lado esquerdo, são apresentados todos os defeitos. Selecionando um deles, aparecerá na parte inferior, um exemplo de cada nível do defeito. É composta de fotos tiradas em estradas e ruas do país. Os defeitos e as fotos seguem estrutura do trabalho de DOMINGUES (1993b). A montagem do manual poderia ser feita segundo a estrutura de qualquer manual como por exemplo o VIZIR (1991).

9.2.2. Uma Forma de Simulação Utilizando RN - Avaliação da Condição

Para se obter os resultados de uma simulação dentro do sistema desenvolvido, é necessário que já tenha sido modelada uma RN com um conjunto de treinamento, como foi proposto no Capítulo 5.

Neste caso a RN montada foi treinada para simular a avaliação da condição do pavimento, e usou como métodos especialistas o Índice de Gravidade Global (IGG) e a Irregularidade, citados no Capítulo 2.

Para se avaliar a condição em todos os trechos relacionados, o usuário terá condições de aplicar a simulação sobre as condições do pavimento, utilizando para isso toda a base de dados referente a cada trecho da estrada.

Depois de selecionada a opção, para se proceder uma simulação, aparecerá na tela (FIGURA 9.3) um quadro de diálogo onde aparecerão os seguintes itens :

a) Multiplicadores:

Do lado esquerdo do quadro existem diversos quadros de edição, onde o usuário deverá entrar com multiplicadores para cada campo da base de dados. Isso

é muito importante, pois neste ponto é onde está sendo selecionado, quais variáveis são pertencentes a RN treinada. O protótipo foi desenvolvido para fazer simulações em qualquer RN montada naquele banco de dados.

b) Ano para a simulação

Do lado direito, existe um campo onde o usuário determina o ano de trabalho para a simulação do processo a ser analisado. Para se gerar qualquer simulação, é obrigatório que se entre com um determinado ano.

c) Execução

Os botões “ Gera arquivos. txt “ e “ Aplicar simulação “ são para a fase final do projeto. Depois de definidos todos os trechos, cada um com a sua base de dados devidamente preenchida, podemos gerar uma simulação para cada ano que se desejar, em um processo rápido e visual.

FIGURA 9.3 - Introduzindo os valores dos pesos

A mudança na cor do trecho delimitado indica a finalização da simulação. Cada cor representa uma avaliação: (Azul - Ótimo, Água - Bom, Prata - Regular, Roxo - Ruim, Marrom - Péssimo), o resultado final obtido é mostrado na FIGURA 9.4.

Figura 9.4: Resultado da Avaliação da Condição

CAPÍTULO 10

CONCLUSÕES E TRABALHOS FUTUROS

São apresentadas neste capítulo as principais conclusões obtidas no trabalho, e novas idéias para seu aperfeiçoamento. O capítulo foi dividido nos seguintes itens: aspectos gerais da utilização das RN; aspectos relacionados com a avaliação da condição do pavimento; aspectos envolvidos no projeto de restauração do pavimento e; relacionamento de um banco de dados gráfico com as redes neurais montadas.

10.1. Aspectos Gerais

O trabalho baseou-se na idéia da utilização das redes neurais como uma ferramenta de auxílio na solução dos problemas relacionados aos Sistemas de Gerência de Pavimentos. Neste sentido procedeu-se ao reconhecimento e classificação dos dados tanto para a avaliação da condição, como para o projeto de pavimentos.

Algumas das principais vantagens encontradas na abordagem, e que merecem ser enfatizadas, são: o procedimento envolve um conjunto reduzido de

variáveis; a geração aleatória das amostras (não sendo necessária a escolha dos casos por um especialista); e a facilidade de integração de RN treinadas em bancos de dados gráficos.

Na verificação da influência dos parâmetros relacionados ao problema, resolveu-se pela escolha de uma solução inicial. Esta solução mostrou-se interessante, uma vez que foi possível realizar-se a comparação do reconhecimento com poucas mudanças nas RN.

Devido a existência de uma grande número de parâmetros relativos aos trechos adotou-se, para sua análise, duas abordagens: 1) o estudo de todo o conjunto de casos e 2) o agrupamento dos casos segundo suas características. Nas duas abordagens obteve-se o reconhecimento dos casos e conseguiu-se diagnosticar alguns fatos relacionados a estes.

Através das abordagens acima foram obtidos bons resultados. Apesar disso não foram esgotadas as possibilidades de combinação de casos. A busca de novas combinações de casos pode ser um aperfeiçoamento interessante para a continuidade desta pesquisa.

O rapidez no treinamento das RN, bem como, a necessidade de apenas um pequeno conjunto de amostras de teste, indicam que os dados possuem alta correlação. Evidentemente ainda são possíveis várias outras otimizações, como também completar a Base de Dados com mais casos.

Este trabalho foi direcionado à análise dos aspectos qualitativos da gerência de pavimentos. Outro caminho a ser tomado seria a inclusão de informações de custo, para fornecer critérios econômicos de escolha ao engenheiro de pavimentos.

Existe ainda a possibilidade de utilizar as RN na previsão do desempenho dos pavimentos.

10.2. Aspectos da Avaliação da Condição do Pavimento

Este trabalho demonstrou experimentalmente que é possível tratar o problema da avaliação da condição de pavimentos com uma rede neural MLP-*Backpropagation* e que esta pode avaliar melhor o pavimento do que os processos propostos por norma.

Na comparação de reconhecimento, os resultados obtidos foram: as RN e o IGG concordaram em 78,6% dos casos; as RN e a Irregularidade concordaram em 59,4% dos casos. Essa conclusão é muito significativa quando se considera que o IGG e a Irregularidade só concordam em 52%.

A comparação com o IGG e com a Irregularidade mostrou que ambas influenciam o reconhecimento das RN de maneira diferente.

Para o caso selecionado os resultados mais importantes foram: a comprovação da não influência do tráfego sobre o reconhecimento; a constatação de que os dados de ensaios (o CBR do subleito e a deflexão de viga) não melhoram o reconhecimento; e a confirmação da não influência da irregularidade no IGG.

10.3. Aspectos do Projeto de Restauração

O uso das RN também mostrou-se adequado para o tratamento do problema do projeto de restauração de pavimentos.

A porcentagem de reconhecimento foi de 86.2% dos casos.

Notou-se realmente que as variáveis envolvidas no projeto de restauração não são necessariamente as mesmas empregadas na avaliação da condição do pavimento.

10.4. Aspectos da Utilização das RN

Este trabalho demonstrou a utilidade de se desenvolver um sistema computacional voltado para a gerência de pavimentos, que empregue as técnicas de RN. Mostrou também que este sistema poderia ser mais simples, por se tratar de dados não geograficamente precisos.

A simplicidade do sistema reside no fato de utilizar um número relativamente pequeno de informações de cada ponto: 18 variáveis, além da localização geográfica (não obrigatoriamente exata).

Com os dados cadastrados, e com as redes treinadas, o trabalho demonstrou experimentalmente que é possível representar a avaliação da condição de pavimentos, bem como, o problema do projeto de pavimentos, com uma saída gráfica simples.

Pode-se desenvolver, dentro deste sistema, formas de facilitar o cruzamento de informações das redes para o engenheiro de pavimentos. Com este aperfeiçoamento o sistema pode ser empregado como uma ferramenta de decisão ou até de ensino.

ANEXO 1

Com a finalidade de melhor ilustrar o funcionamento das redes neurais perceptron, é apresentada a solução de um problema de reconhecimento de padrões.

O exemplo proposto consiste de uma rede do tipo Perceptron com 3 terminais de entrada, utilizando pesos iniciais $w_0 = 0.4$, $w_1 = -0.6$ e $w_2 = 0.6$, um limiar $\theta = 0.5$ e uma taxa de aprendizado $\eta = 0.8$, sendo que v é o valor calculado, y é o resultado (da função de saída) e d é a saída desejada. A função de ativação escolhida é a função passo (vide Figura 3.3.c).

Na fase de aprendizagem são propostas duas situações: para o conjunto de entrada (0,0,1) é gerada a saída (1) e para o conjunto de entrada (1,1,0), a saída gerada é (0).

Na fase de uso, o conjunto de teste utilizado é o seguinte: (1,1,1), (0,0,0), (1,0,0) e (0,1,1).

Fase de Aprendizagem

As atividades realizadas nesta fase são as seguintes:

1) Para o conjunto (0,0,1)

Passo 1: Definir a saída (utilizando equação 3.1)

$$v = 0 \times 0.4 + 0 \times (-0.6) + 1 \times (0.6) = 0.6$$

$$y = a = 1 \text{ (uma vez que } 0.6 \geq \theta \text{)}$$

Passo 2: Atualizar pesos (utilizando equações 3.2 e 3.3)

$$w_o = 0.4 + 0.8 \times 0 \times (0 - 1) = 0.4$$

$$w_i = -0.6 + 0.8 \times 0 \times (0 - 1) = -0.6$$

$$w_j = 0.6 + 0.8 \times 1 \times (0 - 1) = -0.2$$

2) Para o conjunto (1,1,0)

Passo 1: Definir a saída

$$v = 1 \times 0.4 + 1 \times (-0.6) + 0 \times (-0.2) = -0.4$$

$$y = a = 0 \text{ (uma vez que } -0.4 < \theta \text{)}$$

Passo 2: Atualizar pesos

$$w_o = 0.4 + 0.8 \times 1 \times (1 - 0) = 1.2$$

$$w_i = -0.6 + 0.8 \times 1 \times (1 - 0) = 0.2$$

$$w_j = -0.2 + 0.8 \times 0 \times (1 - 0) = -0.2$$

3) Para o conjunto (0,0,1)

Passo 1: Definir a saída

$$v = 0 \times 1.2 + 0 \times (0.2) + 1 \times (-0.2) = -0.2$$

$$y = a = 0 \text{ (uma vez que } -0.2 < \theta \text{)}$$

Passo 2: Atualizar pesos

como $d = y$, os pesos não precisam ser modificados

4) Para o conjunto (1,1,0)

Passo 1: Definir a saída

$$v = 1 \times 1.2 + 1 \times (0.2) + 0 \times (-0.2) = 1.4$$

$$y = a = 1 \text{ (uma vez que } 1.4 \geq \theta \text{)}$$

Passo 2: Atualizar pesos

como $d = y$, os pesos não precisam ser modificados

Fase de Uso

1) Para o conjunto (1,1,1)

Passo 1: Definir a saída

$$v = 1 \times 1.2 + 1 \times (0.2) + 1 \times (-0.2) = 1.2$$

$$y = a = 1 \text{ (uma vez que } 1.2 \geq \theta \text{)} \Rightarrow \text{CLASSE 1}$$

2) Para o conjunto (0,0,0)

Passo 1: Definir a saída

$$v = 0 \times 1.2 + 0 \times (0.2) + 0 \times (-0.2) = 0.0$$

$$y = a = 0 \text{ (uma vez que } 0.0 < \theta \text{)} \Rightarrow \text{CLASSE 0}$$

3) Para o conjunto (1,0,0)

Passo 1: Definir a saída

$$v = 1 \times 1.2 + 0 \times (0.2) + 0 \times (-0.2) = 1.2$$

$$y = a = 1 \text{ (uma vez que } 1.2 \geq \theta \text{)} \Rightarrow \text{CLASSE 1}$$

4) Para o conjunto (0,1,1)

Passo 1: Definir a saída

$$v = 0 \times 1.2 + 1 \times (0.2) + 1 \times (-0.2) = 0.0$$

$$y = a = 0 \text{ (uma vez que } 0.0 < \theta \text{)} \Rightarrow \text{CLASSE 0}$$

ANEXO 2

É apresentada, neste anexo, a sequência das tarefas do ponto de vista computacional, utilizadas para a obtenção da solução de um problema de reconhecimento de padrões pela técnica de redes neurais artificiais.

O exemplo proposto consiste na comparação dos resultados obtidos pela função $f(x) = 0,2 * x_1 + 0,3 * x_2 + 0,5 * x_3$, com os obtidos por uma rede neural artificial do tipo MLP-Backpropagation.

O domínio adotado para os valores foi de 0,0 até 10,0 sendo que a imagem da função pode ser de 0,0 até 10,0. As categorias foram assim divididas: de 0,0 até 3,33 - CLASSE 1; de 3,34 até 6,66 - CLASSE 2; e de 6,67 até 10,0 - CLASSE 3.

A arquitetura da rede é a seguinte: 3 neurônios de entrada, 3 neurônios de saída, uma camada escondida com 4 nós, erro de treinamento de 0,009. A função de ativação escolhida é a função sigmóide (vide Figura 3.3.d).

A FIGURA A.1 apresenta a fase de preparação dos dados e a FIGURA A.2 ilustra o método adotado para a obtenção do reconhecimento para o exemplo proposto. Esta metodologia consistiu, na geração de um conjunto de 125000 casos, do qual foram selecionados aleatoriamente um conjunto de 72 casos para o treinamento. (TABELA A.1).

Para a fase de reconhecimento foi criado um novo conjunto de 125 casos. O novo conjunto e os resultados comparativos, caso a caso, estão na TABELA A.2 e o resultado final está apresentado na TABELA A.3.

FASE DE PREPARAÇÃO
DOS DADOS Geração dos
casos iniciaisCasos iniciais gerados
(125000 casos) Seleção aleatória
de amostra Conjunto de treinamento
(amostra com 72 casos)

FIGURA A.1: Fase de preparação dos dados

FIGURA A.2: Método adotado para o reconhecimento

TABELA A.1 : Conjunto de casos para treinamento

FATOR 1	FATOR 2	FATOR 3	CLASSE
0.40	1.00	3.40	1
0.60	0.60	7.40	2
0.60	2.20	4.20	1
0.80	4.00	2.00	1
1.00	0.60	9.00	2
1.00	7.00	0.80	1
1.20	6.20	10.00	3
1.40	0.40	7.40	2
1.40	1.20	4.60	1
1.60	3.60	3.60	1
1.60	9.80	6.60	2
2.00	0.20	3.60	1
2.00	6.60	9.00	3
2.00	9.40	1.00	2
2.20	3.00	1.20	1
2.40	8.60	3.60	2
2.60	0.40	3.40	1
2.60	8.80	7.20	3
2.80	4.20	1.00	1
2.80	7.80	1.40	2
3.20	2.20	0.80	1
3.20	6.80	2.20	2
3.20	8.60	10.00	3
3.60	1.00	4.20	1
3.60	5.60	6.80	2
3.80	7.00	9.00	3
4.00	0.60	3.80	1
4.00	4.60	2.40	2
4.20	9.20	8.60	3
4.40	0.80	3.00	1
4.40	3.40	3.60	2
4.80	1.60	3.40	1
4.80	2.20	4.40	2
4.80	3.80	9.40	3
5.20	1.00	4.00	2
5.20	3.80	0.60	1
5.20	5.00	8.40	3
5.40	9.60	2.20	2
5.60	4.20	9.60	3
5.80	1.40	2.40	1
5.80	8.40	0.20	2

TABELA A.1 : Conjunto de casos para treinamento (CONTINUAÇÃO)

FATOR 1	FATOR 2	FATOR 3	CLASSE
5.80	9.80	8.40	3
6.20	7.20	3.60	2
6.20	8.60	7.00	3
6.40	1.00	0.40	1
6.60	6.20	5.80	2
6.60	6.20	10.00	3
6.80	9.80	5.60	3
7.00	2.00	0.60	1
7.00	5.40	5.80	2
7.20	6.80	9.00	3
7.40	4.80	4.20	2
7.40	9.60	5.40	3
7.80	1.00	2.80	1
7.80	4.40	1.80	2
7.80	5.40	8.80	3
8.00	8.00	7.20	3
8.20	4.00	6.20	2
8.20	9.60	10.00	3
8.60	4.00	4.20	2
8.60	4.00	9.80	3
8.60	4.40	0.40	1
8.80	6.20	7.80	3
9.00	4.20	3.20	2
9.00	7.60	6.40	3
9.20	8.60	5.60	3
9.40	4.60	3.60	2
9.40	9.20	9.40	3
9.60	9.80	7.60	3
9.80	5.40	0.80	2
10.00	0.60	0.80	1
10.00	0.80	9.80	3

TABELA A.2 : Conjunto de casos para reconhecimento

CASO	FATOR 1	FATOR 2	FATOR3	CALCU- LADO	RN
1	0,00	0,00	0,00	1	1
2	0,10	0,00	2,20	1	1
3	0,20	1,00	5,50	1	1
4	0,30	1,00	6,50	2	2
5	0,40	1,00	9,80	2	2
6	0,50	1,50	0,40	1	1
7	0,60	1,50	2,10	1	1
8	0,70	2,50	4,50	1	1
9	0,80	3,50	6,50	2	2
10	0,90	3,50	10,00	2	3
11	1,00	4,00	0,90	1	1
12	1,10	4,00	2,30	1	1
13	1,20	5,00	5,80	2	2
14	1,30	6,00	7,30	2	2
15	1,40	6,00	9,20	3	3
16	1,50	6,50	1,00	1	1
17	1,60	6,50	2,00	1	1
18	1,70	7,50	3,50	2	2
19	1,80	8,50	7,50	2	3
20	1,90	8,50	8,30	3	3
21	2,00	8,00	0,70	1	1
22	2,10	8,00	2,90	2	2
23	2,20	9,00	5,40	2	2
24	2,30	10,00	7,60	3	3
25	2,40	10,00	9,30	3	3
26	2,60	1,00	0,70	1	1
27	2,70	1,00	2,10	1	1
28	2,80	1,00	5,30	2	2
29	2,90	1,50	7,20	2	2
30	3,00	1,50	8,30	2	2
31	3,10	2,00	0,10	1	1
32	3,20	2,00	2,20	1	1
33	3,30	2,50	3,50	1	1
34	3,40	3,50	8,50	2	2
35	3,50	3,50	9,50	2	3
36	3,60	4,00	0,00	1	1
37	3,70	4,00	2,20	1	1
38	3,80	5,00	6,40	2	2
39	3,90	5,50	6,50	2	2

TABELA A.2 : Conjunto de casos para reconhecimento (CONTINUAÇÃO)

CASO	FATOR 1	FATOR 2	FATOR3	CALCU- LADO	RN
40	4,00	5,50	7,60	2	2
41	4,10	6,00	0,70	1	1
42	4,20	6,50	2,40	2	2
43	4,30	0,50	5,00	2	2
44	4,40	7,50	7,60	3	3
45	4,50	8,00	9,00	3	3
46	4,60	8,50	1,00	2	2
47	4,70	9,00	2,00	2	2
48	4,80	9,00	5,40	2	2
49	4,90	9,50	7,00	3	3
50	5,00	10,00	4,70	2	2
51	5,10	0,50	4,30	1	2
52	5,20	1,00	4,50	2	2
53	5,30	1,00	5,00	2	2
54	5,40	1,50	7,30	2	2
55	5,50	1,50	8,90	2	3
56	5,60	2,00	0,40	1	1
57	5,70	2,00	2,20	1	1
58	5,80	2,50	6,00	2	2
59	5,90	2,80	7,20	2	2
60	6,00	2,90	9,90	3	3
61	6,10	3,50	0,90	1	1
62	6,20	4,00	2,30	2	2
63	6,30	4,50	5,60	2	2
64	6,40	5,00	7,50	2	3
65	6,50	6,00	8,50	3	3
66	6,60	6,50	0,10	1	1
67	6,70	6,50	2,00	2	2
68	6,80	7,00	3,50	2	2
69	6,90	7,00	8,50	3	3
70	7,00	7,50	9,50	3	3
71	7,10	8,00	0,50	2	2
72	7,20	8,50	2,20	2	2
73	7,30	8,50	4,50	2	2
74	7,40	9,00	9,50	3	3
75	7,50	9,60	9,60	3	3
76	7,50	0,60	0,90	1	1
77	7,50	0,80	1,80	1	1
78	7,50	1,00	1,90	1	1

TABELA A.2 : Conjunto de casos para reconhecimento (CONTINUAÇÃO)

CASO	FATOR 1	FATOR 2	FATOR3	CALCU- LADO	RN
79	7,50	1,00	3,50	2	2
80	7,50	1,20	6,20	2	2
81	7,50	2,00	5,60	2	2
82	7,50	2,30	4,30	2	2
83	7,50	2,40	7,00	2	2
84	7,50	2,50	7,10	2	2
85	7,50	2,60	8,70	2	3
86	7,50	3,00	0,00	1	1
87	7,50	3,00	2,30	2	2
88	7,50	4,00	6,50	2	2
89	7,50	5,00	9,50	3	3
90	7,50	5,50	9,20	3	3
91	7,50	6,50	0,50	2	2
92	7,50	6,70	2,30	2	2
93	7,50	7,00	5,90	2	3
94	7,50	7,00	7,50	3	3
95	7,50	7,80	8,40	3	3
96	7,50	7,90	1,50	2	2
97	7,50	8,00	3,50	2	2
98	7,50	9,80	5,50	3	3
99	7,50	9,90	6,50	3	3
100	7,50	10,00	8,50	3	3
101	7,60	0,20	0,50	1	1
102	7,70	0,40	1,50	1	1
103	7,80	0,60	2,50	1	1
104	7,90	0,80	8,50	2	3
105	8,00	1,50	9,70	3	3
106	8,10	2,00	0,70	1	1
107	8,20	2,20	2,20	2	2
108	8,30	2,30	5,40	2	2
109	8,40	3,40	7,20	2	3
110	8,50	4,30	8,90	3	3
111	8,60	4,40	1,00	2	2
112	8,70	4,50	2,10	2	2
113	8,80	5,10	3,50	2	2
114	8,90	5,30	6,50	2	3
115	9,00	5,90	9,00	3	3
116	9,10	6,30	2,00	2	2
117	9,20	7,20	2,50	2	2

TABELA A.2 : Conjunto de casos para reconhecimento (CONTINUAÇÃO)

CASO	FATOR 1	FATOR 2	FATOR3	CALCU- LADO	RN
118	9,30	7,50	3,00	2	2
119	9,40	7,80	7,00	3	3
120	9,50	7,90	8,00	3	3
121	9,60	8,00	1,50	2	2
122	9,70	8,20	2,10	2	2
123	9,80	8,40	7,00	3	3
124	9,90	8,70	9,50	3	3
125	10,00	9,10	10,00	3	3

TABELA A.3 : Resultado comparativo

TESTE x RN	CLASSE1	CLASSE2	CLASSE3	Não Ident.	%Acerto
CLASSE 1	31	1	0	0	96,9
CLASSE 2	0	55	10	0	84,6
CLASSE 3	0	0	28	0	100,0
% Total de Acerto					91,2

REFERÊNCIAS BIBLIOGRÁFICAS

AUTRET P., BRILLET F., BROUSSE J.L. (1991) *Développement d'un système d'aide à la gestion d'un réseau routier*. LCPC, Paris.

BITTENCOURT G. (1996) *Inteligência Artificial Ferramentas e Teorias*, Instituto de Computação, UNICAMP, Campinas.

CÂMARA G., CASANOVA M. A., HEMERLY A. S., MAGALHÃES G. C., MEDEIROS C. M. B. (1996) *Anatomia de Sistemas de Informação Geográfica*, Instituto de Computação, UNICAMP, Campinas.

COELHO P. S. M., MAGALHÃES J. P. (1986) *Procedimento para cálculo do Índice de Suficiência*. Departamento Nacional de Estradas de Rodagem, Ministério dos Transportes, Rio de Janeiro.

CYBENKO G. (1989) *Approximation by superposition of a sigmoidal function*. Mathematics of Control, signals and Systems, vol 2, pp. 303-314.

DNER-PRO 007/94. (1994) *Avaliação subjetiva da superfície de pavimentos*. Departamento Nacional de Estradas de Rodagem, DNER, Ministério dos Transportes.

DNER-PRO 008/94. (1994) *Avaliação objetiva da superfície de pavimentos flexíveis e semi-rígidos*. Departamento Nacional de Estradas de Rodagem, DNER, Ministério dos Transportes.

DNER-PRO 159/85 (1985) *Projeto de restauração de pavimentos flexíveis e semi-rígidos*. Departamento Nacional de Estradas de Rodagem, DNER, Ministério dos Transportes.

- DNER-PRO 164/94 (1994) *Método de nível e mira para calibração de sistemas medidores de irregularidade tipo resposta*. Departamento Nacional de Estradas de Rodagem, DNER, Ministério dos Transportes.
- DOMINGUES F. A. A. (1993) *Gerência de pavimentos: O uso do modelo HDM-III*. Apostila da EPUSP, São Paulo.
- DOMINGUES F. A. A. (1993) *Manual para identificação de defeitos de revestimentos asfálticos de pavimentos*, São Paulo.
- FILHO E. C. B. C., LUDERMIR T. B., JUNIOR W. R. O. FRANÇA F. G. (1994) *Minicurso: modelagem, aplicações e implementações de redes neurais*. I Congresso Brasileiro de Redes Neurais. Itajubá MG.
- FORTES F. Q. (1994) *Pavimentos de baixo custo: considerações sobre seus defeitos e propostas de conservação e recuperação*. 163p. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo.
- FREEMAN J. A., SKAPURA D. M. (1992) *Neural networks: algorithms, applications and programming techniques*. Addison-Wesley Publishing Company.
- HAAS R., HUDSON W. R. (1978) *Pavement management systems*. McGraw Hill.
- HAYKIN S.. (1994) *Neural networks: A comprehensive foundation*. Macmillan College Publishing Company.
- HEBB D. O. (1949) *The organization of behavior: a neuropsychological theory*. Wiley. New York.
- HECHT-NIELSEN R.(1989) *Theory of the backpropagation neural network*. Proc. IJCNN (Washington) D.C., pp. 18-22.
- HECHT-NIELSEN R.(1990) *Neurocomputing*. Addison-Wesley Inc., New York, 1990.

- HERRIGEL, E. (1994) *A arte cavalheiresca do arqueiro zen*. Ed. Pensamento, São Paulo, 12^a edição.
- HUDSON W. R., FERNANDES JR J. L. F.(1994) *Curso intensivo de gerência de pavimentos*. DER-MG e IPC, Belo Horizonte.
- HUDSON W. R., HAAS R. (1994) *Future directions and need for innovation in pavement management*. Third International Conference on Managing Pavements. San Antonio, Texas, vol 1, pp 121-130.
- PANT P. D. et al. (1994) *Neural-network-based procedure for condition assessment of utility cuts in flexible pavements*. TRR 1399.
- PHAN D.T., LIU W..(1995) *Neural networks for identification, prediction and control*. Springer-Verlag.
- PEREIRA A. M.(1972) *Um método de avaliação de pavimentos flexíveis e semi-rígidos*. II^a Reunião das Organizações Rodoviárias e Reunião da International Road Federation, Brasília.
- PETERSON D. E.(1987). *Pavement management practices*. NCHRP n. 135, nov. 1987, 139p.
- MARAR J. F. (1996). *Polinômios-Potência de Sigmóide (PPS): Uma nova técnica para aproximação de funções, construção de wavenets e suas aplicações em processamento de imagens e sinais*. Tese de Doutorado em andamento, Departamento de Informática, UFPE, Recife.
- QUEIROZ C. A. V..(1984) *Modelos de previsão do desempenho para a gerência de pavimentos no Brasil*. DNER.
- QUEIROZ C. A. V. (1994) *Technical and economic issues in road deterioration and maintenance*. Seminario Provial, Fortaleza, Ceará.
- QUEIROZ C. A. V., HUDSON W. R., HAAS R. (1994) *Standatization of pavement management systems in Brazil and other developing countries*. Transportation Research Record 1344. pp 31-37.

RICH E., KNIGHT, K. (1994) *Inteligência Artificial*. Makron Books do Brasil Editora Limitada. 722pp.

ROAD DETERIORATION STUDY : LISTING OF PAVED ROAD DATA FILES
(1985) Research on the interrelationships between costs of highway construction, maintenance and utilization - Brazil. Transportation Department, The World Bank, Washington D.C..

RUMELHART D. E., HINTON G. E., WILLIAMS R. J. (1986) *Learning Representations by back-propagating errors*. Nature (Londres) 323, pp 533-545.

RUMELHART D. E., HINTON G. E., WILLIAMS R. J. (1986) *Learning internal representations by error propagation*. Parallel Distributed Processing, vol 1, pp 318-362.

VIZIR - Méthode assistée par ordinateur pour l'estimation des besoins en entretien d'en réseau routier (1991) LCPC, Paris.

WATANADA T. et al. *The Highway Design and Maintenance Standards Model - Vol 1 - Descrição do Modelo HDM-III*. (1987) Banco Mundial, Washigton, U.S.A.