

USO DE REDES NEURAS ARTIFICIAIS PARA O DESENVOLVIMENTO DE MODELOS DE PREVISÃO DA CONDIÇÃO DE PAVIMENTOS DE AEROPORTOS

R. K. M. Assis, J. B. C. Durán, A. L. Cunha, C. S. Pitombo e J. L. Fernandes Jr.

RESUMO

O objetivo deste trabalho é desenvolver modelos de previsão da condição de pavimentos aeroportuários com uso da técnica de Redes Neurais Artificiais. Foram realizadas 20 simulações, com variação do conjunto de variáveis, do método utilizado, da arquitetura da rede, da função de ativação e do tipo de treinamento, mantendo-se constante a partição do banco de dados. As análises foram realizadas considerando-se três escalas de condição do pavimento, contendo 7, 5 e 3 categorias. O conjunto de dados abrangeu as variáveis numéricas Severidade, Densidade do Defeito, Valor Deduzido e ICP (Índice de Condição do Pavimento) de cada amostra e as variáveis categóricas Seção, Severidade e Defeito segundo a ASTM. Os resultados obtidos mostram um alto índice de acerto de alguns dos modelos gerados, destacando-se que os melhores resultados foram obtidos com a escala com três categorias (Condição Boa, Regular ou Ruim).

1 INTRODUÇÃO

Existem diversas formas de se avaliar a condição dos pavimentos, que afeta a percepção dos usuários em relação ao conforto e também os efeitos que um pavimento provoca nos veículos. A primeira forma de avaliação funcional dos pavimentos foi concebida por Carey e Irick (1960), quando do experimento rodoviário da AASHO (American Association of State Highway Officials), através do Valor de Serventia Atual (VSA), obtido da média de notas de avaliadores, cuja principal preocupação era com o conforto ao rolamento de um determinado trecho, em um dado momento da vida do pavimento.

No Brasil, esse índice é adotado através da norma DNIT 009/2003-PRO, com o VSA compreendendo valores entre 0 e 5, onde 0 é o limite inferior da condição muito ruim e 5 é o limite superior da condição muito boa. Outra forma de se avaliar a condição funcional dos pavimentos adotada no Brasil é o Índice de Gravidade Global (IGG), normalizado pela norma DNIT 006/2003 – PRO. Trata-se de um índice determinado com base no levantamento de defeitos em uma área amostral da via, com o registro apenas da ocorrência ou não de um determinado defeito nas seções do levantamento, sem quantificação da extensão e com limitada avaliação da severidade com que os defeitos se apresentam. Em relação aos tipos de defeito tem-se: fissuras e trincas; trincas em bloco ou por fadiga sem erosão; trincas em bloco ou por fadiga com erosão; afundamentos localizados ou nas trilhas de roda; corrugação e panelas; exsudação; desgaste; remendos. O IGG é calculado com base na frequência de ocorrência dos defeitos, juntamente com fatores de ponderação para cada defeito. O índice pode assumir valores entre 0 (melhor condição) e valores acima de 160 (pior condição).

Da mesma forma que o IGG, outro índice que utiliza a observação de defeitos no pavimento é o ICP (Índice de Condição do Pavimento). Contudo, a determinação do ICP é baseada na quantificação da extensão dos defeitos, para cada nível de severidade encontrado no segmento em análise (não apenas numa área de avaliação, representativa do segmento). O ICP, para pavimentos aeroportuários, é normatizado pela ASTM (American Society for Testing and Materials), através da norma D5340-12, podendo apresentar valores no intervalo de 0, para o pavimento na pior condição, a 100, para o pavimento em perfeitas condições. Sua determinação é feita a partir de pontuações a serem deduzidas (Valor Deduzido – VD), em função da extensão da ocorrência e da severidade com que os defeitos se apresentam.

2 ESCALAS DE CLASSIFICAÇÃO DO ICP

Com o valor de ICP, os Sistemas de Gerência de Pavimentos (SGP) podem indicar qual a melhor estratégia de intervenção nos pavimentos, dentre cinco opções: nada a fazer, manutenção preventiva, manutenção corretiva, reforço e reconstrução. Em outras palavras, há correspondência entre as escalas de classificação com a melhor estratégia de Manutenção e Reabilitação (M&R) do pavimento.

O FAA (*Federal Aviation Administration*) apresenta uma classificação com 7 categorias para o ICP (FAA, 2014), ou seja, com um maior detalhamento das piores condições do pavimento. Por outro lado, o Instituto do Asfalto recomenda a utilização de 3 categorias.

Deve-se destacar que, para os outros índices utilizados no Brasil, particularmente para pavimentos rodoviários (IGG e VSA), as escalas de classificação propostas nas normas contemplam 5 categorias, descritas na Tabela 1:

Tabela 1: Escalas de classificação do IGG e do VSA

Escala de Classificação IGG		Escala de Classificação VSA	
Conceito	Faixa	Conceito	Faixa
Ótimo	0 - 20	Muito Bom	4 - 5
Bom	21 - 40	Bom	3 - 4
Regular	41 - 80	Regular	2 - 3
Ruim	81 - 160	Ruim	1 - 2
Péssimo	> 160	Muito Ruim	0 - 1

Durán (2015) comenta sobre algumas restrições das escalas de classificação da condição do pavimento, tanto do FAA como do Instituto do Asfalto, pois a primeira dificulta a identificação entre condições diferentes do pavimento, enquanto a segunda prejudica a seleção da estratégia de M&R para recuperação da sua condição funcional. Destaca, inclusive, que seria recomendável, do ponto de vista técnico, a utilização de uma escala de classificação com 5 categorias.

3 REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNA, ou, em inglês, Artificial Neural Networks – ANN), podem ser definidas, de maneira resumida, como uma técnica de Análise Multivariada de Dados, que utiliza o processamento de informações em paralelo, visando simular o comportamento de uma rede neural biológica. O seu uso, segundo Haykin (2001), tem sido motivado pelo fato de o cérebro humano ser, reconhecidamente, um computador altamente complexo, não-linear e paralelo, com capacidade de realizar certos processamentos, como reconhecimento de padrões, com velocidade muito maior do que os mais potentes computadores digitais existentes. E, apesar da alta capacidade de processamento, o mesmo ocorre em unidades de processamento bastante simples, chamadas neurônios, porém com interligações maciças.

A alta capacidade de processamento é atribuída ao que comumente se chama de “experiência”, ou seja, o conhecimento adquirido e armazenado pelos neurônios quando submetidos a um estímulo. A Figura 1 apresenta um esquema simples de funcionamento do sistema nervoso (rede neural), que recebe informações das células receptoras, processa essas informações e toma decisões através das células atuadoras, gerando uma resposta ao estímulo.




Figura 1: Representação Gráfica do Sistema Nervoso (HAYKIN, 2001)

A técnica de RNA visa, portanto, modelar o funcionamento de uma rede neural. Contudo, Haykin (2001) destaca que as redes desenvolvidas em computadores são bastante primitivas se comparadas ao cérebro humano e que os níveis estruturais de organização do sistema nervoso central não são replicáveis computacionalmente. De uma forma simplificada (Figura 2), nas RNA os receptores representam os neurônios da camada de entrada (*input*), a rede neural propriamente dita representa as camadas ocultas (*hidden*) e os atuadores representam os neurônios da camada de saída (*output*). Nessa representação, observa-se que cada terminal de entrada do neurônio está recebendo um valor e cada terminal de entrada apresenta um peso associado a ele. A ponderação dos valores recebidos com os pesos de cada terminal é somada e sobre o valor total recebido pelo neurônio é aplicada uma função de ativação, que restringe a amplitude de saída de um neurônio.

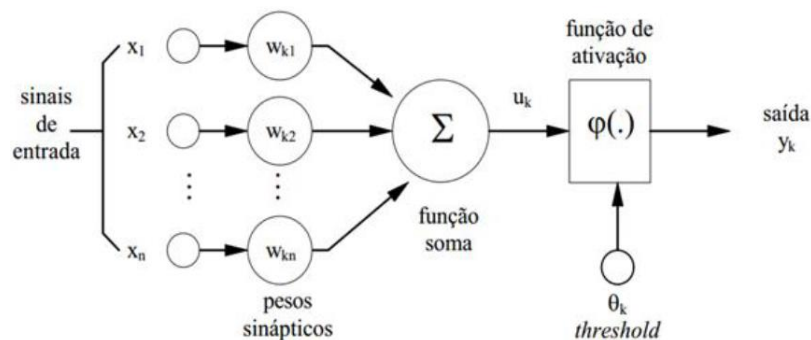


Figura 2: Modelo de um Neurônio Artificial (HAYKIN, 2001)

4. MÉTODO PROPOSTO

Este trabalho visa avaliar diferentes escalas de classificação da condição do pavimento, de modo a identificar qual a condição que melhor se enquadra em cada uma das ocorrências do banco de dados em análise. Em seguida, avaliar os acertos entre os modelos, assim como as diferenças encontradas nas escalas de classificação. Deste modo, foi selecionado um banco de dados referente à avaliação de pavimento flexível, determinadas as variáveis que representam a condição dos segmentos analisados e definidos os cenários das simulações.

4.1. Banco de Dados Utilizado

Foi utilizado um banco de dados com 667 observações de defeitos existentes no pavimento do Aeroporto Estadual Bartolomeu de Gusmão, no município de Araraquara-SP. Esse banco de dados foi coletado por Durán (2015) e utilizado para avaliação da condição do pavimento do aeroporto em sua totalidade, dividido, de acordo com o seu uso, em pista de pouso e decolagem (representada no banco de dados com o código “PI”), pista de rolagem (código “TX”) e pátio de aeronaves (código “PA”).

O banco de dados apresenta as variáveis utilizadas no cálculo do ICP. Há variáveis categóricas, que classificam as seções e as amostras, o tipo de defeito encontrado no pavimento (com seu respectivo código, segundo a norma da ASTM) e a severidade do defeito (variável ordinal), e variáveis numéricas: quantidade do defeito (em m²), área da amostra (m²) e Valor Deduzido (entre 0 e 100), bem como os índices que expressam a qualidade do pavimento (ICP, SCI – *Structural Condition Index* – e FOD – *Foreign Object Debris*), tanto para as amostras, como para as seções. Apenas as variáveis VD (Valor Deduzido), ICP, SCI e FOD são determinadas através de cálculo, com o aplicativo *FAA PAVEAIR*, da FAA (2015). As demais variáveis são obtidas em levantamento no campo, conforme procedimento estabelecido na norma ASTM D5340-12.

Para complementar o banco de dados e auxiliar nas simulações, foram incluídas as variáveis numéricas Severidade (número que expressa, de forma ordinal, o grau de severidade de cada defeito) e Densidade do Defeito (razão entre a quantidade do defeito e a área da amostra) e variáveis categóricas que classificam o pavimento na área da amostra, considerando-se três escalas de classificação, com 3, 5 ou 7 grupos (Tabela 2).

Tabela 2: Escalas de classificação utilizadas

Configuração A (7 grupos)		Configuração B (5 grupos)		Configuração C (3 grupos)	
Conceito	Faixa	Conceito	Faixa	Conceito	Faixa
Excelente	86 - 100	Muito Bom	91 - 100		
Muito Bom	71 - 85	Bom	71 - 90	Bom	71 - 100
Bom	56 - 70				
Regular	41 - 55	Regular	51 - 70	Regular	51 - 70
Ruim	26 - 40				
Muito Ruim	11 - 25	Ruim	31 - 50		
Rompido	0 - 10	Muito Ruim	0 - 30	Ruim	0 - 50

A Configuração A (7 grupos) é a recomendada pelo *United States Army Corps of Engineers* (USACE), em seu documento CERL-Tr-M-268, e é utilizada também pelo DNIT em sua norma 063/2004. A ASTM recomenda os mesmos valores em sua escala, porém com nomenclatura diferente. A Configuração B (5 grupos) foi proposta por Durán (2015), tomando como base experiências anteriores e escalas utilizadas por alguns departamentos de transporte de unidades federativas dos Estados Unidos. A Configuração C (3 grupos) é baseada na adotada pelo Instituto do Asfalto, através do manual MS-16 (AI, 2009), e apresenta as classificações Bom, Regular e Ruim (Durán, 2015).

Para o banco de dados em estudo, a distribuição de frequências em função das classificações do estado funcional do pavimento é apresentada, para cada configuração, nas Figuras 3, 4 e 5. Para a Configuração A há uma concentração maior de ocorrências de Regular a Bom, enquanto que para as Configurações B e C prevalecem as ocorrências de Regular a Ruim.




Figura 3: Distribuição de Frequências da Configuração A

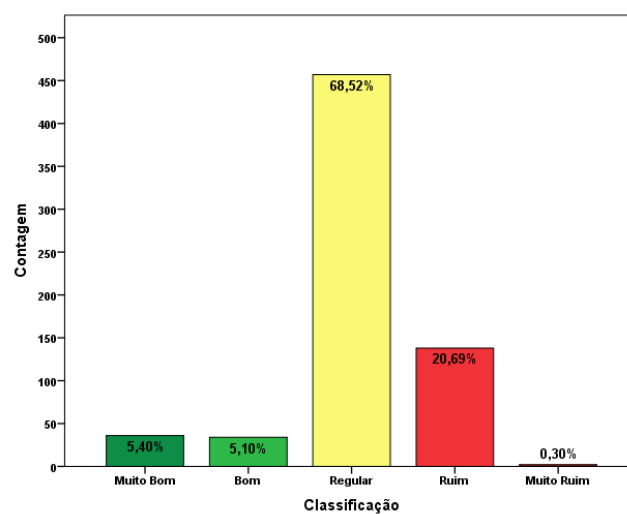


Figura 4: Distribuição de Frequências da Configuração B




Figura 5: Distribuição de Frequências da Configuração C

4.2. Variáveis Utilizadas

Antes das simulações, com aplicação do método de Redes Neurais Artificiais, foi realizada a seleção das variáveis que integrariam, se significativas, os modelos desenvolvidos. Para as simulações foram feitas duas suposições em relação às variáveis independentes: inclusão de variáveis numéricas (Densidade do Defeito, Valor Deduzido e PCI da Amostra) e categóricas (Seção, Severidade e Defeito ASTM); inclusão apenas de variáveis numéricas (com inclusão da variável Severidade, originalmente categórica, agora expressa numericamente). Deve-se destacar que, nas simulações realizadas, todas as variáveis numéricas foram normalizadas, devido à variação dos intervalos das mesmas.

4.3. Definição dos Cenários das Simulações

Foram aplicados dois métodos distintos para as avaliações, realizadas com o programa computacional IBM SPSS Statistics 22: *Perceptron Multicamada* e *Função de Base Radial*.

Nas simulações realizadas com o método *Perceptron Multicamada*, as variações ocorreram em função do conjunto de variáveis independentes (categóricas e numéricas ou apenas numéricas), da definição da arquitetura de rede (automática ou personalizada) e do tipo de treinamento (Lote ou Online). Quando utilizadas arquiteturas de rede personalizadas, adotou-se sempre duas camadas intermediárias, com 3 neurônios na primeira camada e 2 neurônios na segunda camada, sendo essa arquitetura utilizada somente para fins exploratórios, sem possuir uma experiência prévia da arquitetura mais adequada ao banco de dados em estudo. Houve também a variação das funções de ativação (Tangente Hiperbólica ou Curva Sigmoide). Com o método *Perceptron Multicamada* foram realizadas 12 simulações.

Nas simulações utilizando-se o método *Função de Base Radial*, as variações ocorreram também em função do conjunto de variáveis e da definição da arquitetura de rede, porém não havia variação quanto ao tipo de treinamento e, quando utilizada a definição de arquitetura de rede automática, as funções de ativação foram normalizadas ou ordinárias. Com a aplicação desse método foram realizadas 8 simulações.

As Tabelas 3 e 4 apresentam os resultados das simulações, em que “X” indica a utilização de determinada configuração e N/A significa “não se aplica”. Em todas as 20 simulações, a partição do banco de dados foi definida no software de maneira a se ter 70% para treinamento, 20% para teste e 10% para validação, tendo-se como variável dependente a classificação da condição do pavimento, considerando-se as 3 configurações apresentadas na Tabela 2.

Tabela 3: Resumo das simulações para o método *Perceptron Multicamada*

Simulação	Conjunto de Variáveis		Arquitetura		Treinamento		Função de Ativação	
	Catégorica e Numérica	Apenas Numérica	Autom.	Person.	Lote	Online	Tangente Hiperbólica	Curva Sigmóide
SIM1	X		X		X		N/A	N/A
SIM2	X		X			X	N/A	N/A
SIM3	X			X	X		X	
SIM4	X			X		X	X	
SIM5	X			X	X			X
SIM6	X			X		X		X
SIM7		X	X		X		N/A	N/A
SIM8		X	X			X	N/A	N/A
SIM9		X		X	X		X	
SIM10		X		X		X	X	
SIM11		X		X	X			X
SIM12		X		X		X		X

Tabela 4: Resumo das simulações para o método *Função de Base Radial*

Simulação	Conjunto de Variáveis		Arquitetura		Função de Ativação	
	Catégorica e Numérica	Numérica	Automática	Personalizada	Normalizada	Ordinária
SIM13	X		X		X	
SIM14	X		X			X
SIM15	X			X	X	
SIM16	X			X		X
SIM17		X	X		X	
SIM18		X	X			X
SIM19		X		X	X	
SIM20		X		X		X

Em todas as simulações onde a arquitetura foi definida automaticamente pelo software, a rede apresentou somente uma camada intermediária (o que ocorre na Função de Base Radial por definição do método), com um número variável de neurônios na mesma. O número de neurônios da camada intermediária de cada simulação é apresentado na Tabela 5:

Tabela 5: Número de neurônios na camada oculta

Simulação	SIM1	SIM2	SIM7	SIM8	SIM13	SIM14	SIM17	SIM18
Nº Neurônios	10	6	8	8	13	7	4	13

5. RESULTADOS

Para cada caso, os modelos gerados realizam previsões da classificação através do comparativo com a sua classificação efetiva, determinando assim um índice de acertos do modelo. Em cada simulação realizada, o software apresenta, no resumo do modelo, o percentual de previsões incorretas. Da mesma forma, é apresentada a porcentagem correta das previsões em cada etapa do processamento: Treinamento (TR), Testes (TT) e Validação (VA). Com esses índices, os resultados de todas as simulações foram compilados e são apresentados na Tabela 6, em que se pode observar que as simulações que obtiveram os melhores resultados em termos de percentual de previsões corretas foram as simulações SIM2, SIM7 e SIM8.

Tabela 6: Resumo de acertos das Vinte Simulações Realizadas

Simulação	Configuração A			Configuração B			Configuração C		
	TR	TT	VA	TR	TT	VA	TR	TT	VA
SIM1	96,9%	90,0%	88,2%	97,1%	92,5%	95,6%	99,4%	97,5%	97,1%
SIM2	99,6%	99,2%	97,3%	98,9%	100,0%	98,6%	100,0%	100,0%	98,6%
SIM3	82,2%	88,7%	83,6%	92,5%	95,5%	97,0%	98,3%	97,0%	100,0%
SIM4	81,3%	75,7%	77,6%	93,5%	92,8%	92,1%	98,8%	94,6%	98,7%
SIM5	53,9%	48,5%	48,5%	68,0%	72,0%	65,2%	68,0%	72,0%	65,2%
SIM6	72,3%	76,7%	72,6%	68,9%	71,7%	65,8%	68,9%	71,7%	67,1%
SIM7	99,1%	99,2%	98,6%	99,8%	99,2%	100,0%	100,0%	100,0%	100,0%
SIM8	98,9%	98,7%	95,8%	99,6%	99,3%	98,6%	100,0%	100,0%	100,0%
SIM9	82,3%	81,5%	78,7%	92,3%	92,7%	85,3%	97,6%	96,8%	92,0%
SIM10	83,3%	83,9%	83,9%	91,8%	93,4%	85,7%	95,1%	95,6%	96,4%
SIM11	46,3%	45,5%	49,4%	67,0%	71,2%	72,7%	67,0%	71,2%	72,7%
SIM12	46,0%	44,6%	54,7%	67,5%	71,9%	71,9%	67,5%	71,9%	71,9%
SIM13	68,5%	58,2%	63,4%	75,8%	71,9%	77,5%	78,1%	73,3%	80,3%
SIM14	68,5%	67,4%	70,0%	76,0%	65,9%	60,0%	79,2%	70,5%	64,3%
SIM15	65,3%	70,2%	66,2%	74,0%	70,9%	66,2%	75,4%	70,9%	66,2%
SIM16	68,5%	69,9%	64,9%	69,8%	70,7%	71,6%	75,8%	74,8%	74,3%
SIM17	78,9%	82,7%	74,7%	89,5%	89,5%	81,3%	91,7%	92,5%	84,0%
SIM18	85,3%	82,1%	78,8%	90,1%	88,9%	83,3%	90,5%	88,9%	83,3%
SIM19	66,2%	57,5%	66,2%	80,0%	85,1%	73,5%	82,8%	85,1%	79,4%
SIM20	71,3%	66,9%	65,7%	82,2%	79,7%	80,6%	83,3%	80,5%	85,1%

Das simulações que obtiveram os maiores índices de acerto, a SIM2 é a única que utiliza variáveis categóricas e, embora tenha apresentado um percentual de acerto médio menor do que a SIM7 e a SIM8 (que utilizam apenas variáveis numéricas), de um modo geral os modelos que utilizaram o conjunto de variáveis completo (com variáveis categóricas) apresentaram desempenho superior aos modelos gerados apenas com variáveis numéricas.

Quanto aos modelos gerados, o método *Perceptron Multicamada* apresentou melhores resultados do que o método *Função de Base Radial*.

Nas três simulações que apresentaram os melhores resultados, quase sempre um menor número de grupos na escala de classificação corresponde a um maior percentual de acerto do modelo, no máximo há um empate entre as Configurações A e B ou entre B e C. Ou seja, para o banco de dados em estudo, quanto maior o número de grupos utilizados para classificar a condição do pavimento, menores são as chances de um modelo desenvolvido através das redes neurais acertar em qual desses grupos está incluído um elemento.

Ao se realizar uma análise dos elementos onde os modelos erram suas previsões, será possível perceber que esses erros ocorrem, em sua maioria, nas extremidades das escalas, ou seja, em valores muito baixos ou muito altos, notadamente nos limites entre os diferentes grupos. Um exemplo é na SIM7, em que o modelo da Configuração A errou cinco vezes entre as classificações Regular e Ruim e errou uma vez ao classificar um elemento de classificação “Excelente” como “Muito Bom”. Para a mesma SIM7, o modelo da Configuração B errou apenas duas vezes, entre as categorias “Bom” e “Muito Bom”, e o modelo da Configuração C não apresentou erros.

Para a avaliação dos modelos com outro banco de dados, foram usados dados disponíveis no endereço eletrônico do FAA, contendo 65 elementos representativos de todas as faixas de ICP, e considerando-se as três configurações descritas anteriormente. Após a classificação de todos os elementos, foram utilizados os modelos da SIM7 e SIM8 para realizar previsões das categorias em que se encontrariam os novos elementos e comparar com as categorias observadas (Tabela 7).

Os resultados confirmam que, considerando-se um banco de dados diferente, os modelos passam a cometer mais erros, pois a aplicação de Redes Neurais Artificiais depende muito dos dados que alimentam os neurônios nos processos de Treinamento e Testes. Contudo, ainda que haja uma taxa de acerto menor, os modelos desenvolvidos neste trabalho apresentaram índices de acerto satisfatórios, como ocorreu com ambas as simulações na Configuração C e para a SIM8 da Configuração B, reforçando a constatação de que a utilização de um número maior de grupos numa escala de classificação pode provocar uma diminuição da qualidade das previsões, ainda que os dados do FAA não abrangessem a condição “Destruído” e isso pudesse explicar em parte os resultados obtidos.

Tabela 7: Acertos dos modelos gerados, aplicados a um novo banco de dados

Configuração	Acertos	
	SIM 7	SIM 8
A	69,2%	66,2%
B	67,7%	87,7%
C	98,5%	96,9%

6. CONCLUSÕES

Este trabalho analisou a aplicação da técnica de Redes Neurais Artificiais (RNA) na criação de modelos para previsão da condição de pavimentos aeroportuários. Foi utilizado o banco de dados do Aeroporto Estadual de Araraquara. Na criação dos modelos, foram definidos diferentes cenários de simulação, considerando-se três configurações distintas

nas escalas de classificação (3, 5 e 7 grupos). Constatou-se que escalas de classificação com um maior número de grupos tendem a apresentar maiores erros nos modelos gerados através das RNA, o que é esperado, uma vez que essa técnica apresenta isso como uma característica inerente.

Constatou-se, também, que os modelos desenvolvidos são aplicáveis à análise de outros bancos de dados de pavimentos aeroportuários, porém com menores índices de acerto, especialmente em valores de ICP que não constavam dos dados utilizados no treinamento dos neurônios. Sendo assim, é desejável que os modelos criados passem por testes com outros bancos de dados, a fim de aperfeiçoá-los, num processo cíclico, através da retroalimentação do modelo.

Finalmente, a aplicação de técnicas de Análise Multivariada de Dados em bancos de dados voltados à gerência de pavimentos aeroportuários é de grande importância, uma vez que tais técnicas podem auxiliar na tomada de decisão, ao permitir agrupamentos, criação de modelos, comparação com modelos existentes e o uso das RNA em análises financeiras, como destacam Yang *et al* (2003) e Randolph (1996).

AGRADECIMENTO

Os autores agradecem à FAPESP (Processo nº 2016/14056-6) o suporte financeiro para a realização desta pesquisa.

7 REFERÊNCIAS

AI (2009) **Asphalt in Pavement Preservation and Maintenance**. Asphalt Institute. MS-16 4th Ed. ISBN 978-1934154-58-8. Lexington, KY, USA. 155p.

ASTM (2012) **Standard Test Method for Airport Pavement Condition Index Surveys**. American Society of Testing Materials – D5340-12.

Carey Jr., W.N., Irick, P.E. (1960) The pavement serviceability-performance concept. **HRB Bulletin**, 250, 40-58.

Durán, J. B. C. (2015) **Sistema de Gerência de Pavimentos Aeroportuários: estudo de caso no Aeroporto Estadual de Araraquara**. Dissertação (Mestrado) – Programa de Pós-graduação em Engenharia de Transportes. Escola de Engenharia de São Carlos. Universidade de São Paulo, São Carlos, SP.

FAA (2014) **Airport Pavement Management Program**. Advisory Circular – AC 150/5380-7B. Federal Aviation Administration. United States Department of Transportation. Washington, DC.

FAA (2015) **FAA PAVEAIR**. Acesso às bases de dados. Disponível em: <<http://faapaveair.faa.gov/Default.aspx>>. Acesso em: 24 nov.2015.

Haykin, S. (2001) **Redes Neurais: Princípios e Prática**. trad. Paulo M. Engel. Porto Alegre, Bookman. 900 p.

Randolph, D. A. (1996) Application of Neural Network Technology to Highway Maintenance Management. **Transportation Research Record**, 1533, 3–10.

Yang, J., Lu, J.J., Gunaratne, M. e Xiang, Q. (2003) Forecasting Overall Pavement Condition with Neural Networks: Application on Florida Highway Network. **Transportation Research Record**, 1853, 3–12.