

REDES NEURONAIS PARA A PREVISÃO DO MÓDULO DE RESILIÊNCIA DE MISTURAS ASFÁLTICAS DENSAS

Leonardo Goliatt, Michèle C. R. Farage, Gabriela C. Polisseni, Flávio S. Barbosa e Geraldo L. Marques

^aUniversidade Federal de Juiz de Fora, MG Rua José Lourenço Kelmer, s/n – Campus Universitário, Bairro São Pedro - CEP: 36036-900, Juiz de Fora, Minas Gerais, Brasil

Palavras Chave: Misturas asfálticas, Módulo de Resiliência, Redes Neurais Artificiais.

Resumo. O Módulo de Resiliência é uma das principais propriedades mecânicas de misturas asfálticas, sendo empregada nas etapas de projeto e dimensionamento de pavimentos asfálticos. Trata-se de uma grandeza análoga ao módulo de elasticidade do concreto de cimento Portland, sendo determinado por meio de ensaios dinâmicos. Dentre os fatores que influenciam o valor desta propriedade citam-se parâmetros relacionados aos componentes empregados na dosagem e confecção da mistura, como granulometria e tipo de agregados, tipo e teor de ligante, técnica de compactação, e a temperatura ambiente. Pretende-se neste trabalho empregar redes neurais artificiais para estimar o Módulo de Resiliência com base em parâmetros da mistura. Para tanto, será empregado um banco de dados experimentais em que se consideram os principais fatores de influência. Os resultados preliminares aqui obtidos encorajam a aplicação a conjuntos de caráter mais geral, visando no futuro o desenvolvimento de ferramentas que permitam estabelecer critérios de projeto na etapa de dosagem de misturas asfálticas.

1 INTRODUÇÃO

O principal sistema de transporte do Brasil é o rodoviário, formado por um conjunto de redes de 1.691.522 km de estradas e rodovias nacionais (DNIT-DPP-CG-PLAN, 2014). Os pavimentos da superestrutura rodoviária são formados por multicamadas: subleito, regularização e reforço do subleito, sub-base, base e revestimento ou capa selante. A camada responsável por suportar as tensões e deformações provenientes de todas as cargas da frota de veículos e da ação climática é o revestimento. Com o grande aumento do tráfego de viaturas no país, são cada vez mais frequentes os problemas de durabilidade relacionados ao comportamento mecânico de pavimentos. É, portanto, extremamente importante conhecer detalhadamente os constituintes do revestimento e suas interações afim de construir estruturas mais duráveis e resistentes, tanto por razões econômicas quanto por aspectos relacionados à segurança dos usuários.

A grande maioria dos pavimentos brasileiros empregam os revestimentos asfálticos, constituídos, basicamente, da associação de ligantes asfálticos e agregados minerais que, de forma proporcionada, geram misturas que devem ser capazes de assegurar impermeabilidade, flexibilidade, estabilidade, durabilidade e resistência estruturais. Uma das propriedades mais importantes para a análise de tensões e deformações na estrutura de pavimentos é o Módulo de Resiliência Asfáltico (MR) que é análogo ao módulo de elasticidade: ambos são definidos na relação entre tensão e deformação, sendo que o MR é determinado por meio de ensaios de carga aplicada repetidamente no plano diametral vertical de um corpo-de-prova cilíndrico regular (Marques, 2004). Para este fim, os ensaios mais comumente empregados são: tração uniaxial, compressão uniaxial, flexão em viga, tração diametral indireta e compressão triaxial.

Observa-se que o MR é influenciado por diversos parâmetros relacionados à dosagem das misturas, tais como tipo, quantidade e granulometria dos agregados, teor e tipo de ligante asfáltico, assim como a técnica e o grau de compactação adotados na confecção do material. A temperatura ambiente também é um fator importante, que altera fortemente a viscosidade do material.

Durante as etapas de projeto e dimensionamento de um pavimento asfáltico adota-se para o Módulo de Resiliência um valor que, não raro, é diferente daquele apresentado pelo material empregado na confecção da estrutura. Tal fato decorre da dificuldade em se estabelecer critérios científicos para a dosagem da mistura asfáltica, de modo a permitir que a composição e a compactação empregados durante a fabricação do material sejam determinados com base em requisitos de projeto - como o valor do Módulo de Resiliência. Daí tem-se que, de uma forma geral, o concreto asfáltico fabricado no canteiro de obras é um material diferente daquele considerado pelo projetista nas etapas de cálculo e dimensionamento - o que pode dificultar a previsão e análise do comportamento mecânico da estrutura e afetar a estabilidade e segurança do pavimento.

Existem dois métodos para a dosagem de misturas asfálticas, denominados Marshall e Superpave. Ambos empregam critérios volumétricos para definição do traço. Para fins práticos, não se dispõe atualmente de técnicas que permitam estipular a dosagem de uma mistura asfáltica com base em um valor desejado para o Módulo de Resiliência do material pronto - ou mesmo estimar de modo confiável o Módulo de Resiliência a partir dos tipos e proporções adotados para os componentes de uma mistura sem a realização de ensaios mecânicos.

Aplica-se aqui a técnica das Redes Neurais Artificiais (RNAs) para estimar o Módulo de Resiliência de misturas asfálticas. Tais algoritmos computacionais consistem em um modelo matemático inspirado na estrutura neuronal de organismos vivos que, quando treinada, possui a capacidade de aprendizagem e aperfeiçoamento do conhecimento (Silva et al., 2010). As RNAs

são largamente utilizadas para solução de problemas na Engenharia Civil e, em particular, para estimar propriedades mecânicas de materiais a base de cimento, como o módulo de elasticidade (Duan et al., 2013b) e a resistência à compressão (Duan et al., 2013a; Dantas et al., 2013) de concretos feitos com agregados reciclados; a resistência ao cisalhamento de concretos reforçados com fibras (Lee e Lee, 2014) e a retração por secagem de concretos convencionais (Bal e Buyle-Bodin, 2013). Tapkin et al. (2010) aplicou RNAs a misturas de asfalto com fibras de polipropileno, obtendo bons resultados na previsão do Quociente Marshall, que é uma grandeza relacionada à rigidez do material.

O presente trabalho consiste na primeira etapa de um estudo que visa obter uma ferramenta para a dosagem científica de misturas asfálticas, a exemplo de Moretti (2010), que desenvolveu um sistema inteligente baseado em redes neuronais para a dosagem do concreto de cimento Portland baseado em critérios de resistência estabelecidos em projeto. Para tanto, contou-se aqui com informações experimentais referentes a mais de 700 corpos-de-prova, cujo MR foi determinado através de testes mecânicos, considerando a variação de parâmetros diversos (Marques, 2004). Apresentam-se a seguir a descrição geral das informações experimentais empregadas nas análises e os estudos numéricos, que consistiram em uma análise estatística exploratória dos dados experimentais e na estimativa do MR através de modelos de regressão linear e de uma Rede Neuronal Artificial Perceptron Multicamadas com Retropropagação.

2 BANCO DE DADOS EXPERIMENTAIS

As informações experimentais aqui empregadas foram obtidas por Marques (2004) em um extenso programa experimental envolvendo ensaios dinâmicos - destrutivos - em mais de 700 corpos-de-prova feitos com 234 composições distintas - classificadas em três grupos de misturas (aqui denominadas M1, M2 e M3), caracterizadas pelo tipo e granulometria dos agregados empregados. Todos os corpos-de-prova foram confeccionados através do Método Marshall - empregando 75 golpes na compactação por impacto. Os parâmetros variados na composição das misturas foram os seguintes:

- Propriedades dos volumétricas das misturas: valores medidos em laboratório, para cada corpo-de-prova, das seguintes propriedades: vazios no esqueleto sólido do agregado agregado mineral (VMA, %), vazios preenchidos por asfalto (VFA, %) e teor de vazios da mistura (V_a , %). Embora tais grandezas sejam medidas na mistura já compactada, foram consideradas como entrada de dados por se tratar de grandezas cujos valores admissíveis são estabelecidos em norma (DNIT-DPP-CG-PLAN, 2014);
- Propriedades do ligante asfáltico: foram empregados três tipos de ligantes asfálticos, caracterizados pela viscosidade (Visc), com diferentes origens, denominados CAP 20 e CAP 40, produzido pela REDUC, e o CAP 50/60 produzido pela RELAM. Os teores (t) utilizados nas misturas M1 e M2 foram de 3,5%, 4,5% e 5,5% enquanto que na mistura M3 empregaram-se teores de 4,5%, 5%, 5,5% e 6%;
- Temperatura (T): as amostras foram expostas a temperaturas ambientes de 10, 25 e 35°C.

A Tabela 1 descreve os dados de entrada e a variável de saída aqui empregados, indicando a notação adotada e o número de possíveis valores de cada grandeza (a exemplo de Tsanas e Xifara (2012)). Todos os detalhes sobre as informações experimentais aqui empregadas e o banco de dados completo estão disponíveis na referência (Marques, 2004). A título de ilustração, a Tabela 2 mostra parte do conjunto de dados experimentais aqui empregados. Cada

Tabela 1: Descrição das variáveis de entrada (X1, ..., X6) e de saída (Y1) para facilitar a compreensão das análises e resultados numéricos.

Notação	Variável de entrada ou de saída	Níveis de valores
X1	(Visc) viscosidade, caracterizando o tipo de ligante (P)	3
X2	(t) teor de ligante (%)	3 ou 4 *
X3	(Va) teor de vazios do agregado (%)	90
X4	(VMA) vazios de agregado mineral (%)	90
X5	(VFA) teor de vazios do agregado preenchidos por ligante (%)	90
X6	(T) Temperatura (°C)	3
Y1	(MR) Módulo de Resiliência (MPa)	234

* 3 valores para as misturas M1, M2; 4 valores para M3.

linha corresponde a uma amostra de mistura asfáltica para a qual foram testados três corpos-de-prova para obtenção de um valor médio para o Módulo de Resiliência (MR médio).

Tabela 2: Parte do banco de dados experimentais (Marques, 2004).

Amostra	Visc	t	Va	VMA	VFA	T	MR médio
Variável	X1	X2	X3	X4	X5	X6	Y1
1	3144	4,5	2,43	13,24	1,9	10	13475
2	3144	4,5	2,44	13,05	2,3	10	14730
3	3144	4,5	2,45	12,81	2,6	10	16528
4	3144	5	2,47	12,54	2,3	10	18444
5	3144	5	2,47	12,56	2,2	10	15668
6	3144	5	2,47	12,25	2	10	14309
7	3144	5,5	2,48	12,51	2,2	10	16301
8	3144	5,5	2,48	12,37	2,2	10	17183
9	3144	5,5	2,47	12,78	1,8	10	17730
10	3144	6	2,50	12,43	1,78	10	14898
...
234	4367	6	2,48	13,04	1,2	35	2104

3 MÉTODOS

3.1 Análise Exploratória dos Dados

Para melhor compreensão das variáveis de entrada (X1, X2, ..., X6) foi realizada, previamente à aplicação da RNA, uma análise exploratória de dados. Tal análise estatística permitiu verificar a relação de cada uma das variáveis sobre o valor do Módulo de Resiliência, assim como as possíveis correspondências entre si (Tsanas e Xifara, 2012).

A análise exploratória dos dados é o primeiro passo na compreensão das propriedades estatísticas das variáveis, e é obtida por meio de gráficos e densidades de probabilidades, que sucintamente descrevem visualmente cada variável. Uma forma de se obter uma estimativa da densidade empírica não paramétrica é por meio de histogramas. Os histogramas não fazem hipóteses considerando a distribuição da variável analisada e são de construção extremamente

simples. Este passo inicial pode revelar se a variável possui uma distribuição Gaussiana (normal) ou multimodal, indicar assimetria e o intervalo de variação de seus valores. Além dos histogramas, este trabalho usa gráficos de dispersão para cada variável de entrada com a variável de saída.

Em dados que não apresentam distribuição normal usa-se o Coeficiente de Correlação de postos de Spearman (CCS) para obter uma métrica que quantifica a associação entre cada variável de entrada e a variável de saída. O CCS, que pode caracterizar relações monotônicas gerais, está definido no intervalo $[-1, 1]$, onde o sinal negativo indica relações inversamente proporcionais e o sinal positivo indica relações proporcionais, enquanto a magnitude denota o quão forte é tal relação. Adicionalmente, é interessante verificar se a relação é estatisticamente significativa usando os p -valores e checando a significância no nível 0.01. Além disso, usa-se a Informação Mútua Normalizada (IMN), que fornece a informação que duas variáveis X e Y compartilham. A IMN mede em quanto o conhecimento de uma variável reduz a incerteza sobre a outra. Se X e Y são independentes, então conhecer X não traz nenhuma informação sobre Y (e vice-versa) uma vez que a informação mútua é nula. Por outro lado, se X e Y são idênticas, então toda informação proporcionada por X é compartilhada com Y .

3.2 Relações entre as Variáveis de Entrada e Saída

As $N = 234$ amostras e $d = 6$ variáveis de entrada dados são representadas na forma matricial dada pela Eq.(1):

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1d} \\ x_{21} & x_{22} & \cdots & x_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{Nd} \end{bmatrix} \quad (1)$$

e associadas a uma variável de saída $Y \in \mathfrak{R}^N$. O objetivo é determinar uma relação funcional entre X e Y . Por conveniência, denotamos Y pelo Módulo de Resiliência MR. A ferramenta que representa a relação funcional entre X e Y é chamada de regressor na literatura de aprendizado de máquina. Neste trabalho, usamos uma Rede Neuronal Artificial (RNA) (Haykin, 1998) como regressor e comparamos seu desempenho com um regressor linear chamado Modelo Linear Generalizado (MLG) (Hastie et al., 2009).

3.2.1 Modelos Lineares Generalizados

Modelos Lineares Generalizados (MLG) ajustam um modelo linear com $d + 1$ coeficientes $w = (w_0, w_1, w_2, \dots, w_d)$ que minimizam a soma dos resíduos ponderados entre as respostas observadas no conjunto de dados e as respostas previstas pelo modelo linear.

Matematicamente, o MLG pode ser escrito como um problema de minimização na forma da Eq. 2:

$$\min_w \frac{1}{2N} \|Xw - y\|_2^2 + \alpha \rho \|w\|_1 + \frac{\alpha(1-\rho)}{2} \|w\|_2^2 \quad (2)$$

onde X é dado pela Eq. 3:

$$X = \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1d} \\ 1 & x_{21} & x_{22} & \cdots & x_{2d} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{N1} & x_{N2} & \cdots & x_{Nd} \end{bmatrix}. \quad (3)$$

$\alpha \geq 0$, $\|w\|_2$ e $\|w\|_1$ são respectivamente as normas L_2 e L_1 do vetor de parâmetros w e ρ é a chamada taxa da norma L_1 .

O MLG é um modelo linear treinado com regularização L_1 e L_2 . Essa combinação permite o aprendizado de modelos esparsos onde poucos coeficientes são não-nulos, porém mantendo as propriedades de regularização. Esse compromisso é controlado pelo parâmetro ρ . O MLG é útil quando há múltiplas variáveis correlacionadas entre si.

3.2.2 Redes Neurais Artificiais

Redes Neuronal Artificiais (RNA) podem ser caracterizadas como modelos computacionais com propriedades particulares com a habilidade de adaptação ou aprendizado, para generalizar, agrupar ou organizar dados (Kröse e van der Smagt, 1993). Uma RNA consiste em um conjunto de simples unidades de processamento que se comunicam pela troca de mensagens através de conexões adequadamente construídas. Os principais componentes do modelo são: (1) um conjunto de unidades de processamento; (2) um estado de ativação z_k para cada unidade, que é equivalente à saída da unidade; (3) conexões entre as unidades, geralmente definidas por pesos w_{jk} , e (4) uma função de ativação φ , que determina o novo nível de ativação $z_k = \varphi(s_k)$ baseado na saída efetiva $s_k = \sum w_{kj}x_j$. A Fig. 1 mostra uma rede neuronal com os componentes citados acima.

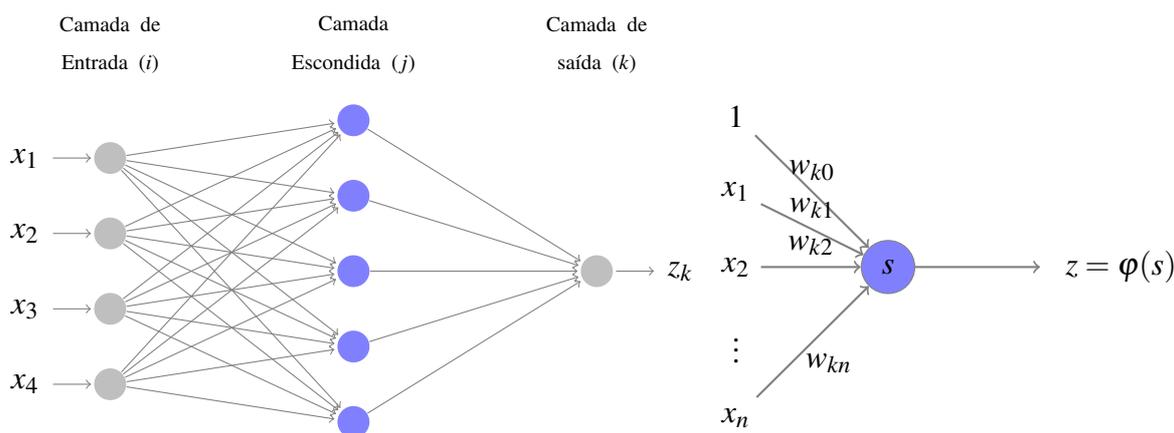


Figura 1: Redes neurais artificiais com múltiplas camadas. As conexões entre as unidades são representadas por w_{kj} e o nível de ativação $z_k = \varphi(\sum w_{kj}x_j)$. À esquerda, um exemplo de uma rede com 4 variáveis de entrada, uma camada escondida com 5 neurônios e uma saída. À direita o esquema de um único neurônio.

Neste trabalho usamos a função de ativação sigmoideal, dada pela expressão $\varphi = 1/(1 + \exp(x))$. A rede neuronal é treinada ajustando-se os pesos sinápticos w_{kj} com o algoritmo L-BFGS (Nocedal e Wright, 2006) com a função de perda dada pela Eq. (4):

$$J(w) = \frac{1}{2} \sum_{k=1}^N (z_k - y_k)^2 + \alpha \|w\|_2 \quad (4)$$

onde N é o número de amostras, z_k é a resposta funcional da rede neuronal, e α é o parâmetro de regularização. O ajuste dos pesos é realizado por um processo iterativo pela adição de correções na forma da Eq. (5)

$$w_{kj} \leftarrow w_{kj} + \eta \Delta w_{kj}, \quad \eta = \frac{\eta_0}{t^{0.25}}. \quad (5)$$

onde t indica o número da iteração corrente.

3.3 Validação Cruzada e Generalização

Após o treinamento do modelo de aproximação, é necessário testar o seu desempenho de generalização, que é o desempenho esperado em um novo conjunto de dados com as mesmas características. Para isso, adotou-se uma técnica estatística de amostragem - o procedimento de validação cruzada com k -fold (Geisser, 1993), em que o conjunto de treinamento original é dividido em k subconjuntos, dos quais um é separado para a validação do modelo treinado/ajustado nos $k - 1$ subconjuntos restantes. O processo de validação cruzada é então repetido k vezes para o modelo treinado, de modo que cada um dos k subconjunto seja utilizado exatamente uma vez como dado de teste para validação do modelo. Usualmente o valor de k é escolhido ente 5 e 10 (Hastie et al., 2009). Neste trabalho usamos $k = 9$, resultando em 9 agrupamentos com 26 amostras.

Para cada execução dos modelos, são armazenados os valores do Índice de Variância (PVE), Erro Médio Absoluto (EMA), Erro Médio Quadrático (EMQ), Erro Médio Percentual (EMP) e Coeficiente de Ajuste (R^2).

A Proporção da Variância Explicada (PVE) mede a proporção que um modelo explica a variância (dispersão) em um determinado conjunto de dados. Se \hat{y} é a saída estimada e y é a saída (correspondente) correta, então a PVE é estimada através da Eq. (6):

$$\text{PVE}(y, \hat{y}) = 1 - \frac{\text{Var}\{y - \hat{y}\}}{\text{Var}\{y\}} \quad (6)$$

onde o melhor valor possível é 1 e valores próximos de zero indicam um baixo desempenho.

Se \hat{y}_i é o valor predito para a i -ésima amostra, e y_i é o valor correspondente correto, então o EMA, dado pela Eq. (7) computa o erro médio absoluto:

$$\text{EMA}(y, \hat{y}) = \frac{1}{N} \sum_{i=0}^{N-1} |y_i - \hat{y}_i| \quad (7)$$

e o Erro Médio Quadrático (EMQ) é dado pela Eq. (8):

$$\text{EMQ}(y, \hat{y}) = \frac{1}{N} \sum_{i=0}^{n_{\text{samples}}-1} (y_i - \hat{y}_i)^2, \quad (8)$$

enquanto o EMP é descrito pela Eq. (9):

$$\text{EMP}(y, \hat{y}) = \frac{1}{N} \sum_{i=0}^{N-1} \frac{|y_i - \hat{y}_i|}{|y_i|} \times 100. \quad (9)$$

O coeficiente R^2 computa o coeficiente de determinação, uma medida de ajustamento de um modelo em relação aos valores observados. O coeficiente de determinação R^2 estimado sobre N amostras é definido pela Eq. (10):

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=0}^{N-1} (y_i - \hat{y}_i)^2}{\sum_{i=0}^{N-1} (y_i - \bar{y})^2} \quad (10)$$

onde \bar{y} é a média de y .

Para cada modelo, foi realizada uma busca exaustiva em um conjunto de possíveis parâmetros com intuito de maximizar o coeficiente de determinação R^2 . O modelo MLG foi analisado considerando-se os parâmetros α e ρ , enquanto no modelo RNA foram sofreram variações os parâmetros α e η_0 . Para obtermos uma confiabilidade da estimativa da precisão dos modelos, os procedimento acima foi repetido 100 vezes com os dados permutados aleatoriamente em cada execução antes de dividi-lo em subconjuntos de teste e treinamento. Os valores médios obtidos nas 100 realizações são usados como medidas de desempenho dos modelos treinados/ajustados.

4 RESULTADOS

A Fig. 2 mostra a distribuição de probabilidade empírica para as variáveis de entrada (X_1, \dots, X_6) e a variável de saída (Y_1). As distribuições mostram que nenhuma variável segue uma distribuição normal.

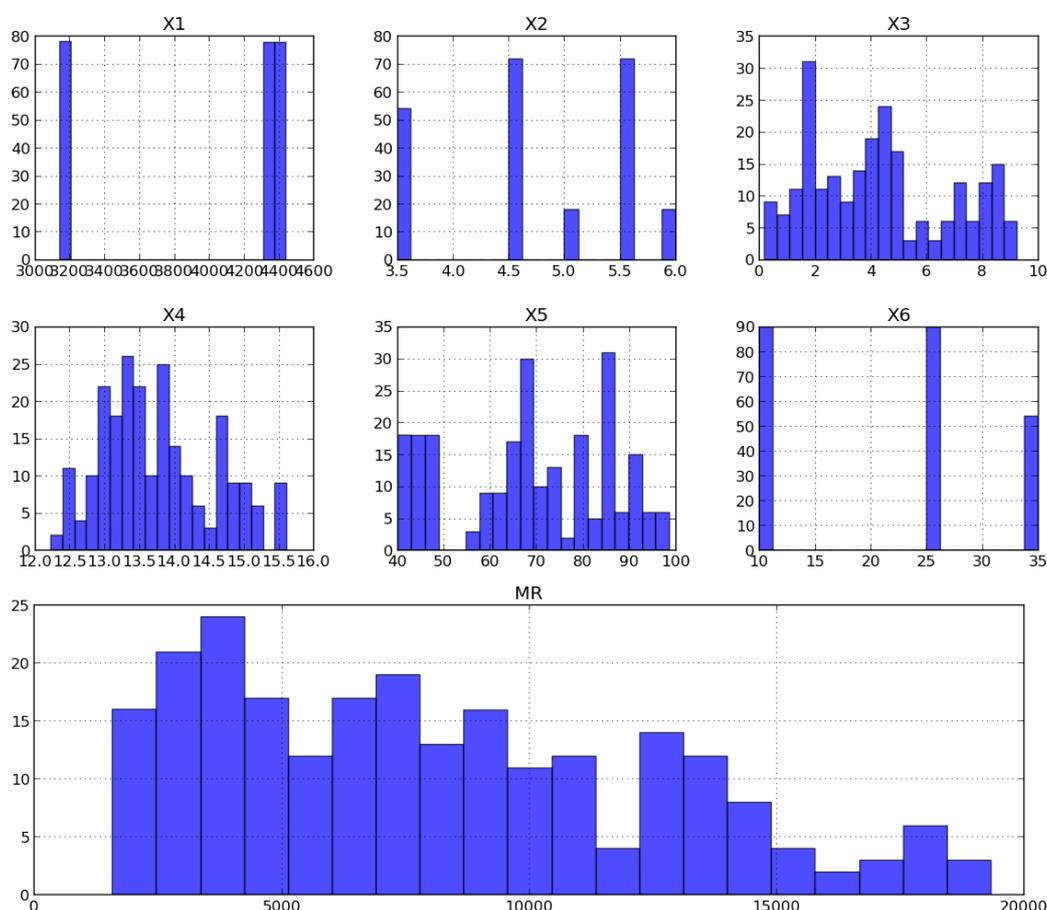


Figura 2: Estimativas das densidades de probabilidades usando histogramas para as variáveis de entrada X_1, \dots, X_6 e da variável de saída MR.

A Fig. 3 mostra os gráficos de dispersão para cada variável de entrada e a variável de saída. Segundo esses gráficos, exceto para X_6 , as relações funcionais entre os as variáveis de entrada e variável de saída possuem alguma não-linearidade que não é facilmente visualizada. Isto sugere que métodos de aprendizado clássicos, como regressores lineares, podem falhar em obter uma relação funcional precisa entre as variáveis de entrada e a variável de saída. Esse gráficos, portanto, justificam o uso de técnicas de aprendizado que possam representar não linearidades

em sua formulação - como as Redes Neuronais Artificiais.

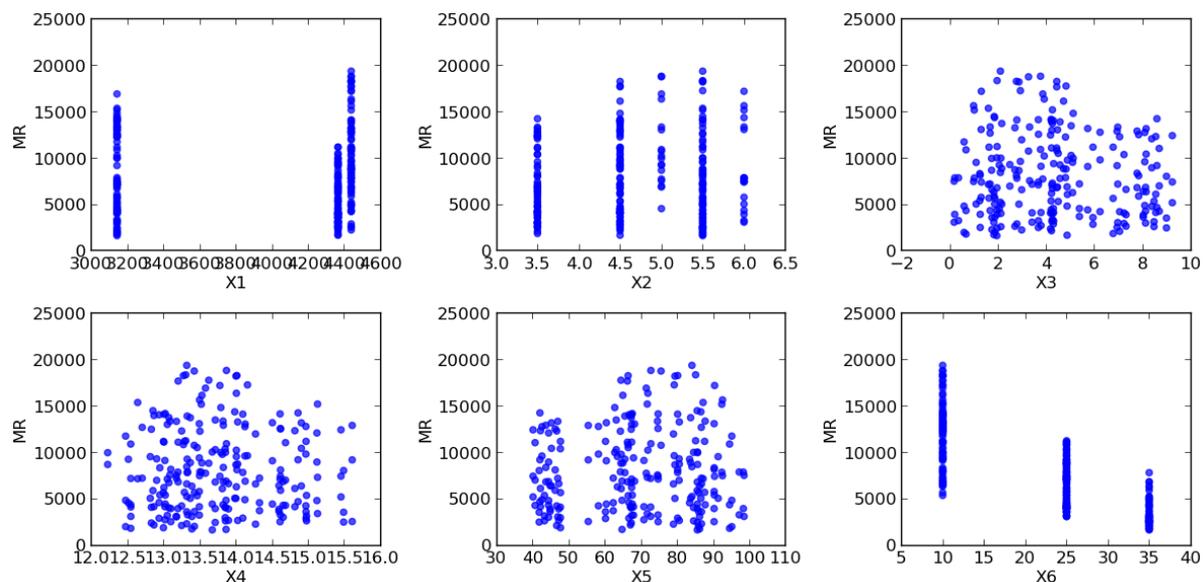


Figura 3: Gráfico de dispersão mostrando visualmente a relação entre as variáveis de entrada (X_1, \dots, X_8) e a saída (MR).

A Tab. 3 apresenta a associação entre as variáveis, quantificada em termos da Informação Mútua Normalizada (IMN) e do Coeficiente de Correlação de postos de Spearman (CCS) para cada variável de entrada com a saída MR . Daí pode-se inferir que a variável X_6 (temperatura) aparece inversamente correlacionada com a a variável de saída - como esperando, uma vez que elevações na temperatura ambiente tornam as misturas asfálticas mais deformáveis. É interessante perceber que as variáveis X_3 , X_4 , e X_5 , que possuem os maiores valores de IMN, apresentam valores baixos do coeficiente de correlação CCS.

Tabela 3: Associação estimada entre as variáveis usando a Informação Mútua Normalizada (IMN) e o Coeficiente de Correlação de postos de Spearman (CCS) para as variáveis X_1, \dots, X_6 com a variável de saída Y_1 (MR).

Variável	IMN	CCS	Valor p
X_1	0.449	0.190	0.004
X_2	0.515	0.067	0.308
X_3	0.906	-0.012	0.859
X_4	0.906	0.011	0.866
X_5	0.906	0.009	0.886
X_6	0.444	-0.809	$< 1e - 8$

A Tab. 4 apresenta a matriz de covariância, que representa as correlações entre as variáveis de entrada. Os resultados mostram que X_2 (teor de ligante) e X_5 (teor de vazios preenchidos pelo ligante) são proporcionais entre si, uma vez que o ligante ocupa os vazios durante o processo de confecção da liga asfáltica. Pode-se verificar também uma relação inversamente proporcional entre X_3 (teor de vazios do agregado) e X_5 (teor de vazios preenchidos pelo ligante), indicando que misturas de agregados com alto teor de vazios não contribuem para a homogeneidade da liga asfáltica, evidenciando a importância da granulometria para o desempenho do material.

Tabela 4: Matriz de correlação usando a correlação de Spearman entre as 6 variáveis.

	X1	X2	X3	X4	X5	X6
X1	1.000	0.000	0.065	0.284	-0.061	0.000
X2	0.000	1.000	-0.932	-0.300	0.947	-0.118
X3	0.065	-0.932	1.000	0.589	-0.995	0.116
X4	0.284	-0.300	0.589	1.000	-0.540	0.069
X5	-0.061	0.947	-0.995	-0.540	1.000	-0.116
X6	0.000	-0.118	0.116	0.069	-0.116	1.000

A Figura 4 mostra os gráficos de dispersão com intervalo de confiança de 95%, os respectivos parâmetros encontrados pelo procedimento de busca exaustiva com validação cruzada e as respectivas métricas para uma das 100 execuções dos modelos de aprendizado de máquina. É possível observar a dificuldade do método MLG em avaliar com precisão o módulo de resiliência - além de apresentar um erro médio percentual de 29,915%, nota-se que os valores mais elevados do MR tendem para uma assíntota horizontal. Os resíduos no modelo MLG seguem uma distribuição normal. Para cada execução do modelo foi realizado um teste de normalidade de Shapiro-Wilk, de onde obteve-se um p-valor médio de 0.208 ± 0.015 . Assim, pode-se afirmar com nível de significância de 5% que os resíduos provêm de uma população normal, e com isso as hipóteses para o modelo MLG não são violadas. A análise gráfica dos resíduos, para uma das execuções, é mostrada na Fig. 5. A Figura 4 denota o melhor desempenho da RNA para a aplicação em questão, fornecendo melhores estimativas em toda a faixa de valores analisados, com erro médio percentual de 9,014%. Para cada modelo, em

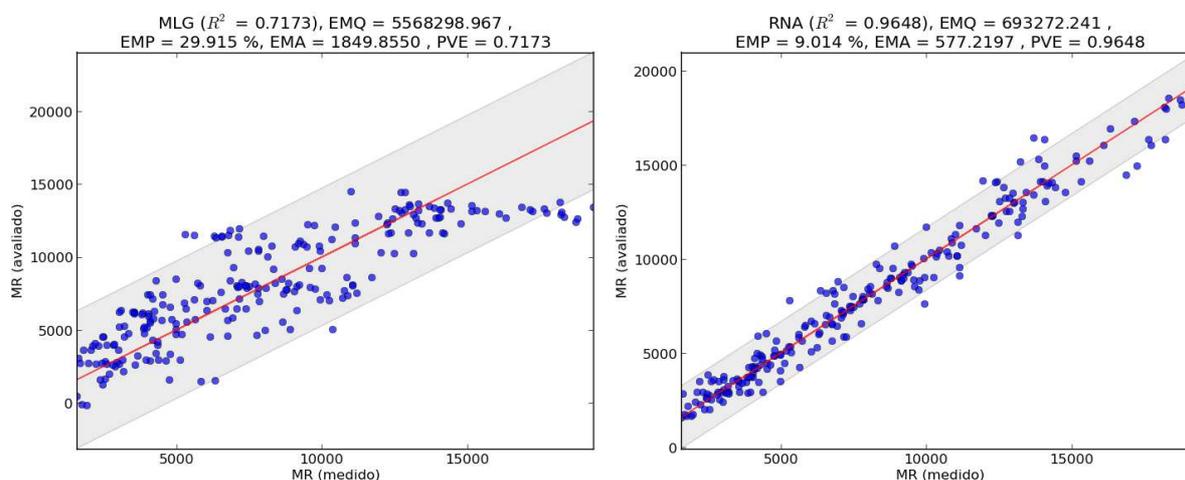


Figura 4: Esquerda: gráfico de dispersão obtido para uma das execuções do modelo MLG. Parâmetros do modelo: $\alpha = 1.0$ $\rho = 1.0$ (vide Seção 3.2.1). A região em cinza indica o intervalo de confiança de 95%. Direita: gráfico de dispersão obtido para uma das execuções do modelo RNA. Parâmetros do modelo: $\alpha = 10^{-6}$, $\eta_0 = 0.5$ e 120 neurônios na camada oculta (vide Seção 3.2.2).

cada execução, foi realizada uma busca exaustiva nos parâmetros mostrados na Tab. 5, com o objetivo de maximizar o coeficiente de determinação R^2 . Cada execução do modelo MLG envolve 24 ajustes, correspondentes aos 3 níveis do parâmetro α e 8 níveis do parâmetro ρ , e cada execução do modelo RNA resulta em 12 ajustes, devido aos 3 níveis do parâmetro α e 4

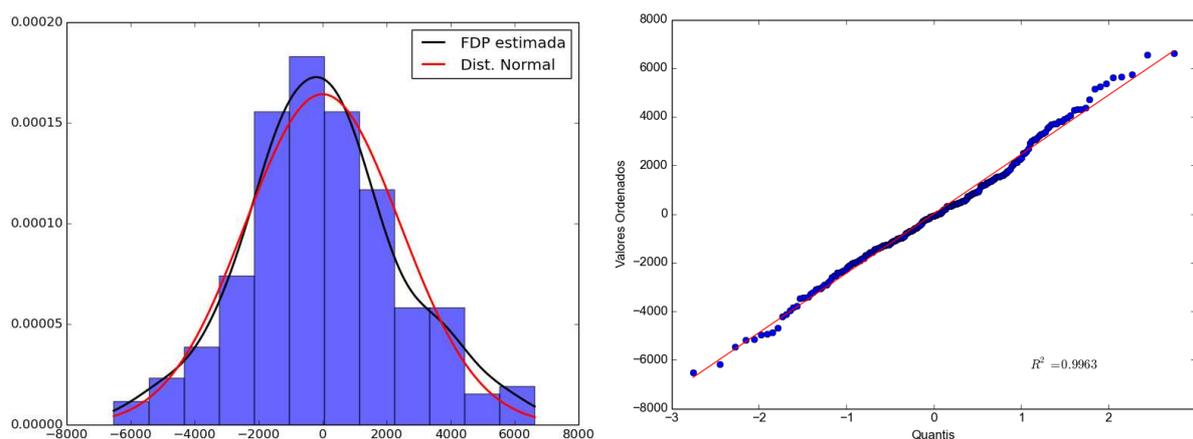


Figura 5: Análise da normalidade dos resíduos do modelo MLG. Esquerda: histograma dos erros para as 100 execuções, juntamente com a função de densidade de probabilidade estimada. Para efeito de comparação, é mostrada também uma distribuição normal com a mesma média e desvio padrão dos erros do modelo. Direita: gráfico quantil-quantil resíduos do modelo MLG.

níveis do parâmetro η_0 .

Tabela 5: Variação dos parâmetros para cada modelo analisado. Detalhes na Seção 3.2.

Modelo	Parâmetros
MLG	$\alpha \in [10^{-4}, 10^{-5}, 10^{-6}]$, $\rho \in [0.70, 0.80, 0.85, 0.90, 0.95, 0.98, 0.99, 1.00]$
RNA	$\alpha \in [10^{-4}, 10^{-5}, 10^{-6}]$, $\eta_0 \in [1.00, 0.50, 0.01, 0.001]$

Após a análise estatística preliminar, que permite descobrir associações entre as variáveis de entrada com as variáveis de saída, vamos avaliar a precisão dos modelos empregados por meio da avaliação de erros de amostragem. As Tabelas 6 e 7 mostram as medidas de desempenho PVE, EMA, EMP, EMQ e R^2 para a tarefa de predição do Módulo de Resiliência. Percebemos que o modelo RNA demonstra consistentemente melhor desempenho que o modelo MLG, uma vez que as relações não lineares entre as variáveis de entrada e a variável de saída são de difícil aprendizado pelo modelo linear.

Tabela 6: Métricas PVE, EMA, e EMP obtidas para os dois modelos analisados, usando validação cruzada 9-fold com 100 repetições. Os resultados são mostrados na forma média \pm desvio padrão.

Modelo	PVE	EMA	EMP
MLG	0.718 \pm 0.000	1850.146 \pm 0.298	29.959 \pm 0.045
RNA	0.966 \pm 0.010	559.146 \pm 88.713	8.704 \pm 1.473

5 CONCLUSÃO

Este trabalho consiste na primeira etapa de um estudo que visa à obtenção de ferramentas para a dosagem científica de misturas asfálticas densas com base em critérios estabelecidos no projeto de pavimentos - como o Módulo de Resiliência. As análises numéricas, baseadas em informações experimentais relativas a mais de 700 corpos-de-prova de composições variadas,

Tabela 7: Métricas EMQ e R^2 obtidas para os dois modelos analisados, usando validação cruzada 9-fold com 100 repetições. Os resultados são mostrados na forma média \pm desvio padrão.

Modelo	EMQ	R^2
MLG	5564444.202 \pm 3959.637	0.718 \pm 0.000
RNA	668724.138 \pm 197633.497	0.966 \pm 0.010

permitiu verificar a influência de fatores diversos sobre o Módulo de Resiliência do material. Análises exploratórias dos dados experimentais indicam a forte não-linearidade inerente ao problema, que compromete o desempenho de Modelos de Regressão Linear, e justifica o emprego de modelos de aprendizagem capazes de representar tal característica. A aplicação de uma Rede Neural Artificial mostrou-se eficiente e eficaz na estimativa do MR, apresentando erro médio de cerca de 9%. Tais resultados encorajam a realização de estudos envolvendo outras técnicas de inteligência computacional para a análise de misturas considerando outros parâmetros influentes, como o tipo e a granulometria dos agregados e aspectos relacionados à técnica de compactação.

AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq – PQ 306712/2012-1), à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG - APQ-03900-10, APQ 01659-12 e PPM 00020/14) e à Universidade Federal de Juiz de Fora, que apoiaram este trabalho através da concessão de bolsas de Iniciação Científica e de recursos para o desenvolvimento de projetos de pesquisa.

REFERÊNCIAS

- Bal L. e Buyle-Bodin F. Artificial neural network for predicting drying shrinkage of concrete. *Construction and Building Materials*, 38(0):248 – 254, 2013.
- Dantas A.T.A., Leite M.B., e Nagahama K. Prediction of compressive strength of concrete containing construction and demolition waste using artificial neural networks. *Construction and Building Materials*, 38(0):717 – 722, 2013.
- DNIT-DPP-CG-PLAN. Extensão da rede rodoviária (km) - Brasil. Disponível em: <http://www.abcr.org.br/Conteudo/Secao/43/estatisticas.aspx>. Acesso em 07 de abril. 2014, 2014.
- Duan Z., Kou S., e Poon C. Prediction of compressive strength of recycled aggregate concrete using artificial neural networks . *Construction and Building Materials*, 40(0):1200 – 1206, 2013a.
- Duan Z., Kou S., e Poon C. Using artificial neural networks for predicting the elastic modulus of recycled aggregate concrete . *Construction and Building Materials*, 44(0):524 – 532, 2013b.
- Geisser S. *Predictive inference: an introduction*. Chapman & Hall, New York, 1993.
- Hastie T., Tibshirani R., e Friedman J. *The Elements of Statistical Learning*. Springer, New York, 2009.
- Haykin S. *Neural Networks: A Comprehensive Foundation*. Prentice Hall PTR, Upper Saddle River, NJ, USA, 2nd edição, 1998. ISBN 0132733501.
- Kröse B.J.A. e van der Smagt P.P. *An Introduction to Neural Networks*. University of Amsterdam, Amsterdam, 1993.
- Lee S. e Lee C. Prediction of shear strength of frp-reinforced concrete flexural members without

- stirrups using artificial neural networks. *Engineering Structures*, 61(0):99 – 112, 2014.
- Marques G. *Utilização do módulo de resiliência como critério de dosagem de Mistura asfáltica; efeito da compactação por impacto e giratória*. Tese de Doutorado, Universidade Federal do Rio de Janeiro, 2004.
- Moretti J. *Sistema Inteligente Baseado na Redes Neurais Artificiais para Dosagem do Concreto*. Tese de Doutorado, Faculdade de Engenharia UNESP Ilha Solteira, 2010.
- Nocedal J. e Wright S.J. Numerical optimization, second edition. *Numerical optimization*, páginas 497–528, 2006.
- Silva N., Spatti H.D., e Flauzino R.A. *Redes Neurais Artificiais: curso prático*. Artliber, São Paulo, 2010.
- Tapkin S., Çevik A., e Uşar U. Prediction of marshall test results for polypropylene modified dense bituminous mixtures using neural networks. *Expert Systems with Applications*, 37(6):4660 – 4670, 2010.
- Tsanas A. e Xifara A. Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools. *Energy and Buildings*, 49:560–567, 2012.