



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS DE CRATEÚS
CURSO DE ENGENHARIA CIVIL

FRANCISCO MAILSON MOURÃO BEZERRA

**PROPOSTA DE MODELAGEM DA RESISTÊNCIA À DEFORMAÇÃO
PERMANENTE DE MISTURAS ASFÁLTICAS DENSAS**

CRATEÚS
2021

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo (a) autor (a)

- B469p Bezerra, Francisco Mailson Mourão.
Proposta de modelagem da resistência à deformação permanente de misturas asfálticas densas / Francisco Mailson Mourão Bezerra. – 2021.
100 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Crateús, Curso de Engenharia Civil, Crateús, 2021.
Orientação: Prof. Me. Jorge Luis Santos Ferreira.
1. Deformação permanente. 2. Flow Number. 3. Redes Neurais Artificiais. 4. Regressão linear. 5. Regressão não linear. I. Título.

CDD 620

FRANCISCO MAILSON MOURÃO BEZERRA

PROPOSTA DE MODELAGEM DA RESISTÊNCIA À DEFORMAÇÃO PERMANENTE
DE MISTURAS ASFÁLTICAS DENSAS

Trabalho de Conclusão de Curso apresentado ao
Curso de Engenharia Civil da Universidade
Federal do Ceará, Campus de Crateús como
requisito parcial à obtenção do título de bacharel
em Engenharia Civil.

Aprovada em: ___ / ___ / ____.

BANCA EXAMINADORA

Prof. Me. Jorge Luis Santos Ferreira (Orientador)
Universidade Federal do Ceará (UFC)

Profª. Dra. Juceline Batista dos Santos Bastos
Instituição Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Prof. Dr. Giannini Italino Alves Vieira
Universidade Federal do Ceará (UFC)

AGRADECIMENTOS

Agradeço a Deus, por minha vida e por me ajudar a ultrapassar todos os obstáculos encontrados ao longo do curso.

Aos meus pais, Maria e Onécio, pelo incentivo nos momentos difíceis e por compreenderem minha ausência enquanto eu me dedicava a realização desse trabalho.

Aos meus avós, Francisca e Osvaldo, por todo acolhimento, amor e por me moldarem na pessoa que sou hoje, a vocês toda a minha gratidão por tudo que fizeram por mim.

Ao meu orientador, Jorge Luis, pelo empenho e dedicação durante todo esse ano de orientação, com o auxílio necessário para elaboração desse trabalho.

À banca avaliadora, Prof^{ta} Juceline e Prof. Giannini, pelas sugestões que contribuíram para a qualidade final do trabalho.

Aos meus amigos, Felipe Seixas, Phablo Caetano, Douglas Ribeiro, Lucas Rafael e João Victor, por toda a caminhada ao longo do curso e por estarem presente nos momentos difíceis e alegres da faculdade.

“Esteja sozinho, este é o segredo da invenção,
estar sozinho, isto é quando as ideias nascem.”

Nikola Tesla

RESUMO

A deformação permanente é uma das principais manifestações patológicas apresentadas por pavimentos asfálticos. O Flow Number (FN) é um parâmetro obtido no ensaio uniaxial de carga repetida que permite hierarquizar misturas asfálticas quanto à capacidade de resistência a esse defeito, ou em outras palavras, de resistência ao acúmulo de deformações plásticas. O MeDiNa, atual método nacional de dimensionamento de pavimentos asfálticos, estabelece que tal defeito deve ser combatido ainda na fase de dosagem da mistura asfáltica, o que abre margem para a possibilidade do emprego de modelos de previsão do FN a fim de orientar a seleção de materiais e sua proporcionalidade. Na literatura internacional já existem diversas tentativas no sentido de desenvolver modelos capazes de estimar o FN, porém, não é possível garantir que tais modelos são adequados às condições nacionais. Logo, diante do cenário de escassez de modelos preditivos para o FN adaptados às condições dos pavimentos brasileiros, buscou-se desenvolver e analisar modelos com diferentes variáveis preditoras e graus de complexidade distintos, objetivando com isso, a proposição de uma ferramenta auxiliar na dosagem de misturas asfálticas. Foram analisadas as capacidades explicativas de modelos de regressão lineares e não lineares, e ainda provenientes de Redes Neurais Artificiais (RNAs), chegando-se à conclusão que os primeiros não são capazes de explicar satisfatoriamente as variações do FN e que a utilização dos últimos só se justifica para investigações em banco de dados maiores. Consequentemente, os modelos não lineares são os mais recomendados no que se refere à previsão deste parâmetro, destacando-se os provenientes do método Bailey.

Palavras-chave: Deformação permanente. *Flow Number*. Redes Neurais Artificiais. Regressão linear. Regressão não linear.

ABSTRACT

Permanent deformation is one of the main pathological manifestations presented by asphalt pavements. The Flow Number (FN) is a parameter obtained in the uniaxial repeated load test that allows to hierarchize asphalt mixtures as to the capacity of resistance to this defect, or in other words, resistance to the accumulation of plastic deformations. MeDiNa, the current national method for asphalt pavements design, establishes that this defect must be prevented even in the asphalt mix design, which opens up the possibility of using FN prediction models to guide the selection of materials and their proportion. In the international literature, there are already several attempts to develop models capable of estimating the FN, however, it is not possible to ensure that such models are suitable to national conditions. Therefore, given the scarcity of predictive models for the FN adapted to the conditions of Brazilian pavements, we sought to develop and analyze models with different predictor variables and different degrees of complexity, aiming with this, the proposal of an auxiliary tool in the design of asphalt mixtures. The explanatory capacities of linear regression, nonlinear regression, and derived from Artificial Neural Networks (ANNs) were analyzed, concluding that the former is not able to satisfactorily explain the variations of the FN and that the use of the latter is only justified for investigations into larger databases. Consequently, nonlinear models are the most recommended for the prediction of this parameter, highlighting those from the Bailey method.

Keywords: Permanent deformation. Flow Number. Artificial Neural Networks. Linear regression. Nonlinear regression.

LISTA DE FIGURAS

Figura 1 - Mecanismos de deformação.....	19
Figura 2 - Contato intergranular de um conjunto de partículas	20
Figura 3 - Faixas granulométricas do DNIT.....	22
Figura 4 - Pontos de controle e LDM para TMN = 19mm.....	23
Figura 5 - Representação da proporção α	25
Figura 6 - Correlação dos parâmetros α e C com o FN	26
Figura 7 - Forma, angularidade e textura superficial das partículas de agregado	28
Figura 8 - Correlação entre a viscosidade rotacional e o FN.....	29
Figura 9 - Resultados dos ensaios para as misturas com ligantes asfálticos + Polímero + PPA	30
Figura 10 - Correlação entre o teor de ligante asfáltico 50/70 e o FN	31
Figura 11 - Correlação entre o teor de ligante de projeto (%) e o FN	31
Figura 12 - Carregamento e deformação no ensaio uniaxial de carga repetida.....	32
Figura 13 - Esquema de montagem do ensaio de número de fluxo (FN).....	33
Figura 14 - Exemplo de um corpo de prova antes e após o ensaio de FN.....	34
Figura 15 - Curva típica do ensaio uniaxial de carga repetida	34
Figura 16 - Neurônio biológico	36
Figura 17 - Neurônio artificial.....	37
Figura 18 - Exemplo de rede PMC.....	38
Figura 19 - Log dos FNs medidos versus previstos	40
Figura 20 - Comparação dos FNs previstos versus medidos em laboratório	41
Figura 21 - Correlação para a função linearizada do FN.....	42
Figura 22 - Nomenclatura dos modelos.....	50
Figura 23 - Erro Absoluto Médio dos modelos lineares.....	54
Figura 24 - Coeficiente de determinação dos modelos lineares propostos e presentes na literatura.....	54
Figura 25 - FNs medidos versus estimados para os modelos lineares	57
Figura 26 - Erro Absoluto Médio dos modelos não lineares propostos e da literatura	60
Figura 27 – Coeficiente de determinação dos modelos não lineares.....	60
Figura 28 - Contribuição individual de cada variável para os modelos não lineares	61
Figura 29- FNs medidos versus estimados dos modelos não lineares.....	63
Figura 30 - Erro absoluto médio das RNA de estimativa do FN.....	67

Figura 31 - Coeficiente de determinação das RNA de estimativa do FN.....	67
Figura 32 - FNs medidos versus estimados do Perceptron Simples.....	68
Figura 33 - Box-plot de L e FN para os métodos Marshall e Superpave	72
Figura 34 - Teores de ligante obtidos por Almeida Jr. et al. (2018).....	73
Figura 35 - Acurácias obtidas pelos PS e PMC de classificação.....	75
Figura 36 - Acurácia dos modelos lineares	76
Figura 37 - Acurácia dos modelos não lineares.....	76
Figura 38 - Acurácia do Perceptron simples de estimativa do FN	77
Figura 39 - Acurácia do Perceptron Multicamadas de estimativa do FN.....	77
Figura 40 - Matrizes de confusão dos melhores modelos	78
Figura 41 - Tempo médio de processamento para cada tipo de modelo	79

LISTA DE TABELAS

Tabela 1 - Critérios para o nível de correlação.....	27
Tabela 2 – Dados referentes à mistura asfáltica e ao ligante.....	44
Tabela 3 - Parâmetros granulométricos das misturas	45
Tabela 4 - Modelos obtidos e ferramentas utilizadas	48
Tabela 5 - Bibliotecas utilizadas no desenvolvimento das Redes Neurais Artificiais.....	49
Tabela 6 - Combinação de variáveis.....	50
Tabela 7 - Critérios de FN para o nível de tráfego resistido.....	51
Tabela 8 - Equações dos modelos lineares	53
Tabela 9 - Valor-p para os modelos baseados no método FAD	55
Tabela 10 - Valor-p para os modelos baseados no Método Bailey	55
Tabela 11 - Valor-p para os modelos baseados no Modelo Híbrido	55
Tabela 12 - Equações dos modelos não lineares	59
Tabela 13 - Hiperparâmetros utilizados no Perceptron simples	66
Tabela 14 - Hiperparâmetros utilizados no Perceptron Multicamadas.....	66
Tabela 15 - Dados das misturas analisadas por Possebon (2018) e FN e nível de tráfego medidos e estimados pelo PS-EST-FAD-1	70
Tabela 16 - Valores médios de L e FN para os métodos Marshall e Superpave.....	72
Tabela 17 - Hiperparâmetros utilizados nos Perceptrons simples de Classificação.....	73
Tabela 18 - Hiperparâmetros utilizados nos Perceptrons Multicamadas de Classificação	74

LISTA DE ABREVIATURAS E SIGLAS

AG	Proporção do Agregado Graúdo
AIMS	<i>Aggregate Image Measurement System</i>
ATR	Afundamento da Trilha de Roda
CA	Concreto Asfáltico
CNT	Confederação Nacional do Transporte
CP	Corpo de Prova
CV	<i>Cross Validation</i>
FAD	Faixa de Agregados Dominantes
FAF	Proporção Fina dos Agregados Miúdos
FN	<i>Flow Number</i>
GAF	Proporção Graúda do Agregado Miúdo
MC	Matriz de Confusão
MeDiNa	Método de Dimensionamento Nacional
PCP	Peneira de Controle Primário
PCS	Peneira de Controle Secundário
PCT	Peneira de Controle Terciário
PDI	Processamento Digital de Imagens
PMC	<i>Perceptron</i> Multicamadas
PS	<i>Perceptron</i> Simples
RNA	Rede Neural Artificial

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Considerações iniciais	13
1.2	Justificativa e problema de pesquisa	15
1.3	Objetivos.....	16
1.4	Estrutura do Trabalho.....	17
2	REVISÃO BIBLIOGRÁFICA	18
2.1	Deformação permanente – definição e mecanismos.....	18
2.2	Fatores influentes	20
2.2.1	<i>Influência dos agregados</i>	<i>21</i>
2.2.2	<i>Influência do Ligante</i>	<i>28</i>
2.3	Ensaio uniaxial de carga repetida.....	32
2.4	Redes neurais artificiais.....	35
2.5	Modelos para previsão do FN.....	39
3	MATERIAIS E MÉTODOS.....	44
3.1	Banco de dados	44
3.2	Etapas metodológicas	46
3.2.1	<i>Escolha das variáveis</i>	<i>46</i>
3.2.2	<i>Obtenção e avaliação dos modelos.....</i>	<i>48</i>
4	RESULTADOS E DISCUSSÕES	53
4.1	Modelos lineares	53
4.2	Modelos não lineares	59
4.3	Redes Neurais Artificiais	65
4.4	Classificação do nível de tráfego resistido.....	71
4.5	Complexidade dos modelos.....	79
5	CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS.....	81
5.1	Sugestões para trabalhos futuros.....	82
	REFERÊNCIAS	83
	APÊNDICE A – FN ESTIMADO PELOS MODELOS LINEARES	89
	APÊNDICE B – CLASSES ESTIMADAS PELOS MODELOS LINEARES	90
	APÊNDICE C – FN ESTIMADO PELOS MODELOS NÃO LINEARES	91
	APÊNDICE D – CLASSES ESTIMADAS PELOS MODELOS NÃO LINEARES.....	92

APÊNDICE E – FN ESTIMADO PELOS PERCEPTRONS SIMPLES.....	93
APÊNDICE F – CLASSES ESTIMADAS PELOS PRECEPTRONS SIMPLES DE ESTIMATIVA DO FN	94
APÊNDICE G – FN ESTIMADO PELOS PRECEPTRONS MULTICAMADAS	95
APÊNDICE H – CLASSES ESTIMADAS PELOS PERCEPTRONS MULTICAMADAS DE ESTIMATIVA DO FN	96
APÊNDICE I – CLASSES ESTIMADAS PELOS PERCEPTRONS SIMPLES DE CLASSIFICAÇÃO PARA AS COMBINAÇÕES DE VARIÁVEIS 1, 2, 3, 4, 5 E 6	97
APÊNDICE J – CLASSES ESTIMADAS PELO PERCEPTRON SIMPLES DE CLASSIFICAÇÃO PARA AS COMBINAÇÕES DE VARIÁVEIS 7, 8 E 9	98
APÊNDICE K – CLASSES ESTIMADAS PELOS PERCEPTRONS MULTICAMADAS DE CLASSIFICAÇÃO PARA AS COMBINAÇÕES DE VARIÁVEIS 1, 2, 3, 4, 5 E 6.....	99
APÊNDICE L – CLASSES ESTIMADAS PELOS PERCEPTRONS MULTICAMADAS DE CLASSIFICAÇÃO PARA AS COMBINAÇÕES DE VARIÁVEIS 7, 8 E 9.....	100

1 INTRODUÇÃO

1.1 Considerações iniciais

Segundo uma pesquisa da Confederação Nacional do Transporte (CNT) de 2019, o modal rodoviário é responsável pelo tráfego de cerca de 95% dos passageiros e de mais de 61% das cargas que circulam no país, portanto, uma rodovia com más condições de pavimento tem impacto direto na economia do Brasil, pois aumenta o custo operacional do transporte e reduz o conforto e a segurança dos passageiros e das cargas.

Apesar de sua importância para a economia brasileira, conforme levantamento da CNT, mais da metade das rodovias brasileiras está mal conservada, sendo este, um problema que passa por diversos fatores, tais como, inexistência de projetos, execução inadequada ou até mesmo a utilização de métodos de dimensionamento ultrapassados, ou inadequados para as condições nacionais.

Bernucci *et al.* (2010) definem os pavimentos como estruturas de múltiplas camadas, sendo o revestimento a camada que se destina a receber a carga dos veículos e mais diretamente a ação climática, o que exige, portanto, características como impermeabilidade, flexibilidade, durabilidade e resistência à fadiga e ao trincamento térmico. O revestimento asfáltico é o tipo mais utilizado no Brasil, e conforme estes mesmos autores, é caracterizado por uma associação de ligantes asfálticos, agregados e, em alguns casos, produtos complementares.

O revestimento asfáltico pode apresentar diversas manifestações patológicas, como, por exemplo, desprendimento dos agregados, exsudação, trincamento por fadiga, e deformação permanente, sendo este último caracterizado por um afundamento da trilha de roda (ATR), que corresponde ao acúmulo de deformação ao longo do tempo decorrente do carregamento repetido do tráfego (FERREIRA, 2017).

A deformação permanente em pavimentos asfálticos é uma falha que se manifesta tipicamente no início de sua vida de serviço, ocorrendo principalmente na camada de revestimento (BERNUCCI *et al.*, 2010). Pode ser causada por densificação e/ou movimento lateral (deformação por cisalhamento) desse material sob a ação do tráfego (CHOI; KIM, 2013). Na densificação, observa-se a diminuição do volume, portanto, o aumento da densidade. Já na

deformação por cisalhamento, observam-se mudanças de forma na camada asfáltica sem alteração volumétrica considerável (BROWN *et al.*, 2001).

Tradicionalmente avalia-se o potencial de resistência ao acúmulo de deformação a partir de ensaios laboratoriais de desempenho. Um dos parâmetros mais utilizados com esta finalidade é o número de fluxo ou *Flow Number* (FN), na designação internacional, que é obtido no ensaio uniaxial de carga repetida e pode ser utilizado para ranquear misturas asfálticas quanto à sua suscetibilidade à deformação permanente.

Como demonstrado na literatura (WITCZAK *et al.*, 2002; BASTOS *et al.*, 2017), existe uma boa correlação entre o FN e a deformação permanente em campo. Diante disso, no Brasil foi elaborada a norma DNIT 184/2018 - ME no intuito de formalizar o método de ensaio para obtenção do FN. Assim, o FN é entendido como a opção mais viável para estimar a suscetibilidade de revestimentos asfálticos quanto ao acúmulo de deformação sob a ação do tráfego.

Considerando que o novo método de dimensionamento nacional (MeDiNa) estabelece que a deformação permanente no revestimento asfáltico é um defeito a ser combatido na etapa de dosagem da mistura asfáltica (FRANCO; MOTTA, 2018), entende-se que um modelo preditivo para o FN encontraria uma grande aplicabilidade, pois poderia atuar como um norteador do método de dosagem. Logo, a seleção e proporção dos materiais (ligante asfáltico e agregados) seriam orientadas objetivamente para atender aos critérios de resistência à deformação permanente. Além disso, a existência de tal modelo possibilitaria a aplicação de métodos de otimização dos componentes da mistura, isto é, variando os parâmetros do modelo até que a solução de menor custo fosse encontrada.

Um modelo científico trata-se de uma abstração da realidade por meio da qual é possível simular o comportamento de um sistema concreto de forma simplificada. Assim sendo, estes modelos necessitam de variáveis que, em conjunto, possam reproduzir o comportamento do fenômeno estudado, o que torna a escolha de tais variáveis uma das principais etapas do processo de modelagem.

A escolha das variáveis explicativas de um modelo consiste em determinar qual conjunto de variáveis independentes melhor explica a variável resposta, ou seja, tal tarefa deve cumprir alguns objetivos, como, por exemplo, diminuir a variância das previsões e o custo da coleta de dados através de um modelo com um número reduzido de variáveis, e apesar disso, fornecer o máximo de informações possível a respeito do fenômeno analisado.

A mistura asfáltica é um material compósito formado por agregados, ligante asfáltico e vazios com ar (FERREIRA, 2017), portanto, um modelo preditivo de qualquer de

suas características, deve conter variáveis que possam captar o comportamento desses componentes. Com relação à deformação permanente, essas variáveis devem estar relacionadas aos mecanismos resistentes a esse defeito em específico, tais como, a granulometria dos agregados, já que esta afeta a estrutura interna e a distribuição de tensões em uma mistura asfáltica (MASAD *et al.*, 1999).

Há diversas formas de estabelecer uma relação funcional entre determinados parâmetros e uma variável de interesse, podendo ocorrer por meio de equações diferenciais, métodos estatísticos de regressão ou mediante aprendizagem computacional. Como o comportamento mecânico de misturas asfálticas é bastante complexo, o uso de equações diferenciais é uma tarefa igualmente trabalhosa. Ademais, nem sempre é possível encontrar uma solução analítica, o que exige a adoção de fórmulas aproximadas como solução do problema. Tendo em vista que fórmulas aproximadas também podem fornecer boas previsões, um modelo decorrente de métodos estatísticos de regressão entre dados obtidos em ensaios de laboratório e os valores reais do FN, poderia ser utilizado como método para se obter um modelo de previsão.

Outra alternativa seria a utilização de métodos de aprendizagem computacional como as Redes Neurais Artificiais (RNAs), visto que são capazes de adaptar-se aos dados disponíveis e posteriormente generalizar o conhecimento obtido. No entanto, esse tipo de aprendizagem de máquina, normalmente necessita de uma grande quantidade de dados para fornecer bons resultados.

Por último, é importante pontuar que apesar de sua importância, um modelo preditivo para o FN não tem a função de substituir a realização do ensaio uniaxial de carga repetida, mas sim auxiliar na escolha dos constituintes da mistura asfáltica, atuando dessa forma como orientador do processo de dosagem.

1.2 Justificativa e problema de pesquisa

A maioria dos métodos existentes para dosagem de misturas asfálticas, como, por exemplo, o método de dosagem Marshall, não consideram em sua formulação o combate ao desenvolvimento futuro de deformações permanentes no pavimento. Com relação a esse defeito específico, normalmente considera-se apenas o FN, obtido no ensaio uniaxial de carga repetida,

como indicativo da capacidade de resistência ao acúmulo de deformações de uma determinada mistura asfáltica.

Contudo, o valor do FN, tomado de forma isolada, fornece apenas informações qualitativas quanto à mistura asfáltica analisada. Um exemplo disso, pode ser visto ao considerar os critérios propostos por Bastos *et al.* (2017), onde um determinado valor de FN está associado ao nível de tráfego resistido. Nessa situação, com base no valor do FN, é possível dizer apenas se uma determinada mistura é adequada ou não ao volume de tráfego esperado, não fornecendo nenhuma informação de como a mistura pode ser modificada para atender as especificações.

Gouveia *et al.* (2018), ao analisarem modelos de previsão do módulo dinâmico $|E^*|$ presentes na literatura internacional, com dados de ensaios de 24 misturas asfálticas nacionais, justificaram a importância desse estudo, argumentando que apesar de consagrados no exterior, não é possível afirmar que estes modelos são aplicáveis para a previsão de módulo dinâmico de misturas brasileiras, pois foram criados a partir de pesquisas que se utilizam de dados de misturas com características diferentes das misturas locais, por exemplo, origem dos ligantes, características dos agregados e procedimentos de dosagem distintos.

O que foi dito sobre modelos preditivos para o módulo dinâmico, também é válido para modelos que buscam estimar o FN, o que respalda o desenvolvimento de modelos adaptados às condições nacionais, visto que ambos se referem à ensaios relacionados a capacidade de resistência a deformação. Também é possível mencionar a importância de um modelo preditivo em si, qual seja, reduzir tempo e custos experimentais (GOUVEIA *et al.*, 2018).

Delimita-se como problema de pesquisa, a ausência de um modelo de previsão do FN para misturas asfálticas nacionais no intuito de otimizar o processo de dosagem em laboratório.

1.3 Objetivos

Pode-se definir como objetivo geral deste trabalho, o desenvolvimento de modelos capazes de estimar o FN de misturas asfálticas com base em parâmetros disponíveis na fase de anteprojeto.

Como objetivos específicos, destacam-se os seguintes:

- a) Identificar as variáveis mais relevantes para a estimação do FN;
- b) Investigar diferentes modelos de previsão para o FN;
- c) Identificar os modelos de melhor desempenho.

1.4 Estrutura do Trabalho

O presente trabalho é composto por cinco seções, incluindo esta introdução (seção 1), onde apresenta-se o contexto em que o problema analisado está inserido, bem como, a justificativa, o objetivo geral e os objetivos específicos deste trabalho.

A seção 2 traz uma revisão bibliográfica que trata aspectos que vão desde os princípios mecânicos básicos presentes no desenvolvimento e acúmulo de deformação em misturas asfálticas, além da influência dos seus componentes, passando pelo ensaio mais utilizado para a caracterização deste fenômeno e culmina com uma breve discussão sobre os fundamentos das Redes Neurais Artificiais (RNAs) e diferentes modelos preditivos do FN presentes na literatura nacional e internacional.

Na seção 3 expõe-se o banco de dados adotado para o desenvolvimento deste trabalho e detalha-se as etapas metodológicas empregadas para o alcance dos objetivos específicos aqui propostos. Já a seção 4 apresenta os resultados encontrados e traz uma análise e discussão crítica da relevância e capacidade explicativa dos diferentes modelos investigados.

Por fim, a seção 5 traz as principais conclusões obtidas a partir dos resultados alcançados, bem como, sugestões de trabalhos futuros que podem complementar a investigação de modelos preditivos do FN.

2 REVISÃO BIBLIOGRÁFICA

2.1 Deformação permanente – definição e mecanismos

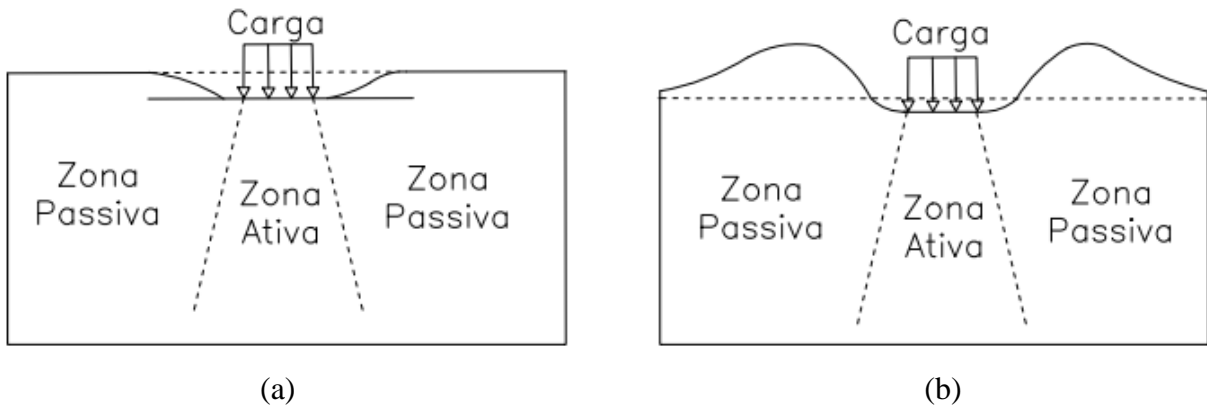
Segundo Hibbeler (2009), sempre que uma força é aplicada a um corpo, este tende a mudar sua forma e tamanho, sendo tais mudanças denominadas deformações, que podem ser causadas tanto pela aplicação de cargas externas quanto pela variação de temperatura, já que em ambos os casos são geradas tensões internas no material. As deformações podem ainda ser de dois tipos, elásticas ou plásticas, onde a primeira caracteriza-se por um retorno ao estado original, enquanto na segunda a deformação mantém-se permanentemente.

Em pavimentos asfálticos, a deformação plástica também recebe o nome de deformação permanente, e como sugere o próprio nome, refere-se às mudanças irreversíveis na forma e/ou volume do pavimento, podendo essa alteração estar associada ao revestimento ou às subcamadas.

As camadas não-asfálticas abaixo do revestimento podem apresentar deformações permanentes principalmente por densificação adicional pelo tráfego e por ruptura ao cisalhamento. Já as deformações permanentes no revestimento asfáltico, ocorrem devido a uma combinação do fluxo do material (viscoelástico ou viscoplástico) e do dano neste material, representado pela formação e propagação de trincas (BERNUCCI *et al.*, 2010).

No revestimento asfáltico, a deformação permanente é causada pela carga de tráfego aplicada sobre a trilha da roda. A área da camada asfáltica solicitada diretamente por esta carga sofre tensão de compressão na direção vertical, o que gera deformações irreversíveis. Por isso, Choi (2013) define esta área como zona ativa, enquanto a área adjacente e sem aplicação direta de carga é referida como zona passiva. Para este autor, na densificação, a zona passiva possui resistência suficiente contra as deformações laterais, o que não se repete quando se considera a deformação por cisalhamento. A Figura 1 exemplifica as deformações por densificação e cisalhamento, bem como as zonas ativa e passiva.

Figura 1 - Mecanismos de deformação



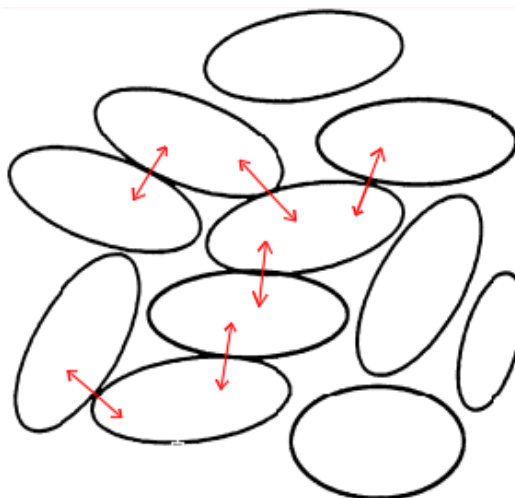
Fonte: Adaptada de Choi (2013).

Ainda segundo Choi (2013), quando uma carga de veículo é aplicada ao pavimento asfáltico, a zona ativa deforma verticalmente, o que provoca uma deformação lateral devido ao efeito de Poisson. Ao mesmo tempo, a tensão horizontal exerce uma pressão de confinamento contra a zona ativa, reduzindo a intensidade das deformações. Dessa forma, as deformações da zona ativa exercem influência na zona passiva e vice-versa.

Para que um material não sofra acúmulo de deformação quando submetido a tensões internas, a estrutura desse material deve ser capaz de absorver os esforços solicitantes. Para o caso de misturas asfálticas, os mecanismos resistentes à deformação permanente estão ligados à estrutura interna do material, podendo ser definida como a quantidade e distribuição espacial do ligante asfáltico, dos agregados e dos vazios com ar (MASAD *et al.*, 1999).

Dentre os mecanismos resistentes à deformação permanente, pode-se mencionar a transmissão interna de cargas, que ocorre essencialmente através de um mecanismo de contato (Figura 2), definido de modo que a execução da transmissão de carga/força seja caracterizada principalmente pela interação força-deslocamento baseada no contato de partículas adjacentes umas às outras (ZHU e NODES, 2000).

Figura 2 - Contato intergranular de um conjunto de partículas



Fonte: Adaptado de Zhu e Nades (2000)

Para Nijboer (1948), as transmissões de carga entre os agregados graúdos ocupam um papel de destaque, considerando o intertravamento entre estes agregados o melhor mecanismo de resistência à deformação permanente.

A distribuição granulométrica em misturas asfálticas é responsável pelo imbricamento ou entrosamento dos agregados, de maneira que os agregados menores ocupem os vazios deixados pelos agregados maiores (MOMM; DOMINGUES, 1998). Este entrosamento dos agregados também é conhecido por intertravamento do esqueleto pétreo (NASCIMENTO *et al.*, 2015).

2.2 Fatores influentes

Uma mistura asfáltica é composta essencialmente por ligante asfáltico e agregados, conseqüentemente, os fatores influentes no fenômeno da deformação permanente estão associados às características e propriedades que estes materiais apresentam, individualmente e quando utilizados em conjunto.

Além das propriedades dos materiais, também deve-se considerar alguns fatores externos. Barboza Jr. *et al.* (2019) ressaltam que os principais fatores de campo que afetam a resistência a deformação permanente são a temperatura, as repetições de carga, o estado de tensões e a ação da água.

Diante da grande quantidade de variáveis que podem afetar a resistência à deformação permanente, uma descrição geral do comportamento de uma mistura asfáltica com relação a este fenômeno é bastante complexa, tornando-se mais viável uma abordagem analítica, ou seja, uma análise das propriedades dos materiais componentes e o posterior estabelecimento das relações entre estas características e a referida manifestação patológica.

2.2.1 Influência dos agregados


A forma como o revestimento resiste ao desenvolvimento de deformações permanentes está relacionada à composição do esqueleto pétreo. Oliveira *et al.* (2000) definem a escolha da granulometria como o problema da correta seleção da proporção e do tamanho adequado dos materiais particulados, de forma que os vazios maiores sejam preenchidos por partículas menores, cujos vazios serão novamente preenchidos com partículas ainda menores e assim sucessivamente.

Dessa forma, a granulometria dos agregados, que consiste na distribuição dos seus diferentes tamanhos de partículas, é uma das propriedades mais importantes para o processo de dosagem, uma vez que o agregado mineral é o seu principal constituinte, tanto em massa quanto em volume (BERNUCCI *et al.*, 2010).

Os métodos normatizados para a escolha da granulometria dos agregados de uma mistura asfáltica seguem uma lógica de enquadramento dos percentuais passantes nas peneiras dentro de intervalos.

No Brasil, o projeto e a execução de uma mistura asfáltica densa (ou concreto asfáltico, CA) devem estar de acordo com a especificação de serviços DNIT 031 (2006). Essa especificação propõe três faixas granulométricas (A, B e C) (Figura 3). Para cada faixa são definidas as peneiras a serem usadas no projeto, assim como, os valores dos percentuais passantes em cada peneira e as tolerâncias envolvidas (FERREIRA *et al.*, 2015; Norma DNIT 031/2006 – ES).

Figura 3 - Faixas granulométricas do DNIT



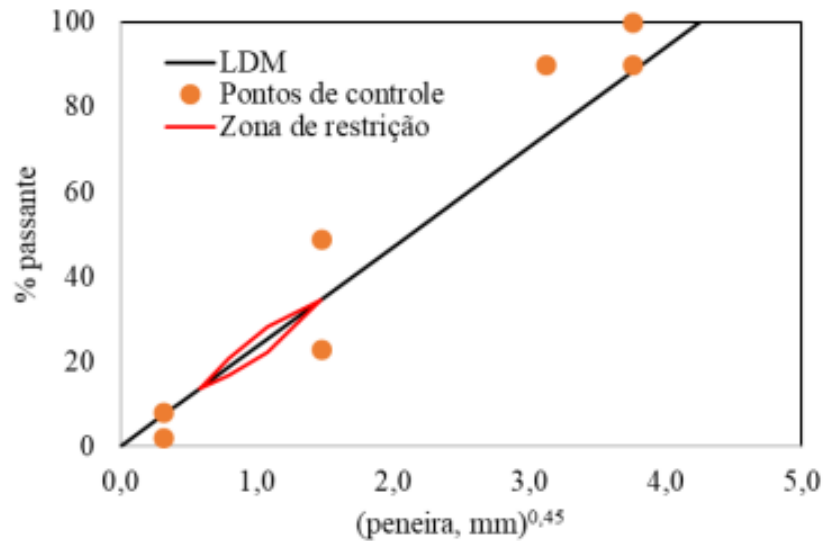
Fonte: Ferreira (2017).

A norma AASHTO M 323 (2017), que se baseia na metodologia *Superior Performing Asphalt Pavements* (Superpave), também aborda o processo de escolha da granulometria. Esse método de dosagem adiciona à curva da Linha de Densidade Máxima (LDM), proposta por Fuller e Thompson em 1907, os pontos de controle, definidos por Bernucci *et al.* (2010) da seguinte forma:

- a) os pontos de controle funcionam como pontos mestres onde a curva granulométrica deve passar. Eles estão no tamanho máximo nominal, um no tamanho intermediário (2,36mm) e um nos finos (0,075mm);

A Figura 4 exemplifica os pontos de controle e a LDM para uma granulometria com Tamanho máximo nominal (TMN) de 19mm. Nesta Figura também é possível observar a zona de restrição (em vermelho), porém, esta foi descontinuada.

Figura 4 - Pontos de controle e LDM para TMN = 19mm



Fonte: Ferreira (2017).

É possível mencionar ainda, outros métodos para a definição do esqueleto pétreo, tais como:

- a) Método Bailey: que objetiva determinar a melhor composição granulométrica para uma determinada mistura asfáltica levando em consideração os requisitos volumétricos de dosagem e obtendo características adequadas de compactação (VAVRIK, 2000);
- b) Método da Faixa de Agregados Dominantes (FAD): que permite avaliar a estrutura granulométrica de misturas asfálticas objetivando a composição de um esqueleto pétreo que confira estabilidade e resistência à deformação permanente (KIM, 2006).

Para poder diferenciar os agregados graúdos e miúdos, o método Bailey – que já está oficialmente incluído na norma AASHTO M 323 (2017) – utiliza a Peneira de Controle Primário (PCP), a qual se baseia no TMN da mistura (MENDES; MARQUES, 2012). A PCP é definida pela Equação 1.

$$PCP = TMN \times 0,22 \quad (1)$$

Os agregados graúdos são, então, aqueles retidos na PCP e recebem a denominação de Proporção do Agregado Graúdo (Proporção AG). O material passante na PCP representa os

agregados miúdos e são divididos em duas proporções: Proporção Graúda do Agregado Miúdo (Proporção GAF) e Proporção Fina dos Agregados Miúdos (Proporção FAF) (MENDES; MARQUES, 2012).

Para o cálculo de AG, GAF e FAF, utiliza-se ainda a Peneira Média (PM), que é aquela mais próxima da metade do TMN, e as Peneiras de Controle Secundário (PCS) e Terciário (PCT), definidas pelas Equações 2 e 3. As proporções AG, GAF e FAF são calculadas utilizando-se as equações 4, 5 e 6, respectivamente.

$$PCS = PCP \times 0,22 \quad (2)$$

$$PCT = PCS \times 0,22 \quad (3)$$

$$AG = \frac{(\% \text{ passante na PM} - \% \text{ passante na PCP})}{(100\% - \% \text{ passante na PM})} \quad (4)$$

$$GAF = \frac{(\% \text{ passante na PCS})}{(\% \text{ passante na PCP})} \quad (5)$$

$$FAF = \frac{(\% \text{ passante na PCT})}{(\% \text{ passante na PCS})} \quad (6)$$

Como já mencionado, Nijboer (1948) considera que a quantidade de agregados graúdos presentes no revestimento asfáltico exerce grande influência na resistência a deformação desta camada. Os agregados suficientemente graúdos (maiores que 1,18mm) e em proporção adequada compõem a chamada Faixa de Agregados Dominantes (FAD), originalmente *Dominant Aggregate Size Range* (KIM, 2006). Tal estrutura é a principal responsável pela resistência à deformação permanente, sendo tanto mais resistente quanto mais graúda for a estrutura de agregados dominantes, conforme concluiu Ferreira (2015).

Para corroborar essas afirmações, pode-se mencionar o trabalho de Ferreira *et al.* (2020), onde foram propostos dois parâmetros granulométricos complementares à proposta original e que possuem uma correlação moderada com o FN, quais sejam:

- a) proporção de agregados não estruturais (α): percentual de agregados não estruturais dispersos na matriz pétreia de interesse, sendo definido como a razão entre a massa de agregados intersticiais ($M_{ag.int}$) e a massa de agregados não flutuantes (Equação 7). Onde esta última é dada pela soma entre a massa de agregados intersticiais ($M_{ag.int}$) e a massa de agregados dominantes ($M_{ag.dom}$).

As definições de agregados intersticiais e flutuantes são as mesmas estabelecidas por Kim (2006);


$$\alpha = \frac{M_{ag.int}}{M_{ag.int} + M_{ag.dom}} \quad (7)$$

b) proporção graúda dominante (C): é definida como a razão entre o percentual de material retido na maior peneira da FAD ($P_{ret(maior\#FAD)}$) e o somatório dos percentuais retidos nas demais peneiras da FAD ($\sum P_{ret(demais\#FAD)}$) (Equação 8);

$$C = \frac{P_{ret(maior\#FAD)}}{\sum P_{ret(demais\#FAD)}} \quad (8)$$

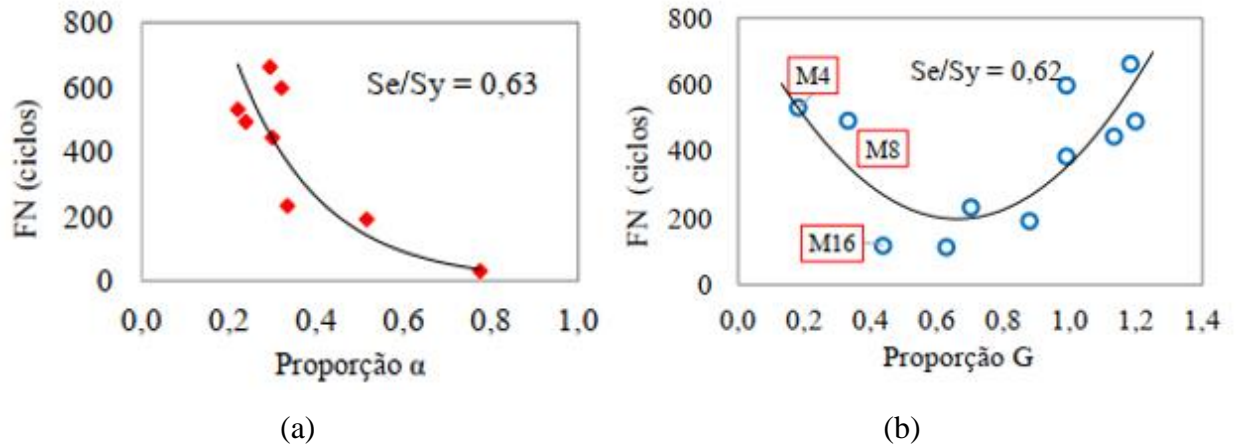
Nas Figuras 5, 6a e 6b, têm-se respectivamente, uma representação visual dos agregados correspondentes às variáveis do parâmetro α , a relação entre o parâmetro α e o FN e a relação entre C e o FN.

Figura 5 - Representação da proporção α



Fonte: Ferreira (2017)

Figura 6 - Correlação dos parâmetros α e C com o FN



Fonte: Ferreira (2017)

Obs: Na Figura 6b, onde existe 'G' (nomenclatura original de Ferreira (2017)) leia-se 'C' (nomenclatura adotada em Ferreira *et al.* (2020)).

Na Figura 6, Se/Sy representa a taxa de erro padrão, onde Se é o erro padrão da estimativa da regressão (Equação 9) e Sy é o desvio padrão da variável dependente (Equação 10).

$$Se = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - Y_i')^2} \quad (9)$$

$$Sy = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \mu)^2} \quad (10)$$

Nas equações acima, Y_i é o valor experimental, Y_i' é o valor estimado pela regressão, μ representa o valor médio e N é o número de dados da população (FERREIRA, 2017).

Witczak *et al.* (2002) propuseram critérios subjetivos para classificar o nível de correlação entre as variáveis, os quais podem ser visualizados na Tabela 1.

Tabela 1 - Critérios para o nível de correlação

Nível de correlação	Se/Sy
Excelente	< 0.35
Bom	0.36 – 0.55
Moderado	0.56 – 0.75
Fraco	0.76 – 0.90
Muito fraco	> 0.90

Fonte: Adaptada de Witczak *et al.* (2002)

Os métodos FAD e Bailey buscam uma proporção adequada entre os diferentes tamanhos de agregados de forma que o esqueleto pétreo seja estável e possua um bom intertravamento. Conforme Ferreira (2017), o esqueleto pétreo formado pelos agregados, o qual determina a capacidade da mistura asfáltica resistir ao carregamento, ganha maior relevância em países de clima tropical como o Brasil, pois o revestimento atinge elevadas temperaturas e o ligante se torna menos rígido.

Essa observação é ratificada por autores como Barboza *et al.* (2019), os quais constataram que quanto maior a temperatura, menor o valor obtido para o FN no ensaio uniaxial de carga repetida.

Através de modelos constitutivos, Zhu e Dass (1996) e Zhu (1998) já demonstraram a influência das propriedades geométricas de contato entre as partículas para a deformação permanente em misturas asfálticas. Dentre essas propriedades, pode-se mencionar a área e a orientação de contato intergranular, visto que estas influenciam a forma como as tensões serão distribuídas no interior da mistura asfáltica.

Rodrigues *et al.* (2019) avaliaram a forma, textura e angularidade dos agregados de nove misturas asfálticas via Processamento Digital de Imagens (PDI) por meio do *Aggregate Image Measurement System* (AIMS). Os autores notaram que o FN apresentou maior correlação com a característica de forma 2D (agregado miúdo) e que a análise da FAD se mostrou promissora para avaliar a resistência à deformação permanente. A Figura 7 ilustra graficamente os conceitos de angularidade, forma e textura.

Figura 7 - Forma, angularidade e textura superficial das partículas de agregado



Fonte: Diógenes (2018).

2.2.2 Influência do Ligante

As misturas asfálticas herdam as características viscoelásticas e termosuscetíveis dos ligantes asfálticos, que dependendo do tipo e teor apresentam-se mais ou menos susceptíveis à variação de temperatura, frequência e do tempo de aplicação de carga (SPECHT *et al.*, 2017), e conseqüentemente, de apresentar à deformação permanente em altas temperaturas (ALMEIDA JR. *et al.*, 2017).

A viscosidade é uma das principais características de interesse desse material, pois conforme Bernucci *et al.* (2010), a maioria dos países utiliza medidas simples de características físicas do ligante para especificar um determinado asfalto como adequado para pavimentação, como, por exemplo, a resistência ao fluxo, medida por ensaios de viscosidade.

Ainda segundo Bernucci *et al.* (2010), todas as propriedades físicas do asfalto estão associadas à temperatura, entre estas, a capacidade de resistência ao escoamento, visto que, em temperaturas muito baixas, as moléculas não têm condições de se mover umas em relação às outras, o que torna a viscosidade muito elevada. Em contrapartida, à medida que a temperatura aumenta, algumas moléculas começam a se mover, podendo mesmo haver um fluxo entre as moléculas.


Partindo dessa definição, é possível inferir que a viscosidade do ligante exerce um importante papel na resistência à deformação permanente de uma mistura asfáltica, pois tem a

função de manter unido e coeso o esqueleto pétreo que compõe a camada de revestimento asfáltico.

Visto que a viscosidade da mistura asfáltica depende de sua temperatura, em países como o Brasil, onde há predominância de temperaturas mais elevadas, as características do ligante asfáltico ganham ainda mais importância, afinal, o ligante asfáltico torna-se menos viscoso e tende a produzir uma lubrificação no interior do esqueleto pétreo, prejudicando, conseqüentemente, o intertravamento e a capacidade estrutural (FERREIRA, 2017).

De maneira geral, ligantes menos viscosos tornam a mistura menos rígida e mais propensa ao acúmulo de deformações plásticas (NASCIMENTO, 2008). Ferreira (2017), através da análise de um banco de dados composto por 27 misturas asfálticas, demonstrou que existe uma correlação entre a viscosidade rotacional e o FN obtido no ensaio uniaxial de carga repetida (Figura 8), sendo observada uma tendência em se obter maiores valores de FN conforme aumenta a resistência ao escoamento do ligante.

Figura 8 - Correlação entre a viscosidade rotacional e o FN



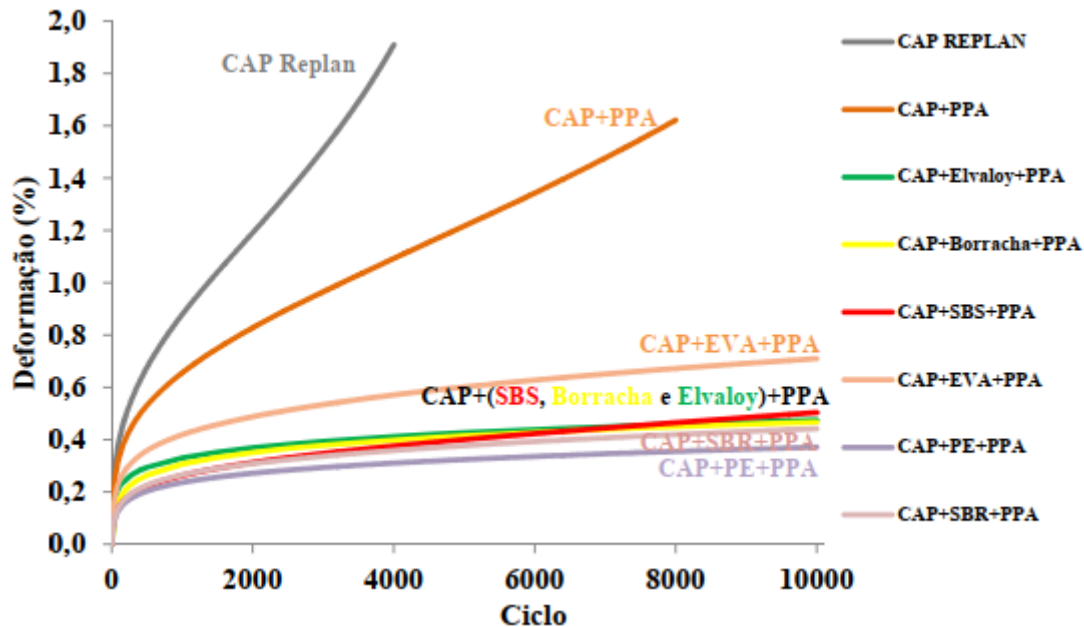
Fonte: Ferreira (2017)

Uma das formas de modificar e melhorar as propriedades do ligante asfáltico é a adição de polímeros, que normalmente também impacta elevando a sua viscosidade. De acordo com Yildirim (2007), a adição de polímeros proporciona menor suscetibilidade térmica, reduzido o dano por fadiga, e aumentando a resistência à deformação permanente.

Onofre (2012) avaliou o comportamento mecânico de misturas asfálticas produzidas com ligantes asfálticos modificados por ácido polifosfórico (PPA) e polímeros no que diz respeito à rigidez e à resistência à deformação permanente. Os resultados mostraram que a modificação dos ligantes asfálticos aumentou a capacidade de resistência ao desenvolvimento de deformações irreversíveis, principalmente naquelas em que foram utilizados ligantes asfálticos modificados por polímeros + PPA, por não terem atingido a

ruptura até o final do ensaio. A Figura 9 mostra as curvas de deformação acumulada para as diferentes misturas asfálticas avaliadas pelo referido autor.

Figura 9 - Resultados dos ensaios para as misturas com ligantes asfálticos + Polímero + PPA



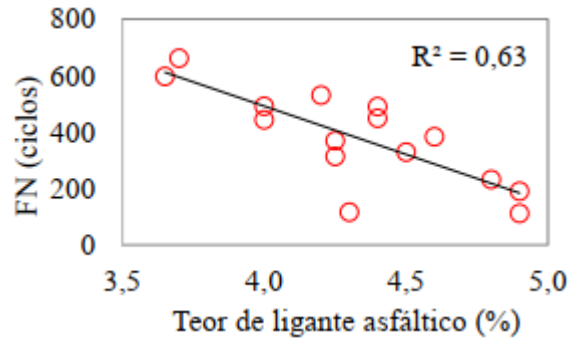
Fonte: Onofre (2012).

O teor de ligante presente na mistura asfáltica também é uma característica de interesse no que se refere ao acúmulo de deformações plásticas. De acordo com Ferreira (2017), o excesso de ligante pode acarretar o desenvolvimento de deformação permanente, observando-se inclusive uma tendência contrária à viscosidade, ou seja, quanto menor o teor de ligante asfáltico, maior o FN.

Almeida Jr. *et al.* (2018) avaliaram a influência na deformação permanente do tipo e teor de ligante asfáltico e da granulometria quanto aos métodos Bailey, FAD e faixas granulométricas B e C por meio do ensaio uniaxial de carga repetida. Os resultados indicaram que as modificações no tipo e no teor dos ligantes asfálticos foram mais influentes no acúmulo de deformações do que a granulometria das misturas, encontrando-se inclusive boa correlação entre a reologia dos ligantes e os respectivos valores de FN.

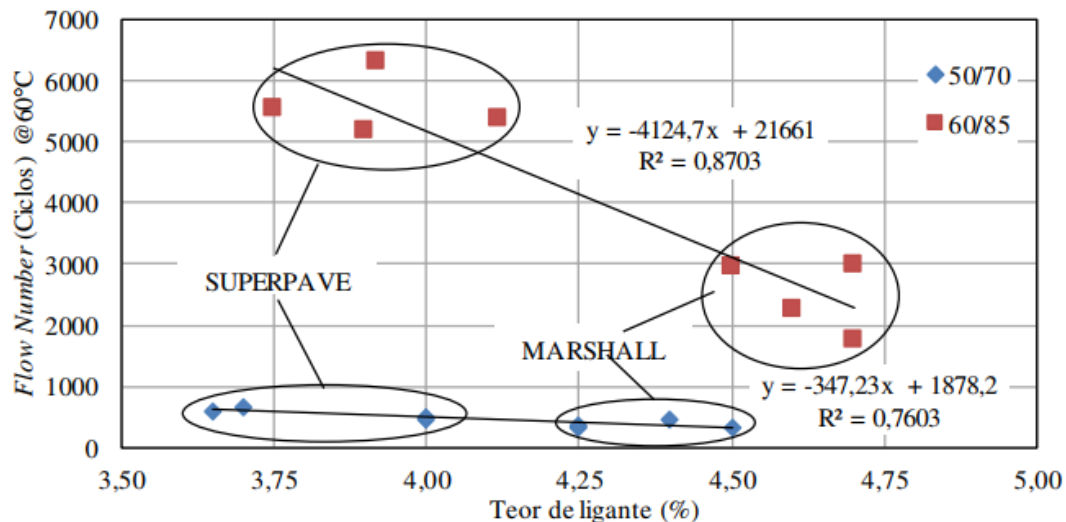
As Figuras 10 e 11 mostram as correlações entre o teor de ligante e o FN obtidos por Ferreira (2017) e Almeida Jr. *et al.* (2018), respectivamente.

Figura 10 - Correlação entre o teor de ligante asfáltico 50/70 e o FN



Fonte: Ferreira (2017).

Figura 11 - Correlação entre o teor de ligante de projeto (%) e o FN



Fonte: Almeida Jr. *et al.* (2018).

Ao observar a Figura 11 também é possível notar que o método de dosagem influencia o valor do FN, pois o método Superpave tende a fornecer valores menores para o teor de ligante, e conseqüentemente maiores valores para o FN.

O envelhecimento do ligante asfáltico, caracterizado por um endurecimento do material, resultado do aumento da sua viscosidade e da redução da sua flexibilidade (ROSSI; FAXINA, 2018), também pode exercer influência na deformação permanente, pois reduz sua plasticidade e conseqüentemente a suscetibilidade da mistura asfáltica ao acúmulo de deformações plásticas. Rossi e Faxina (2018) advertem, contudo, que o envelhecimento do ligante torna a camada asfáltica mais quebradiça e propensa a trincamentos, sejam estes de origem térmica ou por fadiga, além de ocasionar problemas como desgaste e desagregação.

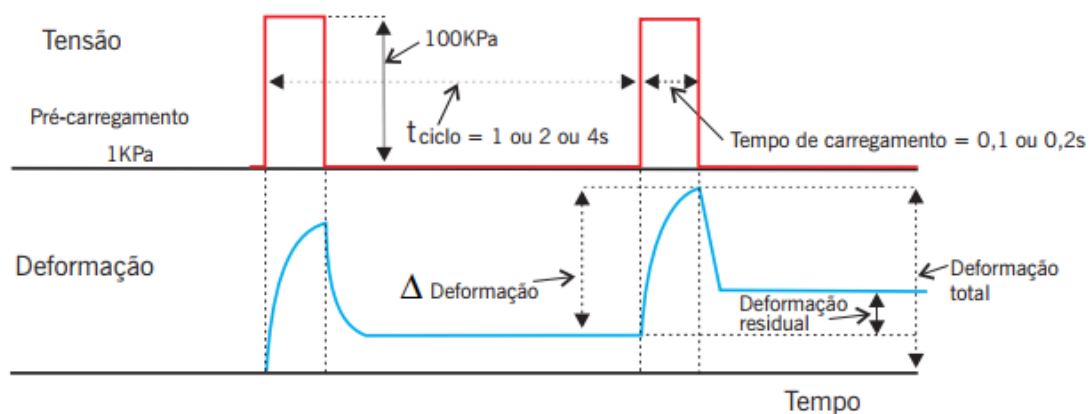
2.3 Ensaio uniaxial de carga repetida

A Norma DNIT 184/2018 – ME, desenvolvida pelo Instituto de Pesquisas Rodoviárias (IPR), estabelece um método que prescreve o modo pelo qual se determina a deformação permanente de um corpo de prova (CP) cilíndrico de mistura asfáltica, resultante da aplicação de carregamento de compressão uniaxial vertical repetido.

O método descrito nesta norma trata do ensaio uniaxial de carga repetida, o qual é realizado da seguinte forma: após a colocação do corpo de prova em uma câmara com temperatura aproximada de 60°C por no mínimo 3 horas, devem ser acoplados na amostra, dois sensores LVDT que terão a função de captar os deslocamentos ocorridos.

Em seguida deve-se realizar o carregamento, que se divide em duas etapas, o pré-carregamento, aplicando-se ao corpo de prova uma carga de compressão de $10,2 \pm 0,5$ kPa por 60 segundos, e o carregamento cíclico de compressão, que possui duração de 1 segundo, sendo 0,1 segundo destinado à aplicação de um pulso de carga de $204,0 \pm 4$ kPa e o restante reservado ao repouso da amostra, que ocorre com uma carga de 10,2 kPa. A Figura 12 mostra os ciclos de carregamento e o acúmulo de deformações ao longo do tempo.

Figura 12 - Carregamento e deformação no ensaio uniaxial de carga repetida



Fonte: Bernucci *et al.* (2010).

A Figura 13 mostra o equipamento e esquema de montagem do ensaio, e a Figura 14 exemplifica os corpos de prova antes e após a execução do mesmo. Vale ressaltar que segundo a Norma DNIT 184/2018 – ME, o fim do ensaio é caracterizado por dois critérios, sendo estes:


- a) Ruptura do corpo de prova, identificada pelo atingimento da zona terciária na curva de deformação plástica vertical uniaxial;
- b) O número de ciclos atinge 7.200 (aproximadamente 2 horas de carregamento cíclico).

Figura 13 - Esquema de montagem do ensaio de número de fluxo (FN)



Fonte: Norma DNIT 184/2018 – ME.

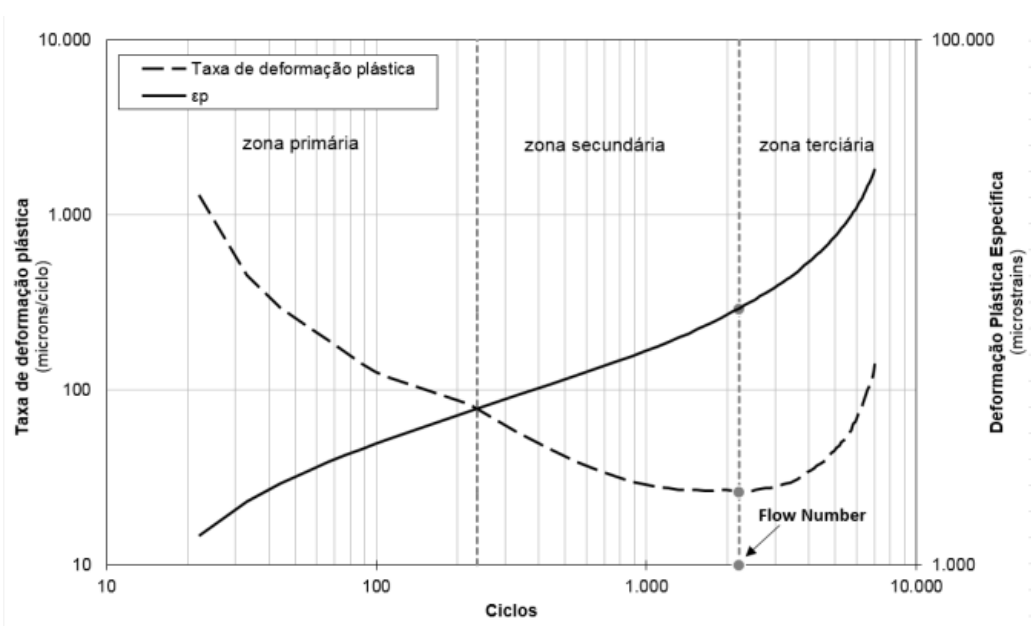
Figura 14 - Exemplo de um corpo de prova antes e após o ensaio de FN



Fonte: Norma DNIT 184/2018 – ME.

A deformação permanente acumulada pode ser dividida em 3 regiões: primária, secundária e terciária. Essas regiões se comportam da seguinte forma: (i) na região primária, a densificação da amostra ocorre a uma taxa elevada, (ii) na região secundária, a taxa de deformação é praticamente constante e (iii) na região terciária (cisalhamento com volume constante) é designado como o já referido *Flow Number*. O FN é o número do ciclo em que a taxa de deformação plástica é mínima e a partir do qual o CP atinge a ruptura (Figura 15) (DONGRE *et al.*, 2009).

Figura 15 - Curva típica do ensaio uniaxial de carga repetida



Fonte: Norma DNIT 184/2018 – ME.

2.4 Redes neurais artificiais

A inteligência artificial, ou sistemas inteligentes, é uma área do conhecimento relativamente nova, no entanto, trata-se de um campo bastante desenvolvido, possuindo diversos métodos pelos quais a partir do fornecimento de um conhecimento prévio, busca-se a dedução ou inferência de novos conhecimentos (SILVA *et al.*, 2004).

Dentre os sistemas inteligentes é possível citar como ferramentas existentes, os sistemas *fuzzy*, que se baseiam na lógica nebulosa ou difusa; a computação evolutiva ou genética, que se trata de um poderoso método estocástico de busca e otimização baseado nos princípios da genética e da seleção natural (MIRZAHOSSEINI, 2015); a inteligência coletiva, que inclui qualquer tentativa de projetar algoritmos ou dispositivos distribuídos de solução de problemas inspirados pelo comportamento coletivo de insetos sociais e outras sociedades animais (BONABEAU *et al.*, 1999); os sistemas imunológicos artificiais, fundamentados nos sistemas imunológicos dos vertebrados; e as Redes Neurais Artificiais (RNA).

Como pode ser observado, a maioria dos sistemas inteligentes baseiam-se no *modus operandi* de sistemas vivos, e buscam por meio de modelos matemáticos, a simulação da forma como esses sistemas tomam alguma decisão ou adquirem conhecimento. Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torna-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos (HAYKIN, 2008):


1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

De acordo com Silva *et al.* (2016), a primeira publicação relacionada à neuro computação data de 1943, e foi elaborada por McCulloch e Pitts (1943), onde neste trabalho, os autores realizaram o primeiro modelamento matemático inspirado no neurônio biológico, resultando na primeira concepção de neurônio artificial.

O neurônio é o principal componente para o funcionamento do cérebro, tratando-se, de uma célula altamente estimulável, que processa e transmite informação através de sinais eletroquímicos (MOREIRA, 2013). São constituídos em sua maioria, por um corpo celular

(membrana e núcleo), dois tipos de prolongamentos citoplasmáticos, os dendritos (ou soma) e axônios, e as terminações sinápticas (Figura 16).

Figura 16 - Neurônio biológico



Fonte: Azevedo (2016).

Simplificadamente, pode-se explicar o funcionamento de um neurônio da seguinte forma: as informações vindas de outros neurônios chegam aos dendritos por meio de substâncias químicas que provocam reações no corpo celular, podendo essa reação ser excitatória ou inibidora, isto é, uma reação que produzirá ou não, o disparo de um impulso elétrico através do axônio rumo às terminações sinápticas que irão se conectar a outros neurônios, transmitindo assim, informações através do sistema nervoso.

As RNAs buscam simular o procedimento descrito anteriormente mediante funções matemáticas que recebem um conjunto de entradas numéricas, similares aos impulsos elétricos captados pelos dendritos, que são ponderadas por um conjunto de pesos sinápticos, de forma a determinar o grau de importância da entrada em questão.

Em seguida, este conjunto de dados, passa por um combinador linear, sendo a diferença entre o valor produzido por este combinador e o limiar de ativação, conhecido como potencial de ativação. Cabe ressaltar, que o limiar de ativação é uma variável que especifica qual será o patamar apropriado para que o resultado produzido pelo combinador linear possa gerar um valor de disparo em direção à saída do neurônio (SILVA *et al.*, 2016).

Por último, antes de fornecer um valor final, o potencial de ativação passa por uma função de ativação, cujo objetivo é limitar a saída do neurônio dentro de um intervalo de valores razoáveis a serem assumidos pela sua própria imagem funcional (SILVA *et al.*, 2016).


As Equações 11 e 12 sintetizam o processo descrito anteriormente e a Figura 17 ilustra o neurônio artificial:

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (11)$$

$$y = g(u) \quad (12)$$

onde x_i são os sinais de entrada, w_i são os pesos sinápticos, Σ é combinador linear, θ é o limiar de ativação, u é o potencial de ativação, g é a função de ativação e y é o sinal de saída.

Figura 17 - Neurônio artificial




Fonte: Adaptado de Silva *et al.* (2016).

Uma categorização fundamental da topologia dos neurônios pode ser feita em relação ao método de propagação da informação recebida. Pode-se distinguir entre redes de propagação para frente (*feedforward*) e redes realimentadas (*recurrent*). No caso das redes de propagação para frente o fluxo de informação é unidirecional (RAUBER *et al.*, 2014), ou seja, flui da camada de entrada em direção a camada de saída.

Pode-se ainda diferenciar as RNAs quanto ao número de camadas existentes, definindo-se camada como o conjunto de neurônios que recebem informações simultaneamente.

São exemplos de redes *feedforward* o *Perceptron simples* (Figura 17), que possui apenas as camadas de entrada e saída, o Perceptron multicamadas (PMC) ou *Multilayer Perceptron* (MLP) (Figura 18), que possui camadas ocultas responsáveis por extrair as características associadas ao processo ou sistema a ser inferido (SILVA *et al.*, 2016), o Adaline e as redes de base radial.

Figura 18 - Exemplo de rede PMC



Fonte: Adaptado de Silva *et al.* (2016)

De acordo com Santana (2012), o processo de aprendizagem envolve a adaptação dos pesos da rede neural a partir de estímulos fornecidos por um conjunto de dados, podendo esse ajuste ser classificado como: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço.

No aprendizado supervisionado, são fornecidos os conjuntos de entrada e suas respectivas saídas, tendo a rede, a função de adaptar-se a esses dados da melhor forma possível, minimizando a diferença entre os valores calculados e as saídas desejadas. Já no aprendizado não supervisionado, não há o conjunto de exemplos formado por pares de entrada e saída desejada, conseqüentemente, o ajuste dos pesos é realizado com base nas regularidades estatísticas dos dados fornecidos à rede (SANTANA, 2012).

Os algoritmos de aprendizado utilizados no treinamento com reforço ajustam os parâmetros internos dos neurônios baseando-se em quaisquer informações quantitativas ou qualitativas advindas da interação com o sistema (ambiente) que está sendo mapeado, as quais são então utilizadas para medir o desempenho do aprendizado (SILVA *et al.*, 2016). Dito de outro modo, o treinamento é realizado com base nos sinais de reforço ou penalização fornecidos por um crítico externo à rede (SANTANA, 2012).

Existem diversos algoritmos que executam o ajuste dos pesos sinápticos e consequentemente o aprendizado da rede, dentre os quais pode-se mencionar:

- a) regra delta: objetiva minimizar o erro entre os valores calculados pela rede e desejados pelos exemplos fornecidos num problema de aprendizagem supervisionada (SANTANA, 2012);
- b) algoritmo *backpropagation* ou regra delta generalizada: utilizado no treinamento de redes PMC, onde basicamente, o procedimento de aprendizagem utiliza vetores que mapeiam um conjunto de entradas para um conjunto de saídas (TISSOT *et al.*, 2015)

As RNA possuem aplicabilidade em uma gama variada de problemas, onde conforme Silva *et al.* (2016), pode-se mencionar: aproximador universal de funções, controle de processos, reconhecimento/classificação de padrões, agrupamento de dados (clusterização), sistemas de previsão, otimização de sistemas e memórias associativas. Tissot *et al.* (2015) também ressaltam que RNAs oferecem maneiras diferentes de resolver muitos problemas não lineares que são difíceis de serem resolvidos por meio de técnicas convencionais.

2.5 Modelos para previsão do FN


A literatura já contempla algumas tentativas de desenvolvimento de modelos para estimar o FN. Estes modelos podem ser usados como ferramenta para classificar misturas com base em seu FN potencial, além de auxiliar a otimização da dosagem a partir de uma seleção de materiais baseada em indicadores objetivos.

A avaliação do potencial de formação do ATR, têm sido, de acordo com Gandomi *et al.* (2011), foco de muitas pesquisas na engenharia de pavimentação nas últimas décadas, contudo, reitera que a maioria dos modelos de deformação permanente disponíveis, são empíricos ou semimecânicos com caracterização fundamental limitada do material.

É importante salientar que, normalmente esses modelos utilizam informações dos materiais constituintes da mistura asfáltica e seus resultados preditivos estão condicionados ao protocolo de ensaio utilizado em seu desenvolvimento (FERREIRA, 2017).

Rodezno *et al.* (2010) propuseram um modelo a partir de análises estatísticas de regressão, que utiliza propriedades volumétricas da mistura asfáltica, além de condições de tensão e temperatura do ensaio como variáveis preditoras. Tal modelo obteve um R^2 de 0,62 (Figura 19), e emprega a viscosidade na temperatura de ensaio (V1), a temperatura (T), o volume de vazios (Va), percentual passante na peneira 200 (P_{200}), percentuais retidos nas peneiras 3/4 ($R_{3/4}$) e n°4 (R_{04}) e as tensões de cisalhamento e normal (p e q), como variáveis preditoras (Equação 13).

Figura 19 - Log dos FNs medidos *versus* previstos



Fonte: Rodezno *et al.* (2010).

$$\log(\text{FN}) = 2,174 + 0,649 \log(\text{V1}) + 0,101P_{200} + 18,465 \log(p) + 0,0140R_{04} - 0,084V_a - 18,901 \log(q) - 0,872R_{\frac{3}{4}} + 0,182q - 0,193p - 0,871 \log(T) \quad (13)$$

Apeagyei (2014) desenvolveu um modelo de regressão múltipla de primeira ordem para descrever a relação entre o FN e propriedades volumétricas da mistura asfáltica e propriedades do ligante asfáltico. O modelo final obtido possui um R^2 de 0,94 (Figura 20) e pode ser expresso na Equação 14.

$$\text{FN} = 4698,1734P_{be} + 423,6569VFA + 924,1876 \left(\frac{G^*}{\text{sen}(\delta)} \right) - 1001,435P_{25} + 148,0361P_{19} - 4395,186P_{200} + 24,751DB + 31,393 \quad (14)$$

Onde:

P_{be} = teor efetivo de ligante asfáltico;

VFA = vazios preenchidos com ligante asfáltico;

$\left(\frac{G^*}{\text{sen}(\delta)}\right)$ = porção elástica do módulo de cisalhamento;


P_{25} = percentual passante na peneira de 25 mm;

P_{19} = percentual passante na peneira de 19 mm;

P_{200} = percentual passante na peneira 200;

DB = razão entre o percentual passante na peneira 200 e teor efetivo de ligante asfáltico.

Figura 20 - Comparação dos FNs previstos *versus* medidos em laboratório



Fonte: Apeagyei (2014).

No Brasil, houve algumas tentativas de produzir modelos para a estimação do FN. Nesse sentido, é possível mencionar Bastos *et al.* (2016), que investigaram as relações entre parâmetros granulométricos do método Bailey (proporção AG) e características de forma na resistência à deformação permanente, obtendo o modelo preditivo para o FN da Equação 15.

$$FN = \frac{(-2,1631 + X_2)}{(-1,0104 \cdot 10^{-2} - 1,3986 \cdot 10^{-3} X_1)} - \frac{215,27}{X_2} \quad (15)$$


Em que X_1 representa a forma 2D do agregado miúdo obtida no *Aggregate Image Measurement System (AIMS2)*; e X_2 , a proporção AG.

Ferreira (2017) propôs um método expedito de estimação do FN baseado nas variáveis consideradas mais influentes na resistência ao acúmulo de deformações plásticas. Dentre essas variáveis, pode-se mencionar: características de intertravamento e graudez da estrutura de agregados dominantes – representadas pelos parâmetros α e C , respectivamente –, teor de ligante de projeto (L) e viscosidade rotacional do ligante asfáltico a 135°C (μ). Para esse método, após linearização da Equação 16, foi obtido um coeficiente de correlação de Pearson (r) de 0,95 (Figura 21), o que caracteriza uma relação linear bastante forte (FERREIRA, 2017).

$$k = \frac{L}{1 + e^{\frac{\mu}{L}(\frac{1}{\alpha} + C)}} \quad (16)$$

$$FN = 81653e^{-2,972k} \quad (17)$$

Figura 21 - Correlação para a função linearizada do FN



Fonte: Ferreira (2017).

Almeida Jr. *et al.* (2018), após avaliar 24 misturas através do ensaio uniaxial de carga repetida, buscaram construir um modelo do FN em função do *Performance Grade* (PG) de alta temperatura dos ligantes asfálticos, teor de ligante asfáltico de projeto, proporção AG (método Bailey) e porosidade FAD das misturas. O modelo (Equação 18) apresentou um R^2 de 0,85, indicando um bom ajuste da reta e boa significância global ($\rho < 0,05$).

$$FN = -21361,14 + 574,66 \cdot PG - 2342,97 \cdot Teor + 196,91 \cdot \text{Proporção AG} - 74,06 \cdot \text{Porosidade} \quad (17)$$

Gandomi *et al.* (2011) utilizaram uma variante promissora da programação genética, a saber, a programação de expressão gênica, para prever o FN de misturas densas, fornecendo uma ferramenta de análise da resistência à deformação permanente para esse tipo de compósito.

Mirzahosseini *et al.* (2015) desenvolveram modelos não lineares de previsão do FN utilizando duas técnicas, a programação genética linear e RNAs. Tal modelo foi formulado em termos de porcentagem de agregado graúdo, fíler, ligante asfáltico, volume de vazios, vazios no agregado mineral e quociente de Marshall.

Um modelo de alta precisão para prever o FN de misturas asfálticas densas foi proposto por Alavi *et al.* (2011). Para obtenção deste modelo lançou-se mão de um método híbrido, o qual acopla programação genética e Recozimento Simulado, que é uma heurística baseada em busca local capaz de escapar da armadilha de um ótimo local ao aceitar, com pequena probabilidade, soluções piores durante suas iterações (LIN; YU, 2012).

3 MATERIAIS E MÉTODOS

3.1 Banco de dados

Para o desenvolvimento do presente trabalho foi utilizado o banco de dados compilado por Ferreira (2017), no qual constam informações referentes a 27 misturas asfálticas nacionais. As Tabelas 2 e 3 apresentam as variáveis utilizadas para obtenção dos modelos.

Tabela 2 – Dados referentes à mistura asfáltica e ao ligante

Mistura	m_d	L (%)	μ (cP)	FN
M1	Marshall	5,80	690	30
M2	Superpave	4,80	350	232
M3	Marshall	4,90	360	191
M4	Marshall	4,20	360	531
M5	Superpave	4,00	330	444
M6	Superpave	3,70	330	597
M7	Superpave	3,70	330	662
M8	Superpave	4,00	330	492
M9	Superpave	4,30	430	340
M10	Superpave	4,70	580	1214
M11	Superpave	4,10	1030	5367
M12	Superpave	3,80	1030	5528
M13	Superpave	4,50	520	795
M14	Marshall	4,60	360	384
M15	Marshall	4,90	360	112
M16	Superpave	4,30	390	117
M17	Superpave	4,40	360	490
M18	Superpave	3,90	1030	5165
M19	Superpave	3,90	1030	6300

continua

conclusão

M20	Marshall	4,50	330	329
M21	Marshall	4,30	330	370
M22	Marshall	4,30	330	314
M23	Marshall	4,40	330	449
M24	Marshall	4,70	1030	1742
M25	Marshall	4,50	1030	2976
M26	Marshall	4,60	1030	2244
M27	Marshall	4,50	1030	2945

Fonte: Elaborada pelo autor.

Obs: m_d é o método de dosagem; L é o teor de ligante asfáltico; μ é a viscosidade rotacional a 135 °C; FN é o *Flow Number*.

Tabela 3 - Parâmetros granulométricos das misturas

Mistura	Método de Faixa de Agregados Dominantes (FAD)		Método Bailey (MBA)			FN
	α	C	AG	GAF	FAF	
M1	0,78	0,95	0,48	0,61	0,24	30
M2	0,33	0,70	0,85	0,50	0,49	232
M3	0,52	0,88	1,00	0,60	0,40	191
M4	0,22	0,18	0,94	0,47	0,65	531
M5	0,30	1,13	1,42	0,48	0,59	444
M6	0,32	0,99	0,65	0,48	0,59	597
M7	0,29	1,18	1,08	0,48	0,59	662
M8	0,24	0,33	0,73	0,49	0,59	492
M9	0,30	0,42	0,36	0,54	0,51	340
M10	0,35	1,34	1,43	0,56	0,59	1214
M11	0,30	1,13	1,42	0,48	0,59	5367
M12	0,32	1,36	0,65	0,48	0,59	5528
M13	0,41	1,39	0,18	0,76	0,68	795
M14	0,39	0,99	1,03	0,55	0,50	384
M15	0,41	0,63	0,68	0,53	0,48	112

continua

conclusão

M16	0,35	0,44	0,29	0,65	0,49	117
M17	0,32	1,20	1,58	0,51	0,54	490
M18	0,29	1,18	1,08	0,48	0,59	5165
M19	0,24	0,33	0,73	0,49	0,59	6300
M20	0,30	1,13	1,42	0,48	0,59	329
M21	0,32	1,36	1,36	0,48	0,59	370
M22	0,29	1,18	1,18	0,48	0,59	314
M23	0,24	0,33	0,33	0,49	0,59	449
M24	0,30	1,13	1,13	0,48	0,59	1742
M25	0,32	1,36	1,36	0,48	0,59	2976
M26	0,29	1,18	1,18	0,48	0,59	2244
M27	0,24	0,33	0,33	0,49	0,59	2945

Fonte: Elaborada pelo autor.

Obs: α é a proporção de agregados não estruturais; C é a proporção graúda dominante; AG é a proporção de agregado graúdo; GAF é a proporção graúda de agregado miúdo; FAF é a proporção fina dos agregados miúdos.

Todas as misturas asfálticas possuem graduação densa, sendo que algumas delas possuem a mesma granulometria, diferenciando-se apenas no teor e tipo de ligante asfáltico utilizado na dosagem. Ressalta-se também, que todas as misturas foram submetidas ao ensaio uniaxial de carga repetida sob um protocolo semelhante (dimensões das amostras, carga, tempos de carregamento e descanso e temperatura) (FERREIRA, 2017).

3.2 Etapas metodológicas

3.2.1 Escolha das variáveis

Este trabalho pode ser classificado quanto à abordagem como uma pesquisa quantitativa de natureza aplicada e com objetivos descritivos, isto é, que objetiva gerar conhecimentos para a solução de problemas específicos por meio da descrição de características de populações ou fenômenos e de correlação entre variáveis (NASCIMENTO, 2016).

Quanto aos procedimentos, trata-se de uma pesquisa *ex-post-facto*, ou seja, realizada após a observação ou ocorrência do fenômeno ou do experimento (NASCIMENTO, 2016). Neste caso, o problema específico é a estimativa do FN para misturas asfálticas, e o experimento diz respeito ao ensaio uniaxial de carga repetida.

A escolha preliminar dos parâmetros para compor os modelos se deu por consulta bibliográfica a trabalhos correlatos, tanto referentes à descrição dos mecanismos de resistência à deformação permanente, quanto a trabalhos cujo objetivo era a proposição de modelos preditivos propriamente ditos.

Uma inspeção cuidadosa dos fatores que afetam tal fenômeno, identificados em estudos anteriores, sugere que esses podem ser classificados em dois grupos principais. Em primeiro lugar estão as propriedades do ligante asfáltico, que controlam o comportamento viscoelástico e viscoplástico e, em segundo lugar, estão as propriedades dos agregados, incluindo a granulometria que controla o comportamento elástico (e possivelmente plástico) da mistura asfáltica (APEAGYEI, 2014).

Como representativo das propriedades do ligante, adotou-se a viscosidade rotacional a 135°C (μ). Quanto as propriedades dos agregados, foram investigadas duas abordagens de caracterização da estrutura granulométrica, ou esqueleto pétreo da mistura asfáltica, sendo estas, o método de Faixa de Agregados Dominantes (FAD), representado pelos parâmetros α e C sugeridos por Ferreira *et al.* (2020), e método Bailey (MBA), caracterizado pelos parâmetros AG, GAF e FAF.

Também foi testada uma combinação entre os referidos métodos, o que resultou em um modelo híbrido (MHI). Neste modelo, os parâmetros α (obtido por meio da FAD) e AG (Bailey) foram utilizados, já que trabalhos anteriores mostram que estas variáveis possuem maior relevância na caracterização da estrutura granulométrica (BASTOS *et al.*, 2016; FERREIRA *et al.*, 2020). Com relação às propriedades volumétricas da mistura asfáltica, foram utilizados o método de dosagem (m_d) e o teor de ligante (L).

A literatura também apresenta como influentes no valor do FN diversos outros parâmetros, tais como: volume de vazios (V_v), tamanho máximo nominal (TMN) do agregado, vazios no agregado mineral (VAM), tensões de cisalhamento normal (p e q), porção elástica do módulo de cisalhamento ($\frac{G^*}{\sin(\delta)}$), porcentagem passante nas peneiras N° 4, N° 16 e N° 200, e forma 2D do agregado miúdo (KALOUSH *et al.*, 2003; KVASNAK *et al.*, 2007, RODEZNO *et al.*, 2010; APEAGYEI, 2014; BASTOS *et al.*, 2016), porém, como o objetivo geral deste trabalho é a proposição de modelos destinados a serem utilizados na fase de anteprojeto, optou-

se pela inclusão de uma pequena quantidade de variáveis explicativas, dando-se prioridade a parâmetros não volumétricos, os quais só são conhecidos após a etapa de dosagem.

3.2.2 Obtenção e avaliação dos modelos

Após a definição do conjunto de variáveis que exercem influência na deformação permanente, foram desenvolvidos modelos com diferentes graus de complexidade, pois conforme a Navalha de Ockham, “inutilmente se faz por mais o que se pode fazer por menos” (*frusta fit per plura quod poteste fieri per pauciora*) (BORGES e STREFLING, 2019), ou seja, diante de modelos com semelhantes capacidades preditivas e diferentes graus de complexidade, torna-se mais sensato adotar o menos complexo.

O conceito de complexidade aqui utilizado é semelhante ao desenvolvido para algoritmos, isto é, refere-se, em geral, aos requerimentos de recursos necessários para a resolução de um problema sob o ponto de vista computacional (LORETO, 2006). Para fins comparativos, o esforço computacional foi condensado no tempo necessário para obtenção dos modelos, dessa forma, o modelo cuja obtenção requer um tempo de execução maior, é mais complexo que um modelo cujo tempo para obtenção é menor.

Os tipos de modelo obtidos, bem como as respectivas ferramentas utilizadas, podem ser visualizados na Tabela 4.

Tabela 4 - Modelos obtidos e ferramentas utilizadas

Tipo de Modelo	Ferramenta utilizada
Modelo Linear (ML)	Excel®
Modelo Não Linear (MNL)	Minitab®
<i>Perceptron</i> Simples (PS)	Google Colaboratory
<i>Perceptron</i> Multicamadas (PMC)	

Fonte: Elaborada pelo autor.

O Google Colaboratory pode ser definido como um ambiente de programação Jupyter que permite que o usuário crie programas escritos em Python diretamente no navegador (HOMEM, 2020).

Também foram utilizadas para construir e realizar o processo de treinamento das RNAs as bibliotecas listadas na Tabela 5.

Tabela 5 - Bibliotecas utilizadas no desenvolvimento das Redes Neurais Artificiais

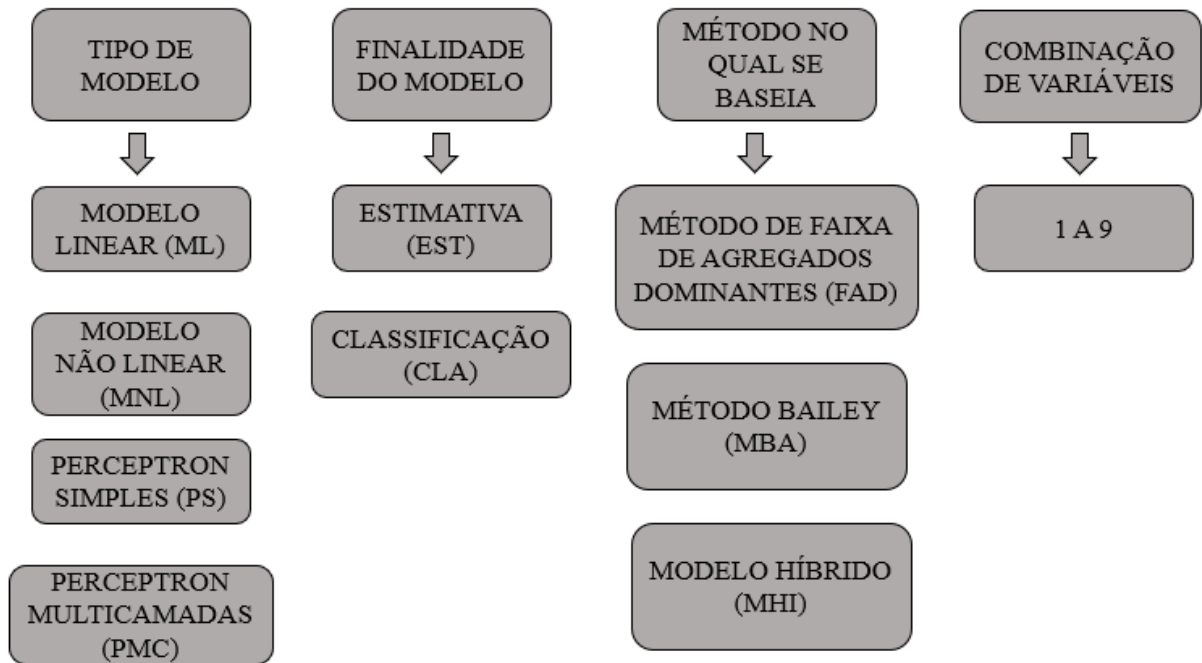
Biblioteca	Descrição
<i>TensorFlow</i>	Ferramenta de interface de desenvolvimento que tem como objetivo a elaboração e implementação de algoritmos de aprendizado de máquina, otimização e treinamento (ALMEIDA <i>et al.</i> , 2018);
<i>Keras</i>	Biblioteca de código aberto, para aplicação de redes neurais, desenvolvida em linguagem Python, com um conjunto de funções de alto nível trabalhando com recursos do <i>TensorFlow</i> e do Theano (ALMEIDA <i>et al.</i> , 2018);
<i>NumPy</i>	Biblioteca com estruturas de dados desenvolvidas para a computação eficiente de matrizes (ou <i>arrays</i>) numéricas destinadas a linguagem Python (ALMEIDA <i>et al.</i> , 2018);
<i>Pandas</i>	Ferramenta de análise e manipulação de dados de código aberto.

Fonte: Elaborada pelo autor.

Pontua-se que os modelos desenvolvidos em RNAs foram avaliados em duas diferentes propostas, a saber: (i) como um modelo de regressão, ou seja, de estimativa dos valores de FN; e (ii) como um modelo de classificação, isto é, de categorização das misturas asfálticas em função do FN considerando os níveis de tráfego propostos por Bastos *et al.* (2017).

Objetivando facilitar a compreensão, bem como as análises e discussões dos resultados, cada modelo foi designado conforme nomenclatura proposta na Figura 22. As combinações de variáveis utilizadas encontram-se na Tabela 6. Dessa forma, a título de exemplo, o modelo ML-EST-FAD-1 refere-se ao modelo linear baseado no método de Faixa de Agregados Dominantes e na combinação 1 de variáveis, tendo como objetivo a estimativa do valor do FN.

Figura 22 - Nomenclatura dos modelos



Fonte: Elaborada pelo autor.

Tabela 6 - Combinação de variáveis

Combinação	Variáveis	Método de origem
1	μ, L, α, C	
2	μ, α, C	FAD
3	$\mu, m_d, \alpha, C,$	
4	μ, L, AG, GAF, FAF	
5	μ, AG, GAF, FAF	MBA
6	μ, m_d, AG, GAF, FAF	
7	μ, L, α, AG	
8	μ, α, AG	MHI
9	μ, m_d, α, AG	

Fonte: Elaborada pelo autor.

Quanto às combinações da Tabela 6, nota-se que além de investigar qual metodologia de caracterização do esqueleto pétreo melhor descreve o fenômeno analisado, também buscou-se analisar se a presença do teor de ligante (L) nos modelos produziria mudanças significativas, uma vez que apenas esta variável não é conhecida na fase de anteprojeto.

Para comparar quantitativamente os modelos, foram utilizados o coeficiente de determinação (R^2) (Equação 18) e o Erro Absoluto Médio (EAM) (Equação 19), uma métrica comumente utilizada em processos de *machine learning*.

$$R^2 = 1 - \frac{SQE}{SQT} \quad (18)$$

$$EAM = \frac{1}{N} \sum_{i=1}^N |Y_i - Y_i'| \quad (19)$$

Onde:

SQE = soma dos quadrados dos erros;

SQT = soma total dos quadrados;

N = tamanho da amostra;

Y_i = i -ésimo valor de Y ;

Y_i' = valor estimado de Y .

Com as estimativas do FN obtidas através de cada modelo, foi verificado qual seria a classificação de cada mistura conforme os critérios estabelecidos por Bastos *et al.* (2017) (Tabela 7). Dessa forma, também foi utilizada para fins de comparação, a acurácia (Equação 20), uma métrica relacionada a problemas de classificação e que corresponde ao número de predições corretas dividido por todas as predições feitas (PEREIRA, 2018).

Tabela 7 - Critérios de FN para o nível de tráfego resistido

	Nível de Tráfego			
	Leve	Médio	Pesado	Extremamente Pesado
	$N < 3 \times 10^6$	$3 \times 10^6 < N < 1 \times 10^7$	$1 \times 10^7 < N < 3 \times 10^7$	$N > 3 \times 10^7$
Bastos <i>et al.</i> (2017)	$FN < 100$	$FN > 100$	$FN > 300$	$FN > 1000$

Fonte: Bastos *et al.*, 2017.

Obs.: N representa o número equivalente de operações do eixo padrão.

$$\text{Acurácia} = \frac{\text{Total de classificações corretas}}{\text{Total de classificações}} \quad (20)$$

A acurácia se baseia na Matriz de Confusão (MC), que consiste em uma tabela, ou matriz, na qual cada célula é uma quantificação do quão errado ou o quão certo um classificador está sob duas diferentes perspectivas: uma relacionada à classe positiva, e outra à classe negativa (BISHOP, 2006).

Na matriz de confusão, as linhas da matriz representam as predições de um determinado classificador, enquanto as colunas representam a verdadeira classe dos exemplos para os quais foram geradas as predições (DUDA *et al.*, 2000). O Quadro 1 exemplifica a matriz de confusão para os possíveis níveis de tráfego.

Quadro 1 - Matriz de confusão para as classes de tráfego

		Real			
		Leve	Médio	Pesado	Extr. Pesado
Estimado	Leve	Tráfego leve classificado corretamente	Tráfego médio classificado como leve	Tráfego pesado classificado como leve	Tráfego extr. Pesado classificado como leve
	Médio	Tráfego leve classificado como médio	Tráfego médio classificado corretamente	Tráfego pesado classificado como médio	Tráfego extr. Pesado classificado como médio
	Pesado	Tráfego leve classificado como pesado	Tráfego médio classificado como pesado	Tráfego pesado classificado corretamente	Tráfego extr. pesado classificado como pesado
	Extr. Pesado	Tráfego leve classificado como extr. pesado	Tráfego médio classificado como extr. pesado	Tráfego pesado classificado como ext. pesado	Tráfego extr. pesado classificado corretamente

Fonte: Elaborado pelo autor.

4 RESULTADOS E DISCUSSÕES

4.1 Modelos lineares


As equações obtidas para os modelos lineares, bem como os resultados para o EAM e R^2 , encontram-se respectivamente na Tabela 8 e nas Figuras 23 e 24. No apêndice A, encontram-se os valores estimados de FN. Visando investigar a influência dos parâmetros granulométricos nos modelos, também foi desenvolvido para fins de comparação um modelo dependente apenas de L e μ , o qual também consta na Tabela 8.

Tabela 8 - Equações dos modelos lineares

Modelo	Equação
ML-EST-FAD-1	$FN = 7179,70 - 2151,74L + 5,34\mu + 2949,98\alpha - 361,83C$
ML-EST-FAD-2	$FN = -207 + 5,13\mu - 4033,44\alpha + 78,94C$
ML-EST-MBA-4	$FN = 9196,57 - 2214,32L + 5,36\mu + 298,81AG + 1507,55GAF - 3880,29FAF$
ML-EST-MBA-5	$FN = -1331,97 + 4,98\mu - 255,52AG - 3695,23GAF + 3751,94FAF$
ML-EST-MHI-7	$FN = 6501,51 + 5,24\mu - 2069,36L + 198,72AG - 2548,32\alpha$
ML-EST-MHI-8	$FN = -113,42 + 5,15\mu - 48,17AG - 4004,88\alpha$
FN(L, μ)	$FN = 5582,15 - 1619,85L + 5,20\mu$


Fonte: Elaborada pelo autor.

Figura 23 - Erro Absoluto Médio dos modelos lineares



Fonte: Elaborada pelo autor.

Figura 24 - Coeficiente de determinação dos modelos lineares propostos e presentes na literatura



Fonte: Elaborada pelo autor.

Analisando os resultados, é possível notar que o EAM não apresentou variações significativas, porém o R^2 apresentou uma leve tendência em produzir melhores resultados quando o teor de ligante asfáltico (L) faz parte da Equação, como é o caso dos modelos ML-EST-FAD-1, ML-EST-MBA-4 e ML-EST-MHI-7. Tal observação pode ser explicada, em virtude do valor-p desta variável ser muito baixo em todos os modelos (Tabelas 9, 10 e 11), o

que indica que as alterações em seu valor, estão relacionadas as alterações na variável resposta (FN). Definindo-se a hipótese nula de nenhuma diferença estatística entre os grupos e a hipótese alternativa de uma diferença estatística (FERREIRA e PATINO, 2015), o valor-p é o menor nível de significância que conduz a rejeição da hipótese nula com os dados fornecidos

Tabela 9 - Valor-p para os modelos baseados no método FAD

Variável	Valor-p	
	ML-EST-FAD-1	ML-EST-FAD-1
L	0,0003	-
μ	0,0000	3,73E-08
α	0,1804	0,0362
C	0,3730	0,8780

Fonte: Elaborada pelo autor.

Tabela 10 - Valor-p para os modelos baseados no Método Bailey

Variável	Valor-p	
	ML-EST-MBA-4	ML-EST-MBA-5
L	0,0003	-
μ	0,0000	1,264E-07
AG	0,5324	0,6778
GAF	0,6150	0,3174
FAF	0,1436	0,1422

Fonte: Elaborada pelo autor.

Tabela 11 - Valor-p para os modelos baseados no Modelo Híbrido

Variável	Valor-p	
	ML-EST-MHI-7	ML-EST-MHI-8
L	0,0004	-
μ	2,192E-10	2,449E-08
α	0,2376	0,0371
AG	0,6264	0,9270

Fonte: Elaborada pelo autor.

Ao analisar as Tabelas 9, 10 e 11, também é possível observar que o valor-p para a viscosidade (μ) é o mais baixo em todos os casos, o que reitera o papel de destaque desse parâmetro na resistência ao acúmulo de deformações plásticas. Além disso, nota-se que os parâmetros relacionados ao esqueleto pétreo da mistura (α , C , AG , GAF , FAF) apresentam valor-p bastante elevados, muitas vezes, bem maiores que o valor convencionalmente aceito de 0,05.

Outro fato que corrobora a pequena influência das variáveis anteriormente mencionadas em modelos lineares é a diferença quase imperceptível (Figuras 23 e 24) entre estes e o modelo dependente apenas das variáveis L e μ . Um modelo dependente apenas de tais variáveis, no entanto, não faz sentido físico, visto que a mistura não é composta apenas por ligante asfáltico. Desse modo, tal modelo não possui uma aplicabilidade real.

Tanto os bons resultados obtidos para as variáveis L e μ , quanto os resultados ruins para as variáveis relacionadas ao esqueleto pétreo, são esperados, visto que alguns trabalhos já demonstraram a relação linear entre as primeiras e o FN (FERREIRA, 2017; ALMEIDA JR. *et al.*, 2018), ao contrário das últimas, que demonstram relação não linear com a variável resposta, como é o caso dos parâmetros α e C investigados por Ferreira (2017), sendo o primeiro representado por uma função exponencial decrescente (Figura 6a, pág. 26), e o segundo por uma parábola (Figura 6b, pág. 26)

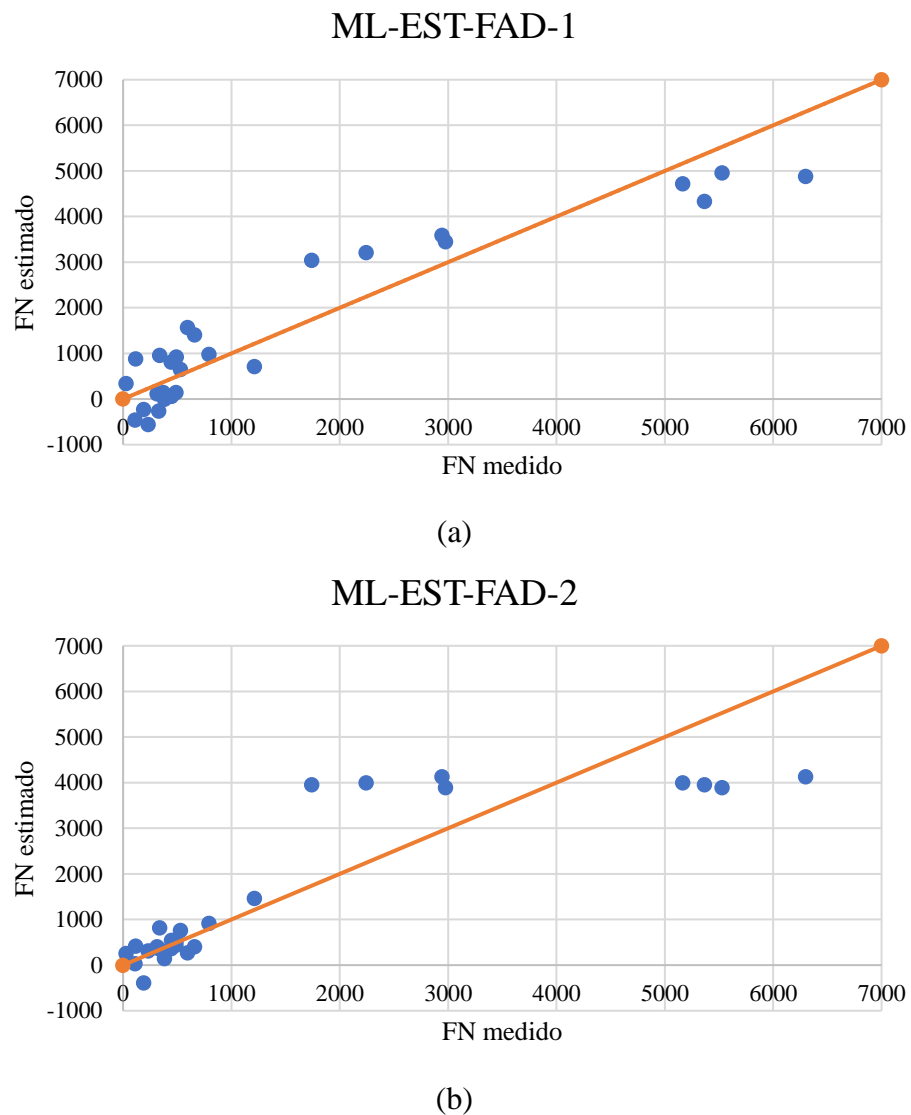
Diante dos resultados apresentados, não é possível inferir que os parâmetros provenientes dos métodos FAD e Bailey não são capazes de fornecer informações úteis ao fenômeno da deformação permanente, tornando-se possível concluir apenas, que modelos lineares não são capazes de captar a influência de tais parâmetros.

Na Figura 24, ao comparar o R^2 dos modelos desenvolvidos neste trabalho, com alguns outros presentes na literatura, nota-se que apenas o modelo desenvolvido por Apeageyi (2014) possui um resultado superior. Contudo, tal modelo utiliza uma grande quantidade de variáveis preditoras, além de ser proveniente de um banco de dados pequeno (13 misturas), fatos que podem ocasionar o sobreajuste do modelo às peculiaridades da amostra, justificando dessa forma o valor elevado para o R^2 .


Uma última observação acerca dos modelos apresentados neste tópico pode ser visualizada na Figura 25 que apresenta os FNs medidos *versus* estimados. Nesta Figura, nota-se que o FN tende a ser superestimado para valores menores que 4000, e a ser subestimado para valores acima deste, sendo estas características mais acentuadas nos modelos ML-EST-FAD-2, ML-EST-MBA-5 e ML-EST-MHI-7, justamente os modelos que não possuem o teor de ligante na Equação.

Estas observações reforçam a importância de considerar o teor de ligante, principalmente para misturas com valores elevados de FN. Tais características, também podem ser explicadas em função do número baixo de misturas com FN superiores a 4000 presentes no banco de dados, existindo apenas 4, sendo estas, as misturas M11, M12, M18 e M19, que possuem respectivamente valores de FN de 5367, 5528, 5165 e 6300.

Figura 25 - FNs medidos *versus* estimados para os modelos lineares

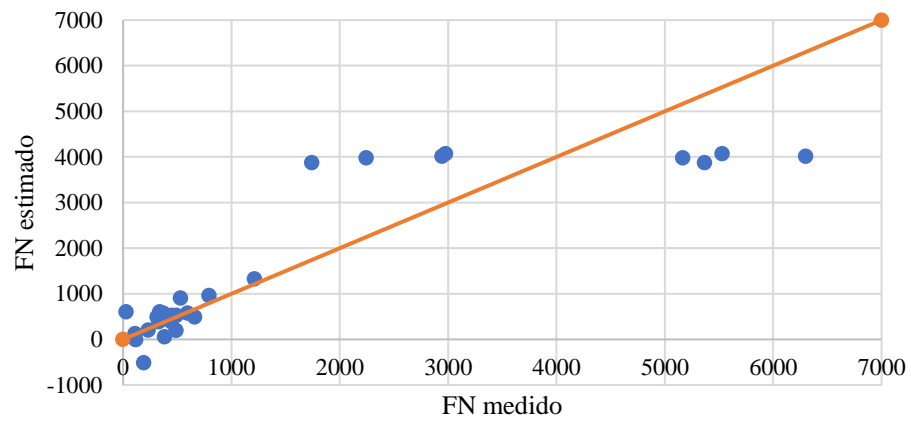


ML-EST-MBA-4




(c)

ML-EST-MBA-5

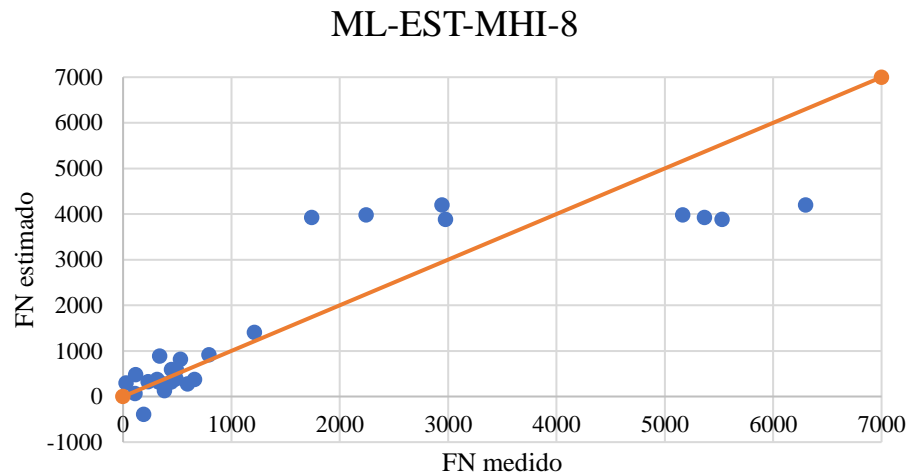


(d)

ML-EST-MHI-7



(e)



(f)

Fonte: Elaborada pelo autor.

4.2 Modelos não lineares

A Tabela 12 e Figuras 26 e 27 mostram respectivamente as equações não lineares obtidas por meio do software Minitab®, e os resultados para o EAM e R^2 . Os valores utilizados para o cálculo dos parâmetros mencionados encontram-se no apêndice C. Com o mesmo objetivo do item 4.2, foi desenvolvido o modelo $FN(L, \mu)$.

Tabela 12 - Equações dos modelos não lineares

Modelo	Equação
MNL-EST-FAD-1	$FN = -3449 + 574L + 32,69\mu - 22165\alpha + 767C - 6,254L \cdot \mu + 4391L \cdot \alpha - 0,984\mu \cdot C$
MNL-EST-FAD-2	$FN = -169 + 5,149\mu - 3966\alpha$
MNL-EST-MBA-4	$FN = 1507 + 1727L + 14,01\mu - 18409GAF - 2224FAF - 6,088L \cdot \mu + 35,47\mu \cdot GAF$
MNL-EST-MBA-5	$FN = -7454 + 5,225\mu + 20606FAF - 17509FAF^2$
MNL-EST-MHI-7	$FN = -3038 - 19181\alpha + 277AG + 486L + 31,18\mu + 3982\alpha \cdot L - 6,105L \cdot \mu$


continua

conclusão

MNL-EST-MHI-8	$FN = 1127 - 7745\alpha - 2081AG + 5,248\mu + 6130\alpha \cdot AG$
$FN(L, \mu)$	$FN = 4214 - 4228L + 30,17\mu + 679L^2 - 5,853L \cdot \mu$


Fonte: Elaborada pelo autor.

Figura 26 - Erro Absoluto Médio dos modelos não lineares propostos e da literatura



Fonte: Elaborada pelo autor.

Figura 27 – Coeficiente de determinação dos modelos não lineares



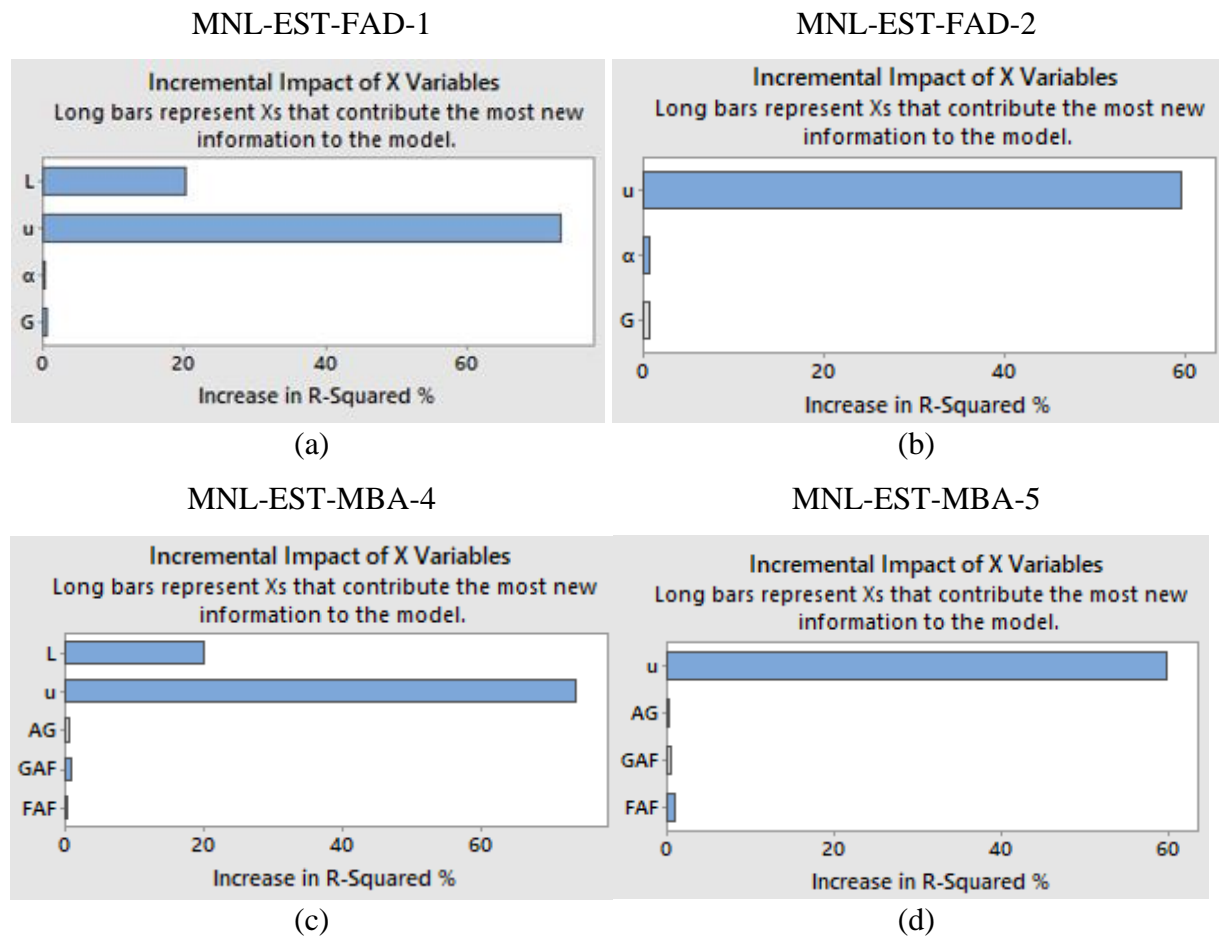
Fonte: Elaborada pelo autor.

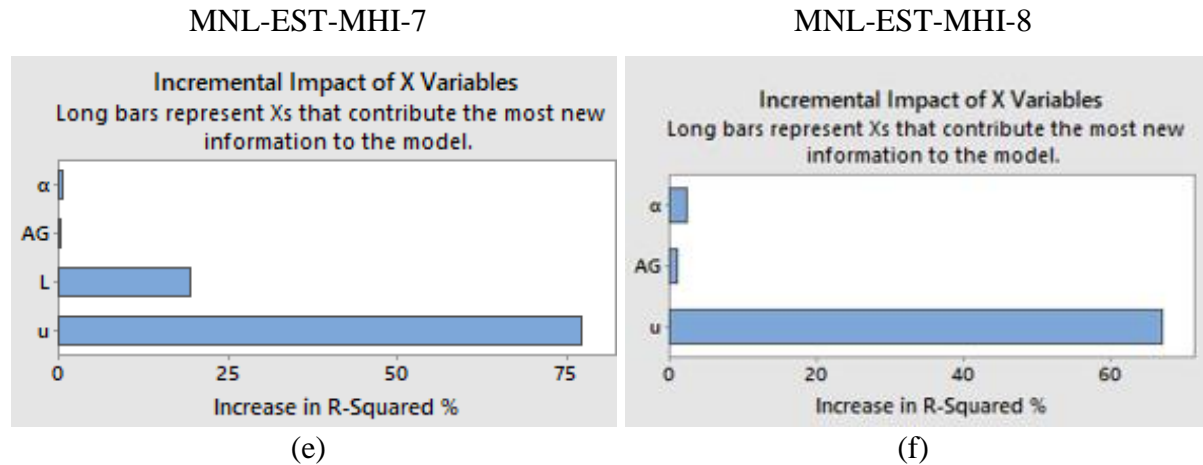
Ao analisar a Tabela 12, observa-se que as equações nem sempre incluem todas as variáveis contidas nas combinações especificadas na Tabela 6, como, por exemplo, o modelo

MNL-EST-MAD-2 que não inclui o parâmetro C , ou o modelo MNL-EST-MBA-5, que não inclui as variáveis AG e GAF.

O motivo da não inclusão de tais variáveis na Equação final pode ser explicado pela pequena contribuição para o aumento do R^2 , como pode ser visto na Figura 28.

Figura 28 - Contribuição individual de cada variável para os modelos não lineares





Fonte: Elaborada pelo autor.

Obs: Nas figuras acima, onde existe 'G' (nomenclatura original de Ferreira (2017)) leia-se 'C' (nomenclatura adotada em Ferreira *et al.* (2020))

As Figuras 27 e 28 comprovam os resultados obtidos no subitem 4.2, isto é, que o teor de ligante asfáltico tem um impacto significativo na capacidade explicativa dos modelos, observando-se inclusive diferenças notáveis no que se refere ao EAM, chegando a provocar reduções de até 71% em seu valor. Um exemplo desta redução pode ser observado nos modelos derivados do método FAD (MNL-EST-FAD-1 e MNL-EST-FAD-2), onde o EAM caiu de 603,89 para 174,44, fato que se reflete nos excelentes resultados obtidos para o R^2 .

Também de acordo com o tópico anterior, nota-se que o método utilizado pelo *software* Minitab® não é capaz de evidenciar a influência dos parâmetros referentes aos agregados, visto que, como já mencionado, não se diferencia fundamentalmente de uma regressão linear múltipla. Dessa forma, percebe-se – assim como nos modelos lineares –, que um modelo proveniente da metodologia mencionada, pode apresentar bons resultados utilizando-se como variáveis preditoras apenas μ e L , apesar de não fazer sentido físico.

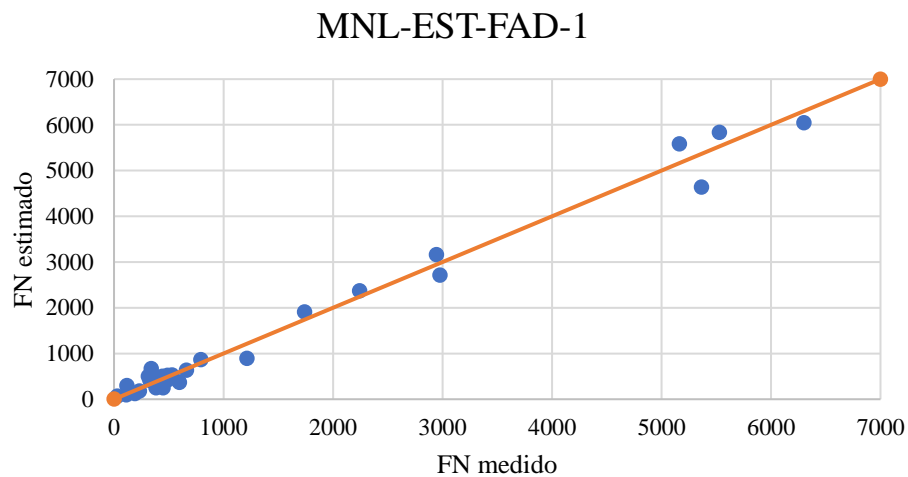
Ao comparar os resultados obtidos por outros trabalhos, notam-se pequenas diferenças, tanto em relação ao EAM, quanto em relação ao R^2 . Contudo, o modelo desenvolvido por Bastos *et al.* (2016) é proveniente de um banco de dados menor, contendo apenas 6 misturas, tornando-se razoável admitir, que os modelos apresentados na Tabela 12, possuem uma melhor capacidade de generalização.

Ainda sobre o modelo proposto por Bastos *et al.* (2016), nota-se que todas as suas variáveis preditoras (Equação 15) estão associadas aos agregados, sendo estas, a proporção AG e a forma 2D do agregado miúdo. Essa observação corrobora a capacidade explicativa de parâmetros associados aos agregados, a depender, porém, da forma como estas estão associadas ao FN.

Ao confrontar os modelos propostos neste trabalho e o desenvolvido por Ferreira (2017) (Equações 16 e 17), já que ambos foram desenvolvidos com base no mesmo banco de dados, notam-se melhorias ínfimas dos primeiros com relação ao último, tendo estes, porém, a vantagem de ser um pouco menos rebuscados, o que facilitaria, por exemplo, a aplicação de métodos de otimização dos componentes da mistura, tais como as metaheurísticas *Greedy Randomized Adaptive Search Procedure* (GRASP) e Busca Tabu.

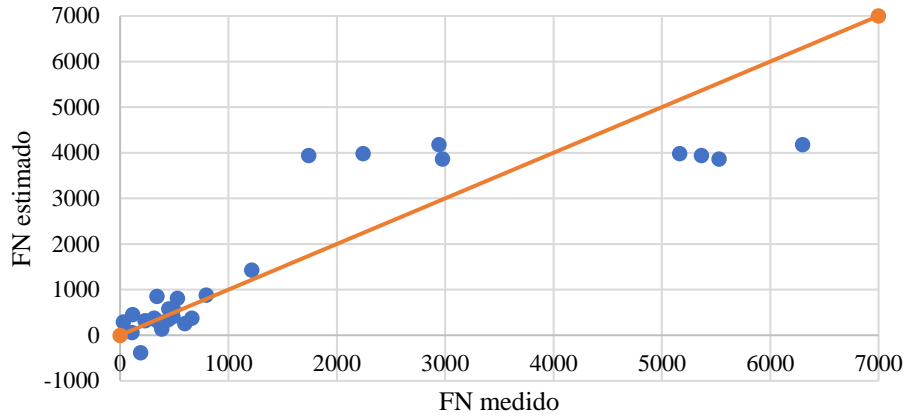
Cabe ainda acrescentar, que os modelos não lineares dependentes de L (MNL-EST-MAD-1, MNL-EST-MBA-4 e MNL-EST-MHI-7) apresentaram resultados bem superiores aos modelos lineares no que se refere à tendência em subestimar ou superestimar os valores de FN, como pode ser observado na Figura 29.

Figura 29- FNs medidos *versus* estimados dos modelos não lineares




(a)

MNL-EST-FAD-2




(b)

MNL-EST-MBA-4




(c)


MNL-EST-MBA-5



(d)



(e)



(f)

Fonte: Elaborada pelo autor.

4.3 Redes Neurais Artificiais

Conforme mencionado no subitem 3.2.2, as RNAs desenvolvidas no presente trabalho podem ser classificadas em dois tipos, onde as primeiras tinham por objetivo uma estimativa do valor do FN, e as últimas, apenas a classificação do tráfego resistido.

Para as RNAs do primeiro tipo, foram testados o PS e o PMC, onde o primeiro possui apenas um único neurônio e o segundo possui uma camada oculta com $n - 1$ neurônios

que a camada de entrada. Os hiperparâmetros utilizados nas duas topologias mencionadas estão apresentados nas Tabelas 13 e 14.

Tabela 13 - Hiperparâmetros utilizados no *Perceptron* simples

Hiperparâmetro	Descrição	Opção utilizada
kernel_initializer	Forma de inicialização dos pesos	randon_uniform
activation	Função de ativação dos neurônios	linear
loss	Função de perda	mean_absolute_error
optimizer	Forma de ajuste dos pesos	adam
epochs	Número de épocas que será realizado o treinamento	2000

Fonte: Elaborada pelo autor.


Tabela 14 - Hiperparâmetros utilizados no *Perceptron* Multicamadas

Hiperparâmetro	Descrição	Opção utilizada
kernel_initializer	Forma de inicialização dos pesos	randon_uniform
activation (camadas de entrada e oculta)	Função de ativação dos neurônios	relu
activation (camada de saída)	Função de ativação dos neurônios	linear
loss	Função de perda	mean_absolute_error
optimizer	Forma de ajuste dos pesos	adam
epochs	Número de épocas que será realizado o treinamento	2000

Fonte: Elaborada pelo autor.


As Figuras 30 e 31 mostram, nesta ordem, o Erro Absoluto Médio e o coeficiente de determinação para os *Perceptrons* simples e multicamadas. Os dados referentes a estes modelos encontram-se nos apêndices E e G, respectivamente.

Figura 30 - Erro absoluto médio das RNA de estimativa do FN



Fonte: Elabora pelo autor.

Figura 31 - Coeficiente de determinação das RNA de estimativa do FN

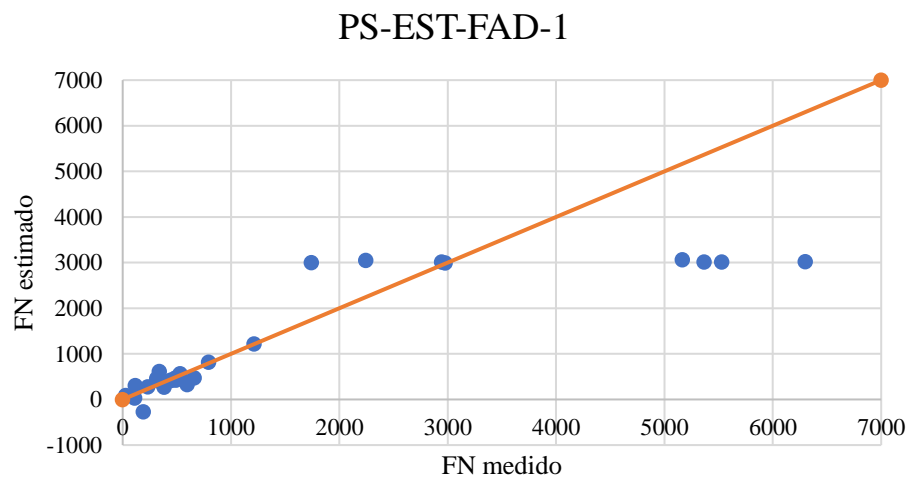


Fonte: Elabora pelo autor.

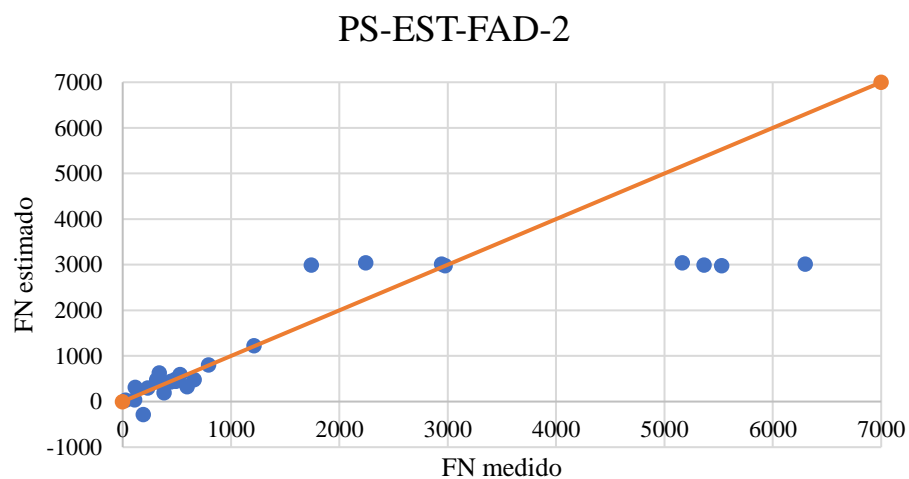
Analisando as Figuras 30 e 31, nota-se que as diferenças com relação ao EAM e R^2 foram mínimas, dessa forma, é possível inferir que a adição de uma camada oculta não proporciona grandes melhorias, resultando apenas em um esforço computacional maior, como pode ser visualizado na Figura 41. Este fato pode ser explicado em decorrência da utilização dos mesmos hiperparâmetros para função de perda e ajuste de pesos, visto que, o conjunto de dados de entrada era o mesmo.

Observando a Figura 32, que mostra os FNs medidos *versus* estimados para o PS, nota-se que a tendência em subestimar ou superestimar os valores de FN para valores menores e maiores que 4000 respectivamente, observada nos modelos lineares e em alguns modelos não lineares (MNL-EST-MAD-2, MNL-EST-MBA-5 e MNL-EST-MHI-8), torna-se ainda mais acentuada, percebendo-se inclusive, uma estabilização em valores próximos a 3000 para misturas cujo FN medido foi maior que 1500.

Figura 32 - FNs medidos *versus* estimados do Perceptron Simples




(a)




(b)

PS-EST-MBA-4




(c)

PS-EST-MBA-5

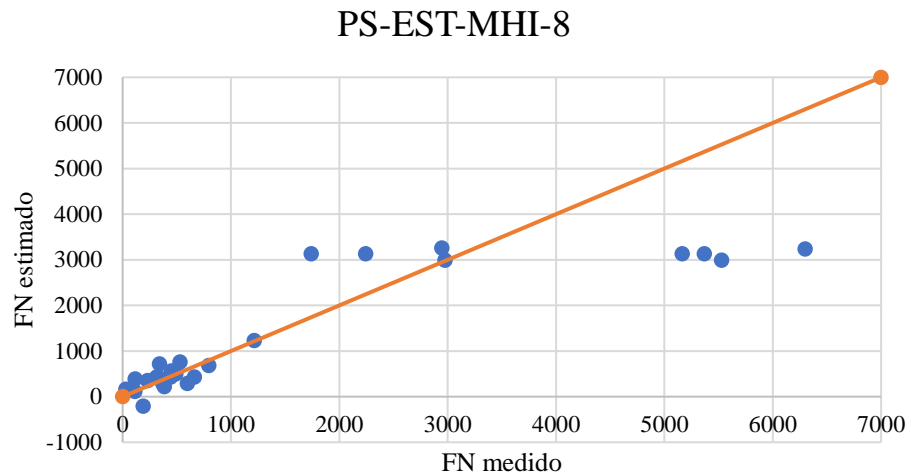


(d)

PS-EST-MHI-7



(e)



(f)

Fonte: Elaborada pelo autor.

Diante do exposto, constata-se que do ponto de vista numérico, a utilização de RNAs não se justifica, dado que, é necessário um esforço computacional bem maior que os métodos apresentados anteriormente, tendo estes últimos, resultados tão bons ou até mesmo melhores que esta metodologia.

Por último, buscando analisar a capacidade de generalização da RNA que obteve o menor EAM (PS-EST-FAD-1), foram analisadas as previsões de FN para as misturas presentes no trabalho de Possebon (2018), verificando-se também a classificação associada a estas previsões. Os valores de FN estimados e suas respectivas classificações encontram-se na Tabela 15.

Tabela 15 - Dados das misturas analisadas por Possebon (2018) e FN e nível de tráfego medidos e estimados pelo PS-EST-FAD-1

Mistura	Teor (%)	μ (cP)	α	C	FN medido	Classe (FN medido)	FN estimado	Classe (FN estimado)
30/45 REGAP	5,47	430	0,24	0,30	214	Médio	148,86	Médio
50/70 LUBNOR	5,42	369	0,24	0,30	128	Médio	126,35	Médio

continua

conclusão

50/70 REFAP	5,72	300	0,24	0,30	176	Médio	100,14	Médio
50/70 REGAP	5,55	315	0,24	0,30	132	Médio	106,06	Médio
50/70 REPAR	5,85	314	0,24	0,30	70	Leve	105,06	Médio
50/70 REVAP	5,66	392	0,24	0,30	165	Médio	134,37	Médio

Fonte: Elaborada pelo autor.

Examinando os resultados da Tabela 15, percebe-se que 5 das 6 misturas tiveram o nível de tráfego classificado corretamente, o que resulta em uma acurácia de 83%. Além disso, o EAM foi de 39,04, um valor bem menor que os obtidos na etapa de treinamento. Contudo, apesar dos resultados promissores, deve-se levar em consideração que todas as misturas analisadas por Possebon (2018) possuíam o mesmo esqueleto pétreo, como pode ser observado pelos parâmetros granulométricos α e C, desse modo, uma validação em uma base de dados mais diversificada torna-se necessária.

4.4 Classificação do nível de tráfego resistido

Como descrito em tópicos anteriores, além das classificações do nível de tráfego resistido com base no FN estimado através de cada modelo, também foi avaliado a capacidade das RNAs em realizar a classificação diretamente, isto é, sem passar pela etapa de estimativa do FN. Neste processo, analisou-se ainda, a possibilidade de substituição do L pela variável categórica método de dosagem (m_d), visto que esta afeta o teor de ligante de uma mistura asfáltica, e pode ser conhecida na fase de anteprojeto.

A influência do m_d no L , e, conseqüentemente no FN, podem ser observadas na Tabela 16 e Figura 33. Nestas, nota-se que a média do L é maior para o método Marshall do que para o método Superpave, ocorrendo o inverso no valor médio do FN. Tais observações permitem inferir que o método que produz valores menores para o L tende a produzir valores maiores para de FN. Esta análise pode ser considerada representativa para misturas asfálticas


de um modo geral, já que aproximadamente metade das misturas foi dosada utilizando-se cada um dos métodos, sendo: 13 – Marshall; e 14 – Superpave.

Tabela 16 - Valores médios de L e FN para os métodos Marshall e Superpave

Método	Média	
	L (%)	FN
Marshall	4,63	970,54
Superpave	4,15	1981,64


Fonte: Elaborada pelo autor.

Figura 33 - Box-plot de L e FN para os métodos Marshall e Superpave



Fonte: Elaborada pelo autor.

Para corroborar a influência do método de dosagem no valor de L , também é possível mencionar o trabalho de Almeida Jr. *et al.* (2018), no qual foram dosadas 24 misturas asfálticas por ambos os métodos, verificando-se que todas as misturas Marshall apresentaram teores de ligante superior às misturas Superpave (ALMEIDA JR. *et al.*, 2018). A Figura 34 mostra os teores obtidos para as 24 misturas. Os hiperparâmetros utilizados nas RNAs de classificação encontram-se nas Tabelas 17 e 18.

Figura 34 - Teores de ligante obtidos por Almeida Jr. *et al.* (2018)

Fonte: Almeida Jr. *et al.*, 2018.

Tabela 17 - Hiperparâmetros utilizados nos *Perceptrons* simples de Classificação

Hiperparâmetro	Descrição	Opção utilizada
kernel_initializer	Forma de inicialização dos pesos	randon_uniform
activation	Função de ativação dos neurônios	softmax
loss	Função de perda	categorical_crossentropy
optimizer	Forma de ajuste dos pesos	adam
epochs	Número de épocas que será realizado o treinamento	2000

Fonte: Elaborado pelo autor.

Tabela 18 - Hiperparâmetros utilizados nos *Perceptrons* Multicamadas de Classificação


Hiperparâmetro	Descrição	Opção utilizada
kernel_initializer	Forma de inicialização dos pesos	randon_uniform
activation (camadas de entrada e oculta)	Função de ativação dos neurônios	relu
activation (camada de saída)	Função de ativação dos neurônios	softmax
loss	Função de perda	categorical_crossentropy
optimizer	Forma de ajuste dos pesos	adam
epochs	Número de épocas que será realizado o treinamento	2000

Fonte: Elaborado pelo autor.

As acurácias obtidas pelos PS e PMC de classificação para todas as combinações de variáveis, podem ser visualizadas na Figura 35. Nesta Figura, nota-se que os PS fornecem resultados melhores e mais constantes que os PMC, indicando que a adição de uma camada oculta, além de não contribuir para a melhoria dos resultados, pode reduzir a acurácia drasticamente, fato que pode ser observado nas combinações 1, 5, 7 e 8, onde em todos os casos, todas as misturas tiveram o nível de tráfego resistido classificado como extremamente pesado. Os resultados destes modelos podem ser consultados nos apêndices I, J, K e L.

As combinações 3, 6 e 9 utilizam a variável categórica m_d como parâmetros de entrada, ou seja, o método de dosagem foi transformado em uma variável *dummy*, onde (1,0) representa o método Marshall e (0,1) representa o método Superpave. Nas três combinações mencionadas, foram observadas acurácias próximas de 1, tanto para o PS quanto para o PMC, indicando que o m_d é um bom atributo previsor.

Figura 35 - Acurácias obtidas pelos PS e PMC de classificação




Fonte: Elaborada pelo autor.

Os resultados elevados para a acurácia obtidos pelos PS, contudo, devem ser encarados com cautela, visto que pode ter ocorrido um processo conhecido por *overfitting* ou memorização excessiva, onde a RNA decora as suas respostas frente aos estímulos introduzidos em suas entradas (SILVA *et al.*, 2016). Diante disso, como o banco de dados é pequeno e não foi dividido em subconjuntos de treinamento e teste, torna-se incerta qualquer afirmação no que diz respeito à capacidade de generalização do conhecimento adquirido.

Para os PMC, nota-se uma tendência inversa à descrita anteriormente, ou seja, o *underfitting*, que é caracterizado por uma extração e armazenamento insuficiente das características do comportamento do processo analisado, configurando uma situação de debilidade neural (SILVA *et al.*, 2016).


Os resultados derivados das classificações realizados pelos modelos lineares, não lineares e PS e PMC de estimativa, podem ser visualizados nas Figuras 36, 37, 38 e 39, respectivamente, e examinados nos apêndices B, D, F e H.

Figura 36 - Acurácia dos modelos lineares




Fonte: Elaborada pelo autor.

Figura 37 - Acurácia dos modelos não lineares




Fonte: Elaborada pelo autor.

Figura 38 - Acurácia do *Perceptron* simples de estimativa do FN



Fonte: Elaborada pelo autor.

Figura 39 - Acurácia do *Perceptron* Multicamadas de estimativa do FN



Fonte: Elaborada pelo autor.

Na Figura 36 observa-se o inverso do que foi visto para o R^2 dos modelos lineares, tendo os modelos dependentes de L , acurácias menores do que os que não possuem esta variável. Já para os modelos não lineares (Figura 37), a tendência em produzir bons resultados permanece a mesma, destacando-se os resultados dos modelos derivados do método Bailey, que obtiveram acurácias de 89%, resultados melhores inclusive, que o modelo proposto por Ferreira (2020), que obteve uma acurácia de 85%.

Para os PS, nota-se que apesar de não conseguirem estimar com precisão valores de FN maiores que 1500 (como pode ser observado na Figura 32), ainda assim, proporcionam um elevado grau de acerto com relação ao nível de tráfego resistido, visto que, todos os valores maiores que 1000 são considerados como resistentes ao tráfego extremamente pesado, e 9 das 27 misturas possuem essa classificação.

As matrizes de confusão dos melhores modelos referentes à classificação do nível de tráfego para cada metodologia testada podem ser visualizadas na Figura 40. Nas matrizes de confusão a diagonal principal representa os acertos de cada classe, logo, quanto mais classificações existirem fora desta, pior a capacidade de classificação do modelo.

Figura 40 - Matrizes de confusão dos melhores modelos

<p>ML-EST-MBA-5</p> $MC = \begin{bmatrix} 0 & 2 & 1 & 0 \\ 0 & 2 & 1 & 0 \\ 1 & 0 & 11 & 0 \\ 0 & 0 & 0 & 9 \end{bmatrix}$ <p>(a)</p>	<p>MNL-EST-MBA-4</p> $MC = \begin{bmatrix} 1 & 1 & 0 & 0 \\ 0 & 2 & 1 & 0 \\ 0 & 1 & 12 & 0 \\ 0 & 0 & 0 & 9 \end{bmatrix}$ <p>(b)</p>
<p>PS-EST-MBA-4</p> $MC = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 2 & 13 & 0 \\ 1 & 0 & 0 & 9 \end{bmatrix}$ <p>(c)</p>	<p>PMC-EST-MBA-5</p> $MC = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 4 & 3 & 0 \\ 0 & 0 & 10 & 0 \\ 0 & 0 & 0 & 9 \end{bmatrix}$ <p>(d)</p>
<p>PS-CLA-MBA-4</p> $MC = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 4 & 0 & 0 \\ 0 & 0 & 13 & 0 \\ 0 & 0 & 0 & 9 \end{bmatrix}$ <p>(e)</p>	<p>PMC-CLA-MBA-4</p> $MC = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 0 \\ 0 & 3 & 12 & 0 \\ 1 & 0 & 0 & 9 \end{bmatrix}$ <p>(f)</p>

Fonte: Elaborada pelo autor.

Na Figura 40, nota-se que todos os melhores modelos são baseados na metodologia Bailey, sendo apenas 2, referentes a combinação de variáveis 5, o que mais uma vez reforça o poder explicativo do teor de ligante asfáltico. Os modelos MNL-EST-MBA-4, PS-EST-MBA-4 e PMC-EST-MBA-5 obtiveram acurácias de 89%, porém, analisando a matriz de confusão nota-se que o PS-EST-MBA-4 classificou uma mistura de tráfego resistido leve como extremamente pesado, o que coloca em dúvida a capacidade de classificação quanto a essa categoria. Já com relação aos outros dois modelos, torna-se mais sensato optar pelo MNL-EST-

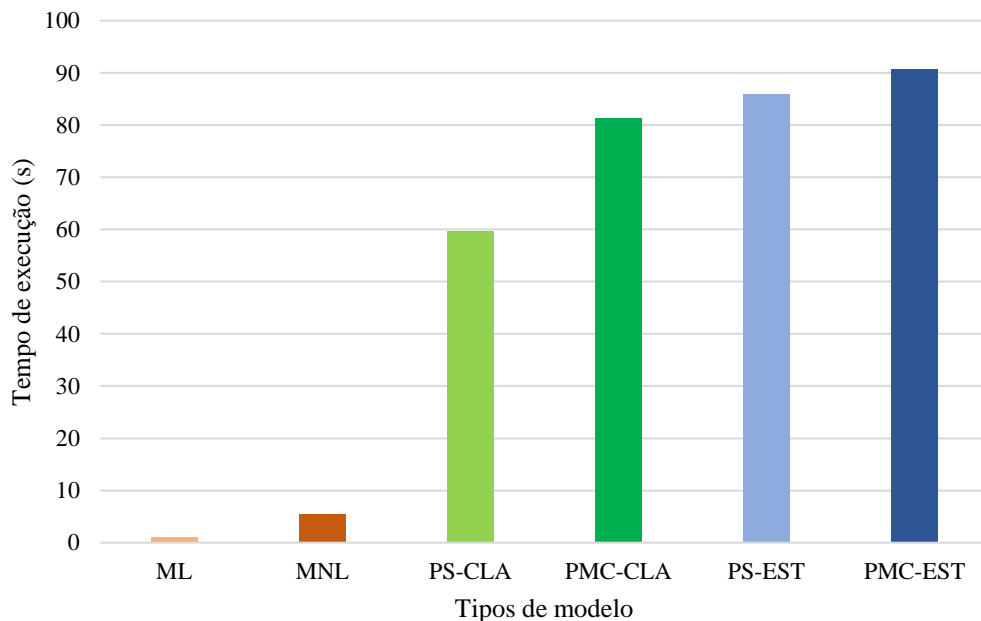
MBA-4, já que este possui o mesmo poder explicativo e uma complexidade menor, além de um EAM 71% mais baixo.

4.5 Complexidade dos modelos

Buscando orientar o desenvolvimento futuro de modelos mais precisos e provenientes de uma base de dados maior, foram testados modelos com diferentes graus de complexidade e obtidos por diferentes metodologias. Como já mencionado, como indicativo de complexidade, adotou-se o tempo de processamento para a obtenção dos modelos.

Na Figura 41 é possível observar o tempo médio de processamento para as diferentes metodologias utilizadas.

Figura 41 - Tempo médio de processamento para cada tipo de modelo



Fonte: Elaborada pelo autor.

Analisando o gráfico, nota-se que os modelos lineares e não lineares demandaram uma quantidade de tempo bem menor que os derivados de RNAs, tendo ambos, tempo de processamento inferior a 10 segundos. Tal fato pode ser explicado pela forma parecida como ambos os modelos são obtidos, visto que, apesar de fornecer modelos com relações não lineares entre as variáveis, a forma como o *software* Minitab® obtém tais modelos não difere

fundamentalmente de uma regressão linear múltipla, isto é, a Equação de regressão ainda é linear com relação aos coeficientes, ocorrendo apenas uma transformação das variáveis preditoras de forma que estas produzam curvatura.

Com relação às RNAs, observa-se um tempo de execução entre 1 minuto e 1 minuto e 30s, sendo estes resultados dependentes exclusivamente da quantidade de épocas pré-estabelecidas para o treinamento e ajuste dos pesos. Vale ressaltar, que em decorrência do elevado número de modelos testados, bem como do pequeno número de misturas no banco de dados, algumas etapas comuns no desenvolvimento de RNAs não foram executadas, sendo estas, a validação cruzada (CV – *Cross Validation*) e o *Tuning* ou ajuste dos hiperparâmetros, etapas estas que poderiam elevar ainda mais o tempo de processamento, podendo chegar até mesmo a horas.

O termo hiperparâmetro refere-se aos parâmetros das RNAs definidos antes do processo de aprendizagem, tais como: número de camadas ocultas, número de neurônios em cada camada, função de ativação, inicialização dos pesos sinápticos e configurações do otimizador.

Também deve ser levado em consideração, que o processo de dosagem e ensaio de misturas asfálticas é demorado, e por conta disso, não foi possível adicionar novas informações à base de dados utilizada.

A CV trata-se de um método extremamente recorrente no ramo da Ciência de Dados, sendo o *k-fold* um dos mais utilizados. Tal método consiste em repartir os dados em K conjuntos de tamanho aproximados, dessa forma, um conjunto é usado para testes e os outros $K - 1$ conjuntos, são usados para estimação dos parâmetros e cálculo do erro (BERTOLETTI *et al*, 2020). No presente trabalho, tanto o treinamento quanto os testes foram realizados em todo o banco de dados. Entretanto, apesar da validação cruzada não ter sido realizada para todas as RNAs, a capacidade de generalização do conhecimento adquirido no processo de treinamento foi testada no banco de dados presente no trabalho de Possebon (2018).

5 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

Este trabalho apresenta uma comparação entre diferentes modelos preditivos para o parâmetro FN, obtidos por metodologias distintas e utilizando diferentes combinações de variáveis. Também foram investigadas as contribuições da inclusão de variáveis granulométricas derivadas de diferentes metodologias de caracterização do esqueleto pétreo, sendo estas, FAD e Bailey.

No total foram avaliados 42 modelos com diferentes graus de complexidade, chegando-se à conclusão que modelos mais complexos como as Redes Neurais Artificiais, além de exigirem um esforço computacional bem maior, nem sempre produzem os melhores resultados, já que necessitam de uma grande quantidade de dados para que ocorra uma aprendizagem profunda e o número de informações referentes a ensaios uniaxiais de carga repetida realizados em misturas asfálticas nacionais é limitado. Assim sendo, deve-se analisar com cautela a real necessidade de utilização desse método.

Seguindo o objetivo de propor modelos úteis à fase de anteprojeto, foi investigado o potencial explicativo da variável categórica método de dosagem (m_d), obtendo-se resultados promissores para as RNAs de classificação do tipo *Perceptron* simples, fato que estimula uma investigação mais profunda dessa metodologia em uma base de dados mais extensa.

Verificou-se ainda, que as variáveis referentes à granulometria proporcionam melhorias ínfimas nos modelos analisados, o que não significa que não forneçam informações relevantes quanto à capacidade de resistência ao acúmulo de deformações permanentes. Desse modo, torna-se necessário não só a investigação de modelos dependentes de outras variáveis relacionadas aos agregados, como os parâmetros de forma, angularidade e textura, como também de modelos com diferentes relações funcionais com o FN, visto que os modelos investigados não são capazes de captar as contribuições destes parâmetros.

Dentre os modelos analisados, acredita-se que os não lineares oferecem a melhor relação custo-benefício no que se refere à dificuldade de obtenção e qualidade dos resultados, visto que, produziram um grau significativo de acerto nas classificações e os menores erros absolutos médios. Em contrapartida, entende-se que os modelos lineares não são indicados à estimativa do FN, apesar de extensamente utilizados na literatura.

Diante do exposto, acredita-se que foi possível nesta pesquisa, identificar por meio de consulta bibliográfica, as variáveis mais relevantes para estimação do FN, bem como, testar e discutir modelos derivados de diferentes metodologias e com diferentes variáveis predictoras,

o que de certa forma, dá embasamento e direciona o desenvolvimento de futuras pesquisas que visem a obtenção de modelos de estimativa para o FN.

Por fim, salienta-se que os modelos aqui apresentados devem ser utilizados com bom senso e cautela, visto que, não incluem uma série de possíveis variáveis potencialmente relevantes, como, por exemplo, a utilização de diferentes modificadores no ligante asfáltico.

5.1 Sugestões para trabalhos futuros

Apesar dos resultados promissores apresentados, ainda há um vasto espaço para a investigação de outros tipos de modelagem, além de modelos com diferentes variáveis explicativas. Ademais, o presente trabalho pode ser complementado de diversas formas. Isto posto, lista-se de modo sugestivo e não exaustivo, as seguintes propostas para trabalhos futuros:

- Investigar modelos dependentes dos parâmetros de forma, angularidade e textura dos agregados;
- Realizar a validação dos modelos desenvolvidos em uma base de dados maior e mais diversificada;
- Testar diferentes arquiteturas e topologias para as RNA, uma vez que não é possível afirmar categoricamente que as configurações utilizadas neste trabalho são as mais adequadas aos dados disponíveis;
- Investigar a utilização de metaheurísticas na otimização dos componentes de uma mistura asfáltica;
- Realizar uma análise de sensibilidade do FN com relação às variáveis componentes dos modelos propostos.

REFERÊNCIAS

- AASHTO M 323. *Standard specification for Superpave volumetric mix design*. American Association of State Highway and Transportation Officials (AASHTO), 2017.
- ALAVI, A. H. et al. Formulation of flow number of asphalt mixes using a hybrid computational method. **Construction and Building Materials**, v. 25, n. 3, p. 1338–1355, mar. 2011.
- ALMEIDA JR, P. O. et al. Avaliação laboratorial do tipo e teor de ligante e da granulometria na deformação permanente de misturas asfálticas. **Transportes**, v. 26, n. 2, p. 1–15, 31 ago. 2018.
- ALMEIDA, M. H. B. et al. Desempenho da técnica Deep Learning na análise e categorização de imagens de defeito de madeira. **Energia na agricultura**, v. 33, n. 3, p. 284–291, 14 dez. 2018.
- APEAGYEI, A. K. Flow number predictive models from volumetric and binder properties. **Construction and Building Materials**, v. 64, p. 240–245, ago. 2014.
- AZEVEDO, L. P. **Aplicação de redes neurais artificiais no processo de classificação de orquídeas do gênero Cattleya**. Monografia (Bacharelado em Sistemas de Informação)—Sabará: Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais, 2016.
- BARBOZA JR., V. DOS S. et al. Influência da temperatura na deformação permanente de misturas asfálticas considerando o parâmetro Flow Number. 2019.
- BASTOS, J. B. DOS S. et al. Triaxial stress sweep test protocol considerations for permanent deformation characterisation of asphalt mixtures. **Road Materials and Pavement Design**, v. 19, n. 2, p. 431–444, 17 fev. 2018.
- BASTOS, J. B. DOS S.; FERREIRA, J. L. S.; SOARES, J. B. Relação entre parâmetros granulométricos e características de forma na resistência à deformação permanente de misturas asfálticas. 2016.
- BASTOS, J. B. DOS S.; SOARES, J. B.; NASCIMENTO, L. A. H. Critérios para os resultados do ensaio uniaxial de carga repetida de misturas asfálticas em laboratório a partir do desempenho em campo. **Transportes**, v. 25, n. 2, p. 19, 31 ago. 2017.
- BERNUCCI, L. B. et al. **Pavimentação Asfáltica: Formação Básica para engenheiros**. Rio de Janeiro: ABEDA, 2010.
- BERTOLETTI, A. Z.; MORAIS, A. P. DE; CARDOSO JR., G. Técnica de Validação Cruzada para Qualificação do Ajuste das Curvas Tempo versus Corrente dos Elos Fusíveis do Tipo Expulsão. p. 6, 2020.
- BISHOP, C. M. **Pattern recognition and machine learning**. New York: Springer, 2006.
- BONABEAU, E.; DORIGO, M.; THERAULAZ, G. **Swarm Intelligence: From Natural to Artificial Systems**. New York: Oxford University Press, 1999.

BORGES, R. L. **Deformação permanente em misturas asfálticas a partir do Shift Model viscoplástico e ensaios triaxiais de carga repetida**. Dissertação (Mestrado em Engenharia de Transportes)—Fortaleza: Universidade Federal do Ceará, 2014.

BORGES, W. S.; STREFLING, S. R. A navalha de Ockham: Função lógica e critérios de aplicação. p. 4, 2019.

BROWN, E. R.; KANDHAL, P. S.; ZHANG, J. PERFORMANCE TESTING FOR HOT MIX ASPHALT. 2001.

CHOI, Y.-T. **Development of a Mechanistic Prediction Model and Test Protocol for the Permanent Deformation of Asphalt Concrete**. Dissertation (Doctor of Philosophy)—North Carolina: North Carolina State University, 2013.

CHOI, Y.-T.; KIM, Y. R. Development of Calibration Testing Protocol for Permanent Deformation Model of Asphalt Concrete, 2013.

DIÓGENES, L. M. **Avaliação das relações entre propriedades de agregados minerais com base nas caracterizações do processo de britagem e da rocha de origem**. Dissertação (Mestrado em Engenharia de Transportes)—Fortaleza: Universidade Federal do Ceará, 2018.

DONGRÉ, R.; D'ANGELO, J.; COPELAND, A. Refinement of Flow Number as Determined by Asphalt Mixture Performance Tester: Use in Routine Quality Control—Quality Assurance Practice. **Transportation Research Record: Journal of the Transportation Research Board**, v. 2127, n. 1, p. 127–136, jan. 2009.

DNIT 031. *Pavimentos flexíveis - Concreto asfáltico - Especificação de serviço*. Departamento Nacional de Infraestrutura de Transportes, DNIT, 2006.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2. ed. New York: [s.n.]. FERREIRA, J. C.; PATINO, C. M. What does the p value really mean? **Jornal Brasileiro de Pneumologia**, v. 41, n. 5, p. 485–485, out. 2015.

FERREIRA, J. L. S. **Novas diretrizes para a seleção granulométrica de misturas asfálticas densas com foco na deformação permanente**. Dissertação (Mestrado em Engenharia de Transportes)—Fortaleza: Universidade Federal do Ceará, 2017.

FERREIRA, J. L. S. et al. A tool to design rutting resistant asphalt mixes through aggregate gradation selection. **Construction and Building Materials**, v. 236, p. 117531, mar. 2020.

FERREIRA, J. L. S.; BASTOS, J. B. DOS S.; SOARES, J. B. Validação da metodologia de faixa de agregados dominantes para avaliação e especificação da granulometria de misturas asfálticas densas. p. 12, 2015.

FERREIRA, J. L. S.; SOARES, J. B.; BASTOS, J. B. DOS S. Métodos de seleção granulométrica com foco na resistência à deformação permanente. **Transportes**, v. 24, n. 2, p. 46, 12 set. 2016.

FRANCO, F. A. C. DE PROENÇA; MOTTA, L. M. G. DA. **Programas MeDiNa, AEMC e BackMedina**. [s.l: s.n.].

GALAR, M. et al. An overview of ensemble methods for binary classifiers in multi-class problems: Experimental study on one-vs-one and one-vs-all schemes. **Pattern Recognition**, v. 44, n. 8, p. 1761–1776, ago. 2011.

GANDOMI, A. H. et al. Nonlinear Genetic-Based Models for Prediction of Flow Number of Asphalt Mixtures. **Journal of Materials in Civil Engineering**, v. 23, n. 3, p. 248–263, mar. 2011.

GOUVEIA, B. C. S. et al. Previsão do módulo dinâmico de misturas asfálticas brasileiras. **Transportes**, v. 26, n. 4, p. 16–29, 28 dez. 2018.

HAYKIN, S. **Redes Neurais: Princípios e prática**. 2. ed. Ontário, Canadá: ARTMED, 2008.

HIBBELER, R. C. **Resistência dos materiais**. 7. ed. São Paulo: Pearson Education, 2009.

HOMEM, W. L. **Apostila de Machine Learning**. Vitória: [s.n.].

KALOUSH, K. E.; WITCZAK, M. W.; SULLIVAN, B. W. **Simple performance test for permanent deformation evaluation of asphalt mixtures**. Sixth International RILEM Symposium on Performance Testing and Evaluation of Bituminous Materials. **Anais...** In: SIXTH INTERNATIONAL RILEM SYMPOSIUM ON PERFORMANCE TESTING AND EVALUATION OF BITUMINOUS MATERIALS. Zurich, Switzerland: RILEM Publications SARL, 2003 Disponível em: <<https://www.rilem.net/boutique/fiche.php?cat=conference&reference=pro028-062>>. Acesso em: 9 maio. 2021

KIM, S. *Identification and assessment of the Dominant Aggregate Size Range (DASR) of asphalt mixture*. 2006. PhD Dissertation – University of Florida, Gainesville, 2006.

LIN, S.-W.; YU, V. F. A simulated annealing heuristic for the team orienteering problem with time windows. **European Journal of Operational Research**, v. 217, n. 1, p. 94–107, fev. 2012.

LORETO, A. B. Análise da Complexidade Computacional de Problemas de Estatística Descritiva com Entradas Intervalares. p. 93, [s.d.].

MASAD, E. et al. Internal Structure Characterization of Asphalt Concrete Using Image Analysis. **Journal of Computing in Civil Engineering**, v. 13, n. 2, p. 88–95, abr. 1999.

MCCULLOCH, W. S.; PITTS, W. A Logical calculus of the ideas immanent in nervous activity. p. 17, 1943.

MENDES, L. D. O.; MARQUES, G. L. DE O. Avaliação da influência do método Bailey no processo de dosagem e desempenho de misturas asfálticas. **Transportes**, v. 20, n. 4, p. 35–43, 27 dez. 2012.

MIRZAHOSSEINI, M. et al. Next-Generation Models for Evaluation of the Flow Number of Asphalt Mixtures. **International Journal of Geomechanics**, v. 15, n. 6, p. 04015009, dez. 2015.

MOGHADDAM, T. B. et al. Estimation of the rutting performance of Polyethylene Terephthalate modified asphalt mixtures by adaptive neuro-fuzzy methodology. **Construction and Building Materials**, v. 96, p. 550–555, out. 2015.

MOMM, Leto; DOMINGUES, Felipe Augusto Aranha. **Estudo dos efeitos da granulometria sobre a macrot textura superficial do concreto asfáltico e seu comportamento mecânico**. 1998. Universidade de São Paulo, São Paulo, 1998.

MOREIRA, C. Neurônio. **Revista de ciência elementar**, v. 1, 2013.

NASCIMENTO, F. P. DO. Classificação da Pesquisa. Natureza, método ou abordagem metodológica, objetivos e procedimentos. In: **Metodologia da Pesquisa Científica: teoria e prática – como elaborar TCC**. Brasília: Thesaurus, 2016.

NASCIMENTO, F. A. C.; GUIMARÃES, A. C. R.; CARNEIRO, L. A. V. Análise da influência das propriedades do ligante asfáltico e do esqueleto pétreo na deformação permanente de misturas asfálticas. p. 18, 2015.

NASCIMENTO, L. A. H. **Nova abordagem da dosagem de misturas asfálticas densas com uso do compactador giratório e foco na deformação permanente**. Dissertação (Mestrado em Engenharia Civil)—Rio de Janeiro: Universidade Federal do Rio de Janeiro, 2008.

NIJBOER, L. W. *Plasticity as a Factor in the Design of Dense Bituminous Road Carpets*. Elsevier, 1948.

NORMA DNIT 184/2018. *Pavimentação – Misturas asfálticas – Ensaio uniaxial de carga repetida para determinação da resistência à deformação permanente – Método de ensaio*. Departamento Nacional de Infraestrutura de Transportes, DNIT, 2006.

OLIVEIRA, I. R. et al. **Dispersão e empacotamento de partículas – princípios e aplicações em processamento cerâmico**. São Paulo: Fazendo Arte, 2000.

ONOFRE, F. C. **Avaliação do comportamento mecânico de misturas asfálticas produzidas com ligantes asfálticos modificados por ácido polifosfórico e aditivos poliméricos, enfatizando a resistência à deformação permanente**. Dissertação (Mestrado em Engenharia de Transportes)—Fortaleza: Universidade Federal do Ceará, 2012.

PEREIRA, C. R. **Árvores de Decomposição Binária: Um novo esquema para a classificação de múltiplas classes**. Trabalho de Conclusão de Curso—Recife: Universidade Federal de Pernambuco, 2018.

Pesquisa CNT de rodovias 2019. . Brasília: CNT : SEST SENAT, 2019.

PINA, D. B. et al. Análise de Hiperparâmetros em Aplicações de Aprendizado Profundo por meio de Dados de Proveniência. p. 6, [s.d.].

POSSEBON, E. P. **Estudo Laboratorial das propriedades mecânicas de misturas com diferentes cimentos asfálticos de petróleo produzidos no Brasil**. Dissertação de mestrado—Santa Maria, RS: Universidade Federal de Santa Maria, 2018.

POURTAHMASB, M. S.; KARIM, M. R.; SHAMSHIRBAND, S. Resilient modulus prediction of asphalt mixtures containing Recycled Concrete Aggregate using an adaptive neuro-fuzzy methodology. **Construction and Building Materials**, v. 82, p. 257–263, maio 2015.

RAUBER, T. W. Redes neurais artificiais. 2014.

RODEZNO, M. C.; KALOUSH, K. E.; CORRIGAN, M. R. Development of a Flow Number Predictive Model. **Transportation Research Record: Journal of the Transportation Research Board**, v. 2181, n. 1, p. 79–87, jan. 2010.

RODRIGUES, A. L. N.; SOARES, F. L.; SOARES, J. B. Influência da forma e dos parâmetros granulométricos no resultado de flow number. p. 12, 2019.

ROSSI, B. F.; FAXINA, A. L. Caracterização reológica de ligantes asfálticos recuperados. p. 11, 2018.

SANTANA, A. F. **Treinamento de redes neurais artificiais utilizando algoritmo genético em plataforma distribuída**. Monografia (Bacharelado em Sistemas de Informação)—Lavras - MG: Universidade Federal de Lavras, 2012.

SEBAALY, H.; VARMA, S.; MAINA, J. W. Optimizing asphalt mix design process using artificial neural network and genetic algorithm. **Construction and Building Materials**, v. 168, p. 660–670, abr. 2018.

SILVA, A. S.; GHISI, E. Análise de sensibilidade global dos parâmetros termofísicos de uma edificação residencial de acordo com o método de simulação do RTQ-R. **Ambiente Construído**, v. 13, n. 4, p. 135–148, dez. 2013.

SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. 2. ed. São Paulo: Artiliber, 2016.

SILVA, I. DE S.; SPRITZER, I. M. P. A.; OLIVEIRA, W. P. A importância da Inteligência Artificial e dos Sistemas Especialistas. p. 12, 2004.

SPECHT, L. P. et al. Application of the theory of viscoelasticity to evaluate the resilient modulus test in asphalt mixes. **Construction and Building Materials**, v. 149, p. 648–658, set. 2017.

TISSOT, H. C.; CAMARGO, L. C.; POZO, A. T. R. Treinamento de Redes Neurais Feedforward: comparativo dos algoritmos Backpropagation e Differential Evolution. p. 13, 2012.

VAVRIK, W. R. **Asphalt mixture design concepts to develop aggregate interlock**. Dissertation (Doctor of Philosophy)—Illinois: University of Illinois, 2000.

WITZCAK, M. W. et al. (EDS.). **Simple performance test for Superpave mix design**. Washington, D.C: National Academy Press, 2002.

YILDIRIM, Y. Polymer modified asphalt binders. **Construction and Building Materials**, v. 21, n. 1, p. 66–72, jan. 2007.

ZHU, H.; NODES, J. E. Contact based analysis of asphalt pavement with the effect of aggregate angularity. **Mechanics of Materials**, p. 10, 2000.

ZHU, H. Contact Mechanism Based Asphalt Concrete Modeling. *In*: 12th ASCE ENGINEERING MECHANICS CONFERENCE, San Diego, California, 1998.

ZHU, H.; DASS, W. C. *Modeling of asphalt concrete*. Applied Research Associates, 1996.

APÊNDICE A – FN ESTIMADO PELOS MODELOS LINEARES

ID	FN medido	ML-EST-FAD-1	ML-EST-FAD-2	ML-EST-MBA-4	ML-EST-MBA-5	ML-EST-MHI-7	ML-EST-MHI-8
M1	30	342	261	202	607	195	294
M2	232	-559	312	-462	204	-589	327
M3	191	-226	-389	-74	-509	-229	-390
M4	531	649	766	307	906	443	815
M5	444	811	365	974	389	999	317
M6	597	1566	273	1398	581	1518	273
M7	662	1409	409	1524	491	1528	373
M8	492	924	544	785	527	708	590
M9	340	957	822	945	605	690	883
M10	1214	712	1462	890	1329	988	1404
M11	5367	4334	3955	4503	3879	4457	3922
M12	5528	4956	3892	4927	4071	4977	3879
M13	795	980	916	585	963	993	914
M14	384	-3	145	129	60	66	129
M15	112	-460	35	-594	130	-573	66
M16	117	883	416	910	-2	595	480
M17	490	144	443	533	196	411	383
M18	5165	4717	3999	4831	3981	4779	3978
M19	6300	4877	4134	4756	4017	4581	4196
M20	329	-265	365	-133	389	-36	317
M21	370	141	302	69	581	277	273
M22	314	118	409	196	491	286	373
M23	449	63	544	-101	527	-120	590
M24	1742	3043	3955	3174	3879	3216	3922
M25	2976	3449	3892	3376	4071	3529	3879
M26	2244	3211	3999	3281	3981	3331	3978
M27	2945	3586	4134	3428	4017	3339	4196

APÊNDICE C – FN ESTIMADO PELOS MODELOS NÃO LINEARES

ID	FN medido	MNL-EST- FAD-1	MNL-EST- FAD-2	MNL-EST- MBA-4	MNL-EST- MBA-5	MNL-EST- MHI-7	MNL-EST- MHI-8
M1	30	68	290	17	34	48	-5
M2	232	178	324	396	275	165	359
M3	191	126	-378	0	-132	248	95
M4	531	529	812	497	430	717	624
M5	444	499	340	501	333	554	192
M6	597	370	261	525	333	353	302
M7	662	632	380	585	333	606	284
M8	492	421	578	436	333	557	558
M9	340	672	855	856	735	652	974
M10	1214	889	1429	1059	1639	921	1552
M11	5367	4637	3945	4647	3990	4825	3886
M12	5528	5836	3865	6125	3990	5915	3976
M13	795	867	882	840	1190	609	757
M14	384	245	138	225	353	261	315
M15	112	94	59	183	298	123	135
M16	117	300	451	123	491	334	482
M17	490	524	416	433	446	561	349
M18	5165	5585	3984	5531	3990	5691	3958
M19	6300	6047	4183	5737	333	5774	4231
M20	329	413	340	360	333	387	192
M21	370	483	261	356	333	201	302
M22	314	502	380	415	333	382	284
M23	449	247	578	323	3990	328	558
M24	1742	1907	3945	1921	3990	2060	3866
M25	2976	2712	3865	2945	3990	2745	3976
M26	2244	2369	3984	2350	3990	2437	3958
M27	2945	3159	4183	3011	3990	2866	4231

APÊNDICE E – FN ESTIMADO PELOS PERCEPTRONS SIMPLES

ID	FN medido	PS-EST-FAD-1	PS-EST-FAD-2	PS-EST-MBA-4	PS-EST-MBA-5	PS-EST-MHI-7	PS-EST-MHI-8
M1	30	93	36	1256	1305	230	165
M2	232	278	299	382	401	321	356
M3	191	-271	-283	172	193	-192	-210
M4	531	565	594	553	547	715	761
M5	444	423	433	450	446	418	431
M6	597	330	330	383	369	285	292
M7	662	475	480	434	422	421	432
M8	492	428	451	373	366	522	560
M9	340	616	629	556	555	682	714
M10	1214	1221	1224	1195	1195	1217	1233
M11	5367	3017	2995	3070	3055	3125	3130
M12	5528	3013	2981	3003	2978	2992	2991
M13	795	817	808	487	454	678	686
M14	384	275	196	433	348	326	216
M15	112	32	40	320	339	101	117
M16	117	308	314	174	166	371	391
M17	490	477	490	477	483	480	497
M18	5165	3066	3042	3052	3031	3125	3131
M19	6300	3025	3013	2998	2975	3235	3239
M20	329	413	433	438	446	403	431
M21	370	407	418	369	369	267	292
M22	314	462	480	420	422	403	432
M23	449	420	451	364	366	510	560
M24	1742	3004	2995	3056	3055	3107	3130
M25	2976	2998	2981	2987	2978	2971	2991
M26	2244	3051	3042	3035	3031	3104	3131
M27	2945	3013	3013	2984	2975	3217	3259

APÊNDICE G – FN ESTIMADO PELOS PRECEPTONS MULTICAMADAS

ID	FN medido	PMC-EST- FAD-1	PMC-EST- FAD-2	PMC-EST- MBA-4	PMC-EST- MBA-5	PMC-EST- MHI-7	PMC-EST- MHI-8
M1	30	35	33	1245	1281	39	28
M2	232	239	271	368	400	294	284
M3	191	2	1	162	182	0	147
M4	531	524	567	535	555	731	709
M5	444	411	423	444	455	420	427
M6	597	310	312	361	371	242	216
M7	662	467	473	421	428	409	375
M8	492	391	425	352	368	516	474
M9	340	574	597	530	547	646	580
M10	1214	1209	1213	1188	1199	1224	1148
M11	5367	3010	2985	3066	3066	3179	3175
M12	5528	3014	2975	2983	2982	3002	2979
M13	795	799	789	444	439	598	473
M14	384	264	167	417	345	249	218
M15	112	13	30	303	333	35	118
M16	117	260	274	144	150	309	210
M17	490	462	479	475	489	487	488
M18	5165	3063	3035	3041	3039	3166	3165
M19	6300	2995	2987	2980	2979	3280	3314
M20	329	397	423	433	455	409	427
M21	370	399	412	347	371	229	216
M22	314	451	473	407	428	396	375
M23	449	380	425	343	368	508	474
M24	1742	2994	2985	3053	3066	3166	3175
M25	2976	2995	2975	2967	2982	2987	2979
M26	2244	3045	3035	3025	3039	3151	3165
M27	2945	2979	2987	2966	2979	3267	3314

**APÊNDICE J – CLASSES ESTIMADAS PELO PERCEPTRON SIMPLES DE
CLASSIFICAÇÃO PARA AS COMBINAÇÕES DE VARIÁVEIS 7, 8 E 9**

ID	Classe real	PS-CLA- MHI-7	PS-CLA- MHI-8	PS-CLA- MHI-9
M1	Leve	Leve	Leve	Leve
M2	Médio	Pesado	Pesado	Pesado
M3	Médio	Médio	Médio	Médio
M4	Pesado	Pesado	Pesado	Pesado
M5	Pesado	Pesado	Pesado	Pesado
M6	Pesado	Médio	Médio	Pesado
M7	Pesado	Pesado	Pesado	Pesado
M8	Pesado	Pesado	Pesado	Pesado
M9	Pesado	Pesado	Pesado	Pesado
M10	Ext. pesado	Pesado	Ext. pesado	Pesado
M11	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M12	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M13	Pesado	Pesado	Médio	Pesado
M14	Pesado	Pesado	Médio	Pesado
M15	Médio	Médio	Médio	Pesado
M16	Médio	Médio	Médio	Pesado
M17	Pesado	Pesado	Pesado	Pesado
M18	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M19	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M20	Pesado	Pesado	Pesado	Pesado
M21	Pesado	Médio	Médio	Pesado
M22	Pesado	Pesado	Pesado	Pesado
M23	Pesado	Pesado	Pesado	Pesado
M24	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M25	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M26	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M27	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado

**APÊNDICE L – CLASSES ESTIMADAS PELOS PERCEPTRONS MULTICAMADAS
DE CLASSIFICAÇÃO PARA AS COMBINAÇÕES DE VARIÁVEIS 7, 8 E 9**

ID	Classe real	PMC-CLA-MHI-7	PMC-CLA-MHI-8	PMC-CLA-MHI-9
M1	Leve	Ext. pesado	Ext. pesado	Pesado
M2	Médio	Ext. pesado	Ext. pesado	Pesado
M3	Médio	Ext. pesado	Ext. pesado	Pesado
M4	Pesado	Ext. pesado	Ext. pesado	Pesado
M5	Pesado	Ext. pesado	Ext. pesado	Pesado
M6	Pesado	Ext. pesado	Ext. pesado	Pesado
M7	Pesado	Ext. pesado	Ext. pesado	Pesado
M8	Pesado	Ext. pesado	Ext. pesado	Pesado
M9	Pesado	Ext. pesado	Ext. pesado	Pesado
M10	Ext. pesado	Ext. pesado	Ext. pesado	Pesado
M11	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M12	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M13	Pesado	Ext. pesado	Ext. pesado	Pesado
M14	Pesado	Ext. pesado	Ext. pesado	Pesado
M15	Médio	Ext. pesado	Ext. pesado	Pesado
M16	Médio	Ext. pesado	Ext. pesado	Pesado
M17	Pesado	Ext. pesado	Ext. pesado	Pesado
M18	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M19	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M20	Pesado	Ext. pesado	Ext. pesado	Pesado
M21	Pesado	Ext. pesado	Ext. pesado	Pesado
M22	Pesado	Ext. pesado	Ext. pesado	Pesado
M23	Pesado	Ext. pesado	Ext. pesado	Pesado
M24	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M25	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M26	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado
M27	Ext. pesado	Ext. pesado	Ext. pesado	Ext. pesado