

MODELOS DE PREVISÃO DE IRREGULARIDADE LONGITUDINAL APÓS MANUTENÇÃO DE RODOVIAS

Rodrigo Almeida Nascimento

Fernando Silva Albuquerque

Departamento de Engenharia Civil

Universidade Federal de Sergipe

RESUMO

Este trabalho apresenta o ajuste de modelos de previsão de desempenho de índices de irregularidade longitudinal após aplicação de intervenções em duas rodovias no agreste do estado de Pernambuco. Para o primeiro modelo de previsão, utilizaram-se os índices de *IRI* antes e depois das manutenções nas rodovias, e um segundo modelo, com os índices de *QI*. Os dois modelos de previsão de desempenho foram relacionados também com valores de espessura de reforço e porcentagem reciclada do revestimento. Por regressão multivariada, apresentaram-se os modelos determinísticos e seus parâmetros estatísticos para avaliação de consistência, baseando-se na comparação dos valores previstos pelos modelos de previsão e os valores reais observados pelos dados fornecidos. A partir dos valores do coeficiente de determinação (R^2) e o nível de significância dos coeficientes das variáveis independentes (*p-level*), pode-se observar que os modelos obtiveram satisfatória capacidade de previsão dos índices de irregularidade longitudinal para a região do agreste de Pernambuco. Os modelos podem ser aplicados na previsão de irregularidade quando se utiliza a mesma estratégia de manutenção descrita neste trabalho.

Palavras-chave: modelos de previsão, irregularidade longitudinal, manutenção.

ABSTRACT

This paper presents the adjustment of performance prediction models about longitudinal roughness indexes after applying interventions on two highways in the state of Pernambuco. For the first prediction model was used the *IRI* indexes before and after the maintenance of the highways and for the second model was used *QI* indexes. The two performance prediction models also correlated reinforcement thickness values and percentage of recycled base's area. Using non-linear regression method, were presented the deterministic models and their statistical parameters based on the comparison of the values predicted by the prediction models and the actual values observed by the data provided. From the values of the coefficient of determination (R^2) and the significance level of the coefficients of the independent variables (*p-level*), it can be seen that models obtained satisfactory ability to predict the longitudinal roughness indexes for the region of Pernambuco. The models can be applied to the prediction of roughness when is used the same strategy of maintenance described in this paper.

Keywords: prediction models, longitudinal roughness, maintenance.

1. INTRODUÇÃO

Para um sistema rodoviário obter um bom nível de qualidade é necessário que o mesmo possua boas características estruturais, de segurança e conforto ao rolamento. Estas duas últimas características são as mais perceptíveis aos usuários das vias, além de estarem intimamente ligadas aos custos e proteção aos usuários.

O monitoramento destas características nas malhas rodoviárias auxilia Sistemas de Gerência de Pavimentos (SGP), que é um conjunto de métodos que ajudam na busca por melhores estratégias para fornecer e manter pavimentos em condições de serventia adequada por um determinado período de tempo (SONCIM *et al.*, 2014).

Entre as funções do SGP estão o melhoramento e a eficiência das decisões e estratégias escolhidas, a avaliação das consequências destas medidas e assegurar a consistência de tais decisões tomadas. E assim, para auxiliar em tais funções têm-se, como parte de um SGP, os modelos de previsão de desempenho (HAAS *et al.*, 1994).

Os modelos têm como importante função prever a evolução da condição desses pavimentos ao longo do tempo, bem como inferir a eficiência de atividades de intervenção planejadas. A irregularidade longitudinal é uma característica funcional de pavimentos que está bem relacionada com as suas condições de conforto. A redução da irregularidade longitudinal em obras de restauração de pavimentos é, portanto, um dos grandes objetivos para agências gerenciadoras, projetistas e usuários.

Neste trabalho teve-se como objetivo ajustar modelos de previsão de índices de irregularidade longitudinal de pavimentos após aplicação de estratégias de manutenção em duas rodovias situadas no estado de Pernambuco.

2. IRREGULARIDADE LONGITUDINAL

A irregularidade de um pavimento é conceituada como desvio da superfície da rodovia com relação a um plano de referência, que afeta a dinâmica dos veículos, a qualidade do rolamento e as cargas dinâmicas sobre a via (PATERSON, 1987; DNER-PRO 182/94).

Segundo Barella (2008), a irregularidade longitudinal é relacionada com a funcionalidade de um pavimento. Um pavimento foi feito para proporcionar rolamento rápido, econômico, seguro e confortável a seus usuários, portanto um pavimento com alta irregularidade longitudinal prejudica todas essas funcionalidades.

Um elevado índice de irregularidade longitudinal pode decorrer de imperfeições no processo executivo, assim como pode ter como motivo problemas ocorridos após a construção, tais como resultantes da atuação do tráfego, trincamentos, desgastes, deformações e manutenções realizadas (HAAS *et al.*, 1994; LERCH, 2002; BARELLA, 2008).

Segundo Bernucci *et al.* (2008), para quantificar as irregularidades superficiais dos pavimentos, foram desenvolvidas as avaliações diretas, divididas em equipamentos de classe I e II, e indiretas, representadas por equipamentos de classe III. O levantamento topográfico e o dipstick são exemplos de equipamentos classe I (com contato). Na classe II (sem contato) se destacam os equipamentos perfilômetro inercial à laser e o APL (analisador de perfil longitudinal). Os equipamentos tipo-resposta representam equipamentos de classe III (por reação).

De acordo com o DNIT (2006), os primeiros sistemas utilizados internacionalmente e também no Brasil foram os integradores do tipo-resposta, que se baseiam na reação da suspensão do veículo às irregularidades existentes. Porém, a utilização dos perfilômetros inerciais à laser tem sido cada vez mais empregado no Brasil por ser capaz de obter o perfil longitudinal da superfície do pavimento, conjuntamente pela possibilidade de obter-se simultaneamente dados do afundamento na trilha de roda, quando o sistema é equipado com múltiplos módulos (BARELLA, 2008).

De acordo com Barella (2008), no Brasil, embora o *IRI* seja amplamente utilizado, ele ainda não é normatizado. É recomendado pelas normas brasileiras como índice de irregularidade o Quociente de Irregularidade (*QI*), que ainda não foi substituído pelo *IRI* por já ter sido disseminado no Brasil uma cultura do seu uso e também por ter uma origem bastante similar ao *IRI*, ou seja, o modelo de quarto-de-carro. Os valores de *QI* são expressos em contagens por quilômetro (cont./km), enquanto o *IRI* é em metros por quilômetros (m/km).

O quarto-de-carro é movido ao longo do perfil longitudinal a uma velocidade de simulação de 80 km/h. O modelo matemático calcula a deflexão da suspensão do quarto-de-carro utilizando os deslocamentos do perfil medido e parâmetros da estrutura do carro. A suspensão de movimento simulado é acumulada e, em seguida, dividida pela distância percorrida para se obter um índice com a unidade de inclinação, que, quando é em (m/km), é chamado de *IRI* (OLIVEIRA et al., 2017).

O pavimento costuma apresentar um desempenho previsível quanto aos índices de irregularidade. Imediatamente após sua construção costuma-se apresentar uma condição excelente e em sequência vai se deteriorando até alcançar uma condição limite regular/ruim. O limite residual do *IRI* determinado para rodovias administradas pelo DNIT é de 4,0 m/km e o mesmo órgão classifica a irregularidade longitudinal de acordo com a Tabela 1 (DNIT, 2005).

Tabela 1: Classificação da irregularidade longitudinal

Conceito	IRI (m/km)	QI (cont./km)
Excelente	1,0 – 1,9	13 - 25
Bom	1,9 – 2,7	25 - 35
Regular	2,7 – 3,5	35 - 45
Ruim	3,5 – 4,6	45 - 60
Péssimo	> 4,6	> 60

Fonte: DNIT (2005)

3. MODELOS DE PREVISÃO DE DESEMPENHO

Os modelos de previsão de desempenho são expressões do comportamento funcional e estrutural dos pavimentos ao longo do tempo, tendo assim que o uso desses modelos é de grande importância em um projeto de sistema de gerência de pavimentos, pois servem para a definição do trabalho a ser executado e do orçamento destinado (MARCON *et al.*, 1996 *apud* LERCH, 2002).

Segundo Lerch (2002), os modelos de previsão de desempenho são equações, ou sistemas de equações, desenvolvidas após análises e estudos realizados de forma sistemática. Os modelos estimam a evolução dos parâmetros relacionados à degradação dos pavimentos de uma rodovia com base na análise dos dados observados, tais como, irregularidade longitudinal.

No ajuste de modelos de previsão de desempenho há a necessidade de determinar-se a forma desejada para o mesmo. Têm-se modelos do tipo determinísticos e probabilísticos. Modelos do tipo determinísticos determinam os resultados a partir de condições iniciais utilizando regressões para fornecer um único valor de um parâmetro (variável dependente) a partir de uma ou mais variáveis (variáveis independentes). E os modelos do tipo probabilísticos fornecem o alcance de valores de parâmetros, baseando-se em matrizes de transição probabilísticas que estimam a probabilidade de seções de pavimentos se alterarem de uma condição para outra (HAAS *et al.*, 1994)

Para um bom ajuste de modelo de previsão de desempenho, cita-se quatro requisitos fundamentais, quais sejam: um banco de dados adequado às condições e interesses do tema;

a inclusão de variáveis importantes que afetam o desempenho; uma formulação funcional adequada ao modelo e um critério estatístico adequado de acordo com a precisão requerida para o modelo (ALBUQUERQUE, 2007).

Segundo Albuquerque (2007), outro fator preponderante na elaboração de modelos de previsão de desempenho é a utilização de ferramentas estatísticas para avaliar se os resultados fornecidos pelos modelos são confiáveis. A verificação do nível de significância dos coeficientes das variáveis independentes contidas no modelo de desempenho é um bom indicador do tipo e tamanho do efeito sobre a variável resposta.

4. MÉTODOS DE TRABALHO

4.1. Levantamento de dados

Neste trabalho foram analisados dados provenientes de trechos de duas rodovias de pavimentação asfáltica localizadas no agreste do estado de Pernambuco, obtidos no ano de 2014.

Utilizaram-se os dados fornecidos da avaliação da condição de desempenho das rodovias através de perfilômetro inercial a laser (Figura 1), medindo-se assim os índices de irregularidade longitudinal do pavimento, *IRI* e *QI*. Posteriormente, as rodovias sofreram processo de intervenção para recuperação e melhoramento e, novamente com perfilômetro inercial a laser, foram medidos seus índices de irregularidade para verificar a melhora da condição de desempenho dessas rodovias.



Figura 1: Perfilômetro a laser utilizado no monitoramento.

Outro banco de dados necessário foi formado com as estratégias de intervenção utilizadas no processo de recuperação desses pavimentos analisados. Para efeito deste trabalho, foram destacados os valores de porcentagem reciclada do revestimento (correspondente ao percentual da camada que foi fresado e depois reutilizado para recomposição como material já reciclado) e espessuras de reforço (executada com vibroacabadora dotada de régua niveladora). Observou-se que a variável fresagem com recomposição não teve influência significativa na modelagem, portanto não foi levada em consideração neste trabalho.

4.2. Modelos de previsão de desempenho propostos

O método utilizado para o ajuste dos modelos de previsão de desempenho propostos foi o de regressão múltipla não-linear.

A regressão múltipla não-linear é uma forma de análise observacional em que os dados são modelados por uma função que é uma combinação não-linear de parâmetros do modelo e depende de uma ou mais variáveis independentes. O método dos mínimos quadrados foi aplicado para o ajustamento e otimização do modelo. O modelo resultante foi do tipo determinístico.

Tanto para o modelo de *IRI* como para o *QI* foram propostos o mesmo tipo de modelo:

$$y = f(x_1; x_2; \dots; x_n) \quad (1)$$

em que y : é a variável dependente (*IRI* ou *QI*); e

x_i é a i ésima variável independente.

4.3. Tratamento de dados

Primeiramente foi feita uma filtragem dos dados fornecidos de obtenção dos índices de irregularidade. Alguns trechos da medição do perfilômetro a laser apresentavam observações como: lombadas, sonorizadores, viadutos, pontes, postos fiscais e desvios. Os trechos que estavam submetidos a tais observações foram retirados do banco de dados, pois os mesmos tendiam a apresentar valores que representavam dados espúrios, por apresentarem aumento substancial da irregularidade. As Tabelas 2 e 3 trazem resumos dos valores das variáveis dependentes e independentes do banco de dados utilizado para a modelagem de *IRI* e *QI*, respectivamente.

Tabela 2: Resumo de banco de dados das variáveis dependentes e independentes após filtragem de diminuição de erro médio para modelo de *IRI*

Item	Variável	Tipo	Valor mínimo	Valor médio	Valor máximo
<i>IRI</i> posterior (m/km)	<i>IRI</i>	dependente	1,12	1,87	4,60
<i>IRI</i> anterior (m/km)	<i>IRI_ant</i>	independente	1,21	2,98	7,88
Espessura de reforço (cm)	<i>H</i>	independente	3,00	4,08	7,00
Reciclagem do Revestimento (%)	<i>RB</i>	independente	0,00	2,92	35,00

Com os dados devidamente filtrados, necessitou-se uma codificação das variáveis independentes com o intuito de agrupá-las em intervalos de valores que conferissem uma mesma escala, o que proporciona a avaliação estatística dos seus coeficientes. Para tal codificação foi utilizada a seguinte formulação:

$$\text{CÓDIGO} = \frac{X - (X_{\text{máx}} + X_{\text{mín}})/2}{(X_{\text{máx}} - X_{\text{mín}})/2} \quad (2)$$

em que CÓDIGO: representa a variável independente codificada;

X : é a variável independente a ser codificada;

$X_{\text{máx}}$: é o valor máximo da variável independente no banco de dados; e

$X_{\text{mín}}$: é o valor mínimo da variável independente no banco de dados.

Tabela 3: Resumo de banco de dados das variáveis dependentes e independentes após filtragem de diminuição de erro médio para modelo de QI

Item	Variável	Tipo	Valor mínimo	Valor médio	Valor máximo
QI posterior (cont./km)	QI	dependente	6,70	17,18	42,70
QI anterior (cont./km)	QI_{ant}	independente	7,30	34,16	82,50
Espessura de reforço (cm)	H	independente	3,00	4,30	7,00
Reciclagem do Revestimento (%)	RB	independente	0,00	3,67	35,00

As variáveis independentes a serem codificadas apresentaram as seguintes formulações:

- I (IRI anterior):

$$I = \frac{IRI_{ant} - (7,88 + 1,21)/2}{(7,88 - 1,21)/2} = \frac{IRI_{ant} - 4,55}{3,34} \quad (3)$$

- Q (QI anterior):

$$Q = \frac{QI_{ant} - (82,50 + 7,30)/2}{(82,50 - 7,30)/2} = \frac{QI_{ant} - 44,90}{37,60} \quad (4)$$

- H (Espessura de reforço):

$$H = \frac{HR - (7,00 + 3,00)/2}{(7,00 - 3,00)/2} = \frac{HR - 5,00}{2,00} \quad (5)$$

- R (Reciclagem do revestimento):

$$R = \frac{RB - (35,00 + 0,00)/2}{(35,00 - 0,00)/2} = \frac{RB - 17,50}{17,50} \quad (6)$$

Vale observar que os valores médios de espessura de reforço e reciclagem do revestimento são diferentes nas duas tabelas, contudo os valores máximos e mínimos foram iguais. Portanto, as equações 5 e 6 são válidas em todas as modelagens realizadas.

4.4. Ajuste dos modelos

Com o auxílio do software STATISTICA 7, realizaram-se os ajustes dos modelos de regressão múltipla não-linear para IRI e QI .

Aplicado o modelo proposto no software, pôde-se assim obter os valores estimados para a variável dependente e seus resíduos (diferença entre valor observado e valor estimado).

O processo de modelagem sofreu duas iterações, pois, apesar do nível de confiança das constantes das variáveis independentes serem menores de 5%, o coeficiente de determinação do modelo proposto (R^2) não tinha atingido um nível mínimo de 0,80. Portanto, na segunda iteração os bancos de dados de IRI e QI sofreram uma filtragem para obter um modelo mais satisfatório.

Na filtragem retirou-se do banco de dados os valores com erro percentual entre o valor observado e valor estimado superior a 20%, ou seja, tal filtragem teve o intuito de diminuir o erro médio dos valores estimados pelo modelo. Também, os valores com erros percentuais superiores a 20% representam possíveis erros de medição ou possíveis desvios no

procedimento executivo adotado na execução das intervenções. Ambas as filtragens realizadas nesse trabalho aos bancos de dados de IRI e QI resultaram na supressão de 21% e 47% dos dados originais, respectivamente.

No processo de modelagem, o software STATISCA 7 apresentou como resultados os parâmetros do modelo de acordo com o tipo escolhido, o erro padrão associado a cada parâmetro do modelo, o respectivo *t-value*, que é a razão entre cada parâmetro do modelo e seu erro padrão e os correspondentes níveis de significância observados, *p-levels*.

O *p-level* deve ser comparado ao nível de significância adotado na análise. A norma DNER-PRO 277/97 do DNIT estabelece um nível de significância padrão de 10%, devido à grande variabilidade constatada em controles de serviços de pavimentação. Porém, para efeito desse trabalho foi estabelecido um nível de significância de 5%. Neste caso, se o *p-level* de um determinado parâmetro do modelo for menor que o nível de significância a ser comparado, este é dito como significativo na previsão de desempenho. O contrário indica que o parâmetro do modelo é pouco significativo e que contribui para os erros de estimativa.

Verificou-se ainda para cada modelo o coeficiente de determinação (R^2). O R^2 que é uma medida de proporção da variabilidade no parâmetro de desempenho do modelo (variável independente), explicada pela variabilidade dos fatores utilizados no mesmo (*I* ou *Q*, *H* e *R*) (ALBUQUERQUE, 2007). Quanto mais próximo o valor de R^2 for de 1, melhor se apresentará o modelo.

5. RESULTADOS E ANÁLISES

5.1. Banco de dados

O banco de dados utilizado nesse trabalho forneceu o levantamento dos índices *IRI* e *QI* antes e após intervenção para manutenção das rodovias analisadas.

Como apresentado na Figura 2, a distribuição dos dados analisados de *IRI* seguem uma distribuição normal, fornecendo uma média de 2,98 m/km para os dados de pré-intervenção e 1,87 m/km para os dados de pós-intervenção. Nota-se um processo de intervenção bem sucedido devido à queda significativa do valor de *IRI*.




Figura 2: Histograma de valores de *IRI* pré e pós-intervenção das rodovias

Na Figura 3 a distribuição dos dados analisados de *QI* também seguem uma distribuição normal, fornecendo uma média de 34,20 cont./km para os dados de pré-intervenção e 17,18 cont./km para os dados de pós-intervenção. Tal como aconteceu com o *IRI*, o *QI* também confirmou a redução significativa da irregularidade longitudinal.

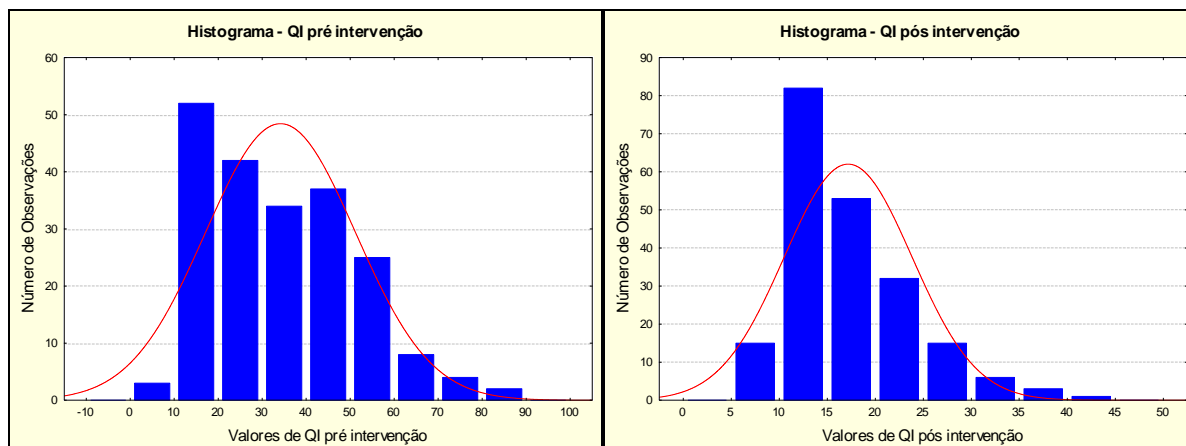


Figura 3: Histograma de valores de *QI* pré e pós-intervenção das rodovias

5.2. Modelo de previsão de desempenho para *IRI*

Com o auxílio do software STATISTICA 7 ajustou-se o seguinte modelo para redução de *IRI* após execução de camada de reforço do pavimento:

$$IRI = 2,44 + 1,68 \cdot I - 0,54 \cdot I \cdot H \cdot R \quad (7)$$

em que *IRI*: valor previsto de irregularidade longitudinal após intervenção (m/km);
I: variável codificada, referente ao *IRI* pré-intervenção, obtida na equação 3;
H: variável codificada, referente à espessura de reforço, obtida na equação 5; e
R: variável codificada, referente % de reciclagem do revestimento, obtida na equação 6.

A Tabela 4 apresenta os parâmetros ajustados pelo software STATISCA 7 para o modelo em questão. Vale salientar que os valores de *p-level* tenderam a 0, representando um alto nível de significância para os coeficientes do modelo.

Tabela 4: Parâmetros estatísticos do modelo de previsão de *IRI*

Estrutura do modelo: $IRI = b_0 + b_1 \cdot I + b_2 \cdot I \cdot H \cdot R$				
	Valor de coeficiente	Erro padrão	t-value	p-level
<i>b</i> ₀	2,44	0,019224	126,8449	~ 0
<i>b</i> ₁	1,68	0,053812	31,1601	~ 0
<i>b</i> ₂	-0,54	0,052383	-10,2739	~ 0

Pode-se ainda analisar o *Scatterplot* dos valores observados e os previstos (Figura 4). O *Scatterplot* consiste em um gráfico de dispersão utilizado para analisar a simetria da curva ajustada entre valores observados e previstos pelos modelos, e estabelecer seus Coeficientes de Determinação (*R*²).

Com um valor de coeficiente de determinação na ordem de 0,83 o modelo apresentou-se significativo, ou seja, aproximadamente 83% da variabilidade total é explicada pela regressão.

Na Figura 4 a reta vermelha indica a tendência ajustada entre os valores observados em campo e os previstos pelo modelo. Vale salientar que quanto mais aproximada a 45° for a inclinação da reta de regressão, menores são os erros por superestimação ou subestimação na inferência de dados pelo modelo. Para evidenciar tal diferença de inclinação, a reta na cor preta indica a inclinação ideal de 45°.

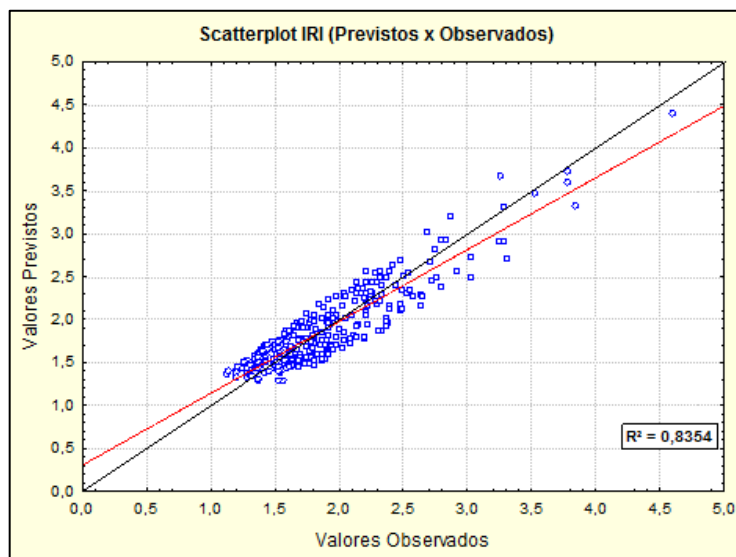


Figura 4: Scatterplot de valores de IRI – Previstos x Observados

Outro fator que pode ser analisado é o gráfico de resíduos x valores previstos (Figura 5). Nele verifica-se que a maior frequência dos resíduos (95%) está na faixa de $\pm 0,4$ m/km, fator que pode ser observado tanto no gráfico das Figuras 5a e 5b. Observa-se ainda pela Figura 5b a distribuição dos resíduos (valor previsto x resíduos) segue uma função normal com média zero, confirmando uma das hipóteses básicas nas análises estatísticas.

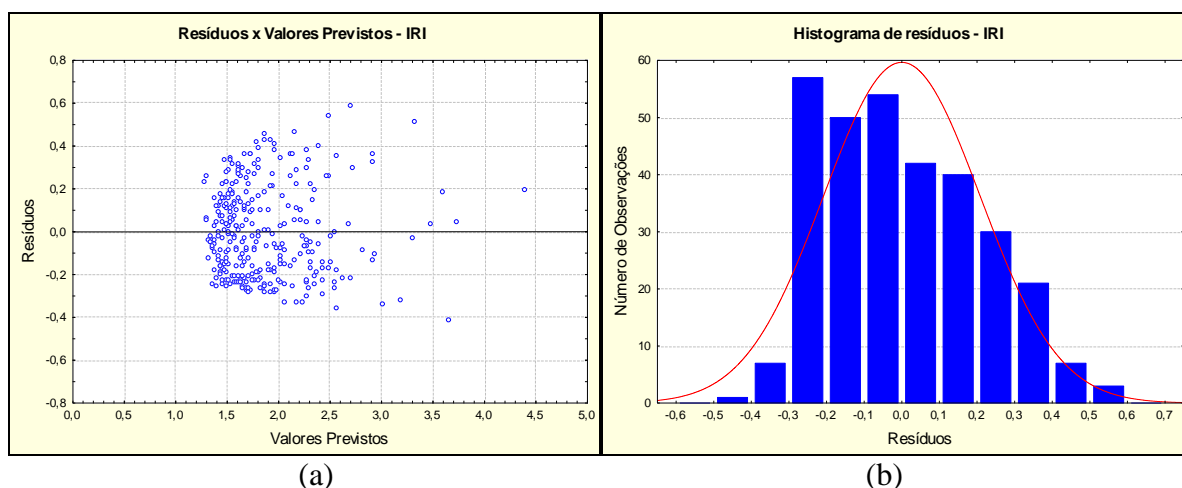


Figura 5: (a) Valores de Resíduos x Previstos de IRI; (b) Histograma de resíduos – IRI

5.3. Modelo de previsão de desempenho para QI

O mesmo procedimento adotado para a modelagem de IRI foi também adotado para o modelo de QI:

$$QI = 20,4 + 16,6 \cdot Q - 4,8 \cdot Q \cdot H \cdot R \quad (8)$$

em que QI : valor previsto de quociente de irregularidade após intervenção (cont./km); e
 Q : variável codificada, referente ao QI pré-intervenção, obtida na equação 4.

A análise de significância dos coeficientes do modelo da equação 8 está na Tabela 5. Valores de p -level também tenderam a 0, sendo todos significantes na inferência do QI .

Tabela 5: Parâmetros estatísticos do modelo de previsão de QI

Estrutura do modelo: $QI = b_0 + b_1 \cdot Q + b_2 \cdot Q \cdot H \cdot R$				
	Valor de coeficiente	Erro padrão	t-value	p-level
b_0	20,4	0,189635	107,6642	~ 0
b_1	16,6	0,474990	34,9410	~ 0
b_2	-4,8	0,586786	-8,2385	~ 0

O modelo de QI apresentou um valor de coeficiente de determinação na ordem de 0,90. Vale salientar que R^2 do modelo de QI superou o do modelo de IRI (0,83), porém pode ser explicado devido ter sido ajustado com um banco de dados menor que o modelo de IRI (banco de dados com 312 amostras), pois a eliminação de dados espúrios foi maior no modelo do QI (banco de dados com 207 amostras).

A inclinação da linha de tendência do modelo de QI também ficou próxima a 45° em seu *Scatterplot* (Figura 6), proporcionando pequenos erros de interferência dos parâmetros do modelo.

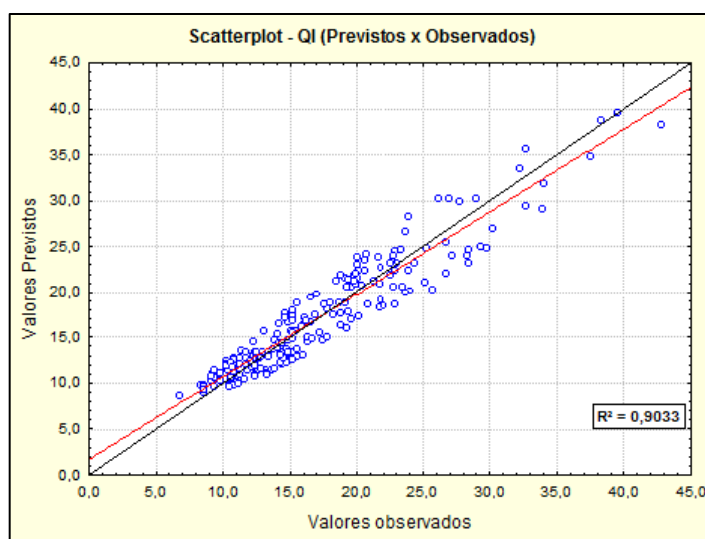


Figura 6: *Scatterplot* de valores de QI – Previstos x Observados

Cabe observar, com relação aos gráficos das Figuras 4 e 6, que as inclinações das retas de ajustes, que decorrem as tendências dos modelos, não foram afetadas pelas filtragens de resíduos durante as modelagens, pois os resíduos negativos e positivos têm a mesma média em valor absoluto, portanto com quantidades suprimidas semelhantes (maiores que 20% de erro). Essa simetria é uma propriedade da otimização realizada pelos mínimos quadrados. Contudo, houve um impacto benéfico ao coeficiente de determinação e à confiabilidade do modelo, com melhor ajuste aos intervalos de confiança oriundos das inferências.

No gráfico de resíduos x valores previstos (Figura 7a), têm-se uma maior frequência dos resíduos na faixa $\pm 4,0$ cont./km (95% dos dados). A distribuição dos resíduos (Figura 7b) também segue uma função normal com média zero.

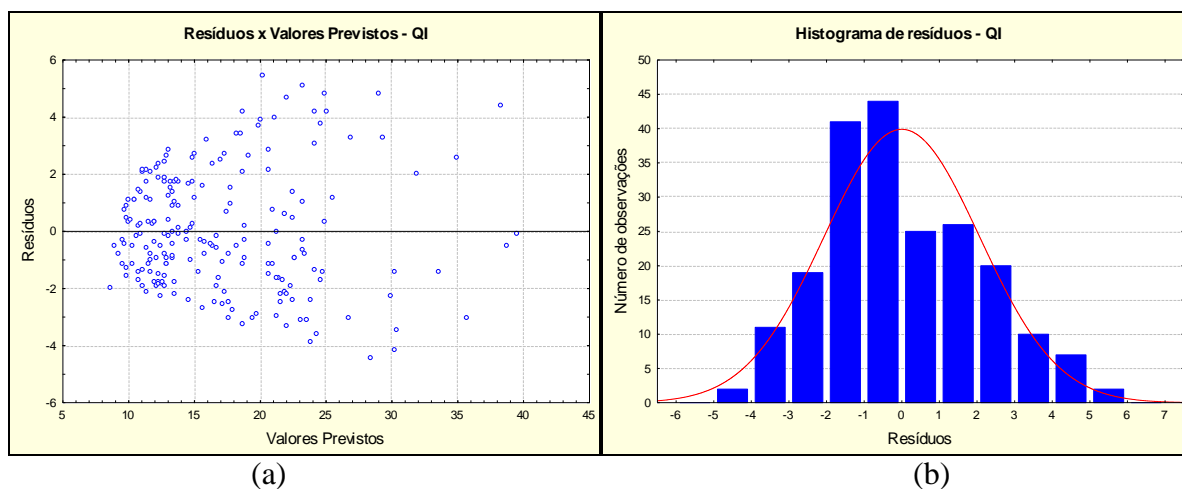


Figura 7: (a) Valores de Resíduos x Previstos de QI ; (b) Histograma de resíduos – QI

6. CONCLUSÕES

Este trabalho visou o ajuste de modelos de previsão de índices de irregularidade longitudinal de pavimentos após a aplicação de manutenção em duas rodovias situadas no agreste do estado de Pernambuco.

Os dois modelos aqui apresentados relacionaram os valores de irregularidade anterior às intervenções, espessura de reforço e porcentagem reciclada do revestimento com os índices de irregularidade longitudinal (IRI e QI) resultantes.

Para o modelo de previsão de desempenho para IRI obteve-se um $R^2 = 0,83$ e p -levels das constantes das variáveis tendendo a zero, valores estes que confirmam uma boa correlação entre os dados previstos e observados e um elevado nível de confiança do modelo, respectivamente.

Para o modelo de previsão de desempenho para QI , obteve-se uma excelente correlação entre dados previstos e observados, $R^2 = 0,90$, e alto nível de confiança dos coeficientes do modelo, com p -level tendendo a zero. Contudo, a filtragem necessária para redução dos erros de estimativa para o modelo de QI foi maior que para o de IRI . Há a possibilidade disso estar relacionado ao próprio método de cálculo do QI , que acaba suavizando demais as diferenças dos perfis às suas linhas médias.

Assim, após as verificações estatísticas apresentadas, pode-se dizer que os dois modelos de previsão de índices de irregularidade longitudinal de pavimentos obtiveram resultados bastante satisfatórios para as estratégias de manutenção utilizadas nestes pavimentos. Portanto, os modelos podem ser aplicados para a previsão de IRI e QI quando estão previstas intervenções com reciclagem do revestimento e espessura de reforço executada com vibroacabadora dotada de régua niveladora.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALBUQUERQUE, F. S. (2007) Sistema de Gerência de Pavimentos para Departamentos Estradas do Nordeste Brasileiro. 303p. Tese de doutorado – Universidade Federal do Rio Grande do Sul, Porto Alegre.
- BARELLA, R. M. Contribuição para a avaliação da irregularidade longitudinal de pavimentos com perfilômetro inerciais / R.M. Barella. – ed. ver. – São Paulo, 2008. 362p.
- BERNUCCI, L. L. B., et al. Pavimentação asfáltica: Formação básica para engenheiros. 1ªed. Programa Asfalto nas Universidades, Petrobras Distribuidora S.A., 2008.
- DNER-PRO 182/94 – Medição da irregularidade de superfície de pavimento com sistemas integradores IPR/USP e maysmeter. MT. – Departamento Nacional de Estradas e Rodagem, Norma Rodoviária.
- DNER-PRO 277/97 – Metodologia para controle estatístico de obras e serviço. MT. – Departamento Nacional de Estradas e Rodagem, Norma Rodoviária – IPR Divisão de Capacitação Tecnológica – Rio de Janeiro, 1997.
- DNIT. Diretoria de Planejamento e Pesquisa. Coordenação Geral de Estudos e Pesquisa. Instituto de Pesquisas Rodoviárias. Manual de conservação rodoviária – IPR 710 - 2. ed. - Rio de Janeiro, 2005.
- DNIT. Diretoria de Planejamento e Pesquisa. Coordenação Geral de Estudos e Pesquisa. Instituto de Pesquisas Rodoviárias. Manual de Restauração de pavimentos asfálticos – IPR 720 - 2. ed. - Rio de Janeiro, 2006.
- HAAS, R. C. G., HUDSON W. R., ZANIEWSKI J. P. Modern pavement management. Krieger Publishing Company. Malabar, Florida, 1994.
- LERCH, R. L. (2002) Previsão de irregularidade pós-recape em rodovias no RS: Ajuste do modelo HDM-4. 108p. Tese de mestrado - Universidade Federal do Rio Grande do Sul, Porto Alegre.
- OLIVEIRA, R. F. S. de ; ALBUQUERQUE, F. S. (2017). Avaliação de perfil longitudinal de pavimento de concreto de cimento Portland com perfilômetro inercial a laser. Transportes (Rio de Janeiro), v. 25, p. 82-92. DOI:10.14295/transportes.v25i1.1138
- PATERSON, W. D.O. (1987) Road deterioration and maintenance effects. World Bank Publications, Washington-DC, USA. Disponível na Web em: <http://www.worldbank.org>.
- SONCIM, S. P.; FERNANDES, J. L.; CAMPOS, L. E. P. (2014) Modelo de previsão da área de desgaste em pavimentos rodoviários com revestimento em tratamento superficial. Transportes, v. 22, n. 2 (2014), p. 51-61.

Rodrigo Almeida Nascimento (rodrigonascimento92@hotmail.com)

Fernando Silva Albuquerque (albuquerque.f.s@uol.com.br)

Laboratório de Topografia e Transportes, Departamento de Engenharia Civil, Universidade Federal de Sergipe
Avenida Marechal Rondon, s/n - Rosa Elze, São Cristóvão - SE, 49100-000