

# CLASSIFICAÇÃO DE QUALIDADE DE PISTAS COM VISTAS AO DESEMPENHO DE PNEUS

**Marcos Manoel Valverde Pereira**

**Linilson Rodrigues Padovese**

Escola Politécnica da Universidade de São Paulo, Departamento de Engenharia Mecânica, 05424-970, São Paulo, SP, Brasil. E-mail: [marcosmvp@hotmail.com](mailto:marcosmvp@hotmail.com), [lrpadove@usp.br](mailto:lrpadove@usp.br)

## Resumo

As solicitações geradas pelas vias de rolamento tem grande relevância para a resposta dinâmica de veículos e seu componentes mecânicos. Vias em mau estado de conservação ou mal projetadas afetam diretamente o custo do transporte, em particular a vida útil dos pneus.

O desgaste de pneus é influenciado pela severidade da pista. O conceito de severidade leva em conta parâmetros como rugosidade do pavimento, nível de ondulação do perfil, número e intensidade de curvas, etc.

Com um enfoque nas ondulações verticais, buscou-se um método de classificar trechos de pistas em diferentes classes. A parte experimental deste estudo se concentrou na obtenção de sinais de pistas para referência. Os sinais consistem em arquivos de aceleração vertical, em um veículo, através de acelerômetros instalados na suspensão.

Os sinais obtidos são tratados digitalmente e classificados através de redes neurais artificiais. Dois paradigmas diferentes de redes neurais foram utilizados: uma *multilayer* perceptron e uma probabilística. Os resultados obtidos com ambas as redes são discutidos e comparados.

**Palavras-chave:** Vibração, rede neural, rede probabilística, pneu, pistas rodoviárias.

## 1. INTRODUÇÃO

As vias de rolamento tem uma grande importância no Brasil, devido à preponderância do transporte rodoviário. Recentemente, devido ao aumento dos investimentos privados, este setor tem procurado novas soluções tecnológicas para o problema da conservação da malha rodoviária, e para a realização de novas estradas.

A detecção e classificação de diferentes qualidades de trecho de pavimento não só é importante para a manutenção da rodovia, como também para a análise de conforto de veículo, e em particular neste trabalho, para o estudo do desgaste de pneus. Segundo Botura (1998), o Banco Mundial utiliza o índice de classificação IRI (*International Roughnes Index*) para classificação de rodovias. Ainda segundo Botura (1998) o DNER (Departamento Nacional de Estrada de Rodagem) utiliza o índice QI (Quociente de Irregularidade) para avaliar as estradas concessionadas. Basicamente os dois índices utilizados, QI e IRI, medem os níveis de oscilações verticais em função do espaço percorrido. A principal falha nestes índices, é a ausência de parâmetros dinâmicos, como a distribuição de frequências de excitação no veículo. Esta distribuição de frequências é fundamental para verificação de ressonâncias no veículo, em sua suspensão e particularmente neste estudo, nas ressonâncias do pneu.

Deste modo, devido a esta deficiência nesses índices, é utilizado neste trabalho a representação espectral do sinal de vibração obtido no veículo, visto que os sinais coletados

refletem o comportamento do conjunto veículo/pista, dando informações importantes sobre o desempenho do pneu. Como um possível desdobramento deste estudo é a correlação entre o desgaste do pneu com o tipo de pista, optou-se pela coleta do sinal no cubo da roda, resultando em respostas dependentes do veículo de teste. Com o propósito de se fazer uma classificação de tipos diferentes de pistas, foram utilizados dois tipos de redes neurais: uma *multilayer perceptron* (MLP), e uma rede probabilística (PNN).

As diferentes pistas estudadas neste trabalho fazem parte da pista de conforto da pista de testes da Pirelli Pneus.

## 2. PROCEDIMENTO EXPERIMENTAL

Foram utilizados nos ensaios experimentais um ônibus Mercedes-Benz MBB O-371 ano 1992, com pneus Pirelli modelo FH 55 – 295/80 R22.5. Dois acelerômetros indutivos, (HBM B12/200 e B12/500) foram montados no chassi, junto ao ponto de ancoragem da suspensão.

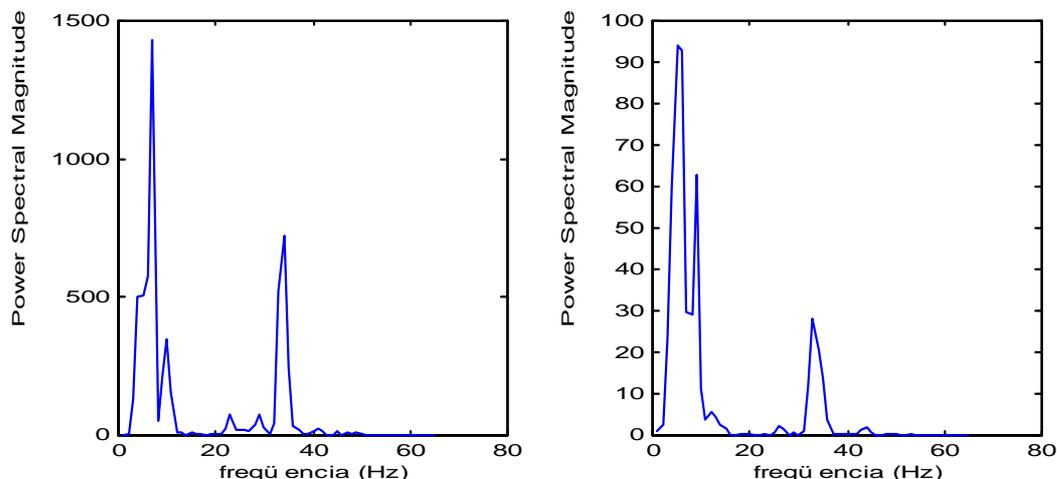
O sistema de aquisição (HBM/MGCPlus) coletou os sinais em três canais distintos, sendo o primeiro para aquisição da velocidade, e dois canais para acelerômetros indutivos no chassi. O primeiro canal serviu para o controle de velocidade durante o ensaio, garantido que os resultados estivessem em uma faixa controlada de velocidade. Os sinais foram coletados com uma frequência de amostragem de 240Hz, sendo previamente filtrados a 100 Hz.

Foram feitas aquisições na velocidade de 40 km/h. No total, foram feitas quatro voltas na pista de conforto da Pirelli. Esta pista de conforto é constituída por trechos representando diversos tipos de piso. Foram identificados cinco categorias de piso:

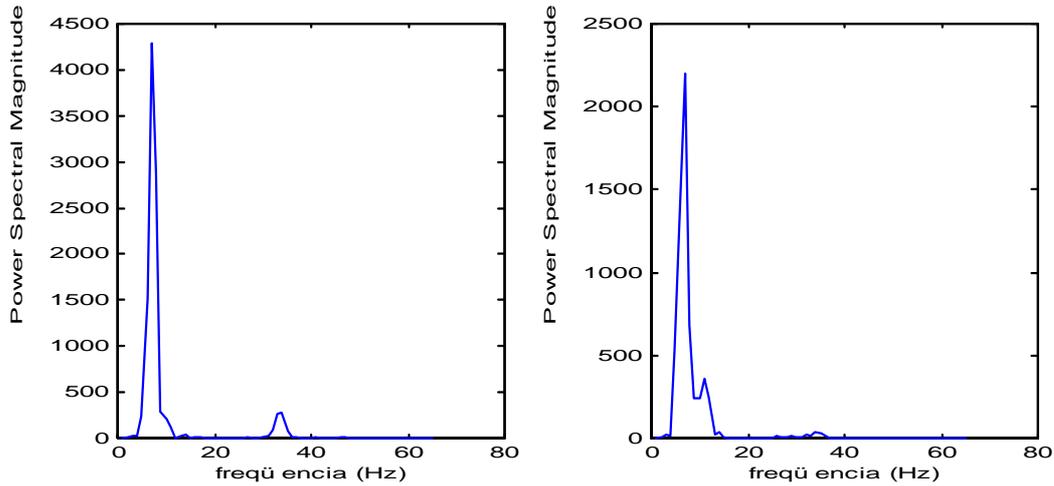
- tipo A: cobertura de paralelepípedos;
- tipo B: obstáculo (barra metálica de 20x200x2500 mm parafusada ao solo);
- tipo C: rasgos profundos no pavimento asfáltico;
- tipo D: série de pequenas ondulações;
- tipo E: asfalto liso, sem irregularidades visíveis;

Esta pista de conforto é utilizada regularmente pela Pirelli, para a avaliação subjetiva de pneus produzidos em série.

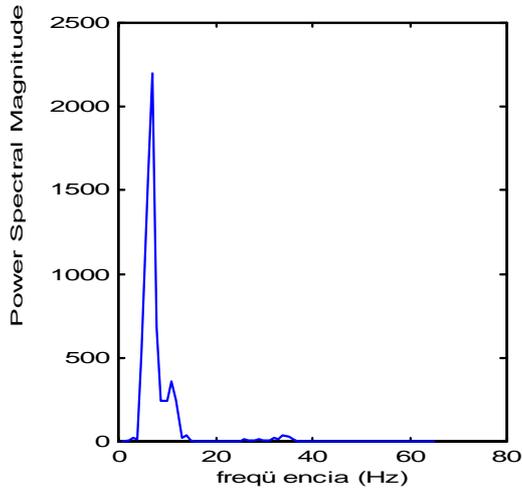
## 3. DADOS OBTIDOS



**Figura 1 e 2:** Exemplos de densidade espectral de uma pista tipo A (paralelepípedos) e tipo B (obstáculo), respectivamente.



**Figuras 3 e 4:** Exemplos de densidade espectral de uma pista tipo C (rasgos) e tipo D (ondulações), respectivamente



**Figura 5:** Exemplo de densidade espectral de uma pista tipo E (liso).

Para cada trecho de pista foram calculadas a densidade espectral de potência do sinal de vibração, Proakis & Manolakis (1996). As figuras de 1 à 5 mostram o espectro de frequência para cada um dos 5 trechos. Dois bancos de dados foram montados para fins de classificação com as redes neurais. O primeiro é composto por vetores das Densidades Espectrais, com banda de 0 a 100Hz, e 128 pontos de tamanho (com resolução espectral de 1 Hz), e outro com mesma banda

espectral, mas com 64 pontos (e uma resolução espectral de 2 Hz). O tamanho total dos bancos de dados é de 226 elementos e 464 elementos respectivamente.

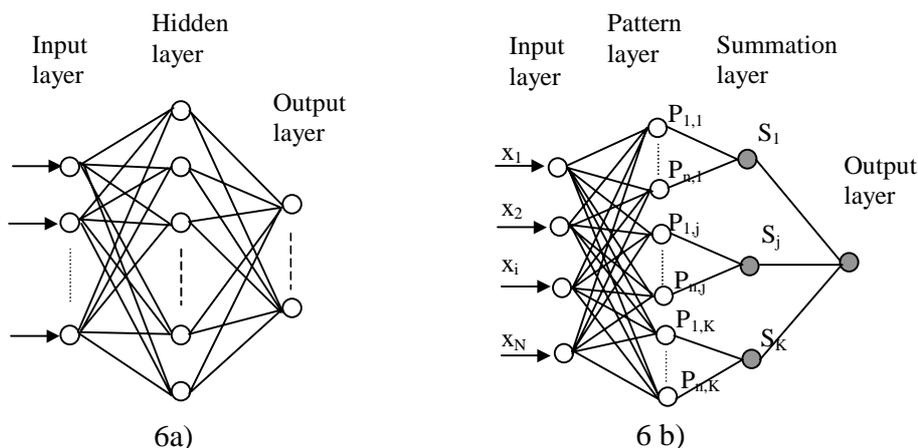
As diferenças entre os resultados mostrados nas figuras de 1 à 5 possibilitam às redes neurais um reconhecimento, se baseando nas diferenças de amplitudes e localizações das frequências de ressonância.

#### 4. REDE NEURAL

Foram utilizados 2 diferentes paradigmas de rede neural com o objetivo de classificar a qualidade de pistas: a MLP e PNN.

##### 4.1 Rede Multilayer Perceptron (MLP)

A rede é formada por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Apenas as camadas ocultas e de saída são camadas de processamento. A função de ativação usada na camada oculta é a tangente hiperbólica sigmoide e na camada de saída é uma função linear. O tamanho do vetor de entrada dita a dimensão da primeira camada. O número de elementos na camada de saída é definida pela quantidade de tipos ou classes a serem classificadas. Uma representação gráfica desta rede é mostrada na figura 6 a).



**Figura 6:** Representação gráfica estrutural das redes MLP e PNN respectivamente

Em relação a camada oculta, não há uma regra clara para sua dimensão. Diversos métodos são propostos, mas a experiência mostra que estes métodos apenas apresentam uma primeira aproximação dos parâmetros desta camada. Na prática, o método de tentativa e falha se torna necessário.

O algoritmo de retroalimentação (*backpropagation*) é utilizado para o treinamento da rede MLP (Padovese, 1999). Existem muitos métodos para acelerar a convergência no treinamento. Neste trabalho será utilizado o método do gradiente conjugado de Fletcher-Reeves (CGFR). Para o treinamento da rede é necessário um conjunto de entradas e suas respectivas classes (*targets*). Cada entrada é processada progressivamente nas camadas ocultas, resultando em uma saída. A partir de então o algoritmo de retroalimentação minimiza o erro quadrático entre os respectivos

target e saída. O mesmo processo é repetido para todas as entrada. Isto é conhecido como fase de treinamento ou aprendizado.

## 4.2 Rede probabilística (PNN)

A arquitetura da rede PNN é composta por quatro camadas. Uma camada de entrada, com a mesma dimensão (N) do vetor de entrada. Uma camada padrão (*pattern layer*), com dimensão N x K (K = número de classes). Uma camada de somatória (*summation layer*), de dimensão K. E uma camada de saída, ou de decisão. A estrutura desta rede pode ser vista na figura 6 b).

Basicamente, esta rede é do tipo *feed-forward*, sem conexão total das camadas adjacentes. Além disto, o número de camadas e seus respectivos nós é extremamente rígido, definidos pela dimensão dos arquivos de treinamento.

Quando um vetor de entrada de dimensão N, e sua respectiva classe são apresentados para a rede, a camada de entrada transfere os N valores para todos os nós da camada padrão. Este vetor recebe pesos conforme a sua categoria, na camada padrão. Depois disto, uma função de transferência modifica os valores calculados em cada um dos nós da camada padrão. A função de transferência é dada pela expressão:

$$f_{ji} = \exp\left(\frac{\bar{v}_{Ti}^t \bar{v}_i - 1}{\sigma^2}\right) \quad (1)$$

Esta expressão leva em conta o vetor de classe  $\bar{v}_{Ti}$ , o vetor de entrada,  $\bar{v}_i$ , sendo que j indica a classe do vetor de comparação e i indica o nó da camada padrão que computa esta classe. A rede PNN possui apenas um parâmetro para ser estimado, o parâmetro *smoothing*  $\sigma$ . O valor otimizado para  $\sigma$  é aquele que obtém a menor porcentagem de classificação errônea de um resultado de um teste da rede. Este parâmetro pode ser obtido por tentativa e erro.

A saída dos nós de cada classe são somados, e entram na camada de somatórias, sendo armazenadas nos nós  $S_j$ .

$$S_j = \sum_{i=1}^K f_{ji} \quad (2)$$

Na camada de saída, uma comparação é feita entre os valores de  $S_j$ . O índice j do máximo valor dos  $S_j$ , entre  $S_1$ , até  $S_n$  indica a qual classe o vetor de entrada pertence.

## 5. RESULTADOS

A principal meta da fase de treinamento é a obtenção de um rede com um bom nível de generalização. Geralmente o nível de erro entre os valores de saída calculados e desejados, controlam esta generalização, mas não garante por si só uma boa generalização. Pode-se ter um erro baixo, mas com resultados de classificação pobres. Neste caso diz-se que a rede não foi capaz de generalizar novas situações.

Por esta razão não será utilizado neste estudo o controle do erro para obtenção de uma boa generalização. O índice de performance da rede será mantido através da porcentagem de acerto da MLP quando um conjunto de teste for a ela apresentada.

Do banco de arquivos de entrada, aproximadamente 20% estão reservados para testes. Os outros 80% fazem parte do conjunto de treinamento. Ambos os bancos de dados (teste e treinamento) foram montados com a preocupação de se obter uma representação apropriada das classes de classificação.

**Tabela 1:** Porcentagem de acerto, por método, por pista.

	Pista A	Pista B	Pista C	Pista D	Pista E
MLP 128 pontos (1 Hz)	89%	100%	63%	71%	0%
MLP 64 pontos (2 Hz)	83%	0%	100%	64%	0%
PNN (80% Confiabilidade)	50%	50%	0%	93%	100%

A tabela 1 apresenta o resultado das redes, com a entrada de arquivos aquisitados no cubo da roda. Os resultados da rede MLP com resolução de 1 Hz e da rede PNN obtiveram uma porcentagem de acerto equivalentes, apenas diferindo a resposta por pista. Agora a resposta da MLP (2 Hz), obteve um desempenho mais pobre, uma explicação para este fato, é a menor resolução frequencial do sinal de entrada. Esta menor resolução prejudica a diferenciação das classes de pistas.

A maior porcentagem de erro de classificação se deve a pista E. Devido a esse fato, procedeu-se ao treinamento das redes com um banco de dado do qual estava ausente os exemplos da pista E. Espera-se com isto que as performances da rede aumente. A tabela 2 mostra os resultados desta simplificação. Os resultados mostram uma melhora nos níveis de acerto. Deve-se observar ainda que a não inclusão da pista E reduz o numero de classes a ser classificado, portanto diminui a complexidade da classificação.

Diante da melhora dos níveis de acerto, realizou-se outros treinamentos de menor complexidade (menor número de classes). A tabela 3 mostra resultados de classificação utilizando-se apenas os conjuntos compostos pelas pistas A,B e A,B,C. Nota-se que os níveis de erro de classificação são nulos.

**Tabela 2:** Porcentagem de acerto, sem levar em conta pista E

	Pista A	Pista B	Pista C	Pista D
MLP 128 pontos (1 Hz)	78%	50%	38%	86%
MLP 64 pontos (2 Hz)	89%	100%	38%	85%

**Tabela 3:** Algumas combinações possíveis de classificação, mét. MLP, resolução 1 Hz.

	Pista A	Pista B	Pista C
A, B	100%	100%	
A, B, C	100%	100%	100%

## **6. CONCLUSÕES**

Os resultados obtidos indicam a viabilidade de se desenvolver um sistema de classificação de qualidade de pista baseados nos sinais de vibração obtidos no chassi do veículo e em redes neurais. Este estudo mostrou que três fatores influem de maneira sinérgica na qualidade do sistema de classificação: o tamanho do banco de dados, o número de classes a ser classificadas e tipo de pré-processamento.

A quantidade de arquivos de entrada, tanto para treinamento quanto para testes, se mostrou muito importante para a confiabilidade dos resultados da rede.

A complexidade de classificação (ditada pelo número de classes) influi na confiabilidade das resposta. Observou-se que quanto maior o número de classes a ser classificada a performance da rede se degrada.

Convém notar que o tipo de pré-processamento utilizado é fundamental para uma boa performance de classificação. Pretende-se como continuação deste trabalho investigar como outros métodos de pré-processamento podem melhorar os níveis de acerto de classificação. Estes métodos devem gerar vetores de entrada de tamanhos reduzidos e ótima descrição das características de cada classe.

## **7. AGRADECIMENTOS**

À empresa Pirelli Pneus, que financiou este trabalho através do Convênio Pirelli – EPUSP/LFS. Além de gentilmente ceder a sua pista de testes, equipamentos para instrumentação e funcionários para a realização da coleta de dados.

## **8. BIBLIOGRAFIA**

- Botura, E.J., 1998, "Contribuição para o estudo da calibração e controle de sistemas medidores de irregularidade rodoviária tipo resposta", Tese de Doutorado, Escola Politécnica da Universidade de São Paulo, 316 p.
- Padovese, L. R., 1999, "Comparison of Neural Networks Performance For Fault Classification in Rolling Bearing", Proceedings of IASTED International Conference Applied Modeling and Simulation, Cairns, Australia.
- Proakis, J. G., Manolakis, D. G., 1996, "Digital Signal Processing – Third Edition", Prentice Hall, New Jersey, USA, 968 p.
- Sayers, M.W., Karamihas, S.M., 1998 "The Little Book of Profiling", 'www.umtri.umich.edu/erd/roughness/litbook.htm', Univesty of Michigan Transportation Institute, 100 p.