

UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA OTIMIZAÇÃO DA MITIGAÇÃO DO RUÍDO EM DUTOS ACÚSTICOS

Maria Alzira de Araújo Nunes, maanunes@unb.br¹
Marcus Antônio Viana Duarte, mvduarte@mecanica.ufu.br²

¹Universidade de Brasília, Faculdade do Gama, Área Especial 2, Lote 14, Setor Central, Gama-DF, Cep: 72405-610.

²Universidade Federal de Uberlândia, Faculdade de Engenharia Mecânica, Campus Santa Mônica, Av. João Naves de Ávila, 2160 Bl.1M, Uberlândia-MG – Cep: 38400-902.

Resumo: *A busca pela redução do ruído é uma necessidade cada vez mais intensa, e atualmente, o número de pesquisas e desenvolvimentos sobre este tema no campo científico e industrial tem sido crescente. As vantagens da mitigação do ruído são tão aparentes que muitas comunidades têm imposto legislações severas com o objetivo de reduzir cada vez mais o ruído excessivo nos ambientes, seja no trabalho, indústria ou residência. Nos últimos anos, tem-se constatado o aumento do interesse dos pesquisadores, refletido pelo grande número de publicações, em controle de ruído em dutos e sistemas HVAC (“air-handling and conditioning system”), principalmente em ambientes industriais, hospitalares e escritórios. Propõe-se neste trabalho a utilização de uma rede neural probabilística (PNN) empregando função de ponderação de Kernel do tipo gaussiana para obtenção do modelo acústico considerado. Tal modelo é constituído de um duto com uma fonte de ruído denominada fonte primária e uma fonte sonora secundária, esta última para controle e mitigação do ruído na saída do duto. De posse do modelo obtido, a fonte secundária terá sua posição e pressão sonora radiada otimizada visando a mitigação do nível de pressão sonora na saída do duto. Os parâmetros otimizados poderão servir de ponto de partida para um possível projeto de controle ativo de ruído, onde nota-se a importância da posição da fonte secundária no desempenho destes sistemas. O modelo acústico utilizado no treinamento da rede e validação dos resultados é baseado em elementos finitos. Mostra-se neste trabalho, que a utilização de um modelo neural produz previsões com grau de acurácia comparável às simulações pelo método de elementos finitos (MEF), tendo como vantagem a redução do custo e tempo computacional quando comparado ao procedimento de otimização utilizando apenas o modelo MEF. No entanto, a precisão dos resultados está diretamente relacionada ao número de pontos treinados pela rede.*

Palavras-chave: *redes neurais, ruído, otimização, duto acústico, mitigação.*

1. INTRODUÇÃO

Na sociedade vigente a poluição sonora é considerada uma das formas mais graves de agressão ao homem e ao meio ambiente. Pesquisas recentes revelam que este tipo de poluição ocupa a terceira posição entre as doenças ocupacionais (Carmo, 1999).

No que tange ao âmbito industrial é crescente o número de registros de perda e danos à audição de trabalhadores que estão expostos ao ambiente fabril. Assim, o ruído industrial e as doenças ocupacionais dele decorrentes, constituem um objeto de estudo de grande relevância no cenário nacional e internacional, pois há a redução da produtividade no trabalho, há as indenizações trabalhistas e os tratamentos médicos correlatos a tais doenças que, geralmente culminam em aposentadoria especial. Um exemplo pertinente às essas assertivas é que até 1996 bastavam 80 dB para caracterizar o direito à aposentadoria especial, ao passo que em 1997 este limite aumentou para 90 dB; e, em 2003 reduziu para 85 dB (Bocchi Jr., 2007).

Um exemplo típico de instalação onde se destacam os elevados níveis de ruído gerados são os Sistemas de Ventilação e Ar Condicionado (HVAC), comumente presentes em plataformas e refinarias petrolíferas. O que torna a situação crítica do ponto de vista dos aspectos e questões de SMS (Segurança, Meio-Ambiente e Saúde) é devido à proximidade de instalação e operação com os alojamentos e escritórios, já que muitas vezes estes são instalados dentro destes compartimentos (Guedes, 2006).

Além da aplicação de dutos em sistemas HVAC, outra aplicação imprescindível destes elementos no setor industrial são os sistemas de exaustão direcionados diretamente para o meio ambiente. Normalmente estes sistemas são de grandes dimensões, com diâmetro (ou largura) maior que 0,5 metro (popularmente conhecidos como chaminés) e comprimentos consideráveis, em que o ruído gerado pelo exaustor/ventilador é propagado até a saída do duto. Dessa

maneira, o ruído irradiado externamente à tubulação propaga-se para o meio externo atingindo a comunidade próxima, seja ela interior ou exterior à empresa.

O estudo de redução de ruído em dutos tornou-se, ao longo dos anos, um campo de intensa aplicação, sobretudo em virtude do potencial industrial e à viabilidade de montagem de sistemas experimentais.

Em ambientes industriais, as principais fontes de ruído são constituídas por ventiladores e exaustores, em que o ruído gerado por este tipo de fonte é em sua grande maioria propagado através de dutos.

Em geral, o ruído irradiado pela tubulação é caracterizado pela passagem de pá do ventilador, constituindo então um ruído do tipo tom puro, isto é, perceptível ao ser humano e considerado incômodo para trabalhos que exijam determinado grau de atenção. A frequência causada pela passagem de pás de ventiladores/exaustores para aplicações industriais encontra-se dentro da faixa de 100 a 500 Hz.

Em um ambiente industrial é muito comum possuir chaminés de exaustão com diâmetros (ou largura, caso seja duto retangular) entre 0,5 e 4 metros, podendo chegar a valores maiores. Para estas configurações, a frequência de corte do duto é muito baixa. Por exemplo, para um duto de 4 metros de diâmetro a primeira frequência de corte é 50 Hz (somente se propagam ondas planas abaixo desta frequência), acima de 50 Hz tem-se a propagação de modos acústicos de alta ordem.

A abordagem tradicional para controle acústico em dutos usa-se de técnicas passivas, como silenciadores resistivos e reativos fixos, para atenuar o ruído. Os silenciadores passivos resistivos são eficientes para atenuação em altas frequências, porém, são relativamente grandes e ineficazes em baixas frequências (Elliot; Nelson, 1993). Por isso, o controle ativo de ruído (CAR) está se tornando uma abordagem atraente para redução e tratamento de ruído, uma vez que este tipo de tratamento é eficiente em baixas frequências (Pacheco, 2006).

O princípio da técnica de controle ativo é captar o campo sonoro indesejado no interior do duto e através de um sistema de controle juntamente com um alto-falante gerar um campo sonoro invertido, de modo que o campo sonoro resultante seja reduzido (Gerges, 2000).

No tocante à propagação de modos acústicos de alta ordem, o campo sonoro ao longo da seção transversal de um duto varia, portanto, a posição dos sensores e alto-falantes ao longo deste plano se torna extremamente significativa para o controle de ruído, ao contrário do que acontece quando há propagação de ondas planas.

Segundo Hansen et al (1996), em um sistema de controle ativo de ruído é extremamente importante ter conhecimento dos fatores que limitam o desempenho do sistema e a importância hierárquica destes. O primeiro fator é a localização das fontes de controle (ou secundária). Uma vez que esta variável tenha sido otimizada, o local dos sensores de erro determinará a máxima redução do ruído.

Portanto, é neste contexto que este artigo irá contribuir, ou seja, na determinação da posição ótima da fonte secundária visando contribuir no projeto de controle ativo de ruído. Desta maneira os fenômenos físicos acústicos do sistema são previamente estudados e analisados antes do projeto de leis de controle e implementação destas.

Propõe-se neste trabalho uma metodologia constituída de simulações numéricas de controle de ruído no interior de dutos acústicos de grandes dimensões utilizando para isto uma fonte sonora secundária. O modelo acústico do sistema será obtido utilizando-se de redes neurais artificiais. De posse do modelo, a posição desta fonte será otimizada bem como a pressão sonora irradiada por ela visando a redução do nível de pressão sonora irradiada na saída do duto. O principal objetivo é utilizar redes neurais para obter o modelo acústico do duto e utilizá-lo em rotinas de otimização, visando assim uma redução do tempo de processamento e do custo computacional quando comparados com modelos de elementos finitos.

As simulações numéricas têm como objetivo o estudo do sistema físico diante do comportamento acústico do duto em função das seguintes variáveis: pressão sonora emitida pela fonte secundária e sua posição, podendo ser considerada uma ou mais fontes secundárias. Para isto, utiliza-se de técnicas como redes neurais artificiais (especificamente redes neurais probabilísticas), método de elementos finitos (MEF) e otimização baseada em algoritmos genéticos (AG).

Os resultados obtidos poderão ser utilizados como ponto de partida para o projeto de um sistema de controle ativo de ruído, além do possibilitar o entendimento e predição do comportamento acústico de dutos de grandes dimensões diante de um sistema de controle de ruído com uma ou mais fontes secundárias em função das alterações das variáveis de projeto aqui consideradas.

2. REDES NEURAIIS PROBABILÍSTICAS (PNN)

As Redes Neurais Artificiais (RNAs) são modelos matemáticos que representam os princípios das atividades do cérebro, criados com a inspiração da neurobiologia e teoria do comportamento (estímulo-resposta). Também são chamadas de modelos conexionistas, sistemas adaptativos, neurocomputadores ou redes neurais. As RNAs exploram características de sistemas paralelos distribuídos em larga escala, devido à inspiração neurofisiológica.

As RNAs também são adequadas para a resolução de problemas de reconhecimento de padrões, otimização, controle, compressão de dados, diagnóstico, e aproximação de funções, dentre outros. Elas possuem a capacidade de aprender por exemplos e fazer interpolações e extrapolações do que aprendem. Um conjunto de procedimentos bem definidos para adaptar os parâmetros de uma RNA para que a mesma possa aprender uma determinada função é chamado de algoritmo de aprendizado, ou treinamento da rede. A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões entre as unidades de processamento, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando.

Dos vários tipos de redes neurais artificiais existentes será apresentada e utilizada neste trabalho a Rede Neural Probabilística (PNN), a qual será a ferramenta utilizada para obter o modelo acústico do duto e utilizado no procedimento de otimização da fonte secundária para fins de mitigação do ruído irradiado na saída do duto.

O algoritmo padrão para as Redes PNN foi baseado na teoria dos Classificadores Bayesianos (desenvolvido nos anos 50) e descrito por Meisel em 1972. Este algoritmo leva em consideração a probabilidade relativa dos eventos ocorridos e usa esta informação para predição. As PNN também utilizam os conceitos de Estimadores Parzen, que foram desenvolvidos para construir as funções densidade de probabilidade requeridas pela teoria Bayesiana. A grosso modo, as PNN operam segundo conceitos consolidados da estatística tradicional (Masters, 1995).

As PNN têm um modelamento matemático consolidado, são treinadas rapidamente e classificam significativamente bem, comparadas com as redes diretas de múltiplas camadas (Masters 1995).

As suas vantagens quanto ao tradicional Backpropagation consiste em que as PNNs possuem um aprendizado rápido, classificando tão bem ou melhor que uma Backpropagation. As PNNs com o número suficiente de dados convergem para o Classificador Bayesiano, que é definido como ótimo.

Além destas vantagens, as PNNs possuem um treinamento incremental, assim como uma indicação de confiança, pois esta fornece uma saída indicando o grau de evidência sobre o qual se baseia a sua decisão. Entretanto, é necessário ressaltar que tanto as PNNs quanto o Backpropagation possuem algumas características similares, tais como o mapeamento não linear ou *learning*, o tratamento de dados ruidosos, ou seja, caráter de generalização e também paralelismo, ou seja, suporte à concorrência, onde estes fatores representam vantagens adicionais aos métodos. Suas principais desvantagens são: relativamente lentas para classificar e requerem grandes espaços de memória.

A rede neural probabilística tem como base o método estatístico de Bayes, o qual será brevemente detalhado a seguir.

Considerando-se uma coleção de amostras aleatórias de K populações, onde cada amostra, indexada de $k=1, 2, \dots, K$, é um vetor $x=[x_1, x_2, \dots, x_m]$. Num caso geral, admite-se que tais amostras tenham diferentes probabilidades, denominadas h_k . Quando um erro de classificação é cometido com um caso que certamente pertence à população k , o custo associado a este erro é c_k , entretanto, em muitos casos, segundo Masters (1995), as probabilidades h_k são admitidas iguais para todas as amostras, e o mesmo é feito para o custo c_k .

A coleção completa é chamada de conjunto de treinamento, contendo n_1 amostras da classe 1, n_2 da classe 2 e n_k da classe k . Um algoritmo apto a associar corretamente uma amostra desconhecida à uma das classes do conjunto de treinamento, deve ser gerado a partir desse procedimento. O algoritmo taxado como um Bayes ótimo ocorre para o caso em que o mesmo tenha um custo de erro de classificação maior do que qualquer outro.

Prova-se que haverá uma regra de decisão de Bayes ótima caso seja fornecida a verdadeira função densidade de probabilidade (fdp) para toda a coleção de amostras. Faz-se a classificação de uma amostra desconhecida X como pertencente à uma classe i se:

$$h_i c_i f_i(X) > h_j c_j f_j(X) \quad (1)$$

para toda amostra $j \neq i$; $f_k(X)$ trata-se da concentração de membros da classe k ao redor da amostra desconhecida.

De acordo com a regra de Bayes, deve-se favorecer a classe que possui maior densidade de membros na vizinhança da amostra desconhecida. Há, no entanto, um problema da regra de Bayes, em que não se conhece a verdadeira fdp $f_k(X)$ e neste caso, deve-se utilizar uma estimativa desta. Parzen (1962) apresenta um excelente estimador para a fdp unidimensional que converge para a verdadeira fdp quando o número de amostras cresce.

O modelo de RNA em questão possui um treinamento instantâneo, apresentando-se robusto na presença de ruídos, pois trabalha probabilisticamente e com um conjunto de treinamento suficientemente grande aproximando do Classificador Bayesiano.

Verifica-se nos últimos anos que redes neurais artificiais têm sido largamente utilizadas em acústica nas mais diversas aplicações, o que nos levou à motivação para utilização destes modelos no trabalho proposto. Segue alguns exemplos: Kolich (2004) utilizou redes neurais para modelar e determinar o conforto acústico de assentos automotivos; Lee e Chae (2004) fizeram uso de redes neurais para caracterização do ruído no interior de veículos automotivos, Pellegrini (2005) pesquisou a avaliação da qualidade sonora de compressores herméticos utilizando redes neurais artificiais; D'Ischia et al (2007) e Brindisi et al (2008) desenvolveram um modelo matemático baseado em redes neurais artificiais para avaliação do conforto acústico no interior de cabines de aeronaves. Ressalta-se que diante da extensa pesquisa bibliográfica realizada pelo autor deste trabalho, não se encontrou nenhuma literatura com a aplicação específica descrita neste artigo mas sim aplicações similares como pode ser observado no exemplos acima: aplicação em cavidades acústicas.

Neste trabalho a PNN será utilizada devido à sua forte teoria baseada em estatística bayesiana, o que o torna robusto para a aplicação requerida. Como o sistema (duto acústico) a ser estudado é relativamente simples geometricamente, o conjunto de dados para treinamento é grande e não há necessidade de aplicação em tempo real, sua utilização se torna viável em virtude dos resultados e precisão a serem obtidos.

3. METODOLOGIA

A metodologia do trabalho é composta de simulações numéricas de controle de ruído com otimização da pressão sonora emitida pela fonte secundária e a posição desta no interior do duto fazendo-se uso de um modelo acústico baseado em rede neural probabilística (PNN), a qual é capaz de simular o comportamento acústico do duto em função da pressão sonora da fonte primária e secundária simultaneamente.

Nas simulações aqui apresentadas considerou-se uma fonte sonora do tipo monopolo emitindo tom puro, gerando portanto análises harmônicas. Para efeitos de modelagem e verificação da aplicabilidade da metodologia proposta será admitido que a fonte sonora primária não sofrerá alterações na sua frequência de excitação nem tampouco na pressão sonora irradiada (será considerada fonte sonora de pressão constante). Será assumida esta condição para ambas as fontes sonoras.

O modelo acústico neural é utilizado em uma rotina de otimização baseada em algoritmos genéticos a qual é capaz de fornecer as variáveis de projeto (posição e pressão da fonte secundária) otimizadas. A rotina de otimização foi implementada em ambiente Matlab® (toolbox denominado GAOT (Genetic Algorithms for Optimization Toolbox), versão 5, desenvolvido por Houck et al (1995)).

O banco de dados para o treinamento da RNA foi obtido a partir de resultados gerados pelo modelo acústico do duto em elementos finitos. Os dados para treinamento da rede compreendem o duto acústico excitado por ambas as fontes sonoras. Sendo assim, a fonte secundária possui uma posição e pressão irradiada para cada dado de treinamento da rede, constituindo portanto um grande banco de dados.

O sistema físico a ser simulado é constituído de um duto acústico, contendo propagação de ondas planas e modos de alta ordem simultaneamente, a fim de verificar o comportamento da metodologia em um sistema acústico com este nível de complexidade geométrica.

No modelo é considerado apenas o fluido acústico não levando em consideração interação fluido-estrutura, mesmo sabendo-se que as placas internas possuem uma espessura de 2 mm.

Na saída do duto há um volume de fluido (ar com as mesmas propriedades do fluido no interior do duto). Tal volume representa uma espécie de câmara anecóica de modo que todo o ruído irradiado para o exterior seja absorvido simulando portanto condição de contorno infinita. Estas condições impostas ao modelo têm como intuito simular a propagação do ruído irradiado pela extremidade do duto em campo livre, aproximando então de uma aplicação real em indústrias. Desta maneira conservam-se os efeitos de reflexão na extremidade (borda) do duto. Na Fig. (1) está mostrada a vista frontal do modelo descrito.

Dois modelos foram simulados numericamente: considerando modelo bi-dimensional e tri-dimensional. Ressalta-se que as dimensões geométricas do duto tri-dimensional são menores se comparadas com o duto bi-dimensional devido ao número de graus de liberdade do primeiro modelo ser muito grande, limitando computacionalmente a solução numérica via método de elementos finitos, a qual é necessário para gerar o banco de dados de treinamento da rede.

Para o modelo tri-dimensional, o duto possui diâmetro igual a 0,3 m e comprimento igual a 2m, resultando em uma primeira frequência de corte igual a 669 Hz. A câmara anecóica presente na extremidade superior do duto possui comprimento igual a 1,3m e diâmetro igual a 0,5m. As placas divisoras possuem comprimento igual a 0,6 m e estão posicionados a 1,2 m da base do duto original.

Já para o modelo bi-dimensional, o duto possui largura igual a 1,2m e possui 13 metros de comprimento (a primeira frequência de corte é igual a 142 Hz), não tendo portanto profundidade ou espessura. O comprimento das placas divisoras é igual a 4 metros, sendo sua posição inicial a 7 metros a partir da base do duto.




Figura 1 – Sistema físico considerado.

No interior de ambos os modelos foram consideradas placas divisoras localizadas longitudinalmente ao longo de um determinado comprimento (4 metros), conforme mostrado na Fig. (1). Com isto, em função da frequência de análise, obtêm-se ondas planas se propagando longitudinalmente no interior das divisões e no restante do duto há propagação de modos de alta ordem, como pode ser visto graficamente nos resultados apresentados (item 4).

A priori, as simulações numéricas de otimização da fonte secundária foram realizadas utilizando apenas o modelo acústico em elementos finitos para fins de comparação com a metodologia proposta, segundo esquema mostrado na Fig. (2).

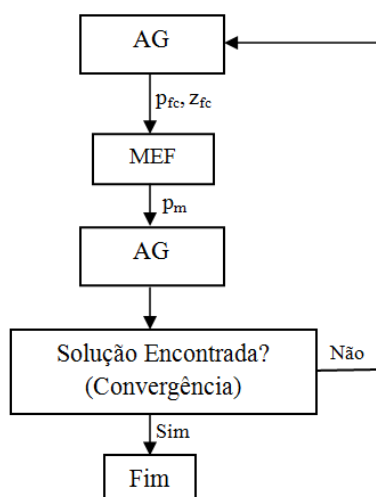


Figura 2 – Otimização utilizando algoritmos genéticos (AG) e modelo acústico via elementos finitos (MEF).

Analisando a Fig. (2) observamos no interior do *loop* de otimização que o modelo utilizado pelo algoritmo de otimização (AG) é baseado em elementos finitos (MEF). Primeiramente o algoritmo de otimização gera a pressão sonora (p_{fc}), parte real e imaginária, e a posição (z_{fc}) da fonte secundária (ambas variáveis de projeto possuem restrições laterais). O modelo acústico (MEF) estima numericamente a pressão média (somente média espacial uma vez que a análise é harmônica) na saída do duto (p_m) a aproximadamente 0,5m do término do duto, resultante do controle de ruído pela fonte secundária. Desta maneira, o algoritmo de otimização recebe o resultado do modelo acústico e conseqüentemente realiza os demais procedimentos de otimização, de modo que a função objetivo seja igual à minimização da pressão acústica irradiada para o exterior do duto.

A desvantagem de se utilizar modelo de elementos finitos a cada iteração do procedimento de otimização, como mostrado na Fig. 2, e tendo ainda grandes intervalos de restrições para as variáveis de projeto, é o alto custo computacional com um tempo despendido nas simulações extremamente elevado.

A fim de reduzir o tempo e custo computacional das simulações é proposto neste trabalho a utilização de um modelo acústico neural em substituição ao modelo MEF, segundo fluxograma mostrado na Fig. (3).

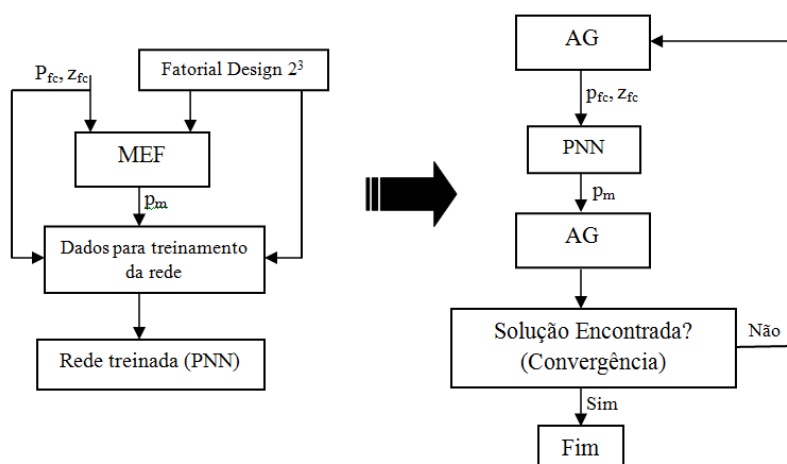


Figura 3 - Fluxograma da otimização utilizando rede neural probabilística (PNN) e algoritmos genéticos (AG).

Conforme mostrado na Fig. (3), o modelo acústico do duto é obtido através da utilização de uma rede neural do tipo Probabilística (PNN). Esta rede possui como característica a função de ponderação de Kernel do tipo gaussiana, devido

ao fato de satisfazer as exigências do método de Parzen e apresentar um bom comportamento matemático além de possuir facilidade no cálculo (Masters, 1995).

Observa-se na Fig. (3) que primeiramente um procedimento de treinamento da rede é realizado, conforme fluxograma da esquerda. Neste treinamento considera-se o fluido acústico juntamente com as duas fontes sonoras (primária e secundária) atuando. Para obtenção dos dados a serem utilizados no treinamento utiliza-se o modelo acústico via elementos finitos. Os dados de entrada para treinamento da rede são compostos de: pressões sonoras (parte real e imaginária) e posição da fonte secundária e a pressão média na saída do duto resultante do controle de ruído. Ressalta-se que um planejamento fatorial (2^3) foi utilizado de modo a incluir nos dados para treinamento da rede os limites de cada variável juntamente com suas combinações entre as variáveis consideradas.

Para treinamento da rede, a princípio foram utilizados 1000 pontos e posteriormente 600 pontos para fins de verificação do desempenho. Ressalta-se que para cada ponto tem-se dados de pressão sonora e posição da fonte secundária e pressão no campo externo ao duto, uma vez que a pressão e posição da fonte primária é constante.

De posse do modelo acústico neural, o mesmo fluxograma descrito na Fig.(2) é utilizado para fazer as simulações, conforme observado no fluxograma da direita na Fig. (3). Ou seja, não se utiliza no procedimento de otimização um modelo em elementos finitos e sim um modelo acústico neural.

No próximo item serão apresentados os resultados obtidos com a otimização do modelo neural comparando com a otimização do modelo em elementos finitos. Suas vantagens e/ou desvantagens serão também abordadas.

4. RESULTADOS E DISCUSSÃO

4.1. Modelo 3D

Utilizando-se do procedimento descrito na Fig. (3), especificamente o fluxograma da esquerda, tem-se que para o modelo do duto em 3D, a rede treinada apresenta os resultados de NPS (Nível de Pressão Sonora) mostrados na Fig. (4).

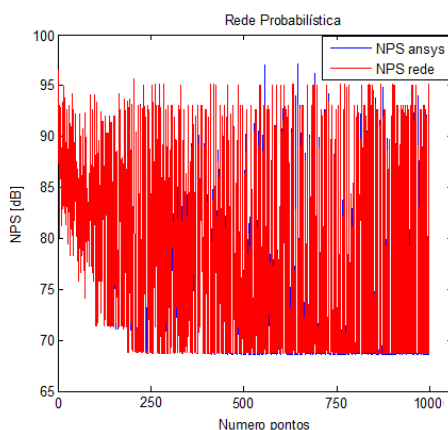


Figura 4 – Rede neural probabilística treinada para o modelo considerado em 3D.

De posse da rede treinada fez-se a otimização da posição da fonte secundária bem como da pressão sonora por ela emitida conforme Fig.(3) à direita.

Na Tab. (1) estão mostrados os resultados otimizados utilizando ambas as metodologias representadas nas Fig. (2) e Fig. (3). A frequência de análise corresponde a 1500 Hz, portanto, há ondas planas no interior das divisórias uma vez que nesta região a frequência de corte é igual a 2065 Hz. Considerou-se apenas uma fonte secundária localizada na lateral do duto, entre a extremidade inferior do duto e abaixo das placas internas divisoras.

Tabela 1. Resultados otimizados obtidos via AG/PNN e AG/MEF para o modelo 3D.

Metodologia	$P_{real_{fc}}$ [Pa]	$P_{imag_{fc}}$ [Pa]	Posição _{fc} [m]	NPS_m [dB]
AG/PNN (Fig. 3)	5.924	0.373	0.811	68.7
AG/MEF (Fig. 2)	6.068	0.488	0.812	68.6

Observa-se que com a quantidade de pontos treinados (1000 pontos) consegue-se obter um modelo gerando resultados satisfatórios, uma vez que o NPS_m , ou seja, nível de pressão sonora médio irradiada para o exterior do duto, obtido com ambas as metodologias possui diferença inferior a 1 dB. Utilizando a metodologia AG/PNN consegue-se uma redução do tempo de processamento em torno de 20 horas quando comparado com a metodologia AG/MEF.

Na Fig. (5) estão mostrados os resultados gráficos do controle de ruído simulados numericamente via método de elementos finitos utilizando os dados otimizados da metodologia AG/PNN para a fonte secundária. Os resultados foram gerados utilizando o software comercial Ansys®.




Figura 5a. Campo acústico do duto 3D sem controle do ruído.




Figura 5b. Campo acústico do duto 3D com controle do ruído.

Observa-se nas Fig. (5a) e (5b) que na saída do duto o NPS médio é igual a 84 dB sem controle do ruído e 68 dB com a fonte secundária atuando no sistema, respectivamente, resultando numa atenuação de 15 dB. Devido à configuração do software, as escala de cores são diferentes para ambas as figura.

Para verificação do comportamento do método, uma nova rede foi treinada, porém, diminuiu-se o número de pontos para 600. O resultados obtidos tem um erro de 3 dB no nível de pressão sonora médio (NPS_m) irradiado, sendo assim, para utilização de um modelo acústico neural é primordial que se escolha adequadamente a quantidade de pontos a ser utilizado no treinamento. Uma análise de sensibilidade deve ser realizada em modelo reduzido para posteriormente obter os resultados otimizados para o modelo em dimensões reais.

A utilização de redes neurais se mostra uma ótima ferramenta para aplicação no problema proposto. Outros tipos de redes neurais foram testadas, como a Backpropagation Lavenberg-Marquat, no entanto, a que forneceu melhores resultados foi a Rede Probabilística.

4.2. Modelo 2D

Um modelo acústico do sistema em 2D, com dimensões próximas de uma aplicação real, teve sua fonte secundária otimizada utilizando as metodologias descritas no item 3.

A análise foi realizada na frequência de 300 Hz, a qual é a frequência de excitação da fonte sonora localizada na extremidade inferior do duto. Foram utilizadas duas fontes secundárias, e cada uma posicionada em uma lateral do duto.

Os resultados obtidos com o modelo de redes neurais foram satisfatórios no que diz respeito à posição otimizada da fonte secundária e do nível de pressão médio irradiado para o exterior do duto, conforme pode ser observado na Tab. (2). Para treinamento da rede neural também foram utilizados 1000 pontos.

Tabela 2. Resultados otimizados obtidos via AG/PNN e AG/MEF para o modelo 2D em 300 Hz.

Método	Preal _{fc1} [Pa]	Pimag _{fc1} [Pa]	Preal _{fc2} [Pa]	Pimag _{fc2} [Pa]	Posição _{fc} [m]	NPS _m [Pa]
AG/PNN (Fig. 3)	0.998	1.029	-0.023	0.455	3.242	47,1
AG/MEF (Fig. 2)	0.817	1.140	-0.034	0.485	3.167	46,7

Para melhor compreensão e visualização dos resultados, na Fig. (6) estão mostrados os campos acústicos do sistema considerado, na frequência de 300Hz, sem e com atuação da fonte secundária. Na Fig. (6b) foram utilizados na simulação os parâmetros da fonte secundária descritos na Tab. (2) obtidos pelo método AG/PNN.

Analisando as Figs. (6a) e (6b) tem-se que o NPS_m sem atuação da fonte secundária é igual a 79 dB e quando simulado com duas fontes secundárias o NPS_m é reduzido para 47 dB. Obtendo, portanto, uma atenuação da ordem de 32 dB.

Outras configurações também foram simuladas, tal como este modelo porém, na frequência de análise igual a 400 Hz. Obtendo portanto, os resultados descritos na Tab. (3).




Figura 6b. Campo acústico do duto 2D com controle do ruído e duas fontes secundárias.




Figura 6b. Campo acústico do duto 2D com controle do ruído e duas fontes secundárias.

Tabela 3. Resultados otimizados obtidos via AG/PNN e AG/MEF para o modelo 2D em 400Hz.

Método	$Preal_{fc1}$ [Pa]	$Pimag_{fc1}$ [Pa]	$Preal_{fc2}$ [Pa]	$Pimag_{fc2}$ [Pa]	Posição _{fc} [m]	NPS_m [Pa]
AG/PNN (Fig. 3)	-0.2718	0.2907	1.0232	0.6220	2.3422	80.81
AG/MEF (Fig. 2)	-0.3131	0.3404	1.1437	0.9459	2.2671	80.06

Para o modelo considerado na frequência de 400Hz tem-se que o NPS médio irradiado na saída do duto é igual a 87dB sem o controle de ruído. Simulando a mitigação do ruído no interior do duto com a fonte secundária otimizada (pressão sonora e posição) conforme dados descrito na Tab. (3) tem-se uma atenuação de 7 dB na pressão sonora externa ao sistema. Com este resultado pode-se verificar a influência da frequência no desempenho do mesmo, sendo assim, este é um parâmetro importante do ponto de vista de projeto de controle acústico em dutos.

5. CONCLUSÕES

Neste trabalho é proposta a utilização de redes neurais, especificamente a rede neural probabilística (PNN), em simulações numéricas de controle de ruído em dutos com propagação de modos de alta ordem. O modelo acústico baseado em redes neurais tem por finalidade ser utilizado em uma rotina de otimização onde a posição e pressão sonora da fonte secundária será otimizada de forma a aumentar a atenuação do ruído global irradiado externamente ao duto.

Considerando um modelo de duto tri-dimensional e fonte primária irradiando ruído do tipo tom puro, a fonte secundária foi otimizada fazendo-se uso de algoritmos genéticos. Tendo em vista as variáveis de projeto: pressão sonora (parte real e imaginária) e posição da fonte secundária, conseguiu-se uma atenuação ótima do ruído irradiado para o exterior do duto da ordem de 15 dB, considerando apenas uma fonte secundária. Ambos os modelos acústicos considerados (RNA e MEF) forneceram resultados otimizados satisfatórios com diferença entre eles menor que 1 dB, validando portanto o modelo aqui proposto baseado em redes neurais.

Devido ao fato do modelo tri-dimensional ter sido simulado em escala reduzida devido às limitações computacionais, um modelo bi-dimensional do duto teve sua fonte secundária otimizada considerando dimensões reais de um sistema físico. Atenuação da ordem de 32dB foi obtida otimizando duas fontes secundárias na frequência de 300 Hz. Já na frequência de 400Hz obteve-se uma redução de 7dB para o mesmo sistema. Nestas simulações pôde-se observar a influência da frequência nos resultados obtidos.

Os resultados demonstraram que a utilização de um modelo acústico obtido a partir de redes neurais produz predições com grau de acurácia comparável às simulações obtidas com o modelo em elementos finitos, tendo como vantagem a redução do custo e tempo computacional (redução de 20 horas no tempo de processamento) quando comparado ao procedimento de otimização utilizando apenas o modelo acústico MEF. No entanto, a precisão dos resultados está diretamente relacionada ao número de pontos treinados pela rede.

6. AGRADECIMENTOS

À Faculdade UnB-Gama (FGA-UnB) e ao Decanato de Pesquisa e Pós – Graduação (DPP) da Universidade de Brasília pelo auxílio financeiro. Ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Uberlândia pelo apoio durante execução do trabalho.

7. REFERÊNCIAS

- Bocchi Jr., H. , O ruído, a surdez e a aposentadoria, *Jornal A Cidade*, 17 de jun de 2007. Disponível em: <<http://www.bocchiodvogados.com.br/artigos/O%20ruído,%20a%20surdez%20e%20a%20aposentadoria.pdf>>,19/12/2008.
- Brindisi, A., Concilio, A., Passengers' comfort modelling inside aircrafts", *Journal of Aircraft*, Vol.45, n.6, Nov-Dec. 2008.
- Carmo, L. I. C., Efeitos do Ruído Ambiental no Organismo Humano e suas Manifestações Auditivas, Monografia, Centro de Especialização em Fonoaudiologia Clínica - CEFAC, Goiânia, 1999.
- D'Ischia, M., Paonessa, A., Brindisi, A., Noise annoyance in civil aircraft cabins: analysis of a ANN based evaluation model", *NoiseatWorks* 2007, Lille, 3-5 July 2007.
- Elliot, S. J. and Nelson, P. A., Active Noise Control, *IEEE Signal Processing Magazine*, October, 1993.
- Hansen, C. H., Howard, C. Q., Burgemeister, K. A., Cazzolato, B. S., Practical Implementation of an Active Noise Control System in a Hot Exhaust Stack, In.: *Acoustics Making Ends Meet: Innovation and Legislation*, Brisbane, Queensland, Australia, 13-15, November, 1996.
- Houck, C. R., Joines, J. A. and Kay, M., G., A Genetic Algorithm for Function Optimization: A Matlab Implementation, North Carolina State University, 1995.
- Gerges, S. N. Y., Ruido – Fundamentos e Controle, 2ª ed., Florianópolis, 696p., 2000.
- Guedes, F. P., Controle Ativo e Ruído em dutos de Ventilação: Um experimento para aplicação em Unidades Offshores, Dissertação de mestrado, 2006, COPPE/UFRJ, Engenharia Oceânica.
- Kolich, M., Seal, N., Taboun, S., Automobile seat comfort prediction: statistical model vs. artificial neural network, *Applied Ergonomics* 35,275-284, 2004.
- Lee, S. K. and Chae, H. C. The application of artificial neural networks to the characterization of interior noise booming in passenger cars. *Proc. Instn Med. Engrs, Part D: J. Automobile Engineering*, 2004, 218(1), 33–42.
- Masters, T., *Advanced Algorithms for Neural Networks: A C++ Sourcebook/Book* , John Wiley & Sons, New York, 1995.
- Pacheco, W. S., Ressonador de Helmholtz Semi-Ativo para Controle de Ruído em Dutos, Dissertação de Mestrado, 2006, COPPE/UFRJ, Engenharia Mecânica.
- Parzen, E., On estimation of a probability density function and mode, *Annals of Mathematical Statistics*, V. 33, pp. 1065 – 1076.
- Pellegrini, C., Avaliação da qualidade sonora de compressores herméticos utilizando redes neurais artificiais, Dissertação, Universidade Federal de Santa Catarina, Faculdade de Engenharia Mecânica, 2005.

8. DIREITOS AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo do material impresso incluído no seu trabalho.

USE OF ARTIFICIAL NEURAL NETWORKS FOR OPTIMIZATION OF THE ACOUSTIC DUCT NOISE MITIGATION

Maria Alzira de Araújo Nunes, maanunes@unb.br¹

Marcus Antônio Viana Duarte, mveduarte@mecanica.ufu.br²

¹Universidade de Brasília, Faculdade do Gama, Área Especial 2, Lote 14, Setor Central, Gama-DF, Cep: 72405-610.

²Universidade Federal de Uberlândia, Faculdade de Engenharia Mecânica, Campus Santa Mônica, Av. João Naves de Ávila, 2160 Bl.1M, Uberlândia-MG – Cep: 38400-902.

Abstract. *The noise reduction become a need in the great cities, and currently, the number of research and development about this theme in science and industry has been growing. The benefits of noise mitigation are so apparent that many communities have imposed strict laws in order to reduce excessive noise in the environment, at work, industry or residence. In recent years, it has found increasing interest of researchers, reflected by the large number of publications, in noise control of ducts and HVAC (air-handling and conditioning system), applied especially in industrial areas, hospital and offices. In this paper is proposed the using of a probabilistic neural network (PNN) which uses kernel weighting function of Gaussian type to simulate the acoustic behavior of system with active noise control. The aim consists in optimizing the position and sound pressure of the source control to minimize the sound pressure level at the output of the duct. The acoustic model used in network training and validation of the results is based on finite elements. It is shown in this study that the use of a neural model produces predictions with a degree of accuracy comparable to the simulations by finite element method (FEM), taking the advantage of reducing the computacional cost and time when compared to the optimization procedure using only the FEM model. However, the accuracy of the results is directly related to the number of points used in the network training.*

Keywords: *neural network, noise, optimization, acoustic duct, mitigation.*