



MODELAGEM DA RESPOSTA SUBJETIVA A VIBRAÇÕES EM AERONAVES USANDO MÉTODOS DE APRENDIZADO DE MÁQUINA

RICARDO LUÍS SCHAEFER¹, CARLOS ANDRES FERRERO¹,
SAMIR NAGI YOUSRI GERGES^{2,3}

¹Universidade Estadual do Oeste do Paraná – UNIOESTE
Centro de Engenharias e Ciências Exatas – CECE
Foz do Iguaçu – PR – Brasil – 85870-650

²Instituto Federal de Santa Catarina – IFSC
Curso de Engenharia Mecatrônica
Florianópolis – SC – Brasil – 88020-300

³Universidade Federal de Santa Catarina – UFSC
Departamento de Engenharia Mecânica
Florianópolis – SC – Brasil – 88040-900

(Recibido 8 de noviembre de 2013, para publicación 27 de enero de 2014)

Resumo – Com o aumento da concorrência no mercado de aeronaves, existe interesse das indústrias em desenvolver serviços de melhor qualidade para os seus clientes. Nesse sentido, está sendo desenvolvido um projeto interinstitucional para modelagem de repostas subjetivas de passageiros em relação a adjetivos (conforto, consistência, força, suportabilidade), a partir de estímulos físicos de vibração em simuladores de aeronaves. Neste trabalho foram utilizados métodos de Inteligência Artificial, especificamente de Aprendizado de Máquina, para a seleção de atributos e a construção de modelos de regressão. Na seleção de atributos foi utilizada uma abordagem do tipo filtro e na construção de modelos foram utilizadas as abordagens de Redes Neurais Artificiais, Regressão Linear Múltipla e Árvores de Regressão. O método experimental proposto tem como objetivo prever a resposta subjetiva de passageiros, apenas considerando as bandas de frequência dos estímulos vibratórios mais importantes de acordo com cada adjetivo. A avaliação dos modelos foi realizada de acordo com a complexidade e a qualidade preditiva. Os resultados mostram que o método proposto permitiu diminuir entre 86,42% e 98,15% a quantidade de bandas de frequência utilizadas para induzir os modelos, sem prejudicar a qualidade preditiva dos modelos, inclusive em três das 12 configurações foi possível constatar melhora estatisticamente significativa. De acordo com os especialistas os modelos apresentaram-se promissores, tanto do ponto de vista de complexidade, quanto de qualidade preditiva.

Palabras-chave – Aviação, conforto, inteligência artificial, seleção de atributos.

1. INTRODUÇÃO

Nos últimos anos, o transporte aéreo vem apresentando um crescimento expressivo no Brasil e no mundo, devido a diversos fatores como o aumento de renda da população, expansão do turismo e globalização comercial [1]. Decorrente ao fato, também houve um aumento no comércio de aeronaves, e consequente aumento na concorrência entre os fabricantes, motivando a construção de aeronaves com serviços melhores para os clientes. Por exemplo, o conforto pode ser um fator diferencial, garantindo melhor qualidade de transporte de passageiros, e possivelmente maiores vendas para os fabricantes.

O conforto é um aspecto que representa a satisfação da pessoa em relação ao ambiente que está inserida. Praticamente tudo que está a sua volta influencia de modo direto no conforto. Especificamente em relação ao conforto de passageiros em aeronaves, os principais fatores incluem: espaço entre as poltronas, ruído, temperatura, umidade, iluminação e vibração [2]. Apesar destes fatores nunca atuarem individualmente, é de extrema importância o conhecimento de como cada um desses sentidos é percebido pelos passageiros.

Para isso, são desenvolvidos ensaios específicos em simuladores de voos, em conjunto com métodos psicofísicos de aquisição de dados subjetivos. A coleta de dados em simuladores é de fundamental impor-

tância, pois, apesar de não reproduzir exatamente as condições de voo, possibilita a variação, por exemplo, de diferentes estímulos vibratórios, de forma a garantir a variabilidade da opinião de passageiros, o que não é possível em voos reais, já que somente poderia ser obtida a opinião de apenas um único estímulo real, o do voo.

Desse modo, a previsão da opinião de passageiros a partir de estímulos vibratórios é uma questão em aberto e de interesse para a indústria de construção de aeronaves [2-7]. A correlação dessas informações no intuito de construir modelos de previsão é uma tarefa complexa e dependente de diversos fatores, como a representação matemática do problema e a estratégia utilizada para construir o modelo. Além disso, considerando que há um universo imenso de parâmetros que podem ser calculados, definir quais são os parâmetros físicos que devem ser considerados na geração dos modelos, de modo a representar de forma fidedigna a opinião dos jurados, é mais uma questão de difícil resolução.

No entanto, métodos computacionais para a construção de modelos utilizando técnicas de Inteligência Artificial, mais especificamente de Aprendizado de Máquina (*Machine Learning*), podem ser utilizadas para contornar essas questões em aberto, e possibilitar a construção de modelos para previsão de adjetivos subjetivos, como conforto, constância, força e suportabilidade, a partir dos parâmetros físicos de vibração considerados mais importantes para cada adjetivo. Assim, esses modelos poderão auxiliar em processos de tomada de decisão associados à construção de aeronaves de melhor qualidade.

Neste trabalho é apresentado um estudo da aplicação de métodos e técnicas de Aprendizado de Máquina para a construção de modelos de regressão que permitam prever as respostas de passageiros voluntários em relação aos adjetivos mencionados, a partir de parâmetros extraídos de estímulos vibratórios controlados. O objetivo consiste em avaliar a influência da seleção de atributos relevantes e não redundantes, na qualidade de modelos de regressão baseados em Redes Neurais Artificiais, Regressões Lineares Múltiplas e Árvores de Regressão.

2. MÉTODO

O método experimental proposto para atingir esse objetivo está delineado em cinco etapas: (1) coleta de dados; (2) construção do conjunto de dados; (3) seleção de atributos; (4) construção de modelos de regressão; (5) avaliação de modelos.

2.1. Etapa 1 – Coleta de Dados

Os dados são coletados por meio de ensaios realizados no simulador de aeronaves do Laboratório de Vibrações e Acústica da Universidade Federal de Santa Catarina (LVA/UFSC) (Fig. 1). Esse simulador, também denominado de *mock-up*, possui estrutura e ambiente semelhantes ao de uma aeronave real. Esse simulador permite reproduzir sinais de excitação gravados em voos reais de forma a avaliar a opinião de passageiros em um ambiente controlado, com menos influência de fatores externos.



Fig. 1. Simulador de aeronaves (*mock-up*) do LVA/UFSC [7].

Inicialmente, já dentro da cabine, os ensaios são precedidos de um vídeo que explica o método do ensaio, e uma etapa de adaptação, na qual o passageiro voluntário, denominado de jurado, é estimulado por sinais de vibração e ruído mais intensos, de forma a eliminar algum tipo de memória sensitiva do jurado com relação a ruído e vibração. Durante todo o ensaio é utilizado um par de fones de ouvido, com ruído de fundo, para evitar que a avaliação do estímulo vibratório seja prejudicada pelo ruído gerado pelo piso do simulador [4].

Desse modo, os dados coletados durante a simulação são classificados em físicos e subjetivos.

2.1.1 Dados Físicos

Os dados físicos consistem em sinais de vibração no tempo e são coletados por meio de um acelerômetro triaxial instalado próximo ao pé da poltrona. A vibração é medida em três eixos coordenados (x , y e z) por um período mínimo de 30 segundos, para garantir a representatividade da amostra. A partir destes sinais são calculados os valores globais de bandas divididas em 1/3 de oitava com a utilização de uma rotina desenvolvida no ambiente de programação e computação numérica MATLAB®, versão 7.6 R2008a.

2.1.2 Dados Subjetivos

A coleta dos dados subjetivos é realizada de modo concomitante com a aquisição de sinais físicos e por meio de jurados voluntários. As informações subjetivas capturadas correspondem a quatro adjetivos: conforto, constância, força e suportabilidade.

Durante a simulação é realizada a captura da opinião sobre esses adjetivos por meio de métodos psicofísicos, como o método de Escala de Resposta – ER. Esse método é amplamente utilizado na psicologia e foi adaptado pela engenharia, onde é utilizado como forma de avaliação no qual o jurado avalia os sinais reproduzidos atribuindo notas a cada característica do estímulo [8]. Assim, consiste na representação das possíveis respostas de forma linear, por meio de uma barra, onde os jurados são informados dos pontos mínimos e máximos da escala, e orientados a posicionar o cursor do mouse no ponto da escala que indicasse a sua opinião, relativa ao estímulo vibratório em relação a cada um dos adjetivos. Na Fig. 2 é apresentado um exemplo da aplicação do método de ER para cinco sinais de vibração (A, B, C, D e E) com valores mínimos e máximos, 0 e 10, respectivamente, e com o posicionamento do cursor na barra, de acordo com a opinião do jurado sobre o adjetivo suportabilidade de cada sinal de vibração.

Dessa forma, para a coleta dos dados subjetivos é armazenada a posição do cursor alocada pelos jurados, e a mesma é transformada em número.

Avalie a vibração conforme:

a suportabilidade

Vibração	Posição do Cursor (aproximada)
Vibração A	4,5
Vibração B	7,5
Vibração C	3,5
Vibração D	5,5
Vibração E	3,5

Confirma resposta

Fig. 2. Exemplo da aplicação do método psicofísico ER para cinco sinais de vibração [5].

2.2. Etapa 2 – Construção do Conjunto de Dados

Uma vez realizada coleta de dados são construídos quatro conjuntos de dados, um para cada adjetivo (classe): conforto – CD_{conf} –, constância – CD_{cons} –, força – CD_{for} – e suportabilidade – CD_{sup} . Os conjuntos de dados são constituídos de exemplos (um para cada jurado) descritos por 162 atributos, referentes às 54 bandas de frequências resultantes da análise de frequências, por meio da *Fast Fourier Transform* – FFT – aplicada em cada eixo x , y e z , e um atributo-classe que indica a resposta subjetiva do jurado. Desse modo, cada CD é representado computacionalmente por uma tabela atributo-valor, conforme Tabela 1.

Nessa tabela, as linhas representam os exemplos, em que n corresponde à quantidade de exemplos, as colunas representam os atributos, sendo a última coluna correspondente à variável objetivo, denominada de atributo-classe, e cada $v_{i,j}$, corresponde ao valor do atributo j para o exemplo i .

Para que esses dados possam ser processados e manipulados por ferramentas computacionais de Aprendizado de Máquina, devem estar em formato adequado. Um dos formatos comumente utilizados para o armazenamento de dados no formato atributo-valor é o *Attribute-Relation File Format* – ARFF, desenvolvido no projeto *Machine Learning Project*, do Departamento de Ciência da Computação da Universidade de Waikato [9].

2.3. Etapa 3 – Seleção de Atributos

Nessa etapa é realizada a identificação de atributos não importantes (redundantes e não relevantes), isto é, bandas de frequência que podem não contribuir positivamente para a construção de modelos de regressão. É desejável que algoritmos de Aprendizado de Máquina – AM – trabalhem de forma eficiente na presença de atributos redundantes e não relevantes, no entanto, o desempenho desses algoritmos é afetado pela presença desses atributos [10]. Outro ponto importante é que conjuntos de dados com alto número de atributos também podem comprometer a construção de uma solução eficiente, devido ao crescimento do espaço de busca de soluções, o qual cresce exponencialmente em relação ao número de atributos.

A Seleção de Atributos é uma subárea de pesquisa, dentro da área de Aprendizado de Máquina, que tem como objetivo desenvolver métodos e técnicas para identificar e remover atributos não importantes. Essa tarefa é essencial dentro do processo de construção de modelos, e as técnicas presentes na literatura são classificadas em: filtro e *wrapper* [10]. Na abordagem filtro consideram-se características intrínsecas dos atributos, extraídas por meio de medidas de importância, e selecionam-se os atributos melhor classificados. Na abordagem *wrapper* os atributos são analisados pela melhora que podem produzir se utilizando um determinado algoritmo para construção de modelos. Como a precisão do modelo é considerada a função de avaliação dos atributos, faz-se necessário construir um alto número de modelos para chegar a uma solução de interesse. Ainda existe uma terceira abordagem especial, denominada embutida, em que o processo de seleção de atributos é realizado durante o processo de construção do modelo.

Tabela 1. Representação computacional do conjunto de dados no formato atributo-valor.

CD	Bandas no eixo x	Bandas no eixo y	Bandas no eixo z	Classe
Exemplo 1	$(v_{1,1}, v_{1,2}, \dots, v_{1,54})$	$(v_{1,55}, v_{1,56}, \dots, v_{1,108})$	$(v_{1,109}, v_{1,110}, \dots, v_{1,162})$	$(v_{1,163})$
Exemplo 2	$(v_{2,1}, v_{2,2}, \dots, v_{2,54})$	$(v_{2,55}, v_{2,56}, \dots, v_{2,108})$	$(v_{2,109}, v_{2,110}, \dots, v_{2,162})$	$(v_{2,163})$
...
Exemplo n	$(v_{n,1}, v_{n,2}, \dots, v_{n,54})$	$(v_{n,55}, v_{n,56}, \dots, v_{n,108})$	$(v_{n,109}, v_{n,110}, \dots, v_{n,162})$	$(v_{n,163})$

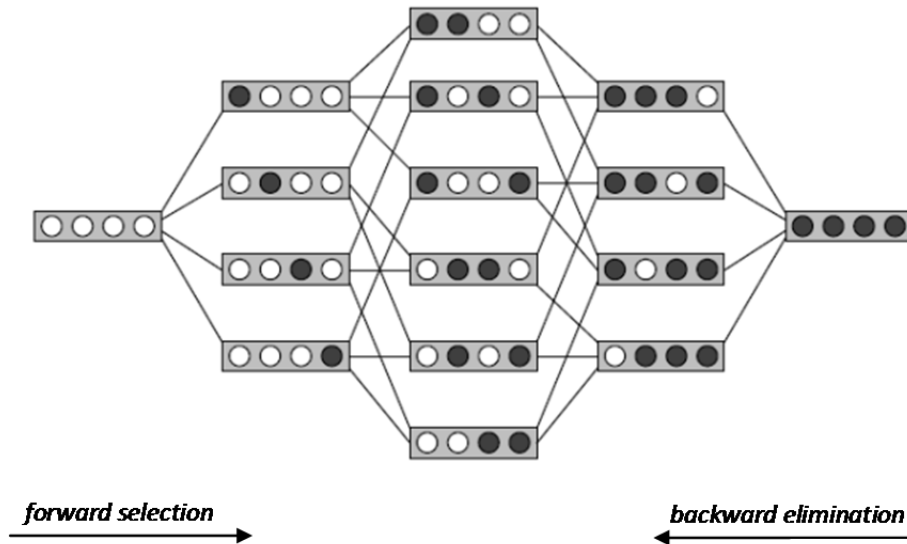


Fig. 3. Processo de busca no espaço de estados de subconjuntos de atributos [11].

2.3.1 Abordagem Filtro

Essa abordagem permite selecionar atributos independentemente do algoritmo de construção de modelos que é utilizado em etapa posterior. Para a utilização dessa abordagem devem ser definidas três características: a medida de importância, a orientação da busca e a estratégia da busca [10]. Na Fig. 3 é apresentado um exemplo do processo de busca a partir de um conjunto de quatro (4) atributos, em que os círculos preenchidos de cor branca representam atributos não selecionados e os círculos preenchidos de cor preta representam atributos selecionados. A medida de importância permite decidir quais atributos são promissores para serem pintados de preto. Para isso, uma das abordagens consiste em calcular a correlação de cada atributo em relação à classe e a correlação entre atributos, de modo a encontrar atributos relevantes e redundantes, respectivamente. A orientação de busca indicará se o processo será da esquerda para a direita (*forward selection*) ou da direita para a esquerda (*backward elimination*), isto é, se inicialmente nenhum dos atributos é considerado importante ou se todos são considerados importantes, respectivamente; e a, estratégia de busca, indicará quais atributos são avaliados pela medida de importância.

No exemplo da Fig. 3 têm-se $16 = 2^4$ possíveis combinações, o que torna impraticável a aplicação de todas as combinações quando o número de atributos é muito alto, pois o crescimento do espaço de busca é exponencial em relação ao número de atributos. Por esse motivo, é necessário utilizar uma estratégia de busca eficiente. Duas estratégias comumente utilizadas são *Best First* e *Greedy Stepwise*.

Após a aplicação da seleção de atributos sob o conjunto CD, é construído o conjunto CD' descrito pelo mesmo número de exemplos que o conjunto CD, no entanto com menor quantidade atributos (espera-se um $m \ll 162$), isto é, descrito apenas pelos atributos considerados importantes, conforme a Tabela 2.

Nessa tabela, as linhas representam os exemplos, as colunas os atributos selecionados considerados importantes, sendo a última coluna correspondente à variável objetivo e cada $v'_{i,j}$, corresponde ao valor do atributo j para o exemplo i .

2.4. Etapa 4 – Construção de Modelos

Depois de realizada a seleção de atributos, e gerando o conjunto CD', é efetuada a construção de modelos de regressão. Aprendizado de Máquina – AM, ou *Machine Learning*, é uma subárea de pesquisa dentro da Inteligência Artificial, que tem como objetivo desenvolver métodos e ferramentas que permitam simular o processo de aprendizado e construção de sistemas com a capacidade de adquirir conhecimento

Tabela 3. Representação do conjunto CD', após a tarefa de seleção de atributos.

CD'	Atributos Seleccionados (A_1, A_2, \dots, A_m)	Classe
Exemplo 1	($v'_{1,1}, v'_{1,2}, \dots, v'_{1,m}$)	($v_{1,163}$)
Exemplo 2	($v'_{2,1}, v'_{2,2}, \dots, v'_{2,m}$)	($v_{2,163}$)
...
Exemplo n	($v'_{n,1}, v'_{n,2}, \dots, v'_{n,m}$)	($v_{n,163}$)

[12,13]. Para isso, os algoritmos de aprendizado utilizam de experiências anteriores, denominadas de exemplos, para reconhecer padrões e auxiliá-los em processos de tomada de decisão.

Esses algoritmos são classificados quanto à natureza do atributo-classe em algoritmos de classificação e regressão. Os primeiros consideram a classe como um valor nominal e os segundos consideram a classe como um valor numérico. Dentro dos algoritmos para classe numérica têm sido propostas diversas abordagens, dentre essas, redes neurais artificiais, regressão linear múltipla e as árvores de regressão, constituem algumas das técnicas mais utilizadas. A seguir são apresentadas cada uma dessas técnicas.

2.4.1. Redes Neurais Artificiais – RNA

Inspiradas na estrutura neural biológica humana, as RNAs possuem capacidade computacional adquirida por meio de aprendizado e generalização [14]. A questão do aprendizado está relacionada com a capacidade de adaptar os seus parâmetros (por exemplo, o peso das interconexões) à medida que interage com exemplos de treinamento; e a generalização com a capacidade de dar respostas coerentes para exemplos novos, não usados durante a etapa de treinamento [15].

As RNAs são constituídas de neurônios artificiais (unidades) e interconexões. Cada neurônio possui um vetor de valores de entrada $X=(x_1, x_2, \dots, x_d)$, associado a um vetor de pesos $W=(w_1, w_2, \dots, w_d)$, e uma função de ativação que gera uma resposta para o problema. Durante a etapa de treinamento da estrutura esses pesos são ajustados de modo a otimizar a qualidade das respostas (por exemplo, diminuindo o erro médio quadrático). Na Fig. 4(a) é apresentado um exemplo de RNA, constituída de cinco atributos de entrada, duas camadas e duas saídas e, na Fig. 4(b) é apresentada a estrutura de um neurônio artificial.

O algoritmo mais utilizado na literatura para otimizar a qualidade das respostas, ajustando os pesos das arestas, é o *backpropagation*, que é aplicado em 90% das aplicações industriais e comerciais [16].




Fig. 4. (a) Exemplo de RNA, com cinco atributos de entrada, duas camadas de neurônios artificiais e duas informações de saída; (b) representação de cada neurônio (Adaptada de [15]).

2.4.2. Regressão Linear Múltipla – RL

Consiste em uma abordagem proveniente da estatística que permite modelar a relação linear entre uma variável dependente e uma ou mais variáveis independentes. Nesse método a classe é considerada a variável dependente e, os atributos, as variáveis independentes. A partir disso, o algoritmo de construção da regressão linear ajusta os pesos para cada atributo de modo a minimizar um critério específico, como o erro quadrático médio ou o erro quadrático mediano.

Algumas abordagens mais utilizadas na área de aprendizado de máquina sugerem a utilização do critério de informação Akaike para selecionar modelos estatisticamente mais promissores [17,18]; e a utilização do erro quadrático mediano como critério de ajuste para reduzir a influência de possíveis *outliers* [19,20].

2.4.3. Árvores de Regressão

A indução de árvores de regressão consiste na combinação de algoritmos para construção de árvores de classificação (aplicada quando a classe é nominal) com a possibilidade de criar modelos de regressão linear nas folhas da árvore.

O algoritmo inicia-se pela quantificação do ganho de informação que cada atributo pode produzir no modelo, sendo escolhido aquele atributo que minimiza a variação do valor da classe. Assim, para cada atributo escolhido é criado um nó que divide os exemplos de treinamento em dois subconjuntos. Esse processo é repetido novamente com cada um dos subconjuntos. Posteriormente, o algoritmo realiza o processo de poda e, nesse processo, cria os modelos de regressão linear a partir dos exemplos contidos em cada folha (direita e esquerda) de cada nó [21,22]. Na Fig. 5 é apresentado um exemplo de árvore de regressão com quatro atributos de entrada x_1, x_2, \dots, x_4 e cinco regressões lineares RL_1, RL_2, RL_3, RL_4 e RL_5 , em que cada RL é uma função linear desses $f(x_1, x_2, \dots, x_4)$ e que determina o valor y da regressão.

2.5. Etapa 5 – Avaliação de Modelos

Após, os modelos construídos na etapa anterior são avaliados de acordo com a sua complexidade e a qualidade preditiva. Ambas as abordagens são descritas a seguir.

2.5.1. Complexidade

Uma das formas de mensurar a complexidade de um modelo consiste em quantificar o número de atributos que são utilizados para descrever modelo de regressão. Dado que um modelo é descrito por m_a atri-

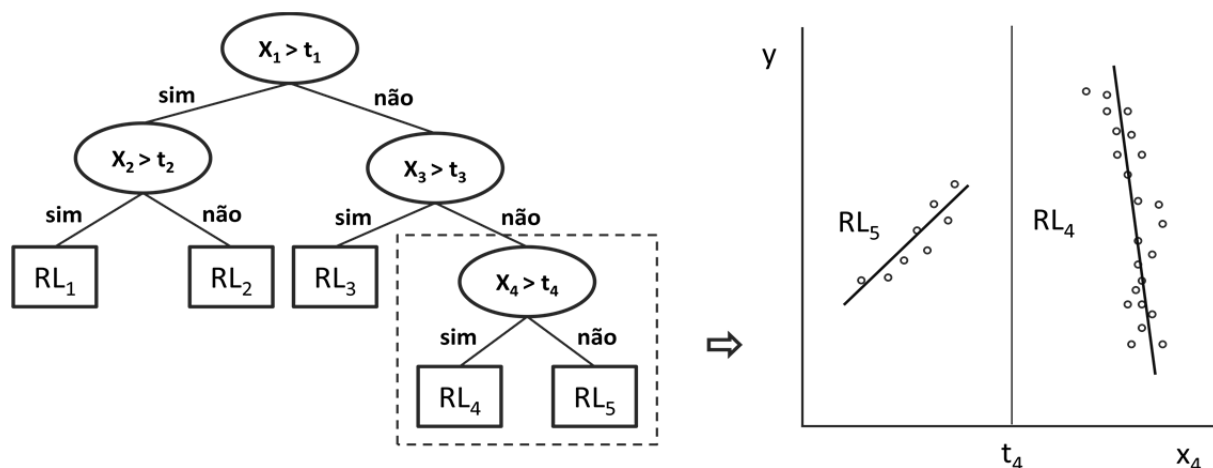


Fig. 5. (a) Exemplo de Árvore de Regressão com quatro atributos x_1, x_2, x_3 e x_4 e cinco regressões lineares RL_1, RL_2, RL_3, RL_4 e RL_5 ; (b) representação espacial da área tracejada na árvore.

butos, o mesmo possui a sua representação no espaço m_a -dimensional. Assim, um modelo é mais simples do que outro se pode ser representado em um espaço de menor dimensão, isto é, com menor número de atributos. De modo a avaliar a capacidade dos algoritmos de indução de modelos de encontrar modelos mais simples, pode ser analisado o número de atributos de entrada para os algoritmos, que possui relação com o custo em tempo para construir o modelo, bem como com o número de atributos que descrevem o modelo.

2.5.2. Qualidade Preditiva

Para quantificar a qualidade preditiva dos modelos construídos é utilizada a técnica de validação cruzada, que permite obter uma aproximação ao erro verdadeiro, isto é, o erro do modelo na previsão de dados que não foram utilizados durante a construção do modelo [19,22]. O método consiste em dividir o conjunto de dados em k amostras de tamanho igual, e criar k grupos constituídos da k -ésima amostra como conjunto de teste e as $(k-1)$ amostras restantes como conjunto de treinamento. Dessa forma, é construído um modelo para cada conjunto de treinamento e testado com o respectivo conjunto de teste. Com isso, a precisão do modelo construído é avaliada por meio de estatísticas descritivas baseadas em uma medida específica, por exemplo, o erro absoluto entre valor observado e valor previsto, nos k conjuntos de teste. Posteriormente, os modelos são comparados por meio de testes estatísticos com intervalo de confiança de 95%.

2.6. Configuração Experimental

O método apresentado foi aplicado em um conjunto de 41 jurados voluntários que realizaram a coleta de dados conforme descrito na Etapa 1. Os sinais reproduzidos pelo simulador consistem em sinais de excitação gravados em uma poltrona da parte central da aeronave. Os dados físicos coletados correspondem às frequências de vibração nos eixos x , y e z , totalizando assim 162 bandas de frequência (atributos) para os quatro adjetivos já mencionados, descritos numericamente pelo método de Escala Resposta.

Na Etapa 2 foram construídos os conjuntos de dados para cada adjetivo: conforto – CD_{conf} –, constância – CD_{cons} –, força – CD_{for} – e suportabilidade – CD_{sup} . Na Etapa 3, para efetuar a seleção de atributos em cada conjunto de dados, foi aplicada uma abordagem filtro com o algoritmo *Correlation-based Feature Selection* – CFS, que calcula a correlação de cada atributo em relação à classe e a correlação entre atributos [10]. A orientação e a estratégia da busca foram configuradas pelas técnicas *forward selection* e *Greedy Stepwise*, respectivamente. Assim, para o CD cada adjetivo aplicou-se o algoritmo CFS, disponibilizado pela ferramenta computacional WEKA [9], gerando um novo conjunto de dados CD' apenas com os atributos selecionados pelo algoritmo.

Na Etapa 4, para cada conjunto de dados, sem seleção de atributos – SS – e com seleção com o algoritmo CFS, foram construídos modelos utilizando as técnicas Redes Neurais Artificiais, Regressão Linear Múltipla e Árvores de Regressão, que também possuem implementações na ferramenta computacional WEKA. Para construir as RNA utilizou-se uma rede *Multilayer Perceptron* – MLP, e o algoritmo *back-propagation* para o ajuste dos pesos das conexões e valores de 0,3 e 500 para os parâmetros de taxa de aprendizado e número de ciclos treinamento, respectivamente. As Regressões Lineares foram construídas com o algoritmo *LinearRegression* – RL –, que utiliza o critério de Akaike para a seleção do modelo e a minimização do erro quadrático médio para o ajuste. E as Árvores de Regressão foram construídas com o algoritmo M5P, proposto em [21,22]. Na Etapa 5, os modelos foram avaliados de acordo com a complexidade e a qualidade preditiva.

3. RESULTADOS E DISCUSSÃO

Na Tabela 3 são apresentados os resultados da aplicação da etapa de seleção de atributos pelo algoritmo CFS e a redução, em porcentagem, do número de atributos em relação ao conjunto original de dados.

Por meio da tabela, é possível observar a redução da representação dos conjuntos de dados para os adjetivos conforto, consistência, força e suportabilidade, em que a maior redução ocorreu para o adjetivo constância, (98,15%) e a menor redução ocorreu para o adjetivo conforto (86,42%). Desse modo, cada

Tabela 4. Resultados da avaliação da complexidade.

Adjetivo	Sem Seleção – SS	Algoritmo de Seleção CFS	
	Atributos	Atributos	Redução
Conforto	162	22	86,42%
Constância	162	03	98,15%
Força	162	13	91,98%
Suportabilidade	162	06	96,30%




Fig. 6. Avaliação da qualidade preditiva dos modelos construídos.

problema de regressão inicialmente descrito no espaço de 162 dimensões poderá ser representado em um espaço substancialmente menor de dimensões. Durante a aplicação de técnicas de Aprendizado de Máquina para a construção de modelos, a seleção de atributos é uma tarefa fundamental, pois a complexidade de encontrar boas ou ótimas soluções cresce exponencialmente em relação ao número de atributos envolvidos na regressão. Tendo apenas os atributos considerados mais relevantes é possível explorar o espaço de soluções em busca de soluções mais precisas, com maior poder de generalização e, geralmente, descritas por um número menor de atributos. Além disso, a partir desses resultados é possível identificar e estudar as bandas de frequência que apresentam maior influência sob os diferentes adjetivos.

Na Fig. 6, são apresentados os resultados da avaliação da qualidade dos modelos construídos. Devido ao fato das distribuições de Erro Absoluto – EA – entre os valores previstos e observados ao longo do processo de validação cruzada não se apresentarem normalmente distribuídos foi realizada uma análise utilizando o diagrama de boxplot-and-whiskers, no qual os valores de previsão que ultrapassaram os limites da linha pontilhada foram considerados outliers e removidos.

Com relação à mediana do erro absoluto é possível observar que, quando aplicada a seleção de atributos pelo CFS: o algoritmo RL apresentou valor menor para todos os adjetivos; o algoritmo M5P apresentou menor valor para o adjetivo constância e semelhante para os outros; e o algoritmo MLP foi semelhante para o adjetivo constância e maior para os outros. Observando o valor máximo do intervalo interquartil

Tabela 5. Resultados da análise comparativa de modelos de classificação construídos pelas abordagens SS e CFS.

SS vs. CFS	Conforto			Constância			Força			Suportabilidade		
	<i>p</i> -valor	SR+	SR-	<i>p</i> -valor	SR+	SR-	<i>p</i> -valor	SR+	SR-	<i>p</i> -valor	SR+	SR-
MLP	0,4642	373	488	0,2854	514	347	0,0714	291	570	0,1555	320	541
LR	0,0779	567	294	<u>0,0006</u>	687	174	0,0630	575	287	<u>0,0045</u>	646	215
M5P	0,9693	427	434	<u>0,0009</u>	687	174	0,5462	311	392	0,6362	394	468

(que representa a dispersão de erros absolutos), é possível visualizar que, após aplicação do CFS: o algoritmo RL apresentou menor valor para todos os adjetivos; o algoritmo M5P apresentou menor valor para constância, semelhante para força e maior para conforto e suportabilidade; e o algoritmo MLP apresentou menor valor para conforto e constância e maior para força e suportabilidade. Em relação ao extremo máximo de erro absoluto, é possível verificar que, após aplicação do CFS: os algoritmos RL e MLP apresentaram valores menores; e o algoritmo M5P apresentou valor menor para o adjetivo constância e maiores para os outros.

Esses resultados mostram que, apesar da redução significativa de atributos ter representado a avaliação de cada jurado por um número substancialmente menor de bandas de frequência, não se observa de modo geral um deterioro dos modelos construídos pelos algoritmos, inclusive verifica-se que após a aplicação do CFS diversos valores de mediana, valor máximo do intervalo interquartil e extremo máximo foram menores.

No entanto, por meio dessa visualização não é possível observar a diferença entre os erros absolutos dos modelos de forma emparelhada. Devido ao fato do processo de validação cruzada ter sido aplicado para todos os casos na mesma ordem, é possível realizar uma análise comparativa de amostras dessa forma. Assim, para verificar a influência do processo de seleção de atributos na construção dos modelos foi realizado um estudo comparativo, apoiado pelo teste estatístico não paramétrico de Wilcoxon para amostras emparelhadas. O resultado do estudo é apresentado na Tabela 4, em que SR+ e SR- correspondem à soma dos rankings em que SS apresentou maior e menor erro absoluto, respectivamente. É importante avaliar esses dois parâmetros quando o *p*-valor evidencia diferença estatisticamente significativa (*p*-valor < 0,05), de modo a identificar qual abordagem apresentou melhor desempenho.

Nessa tabela, observa-se *p*-valor < 0,05 em três comparações, as quais estão indicadas pelo formato sublinhado. As diferenças estatisticamente significativas são constatadas no algoritmo LR para os adjetivos constância e suportabilidade e no algoritmo M5P para o adjetivo constância, não sendo possível evidenciar diferenças significativas nas outras comparações. Os parâmetros SR+ e SR- mostram que, para esses três casos o valor SR+ é, pelo menos, três vezes maior do que o SR-. Isso indica que além de ter sido constatado diferença estatisticamente significativa, verifica-se que a abordagem SS, apresentou maior erro absoluto. Com isso, a utilização de seleção de atributos pelo CFS, além de reduzir consideravelmente o número de atributos, apresentou melhora estatisticamente significativa em três casos, não sendo possível evidenciar essa característica para casos em que os valores de erro absoluto apresentaram-se maiores após a utilização de CFS.

Desse modo, apesar da abordagem de seleção atributos representar o problema de regressão com menor número atributos, foi constatado que os algoritmos de aprendizado de máquina utilizados na construção dos modelos conseguiram induzir alguns modelos de melhor qualidade e outros de qualidade semelhante, mas não pior. Isso pode ser explicado pelo fato de que a retirada de atributos irrelevantes e redundantes reduz a dimensão do espaço de busca de soluções, desse modo, possibilitando que sejam encontradas soluções de melhor qualidade.

4. CONSIDERAÇÕES FINAIS

Neste trabalho foi apresentado um estudo da aplicação de métodos e técnicas de Aprendizado de Máquina para construir modelos de regressão que possibilitem auxiliar em processos de tomada de decisão

associados à percepção de passageiros a estímulos vibratórios em aeronaves. Foram construídos modelos utilizando as abordagens de Redes Neurais Artificiais, Regressões Lineares Múltiplas e Árvores de Regressão. Além disso, foi avaliada a influência de uma etapa prévia à construção de modelos, denominada de Seleção de Atributos, por meio da qual é possível identificar atributos relevantes e não redundantes, e assim outorgar ao algoritmo de construção de modelos um conjunto de dados de melhor qualidade.

Os modelos foram avaliados e comparados de acordo com a complexidade e a precisão preditiva. Os resultados mostraram que a aplicação da seleção de atributos reduziu entre 86,42% e 98,15% o número de atributos nos conjuntos de dados dos quatro adjetivos (conforto, constância, força e suportabilidade), sem prejudicar a qualidade preditiva dos modelos construídos na etapa posterior. Inclusive, foi possível constatar que três dos doze modelos construídos apresentaram melhora estatisticamente significativa em relação à precisão preditiva, dada pela medida de erro absoluto. É importante ressaltar que a seleção de atributos permitiu identificar bandas de frequência que possuem maior relação com as votações do jurado, o que poderá auxiliar numa maior compreensão de vibrações específicas e/ou combinação delas que possuem maior relação com a sensação dos passageiros, mapeadas pelos quatro adjetivos.

Desse modo, a utilização de métodos e técnicas de Aprendizado de Máquina para previsão de respostas subjetivas a partir de dados referentes a estímulos vibratórios, permitiu construir modelos considerados promissores pelos especialistas, tanto em relação à complexidade, quanto à qualidade preditiva.

A partir desse trabalho será realizado o estudo mais aprofundado das bandas de frequência que apresentaram maior influência para cada adjetivo, de forma a investigar as fontes de geração dessas frequências e a relação das mesmas com o conforto dos passageiros. Outros trabalhos futuros incluem: a aplicação da abordagem *wrapper* para encontrar a combinação de atributos relevantes e não redundantes que podem levar a modelos mais promissores para cada algoritmo de construção de modelos específico e a construção de modelos regressão utilizando outras técnicas de Aprendizado de Máquina.

AGRADECIMENTOS

Ao pesquisador Eduardo Lucas Konrad Burin, doutorando do Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Santa Catarina – UFSC, pelas contribuições na revisão do artigo.

REFERÊNCIAS

- [1] Quehl, J., “Comfort studies on aircraft interior sound and vibration”, Tese de Doutorado, Universitat Oldenburg, Oldenburg, Alemanha (2001)
- [2] Schaefer, R.L., Bitencourt, R.F., Teixeira, J.A.M.S., Iturrieta, C.N., Gerges, S.N.Y., “Aircraft vibration perception in a laboratory situation”, *Proceedings of the International Congress of Mechanical Engineering (COBEM)*, Gramado, Brasil (2009)
- [3] Schaefer, R.L., Bitencourt, R.F., Gerges, S.N.Y., “Interferência da vibração no campo acústico em um simulador de aeronaves”, *Anais do Congresso da Academia Trinacional de Ciências*, Foz do Iguacu, Brasil (2009)
- [4] Schaefer, R.L., Bitencourt, R.F., Teixeira, J.A.M.S., Gerges, S.N.Y., “Aircraft vibroacoustic perception threshold in a laboratory situation compared to ISO 2631/1997 Standard”, *Proceedings of the International Congress and Exposition on Noise Control Engineering*, Lisboa, Portugal (2010)
- [5] Schaefer, R.L., “Estudo da resposta subjetiva a vibrações em aeronaves”, Dissertação de Mestrado, Universidade Federal de Santa Catarina, Florianópolis, Brasil (2011)
- [6] Bitencourt, R.F., “Desempenho de métodos na avaliação do conforto acústico no interior de aeronaves”, Tese de Doutorado, Universidade Federal de Santa Catarina, Florianópolis, Brasil (2008)
- [7] Bitencourt, R.F., Chamon, L.F.O., Futatsug, S., Yanagihara, J.I., Gerges, S.N.Y., “Preliminary results on the modeling of aircraft vibroacoustic comfort”, *Proceedings of the International Congress and Exposition on Noise Control Engineering*, New York, USA (2012)
- [8] Rohrmann, B., “Verbal qualifiers for rating scales: Sociolinguistic considerations and psychometric data”, Project Report, University of Melbourne, Melbourne, Australia (2003)

- [9] Witten, I., Frank, E., *Machine Learning: Practical Machine Learning Tools and Techniques*, Morgan Kaufmann, São Francisco, USA (2005)
- [10] Liu, H., Motoda, H., *Computational Methods of Feature Selection*, Chapman & Hall/CRC (2007)
- [11] Langley, P., “Selection of Relevant Features in Machine Learning”, *Proceedings of the AAAI Fall Symposium on Relevance*, 140-144 (1994)
- [12] Mitchell, T.M., *Machine Learning*, McGraw-Hill, New York, USA (1997)
- [13] Alpaydin, E., *Introduction to Machine Learning*, MIT Press (2004)
- [14] Haykin, S., *Neural Networks: a comprehensive foundation*, Prentice-Hall, 2 ed., Upper Saddle River, USA (1999)
- [15] Rezende, S.O., *Sistemas Inteligentes: Fundamentos e Aplicações*, Manole, Barueri, Brasil (2003)
- [16] Munakata, T., *Fundamentals of the New Artificial Intelligence: Neural, Evolutionary, Fuzzy, and More*, Springer, 2 ed. (2008)
- [17] Kundu, D., Murali, G., “Model selection in linear regression”, *Computational Statistics & Data Analysis*, **22**, 461-469 (1996)
- [18] Hastie, T., Tibshirani, R., Friedman, J., *The Elements of Statistical Learning*, Springer, 2 ed. (2009)
- [19] Rousseeuw, P.J., “Least Median of Square Regression”, *Journal of the American Statistical Association*, **79**(388), 871-880 (1984)
- [20] Hekimoglu, S., Erenoglu, R.C., Kalina, J., “Outlier detection by means of robust regression estimators for use in engineering science”, *Journal of Zhejiang University Science A*, 10(6), 909-921 (2008)
- [21] Quinlan, R.J., “Learning with Continuous Classes”, *Proceedings of the 5th Australian Joint Conference on Artificial Intelligence*, Singapore, 343-348 (1992)
- [22] Wang, Y., Witten, I.H., “Induction of model trees for predicting continuous classes”, *Proceedings of the 9th European Conference on Machine Learning*, 128-137 (1997)
- [23] Doria, U., *Introdução à Bioestatística: para simples mortais*, Elsevier, São Paulo, Brasil (1999)

MODELING OF AIRCRAFT VIBRATION COMFORT USING MACHINE LEARNING METHODS

Abstract – The increased competition in the aircraft market has motivated the aircraft industry to develop higher quality services for the customers. In this sense, an inter-institutional project has been developed for modeling passenger subjective responses related to adjectives (comfort, constancy, force, supportability) occasioned by physical stimuli vibrations on aircrafts simulators. In this work, it is used Computational Intelligence methods, specifically Machine Learning, to perform feature selection and to build regression models. In the feature selection task it was used a filter approach. Machine learning algorithms were used to build Artificial Neural Networks, Multiple Linear Regression and Regression Trees. The experimental method proposed aims to predict passenger subjective responses only considering most important frequency bands of vibratory stimuli according to each adjective. The model evaluation was performed based on predictive quality and complexity. It is shown that the proposed method allowed a reduction from 86.42% to 98.15% in the amount of used frequency bands to induce models without impairing the quality of predictions. In addition, 25% of the models showed statistically significant improvement. According to experts the built models were promising, both in terms of complexity and predictive quality.

Keywords – Aviation, Comfort, Artificial Intelligence, Attribute Selection.