

4

Inteligência Artificial em Motores de Combustão

4.1.

Levantamento do Estado da Arte

Os sistemas de inteligência artificial (IA) são aceitos extensamente como uma tecnologia que oferece um modo alternativo de abordar problemas complexos e pouco definidos. Podem-se mencionar os seguintes exemplos: O IA pode analisar dados ruidosos e incompletos, pode tratar problemas não-lineares, e uma vez treinado, o sistema de IA pode executar a previsão e a generalização do problema com um tempo computacional aceitável.

Os sistemas de inteligência artificial são usados em aplicações diversas: no controle e automação, na robótica, no reconhecimento de um teste padrão, na predição de dados, na medicina, nos sistemas de energia, na fabricação, na otimização, no tratamento dos sinais, nas ciências sociais e psicológicas e outros. É particularmente útil nos sistemas que modelam mapeamentos e realizam a identificação de sistemas complexos. Os sistemas de IA compreendem áreas como, sistemas peritos, redes neurais artificiais, algoritmos genéticos, lógica nebulosa e os vários sistemas híbridos, que combinam duas ou mais técnicas.

Com respeito à aplicação em motores de combustão, diferentes pesquisas com IA têm sido desenvolvidas para simular e otimizar processos de combustão de diferentes combustíveis. Também podem ser mencionados processos que utilizam os sistemas de IA para prever e minimizar emissões. Ainda existem trabalhos que utilizam IA para melhorar o controle eletrônico do processo de combustão. À continuação, são listados alguns trabalhos relacionados ao tema.

Kesgin (2004) desenvolveu um algoritmo genético e uma rede neural artificial para a otimização da eficiência e emissões de NO_x . Foi desenvolvido um programa de computador para calcular a quantidade de emissões de NO_x com base em um modelo de reação cinética. O mesmo foi validado através de medições em um motor turbo alimentado utilizando gás natural. Usando os

resultados deste programa, os efeitos dos parâmetros operacionais e de concepção do motor foram investigados. Utilizou-se um modelo de rede neural de múltiplas camadas e com o algoritmo de aprendizagem *Back-propagation*, no programa MATLAB, tendo como dados de entrada: Razão de equivalência, Pressão de carga, Temperatura de carga, Duração da combustão, Início da combustão e fator de forma. Oito neurônios foram utilizados na camada escondida. As saídas foram: Eficiência do motor e emissões de NO_x. A função de ativação utilizada foi a tangente hiperbólica sigmóide (tagsin) na camada escondida e tangente hiperbólica sigmóide (tagsin) na camada de saída. Para avaliar o erro foi utilizada a métrica de medição do erro MSE (erro médio quadrático). Por outro lado, realizou-se o processo de otimização com os parâmetros do motor (investigados anteriormente) utilizando um simples Algoritmo Genético (AG) onde se levou em conta os intervalos para cada dado de entrada, mantendo-se a restrição de uso em motores estacionários; encontrando-se o ponto ótimo de operação. Comparando os dois métodos de Algoritmos Genéticos (AG) e do modelo de Rede Neural (RN) os resultados em um ponto ótimo de operação mostraram que existe uma pequena diferença entre 0,05% e 0,38% para a eficiência e para emissões de NO_x respectivamente.

Parlak et al (2006) desenvolveram uma rede neural para a previsão do consumo específico de combustível e da temperatura de gases de escapamento em motores de ciclo Diesel. O modelo da rede neural utilizou o algoritmo de aprendizagem *Back-propagation* para prever o consumo específico de combustível e temperatura de gases de escape do motor Diesel em vários tempos de injeção. Os resultados foram comparados com valores experimentais, apresentando uma consistência entre os resultados da rede e os valores experimentais, logrando um MSE (Erro quadrático médio) médio de 2%. A rede teve três camadas: a primeira camada com os parâmetros de entrada: rotação do motor, pressão média efetiva e tempo de injeção; a camada intermediária com 07 neurônios e finalmente a camada de saída com dois neurônios: Consumo específico de combustível e temperatura dos gases de escapamento. Usou-se a função de ativação sigmóide (logsin) na camada escondida, e sigmóide (logsin) na camada de saída. Foi utilizado o erro médio quadrático, com valores de 1,93% no consumo específico de combustível e 2,36% na temperatura dos gases de escapamento.

Celik e Arcaklioglu (2004) desenvolveram mapas de desempenho de um motor diesel, onde propõem um modelo de rede neural para determinar as curvas constantes de consumo específico de combustível para motores diesel e, além disso, também predizer a taxa de equivalência ar-combustível e temperatura de escape. Dito modelo de rede neural usou o algoritmo de aprendizagem *Back-propagation*. A rede teve três camadas, sendo a primeira com os seguintes parâmetros de entrada: Temperatura de água resfriada, rotação do motor e potência do motor; a camada intermediária, com 03 e 05 neurônios e, finalmente, a camada de saída com três neurônios: Temperatura de escape, consumo específico de combustível e taxa de equivalência ar-combustível. Foi utilizada a função de ativação sigmóide (logsin) na camada escondida e sigmóide (logsin) na camada de saída. Como métricas de medição do erro foram empregados: MSE (erro médio quadrático), R^2 (Coeficiente de determinação) e MAPE (Erro médio absoluto porcentual). Como resultados foram encontrados os erros MSE de 0,010592, MAPE de 2,0134% e R^2 de 0,999511 para o consumo específico de combustível; com MSE de 0,026127, MAPE de 3,375806% e R^2 de 0,996925 para taxa de equivalência ar-combustível e finalmente um MSE de 0,03, MAPE de 5,24% e R^2 de 0,99 para a temperatura dos gases de escapamento.

Canakci et al (2005) desenvolveram o trabalho sob o desempenho e emissões de gases de escape de motores biodiesel, propondo um modelo de rede neural para avaliar o desempenho e emissões de gases de escapamento em motores diesel utilizando diesel e biodiesel de diferentes procedências. Resultados experimentais (desempenho do motor diesel e emissões de gases de escapamento) foram utilizados para treinar a rede. Dois tipos diferentes de diesel (Nro. 01 e Nro. 02), foram avaliados. Para o biodiesel foi utilizado óleo de soja com “yellow grease”. Esta combinação foi misturada (20%) com o combustível diesel Nro. 02. Dito modelo de rede neural usou o algoritmo de aprendizagem *Back-propagation* e a rede teve três camadas: a primeira camada com os parâmetros de entrada: peso médio molecular, calor neto de combustão, gravidade específica, viscosidade cinemática, proporção C/H e número de cetano de cada combustível; a camada intermediária, com 07 neurônios, e, finalmente, a camada de saída com sete neurônios: consumo específico de combustível, temperatura do coletor de escape e emissões de gases de escapamento (O_2 , CO, CO_2 , HC e NO_x). Usou-se a função de ativação sigmóide (logsin) na camada escondida e sigmóide (logsin) na camada de saída. Como

métrica de medição do erro, RMS (raiz do erro quadrático médio), R^2 (Coeficiente de determinação) e o MEAN%ERROR (Maximo e médio erro porcentual). Encontrando-se os erros RMS entre 0,004 e 0,0007; R^2 de 0,99 (para todas as variáveis) e MEAN%ERROR entre 0,10 e 1,2. Os valores mais elevados de erro foram obtidos para o cálculo do CO_2 .

Serdar et al (2006), fizeram um estudo comparativo numérico e experimental do desempenho nos motores de ignição por vela usando misturas de combustível etanol – gasolina. O estudo consistiu em dois casos. O primeiro envolvendo testes com combustível etanol – gasolina. Nesta primeira etapa foi variado o tempo de ignição, a razão ar-combustível, e a razão de compressão, tudo para uma rotação constante de 2000 RPM e diferentes porcentagens de carga. Os dados de saída foram o torque do motor e o consumo específico de combustível, comparados com os dados experimentais. O segundo caso foi proposta uma rede neural que pudesse determinar o torque e o consumo específica de combustível do motor, tendo como dados de treinamento os resultados da primeira rede utilizada. Este modelo de rede neural usou o algoritmo de aprendizagem *Back-propagation*. A rede teve três camadas: a primeira com os parâmetros de entrada: massa específica, tempo de ignição, razão ar-combustível e razão de compressão; a camada intermediária com 05 neurônios e, finalmente, a camada de saída com dois neurônios: torque do motor e consumo específico de combustível. Usou-se a função de ativação sigmóide (logsin) na camada escondida, e sigmóide (logsin) na camada de saída. Como métrica de medição do erro: RMS (raiz do erro médio quadrático), R^2 (Coeficiente de determinação) e o MAPE (Erro médio absoluto porcentual). Encontrando-se os erros RMS de 0,010, R^2 de 0,99 e MAPE de 1,13% para o torque do motor, e RMS de 0,015, R^2 de 0,99 e MAPE de 2,05% para o consumo específico de combustível.

Wu et al (2007) desenvolveram um sistema experto para o diagnóstico de falhas no motor de combustão interna usando um modelo de redes neurais probabilísticas. O sistema proposto foi dividido em duas partes. a primeira parte ,para a gravação dos sinais do motor, os quais são tratados como pistas de variação de frequência de sinais de banda. Logo foram calculadas as amplitudes com o algoritmo de filtro de alta resolução adaptativa e, finalmente, diagramas de energia do som são utilizados para normalizar as características e reduzir o tempo computacional necessário. Na segunda etapa foram modeladas redes

neurais: probabilística (PNN), *Back-propagation* (BP) e Função Radial Básica (RBF) para classificação, com o treinamento das características dos sinais e condições de falha do motor, respectivamente. Os resultados apresentam razões de reconhecimento médio de 93,79% para a rede Backpropagation (BP), 95,08% para a rede de Função Radial Básica (RBF) e finalmente de 95,73% para a rede probabilística (PNN).

Sayin et al (2007) desenvolveram um trabalho para avaliar o desempenho e emissões dos gases de escapamento de um motor da gasolina usando uma rede neural artificial. Os dados experimentais analisados foram: o consumo específico de combustível, eficiência térmica, temperatura dos gases de escapamento e as emissões. O motor do ciclo Otto analisado trabalhou com diferentes tipos de gasolina, de octanagem de 91; 93; 95; e 95,3 respectivamente, operado com diferentes rotações e torques. O modelo de rede neural usou o algoritmo de aprendizagem *Back-propagation*. A rede teve três camadas: a primeira camada com os parâmetros de entrada: poder calorífico inferior do combustível, torque, rotação do motor e temperatura do ar de entrada; a camada intermediária com 15 neurônios e finalmente a camada de saída com nove neurônios: consumo específico de combustível, eficiência térmica, emissões de CO, emissões de HC e temperatura de gases de escapamento. Usou-se a função de ativação tangente hiperbólica sigmóide (tagsin) na camada escondida e tangente hiperbólica sigmóide (tagsin) na camada de saída. Como métrica de medição do erro: MRE (erro médio relativo), R (Coeficiente de correlação) e o RMSE (Raiz do erro quadrático médio). Encontrando-se os erros MRE de 2,24%, R de 0,99; o RMSE entre 0,04% e 2,96; o MRE entre 1,41% e 3,64%.

Nasr et al (2003) desenvolveram um modelo de rede neural *Back-propagation* para o consumo de gasolina, para prever o consumo futuro na cidade de Lebanom (França), além disso, a rede neural interpola a quantidade de consumo de combustível, o qual é determinado por um conjunto de dados de treinamento. Neste estudo foram realizados quatro modelos de redes neurais: a primeira rede neural está baseada nos dados do consumo de gasolina provenientes de um histórico, a segunda na série de tempo do consumo de gasolina e preço, a terceira no consumo de gasolina e o registro de carros e, finalmente, a quarta que combina o consumo de gasolina, preço e registro de carros. Todas têm como métrica de medição do erro o MSE (Erro quadrático

médio) e o MAD (Desvio médio absoluto). Os modelos de redes neurais usaram o algoritmo de aprendizagem *Back-propagation* e a rede teve três camadas. O primeiro modelo de rede neural uni-variado tem a primeira camada com quatro parâmetros de entrada de consumo de gasolina; a camada intermediária com 03 neurônios e finalmente a camada de saída tem só uma saída: consumo de gasolina. Foi utilizada a função de ativação sigmóide (logsin) na camada escondida e sigmóide (logsin) na camada de saída, encontrando-se os erros MSE de 778,6, e MAD de 22,6 para o consumo gasolina. O segundo modelo de rede neural multivariado tem a primeira camada com sete parâmetros de entrada: quatro quantidades de consumo de gasolina e três quantidades de preços; a camada intermediária tem 05 neurônios: 02 neurônios escondidos conectados aos neurônios de entrada de preços e 03 neurônios escondidos conectados aos neurônios de entrada de consumo de gasolina e finalmente a camada de saída tem só uma saída: consumo de gasolina. Foram usadas a função de ativação sigmóide (logsin) na camada escondida e sigmóide (logsin) na camada de saída, encontrando-se os erros MSE de 757,9 e MAD de 22,3 para o consumo gasolina. O terceiro modelo de rede neural multivariado tem a primeira camada com sete parâmetros de entrada: quatro quantidades de consumo de gasolina e três quantidades de registro de carros; a camada intermediária tem 03 neurônios: 02 neurônios escondidos conectados aos neurônios de entrada de consumo de gasolina e 01 neurônio escondido conectados aos neurônios de registro de carros e finalmente a camada de saída tem só uma saída: consumo de gasolina. Usou-se a função de ativação sigmóide (logsin) na camada escondida e sigmóide (logsin) na camada de saída, encontrando-se os erros MSE de 686,4 e MAD de 21,4 para o consumo gasolina. Finalmente o quarto modelo de rede neural multivariado tem a primeira camada com dez parâmetros de entrada: três quantidades de preços, quatro quantidades de consumo de gasolina e três quantidades de registro de carros; a camada intermediária tem 06 neurônios: 02 neurônios escondidos conectados aos neurônios de entrada do preço; 02 neurônios escondidos conectados aos neurônios de consumo de gasolina e 02 neurônios escondidos conectados aos neurônios de registro de carros e finalmente a camada de saída tem só uma saída: consumo de gasolina. Usou-se a função de ativação sigmóide (logsin) na camada escondida e sigmóide (logsin) na camada de saída, encontrando-se os erros MSE de 594,7 e MAD de 19,5 para o consumo gasolina.

Lucas et al (2001) desenvolveram um modelo com redes neuronais para analisar as emissões de material particulado para um motor de ciclo diesel. Foram feitos testes com 08 diferentes combustíveis sob cinco condições estáveis operacionais num típico automóvel de passageiros europeu de motor diesel. As frações solúveis e insolúveis foram analisadas utilizando alta cromatografia líquida. A influência dos parâmetros da composição do combustível (teor aromático, índice de cetano, potência de calor total, conteúdo de nitrogênio e enxofre) sobre as emissões de partículas foi estudada e os dados foram ajustados em condições de operação (torque e rotação do motor), usando redes neurais. O modelo matemático reproduz dados experimentais dentro de 87-90% de confiança e permite a simulação das emissões em condições estáveis para qualquer valor dos parâmetros no intervalo experimental. O software também permite a completa estimativa de emissões de um único modo de funcionamento ou para um ciclo completo, incluindo a composição de sulfatos, nitratos e água (ou fração delas). O consumo de combustível e de ar também é estimado a partir de integração.

Najafi et al (2009) desenvolveram um trabalho para avaliar o desempenho e emissões dos gases de escapamento de motores de ciclo Otto usando redes neurais. Essa proposta analisou o desempenho e as emissões dos poluentes dos motores de ignição por velas que operam com mistura de gasolina e etanol (0%, 5%, 10%, 15% e 20%). O modelo de rede neural usou o algoritmo de aprendizagem *Back-propagation* e a rede teve três camadas. A primeira camada com os parâmetros de entrada: rotação do motor e porcentagem de mistura de etanol-gasolina; a camada intermediária com 20 neurônios e finalmente a camada de saída com nove neurônios: potência, torque, consumo específico de combustível, eficiência térmica, eficiência volumétrica, emissões de CO, emissões de HC, emissões de CO₂ e emissões de NO_x. Usou-se a função de ativação sigmóide (logsin) na camada escondida e linear (purelin) na camada de saída e como métrica de medição do erro MRE (erro médio relativo), R (Coeficiente de correlação) e o RMSE (Raiz do erro quadrático médio). Foram determinados erros MRE entre 0,46% e 5,57%, R de 0,99% (para todos eles), sendo o caso crítico as emissões de NO_x.

Gölcü et al (2005) desenvolveram um modelo baseado numa rede neural artificial de sincronização das válvulas (escape/admissão) em motores de ignição por vela, cujos parâmetros de operação e desenho afetam no desempenho e

emissões. Usaram-se redes neurais artificiais para determinar o efeito das entradas sincronizadas das válvulas no desempenho e economia do combustível. O modelo de rede neural usou o algoritmo de aprendizagem *Back-propagation*. A rede teve três camadas: a primeira camada com os parâmetros de entrada: sincronização das válvulas e rotação do motor; a camada intermediária com 15 neurônios, e finalmente a camada de saída com dois neurônios: torque e consumo específico de combustível. Usou-se a função de ativação sigmóide (logsin) na camada escondida e linear (purelin) na camada de saída e como métrica de medição do erro RMSE (Raiz do erro quadrático médio), R^2 (Coeficiente de determinação) e MAPE (erro médio absoluto porcentual). Encontrando-se os erros RMSE de 0,90 Nm, R^2 de 0,99 e MAPE de 7,26% para o torque do motor, e para o segundo um RMSE de 0,2860 kg/h, R^2 de 0,93 e MAPE de 7,55% para o consumo específico de combustível.

Choi, e Chen (2005) desenvolveram um modelo de previsão rápida do início da combustão em um motor que utiliza a tecnologia HCCI (ignição por compressão de uma carga homogênea) combinado com a rede neural artificial e um modelo de atraso da ignição. Apesar das muitas características vantajosas do motor, o controle do início da combustão continua sendo um desafio para aplicações práticas. Um modelo rápido e exato para o início da combustão pode ser útil para o desenvolvimento de estratégias de controle do desempenho do motor HCCI. A ideia é treinar uma rede neural para o atraso da ignição e uni-la a uma rede neural com um modelo semi-empírico, isto para fornecer um rápido e confiável modelo para controlar o início da combustão. Dito modelo de rede neural usou o algoritmo de aprendizagem *Back-propagation*. A rede teve três ou quatro camadas: a primeira com os parâmetros de entrada: temperatura de entrada, pressão de entrada, razão de equivalência e a recirculação dos gases de escapamento. A camada de saída teve só um neurônio: atraso da ignição. Usou-se a função de ativação de desconhece na camada escondida também na camada de saída e, como métrica de medição do erro médio como métrica. Encontrando-se o erro médio de 2,4% obtido com 200 épocas e com um número de 20 neurônios na camada escondida.

4.2. Posicionamento do trabalho e Objetivos

Nos trabalhos até agora pesquisados pode-se observar que o uso de redes neurais e algoritmos genéticos são amplamente usados para avaliar e melhorar o desempenho de motores, tanto do ciclo Otto, como do ciclo diesel. As estratégias utilizadas variam segundo cada caso, mas, em termos gerais, os resultados indicam que o uso da Inteligência Artificial (IA) é uma boa ferramenta de previsão e de otimização do processo térmico no motor de combustão. Porém, os casos avaliados até hoje, envolvem o uso de um só combustível ou o uso de misturas de combustíveis líquidos. Não se tem referência de trabalhos de pesquisa que avaliem o uso de diesel-gás natural como combustível. Também não foram observados casos que otimizem todos os parâmetros de desempenho (emissões dos gases de escapamento, temperatura dos gases, eficiência térmica, taxa de substituição, etc.).

4.3. Objetivos

- Utilizar as técnicas dos sistemas de Inteligência Artificial para melhorar o desempenho em motores que utilizam como combustível uma mistura de diesel e gás natural de 107 kW de potência.
- Implementar um modelo de predição de dados para definir completamente o mapa de desempenho do motor em qualquer condição de trabalho, dentre dos limites estabelecidos pelos testes experimentais.
- Implementar um modelo de otimização de dados para determinar os parâmetros ótimos em cada condição de funcionamento do motor, onde as variáveis a serem maximizadas são a taxa de substituição e a eficiência térmica, e as variáveis a serem minimizadas são as emissões dos diferentes gases de escapamento.