

Modelagem Substituta para Avaliação de Parâmetros Aerodinâmicos em Otimização Multidisciplinar

Livia C. Andrade¹, Maurício M. Andrade¹

¹Universidade Federal da Grande Dourados
Dourados, MS – Brasil

livia.andrade073@academico.ufgd.edu.br, mauricio.menean@gmail.com

Resumo. A aplicação de um processo de Otimização Multidisciplinar (MDO) no projeto preliminar de aeronaves exige um grande número de avaliações aerodinâmicas, tornando ferramentas tradicionais (como XFOIL ou CFD) um gargalo devido ao alto custo computacional e falhas de convergência. Este artigo apresenta modelos substitutos de aprendizado de máquina (Superfícies de Resposta Polinomial, Kriging e Redes Neurais Artificiais), como alternativa às simulações convencionais, para prever determinados parâmetros aerodinâmicos relevantes. Os resultados indicam que os modelos substitutos aceleram o tempo de inferência em ordens de grandeza em relação ao XFOIL, mantendo alta precisão preditiva e viabilizando ciclos de otimização mais amplos e robustos.

Abstract. The employment of Multidisciplinary Optimization for the preliminary design of aircraft requires numerous iterations of aerodynamical analysis, making traditional tools (XFOIL or CFD) a relevant bottleneck for their high computational cost and convergence issues. This paper presents machine learning models (Polynomial Response Surfaces, Kriging and Artificial Neural Networks), as an alternative to conventional simulations, to predict predetermined aerodynamical characteristics. The results indicate that the surrogate models speed up inference time by orders of magnitude, retaining predictive accuracy and allowing broader optimization cycles.

1. Introdução

O projeto conceitual e preliminar de aeronaves é um processo inerentemente iterativo que exige a integração de diversas disciplinas, como aerodinâmica, estruturas e desempenho de voo. Para alcançar soluções ótimas, se faz necessário recorrer a técnicas de Otimização Multidisciplinar (MDO - *Multidisciplinary Design Optimization*).

Para realizar um ciclo de MDO, são necessárias milhares a milhões de iterações. De modo a permitir a otimização geométrica de perfis de asa, os parâmetros aerodinâmicos precisam ser reavaliados em cada uma destas iterações [Martins and Lambe 2013]. O uso de métodos convencionais para a obtenção destes resultados, como o método dos painéis (presente no XFOIL [Drela 1989]) ou simulações de fluidodinâmica computacional (CFD), impõe um severo gargalo de desempenho. Além de serem computacionalmente custosos, esses métodos frequentemente apresentam descontinuidades e falhas de convergência numérica, especialmente em regimes de escoamento próximos ao estol, o que compromete a eficiência de algoritmos de otimização [Forrester et al. 2008].

Diante deste desafio, este artigo apresenta um estudo de modelos substitutos (*surrogate models*) como alternativa aos solvers aerodinâmicos tradicionais no *loop* de otimização.

1.1. Objetivo

O objetivo principal deste trabalho é construir, treinar e avaliar três estruturas de modelo substituto (Superfícies de Resposta Polinomial, Kriging e Redes Neurais Artificiais), para que sejam capazes de prever com precisão e eficiência alguns parâmetros aerodinâmicos de aerofólio fundamentais. Os parâmetros de saída pré-determinados são: coeficiente de sustentação máximo (CL_{max}), arrasto no CL_{max} ($CD@CL_{max}$), momento no CL_{max} ($CM@CL_{max}$), ângulo de sustentação máxima ($\alpha_{CL_{max}}$), coeficiente de arrasto mínimo (CD_{min}), sustentação no CD_{min} ($CL@CD_{min}$), momento no CD_{min} ($CM@CD_{min}$), ângulo de arrasto mínimo ($\alpha_{CD_{min}}$) e gradiente da curva de sustentação ($\frac{dCL}{d\alpha}$).

Considerando qualquer perfil aerodinâmico base definido, a metodologia apresentada visa a construção de um modelo substituto capaz de avaliar as características aerodinâmicas de variações geométricas de tal perfil. Após a escolha do perfil-base, um modelo substituto pode ser gerado através de poucos milhares de amostras. Assim, é possível integrar a geometria do aerofólio como variável otimizada dentro de um fluxo de Otimização Multidisciplinar (MDO), onde milhares a milhões de variações geométricas serão avaliadas.

2. Fundamentação Teórica

Neste trabalho, avaliamos três abordagens com características computacionais distintas: Superfícies de Resposta Polinomiais, Kriging e Redes Neurais Artificiais.

2.1. Superfícies de Resposta Polinomiais (PRS)

As Superfícies de Resposta Polinomiais (PRS - *Polynomial Response Surfaces*) são modelos de regressão global que utilizam polinômios, tipicamente de segunda ordem, para aproximar a função objetivo [Forrester et al. 2008]. Embora apresentem custo de treinamento e tempo de inferência ínfimos, as PRS possuem baixa flexibilidade para capturar comportamentos não-lineares, situação comum na aerodinâmica de perfis.

2.2. Kriging (Regressão de Processos Gaussianos)

O Kriging, ou Regressão de Processos Gaussianos (GPR), é um método de interpolação estocástica que assume que os dados observados são realizações de um processo Gaussiano. Diferente de uma regressão polinomial global, o Kriging modela a resposta como uma combinação de um modelo de tendência global e um desvio local sistemático [Rasmussen and Williams 2006]. A predição do Kriging em um ponto não amostrado x é dada pela Equação 1:

$$\hat{y}(x) = f(x)^T \beta + Z(x) \quad (1)$$

Em que:

- $f(x)^T \beta$ representa o modelo de tendência (geralmente uma constante ou polinômio de baixa ordem), onde β é o vetor de coeficientes.

- $Z(x)$ é um processo estocástico Gaussiano com média zero e variância σ^2 , cuja covariância espacial é controlada por uma função de correlação (ou *kernel*).

O Kriging é amplamente adotado em engenharia devido a duas vantagens principais para otimização:

1. **Interpolação Exata:** Na ausência de ruído, o modelo prediz exatamente os valores das respostas nos pontos de treinamento originais.
2. **Estimativa de Incerteza:** O modelo fornece não apenas o valor predito $\hat{y}(x)$, mas também a incerteza estatística (variância) associada a essa predição, permitindo que algoritmos de MDO explorem de forma inteligente áreas do domínio com alta incerteza.

Computacionalmente, o desafio do Kriging reside no treinamento, que envolve a inversão de uma matriz de covariância de dimensão $N \times N$ (onde N é o número de amostras), resultando em uma complexidade de tempo de $O(N^3)$.

2.3. Redes Neurais Artificiais (Perceptron de Múltiplas Camadas)

As Redes Neurais Artificiais, especificamente a arquitetura *Multilayer Perceptron* (MLP), são modelos de aprendizado de máquina inspirados em sistemas biológicos. Uma MLP consiste em camadas de neurônios artificiais: uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída [Haykin 2009]. A transformação matemática realizada por um único neurônio j em uma camada oculta é definida na Equação 2:

$$h_j = \phi \left(\sum_{i=1}^n w_{ij}x_i + b_j \right) \quad (2)$$

Em que:

- h_j é o sinal de saída do neurônio j .
- x_i são os sinais de entrada provenientes da camada anterior.
- w_{ij} são os pesos sinápticos associados a cada conexão.
- b_j é o termo de viés (*bias*).
- $\phi(\cdot)$ é uma função de ativação não-linear (como ReLU, Sigmoid ou Tangente Hiperbólica), que confere à rede a capacidade de mapear relações complexas.

No contexto de avaliação de desempenho, os MLPs apresentam características opostas ao Kriging. O treinamento de um MLP requer ajuste de hiperparâmetros (número de camadas, neurônios e taxa de aprendizado) e exige grandes conjuntos de dados. Contudo, uma vez treinado, a fase de inferência é computacionalmente barata, apresentando complexidade $O(W)$, onde W é o número total de pesos. Isso torna a inferência de MLP ordens de grandeza mais rápida que a avaliação do *solver* aerodinâmico ou até mesmo do Kriging, sendo ideal para MDO.

3. Metodologia

O desenvolvimento dos modelos substitutos foi estruturado em cinco etapas principais: parametrização geométrica, amostragem no espaço de busca, simulação automatizada, pré-processamento dos dados e treinamento dos algoritmos de aprendizado de máquina. Tratando-se de um problema de regressão multi-objetivo, os parâmetros de saída são

independentes: o treinamento dos modelos é exclusivo para cada parâmetro, gerando uma instância correspondente a cada saída.

O espaço de atuação dos modelos foi restringido, abrangendo apenas variações paramétricas de um perfil aerodinâmico previamente selecionado. Assim, pôde ser reduzida a dimensionalidade do problema e elevada a densidade de amostras na região de interesse. Em detrimento da capacidade de avaliar qualquer geometria arbitrária, a limitação garante a precisão local dos modelos e a viabilidade do treinamento para otimizar uma família específica de perfis.

3.1. Parametrização Geométrica

Tendo em vista o interesse de restringir o espaço de busca às variações de um perfil base, são aplicadas perturbações controladas à geometria de um perfil previamente definido (neste caso, o Selig S1223). A geometria do perfil foi parametrizada utilizando quatro variáveis fundamentais, expressas em percentual da corda, em conjunto com uma variável de condição de escoamento:

- Espessura máxima (t_{max}).
- Posição longitudinal da espessura máxima (x_t).
- Arqueamento máximo, ou *camber* (c_{max}).
- Posição longitudinal do arqueamento máximo (x_c).
- Logaritmo na base 10 do Número de Reynolds ($\log_{10}(Re)$).

Métodos foram implementados para recalcular e gerar as coordenadas de um novo perfil a partir das variações destes quatro parâmetros geométricos aplicadas ao perfil base. A forma original do perfil, comumente representada por pontos (x, y) , é convertida para uma parametrização em espessura (t) e arqueamento (c), de modo que:

$$\begin{aligned} y_u &= c + \frac{1}{2}t \\ y_l &= c - \frac{1}{2}t \end{aligned} \tag{3}$$

Onde y_u e y_l são coordenadas y da superfície superior e inferior do perfil, respectivamente.

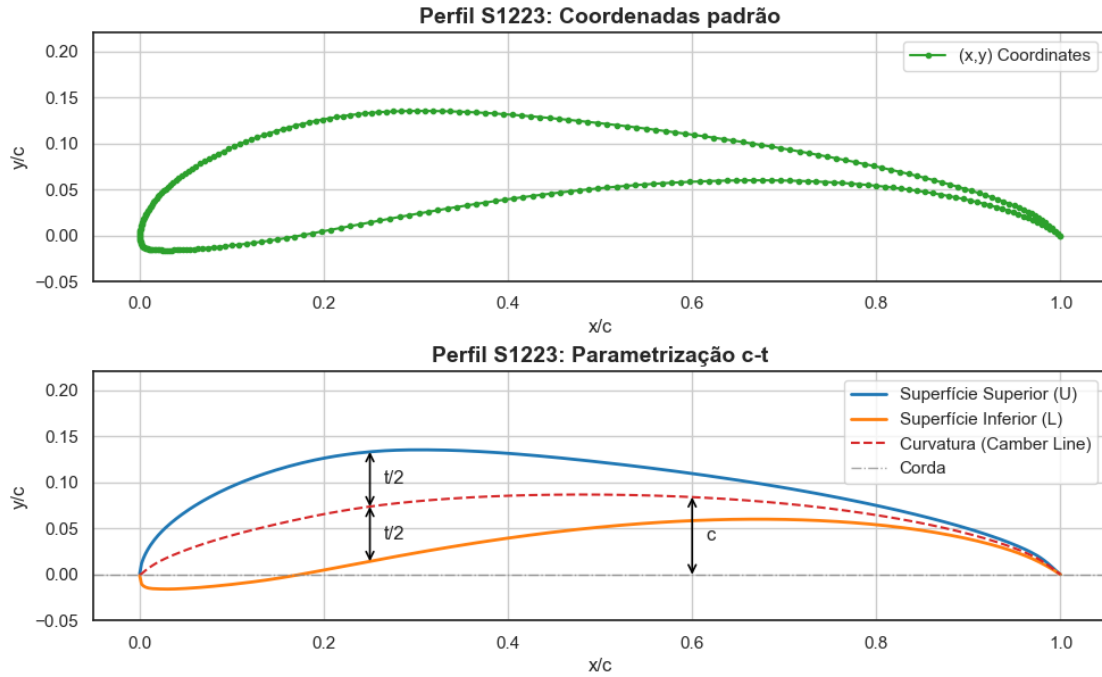


Figura 1. Parametrização do perfil em espessura e arqueamento

As posições de espessura máxima (x_t) e arqueamento máximo (x_c) são ajustadas para os novos perfis remapeando os parâmetros c ou t através de um interpolador *PCHIP*. Esse método garante que as posições resultantes sejam exatamente as desejadas, enquanto a deformação é suavemente distribuída ao longo do perfil e os extremos são mantidos fixos. Os valores absolutos de arqueamento máximo (c_{max}) e espessura máxima (t_{max}) são alterados aplicando uma escala aos parâmetros finais.

$$\mathbf{t}' = \frac{t'_{max}}{t_{max}} \cdot p_2(p_1(\mathbf{x})) \quad (4)$$

$$p_1(x) : (0, x'_t, 1) \mapsto (0, x_t, 1) \quad (5)$$

$$p_2(y) : \mathbf{x} \mapsto \mathbf{t} \quad (6)$$

- \mathbf{t} - vetor de espessura do perfil original
- \mathbf{t}' - vetor de espessura do perfil resultante
- \mathbf{x} - vetor de coordenadas x do perfil
- t_{max} - espessura máxima do perfil original
- t'_{max} - espessura máxima do perfil resultante
- x_t - posição da espessura máxima do perfil original
- x'_t - posição da espessura máxima do perfil resultante
- p_1 e p_2 - interpoladores (mapeamento)

3.2. Amostragem de Dados (*Design of Experiments*)

A construção de um conjunto de treinamento robusto exige uma exploração eficiente do espaço de entrada de cinco dimensões. Utilizou-se a técnica de Amostragem por

Hipercubo Latino (LHS - *Latin Hypercube Sampling*) para gerar um espaço amostral de aproximadamente 3000 instâncias. O método LHS garante que cada dimensão do domínio seja particionada e amostrada uniformemente, prevenindo o agrupamento excessivo de pontos [Myers et al. 2016]. Os limites para os quatro parâmetros geométricos foram definidos em 10% de variação acima e abaixo dos valores nominais do perfil original.

3.3. Simulação e Extração Automatizada (XFOIL)

As geometrias geradas pelo LHS foram submetidas a uma rotina de avaliação aerodinâmica utilizando o *solver* XFOIL. Scripts foram implementados para gerenciar a execução das seguintes tarefas:

1. Definição das coordenadas geométricas para cada amostra gerada.
2. Execução do XFOIL realizando varreduras do ângulo de ataque (α) para construir as curvas de coeficiente de sustentação (C_L), arrasto (C_D) e momento (C_M).
3. Extração dos parâmetros de saída alvo através de algoritmos que garantam robustez a ruído e variações no comportamento dos perfis.

Nesta etapa, o principal desafio consistiu em tratar as falhas de convergência inerentes ao método dos painéis do XFOIL, especialmente em ângulos de ataque próximos à região de estol.




Figura 2. Curvas típicas de coeficientes aerodinâmicos com parâmetros relevantes identificados

O coeficiente de sustentação máxima e o coeficiente de arrasto mínimo foram obtidos através do operador de *Boltzmann*, que é uma função de máximo contínuo robusta a possíveis ruídos numéricos. Além disso, este operador em específico garante resultados conservadores, retornando valores estritamente dentro dos limites dos dados originais. Os parâmetros correspondentes (α , CL , CD e CM) em (CL_{max}, CD_{min}) são então obtidos de maneira equivalente utilizando os pesos (distribuição de probabilidades) calculados durante aplicação do operador.

$$z_{max} = \mathbf{z} \cdot \boldsymbol{\sigma}(\mathbf{z}') \quad (7)$$

$$k_{@z_{max}} = \mathbf{k} \cdot \boldsymbol{\sigma}(\mathbf{z}') \quad (8)$$

$$\boldsymbol{\sigma}(\mathbf{z}')_i = \frac{e^{\omega z'_i}}{\sum_{j=1}^n e^{\omega z'_j}}, \quad z'_i = z_i - \max(\mathbf{z}) \quad (9)$$

Onde z é a variável de interesse (CL ou CD) e k o parâmetro correspondente (α , CL , CD ou CM). O operador $\boldsymbol{\sigma}$ representa a "distribuição de Boltzmann", ω um parâmetro de sensibilidade (quando ω aumenta, o resultado se aproxima do máximo real), e z' um deslocamento da variável original (garante computabilidade). Para obter um valor mínimo com este operador, é atribuído um valor negativo a ω e $z'_i = -(z_i - \min(\mathbf{z}))$.

Para identificar o gradiente de CL na região linear da curva, primeiramente são preenchidos os pontos não simulados e não convergidos para se obter uma grade uniforme de α . A interpolação dos dados faltantes é realizada através de um interpolador *PCHIP*. Um algoritmo de busca então encontra a janela em CL vs α onde os dados são mais lineares (maior R^2) e retorna o gradiente e previsão de α para $CL = 0$.

3.4. Pré-processamento e Limpeza de Dados

A integração das etapas anteriores resultou em um banco de dados bruto contendo a relação entre as 5 variáveis de entrada e as 9 variáveis de saída. Devido a ocasionais falhas de convergência do simulador e possíveis erros numéricos no cálculo das saídas, o conjunto de dados foi submetido a um rigoroso processo de saneamento:

- **Limites Físicos Manuais:** Exclusão de amostras com valores fisicamente improváveis (por exemplo, coeficiente de sustentação alto demais).
- **Filtro MAD (*Median Absolute Deviation*):** Aplicação de um filtro estatístico para detecção e remoção de *outliers*. O MAD foi escolhido em detrimento do desvio padrão por ser mais resiliente e não sofrer influência direta dos próprios *outliers* durante o cálculo da dispersão.

3.5. Treinamento dos Modelos Substitutos

Com o banco de dados consolidado, as variáveis de entrada foram normalizadas com o objetivo de melhorar a estabilidade numérica do treinamento e evitar que disparidades de escala entre as variáveis influenciassem indevidamente o ajuste dos modelos. Para os modelos de Superfície de Resposta Polinomial (PRS) e Kriging, aplicou-se a padronização

Z-score, centralizando os dados na média e escalando-os para variância unitária. Para a Rede Neural do tipo *Multi-Layer Perceptron* (MLP), empregou-se o escalonamento Min-Max, que transforma as entradas para o intervalo $[0, 1]$, favorecendo a convergência do treinamento da rede. Em todos os casos, o conjunto de dados foi particionado em subconjuntos de treinamento (80%) e teste (20%), com semente aleatória fixada para garantir a reprodutibilidade dos experimentos.

As três famílias de modelos substitutos foram implementadas utilizando a biblioteca *scikit-learn*. Os modelos foram estruturados sob uma interface de predição unificada, permitindo retornar tanto o valor previsto quanto uma estimativa de incerteza associada. No caso do Kriging, essa incerteza é obtida diretamente das propriedades probabilísticas do modelo; para a PRS e a MLP, foram desenvolvidas classes auxiliares para extração de métricas de dispersão, garantindo a consistência na comparação entre as diferentes abordagens.

3.5.1. Superfície de Resposta Polinomial (PRS)

A PRS foi implementada por meio de uma expansão polinomial das variáveis de entrada seguida de uma regressão linear com regularização de Tikhonov (*Ridge*). A expansão gera termos lineares, quadráticos, cúbicos e de interação cruzada. O modelo final adotado utilizou grau polinomial igual a 3 e uma constante de regularização ℓ_2 de $\alpha = 10^{-6}$, o que contribuiu para reduzir o sobreajuste e melhorar o condicionamento numérico da inversão matricial.

Como a PRS é um modelo determinístico em sua formulação base, a incerteza preditiva foi estimada a partir do desvio padrão residual calculado sobre o conjunto de treinamento. Este resíduo é atribuído de forma homogênea a todas as predições, fornecendo uma métrica global da fidelidade do ajuste do polinômio em relação aos dados originais.

3.5.2. Kriging (Gaussian Process Regression)

O modelo de Kriging foi estabelecido como um regressor de processos gaussianos, onde a função de covariância (kernel) foi definida pela combinação de um termo de amplitude constante, um kernel de Matérn e um termo de ruído branco:

$$k(\mathbf{x}, \mathbf{x}') = \sigma_f^2 k_{\text{Matérn}}(\mathbf{x}, \mathbf{x}'; \boldsymbol{\ell}, \nu) + \sigma_n^2 \quad (10)$$

O parâmetro de suavidade do kernel de Matérn foi fixado em $\nu = 2.5$, garantindo que a superfície de resposta seja duas vezes diferenciável, escolha coerente com a natureza física e suave das curvas de desempenho aerodinâmico. A sensibilidade do modelo a cada variável de entrada foi tratada por meio da Relevância Automática de Variáveis (ARD), que atribui uma escala de comprimento independente (ℓ_i) para cada dimensão do espaço de busca.

O ajuste dos hiperparâmetros foi realizado via maximização da verossimilhança marginal, utilizando múltiplas reinicializações do algoritmo de otimização para mitigar o

risco de convergência em mínimos locais. Adicionalmente, aplicou-se a normalização da variável resposta durante o processo de ajuste para estabilizar a estimativa da variância posterior.

3.5.3. Redes Neurais com Ensemble (MLP)

A abordagem baseada em redes neurais foi construída com um *ensemble* de 20 instâncias independentes do tipo *Multi-Layer Perceptron*. Cada rede possui duas camadas ocultas com 32 neurônios cada, funções de ativação do tipo Unidade Linear Retificada (ReLU) e treinamento via algoritmo Adam. Os hiperparâmetros incluíram uma taxa de aprendizado inicial de 10^{-3} e regularização de pesos ℓ_2 ($\alpha = 10^{-4}$).

A diversidade preditiva entre os membros do *ensemble*, requisito fundamental para a estimativa de incerteza, foi promovida por duas estratégias: a inicialização aleatória distinta dos pesos de cada rede e o uso de reamostragem *bootstrap*. Nesta técnica, cada modelo é treinado em uma subamostra aleatória de 80% do conjunto de treinamento, com reposição. Para evitar o sobreajuste, utilizou-se a técnica de parada antecipada (*early stopping*), reservando-se 10% dos dados de treino de cada membro para validação interna.

A predição final do modelo é dada pela média aritmética das respostas dos membros do *ensemble*, enquanto a incerteza associada é estimada pelo desvio padrão amostral entre as predições individuais.

4. Resultados e Discussão

Nesta seção, avaliamos o desempenho dos modelos substitutos propostos sob três métricas fundamentais: convergência do treinamento, precisão preditiva frente ao *solver* original e eficiência computacional (tempo de inferência).

4.1. Análise de Convergência e Acurácia

A primeira etapa da avaliação consistiu em determinar a quantidade mínima de amostras (LHS) necessária para atingir predições satisfatórias. Os modelos foram treinados iterativamente com incrementos no tamanho do banco de dados (máximo de 13000 amostras após limpeza). Para quantificar a acurácia dos modelos na predição dos parâmetros de saída, utilizou-se a métrica RMSE percentual, definida na Equação 11, e o Coeficiente de Determinação (Score R^2), com validação simples (*holdout*, 80% treino, 20% teste).

$$RMSE_{\%} = \frac{1}{y_0} \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (11)$$

Em que n é o número de amostras no conjunto de teste, y_i é o valor calculado pelo XFOIL, \hat{y}_i é o valor predito pelo modelo substituto e y_0 a mediana dos valores y_i .

A Figura 3 apresenta a evolução do Score R^2 e de $RMSE$ em função do número de amostras. Nela, ambos os resultados foram normalizados para permitir a apresentação de todos os parâmetros. De maneira complementar, a Figura 4 sumariza o desempenho máximo dos três modelos nas execuções do teste de convergência. Observa-se que os modelos atingem precisão (R^2) e erro similares em todos os parâmetros.

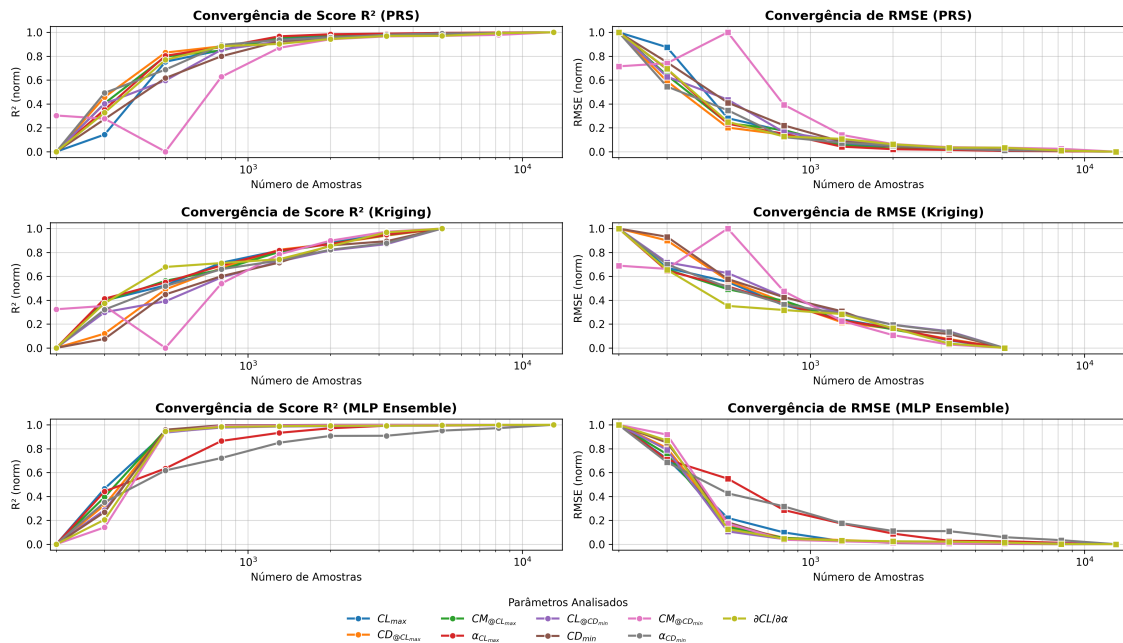


Figura 3. Curvas de convergência do Score R^2 e de RMSE para os três modelos

Observa-se que a PRS necessita de quase 2 mil amostras para atingir seu máximo potencial, enquanto o MLP converge rapidamente, com em torno de 800 amostras, para quase todos os parâmetros. No entanto, para este último, algumas saídas ($\alpha_{CL_{max}}$, $\alpha_{CD_{min}}$) convergem lentamente, exigindo quase 10 mil amostras para que a acurácia se equipare às demais. O Kriging, por sua alta complexidade de treinamento, se torna inviável de treinar para além de 5 mil amostras, mas a análise de convergência indica que mesmo acima deste valor ainda existe potencial de melhora na acurácia.

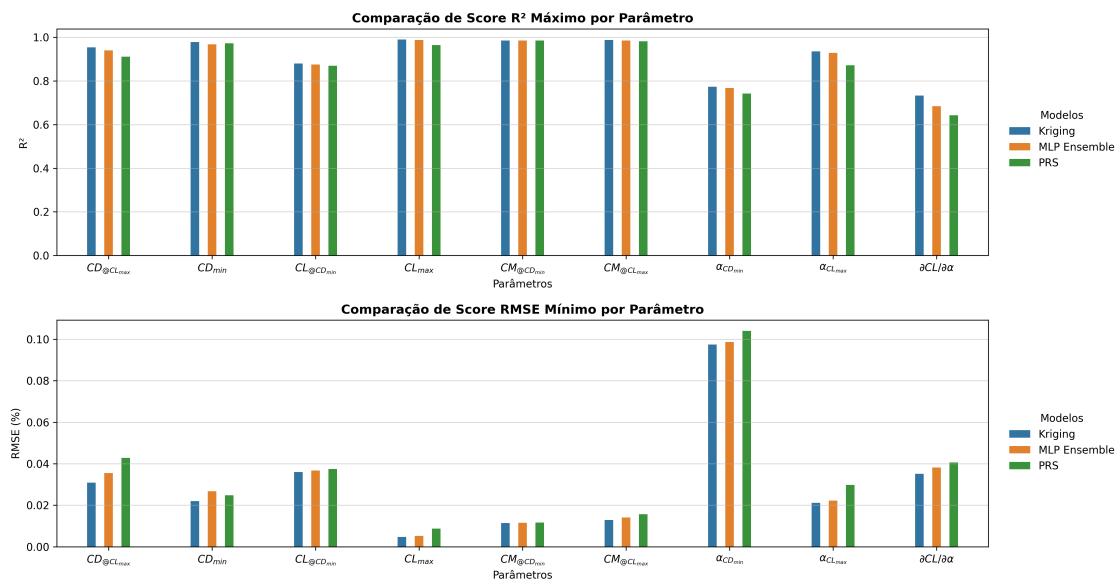


Figura 4. Valores máximos de R^2 e RMSE (validação simples, *holdout*)

É aparente o desempenho mais precário na avaliação de alguns dos parâmetros, especialmente aqueles relacionados ao ângulo de ataque ($\alpha_{CD_{min}}$, $\alpha_{CL_{max}}$, $\partial CL/\partial \alpha$). Esta inacurácia é uma consequência da sensibilidade do método de extração dos valores aos ruídos dos dados simulados. Parâmetros como CL_{max} podem ser determinados de maneira clara e robusta, enquanto outros exigem métodos mais arbitrários e sensíveis (e.g., regressão linear com janela móvel). A falta de robustez na extração diminui a qualidade do conjunto de treino para tais parâmetros.

4.2. Comparativo de Desempenho

O desempenho dos três modelos foi comparado estatisticamente através dos testes de significância de Friedman e Wilcoxon, utilizando o $RMSE$ global (média normalizada). Seguindo as conclusões da análise de convergência e equilibrando o tempo de treino, os resultados apresentados utilizam modelos construídos com um total de: 5 mil amostras para PRS, 3 mil amostras para MLP Ensemble e 1500 amostras para Kriging. Foi utilizada a técnica de validação cruzada “ K -fold” (com $k = 10$) onde o banco de amostras total é dividido em k subconjuntos, um deles é utilizado para teste e os demais para treino em cada uma das iterações.

O teste de Friedman confirmou a existência de disparidade significativa entre os modelos ($p = 0.0051$). Para isolar as diferenças, aplicou-se o teste pareado de Wilcoxon. Os resultados revelaram que não há diferença significativa ($p = 0.219$) entre o modelo Kriging ($RMSE_{\sigma_c} = 5.3\%$) e o MLP Ensemble ($RMSE_{\sigma_c} = 5.5\%$). Contudo, ambos superaram de forma consistente a PRS ($RMSE_{\sigma_c} = 5.9\%$) nas partições avaliadas, com significância estatística idêntica ($p = 0.0156$). Os resultados sugerem que o MLP Ensemble é capaz de atingir a mesma robustez preditiva do Kriging, sem o gargalo computacional deste último. Sendo o modelo mais flexível, o MLP pode apresentar acurácia ainda maior com um aprofundamento na arquitetura e calibração de hiperparâmetros.

4.3. Eficiência Computacional e Desempenho

O principal gargalo superado por este trabalho é o tempo de execução do *solver* aerodinâmico dentro do algoritmo de otimização. A simulação e extração dos 9 parâmetros através de uma polar completa no XFOIL levou, em média, 9 segundos por geometria avaliada (com execução em paralelo, o banco de dados de treino de 15 mil amostras foi gerado em 4 horas e meia).

Em contraste, a avaliação de uma nova geometria (executando a inferência para apenas uma amostra) via Kriging requer, em média, 22 milissegundos, via MLP 37 milissegundos e via PRS apenas 19 milissegundos. Este ganho de desempenho representa uma aceleração de magnitude de aproximadamente 300 vezes. Em um processo de MDO com execução vetorizada, o desempenho pode chegar a 6 microssegundos por amostra com PRS, 60 microssegundos por amostra via MLP e 1.2 milissegundos por amostra via Kriging.

No contexto prático de um MDO que exija 10^5 avaliações, o uso do XFOIL demandaria mais de um dia de processamento paralelo contínuo em uma CPU *desktop* padrão, enquanto os modelos substitutos reduzem este ciclo para escalas de segundos a poucos minutos, viabilizando uma exploração muito mais ampla e profunda do espaço de projeto aerodinâmico.

5. Conclusão e Trabalhos Futuros

A viabilidade da Otimização Multidisciplinar (MDO) no projeto conceitual de aeronaves está fundamentalmente atrelada ao custo computacional da avaliação das funções objetivo. Este trabalho propôs e avaliou uma estrutura robusta para a substituição de simulações aerodinâmicas convencionais (XFOIL) por modelos preditivos de aprendizado de máquina, com foco na eficiência computacional. A partir da parametrização de um aerofólio base e da extração automatizada de parâmetros de saída, foi possível treinar modelos PRS, Kriging e MLP, cujos resultados demonstraram:

- **Eficiência Computacional:** Os modelos substitutos reduziram o tempo de inferência de parâmetros aerodinâmicos em ordens de grandeza quando comparados ao *solver* original, eliminando os problemas causados por falhas de convergência numérica e descontinuidades.
- **Precisão Preditiva:** O Kriging e o MLP Ensemble apresentaram as melhores métricas de acurácia, sem diferença estatística significativa entre si ($p = 0.219$). Ambos superaram a abordagem polinomial ($p = 0.0156$), embora esta apresente acurácia comparável e mantenha o apelo do treino e inferência muito mais ágeis.

Ao reduzir o tempo de inferência de segundos para a escala de milissegundos, os modelos propostos podem reduzir drasticamente o consumo energético associado à infraestrutura em ciclos de otimização que demandam milhões de iterações. Viabilizando mais iterações e, logo, um espaço de busca mais amplo, a solução acelera o desenvolvimento de aeronaves com maior eficiência e contribui para a redução de emissões no setor.

Como trabalhos futuros, sugere-se a expansão do espaço de busca através da parametrização CST [Kulfan 2008] e o acoplamento direto dos modelos treinados em algoritmos genéticos ou otimizadores baseados em gradiente para uma estrutura completa de MDO aeronáutico. Além disso, exploração de outras arquiteturas de Rede Neural e uma calibração mais fina de hiperparâmetros podem aprimorar consideravelmente o desempenho do MLP Ensemble.

Referências

- Drela, M. (1989). Xfoil: An analysis and design system for low reynolds number airfoils. In Mueller, T. J., editor, *Low Reynolds Number Aerodynamics*, pages 1–12. Springer.
- Forrester, A., Sobester, A., and Keane, A. (2008). *Engineering Design via Surrogate Modelling: A Practical Guide*. John Wiley & Sons, Chichester.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. Pearson Education, Upper Saddle River, NJ, 3rd edition.
- Kulfan, B. (2008). Universal parametric geometry representation method. *Journal of Aircraft - J AIRCRAFT*, 45:142–158.
- Martins, J. R. R. A. and Lambe, A. B. (2013). Multidisciplinary design optimization: A survey of architectures. *AIAA Journal*, 51(9):2049–2075.
- Myers, R. H., Montgomery, D. C., and Anderson-Cook, C. M. (2016). *Response Surface Methodology: Process and Product Optimization Using Designed Experiments*. John Wiley & Sons, 4th edition.
- Rasmussen, C. E. and Williams, C. K. I. (2006). *Gaussian Processes for Machine Learning*. MIT Press, Cambridge, MA.