

MODELAGEM MULTI-FIDELIDADE PARA OTIMIZAÇÃO DA GERAÇÃO DE ENERGIA EÓLICA ATRAVÉS DE REDIRECIONAMENTO DE ESTEIRAS

Iago Thiarõ Chaves Bastos, iagotcb@mecanica.coppe.ufrj.br¹

Fernando Alves Rochinha, faro@mecanica.coppe.ufrj.br²

¹Universidade Federal do Rio de Janeiro/COPPE, iagotcb@mecanica.coppe.ufrj.br

Abstract: Turbinas eólicas são instaladas próximas entre si com o objetivo de reduzir os custos de instalação e manutenção. Contudo, devido a esta proximidade, as esteiras formadas na parte posterior dos rotores das turbinas interferem negativamente na geração de energia das demais turbinas que estão localizadas nesta região. Desta forma, o método atual de controle do alinhamento das turbinas em relação a direção do escoamento do ar não é ideal, pois ele busca otimizar a geração de energia das turbinas de maneira individualizada, isto é, desconsiderando a interação entre as turbinas. Nesse contexto, diversos estudos têm sido realizados propondo uma estratégia de controle globalizada ou holística, na qual o desempenho do parque eólico é maximizado como um todo. Para desenvolver esta estratégia propõe-se um desalinhamento proposital do ângulo yaw das turbinas a montante de modo que sua esteira seja redirecionada lateralmente e deixe de incidir sobre as demais turbinas do parque. Embora tais estudos demonstrem o potencial desta técnica, a implementação na prática não é simples, uma vez que os métodos utilizados para solução do problema envolvem métodos numéricos computacionais de alta-fidelidade, os quais demandam uma capacidade de processamento extremamente elevada e logo inviabilizam estratégias de controle de malha fechada ou otimização em larga escala. Além disso, o comportamento dinâmico de uma esteira é governado pelas Equações de Navier-Stokes tridimensionais transientes, as quais não possuem solução analítica para as condições de contorno, termos forçantes tipicamente presentes em parques eólicos e sem hipóteses simplificadoras. Assim, variados modelos de baixa fidelidade, denominados modelos de engenharia, foram desenvolvidos nos últimos anos com o propósito de possibilitar a implementação de controle por redirecionamento de esteira. Busca-se, portanto, neste trabalho realizar uma análise crítica da capacidade de prever a geração de energia das turbinas eólicas em diferentes condições por esses modelos tomando como referência dados de simulações LES (Large-eddy Simulation), isto é, dados de alta fidelidade. Ademais, almeja-se propor um novo modelo multi-fidelidade que integre os dados investigados de diferentes graus de fidelidade mediante técnicas de Machine Learning, mais especificamente Processos Gaussianos auto-regressivos não lineares.

Keywords: Processos Gaussianos, Quantificação de Incerteza, Energia Eólica

1. INTRODUÇÃO

O crescimento exponencial de consumo de energia desde o início da revolução industrial tem produzido mudanças significativas no meio-ambiente, dentre elas destaca-se o crescimento da concentração média na atmosfera de gás carbônico de 280 ppm em 1750 para mais de 390 ppm em 2011 (Michaelides, 2012). Nesse contexto, para evitar um colapso ambiental em escala mundial e ainda atender a demanda energética de todos os países faz-se necessário a maior utilização de fontes de energias sustentáveis, a exemplo de energia eólica. A geração de energia eólica e solar por células fotovoltaicas está crescendo rapidamente: hoje fornecem 6% da produção global de eletricidade em comparação a 0.2% em 2000 (Cozzi and Gould, 2018). O ano de 2020 foi o melhor ano na história para a indústria eólica, o qual apresentou um crescimento relativo ao ano anterior de 53% (Lee and Zhao, 2021). Dessa forma, dado o aumento no número de turbinas eólicas, operá-las da melhor maneira possível torna-se cada vez mais relevante.

Atualmente, o controle de parques eólicos é tipicamente realizado por *greedy control*, no qual a carga estrutural e a geração de energia são otimizados individualmente para cada turbina. No entanto, esse método aparenta ser sub-ótimo para o desempenho de um parque eólico como um todo (Pao and Johnson, 2009). Esse fenômeno pode ser explicado devido à formação de esteira, região turbulenta e de baixa velocidade, atrás das turbinas que se localizadas mais à frente prejudicam a geração de energia das turbinas à jusante em relação ao campo de velocidade. Assim, métodos de controle que visam otimizar a operação de parques eólicos como um todo vêm sendo investigados.

Embora técnicas numéricas e experimentais tenham se tornado extremamente sofisticadas e precisas nos últimos anos, modelos analíticos simplificados ainda são ferramentas úteis para prever os efeitos da esteira em turbinas eólicas e na geração de energia. Estes modelos são usados frequentemente devido à sua simplicidade e baixo custo computacional (Bastankhah and Porté-Agel, 2014). Recentemente diversos modelos de engenharia para a formação de esteira em turbinas eólicas foram desenvolvidos com o propósito de utilização em sistemas de controle. Logo, busca-se nesse estudo analisar a capacidade com a qual esses modelos conseguem prever como os fenômenos de esteira impactam a geração de energia através de uma análise de discrepância. Finalmente, almeja-se propor um modelo multi-fidelidade utilizando modelos de engenharia e de alta-fidelidade mediante técnicas de Machine Learning, especificamente Processos Gaussianos.

2. REVISÃO BIBLIOGRÁFICA

2.1 Turbina Eólica




Figura 1: **Velocidade do escoamento U através da área A varrida pelo rotor no volume de controle. Fonte: (Burton *et al.*, 2011)**

Um modelo simplificado, atribuído à Betz (1926), pode ser utilizado para determinar a potência de um rotor ideal, o empuxo do ar no rotor ideal e o efeito da ação do rotor do escoamento local do ar, (Manwell *et al.*, 2009). Esta é a Teoria de Momento Unidimensional que parte de uma análise em volume de controle, como o da Figura 1 e adota as seguintes hipóteses:

1. Escoamento homogêneo, incompressível e permanente
2. Atrito de arrasto desprezível
3. Número infinito de pás
4. Força de empuxo uniforme na área varrida pelo rotor
5. Rotação da esteira desprezível
6. Pressão à montante e à jusante equivalente à pressão ambiente

Desse modo, é possível através de um balanço de momento no volume de controle encontrar as forças resultantes no mesmo (Manwell *et al.*, 2009). Portanto, a potência de saída de uma turbina eólica é dado pela seguinte expressão:

$$P = \frac{1}{2} \rho A U^3 4a(1-a)^2 \quad (1)$$

Onde ρ representa a densidade do ar e a é definido com coeficiente de indução axial, dado por

$$a = \frac{U - U_r}{U} \quad (2)$$

Onde U_r é a velocidade imediatamente à frente do rotor. Se $a = 0.5$, a velocidade do escoamento atrás do rotor é igual a zero e esta teoria não é mais válida.

A potência produzida pela turbina eólica é caracterizada, contudo, pelo Coeficiente de Potência, C_P . De modo que

$$P = C_P \frac{1}{2} A \rho U^3 \quad (3)$$

O valor máximo teórico para C_P é de 0.593 e é denominado como Limite de Betz (Burton *et al.*, 2011).

De modo análogo a Força de empuxo é caracterizada em função do Coeficiente de Empuxo, C_T , e dado por

$$T = C_T \frac{1}{2} A \rho U^2 \quad (4)$$

Contudo, a aplicação da Teoria de Momento em um disco atuador representando um rotor desalinhado com o escoamento do ar apresenta problemas, de modo que neste caso (Burton *et al.*, 2011):

$$C_P = 4a(\cos \gamma - a)^2 \quad (5)$$

$$C_T = 4a(\cos \gamma - a) \quad (6)$$

onde γ é o ângulo formado entre o plano do rotor e o escoamento do ar, denominado ângulo de *yaw*.

2.2 Modelo de Esteira

Os modelos aerodinâmicos de escoamento em parques eólicos podem ser classificados em três categorias: modelos de engenharia, média fidelidade e alta fidelidade (Andersson *et al.*, 2021).

O comportamento dinâmico de uma esteira (ou de forma geral, de um escoamento) é governado pelas Equações de Navier-Stokes tridimensionais transientes. Essas equações são matematicamente definidas como um sistema infinito não linear com restrição de igualdade. Sob condições de contorno e termos forçantes tipicamente presentes em modelos de parques eólicos, e sem nenhuma hipótese simplificadora, nenhuma solução analítica foi encontrada até hoje segundo Boersma *et al.* (2017).

Portanto, métodos numéricos de discretização espacial e algoritmos devem ser utilizados para solucionar o problema, tal área da mecânica dos fluidos é conhecida por CFD (*Computational Fluid Dynamics*). Métodos de solução como DNS (*Direct Numerical Simulation*) ou LES (*Large-eddy Simulation*) podem ser considerados modelos de mais alta fidelidade.

Um modelo numérico de média fidelidade usado para simular o escoamento de esteiras turbulentas é descrito pelas equações de Navier-Stokes com Reynolds Médio (RANS). A continuidade média e equações de movimento para escoamento incompressível com forças externas podem ser escritas em notação tensorial e em coordenadas Cartesianas como (Qian and Ishihara, 2018):

$$\frac{\partial(\rho U_i)}{\partial x_i} = 0 \quad (7)$$

$$\frac{\partial(\rho U_i)}{\partial t} + \frac{\partial(\rho U_j U_i)}{\partial x_j} = -\frac{\partial \bar{p}}{\partial x_i} + \frac{\partial}{\partial x_j} \left[\mu \left(\frac{\partial U_i}{\partial x_j} + \frac{\partial U_j}{\partial x_i} \right) \right] + \frac{\partial(-\rho \overline{u'_i u'_j})}{\partial x_j} + f_{u,i} \quad (8)$$

Onde U_i e $\bar{p}$ são a velocidade média e a pressão média na i -ésima direção, respectivamente. μ é viscosidade cinemática, $f_{u,i}$ é a força exercida pelo fluido por unidade de volume induzida pela turbina. $-\rho \overline{u'_i u'_j}$ é conhecido como tensor de tensões de Reynolds que representa o efeito de vórtices de alta frequência em relação ao escoamento médio que é relativamente estacionário.

O modelo proposto por Martinez-Tossas *et al.* (2019) utiliza esta abordagem RANS e é denominado modelo Curl, pois o modelo soluciona uma versão linearizada da equação de momento de Navier-Stokes com efeitos de rotação acrescidos por uma coleção de vórtices com uma distribuição elíptica gerados no plano do rotor. No qual cada vórtice é descrito por um vórtice Lamb-Oseen com uma distribuição de velocidade tangencial dada por:

$$u_t = \frac{\Gamma}{2\pi r} (1 - e^{-\frac{r^2}{\sigma^2}}) \quad (9)$$

onde r é a distância do centro do vórtice, Γ é a intensidade de circulação e σ a espessura do núcleo do vórtice.

Segundo Fleming *et al.* (2018), com o propósito de projetar controladores para implementar estratégias de controle de redirecionamento de esteira é necessário desenvolver modelos de engenharia que contenham os fenômenos físicos relevantes, mas que sejam computacionalmente eficientes de modo que possam ser utilizados em otimizações de larga escala ou utilizados como modelos internos de controladores em tempo real.

Com isso, diversos modelos de engenharia foram desenvolvidos e compilados em algoritmos na plataforma aberta desenvolvida pela NREL, a plataforma Floris. Esta plataforma de trabalho foi desenvolvida para proporcionar uma ferramenta computacional eficiente voltada para modelagem de controle de esteira em estado permanente em parques eólicos (NREL, 2021).

Em uma primeira tentativa de modelar de maneira simplificada a física das esteiras formadas por turbinas eólicas, Jensen (1983) propôs um modelo simplificado (modelo de Jensen) a partir de um balanço de momento, no qual o deficit de velocidade na esteira é tratado como um perfil homogêneo (*top-hat*). Contudo, o autor compara o perfil de velocidade logo após uma turbina com dados de campo e conclui que uma aproximação mais razoável seria de um perfil similar a uma distribuição gaussiana. Com isso, diversos trabalhos mais recentes tem proposto alternativas com o propósito de aperfeiçoar o modelo de esteira, tais como em Gebraad *et al.* (2014), Gebraad *et al.* (2016), Bastankhah and Porté-Agel (2014), Bastankhah and Porté-Agel (2016), Abkar and Porté-Agel (2015).

Em (Bastankhah and Porté-Agel, 2014) um modelo para calcular o deficit de velocidade após as turbinas assumindo um perfil Gaussiano é proposto a partir de princípios de conservação de massa e momento, de modo que desprezando termos viscosos e de pressão obtém-se que:

$$\rho \int U_w (U_\infty - U_w) dA = T \quad (10)$$

onde U_∞ é a velocidade ambiente e U_w a velocidade na esteira, como pode ser observado na figura 2 a qual por sua vez ilustra a diferença de formulação entre o modelo de Jensen e modelos Gaussianos.




Figura 2: Abordagem *top-hat* (a) versus formulação Gaussiana (b).

De acordo com (Burton *et al.*, 2011) a auto-similaridade descreve o deficit de velocidade normalizado. Assim, como o modelo adota um perfil Gaussiano para o deficit de velocidade:

$$\frac{\Delta U}{U_\infty} = C(x) e^{-\frac{r^2}{2\sigma^2}} \quad (11)$$

onde $C(x)$ representa o decréscimo de velocidade máximo normalizado em um ponto após a turbina que ocorre no centro da esteira; r é a distância radial do centro da esteira e σ representa o desvio padrão do perfil do deficit de velocidade Gaussiano em cada x .

Embora este modelo Gaussiano adote um perfil distinto ao perfil homogêneo de Jensen (1983), a expansão da região da esteira é tratada de maneira linear em ambos, tal que:

$$\frac{\sigma}{d_0} = k^* \frac{x}{d_0} + \epsilon \quad (12)$$

onde d_0 é diâmetro do rotor da turbina eólica e $k^* = \partial\sigma/\partial x$ é a taxa de crescimento e ϵ é equivalente ao valor de σ/d_0 quando x tende a 0. Com isso:

$$\frac{\Delta U}{U_\infty} = \left(1 - \sqrt{1 - \frac{C_T}{8(k^*x/d_0 + 0.2\sqrt{\beta})^2}} \right) \times \exp \left(-\frac{1}{2(k^*x/d_0 + 0.2\sqrt{\beta})^2} \left[\left(\frac{z - z_h}{d_0} \right)^2 + \left(\frac{y}{d_0} \right)^2 \right] \right) \quad (13)$$

onde β é um parâmetro determinado em função de C_T . Para o modelo Gaussiano proposto em (Bastankhah and Porté-Agel, 2014), k^* é estimado de acordo com dados de simulações LES para diferentes casos.

Já na formulação super-Gaussiana outra variável é introduzida: a ordem n super-Gaussiana. A função super-Gaussiana é uma escolha conveniente para a representação de esteiras já que para altos valores de ordem n , o perfil se aproxima ao perfil *top-hat*, como é observado imediatamente após o rotor, enquanto para baixos valores de n , a função se transforma gradativamente no perfil Gaussiano tradicional, como observado em posições distantes do rotor (Blondel and Cathelain, 2020).

Além de calcular o deficit de velocidade após as turbinas é necessário computar a deflexão da esteira de acordo com o desalinhamento do rotor ou ângulo de yaw. Para isso duas formulações distintas foram desenvolvidas em (Bastankhah and Porté-Agel, 2016) e (Jimenez *et al.*, 2010).

Em (Jimenez *et al.*, 2010) a conservação de momento e o modelo de velocidade com perfil *top-hat* são utilizados para deduzir a expressão do ângulo formado entre a esteira e o rotor, denominado ângulo skew. De modo que, assumindo este ângulo pequeno suficiente para que $\cos \alpha \approx 1$ e $\sin \alpha \approx \alpha$. Além disso, considerando que $U_0 - \Delta U \approx U_0$:

$$\alpha \approx \frac{\cos^2 \gamma \sin \gamma C_T}{2(1 + \beta \frac{x}{d_0})^2} \quad (14)$$

Em contrapartida, Bastankhah and Porte-Agel (2016) utilizam a abordagem gaussiana para deduzir o ângulo skew e em consequência a deflexão da esteira.

$$\theta_c = \frac{\theta_{c0}(\sigma_{y0}\sigma_{z0})(C_0^2 - 3^{1/12}C_0 + 3e^{1/2})}{\sigma_y\sigma_z(C^2 - 3^{1/12}C + 3e^{1/2})} \quad (15)$$

Onde θ_c representa o ângulo skew no centro na esteira, σ representa o desvio padrão do perfil do deficit de velocidade Gaussiano nas respectivas coordenadas y e z , as quais em conjunto com sub-índice 0 indicam a posição $x = 0$. Mais detalhes sobre o cálculo da deflexão da esteira, incluindo o valor de C , podem ser encontrados em (Bastankhah and Porte-Agel, 2016).

A presença de um par de vórtices girando em sentidos opostos presente em parques eólicos utilizando estratégia de controle de redirecionamento de esteira explica o porquê de uma esteira defletida redireciona outras esteiras, mesmo que a respectiva turbina esteja alinhada ao escoamento, um processo denominado "deflexão secundária" (Fleming *et al.*, 2018).

Por isso, King *et al.* (2019) propõem duas correções aos modelos anteriormente propostos com o objetivo de considerar os efeitos de deflexão secundária e a recuperação acelerada da esteira quando redirecionada, isto é:

$$u(x, y, z) = u_G(x, y, z) + \frac{W(x, y, z)(x - x_0)(y - y_0)}{\pi[\alpha_r(x - x_0) + \frac{D}{2}]^2} \quad (16)$$

na qual $u_G(x, y, z)$ é a velocidade computada pelo modelo de esteira e o termo adicional à direita acrescenta o efeito de recuperação acelerada da esteira, onde α_r é um parâmetro a ser ajustado e $W(x, y, z)$ é calculado segundo (King *et al.*, 2019).

De forma análoga King *et al.* (2019) adicionam os efeitos de deflexão secundária ao acrescentar um termo somante no valor do ângulo de yaw:

$$\gamma = \gamma_{turb} + \gamma_{eff} \quad (17)$$

onde γ_{turb} é ângulo de yaw que a turbina está operando, γ_{eff} é computado segundo (King *et al.*, 2019) e então γ é utilizado para computar a deflexão real da esteira. Este modelo é denominado *Gauss Curl Hybrid* ou GCH.

3. MÉTODOS

3.1 Quantificação de Incerteza

Em primeira instância a capacidade de previsão da potência gerada por turbina dos modelos de engenharia contidos na plataforma Floris foram avaliados tomando como referência um modelo de mais alta-fidelidade. A plataforma Floris foi desenvolvida para proporcionar uma ferramenta computacional eficiente voltada para modelagem de controle de esteira em estado permanente em parques eólicos (NREL, 2021).

Para isso, utilizou-se um banco de dados da mesma plataforma que contém 777 simulações LES para diversas configurações de parques eólicos e também variadas condições ambientais e de operação. Contudo, o foco deste estudo concentra-se nos 286 pontos relativos a parques eólicos contendo duas turbinas, uma vez que a modelagem multi-fidelidade proposta trata destes casos. A configuração contendo duas turbinas é um caso clássico simplificado utilizado na literatura para avaliar inicialmente os modelos analíticos propostos.

A base de dados apresenta como entrada o layout do parque eólico, isto é, as posições X e Y das turbinas, a velocidade do escoamento, a intensidade de turbulência e o ângulo yaw. Além disso, tem como saída a potência gerada por turbina. Todas as simulações foram realizadas para a turbina eólica NREL de 5 MW, diâmetro do rotor e altura do hub de 126 e 90 metros, respectivamente. Ainda, apenas a direção do vento de 270° foi considerada.

Nesse contexto, diversas simulações foram realizadas em Python utilizando a biblioteca floris contida na plataforma de mesmo nome que permite calcular a potência gerada por um parque eólico contendo o mesmo modelo de turbina NREL 5 MW utilizado nas simulações LES. A potência é calculada através dos já implementados modelos de engenharia que foram mencionados na seção anterior. Ademais, a densidade do ar foi considerada 1.225 kg/m^3 , o gradiente de vento 0.12 e a presença de *veer* foi desconsiderada.

Assim, um conjunto de dados das potências por turbina foi gerado para diversas entradas (configuração do parque eólico, condições ambientais e de operação), de modo que os dados de alta fidelidade formem um subconjunto dos dados de menor fidelidade. Então, para quantificar a discrepância entre os modelos de engenharia e o modelo LES utilizou-se as métricas Raiz do Erro Quadrático Médio (RMSE) ou norma l_2 segundo (Brunton and Kutz, 2017) e Erro Médio Percentual Simétrico (SMAPE) segundo (Flores, 1986).

3.2 Modelagem Multi-fidelidade

Dado a avaliação realizada da capacidade de previsão dos modelos de engenharia, um novo modelo multi-fidelidade através de Processos Gaussianos não-lineares é proposto para um parque eólico contendo duas turbinas, utilizando a referência de alta fidelidade e um modelo de engenharia selecionado segundo as métricas empregadas.

Um Processo Gaussiano (PG) é definido como um conjunto de variáveis randômicas, no qual qualquer número finito do mesmo possui uma distribuição de probabilidade conjunta Gaussiana (Rasmussen and Williams, 2006).

A regressão através de PG, portanto, é tratada como um problema de aprendizado supervisionado, no qual o conjunto de dados de treinamento $\mathcal{D}$ consiste de n observações, tal que $\mathcal{D} = \{(\mathbf{x}_i, y_i) \mid i = 1, \dots, n\}$. Onde $\mathbf{x}$ denota o vetor de entradas (covariantes) de dimensão D e y é o escalar de saída ou valor alvo (variável dependente).

Segundo Rasmussen and Williams (2006), a análise Bayesiana em um modelo de regressão linear tradicional com ruído Gaussiano é descrito por:

$$f(\mathbf{x}) = \mathbf{x}^T \mathbf{w}, \quad y = f(\mathbf{x}) + \epsilon \quad (18)$$

onde $\mathbf{w}$ é o vetor de parâmetros do modelo linear tradicional. Para este estudo o ruído, ϵ , é desconsiderado. Hipótese que é considerada razoável uma vez que os dados são todos provenientes de simulações computacionais.

A função desconhecida $f(\mathbf{x})$ é tipicamente assinalada como a priori de um Processo Gaussiano com média zero, isto é $\mathcal{GP}(\mathbf{f}|\mathbf{0}, k(\mathbf{x}, \mathbf{x}'; \theta))$. Onde k representa uma função kernel parametrizada pelo vetor de hiper-parâmetros θ que dá origem a uma matriz simétrica positiva definida de covariância $K_{ij} = k(\mathbf{x}_i, \mathbf{x}_j; \theta)$, $\mathbf{K} \in \mathbb{R}^{n \times n}$. A priori define uma métrica para quantificar a correlação de pares entre as entradas (x_i, x_j) e reflete o conhecimento das propriedades da função a ser aproximada, (Rasmussen and Williams, 2006). Então, o vetor de hiper-parâmetros θ é determinado através da máxima verossimilhança do modelo, mais especificamente, através da maximização do logaritmo da função de verossimilhança.

A regressão PG pode ser estendida para construir modelos estocásticos que permitam combinar fontes de informação de fidelidade variada. De acordo com a abordagem de Kennedy and O'Hagan (2000), esta modelagem é descrita como:

$$f_t(\mathbf{x}) = \rho f_{t-1}(\mathbf{x}) + \delta_t(\mathbf{x}) \quad (19)$$

onde f_{t-1} e f_t são processos Gaussianos que modelam os dados em níveis de fidelidade $(t-1)$ e t , respectivamente, ρ é um fator constante que quantifica a correlação entre as saídas dos modelos $\{y_t, y_{t-1}\}$ e $\delta_t(\mathbf{x}_t)$ é uma distribuição do processo Gaussiano com média μ_δ e função de covariância k_t .

Nesse contexto, Perdikaris *et al.* (2017) propõem uma generalização do esquema auto-regressivo de multi-fidelidade da equação (19), tal que:

$$f_t(\mathbf{x}) = z_{t-1}(f_{t-1}(\mathbf{x})) + \delta_t(\mathbf{x}) \quad (20)$$

onde $z_{t-1}(\cdot)$ é uma função desconhecida que mapeia a saída de baixa fidelidade na saída de alta fidelidade.

Neste método é proposto um tratamento Bayesiano não-paramétrico de z uma vez que z é assinalado como uma priori GP (Perdikaris *et al.*, 2017). Já que f_{t-1} na equação (20) também é tratado como a priori de um GP, a composição das duas funções a priori GP dá origem a um processo denominado *deep GP* e assim, a distribuição posteriori de f_t deixa de ser Gaussiana.

Neste caso, a distribuição PG a priori f_{t-1} é substituída pela PG a posteriori de nível de inferência anterior $f_{*t-1}(x)$. Assim, assumindo um conjunto de treinamento, tal que $x_t \in x_{t-1}$ e observações sem ruído $\{y_t, y_{t-1}\}$ o treinamento se reduz a um problema de estimativa de máxima verossimilhança.

Esta abordagem multi-fidelidade foi implementada em Python através do pacote Emukit que possui diversas ferramentas para análise de incerteza e processos Gaussianos mediante o pacote GPpy.

4. RESULTADOS E DISCUSSÃO

A Tabela 1 expõe os resultados obtidos para a discrepância entre a previsão realizada pelos modelos de engenharia estudados e a simulação LES (referência de alta fidelidade) em um parque eólico contendo duas turbinas. Nota-se que os erros obtidos para a turbina *upstream* são idênticos, pois ela não se localiza na área de influência de nenhuma esteira e os modelos calculam a potência de forma idêntica dado a velocidade do escoamento sobre o rotor. Exceto para o modelo Curl que aborda o problema através de uma modelagem distinta, isto é, através do método RANS.

Tabela 1: **Discrepância entre modelos para parque eólico com duas turbinas.**

Modelo de Velocidade	Modelo de Deflexão	RMSE (kW)		SMAPE (%)	
Jensen	Jimenez	241.7	337.5	7.3	10.9
Multizone	Jimenez	241.7	310.4	7.3	10.9
Gaussiano	Jimenez	241.7	274.2	7.3	10.0
Super-Gaussiano	Jimenez	241.7	250.1	7.3	8.5
Gaussiano	Gaussiano	241.7	279.4	7.3	10.4
Super-Gaussiano	Gaussiano	241.7	263.6	7.3	8.8
GCH	Gaussiano	241.7	258.1	7.3	8.2
Curl	Curl	247.8	1161.1	7.5	58.3

Contudo, para a turbina *downstream* os resultados são distintos, uma vez que os modelos estimam o comportamento da esteira de forma distinta. Assim, a potência gerada pela turbina *downstream* depende da previsão do campo de velocidade. Para este *layout* de duas turbinas foram estudados 286 entradas distintas, dentre elas casos para a intensidade

de turbulência igual a 6% e 10%; ângulos de yaw -20 , 0 e 20 graus; velocidade normal ao rotor $[8, 9, 10, 11, 12]m/s$; e *layout* em que a distância X entre as turbinas é equivalente a 5 a 12 diâmetros; além disso também incluiu-se casos em que as turbinas não estão alinhadas para uma distância Y de $-0.5d$ a $0.5d$.

Pode-se observar, de acordo com a Tabela 1, que a previsão da potência gerada pelo parque eólico que apresentou a menor discrepância foi apresentada pelo modelo de velocidade Super-Gaussiano em conjunto com a modelagem de deflexão proposta em (Jimenez *et al.*, 2010). O modelo GCH apresentou resultados próximos, inclusive, de acordo com a métrica de discrepância relativa (SMAPE) superior ao modelo de menor discrepância segundo a norma l_2 . superou ligeiramente os dois modelos Gaussianos apresentando RMSE equivalente a $258.1kW$ e SMAPE de 8.2%. Este desempenho próximo entre o modelo Gaussiano e o GCH era esperado, pois os efeitos da deflexão secundária só se torna aparente em parques com três ou mais turbinas em sequência. Por outro lado, o modelo Curl apresentou um desempenho decepcionante em comparação com os outros modelos embora seja um modelo RANS, considerado de média fidelidade.

Neste estudo optou-se por utilizar o modelo de menor discrepância em termos de RMSE como modelo de baixa referência em conjunto com os dados das simulações LES com o finalidade de propôr um modelo multi-fidelidade. Foi utilizado o conjunto de dados de alta fidelidade contendo 278 pontos dos 286 utilizados na análise de discrepância para evitar ser necessário especificar a posição da turbina *upstream*, uma vez que para todos os casos incluídos ela se encontra na posição $[1000, 1000]$. Assim, evitou-se adicionar duas entradas para o treinamento do modelo. Logo, as entradas utilizadas foram a velocidade do escoamento, o ângulo yaw da turbina *upstream*, a intensidade de turbulência e as posições x e y da turbina *downstream*, ou seja, 5 entradas. Assim, naturalmente, a saída é a previsão da potência gerada pela turbina *downstream*.

Já os dados de baixa fidelidade foram formados a partir de um conjunto de entradas semelhantes aos de alta fidelidade acrescidos de um conjunto de dados gerados de forma aleatória a partir das simulações realizadas. Deste modo, o conjunto de dados de alta fidelidade forma um subconjunto dos dados de baixa fidelidade, o qual por sua vez possui 5 vezes o número de pontos de alta fidelidade. Então, para o treinamento do modelo foram utilizados de maneira aleatória 80% de cada conjunto, enquanto 20% foram separados para o teste. Além disso, as entradas e saídas foram normalizadas e para o kernel foi utilizada uma função de base radial em todos os casos.




Figura 3: **Modelo Multi-fidelidade em função da Velocidade de Escoamento**

A figura 3 ilustra a previsão do modelo em função de uma das entradas, enquanto as outras são mantidas fixas em um valor contido no conjunto de dados ($9m/s$, 20° , 10% e $5d$, 0 , para X e Y , respectivamente). Percebe-se que dentro do intervalo de velocidades conhecido o modelo consegue prever com bastante fidelidade e baixa incerteza. Por outro lado, à medida que as previsões são realizadas fora do intervalo a incerteza se torna cada vez maior, como é esperado.

Embora tenha sido utilizado um número suficientemente elevado de dados em relação ao que se observa na análise de convergência ilustrada na figura 5, o baixo número de pontos conhecido de ângulos yaw (-20 , 0 , 20°) gera uma grande incerteza quanto a previsão da potência para ângulos intermediários, como visto na figura 4. Logo, deve-se introduzir no modelo dados para estes ângulos, a exemplo -10 e 10° . O mesmo ocorre para a intensidade de turbulência.

A previsão da potência em relação à posição X da turbina *downstream* mantendo as demais entradas fixas, a exemplo o ângulo yaw é mantido em 20° , reduz a correlação da esteira sobre a potência gerada pela turbina em comparação ao que se apresentaria para a turbina alinhada ao escoamento que apresenta um acréscimo claro na geração de energia à medida que se afasta da primeira turbina. Em contra partida, a posição Y apresenta um ganho notável na geração para a turbina com um deslocamento lateral de $0.5d$, como pode ser visto na 6, justamente na direção oposta na qual a esteira é redirecionada pelo yaw de 20° , fato que é previsto pelo modelo proposto, embora novamente a incerteza cresça rapidamente para além




Figura 4: Modelo Multi-fidelidade em função do ângulo Yaw




Figura 5: Análise de convergência do modelo de multi-fidelidade.

da faixa coberta pelos dados utilizados.

Pode-se dizer que o modelo multi-fidelidade proposto é capaz de captar o comportamento dos dados de alta fidelidade. Esta conclusão é corroborada pela redução de discrepância mensurada pelo RMSE em comparação ao modelo de baixa fidelidade de 22.55% para os dados utilizados para o teste dos modelos. Logo, percebe-se que há um ganho de desempenho considerável em relação ao modelo de engenharia. O aumento da capacidade de previsão é ainda mais relevante, dado que apenas 54.32 segundos foram necessários para treinar o modelo proposto. Entretanto, percebe-se que há uma incerteza presente nas inferências realizadas pelo modelo multi-fidelidade, em especial nas faixas que há ausência de informação de alta fidelidade. Outrossim, é factível acrescentar informação ao modelo sem aumentar em demasiado o número de dados para cobrir as áreas onde a presença de incerteza é destacada, em especial para o parque eólico fixado e em treinamento *onsite*.

5. CONCLUSÃO

Este trabalho realiza uma análise sobre a capacidade que os modelos de engenharia possuem para prever o deficit de velocidade e comportamento das esteiras formadas por turbinas eólicas. Observou-se, portanto, que o modelo que apresentou melhor desempenho em relação a dados obtidos por simulações LES para as configurações de entrada estudadas foi o modelo de velocidade Super-Gaussiano em conjunto com o modelo de deflexão Jimenez. Contudo, esta análise é insuficiente para afirmar que tal modelo seja melhor superior aos demais, já que a população estudada é pequena.

Além disso, a abordagem auto-regressiva por Processos Gaussianos não-lineares foi utilizada para a elaboração de um novo modelo multi-fidelidade. Utilizando o modelo de baixa fidelidade de menor RMSE e os dados LES como referência de alta fidelidade obteve-se uma redução de 22.55% na norma l_2 . Este ganho é significativo já que apenas 54.32 segundos




Figura 6: **Modelo Multi-fidelidade em função da Posição relativa Y.**

foram empregados no treinamento do modelo.

Futuros trabalhos envolvem realizar uma análise com mais informações sobre ângulos *yaw* e intensidade de turbulência; uma análise de robustez para verificar a confiabilidade do modelo dado diferentes conjuntos de treinamento; realizar a mesma análise para parques eólicos com mais turbinas; e estudar a possibilidade de um modelo multi-fidelidade com mais de dois níveis de fidelidade.

6. REFERÊNCIAS

- Abkar, M. and Porte-Agel, F., 2015. "Influence of atmospheric stability on wind-turbine wakes: a large-eddy simulation study". *Physics of fluids*. doi:27(3):035104.
- Andersson, L.E., Anaya-Lara, O., Tande, .O., Merz, K.O. and Imsland, L., 2021. "Wind farm control - part i: A review on control system concepts and structures". *IET Renewable Power Generation*, pp. 1–24. doi:10.1049/rpg2.12160.
- Bastankhah, M. and Porte-Agel, F., 2016. "Experimental and theoretical study of wind turbine wakes in yawed conditions". *Journal of Fluid Mechanics*, , No. 806, p. 506–541.
- Bastankhah, M. and Porté-Agel, F., 2014. "A new analytical model for wind-turbine wakes". *Renewable Energy*, Vol. 70, pp. 116–123. ISSN 0960-1481. doi:https://doi.org/10.1016/j.renene.2014.01.002. URL https://www.sciencedirect.com/science/article/pii/S0960148114000317. Special issue on aerodynamics of offshore wind energy systems and wakes.
- Blondel, F. and Cathelain, M., 2020. "An alternative form of the super-gaussian wind turbine wake model". *Wind Energy Science Discussions*. doi:10.5194/wes-2019-99.
- Boersma, S., Doekemeijer, B., Gebraad, P., Fleming, P., Annoni, J., Scholbrock, A., Frederik, J., and van Wingerden, J.W., 2017. "A tutorial on control-oriented modeling and control of wind farms". *American Control Conference*.
- Brunton, S.L. and Kutz, J.N., 2017. *Data Driven Science and Engineering*. Brunton and Kutz, Seattle, WA, USA.
- Burton, T., Jenkins, N., Sharpe, D. and Bossanyi, E., 2011. *Wind Energy Handbook*. Wiley, West Sussex, PO19 8SQ, United Kingdom.
- Cozzi, L. and Gould, T., 2018. Public report, International Energy Agency, https://www.iea.org/topics/world-energy-outlook.
- Fleming, P., Annoni, ., Churchfield, M., Martinez-Tossas, L.A., Gruchalla, K., Lawson, M. and Moriarty, P., 2018. "A simulation study demonstrating the importance of large-scale trailing vortices in wake steering". *National Wind Technology Center*, Vol. 3, pp. 243–255. doi:10.5194/wes-3-243-2018.
- Flores, B.E., 1986. "A pragmatic view of accuracy measurement in forecasting". *Omega*, Vol. 14, No. 2, pp. 93–98. doi:10.1016/0305-0483(86)90013-7.
- Gebraad, P., Teeuwisse, F., van Wingerden, J., Fleming, P., Ruben, S., Marden, J. and Pao, L., 2016. "Wind plant power optimization through yaw control using a parametric model for wake effects—a cfd simulation study". *Wind Energy*, Vol. 19, pp. 95–114.
- Gebraad, P.M.O., Teeuwisse, F.W., J. W. van Wingerden, P.A.F., Ruben, S.D., Marden, J.R. and Pao, L.Y., 2014. "A data-driven model for wind plant power optimization by yaw control". *American Control Conference*.
- Jensen, N.O., 1983. "A note on wind generator interaction". *Risø National Laboratory*.
- Jimenez, A., Crespo, A. and Migoya, E., 2010. "Application of a les technique to characterize the wake deflection of a wind turbine in yaw". *Wind energy*. doi:13(6):559–572.

- Kennedy, M.C. and O'Hagan, A., 2000. "Predicting the output from a complex computer code when fast approximations are available". *Biometrika*, , No. 87, p. 1–13. doi:10.1093/biomet/87.1.1.
- King, J., Fleming, P., King, R. and Martinez-Tossas, L.A., 2019. "Controls-oriented model to capture secondary effects of wake steering". *Submitted to Wind Energy Science*.
- Lee, J. and Zhao, F., 2021. Public report, Global Wind Energy Council, info@gwec.net.
- Manwell, J.F., McGowan, J.G. and Rogers, A.L., 2009. *Wind Energy Explained: Theory, Design and Application*. Wiley, West Sussex, PO19 8SQ, United Kingdom.
- Martinez-Tossas, L.A., Annoni, J., Fleming, P.A. and Churchfield, M.J., 2019. "The aerodynamics of the curled wake: a simplified model in view of flow control". *Wind Energy Science (Online)*.
- Michaelides, E.E., 2012. *Alternative Energy Sources*. Springer, Fort Worth, TX, USA.
- NREL, 2021. "Floris 2.3.0". URL <https://github.com/NREL/floris>.
- Pao, L.Y. and Johnson, K.E., 2009. "A tutorial on the dynamics and control of wind turbines and wind farms". In *2009 American Control Conference*. pp. 2076–2089. doi:10.1109/ACC.2009.5160195.
- Perdikaris, P., Raissi, M., Damianou, A., Lawrence, N.D. and Karniadakis, G.E., 2017. "Nonlinear information fusion algorithms for data-efficient multi-fidelity modelling". *Proc. R. Soc. A*, p. 473. doi:10.1098/rspa.2016.0751.
- Qian, G.W. and Ishihara, T., 2018. "A new analytical wake model for yawed wind turbines". *Energies*. doi:11(3):665.
- Rasmussen, C.E. and Williams, C.K.I., 2006. *Gaussian Processes for Machine Learning*. The MIT Press, Cambridge, Massachusetts.

7. RESPONSABILIDADE AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo deste trabalho.

MULTI-FIDELITY MODELING FOR WAKE REDIRECTION CONTROL OF WIND FARM POWER PRODUCTION

Iago Thiarõ Chaves Bastos, iagotcb@mecanica.coppe.ufrj.br¹

Fernando Alves Rochinha, faro@mecanica.coppe.ufrj.br²

¹Universidade Federal do Rio de Janeiro/COPPE

²Universidade Federal do Rio de Janeiro/COPPE

Resumo: Wind turbines have been positioned near each other seeking to reduce the cost of installation and maintenance. However, due to proximity, the wake formed after the rotors interfere negatively with the energy harnessing of other turbines downstream. For that reason, the present control method of aligning each turbine in respect to the wind flow is not ideal because it aims to optimize the power individually not taking into account the interaction between turbines. Therefore, research has been carried out to develop a new control strategy which the power output is optimize for the whole wind farm. This method proposes a yaw misalignment on the turbines upstream, so the wake is redirect to somewhere out of other turbines. Albeit studies show the potential of this technique, to implement this in real wind turbines is a challenging task since it requires high processing computer capability to solve the numerical problem which takes a while to solve, thus makes closed loop control unfeasible and large scale optimization prohibitive. In addition, the wake dynamics is determined by the three-dimensional transient Navier-Stokes equations which do not have an analytic solution without simplifying hypothesis and boundary layer and forcing terms usually present in wind farms. Hence, low-fidelity models have been built in the last few years with the objective to enable wind farm control via wake redirection. This work seeks, therefore, to study the effectiveness of these models in predicting the power output for different inputs taking as baseline data from large-eddy simulations. Moreover, a new multi-fidelity model is proposed using nonlinear autoregressive Gaussian process regression.

Palavras-chave: Gaussian Processes, Uncertainty Quantification, Wind Energy