

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA**  
**FACULDADE DE ENGENHARIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM**  
**COMPUTACIONAL**

**Anderson de Moura Ribeiro**

**Otimização multiobjetivo do layout de parques eólicos offshore via algoritmos evolucionários utilizando um modelo analítico de esteira de turbulência**

Juiz de Fora

2023

Anderson de Moura Ribeiro

**Otimização multiobjetivo do layout de parques eólicos offshore via algoritmos evolucionários utilizando um modelo analítico de esteira de turbulência**

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem Computacional da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Modelagem Computacional.

Orientadora: Profa. Dra. Patricia Habib Hallak

Coorientador: Prof. Dr. Afonso Celso de Castro Lemonge

Prof. Dr. Felipe dos Santos Loureiro

Juiz de Fora

2023

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Ribeiro, Anderson de Moura.

Otimização multiobjetivo do layout de parques eólicos offshore via algoritmos evolucionários utilizando um modelo analítico de esteira de turbulência / Anderson de Moura Ribeiro. -- 2023.

196 p. : il.

Orientadora: Patricia Habib Hallak

Coorientadores: Afonso Celso de Castro Lemonge, Felipe dos Santos Loureiro

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Modelagem Computacional, 2023.

1. Parque eólico offshore. 2. Modelo analítico de esteiras. 3. Otimização multiobjetivo. 4. Algoritmos evolucionários. 5. FLORIS. I. Hallak, Patricia Habib, orient. II. Lemonge, Afonso Celso de Castro, coorient. III. Loureiro, Felipe dos Santos, coorient. IV. Título.

**Anderson de Moura Ribeiro**

**Otimização multiobjetivo do *layout* de parques eólicos *offshore* via algoritmos evolucionários utilizando um modelo analítico de esteira de turbulência**

Dissertação apresentada ao Programa de pós-Graduação em Modelagem Computacional da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Modelagem Computacional. Área de concentração: Modelagem Computacional.

Aprovada em 07 de março de 2023.

**BANCA EXAMINADORA**

**Prof(a) Dr(a). Patrícia Habib Hallak** - Orientadora

Universidade Federal de Juiz de Fora

**Prof(a) Dr(a). Felipe dos Santos Loureiro** - Coorientador

Universidade Federal de São João del Rei

**Prof(a) Dr(a). Afonso Celso de Castro Lemonge** - Coorientador

Universidade Federal de Juiz de Fora

**Prof(a) Dr(a). Bernardo Martins Rocha**

Universidade Federal de Juiz de Fora

**Prof(a) Dr(a). Bernardo Horowitz**

Universidade Federal de Pernambuco

**Prof(a) Dr(a). Milad Shadman**

Juiz de Fora, 06/03/2023.



Documento assinado eletronicamente por **Patricia Habib Hallak, Professor(a)**, em 07/03/2023, às 17:23, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Milad Shadman, Usuário Externo**, em 07/03/2023, às 17:23, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Afonso Celso de Castro Lemonge, Professor(a)**, em 07/03/2023, às 17:23, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Felipe dos Santos Loureiro, Usuário Externo**, em 07/03/2023, às 17:23, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Bernardo Horowitz, Usuário Externo**, em 07/03/2023, às 17:24, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Bernardo Martins Rocha, Coordenador(a)**, em 07/03/2023, às 17:25, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Uffj ([www2.uffj.br/SEI](http://www2.uffj.br/SEI)) através do ícone Conferência de Documentos, informando o código verificador **1173147** e o código CRC **5A4EBD45**.

*Aos meus pais e irmãos.*

## Resumo

Com a crescente demanda por fontes de energia renováveis, o setor eólico *offshore* se mostra promissor com grandes perspectivas de crescimento. Fatores como o *layout* dos aerogeradores e a intermitência dos ventos (direção e velocidade) têm um papel importante no desempenho dos parques devido ao efeito de esteira (*wake*). Além do *layout*, os tipos de turbinas também interferem diretamente no desempenho do parque. A otimização considerando ambos fatores como variáveis de decisão resulta em ganhos de potência e menor custo de energia, em relação a otimizações considerando apenas o *layout*, conforme mostra a literatura. O presente trabalho aplica esta metodologia e contribui com uma abordagem que visa reduzir o número de diferentes tipos de turbinas, realizando assim um *trade-off* entre o ganho de desempenho sem que os parques eólicos tenham demasiados modelos diferentes de aerogeradores, o que gera problemas logísticos de instalação, operação e manutenção. Utilizou-se modelos analíticos de esteira de turbulência em conjunto com algoritmos evolucionários para a otimização multiobjetivo do *layout* de parques eólicos considerando também os tipos de turbinas. Dois problemas multiobjetivo são formulados e tratados com duas abordagens. A primeira, proposta inovadora desta pesquisa, limita o número de modelos de aerogeradores diferentes, que é tratado como mais um objetivo; enquanto a segunda não limita a escolha do número de turbinas diferentes. Comparou-se os conjuntos de resultados obtidos com e sem a abordagem proposta no presente trabalho, e observou-se, nos dois estudos de caso analisados, que os resultados obtidos utilizando a metodologia aqui proposta apresentou um número reduzido de modelos diferentes de turbinas e resultados competitivos em termos dos objetivos de custo econômico e de performance dos parques. Por fim, aplicou-se um tomador de decisão multi-critério para extração dos resultados do conjunto obtido.

**Palavras-chave:** Parque eólico *offshore*, modelo analítico de esteiras, otimização multi-objetivo, algoritmos evolucionários, *FLORIS*.

# Abstract

With the growing demand for renewable energy sources, the wind energy industry shows promise with great growth prospects. Factors such as the wind turbine layout and the intermittency of the winds (direction and speed) play an important role in the performance of wind farms due to the wake effect. In addition to the layout, the wind turbine type also directly interferes in wind farm performance. The optimization considering both factors as decision variables results in power gains and lower cost of energy, compared to optimizations considering only the wind farm layout, as shown in the literature. The present work applies this methodology and contributes with an approach that aims to reduce the number of different wind turbine types, thus performing a trade-off between wind farm performance gain without wind farms having too many different wind turbine types, which leads to logistical problems of installation, operation and maintenance. It was applied analytical wake models in conjunction with evolutionary algorithms for the multiobjective optimization of the wind farm layout considering also the wind turbine type. Two multiobjective problems are formulated and treated with two different approaches. The first one, a novel proposal of this research, limits the number of different wind turbine types, which is treated as one more objective; while the second one does not limit the choice of the number of different turbine types. We compared the sets of results obtained with and without the approach proposed in this work, and observed, in the two case studies, that the results obtained using the methodology proposed here presented a reduced number of different turbine types and competitive results in terms of the economic and performance objectives for the wind farms. Finally, it was applied a multi-criteria decision maker to extract the results from the obtained set.

**Keywords:** Offshore wind farm, analytical wake model, multi-objective optimization, evolutionary algorithms, FLORIS.

## Agradecimentos

Em primeiro lugar, a Deus pela minha vida e oportunidade a mim concedida de viver esta experiência enriquecedora.

Aos meus familiares: à minha mãe, Nilda, pelo apoio incondicional e amparo nos momentos difíceis; ao meu pai, Josias, pelos ensinamentos e conselhos que moldaram muitas de minhas decisões e aos meus irmãos Felipe e Fabrício.

Aos meus professores e orientadores Profa. Dra. Patricia Habib Hallak, Prof. Dr. Afonso Celso de Castro Lemonge e Prof. Dr. Felipe dos Santos Loureiro, por toda disposição e empenho para comigo e com o presente trabalho.

À FAPEMIG, pelo apoio financeiro para realização desta pesquisa. Ao Programa de Pós-Graduação em Modelagem Computacional e às Universidades Federais de Juiz de Fora (UFJF) e de São João del-Rei (UFSJ) pela infraestrutura para realização desta pesquisa.

A todos os meus amigos que prestaram seu apoio e tempo durante toda minha jornada.

*“Nada a temer*

*Senão o correr da luta*

*Nada a fazer*

*Senão esquecer o medo*

*Abrir o peito à força*

*Numa procura*

*Fugir às armadilhas da mata escura”.*

*Milton Nascimento (Caçador de mim)*

# Conteúdo

<b>Lista de Figuras</b>	<b>8</b>
<b>Lista de Tabelas</b>	<b>15</b>
<b>Lista de Abreviações</b>	<b>17</b>
<b>1 Introdução</b>	<b>18</b>
1.1 Contextualização e justificativa . . . . .	18
1.2 Revisão bibliográfica . . . . .	22
1.2.1 Modelagem de parques eólicos . . . . .	22
1.2.2 Otimização do <i>layout</i> de parques eólicos . . . . .	28
1.3 Objetivos . . . . .	33
1.4 Organização do trabalho . . . . .	34
<b>2 Modelagem matemática de parques eólicos</b>	<b>35</b>
2.1 Condições do vento . . . . .	35
2.1.1 Distribuição conjunta de probabilidades de ocorrência das direções e velocidades do vento . . . . .	36
2.1.2 Perfil vertical de velocidades . . . . .	45
2.2 Turbinas eólicas e o modelo do disco atuador . . . . .	48
2.3 Modelos de esteira de turbinas eólicas . . . . .	53
2.3.1 Modelo do déficit de velocidade . . . . .	61
2.3.2 Modelo de turbulência . . . . .	64
2.3.3 Modelo de sobreposição de esteiras . . . . .	67
2.3.4 Procedimento de cálculo de velocidades nos pontos de interesse . . . . .	70
2.4 Verificação dos modelos de esteira . . . . .	72
2.4.1 Déficit de velocidade para uma turbina . . . . .	72
2.4.2 Verificação parque eólico Horns Rev . . . . .	78
<b>3 Indicadores dos parques eólicos</b>	<b>84</b>
3.1 Avaliação de desempenho do parque eólico . . . . .	84
3.1.1 Produção anual de energia . . . . .	84
3.1.2 Fator de capacidade . . . . .	85
3.1.3 Eficiência do layout . . . . .	86
3.2 Economia e modelos de custos . . . . .	86
3.2.1 Custo inicial do capital . . . . .	88
3.2.2 Gastos anuais de operação . . . . .	94
3.2.3 Custo nivelado de energia . . . . .	95
3.2.4 Custo de energia . . . . .	95
<b>4 Algoritmos evolutivos para otimização multi-objetivo</b>	<b>98</b>
4.1 Otimização multi-objetivo . . . . .	99
4.2 Algoritmos evolutivos . . . . .	102
4.3 NSGA-II . . . . .	105
4.3.1 Seleção dos pais por torneio . . . . .	112

4.3.2	Recombinação - <i>Simulated Binary Crossover</i> (SBX) . . . . .	114
4.3.3	Mutação polinomial . . . . .	116
4.4	Métricas de desempenho . . . . .	118
4.4.1	<i>Inverted Generational Distance Plus</i> - IGD+ . . . . .	121
4.4.2	Hipervolume . . . . .	123
4.5	SMS-EMOA . . . . .	124
4.6	Critérios de convergência/parada . . . . .	127
4.7	Tomador de decisão multi-critério . . . . .	129
<b>5</b>	<b>Experimentos numéricos e resultados</b>	<b>135</b>
5.1	Modelos de turbinas eólicas . . . . .	136
5.2	Regime anual de ventos . . . . .	137
5.3	Restrição de proximidade entre turbinas . . . . .	141
5.4	Formulação dos problemas . . . . .	142
5.4.1	Caso I - FC vs. LCOE . . . . .	145
5.4.2	Caso II - $\eta$ vs. COE . . . . .	146
5.4.3	Minimização do número de modelos diferentes de turbinas instaladas	146
5.5	Algoritmos e parâmetros . . . . .	149
5.6	Resultados e discussões . . . . .	150
5.6.1	Caso I - FC vs. LCOE . . . . .	151
5.6.2	Caso II - $\eta$ vs. COE . . . . .	166
<b>6</b>	<b>Conclusão</b>	<b>178</b>
	<b>Bibliografia</b>	<b>182</b>

## Lista de Figuras

- 1.1 Evolução da capacidade global instalada acumulada de energia eólica *offshore* em MW. Imagem retirada de ASSIS TAVARES et al. (2022) com dados de EWEA (2011), GWEC (2021). . . . . 19
- 1.2 Mapa 1: Estimativa da produção anual de energia (*Annual Energy Production - AEP*) ao longo da costa brasileira. Mapas 2 a 4: AEP detalhada por região brasileira (LOZER DOS REIS; MITSUO MAZETTO; COSTA MALATEAUX DA SILVA, 2021). A linha verde delimita a região com profundidade média até 20 m (Batimetria - *Bath. 20 m*) e a linha preta com profundidade média até 50 m (Batimetria - *Bath. 50 m*). . . . . 21
- 1.3 (a) e (b) Parque eólico de Horns Rev I (Dinamarca) em uma condição de máximo efeito das esteiras de turbulência e efeitos parciais de esteira, respectivamente. Imagem retirada de Porté-Agel, Bastankhah e Shamsoddin (2019). . . . . 21
- 1.4 Fenômenos mecânicos presentes no escoamento em parques eólicos, incluindo esteiras de turbulência, sua superposição e interações com a camada limite atmosférica (CLA), desenvolvimento de camadas limite internas e, se um parque eólico for suficientemente grande, o alcance de um regime de camada limite das turbinas eólicas totalmente desenvolvido. Adaptado de Stevens e Meneveau (2017). . . . . 23
- 1.5 *Layout* das turbinas dos parques eólicos de (a) Horns Rev e (b) Nysted. O desempenho das turbinas na (c) segunda e (d) oitava fileira como função da direção do vento em relação à configuração alinhada com a potência normalizada em função da primeira fileira ( $270^\circ$  para Horns Rev e  $278^\circ$  para Nysted). (e–k) Desempenho como função da distância ao longo da direção do vento  $255\text{--}285^\circ$  para Horns Rev e  $263\text{--}293^\circ$  para Nysted. Os dados são para uma velocidade do vento de entrada de  $8 \pm 0,5$  m/s e são extraídos, originalmente, de (BARTHELMIE et al., 2010). Figura adaptada de Stevens e Meneveau (2017). . . . . 26
- 1.6 Linha do tempo das contribuições científicas a respeito do problema de otimização de parques eólicos. Figura adaptada de (ACERO et al., 2014). . . . . 29
  
- 2.1 Escalas de tempo e espaço dos movimentos atmosféricos. Adaptado de Spera (2009) . . . . . 36
- 2.2 (a) e (b) Parque eólico de Horns Rev I (Dinamarca) em uma condição de máximo efeito das esteiras de turbulência e efeitos parciais de esteira, respectivamente (Grupo Vattenfall) (PORTE-AGEL; BASTANKHAH; SHAMSODDIN, 2019); Campo de velocidades médias simulado exibido em um plano de corte horizontal (paralelo ao solo) na altura do eixo das turbinas com o vento proveniente do Oeste ( $\theta = 270^\circ$ ) (c) (condição de maior efeito de esteira) e  $\theta = 284^\circ$  (d) (condição de efeitos parciais de esteira). Adaptado de (PORTE-AGEL; WU; CHEN, 2013). . . . . 39

2.3	Rosa dos ventos mostrando a frequência de ocorrência do vento para 16 setores de direção, conforme escala de probabilidades no gráfico, assim como a velocidade média de ocorrência do vento em cada setor, seguindo a escala <i>Beaufort</i> em nós (1 nó = 1.852 km/h). Adaptado de Copernicus (2016). . . . .	40
2.4	Probabilidade de ocorrência das barras (velocidade, direção) de condição do vento. Adaptado de (WANG et al., 2015) . . . . .	41
2.5	Parâmetros da distribuição de Weibull ( $k, c$ ) e frequência de ocorrência ( $f_{occ}$ ) como funções da direção do vento. Linha em azul são os dados da tabela 2.1 dos 12 setores; linha vermelha é a abordagem proposta por (FENG; SHEN, 2015a) - interpolação dos dados fornecidos ( <i>Spline</i> ). . . . .	43
2.6	Função densidade probabilidade bivariada da velocidade e direção do vento: (a) dos dados de medição (considerando $\Delta U = 1$ m/s, $\Delta \theta = 10^\circ$ ) (FENG; SHEN, 2015a); (b) utilizando a interpolação Spline - resultados da referência (FENG; SHEN, 2015a); (c) utilizando a interpolação Spline - resultados da implementação no presente trabalho. . . . .	44
2.7	(a) Melhoria na potência gerada por um parque eólico com seu layout otimizado utilizando três opções de pré-processamento da discretização das direções do vento e reavaliados com um número maior de setores de direção do vento; (b) Zonas afetadas pela esteira de turbulência da turbina 1 (WT 1) para as direções do vento considerados na discretização com poucos setores. Percebe-se que as turbinas WT 2 e 3 não são afetadas para esta discretização da direção, quando na realidade serão afetadas adotando-se mais setores de direção do vento (cenário mais realista). Adaptado de Feng e Shen (2015b). . . . .	45
2.8	Perfil vertical de velocidades experimental. Adaptado de Tempel (2006) . . . . .	46
2.9	Componentes de uma turbina eólica . . . . .	49
2.10	Modelo do disco atuador de uma turbina eólica; $U$ , velocidade média do vento; 1, 2, 3, e 4 índices das posições analisadas e $T$ a força de reação do empuxo provocada no disco atuador. Adaptada de Manwell, McGowan e Rogers (2010). . . . .	50
2.11	Exemplo de variação dos parâmetros operacionais de uma turbina eólica controlada por <i>Stall</i> ; $U_{cut_{in}}$ , velocidade de acionamento do rotor; $U_{Rated}$ , velocidade nominal de operação; $U_{cut_{out}}$ , velocidade de desacionamento do rotor. Adaptada de Manwell, McGowan e Rogers (2010). . . . .	53
2.12	Regiões da esteira afetadas pela turbina eólica (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Perfil vertical de velocidades afetadas pelos efeitos de esteira da turbina na região da <i>far-wake</i> , $\bar{\mathbf{u}}$ , e perfil aproximadamente axissimétrico do déficit de velocidades, $\Delta \bar{\mathbf{u}}$ , da esteira da turbina na região da <i>far-wake</i> ; $\mathbf{x}_0$ o comprimento da região de <i>near-wake</i> . . . . .	54
2.13	Esquemático do túnel de vento (vistas frontais e laterais), sistema de coordenadas e locais de medição (figura do topo e do meio), e fotografia da seção de teste do túnel de vento (figura de baixo). Adaptado de CHAMORRO e PORTÉ-AGEL (2008). . . . .	56
2.14	Distribuição transversal da velocidade média normalizada em diferentes posições à jusante da turbina para o caso com rugosidade superficial. <b>a</b> $x/d_0 = 3$ ; <b>b</b> $x/d_0 = 5$ ; <b>c</b> $x/d_0 = 10$ ; e <b>d</b> $x/d_0 = 15$ . A linha horizontal tracejada representa a altura do eixo da turbina. $U$ velocidade do vento; $U_{hub}$ velocidade do vento na altura do eixo da turbina; $r$ raio do rotor da turbina (CHAMORRO; PORTÉ-AGEL, 2008). . . . .	57

2.15	Distribuição transversal do déficit de velocidade normalizado em diferentes posições à jusante da turbina para o caso com rugosidade superficial. <b>a</b> $x/d_0 = 3$ ; <b>b</b> $x/d_0 = 5$ ; <b>c</b> $x/d_0 = 10$ ; e <b>d</b> $x/d_0 = 15$ . A linha horizontal tracejada representa a altura do eixo da turbina. $\Delta U$ déficit de velocidade; $U_{hub}$ velocidade do vento na altura do eixo da turbina; $r$ raio do rotor da turbina (CHAMORRO; PORTÉ-AGEL, 2008). . . . .	58
2.16	Perfis verticais de velocidade com $U_{hub} = 9$ m/s na altura do eixo da turbina (a) velocidade média, $u$ (m/s); (b) intensidade de turbulência, $I_u$ . Adaptado de Wu e Porte-Agel (2012) . . . . .	59
2.17	Comparação dos perfis vertical (a) e lateral (b) do déficit de velocidades normalizado $\Delta U/U_{hub}$ . Adaptado de Wu e Porte-Agel (2012). . . . .	60
2.18	Estimativa de erro de cada abordagem de simulação como uma função do custo computacional para o <i>benchmark</i> de estratificação atmosférica neutra. A estimativa de erro é a norma da diferença normalizada dos perfis de déficit de velocidade unidimensional, com média de tempo nas direções vertical e horizontal e somada para todas as distâncias a jusante. O custo computacional é dado em horas de processamento para uma simulação da esteira com 10 minutos de duração e não inclui o custo de simulação de fluxo atmosférico de entrada e não levando em consideração o desempenho dos códigos de implementação em si (DOUBRAWA et al., 2020). . . . .	62
2.19	Ilustração da comparação entre o perfil gaussiano (utilizado para modelar distribuição radial do déficit de velocidades) e a distribuição do tipo <i>Top-hat</i> (utilizada para a intensidade de turbulência). . . . .	66
2.20	Potência gerada pelo parque eólico de Horns Rev I com diferentes cenários de direção do vento. Adaptado de Porté-Agel, Bastankhah e Shamsoddin (2019), Barthelmie et al. (2009). . . . .	68
2.21	Distribuição dos 9 pontos de interesse na região do rotor da turbina em que as velocidades do vento são calculadas. $d$ representa o diâmetro do rotor e $z_h$ a altura do eixo da turbina. A velocidade efetiva do vento que incide na turbina é determinada como a média da velocidade do vento nestes pontos. . . . .	70
2.22	Plano $xz$ - Vista lateral do campo de velocidades em $y = 0$ . . . . .	74
2.23	Plano $xy$ - Vista superior do campo de velocidades em $z = z_h$ . . . . .	74
2.24	Comparação dos perfis verticais de velocidades do escoamento atmosférico livre - Condição de estabilidade Neutra - utilizados no presente trabalho (FLORIS/NREL, perfil logarítmico) com os utilizados por Wu e Porte-Agel (2012). . . . .	75
2.25	Perfis verticais do déficit de velocidades para condição $z_0 = 0.05m$ e $I = 0.095$	76
2.26	Perfis verticais do déficit de velocidades para condição $z_0 = 0.005m$ e $I = 0.07$	76
2.27	Perfil longitudinal do déficit de velocidades máximo normalizado para $z_0 = 0.05 m$ e $I = 0.095$ . . . . .	76
2.28	Perfil longitudinal do déficit de velocidades máximo normalizado para $z_0 = 0.005 m$ e $I = 0.07$ . . . . .	77
2.29	Perfil do déficit de velocidades normalizado em relação a $r_{1/2}(x)$ de todas as posições, que recaem no mesmo perfil gaussiano ( <i>gaussian self-similarity</i> em linha preta) - abordagem de comparação de acordo com (BASTANKHAH; PORTE-AGEL, 2014) - em comparação com os resultados em <i>LES</i> (WU; PORTE-AGEL, 2012) (pontos com coloração de acordo com a posição em $x$ ) também normalizados em relação a $r_{1/2}(x)$ para as duas condições de escoamento livre avaliadas. . . . .	77
2.30	Turbina Vestas V80 - 2MW (JENSEN et al., 2011) . . . . .	78

2.31	Distribuição da potência normalizada de Horns Rev I para diferentes direções de vento. Os resultados dos 3 modelos de superposição de esteiras (NIAYIFAR; PORTÉ-AGEL, 2016; GUNN et al., 2016; VOUTSINAS; RADOS; ZERVOS, 1990) disponíveis na plataforma FLORIS/NREL (NREL, 2022) são comparados com os resultados <i>LES</i> de (PORTE-AGEL; WU; CHEN, 2013) . . . . .	79
2.32	Agrupamento das turbinas de Horns Rev I . . . . .	80
2.33	Campos de velocidade resultantes dos casos das figuras 2.32a, 2.32b e 2.32c, respectivamente . . . . .	81
2.34	Comparação dos resultados de potências normalizadas, conforme agrupamento das turbinas da figura 2.32a, entre os modelos analítico (FLORIS/NREL) e RANS/k-epsilon (NADERI; PARVANEHMASIHA; TORABI, 2018), e os resultados experimentais (BARTHELMIE et al., 2009) . . . . .	82
2.35	Comparação dos resultados de potências normalizadas, conforme agrupamento das turbinas da figura 2.32b, entre os modelos analítico (FLORIS/NREL) e RANS/k-epsilon (NADERI; PARVANEHMASIHA; TORABI, 2018), e os resultados experimentais (BARTHELMIE et al., 2009) . . . . .	82
2.36	Comparação dos resultados de potências normalizadas, conforme agrupamento das turbinas da figura 2.32c, entre os modelos analítico (FLORIS/NREL) e RANS/k-epsilon (NADERI; PARVANEHMASIHA; TORABI, 2018), e os resultados experimentais (BARTHELMIE et al., 2009) . . . . .	83
3.1	Esquemático de algumas estruturas de fundação para instalação de turbinas eólicas <i>offshore</i> (WANG et al., 2018a). . . . .	89
3.2	Esquema de instalação dos cabos elétricos de interconexão entre as turbinas eólicas do parque offshore de Thanet (na Inglaterra). Adaptado de Vattenfall group (2021). . . . .	92
3.3	Processo de funcionamento do algoritmo de Kruskal (DOUG, 2013). Os nós A, B, C, D, E, F, G e H representam as turbinas e as arestas (em preto) representam as possíveis conexões (candidatas) consideradas para se construir o <i>minimum-spanning-tree</i> . Os pesos de cada aresta representam o comprimento de cabo necessário para a conexão das duas turbinas em questão, o que é dependente do layout das turbinas ao longo do parque. As arestas marcadas em vermelho são as conexões selecionadas pelo algoritmo para comporem a <i>minimum-spanning-tree</i> que representa os cabos de conexão entre as turbinas. . . . .	97
4.1	Um problema de otimização. O rótulo na saída se lê “especificado”, ao invés de “conhecido”, pois o valor específico ótimo pode não ser conhecido, apenas definido implicitamente (e.g., o menor valor possível) (EIBEN; SMITH, 2015). . . . .	98
4.2	Diagrama de blocos de um sistema de projeto assistido por computador à base de um mecanismo de otimização. (TAKAHASHI, 2007) . . . . .	99
4.3	Vetor de variáveis de decisão $\mathbf{x} \in D$ (sendo $D \subseteq \mathbb{R}^3$ o espaço de busca das variáveis de decisão) com sua imagem no espaço das soluções, i.e., $f(\mathbf{x}) \in \mathbb{R}^2$ . . . . .	100
4.4	Frente de pareto do exemplo da Figura 4.3, onde o objetivo é minimizar $f_1$ e $f_2$ . . . . .	101
4.5	Ilustração das características de convergência e diversidade que a imagem de um conjunto discreto $Q'$ (representado pelos pontos vermelhos) deve ter para que ele seja considerado uma boa aproximação de $Q$ (VARGAS, 2015). . . . .	102

4.6	Exemplo da ordenação de pareto em um problema com duas funções objetivos pelo procedimento proposto por GOLDBERG (1989). . . . .	106
4.7	Esquema de seleção da próxima geração no NSGA-II (DEB et al., 2002). . . . .	109
4.8	Cálculo do <i>Crowding-distance</i> . Os círculos preenchidos são soluções do mesmo conjunto não-dominado (DEB et al., 2002). . . . .	111
4.9	Função de densidade de probabilidade para criação dos vetores filhos a partir do operador SBX- $\eta_c$ (DEB; SINDHYA; OKABE, 2007). . . . .	116
4.10	Função de densidade de probabilidade para criação de um vetor filho mutado utilizando o operador de mutação polinomial (DEB; DEB, 2014). . . . .	117
4.11	Os dois propósitos da otimização multi-objetivo (DEB, 2001). . . . .	118
4.12	Um conjunto ideal de soluções não-dominadas (DEB; DEB, 2014) . . . . .	119
4.13	Pontos de interesse para avaliação da métrica <i>generational distance</i> (GD) (DEB et al., 2002). . . . .	122
4.14	Ilustração dos dois vetores distância $\mathbf{d}$ (distância euclidiana) e $\mathbf{d}^+$ (ISHI-BUCHI et al., 2015) . . . . .	123
4.15	O hipervolume gerado pelas soluções não-dominadas (DEB, 2001). . . . .	124
4.16	O hipervolume dominado pela frente $\mathcal{F}_2 = \{y_7, \dots, y_{10}\}$ está colorido em cinza claro e as contribuições $\Delta_s(y_8, \mathcal{F}_2)$ e $\Delta_s(y_9, \mathcal{F}_2)$ são visualizadas pelos retângulos em azul (BEUME; NAUJOKS; EMMERICH, 2007). . . . .	125
4.17	A solução ótima escolhida utilizando a abordagem dos vetores de pseudo- pesos (DEB, 2001). . . . .	133
4.18	Comparação das diferentes escalas dos objetivos $f_1$ e $f_2$ . Os limites inferiores e superiores de ambos os objetivos são <i>Escala f1</i> : [2.5854948741290507, 79.76691689089954] e <i>Escala f2</i> : [0.011423710054466784, 0.7065147569542829] (Blank; Deb, 2020). . . . .	134
4.19	Ilustração dos pontos importantes para problemas de otimização multi- objetivo (WANG; HE; YAO, 2017) . . . . .	134
5.1	Curvas do coeficiente de potência, $C_P(U)$ . . . . .	137
5.2	Curvas do coeficiente de empuxo, $C_T(U)$ . . . . .	138
5.3	Função densidade de probabilidades utilizada nos estudos de caso, $p(\theta, U(z_r))$ . As figuras mostram o regime anual de ventos no local de instalação do par- que eólico. . . . .	139
5.4	Perfis verticais de velocidade, $U(z)$ extraído do FLORIS, (segundo lei de potência da Equação 2.12) para cada uma das $N_{ws}$ velocidades ( $U(z_r)$ ) discretizadas em $p(\theta, U(z_r))$ da Figura 5.3. . . . .	140
5.5	Espaço de busca das variáveis $(x_i, y_i)$ para composição do <i>layout</i> do parque eólico. . . . .	144
5.6	Vetor de variáveis de decisão e tabela com informações sobre os modelos de aerogeradores pré-cadastrados (Seção 5.1), acessados através dos ponteiros, $mod_i$ . . . . .	146
5.7	Frentes de Pareto resultantes das 20 rodadas independentes do Caso I - FC vs. LCOE: a) NSGA-II e b) SMS-EMOA. . . . .	151
5.8	a) Frentes de Pareto Unificadas das 20 rodadas independentes do Caso I - FC vs. LCOE, conforme cada algoritmo e b) Frente de Pareto Unificada entre as frentes de Pareto de a). . . . .	152

5.9	Ponto de referência, $W = (1.1, 1.1)$ em vermelho, para o cálculo do Hipervolume das frentes de Pareto resultante das 20 rodadas independentes dos algoritmos a) NSGA-II e b) SMS-EMOA; Curvas de evolução das Métricas de desempenho ( $IGD^+$ e Hipervolume) ao longo das gerações de cada uma das 20 rodadas independentes dos algoritmos c) NSGA-II e d) SMS-EMOA.	153
5.10	a) Histograma do número de indivíduos da frente de Pareto da Figura 5.8b que apresentaram parques eólicos com 4, 5, ..., 10 modelos diferentes de aerogeradores para o Caso I - FC vs. LCOE; b) Número de ocorrências em que cada modelo, dentre os 25 disponíveis para seleção, foi selecionado para cada uma das 30 turbinas em cada um dos indivíduos que constituem a frente de Pareto da Figura 5.8b	155
5.11	Frentes de Pareto unificadas das 20 rodadas independentes do Caso I - FC vs. LCOE vs. $N_{dma}$ utilizando os algoritmos a) NSGA-II e b) SMS-EMOA. c) Frente de Pareto unificada entre as frentes de a) e b).	157
5.12	Curvas de evolução das Métricas de desempenho ( $IGD^+$ e Hipervolume) ao longo das gerações de cada uma das 20 rodadas independentes dos algoritmos a) NSGA-II e b) SMS-EMOA para o Caso I - FC vs. LCOE vs. $N_{dma}$	158
5.13	a) Histograma do número de indivíduos da frente de Pareto da Figura 5.11c que apresentaram parques eólicos com 2, 3, ..., 12 modelos diferentes de aerogeradores para o Caso I - FC vs. LCOE vs. $N_{dma}$ ; b) Número de ocorrências em que cada modelo, dentre os 25 disponíveis para seleção, foi selecionado para cada uma das 30 turbinas em cada um dos indivíduos que constituem a frente de Pareto da Figura 5.11c	159
5.14	Comparação da frente de Pareto das abordagens do Caso I - FC vs. LCOE e Caso I - FC vs. LCOE vs. $N_{dma}$ no plano dos objetivos FC vs. LCOE.	160
5.15	Comparação da frente de Pareto das abordagens do Caso I - FC vs. LCOE e Caso I - FC vs. LCOE vs. $N_{dma}$ no plano dos objetivos FC vs. LCOE, utilizando uma rotulação nos indivíduos segundo seu número de modelos de aerogeradores diferentes, $N_{dma}$ .	161
5.16	Indivíduos selecionados pelo tomador de decisão multi-critério, da Seção 4.7, segundo vetores de peso $W_1$ , $W_2$ e $W_3$ , marcados na a) frente de Pareto e na b) projeção da frente de Pareto no plano dos objetivos FC vs. LCOE.	161
5.17	<i>Layout</i> dos parques eólicos escolhidos conforme vetores de peso a) $W_1$ , b) $W_2$ e c) $W_3$ . Os números apresentam o modelo de cada aerogerador, dentre os 25 disponíveis da Tabela 5.1. A região delimitada pelos círculos azuis tracejados representa a região referente às restrições de proximidade (ver Seção 5.3) de cada uma das turbinas.	162
5.18	a) Marcação das 3 condições de vento utilizadas para ilustrar os campos de velocidades dos parques eólicos selecionados pelo tomador de decisão multi-critério. $\mathbf{V}_{U_\infty, \theta}^1 = (U_\infty = 9 \text{ m/s}, \theta = 230^\circ)$ , $\mathbf{V}_{U_\infty, \theta}^2 = (U_\infty = 9 \text{ m/s}, \theta = 90^\circ)$ e $\mathbf{V}_{U_\infty, \theta}^3 = (U_\infty = 9 \text{ m/s}, \theta = 70^\circ)$ ; b) Convenção do sistema de orientações das direções do vento, utilizada pelo <i>FLORIS</i> , e ilustrada conforme $\mathbf{V}_{U_\infty, \theta}^1$ , $\mathbf{V}_{U_\infty, \theta}^2$ e $\mathbf{V}_{U_\infty, \theta}^3$ .	163
5.19	Campos de velocidades do parque eólico apontado pelo vetor de pesos $W_1$ para cada uma das condições de vento selecionadas na Figura 5.18a.	163
5.20	Campos de velocidades do parque eólico apontado pelo vetor de pesos $W_2$ para cada uma das condições de vento selecionadas na Figura 5.18a.	164
5.21	Campos de velocidades do parque eólico apontado pelo vetor de pesos $W_3$ para cada uma das condições de vento selecionadas na Figura 5.18a.	164

5.22	Eficiência do layout, $\eta$ (Equação 3.4), dos parques eólicos a) $W_1$ , b) $W_2$ e c) $W_3$ em função das direções do vento, $\theta$ . . . . .	165
5.23	Frentes de Pareto das 20 rodadas independentes do Caso II - $\eta$ vs. COE: a) NSGA-II e b) SMS-EMOA. c) Frentes de Pareto unificadas das 20 rodadas independentes do Caso II - $\eta$ vs. COE, por algoritmo de a) e b). . . . .	166
5.24	Curvas de evolução das métricas de desempenho ( $IGD^+$ e Hipervolume) ao longo das gerações de cada uma das 20 rodadas independentes dos algoritmos a) NSGA-II e b) SMS-EMOA. . . . .	167
5.25	a) Histograma do número de indivíduos da frente de Pareto da Figura 5.8b que apresentaram parques eólicos com 3, 4, ..., 7 modelos diferentes de aerogeradores para o Caso I - $\eta$ vs. COE; b) Frente de Pareto unificada final entre as frentes da Figura 5.23c. . . . .	168
5.26	Frente de Pareto unificada das 20 rodadas independentes do Caso II - $\eta$ vs. COE vs $N_{dma}$ : a) NSGA-II e b) SMS-EMOA. Curvas de evolução das Métricas de desempenho ( $IGD^+$ e Hipervolume) ao longo das gerações de cada uma das 20 rodadas independentes dos algoritmos c) NSGA-II e d) SMS-EMOA. . . . .	169
5.27	a) Histograma do número de indivíduos da frente de Pareto da Figura 5.27c que apresentaram parques eólicos com 2, 3, ..., 6 modelos diferentes de aerogeradores para o Caso II - $\eta$ vs. COE vs. $N_{dma}$ ; b) Número de ocorrências em que cada modelo, dentre os 25 disponíveis para seleção, foi selecionado para cada uma das 30 turbinas em cada um dos indivíduos que constituem a frente de Pareto da Figura 5.27c; c) Frente de Pareto unificada entre as frentes de Pareto das Figuras 5.26a e 5.26b. . . . .	171
5.28	Comparação da frente de pareto das abordagens do Caso II - $\eta$ vs. COE e Caso II - $\eta$ vs. COE vs. $N_{dma}$ no plano dos objetivos $\eta$ vs. COE. . . . .	172
5.29	Comparação da frente de pareto das abordagens do Caso II - $\eta$ vs. COE e Caso II - $\eta$ vs. COE vs. $N_{dma}$ no plano dos objetivos $\eta$ vs. COE utilizando rotulação nos indivíduos segundo seu número de modelos de aerogeradores diferentes, $N_{dma}$ ; a) mostra os indivíduos da frente de Pareto que têm no máximo 5 modelos diferentes de aerogeradores, enquanto b) mostra os indivíduos com no máximo 7 modelos diferentes de aerogeradores. . . . .	173
5.30	Indivíduos selecionados pelo tomador de decisão multi-critério, da Seção 4.7, segundo vetores de peso $W_1$ , $W_2$ e $W_3$ . . . . .	174
5.31	<i>Layout</i> dos parques eólicos escolhidos conforme vetores de peso a) $W_1$ , b) $W_2$ e c) $W_3$ . Os números apresentam o modelo de cada aerogerador, dentre os 25 disponíveis da Tabela 5.1. A região delimitada pelos círculos azuis tracejados representa a região referente às restrições de proximidade (ver Seção 5.3) de cada uma das turbinas. . . . .	175
5.32	Campos de velocidades do parque eólico apontado pelo vetor de pesos $W_1$ para cada uma das condições de vento selecionadas na Figura 5.18a. . . . .	176
5.33	Campos de velocidades do parque eólico apontado pelo vetor de pesos $W_2$ para cada uma das condições de vento selecionadas na Figura 5.18a. . . . .	176
5.34	Campos de velocidades do parque eólico apontado pelo vetor de pesos $W_3$ para cada uma das condições de vento selecionadas na Figura 5.18a. . . . .	177
5.35	Eficiência do layout, $\eta$ (Equação 3.4), dos parques eólicos a) $W_1$ , b) $W_2$ e c) $W_3$ em função das direções do vento, $\theta$ . . . . .	177

## Lista de Tabelas

1.1	Classificação dos modelos. Adaptado de Sanderse, Pijl e Koren (2011) . . . . .	24
2.1	Parâmetros da distribuição de Weibull ( $k, c$ ) e frequência de ocorrência ( $f$ ) para 12 setores de direção do vento (FENG; SHEN, 2015a) . . . . .	42
2.2	Modelos comparados na simulação de esteira; O modelo de escoamento de entrada do tipo <i>Prescribed</i> equivale aos perfis logarítmicos/lei de potência da seção 2.1.2; os demais modelos são apenas considerados aqui a título de comparação; para maiores detalhes verificar Doubrawa et al. (2020). O modelo de turbina do tipo $C_P, C_T$ são os apresentados na Seção 2.2; para maiores detalhes dos demais modelos, verificar referência. Adaptado de Doubrawa et al. (2020). . . . .	61
2.3	Diferentes técnicas de sobreposição utilizadas na literatura para modelar as sobreposições de esteira em parques eólicos. . . . .	69
5.1	Modelos de turbinas eólicas pré-selecionadas . . . . .	136
5.2	Distância média entre turbinas eólicas em parques eólicos offshore . . . . .	142
5.3	Parâmetros dos operadores de recombinação e mutação <i>default</i> conforme Blank e Deb (2020) . . . . .	150
5.4	Experimentos numéricos . . . . .	150
5.5	Análise estatística das métricas de desempenho para as 20 rodadas independentes de cada um dos dois algoritmos (NSGA-II e SMS-EMOA) para o Caso I - FC vs. LCOE, onde: $IGD^+_{media}$ e $HV_{media}$ são a média da métrica $IGD^+$ e do hipervolume, respectivamente, das 20 rodadas independentes; $\sigma_{IGD^+}$ e $\sigma_{HV}$ o desvio padrão das métricas de desempenho; $IGD^+_{min}$ e $IGD^+_{max}$ os valores mínimo e máximo do $IGD^+$ dentre as 20 rodadas independentes e, de maneira análoga para os valores $HV_{min}$ e $HV_{max}$ do hipervolume. . . . .	154
5.6	Análise estatística das métricas de desempenho para as 20 rodadas independentes de cada um dos dois algoritmos (NSGA-II e SMS-EMOA) para o Caso I - FC vs. LCOE vs. $N_{dma}$ , onde: $IGD^+_{media}$ e $HV_{media}$ são a média da métrica $IGD^+$ e do hipervolume, respectivamente, das 20 rodadas independentes; $\sigma_{IGD^+}$ e $\sigma_{HV}$ o desvio padrão das métricas de desempenho; $IGD^+_{min}$ e $IGD^+_{max}$ os valores mínimo e máximo do $IGD^+$ dentre as 20 rodadas independentes e, de maneira análoga para os valores $HV_{min}$ e $HV_{max}$ do hipervolume. . . . .	156
5.7	Análise estatística das métricas de desempenho para as 20 rodadas independentes de cada um dos dois algoritmos (NSGA-II e SMS-EMOA) para o Caso II = $\eta$ vs. COE, onde: $IGD^+_{media}$ e $HV_{media}$ são a média da métrica $IGD^+$ e do hipervolume, respectivamente, das 20 rodadas independentes; $\sigma_{IGD^+}$ e $\sigma_{HV}$ o desvio padrão das métricas de desempenho; $IGD^+_{min}$ e $IGD^+_{max}$ os valores mínimo e máximo do $IGD^+$ dentre as 20 rodadas independentes e, de maneira análoga para os valores $HV_{min}$ e $HV_{max}$ do hipervolume. . . . .	168

5.8 Análise estatística das métricas de desempenho para as 20 rodadas independentes de cada um dos dois algoritmos (NSGA-II e SMS-EMOA) para o Caso II =  $\eta$  vs. COE vs.  $N_{dma}$ , onde:  $IGD_{media}^+$  e  $HV_{media}$  são a média da métrica  $IGD^+$  e do hipervolume, respectivamente, das 20 rodadas independentes;  $\sigma_{IGD^+}$  e  $\sigma_{HV}$  o desvio padrão das métricas de desempenho;  $IGD_{min}^+$  e  $IGD_{max}^+$  os valores mínimo e máximo do  $IGD^+$  dentre as 20 rodadas independentes e, de maneira análoga para os valores  $HV_{min}$  e  $HV_{max}$  do hipervolume. . . . . 170

## Lista de Abreviações

ACO	Ant colony optimization
AE	Algoritmo evolucionário
AEP	Annual Energy Production
AOE	Annual operation expenses
BEM	Blade Element Momentum
BOS	Base of station
CLA	Camada limite atmosférica
CFD	Computational fluid dynamics
CIC	Custo inicial de capital
COE	Cost of energy
DE	Differential evolution
DECOM	Custo de descomissionamento
DWMT	Dynamic wake meandering type
EPE	Empresa de Pesquisa Energética
EWEA	Europe Wind Energy Association
FC	Fator de capacidade
FDP	Função densidade de probabilidade
FLORIS	Flow Redirection and Induction in Steady State
GA	Genetic algorithm
GWEC	Global Wind Energy Council
IEA	International Energy Agency
LCOE	Levelized cost of energy
LEASE	Custo de concessão da terra (ou do mar)
LES	Large Eddy Simulation
LiDAR	Light detection and ranging
MOEA	Multi-objective evolutionary algorithm
NREL	National renewable energy laboratory
NSGA-II	Non-dominated sorting genetic algorithm II
OM	Custo de operação e manutenção
PAE	Produção anual de energia
PSO	Particle swarm optimization
RANS	Reynolds-averaged Navier–Stokes
RANS-E	Reynolds-averaged Navier-Stokes elíptica
RANS-P	Reynolds-averaged Navier-Stokes parabólica
SBX	Simulated binary crossover
SCADA	Supervisory control and data acquisition
SMS-EMOA	S metric selection evolutionary multi-objective algorithm
SSA	Steady State Analytical

# 1 Introdução

Espera-se que as energias renováveis venham a desempenhar um papel importante no atendimento às necessidades energéticas mundiais no futuro, mitigando simultaneamente as mudanças climáticas e a poluição ambiental. Enquanto a demanda mundial de energia continua a aumentar a uma taxa média anual de cerca de 2%, a maior parte da demanda (cerca de 80%) era, até o ano de 2018, atendida por combustíveis fósseis (IEA, 2018), apesar dos conhecidos impactos negativos sobre o meio ambiente e o clima. Isto, juntamente com as crescentes preocupações de segurança em torno da energia nuclear, levou muitos países a estabelecer metas estratégicas ambiciosas para as energias renováveis com baixas emissões de gases de efeito estufa e poluentes, incluindo a energia eólica (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Um objetivo, definido pela Agência Internacional de Energia (*International Energy Agency - IEA*), é de suprir 18% das necessidades globais de eletricidade através da energia eólica até 2050 (IEA, 2013). Além disso, investir em energia solar, eólica e geotérmica, melhorar a produtividade energética e garantir energia para todos é vital para alcançar a 7<sup>a</sup> meta de desenvolvimento sustentável - Energia acessível e limpa - das Nações Unidas até 2030 (UNITED NATIONS, acessado 12 Fev 2023).

Para que essas metas sejam atingidas, a quantidade total de energia eólica gerada deverá aumentar substancialmente nos próximos anos. Atingir esse crescimento exigirá, necessariamente, o projeto e a instalação de novos grandes parques eólicos em regiões de alto potencial eólico e a expansão dos existentes (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019).

## 1.1 Contextualização e justificativa

A modalidade de energia eólica *offshore* (i.e., parques eólicos no mar) tem expandido sua capacidade nas últimas décadas, de acordo com dados da Associação Européia de Energia Eólica (*Europe Wind Energy Association - EWEA*) de 1991 a 2010 (EWEA, 2011) e

do Conselho Global de Energia Eólica (*Global Wind Energy Council - GWEC*) para o período de 2011 a 2020 (GWEC, 2021), conforme mostra a Figura 1.1 (retirada de ASSIS TAVARES et al. (2022)), aumentando de 1% da capacidade de produção globais para instalações eólicas em 2009 para mais de 4,5% em 2020 (GWEC, 2021; ASSIS TAVARES et al., 2022). Embora ainda seja um setor recente, o setor eólico *offshore* é um dos setores mais promissores, com um potencial de geração de cerca de 600 TWh, determinada pela IEA, de acordo com o cenário de desenvolvimento sustentável para 2000-2030 (IEA, 2019). Além disso, conforme pontuado pela IEA (2019), os custos de desenvolvimento da indústria de energia eólica *offshore* estão diminuindo nos últimos anos, e os especialistas prevêm que esses custos sejam mais competitivos nas próximas décadas (IEA, 2019).

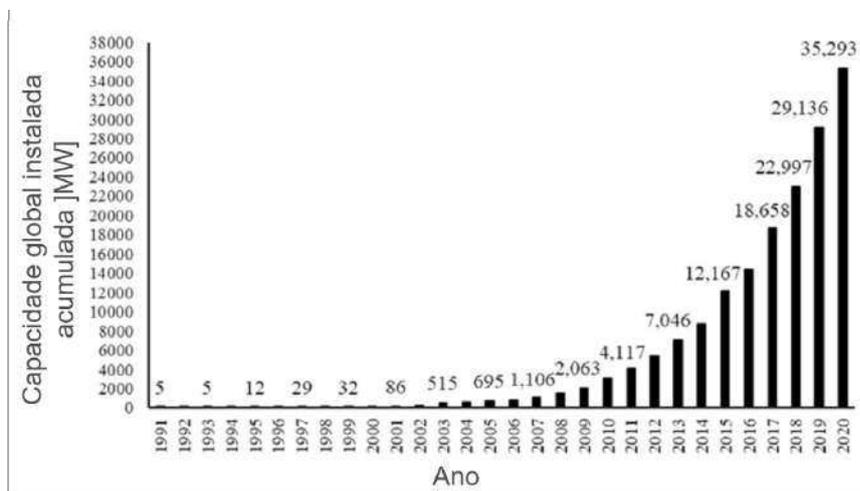


Figura 1.1: Evolução da capacidade global instalada acumulada de energia eólica *offshore* em MW. Imagem retirada de ASSIS TAVARES et al. (2022) com dados de EWEA (2011), GWEC (2021).

O Brasil, um dos dez principais países do *ranking* mundial de capacidade instalada de energia eólica *onshore* (i.e., parques eólicos em terra), é visto como um mercado emergente de energia eólica *offshore* (GWEC, 2017; IEA, 2019); entretanto o recurso eólico *offshore* ainda não está sendo explorado no país. Além disso, a Empresa de Pesquisa Energética (EPE) estimou um potencial teórico de 6.767 TW no país (EPE, 2020). Vinhoza e Schaeffer (2021), através de uma análise de decisão espacial multicritério, estimaram um potencial eólico *offshore* de 1688 GW, um potencial técnico de 1064 GW, assim como um potencial ambiental e social de 330 GW na Zona Econômica Exclusiva brasileira. Este potencial é mais de 450 vezes maior do que a capacidade eólica local

instalada em terra em 2019, que era de 15,45 GW e correspondia a cerca de 9% da participação na matriz energética brasileira (LOZER DOS REIS; MITSUO MAZETTO; COSTA MALATEAUX DA SILVA, 2021).

A Figura 1.2 mostra um dos resultados, obtidos por LOZER DOS REIS, MITSUO MAZETTO e COSTA MALATEAUX DA SILVA (2021), da produção anual de energia (*Annual Energy Production - AEP*) em GWh em seu estudo do potencial eólico *offshore* brasileiro. O Mapa 1 mostra a AEP ao longo de toda costa brasileira. Os Mapas 2 a 4 mostram a AEP focalizada nas costas Nordeste, Sudeste e Sul, respectivamente. Destaca-se o alto potencial de produção em grande parte da região Nordeste do Brasil, especialmente entre os estados de Maranhão (MA) e Ceará (CE). Outros dois estados mostraram resultados expressivos: as áreas entre o litoral sul do Espírito Santo (ES) e o norte do Rio de Janeiro (RJ) e entre os estados de Santa Catarina (SC) e Rio Grande do Sul (RS) (LOZER DOS REIS; MITSUO MAZETTO; COSTA MALATEAUX DA SILVA, 2021).

Devido a fatores econômicos, como a redução dos custos de cabeamento, construção e manutenção mais fáceis e a menores áreas para comissionamento dos empreendimentos, as turbinas eólicas são instaladas em grupos (i.e., parques eólicos) (STANLEY et al., 2021). Entretanto, a construção de turbinas próximas umas das outras também introduz alguns desafios. Um desses desafios é a interação das esteiras de turbulência (*wake*) entre turbinas. Como as turbinas estão extraíndo a energia cinética do fluxo de vento, regiões de esteira com velocidade de vento mais lenta e escoamento turbulento são produzidas na área à jusante das turbinas. Este fenômeno faz com que as turbinas a jusante produzam menos energia (STANLEY et al., 2021). As Figuras 1.3a e 1.3b ilustram este fenômeno para diferentes direções do vento em um parque eólico *offshore* real.

Estas perdas significativas podem ser evitadas através da modelagem precisa do escoamento turbulento ao longo do parque eólico e através da otimização do *layout* do mesmo. Este processo de otimização envolve a determinação da posição das turbinas a serem instaladas em um parque eólico, adotando um modelo de esteira preciso, determinando assim as localizações das turbinas a fim de reduzir as interações de esteira entre elas e atribuindo um objetivo de otimização realista para maximizar a geração de energia

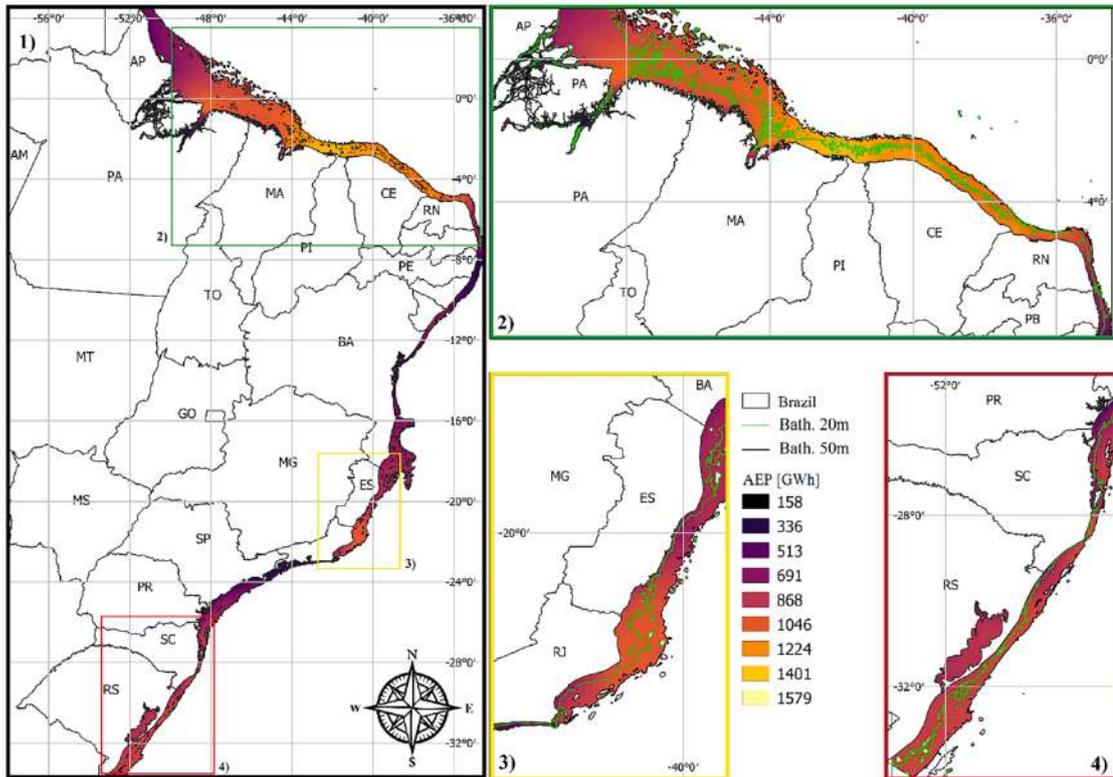


Figura 1.2: Mapa 1: Estimativa da produção anual de energia (*Annual Energy Production* - AEP) ao longo da costa brasileira. Mapas 2 a 4: AEP detalhada por região brasileira (LOZER DOS REIS; MITSUO MAZETTO; COSTA MALATEAUX DA SILVA, 2021). A linha verde delimita a região com profundidade média até 20 m (Batimetria - *Bath. 20 m*) e a linha preta com profundidade média até 50 m (Batimetria - *Bath. 50 m*).



(a)



(b)

Figura 1.3: (a) e (b) Parque eólico de Horns Rev I (Dinamarca) em uma condição de máximo efeito das estelas de turbulência e efeitos parciais de esteira, respectivamente. Imagem retirada de Porté-Agel, Bastankhah e Shamsoddin (2019).

ou retorno econômico (STANLEY et al., 2021; AZLAN et al., 2021). Estas questões são necessárias para melhorar a competitividade financeira e viabilidade técnica dos parques eólicos como uma alternativa aos métodos convencionais de geração de energia (AZLAN et al., 2021).

## 1.2 Revisão bibliográfica

Como discutido anteriormente, o processo de otimização do projeto do *layout* do parque eólico consiste principalmente na adoção de um modelo de esteira de turbulência preciso enquanto atribui um, ou mais, objetivo(s) de projeto de modo a determinar a posição das turbinas a fim de maximizar ou minimizar este(s) objetivo(s) de projeto. A Seção 1.2.1 apresenta uma revisão das diferentes abordagens adotadas na literatura, a respeito da modelagem do escoamento em turbinas eólicas e parques eólicos, enquanto a Seção 1.2.2 revisa diferentes objetivos, técnicas e escopos de projeto adotados em otimização de parques eólicos na literatura.

### 1.2.1 Modelagem de parques eólicos

Dependendo do *layout* e das condições de vento de um parque eólico, a perda de energia de uma turbina à jusante pode chegar a 40% em condições onde o efeito das esteiras naquela turbina são máximos na configuração do parque (e.g., Figura 1.3a). Quando se calcula a média em diferentes direções de vento, são observadas perdas de aproximadamente 8% para parques *onshore* e 12% para parques *offshore* (BARTHELMIE et al., 2008; BARTHELMIE et al., 2009). Além do escoamento turbulento na região da esteira ser responsável por perdas substanciais dos níveis de conversão de energia, devido à redução da velocidade do vento, ele também leva ao aumento das cargas de fadiga e custos de manutenção associados, devido ao aumento dos níveis de turbulência experimentados pelas pás das turbinas afetadas (VERMEER; SORENSEN; CRESPO, 2003; SANDERSE; PIJL; KOREN, 2011; STEVENS; MENEVEAU, 2017). Devido a isso, pesquisas recentes se concentraram nos fenômenos do escoamento e turbulência que surgem de forma única no contexto de parques eólicos (STEVENS; MENEVEAU, 2017).

Um desafio recorrente na modelagem do escoamento em parques eólicos é o de como abordar a ampla gama de escalas compreendidas pelos diferentes fenômenos relevantes no escoamento, conforme ilustrado na Figura 1.4, onde a esteira gerada por cada turbina está inserido na camada limite atmosférica (CLA), e mais adiante na direção do escoamento, quando o desenvolvimento da camada interna atinge a altura total da CLA, é então alcançado o regime totalmente desenvolvido da camada limite gerada pela presença

das turbinas instaladas no parque (CALAF; MENEVEAU; MEYERS, 2010). Fenômenos como expansão e recuperação das esteiras, arraste vertical de energia cinética média, estratificação térmica estável e instável e efeitos próximos ao solo são conhecidos por afetar o desempenho do parque eólico (STEVENS; MENEVEAU, 2017).

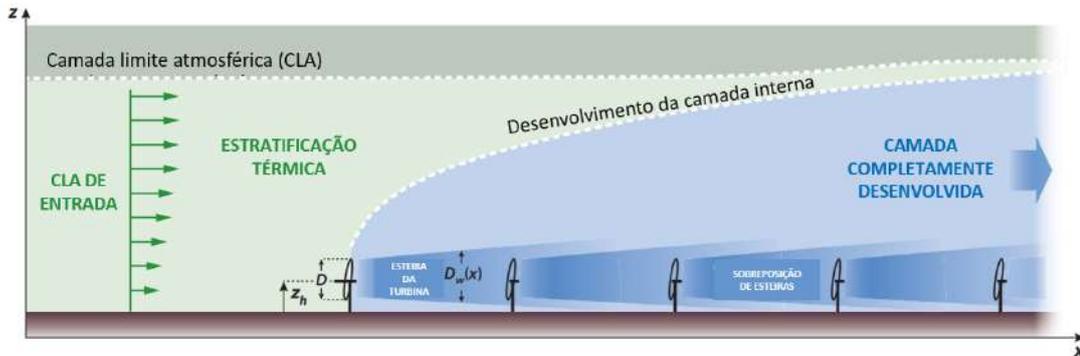


Figura 1.4: Fenômenos mecânicos presentes no escoamento em parques eólicos, incluindo esteiras de turbulência, sua superposição e interações com a camada limite atmosférica (CLA), desenvolvimento de camadas limite internas e, se um parque eólico for suficientemente grande, o alcance de um regime de camada limite das turbinas eólicas totalmente desenvolvido. Adaptado de Stevens e Meneveau (2017).

Desde os trabalhos de Betz (1920), esforços substanciais de pesquisa têm sido feitos no campo da aerodinâmica de turbinas eólicas e, particularmente, na simulação e otimização de rotores de turbinas eólicas de eixo horizontal (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019; SANDERSE; PIJL; KOREN, 2011). Uma variedade de abordagens analíticas, computacionais e experimentais têm sido usadas nos últimos anos para estudar a interação do escoamento na CLA turbulenta com turbinas eólicas e parques eólicos. A Tabela 1.1 apresenta um breve apanhado das diferentes abordagens de simulação dos rotores das turbinas eólicas assim como dos modelos utilizados para as esteiras das turbinas, reunidos na revisão de Sanderse, Pijl e Koren (2011). A primeira e mais simples abordagem é um método analítico que explora a natureza auto-similar da esteira, após uma certa distância à jusante, para obter expressões para o déficit de velocidade e a intensidade da turbulência. A segunda, a teoria denominada *Blade Element Momentum* (BEM), utiliza um equilíbrio global da quantidade de movimento junto com elementos de pás bidimensionais (2D) para calcular as características aerodinâmicas das pás. Os métodos *vortex-lattice* e *vortex-particle* assumem escoamento invíscido e incompressível e o descrevem com vorticidade concentrada em *sheets* ou partículas. Os métodos dos

painéis descrevem similarmente um campo de escoamento invíscido, mas a geometria da pá é levada em conta com mais precisão, e os efeitos viscosos podem ser incluídos com um código de camada limite; a esteira segue como nos métodos *vortex* citados. Estes quatro métodos já foram amplamente discutidos em revisões como Vermeer, Sorensen e Crespo (2003), Crespo, Hernández e Frandsen (1999), Snel (1998), Snel (2003), Hansen et al. (2006). O método do disco atuador generalizado e o método direto, são relativamente novos e são comumente chamados de métodos de dinâmica de fluidos computacional (CFD), revisados por Sanderse, Pijl e Koren (2011).

Tabela 1.1: Classificação dos modelos. Adaptado de Sanderse, Pijl e Koren (2011)

Método	Modelo da pá ( <i>blade model</i> )	Modelo da esteira ( <i>wake model</i> )
Cinemático	Coefficiente de empuxo	Solução <i>Self-similar</i> (e.g., perfil Gaussiano)
BEM	Disco atuador + elemento de pá	<i>Quasi one-dimensional momentum theory</i>
<i>Vortex lattice, vortex particle</i>	Linha/superfície sustentadora + elemento de pá	Folha de vorticidade livre/fixa, partículas
Painéis	Malha de superfície (geometria das pás)	Folha de vorticidade livre
Atuador generalizado	Disco/Linha/Superfície atuador(a)	Malha de volume, Euler/RANS/LES
Direto	Malha de volume (geometria das pás)	Malha de volume, Euler/RANS/LES

Para além da simulação dos rotores das turbinas eólicas, o escoamento no interior dos parques eólicos tem sido objeto de inúmeros estudos numéricos, de campo e de túnel de vento nos últimos anos (CORTEN; SCHAAK; HEGBERG, 2004; BARTHELMIE et al., 2010; BARTHELMIE et al., 2006; BARTHELMIE; JENSEN, 2010; BARTHELMIE et al., 2008; BARTHELMIE et al., 2009; BASTANKHAH; PORTE-AGEL, 2016; BASTANKHAH; PORTE-AGEL, 2014; CHAMORRO; PORTÉ-AGEL, 2008; WU; PORTE-AGEL, 2012), como também revisa Porté-Agel, Bastankhah e Shamsoddin (2019). O escoamento no interior dos parques eólicos é caracterizado como de baixa velocidade com alta intensidade de turbulência, devido aos efeitos cumulativos das esteiras de turbulência (ver Figura 1.4). Tanto o déficit de velocidade quanto o aumento da intensidade da turbulência aumentam nas primeiras fileiras de turbinas, enquanto sua variação entre as fileiras subsequentes se torna progressivamente menor. Vários estudos têm mostrado que, para certos arranjos de parques eólicos e direções de vento, o déficit de velocidades dentro de alguns parques eólicos se mostra assintótico a condições totalmente desenvolvidas após as primeiras fileiras de turbinas eólicas (BARTHELMIE; JENSEN, 2010; BARTHELMIE et al., 2009; MARKFORT; ZHANG; PORTÉ-AGEL, 2012; HAMILTON; MELIUS; CAL, 2015; ARCHER; MIRZAEISEFAT; LEE, 2013).

Esse comportamento pode ser mostrado na Figura 1.5 (adaptada de Stevens e Meneveau (2017)), que mostra os dados de medição SCADA (*supervisory control and data acquisition*) obtidos por Barthelmie et al. (2010), Barthelmie e Jensen (2010), Barthelmie et al. (2009) para os parques eólicos Horns Rev I e Nysted, ambos na Dinamarca. Estes dados foram utilizados no teste e comparação do modelo de esteira utilizado no presente trabalho (ver Capítulo 2). Dadas as diferentes direções de entrada de vento, as medições de campo são tipicamente calculadas como média sobre um setor eólico ( $5^\circ$  neste caso). As Figuras 1.5a,b mostram o posicionamento das turbinas em cada parque e algumas direções de vento consideradas; as Figuras 1.5c,d mostram o decaimento da potência nas turbinas que constituem a fileira 2 e 8 (*row 2 e 8*) como função da direção do vento (BARTHELMIE et al., 2010). As Figuras 1.5e–k mostram o desenvolvimento a jusante da produção de energia para diferentes direções do vento. Quando a direção do vento é alinhada ao posicionamento das turbinas (ou seja,  $270^\circ$  para Horns Rev e  $278^\circ$  para Nysted), uma queda significativa na produção de energia é observada imediatamente após a primeira turbina, enquanto a produção de energia da segunda para a última linha de turbinas permanece quase constante. Para as outras direções do vento, observa-se uma redução mais gradual da produção de energia em função da distância a jusante, já que as turbinas da segunda e terceira fila não estão necessariamente expostas por completo à esteira das turbinas da primeira fila (STEVENS; MENEVEAU, 2017). Isso mostra que a direção do vento e a sua variação ao longo do ano tem um profundo impacto nos níveis de produção dos parques eólicos, devido aos diferentes efeitos das esteiras provocados ao longo do *layout* do parque eólico (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019; BARTHELMIE et al., 2010; BARTHELMIE; JENSEN, 2010; BARTHELMIE et al., 2009; BARTHELMIE et al., 2006; BARTHELMIE et al., 2008).

A dinâmica dos fluidos computacional associada a modelos de turbulência, como o *Reynolds-averaged Navier–Stokes* (RANS), tem sido amplamente utilizada para estudar o escoamento em turbinas eólicas e parques eólicos (VERMEER; SORENSEN; CRESPO, 2003; SANDERSE; PIJL; KOREN, 2011). Com o rápido crescimento do poder computacional, foram feitos importantes progressos na última década no desenvolvimento, validação e aplicação de ferramentas de CFD que resolvem turbulências, em particular

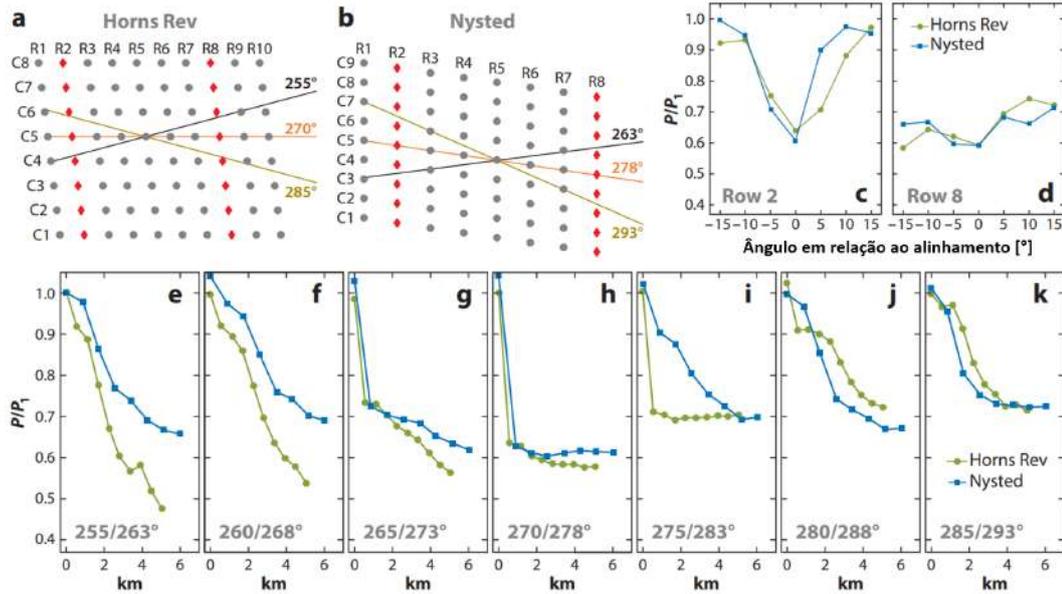


Figura 1.5: *Layout* das turbinas dos parques eólicos de (a) Horns Rev e (b) Nysted. O desempenho das turbinas na (c) segunda e (d) oitava fileira como função da direção do vento em relação à configuração alinhada com a potência normalizada em função da primeira fileira ( $270^\circ$  para Horns Rev e  $278^\circ$  para Nysted). (e–k) Desempenho como função da distância ao longo da direção do vento  $255\text{--}285^\circ$  para Horns Rev e  $263\text{--}293^\circ$  para Nysted. Os dados são para uma velocidade do vento de entrada de  $8 \pm 0,5$  m/s e são extraídos, originalmente, de (BARTHELMIE et al., 2010). Figura adaptada de Stevens e Meneveau (2017).

a *Large Eddy Simulation* (LES) para aplicações de energia eólica, conforme revisado por Mehta et al. (2014).

Ao longo dos últimos anos, experimentos em túneis de vento também foram realizados para estudar a interação entre os escoamentos turbulentos da camada limite e as turbinas ou parques eólicos (CHAMORRO; PORTÉ-AGEL, 2008; HAMILTON; MELIUS; CAL, 2015). Esses experimentos forneceram informações valiosas sobre a estrutura do escoamento das esteiras de turbinas na camada limite, que apresentam diferenças importantes com relação ao escoamento livre (PORTÉ-AGEL; BASTANKHAH; SHAM-SODDIN, 2019). Eles também forneceram conjuntos de dados únicos para a validação de modelos analíticos e modelos CFD. Mais recentemente, a aplicação de tecnologias de sensoriamento remoto, tais como *light detection and ranging* (LiDAR) (KÄSLER et al., 2010; BANTA et al., 2015; DOUBRAWA et al., 2020), está fornecendo novos conhecimentos sobre o efeito da turbulência atmosférica na estrutura e dinâmica do escoamento em torno de turbinas eólicas e parques eólicos, bem como conjuntos de dados para testar

modelos numéricos (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019).

A turbina extrai quantidade de movimento e energia do escoamento atmosférico, causando um decaimento de pressão e conseqüentemente um gradiente de pressão axial, uma expansão da esteira e uma diminuição da velocidade axial (SANDERSE; PIJL; KOREN, 2011). Em distâncias maiores que três vezes o diâmetro do rotor da turbina, a forma real do rotor (i.e., sua geometria de fato) só é percebida indiretamente, por meio da redução da velocidade axial e do aumento da intensidade da turbulência (SANDERSE; PIJL; KOREN, 2011; BASTANKHAH; PORTE-AGEL, 2014). A partir desta distância a jusante, o déficit de velocidade se torna aproximadamente axissimétrico assumindo um perfil aproximadamente gaussiano, o que é uma das suposições na formulação usada por alguns modelos analíticos de esteira (BASTANKHAH; PORTE-AGEL, 2014; BASTANKHAH; PORTE-AGEL, 2016), como será explorado em maiores detalhes no Capítulo 2.

Vários modelos analíticos simples foram propostos para a previsão do déficit de velocidade ao longo das esteiras das turbinas eólicas (JENSEN, 1983; FRANDSEN et al., 2006; BASTANKHAH; PORTE-AGEL, 2014). Embora sejam necessariamente menos precisos do que ferramentas de simulação numérica mais sofisticadas para resolver turbulências, sua simplicidade e baixo custo computacional as tornam a escolha mais usual para fins de otimização do layout e controle de parques eólicos sobre terrenos planos (por exemplo, *offshore*) (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Isto porque técnicas de otimização, tais como algoritmos genéticos, otimização por enxames de partículas, evolução diferencial, entre outras, necessitam da simulação de muitos casos abrangendo a combinação de múltiplas condições de vento (direções e velocidade), assim como configurações e/ou estratégias de controle de parques eólicos (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019).

De forma geral, estes modelos descrevem a estrutura de uma única esteira de turbina eólica, como apresentado com mais detalhes na Seção 2.3, que são então combinados com métodos para contabilizar a sobreposição e interação de múltiplas esteiras (ver Seção 2.3.3) (STEVENS; MENEVEAU, 2017). O Capítulo 2 aborda, em maior detalhes, o modelo analítico utilizado, assim como o modelo de superposição, no presente trabalho.

### 1.2.2 Otimização do *layout* de parques eólicos

Sendo uma das primeiras etapas do projeto, o *layout* de um parque eólico é um fator crítico para sua caracterização. Com a melhoria do conhecimento e da competitividade deste mercado, este fator está sendo altamente explorado e levado ao extremo a fim de maximizar a rentabilidade de cada empreendimento. A principal atribuição da alocação de turbinas eólicas (i.e., *micro-siting*) é extrair o máximo de energia das turbinas eólicas disponíveis (SHAKOOR et al., 2016). Encontrar um *layout* ideal para um parque eólico é um problema desafiador, não convexo, com muitas variáveis de projeto que interagem entre si (STANLEY et al., 2021). É difícil resolver este problema sem técnicas de otimização, pois muitas vezes é necessário fazer concessões não tão óbvias para chegar a uma solução (STANLEY et al., 2021). Este cenário leva ao uso de algoritmos de aproximação, também conhecidos como métodos heurísticos, para resolver os desafios de otimização (AZLAN et al., 2021). Conforme revisado por Azlan et al. (2021), diferentes abordagens na literatura têm utilizado uma gama de diferentes algoritmos, tais como Algoritmos Genéticos (GA), Otimização por enxame de partículas (PSO), Otimização de Colônia de Formigas (ACO), Evolução Diferencial (DE), entre outras.

O clássico trabalho de Mosetti, Poloni e Diviacco (1994) sobre otimização do *layout* de parques eólicos surgiu, levando a melhorias significativas tanto na descrição do desempenho do parque eólico (quantificado através da relação de produção de energia elétrica por custo de investimento) quanto na abordagem numérica para tratar o problema (um algoritmo genético de codificação binária). Depois disso, muitos autores realizaram uma quantidade significativa de contribuições de complexidade variável ao longo dos dois aspectos principais (ACERO et al., 2014):

- Melhoria da modelagem do desempenho de parques eólicos (i.e., considerando a inclusão de submodelos complexos para prospecção financeira, aerodinâmica e física do escoamento de ar, fadiga estrutural e degradação, interconexão do sistema elétrico e da rede, impacto ambiental e incerteza, entre outros);
- Desenvolvimento e teste de diferentes procedimentos de solução numérica.

Conforme observado na Figura 1.6, a evolução da pesquisa sobre este tema tem

sido expressiva na última década, de acordo com a revisão da literatura realizada por Acero et al. (2014).

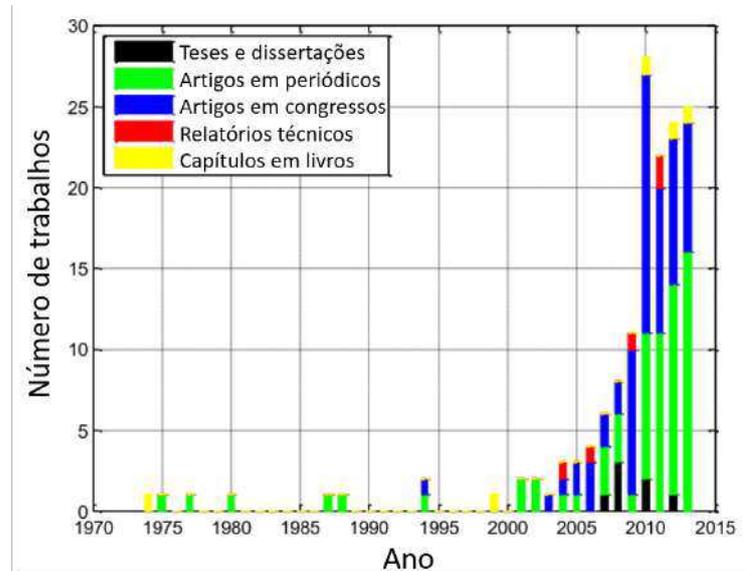


Figura 1.6: Linha do tempo das contribuições científicas a respeito do problema de otimização de parques eólicos. Figura adaptada de (ACERO et al., 2014).

Como revisado por Tao et al. (2020), os objetivos de projeto comumente usados para projetar os parques eólicos podem ser classificadas em três categorias:

- Objetivos em conversão de energia, incluindo a maximização da potência total de saída (CHEN et al., 2013; ABDULRAHMAN; WOOD, 2017), produção anual de energia (RAHBARI et al., 2014; VASEL-BE-HAGH; ARCHER, 2017), fator de capacidade (RAHBARI et al., 2014; ABDULRAHMAN; WOOD, 2017) e eficiência (CHOWDHURY et al., 2012; RAHBARI et al., 2014; ABDULRAHMAN; WOOD, 2017);
- Objetivos econômicos, incluindo a minimização do custo de energia (CHEN et al., 2013; SONG; CHEN; WANG, 2018; TANG et al., 2018), o custo nivelado de energia (FENG; SHEN, 2017; HUANG et al., 2020) ou maximização do lucro (POOKPUNT; ONGSAKUL, 2016) ou valor presente líquido (DUAN; WANG; GU, 2014);
- Objetivos mecânicos, incluindo a minimização da distribuição de carregamentos de fadiga nas turbinas eólicas (HUANG et al., 2020).

Um passo crítico é selecionar adequadamente a função objetivo, porque a função objetivo terá um grande efeito sobre o parque eólico otimizado resultante (KIRCHNER-BOSSI; PORTÉ-AGEL, 2021), conforme também mostrado por Stanley et al. (2021) em seus estudos de caso na otimização de parques eólicos usando três diferentes funções objetivos. Eles mostraram que o número ideal de turbinas e seu *layout* (i.e., parâmetros a serem otimizados, em particular, no estudo de Stanley et al. (2021)) são completamente diferentes, dependendo do objetivo utilizado. Todos os parques eólicos otimizados para um objetivo específico têm um desempenho muito inferior quando avaliado nos outros objetivos (STANLEY et al., 2021). Dessa forma, ao realizar a otimização de parques eólicos, a função objetivo deve ser definida para representar verdadeiramente o desempenho desejado, pois isso afetará a solução final.

Como uma abordagem para lidar com mais de uma consideração de projeto, alguns estudos propuseram uma abordagem multiobjetivo para projetar o layout do parque eólico de forma mais eficiente, considerando minimizar três objetivos, por exemplo, como conduzido por Moreno et al. (2021), incluindo o custo da produção anual de energia, a área geral do parque eólico e as perdas por efeito de esteira, simultaneamente, em sua análise. Recentemente, Dijk et al. (2017) investigaram a distribuição de esforços mecânicos em turbinas eólicas devido ao efeito das esteiras e também propuseram uma abordagem multiobjetivo. Tingey e Ning (2017) abordaram o *trade-off* relacionado ao nível de pressão sonora e à produção média de energia para o *layout* do parque eólico. Um modelo bi-objetivo proposto por Chen et al. (2015) considera a potência gerada e o custo. Sorkhabi et al. (2016) aplicaram um algoritmo evolutivo multi-objetivo para a produção anual de energia e os níveis de ruído recebidos de todas as posições das turbinas, com restrições de uso do solo. Três objetivos conflitantes foram considerados por Li, Özcan e John (2017) que aplicaram uma hiper-heurística para maximizar a produção de energia, minimizando tanto o comprimento dos cabos que conectam todas as turbinas e a área total do parque. O *trade-off* entre energia e ruído foi investigado por Mittal, Mitra e Kulkarni (2017) através da aplicação de um algoritmo híbrido baseado no *non-dominated sorting genetic algorithm II* (NSGA-II). Os trabalhos de Liu et al. (2021), Ma et al. (2022), Rodrigues, Bauer e Bosman (2016), Cao et al. (2022) sintetizam demais abordagens utilizadas pela

literatura referente a otimização de parques eólicos, considerando diferentes objetivos (mono e multi-objetivo), modelos analíticos de esteira, sub-modelos para análise de custo, algoritmos de otimização, variáveis para otimização e restrições.

Além de diferentes funções objetivo, diferentes escopos de projeto também são adotados na literatura; estudos de otimização de layout são quase sempre realizados assumindo que o número de turbinas no parque eólico é previamente conhecido. Determinar o número ideal de turbinas em um parque é um problema muito mais difícil de resolver porque requer a otimização de pelo menos uma variável inteira de projeto ou um espaço de projeto descontínuo, como conduzido por Stanley et al. (2021) e Ziyaei et al. (2022). Um escopo de projeto diferente foi o mostrado por Kirchner-Bossi e Porté-Agel (2021), em que abordaram o problema multi-objetivo do comprimento dos cabos elétricos versus a potência de saída do parque, realizando uma otimização do formato da área do parque eólico (ou seja, sem nenhuma família de formas pré-definidas a priori, o que comumente é estipulado como retangular ou quadrado), em que é imposto apenas um valor máximo permitido para a área total do parque ( $\text{km}^2$ ), assegurando que qualquer melhoria potencial seja devido à otimização da forma do parque ao invés de um mero aumento de área (KIRCHNER-BOSSI; PORTÉ-AGEL, 2021). Liu et al. (2021) realizaram otimizações do layout do parque eólico *offshore* considerando diferentes terrenos para o fundo do mar para determinar seus efeitos no custo das estruturas de apoio para turbinas eólicas *offshore*, afetando assim o custo total do parque eólico, dependendo da profundidade do mar, que na formulação de Liu et al. (2021) varia em função das coordenadas de instalação das turbinas eólicas.

Normalmente, apenas um tipo e tamanho de turbina eólica é considerado em projetos de parques eólicos (WANG et al., 2018b; PAUL; RATHER, 2019; PARADA et al., 2017; TAO et al., 2019); no entanto, é possível implementar turbinas com diferentes alturas de torre (CHEN et al., 2013; VASEL-BE-HAGH; ARCHER, 2017), e diferentes tipos de turbinas (CHOWDHURY et al., 2013; ABDULRAHMAN; WOOD, 2017; CHEN et al., 2016; DUAN; WANG; GU, 2014; CHARHOUNI; SALLAOU; MANSOURI, 2019a). Geralmente, a literatura a respeito do problema de otimização do layout de parques eólicos pode ser classificada em otimização uniforme de parques eólicos, com apenas um tipo de

turbina eólica, e otimização não uniforme de parques eólicos, com vários tipos de turbinas eólicas (TAO et al., 2020). Posteriormente, várias abordagens em otimização de parques eólicos foram propostas levando em consideração a seleção e a instalação mista de diferentes tipos de turbinas, com diversas dimensões físicas e várias curvas de potência (TAO et al., 2020). Estes estudos revelam que a instalação mista de modelos de aerogeradores poderia ajudar a aumentar a potência total do parque (CHOWDHURY et al., 2013; CHEN et al., 2013; ABDULRAHMAN; WOOD, 2017; VASEL-BE-HAGH; ARCHER, 2017), obter um menor custo de energia (CHEN et al., 2013; ABDULRAHMAN; WOOD, 2017; SONG; CHEN; WANG, 2018; TANG et al., 2018), melhorar a eficiência do layout (CHOWDHURY et al., 2012; RAHBARI et al., 2014) e homogeneizar as cargas por fadiga (HUANG et al., 2020).

Em contrapartida dos benefícios acima listados, os problemas logísticos de se lidar com uma série de diferentes modelos de turbinas eólicas em um determinado parque eólico aumenta com o número de diferentes modelos utilizados, devido a complicações para instalação de turbinas de diferentes portes, as quais requerem embarcações e infraestruturas específicas para cada porte de aerogerador. Isto implica em um maior custo de instalação para o empreendimento, tendo em vista que os custos para instalação e operação de um parque eólico no mar (*offshore*) são substancialmente mais elevados. Além disso, a operação de turbinas eólicas de diferentes portes geram complicações de controle de potência na subestação *offshore*. Outra desvantagem de aumentar a quantidade demasiada de diferentes modelos de aerogeradores é que tanto sua gestão quanto o treinamento de pessoal especializado para as operações de manutenção se tornam despesas adicionais (MONTROYA et al., 2014). Como consequência destas desvantagens, um empreendimento com tais características pode ainda não ser viável economicamente na atualidade, apesar dos ganhos substanciais de desempenho, conforme citado nos diversos estudos ao final do parágrafo anterior e o tema ser objeto de estudo de várias pesquisas em otimização não uniforme de parques eólicos (TAO et al., 2020). Estas questões referentes à viabilidade econômica se dão também em decorrência do mercado de energia eólica *offshore* ser muito recente, e com o tempo as tecnologias envolvidas podem ter seus custos reduzidos, tornando a implementação e operação de parques eólicos não uniformes mais viável eco-

nomicamente. Por fim, é importante ponderar entre os ganhos de desempenho citados e o número de diferentes tipos de turbinas, sendo necessário um *trade-off* entre estes dois pontos, o que configura o objeto de estudo e principal contribuição do presente trabalho.

## 1.3 Objetivos

Tendo em vista as questões a respeito da otimização não uniforme de parques eólicos, levantadas ao final da Seção 1.2.2, o principal objetivo e contribuição do presente trabalho é propor uma abordagem de otimização multiobjetivo, através de algoritmos evolucionários e modelos analíticos de esteira (*wake*), do *layout* de parques eólicos *offshore* com diferentes tipos de turbinas, onde realiza-se um *trade-off* entre os ganhos de desempenho por otimização não uniforme e o número de diferentes tipos de turbinas instaladas, o qual almeja-se minimizar.

Para atingir este objetivo, estipulam-se como objetivos específicos:

- Calcular a distribuição anual dos ventos através da probabilidade de ocorrência de cada direção e velocidade (i.e., potencial eólico no local de instalação do parque);
- Calcular a produção de energia elétrica dos parques através das curvas de potência e empuxo das turbinas, distribuição anual de ventos e modelos de esteira;
- Avaliar os indicadores de viabilidade econômica dos parques eólicos a serem considerados nos problemas de otimização;
- Solucionar dois estudos de caso de problemas multiobjetivo, a saber:
  - Caso I : Fator de capacidade pelo custo nivelado de energia;
  - Caso II: Eficiência do *layout* do parque (efeitos de *wake*) pelo custo de energia.
- Avaliar o desempenho de dois algoritmos evolucionários na resolução dos Casos I e II através de métricas de desempenho e análise dos resultados;
- Extrair e avaliar os resultados da frente de Pareto segundo preferências de projeto pré-determinadas.

## 1.4 Organização do trabalho

O presente trabalho está organizado da seguinte forma: o Capítulo 2 inicia apresentando os modelos utilizados para descrever a distribuição anual de ocorrência dos ventos, por meio de uma função densidade probabilidade em relação às diferentes direções e velocidades de vento. O capítulo segue descrevendo o perfil vertical de velocidades atmosféricas adotado, finalizando assim a descrição das condições atmosféricas às quais o parque eólico está sujeito. Também é abordado a descrição matemática dos modelos analíticos tridimensionais de esteira que simulam o escoamento turbulento no interior do parque eólico, avaliando assim a velocidade de incidência que cada turbina eólica experimenta (para cada condição do vento - direção e velocidade), o que permite calcular o desempenho de cada turbina por meio das curvas de potência e empuxo para cada cenário simulado. O Capítulo 3 aborda os modelos utilizados para quantificar os indicadores de desempenho (fator de capacidade e eficiência) e econômicos (custo nivelado de energia e custo da energia) dos parques eólicos; estes indicadores são utilizados como funções objetivos nos dois estudos de caso realizados no presente trabalho. O Capítulo 4 descreve toda a metodologia dos dois algoritmos evolucionários de otimização utilizados no presente trabalho, assim como as métricas de desempenho para avaliar os resultados de cada algoritmo e, por fim, apresenta-se o tomador de decisão multi-critério utilizado para extração de resultados do conjunto de resultados obtidos, através de preferências de projeto pré-determinados por um projetista. O Capítulo 5 descreve os experimentos numéricos realizados por meio de dois estudos de caso, assim como a formulação da abordagem para otimização multiobjetivo de parques eólicos *offshore* com diferentes modelos de aerogeradores, proposta no presente trabalho. Também são apresentados os resultados e discussões a respeito das vantagens e desvantagens da abordagem proposta. Por fim, o Capítulo 6 apresenta as conclusões tiradas dos experimentos numéricos e aponta possíveis trabalhos futuros.

## 2 Modelagem matemática de parques eólicos

O presente capítulo aborda as metodologias de modelagem matemática do desempenho de parques eólicos utilizadas na resolução dos estudos de caso discutidos nos capítulos subsequentes. Este capítulo se inicia discutindo a importância e impactos das condições anuais de vento no desempenho dos parques eólicos, modelando a variabilidade de características como direção e velocidade do vento ao longo do ano, que no presente trabalho é realizado via uma distribuição de densidade de probabilidade. Em sequência é abordado tópicos relacionados aos princípios de conversão da energia cinética dos ventos em energia elétrica, por parte das turbinas eólicas, bem como as equações que modelam seu funcionamento. Posteriormente discutem-se os efeitos de esteira de turbulência (*wake*) que uma turbina gera no escoamento do parque eólico, assim como a sobreposição dos efeitos das demais turbinas e seu impacto nos níveis globais de produção do parque.

### 2.1 Condições do vento

A fonte primária de energia renovável contida nos recursos eólicos da Terra é o sol. Os ventos globais são causados por diferenças de pressão ao longo da superfície terrestre devido ao aquecimento não-uniforme da Terra pela radiação solar. Por exemplo, a quantidade de radiação solar absorvida na superfície da terra é maior ao longo da linha do equador do que nos pólos. A variação da energia de entrada estabelece células convectivas nas camadas inferiores da atmosfera (a troposfera) (MANWELL; MCGOWAN; ROGERS, 2010).

Em um modelo simples, uma dada massa de ar sobe (ganha altitude) na linha do equador e desce (perde altitude) nos pólos. A dinâmica de circulação do ar da atmosfera, resultante do aquecimento não-uniforme da superfície terrestre, é muito influenciada pelos efeitos da rotação da Terra (a uma velocidade de cerca de 1670 km/h na linha do Equador, diminuindo para zero nos Pólos). Além disso, as variações sazonais na distribuição da energia solar dão origem a variações na circulação.

A dinâmica da circulação atmosférica varia tanto no tempo (de segundos a meses) como no espaço (de centímetros a milhares de quilômetros), como se pode ver na Figura 2.1, onde as variações na velocidade do vento ao longo do tempo podem ser divididas em interanuais, anuais, diurnas e de curto prazo (rajadas de vento e turbulência) (MANWELL; MCGOWAN; ROGERS, 2010). A direção do vento em um determinado local também varia ao longo das mesmas escalas de tempo sob as quais a velocidade do vento varia. As variações sazonais podem ser pequenas, na ordem dos 30°, ou os ventos médios mensais podem mudar de direção em até 180° durante um ano (MANWELL; MCGOWAN; ROGERS, 2010).

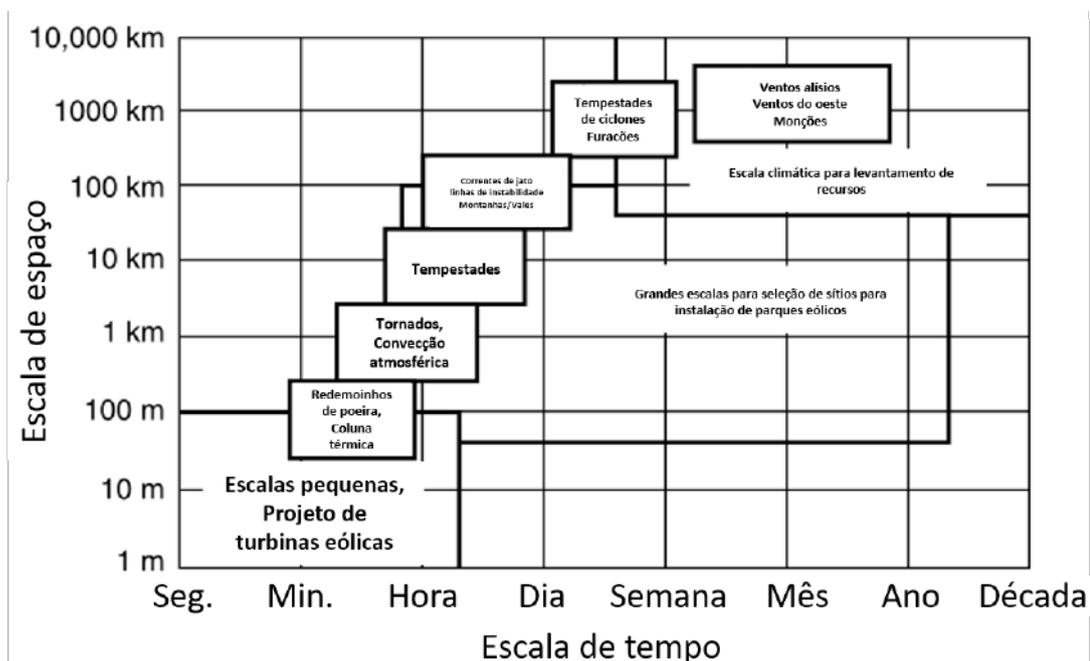


Figura 2.1: Escalas de tempo e espaço dos movimentos atmosféricos. Adaptado de Spera (2009)

### 2.1.1 Distribuição conjunta de probabilidades de ocorrência das direções e velocidades do vento

Conforme discutido nas Seções 2.2 e 2.3, o desempenho das turbinas eólicas e do parque eólico variam conforme a velocidade do vento, assim como com a direção de ocorrência do vento no local de instalação do parque. Dessa forma, torna-se de grande importância ter conhecimento da variabilidade destas condições meteorológicas do vento ao longo do

ano. A fim de dispor de dados meteorológicos confiáveis sobre o local de interesse, para a instalação do parque eólico, devem ser feitas medições especificamente para determinar o potencial eólico no local candidato. As campanhas de medições em energia eólica utilizam diferentes tipos de sensores meteorológicos, tais como: anemômetros para medir a velocidade do vento, palhetas de vento para medir a direção do vento, termômetros para medir a temperatura do ar ambiente e barômetros para medir a pressão do ar (MANWELL; MCGOWAN; ROGERS, 2010), de forma que a avaliação das condições do vento no local de interesse possa ser realizada de acordo com uma grande quantidade de dados coletados para caracterização das condições do vento. Para o presente trabalho, os dados de interesse são os dados de direção de ocorrência do vento, bem como dados de velocidade do vento a uma altura de referência. Há várias formas de sumarizar os dados de forma compacta para que se possa avaliar o potencial eólico ou o potencial de produção de energia eólica de um determinado local (MANWELL; MCGOWAN; ROGERS, 2010).

A análise estatística pode ser utilizada para determinar o potencial de energia eólica de um determinado local e também para estimar a produção de energia de um parque eólico instalado neste local. Estas técnicas têm sido discutidas por vários autores, incluindo Justus (1978), Johnson (1985), entre outros. Uma distribuição de probabilidade é um termo que descreve a probabilidade de ocorrência de certos valores de uma variável aleatória contínua (como a velocidade do vento). As distribuições de probabilidade são tipicamente caracterizadas por uma função de densidade de probabilidade (FDP) ou uma função de densidade cumulativa (MANWELL; MCGOWAN; ROGERS, 2010). A frequência de ocorrência das velocidades do vento pode ser descrita pela função de densidade de probabilidade,  $p(U)$ , para expressar a probabilidade de uma velocidade do vento ocorrer entre dois valores de velocidade  $U_a$  e  $U_b$ :

$$p(U_a \leq U \leq U_b) = \int_{U_a}^{U_b} p(U) dU, \quad (2.1)$$

e, para que  $p(U)$  seja de fato uma FDP, a área total sob a curva de densidade de probabilidade deve se igualar à unidade, isto é:

$$\int_{-\infty}^{\infty} p(U) dU = 1. \quad (2.2)$$

De forma a se obter  $p(U)$ , uma das distribuições de probabilidades comumente utilizadas em análise de dados em energia eólica é a distribuição de Weibull (LUKO, 1999; MANWELL; MCGOWAN; ROGERS, 2010), que é baseada em dois parâmetros:  $k$ , um fator de forma, e  $c$ , um fator de escala. Neste contexto, ambos os parâmetros são funções da velocidade média observada nos dados coletados,  $\bar{U}$  (Equação (2.3)) e seu desvio padrão,  $\sigma_U$  (Equação (2.4)), e podem ser avaliados de acordo com as equações 2.5 (JUSTUS, 1978) e 2.6 (LYSEN, 1983), respectivamente:

$$\bar{U} = \frac{1}{N} \sum_{i=1}^N U_i, \quad (2.3)$$

$$\sigma_U = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (U_i - \bar{U})^2}, \quad (2.4)$$

$$k = \left( \frac{\sigma_U}{\bar{U}} \right)^{-1.086}, \quad (2.5)$$

$$\frac{c}{\bar{U}} = (0.568 + 0.433/k)^{\frac{-1}{k}}, \quad (2.6)$$

onde  $U_i$  é uma medida de velocidade do vento média ao longo de um intervalo de tempo de observação (geralmente de 10 minutos) e  $N$  é número de medições de velocidade do vento disponíveis. A função de densidade de probabilidade de Weibull é por:

$$p(U) = \left( \frac{k}{c} \right) \left( \frac{U}{c} \right)^{k-1} \exp \left[ - \left( \frac{U}{c} \right)^k \right]. \quad (2.7)$$

Como discutido na Seção 2.3, a produção de energia de um parque eólico é bastante sensível à direção do vento, devido aos complexos efeitos de esteira de turbulência gerados pelas turbinas eólicas dentro do parque. Em seus estudos numéricos de dinâmica dos fluidos computacional, Porte-Agel, Wu e Chen (2013) mostraram que uma mudança na direção do vento de 10°, em relação ao pior cenário, i.e., com maiores efeitos de esteira de turbulência, aumenta-se a produção de energia em até 43%. A Figura 2.2 apresenta um exemplo da mudança do desempenho de todo o parque eólico de Horns Rev I (Dinamarca) (para maiores informações sobre o parque (BARTHELMIE et al., 2010)) com

uma pequena variação na direção do vento. Quantitativamente este efeito é apresentado nas Figuras 2.20b e 2.20c, e é discutido em maiores detalhes adiante na Seção 2.3.3.

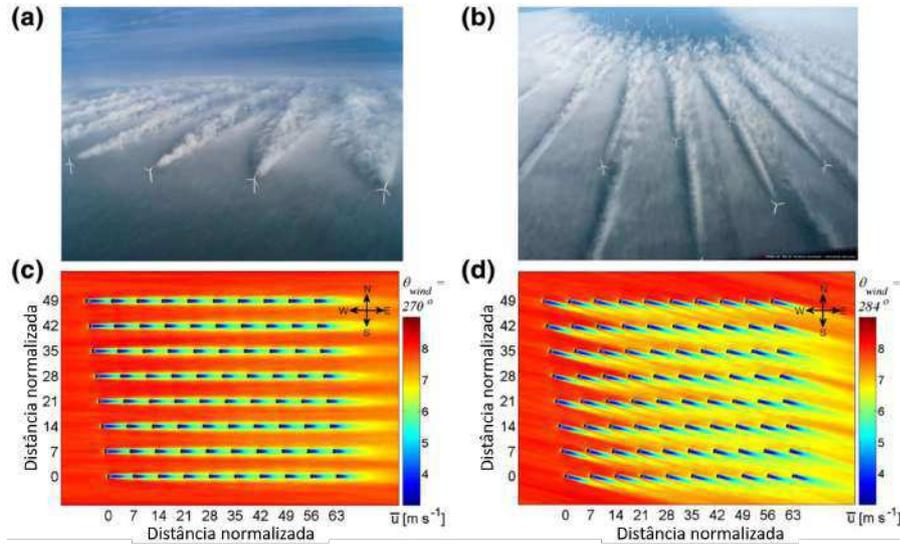


Figura 2.2: (a) e (b) Parque eólico de Horns Rev I (Dinamarca) em uma condição de máximo efeito das esteiras de turbulência e efeitos parciais de esteira, respectivamente (Grupo Vattenfall) (PORTE-AGEL; BASTANKHAH; SHAMSODDIN, 2019); Campo de velocidades médias simulado exibido em um plano de corte horizontal (paralelo ao solo) na altura do eixo das turbinas com o vento proveniente do Oeste ( $\theta = 270^\circ$ ) (c) (condição de maior efeito de esteira) e  $\theta = 284^\circ$  (d) (condição de efeitos parciais de esteira). Adaptado de (PORTE-AGEL; WU; CHEN, 2013).

Embora este tipo de mudança drástica ocorra apenas em certas direções do vento e a sensibilidade à direção do vento não seja tão profunda quando se consideram todas as direções, ainda é uma tarefa importante pré-processar adequadamente os dados dos recursos eólicos a fim de reduzir o impacto da incerteza da direção do vento e aumentar a precisão do cálculo da potência gerada pelo parque (FENG; SHEN, 2015b). Considerando os dados de medição do vento, é então importante decidir quantos setores de direção do vento e quantos valores de velocidade do vento devem ser utilizados na discretização para se realizar os cálculos de desempenho do parque eólico, tendo em vista que a direção e velocidade do vento variam de maneira contínua na natureza. Como a campanha de medições dos recursos eólicos não é o foco do presente trabalho, consideram-se os dados de recursos eólicos já condensados em termos dos parâmetros da distribuição de Weibull para 12 setores de direção do vento, fornecidos na Tabela 2.1, para as condições anuais de vento do parque eólico de Horns Rev I. A fim de se obter resultados consistentes e confiáveis na otimização do layout de um parque eólico, é necessário um certo número de

setores de direção do vento, para se avaliar o desempenho do parque. Por outro lado, a utilização de muitos setores de direção do vento irá aumentar desnecessariamente o custo computacional (FENG; SHEN, 2015b).

Como discutido anteriormente, para a variação da velocidade do vento, a distribuição de Weibull é a mais utilizada. Para a variação da direção do vento, são normalmente utilizadas as frequências de ocorrência dos setores de diferentes direções, normalmente apresentadas em uma rosa dos ventos (MANWELL; MCGOWAN; ROGERS, 2010) (ver Figura 2.3). Combinando estes dois, os dados de vento medidos podem ser ajustados nas distribuições Weibull setoriais, que é uma prática comum na modelagem do vento para avaliação dos recursos eólicos e cálculo da produção anual de energia (*PAE*) (FENG; SHEN, 2015a).

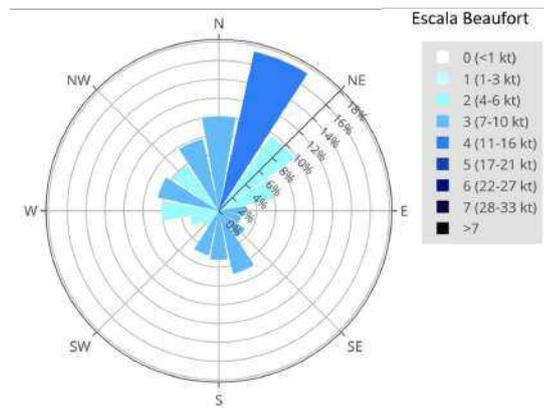


Figura 2.3: Rosa dos ventos mostrando a frequência de ocorrência do vento para 16 setores de direção, conforme escala de probabilidades no gráfico, assim como a velocidade média de ocorrência do vento em cada setor, seguindo a escala *Beaufort* em nós (1 nó = 1.852 km/h). Adaptado de Copernicus (2016).

Este método de modelagem do vento foi adotado em vários estudos de otimização do layout dos parques eólicos. Alguns estudos utilizaram 12 setores de direção do vento (RIVAS et al., 2009; DOBRIC; DURISIC, 2014), enquanto alguns estudos utilizaram 24 setores (KUSIAK; SONG, 2010). Entretanto, como observado por Feng e Shen (2015b), descobriu-se que este método de modelagem poderia causar resultados problemáticos ao otimizar o layout de um grande parque eólico offshore. A razão se encontra na discretização e descontinuidade da direção do vento na modelagem, quando se utiliza poucos setores (poucas direções efetivamente modeladas de todo o cenário contínuo que ocorre na natureza) e também na descontinuidade dos parâmetros  $k$  e  $c$  que possuem valores

diferentes para setores adjacentes de direção. Estes estudos sugerem que métodos mais avançados de modelagem de vento, que podem caracterizar melhor a variação da direção do vento são necessários, especialmente para aplicação na otimização do layout do parque eólico. Neste trabalho foi utilizada a distribuição conjunta de velocidades e direções do vento proposta por Feng e Shen (2015a), detalhada a seguir.

Primeiramente discretiza-se as condições do vento em  $N_{ws} \times N_{wd}$  cenários possíveis em um intervalo com valor máximo e mínimo de velocidade  $[U_{max}, U_{min}]$  (m/s) e direção  $[\theta_{max}, \theta_{min}]$  ( $^\circ$ ), com incrementos de tamanho  $\Delta U$  para velocidade e  $\Delta \theta$  para direção do vento, onde  $N_{ws}$  e  $N_{wd}$  são os números de valores de velocidade do vento e direção considerados na discretização, respectivamente, como mostra a Figura 2.4. Desta forma, os dados do vento podem ser sumarizados em uma matriz da forma:  $\mathbf{F} = (F_{ij})$ , em que  $F_{ij} = f_{occ}(U_{ij}, \theta_{ij})$  se refere à frequência de ocorrência da  $ij$ -ésima barra (i.e., condição do vento: combinação velocidade e direção)  $(U_{ij}, \theta_{ij})$ . Baseado na frequência de ocorrência, se pode também calcular a função densidade probabilidade bivariada,  $P(\theta, U)$ , da velocidade e direção do vento em cada ponto  $(U_{ij}, \theta_{ij})$  conforme Equação (2.8).

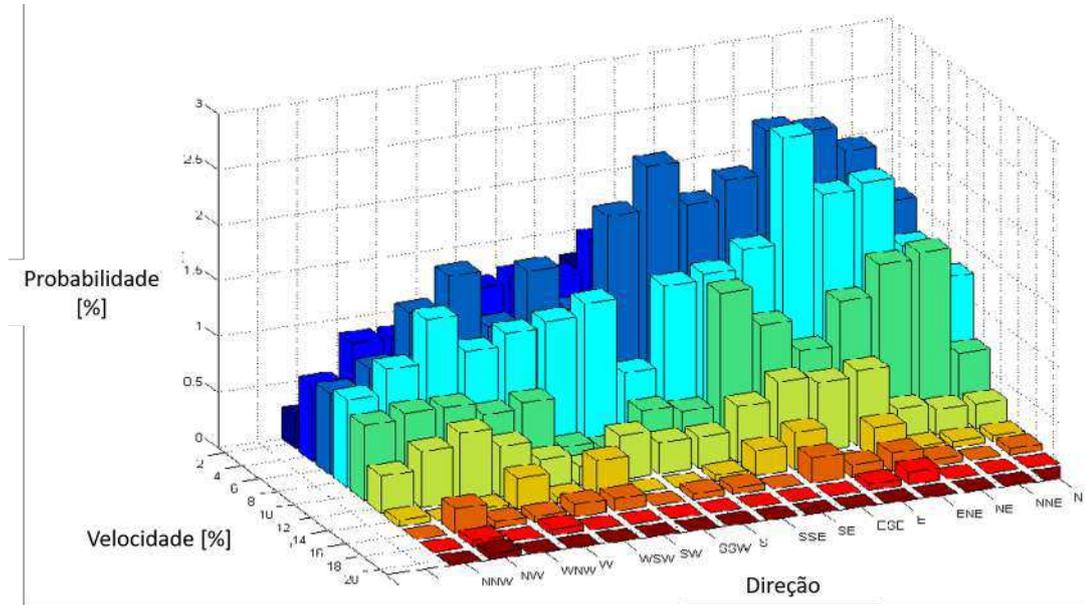


Figura 2.4: Probabilidade de ocorrência das barras (velocidade, direção) de condição do vento. Adaptado de (WANG et al., 2015)

$$p(U_{ij}, \theta_{ij}) = f_{occ}(U_{ij}, \theta_{ij}) / (\Delta U \Delta \theta). \quad (2.8)$$

A Figura 2.4 ilustra uma distribuição bivariada das condições do vento (velocidade e direção) discretizada.

Conforme apresentado na Equação (2.7), a distribuição de probabilidade de velocidade leva em consideração o fator de forma,  $k$ , e o fator de escala,  $c$ , que por sua vez assumem valores diferentes em função das observações de velocidade  $U_i$ , como visto nas Equações (2.5) e (2.6), para cada direção de observação do vento em que  $U_i$  foi coletada, i.e.:  $k = k(\theta)$  e  $c = c(\theta)$ , resultando em uma distribuição conjunta da velocidade do vento (varia conforme distribuição de Weibull) e direção do vento (com os parâmetros  $k$  e  $c$  variando de acordo com a direção  $\theta$ ), constituindo assim a função densidade probabilidade bivariada,  $p(U, \theta)$ . A Tabela 2.1 apresenta os parâmetros da distribuição de Weibull e a frequência de ocorrência para cada setor de direção do vento observados no parque eólico de Horns Rev 1.

Tabela 2.1: Parâmetros da distribuição de Weibull ( $k, c$ ) e frequência de ocorrência ( $f$ ) para 12 setores de direção do vento (FENG; SHEN, 2015a)

$\theta$	0°	30°	60°	90°	120°	150°	180°	210°	240°	270°	300°	330°
<b>Direção</b>	<b>N</b>	<b>NNE</b>	<b>ENE</b>	<b>E</b>	<b>ESE</b>	<b>SSE</b>	<b>S</b>	<b>SSW</b>	<b>WSW</b>	<b>W</b>	<b>WNW</b>	<b>NNW</b>
$c$ [m/s]	8.89	9.27	8.23	9.78	11.64	11.03	11.50	11.92	11.49	11.08	11.34	10.76
$k$ [-]	2.09	2.13	2.29	2.30	2.67	2.45	2.51	2.40	2.35	2.27	2.24	2.19
$f$ [%]	4.82	4.06	3.59	5.27	9.12	6.97	9.17	11.84	12.41	11.34	11.70	9.69

De forma a se fazer  $\Delta\theta < 30^\circ$ , conforme já mencionado nesta seção, a interpolação por *spline* é utilizada para se interpolar os valores de  $k$  e  $c$  para uma discretização de  $\theta$  com mais setores do que os fornecidos na Tabela 2.1. Dessa forma, é possível se obter os parâmetros de Weibull e a frequência de ocorrência como uma função contínua da direção do vento,  $\theta$ :  $k = k(\theta)$ ,  $c = c(\theta)$  e  $f_{occ} = f_{occ}(\theta)$  (FENG; SHEN, 2015a). Estas diferentes funções são mostradas na Figura 2.5.

A distribuição conjunta da velocidade e direção do vento pode ser então construída usando a interpolação *Spline* (terceira ordem) e a Equação 2.8, conforme  $p(U_{ij}, \theta_{ij})$  (FENG; SHEN, 2015a), o que resulta na seguinte equação:

$$p(U, \theta) = p_{weibull}(U, k(\theta), c(\theta)) \frac{f_{occ}(\theta)}{360/N_{sectors}}, \quad (2.9)$$

onde  $N_{sectors}$  é o número de setores de direção do vento considerados.

A Figura 2.6 apresenta uma comparação da distribuição conjunta obtida dos

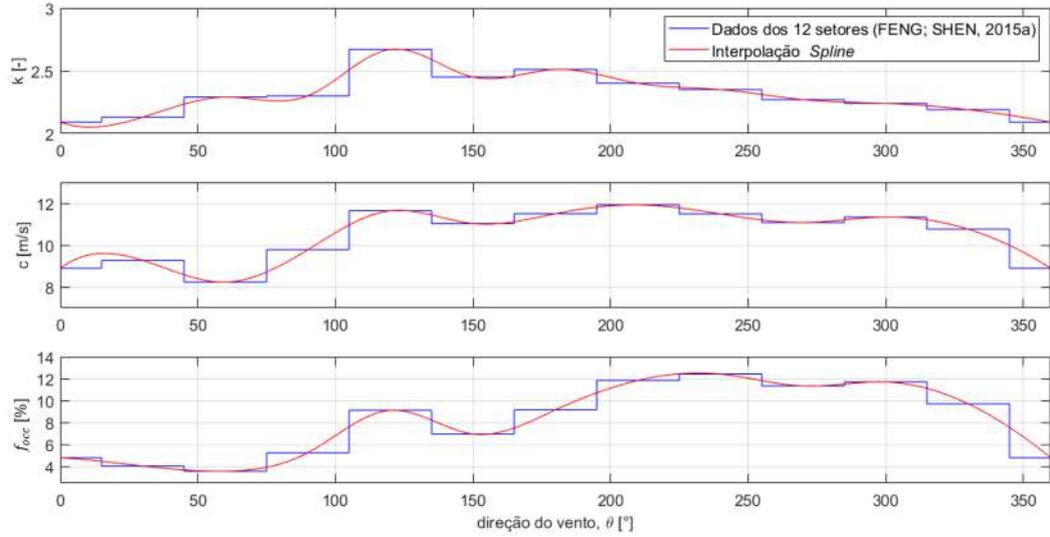


Figura 2.5: Parâmetros da distribuição de Weibull ( $k$ ,  $c$ ) e frequência de ocorrência ( $f_{occ}$ ) como funções da direção do vento. Linha em azul são os dados da tabela 2.1 dos 12 setores; linha vermelha é a abordagem proposta por (FENG; SHEN, 2015a) - interpolação dos dados fornecidos (*Spline*).

dados de medição, distribuição conjunta obtida por Feng e Shen (2015a) e  $p(U_{ij}, \theta_{ij})$ , a distribuição conjunta implementada no presente trabalho, para comparação.

Também é importante destacar que, como a função densidade probabilidade  $p(U, \theta)$  modela os cenários de eventos possíveis de ocorrência do vento (velocidade e direção do vento),  $p(U, \theta)$  se dá de tal forma que a Equação (2.10) seja satisfeita (MANWELL; MCGOWAN; ROGERS, 2010).

$$\int_0^{\infty} \int_{0^{\circ}}^{360^{\circ}} p(u, \theta) d\theta du = 1 \quad (2.10)$$

Conforme afirmado por Feng e Shen (2015b), a fim de se obter resultados consistentes e confiáveis na otimização do *layout* de parques eólicos, um certo número de setores de direção do vento é necessário. Em contrapartida, o uso de muitos setores de direção do vento irá aumentar o custo computacional desnecessariamente. Durante a análise dos resultados da otimização do layout de um parque eólico existente, Feng e Shen (2015b) reavaliaram a melhoria relativa na potência gerada dos parques resultantes como função do número dos setores usados no processo de otimização. Esta reavaliação é mostrada na Figura 2.7a para três opções de pré-processamento. Os valores de melhoria obtidos

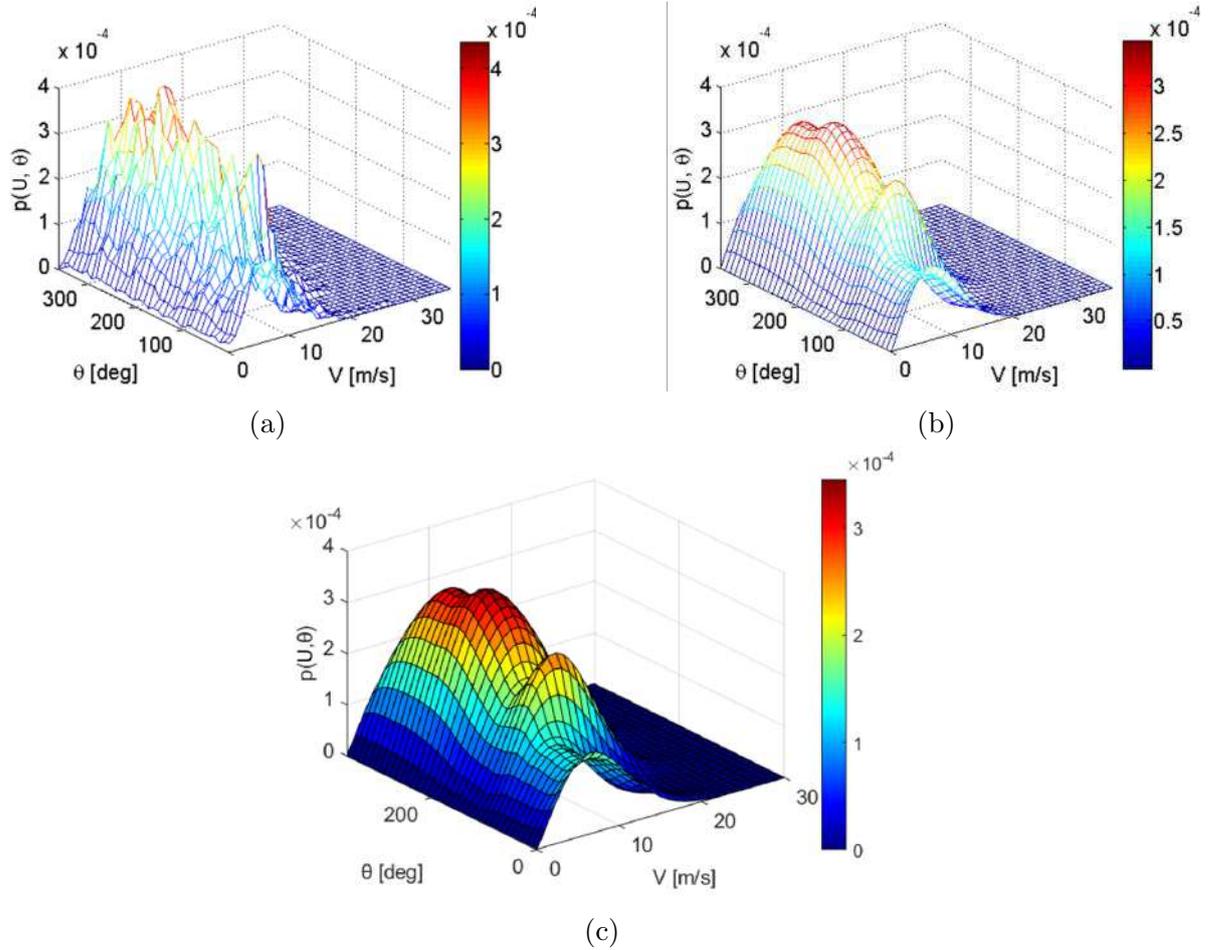


Figura 2.6: Função densidade probabilidade bivariada da velocidade e direção do vento: (a) dos dados de medição (considerando  $\Delta U = 1$  m/s,  $\Delta\theta = 10^\circ$ ) (FENG; SHEN, 2015a); (b) utilizando a interpolação Spline - resultados da referência (FENG; SHEN, 2015a); (c) utilizando a interpolação Spline - resultados da implementação no presente trabalho.

nos três processos de otimização são mostrados com asteriscos (\*) na figura. Pode-se ver que, quando utilizados 12 setores a potência tem um aumento, de forma impressionante, de mais de 7%, porém quando reavaliado com uma discretização mais refinada das direções do vento, i.e., utilizando mais setores, a melhoria na potência gerada decai. Este fenômeno pode ser explicado pelo fato de que utilizar 12 setores equivale a assumir que o vento somente ocorre nestas 12 direções específicas, enquanto na realidade o vento ocorre em todas as direções e varia entre elas continuamente. A discretização das direções do vento deixa um grande espaço para os algoritmos de otimização ajustarem o layout do parque eólico de acordo com estes espaços deixados (a Figura 2.7b ilustra este fenômeno). Portanto, os resultados obtidos pela otimização usando 12 setores não são realistas e não são recomendados para uma aplicação em um projeto real. Quando se usa 72 setores, a

diferença entre o valor obtido na otimização e o reavaliado (utilizando ainda mais setores) da melhoria na potência gerada é menor do que o caso com 12 setores. A melhoria alcançada utilizando 360 setores é muito menor do que aquelas utilizando menos setores, mas o resultado é muito mais consistente quando reavaliado utilizando mais setores. Dessa forma, a discretização do regime de ventos tem um papel importante no projeto de otimização de parques eólicos e deve ser realizada considerando os objetivos de projeto e custo computacional disponível. A abordagem realizada no presente trabalho é descrita na Seção 5.2.

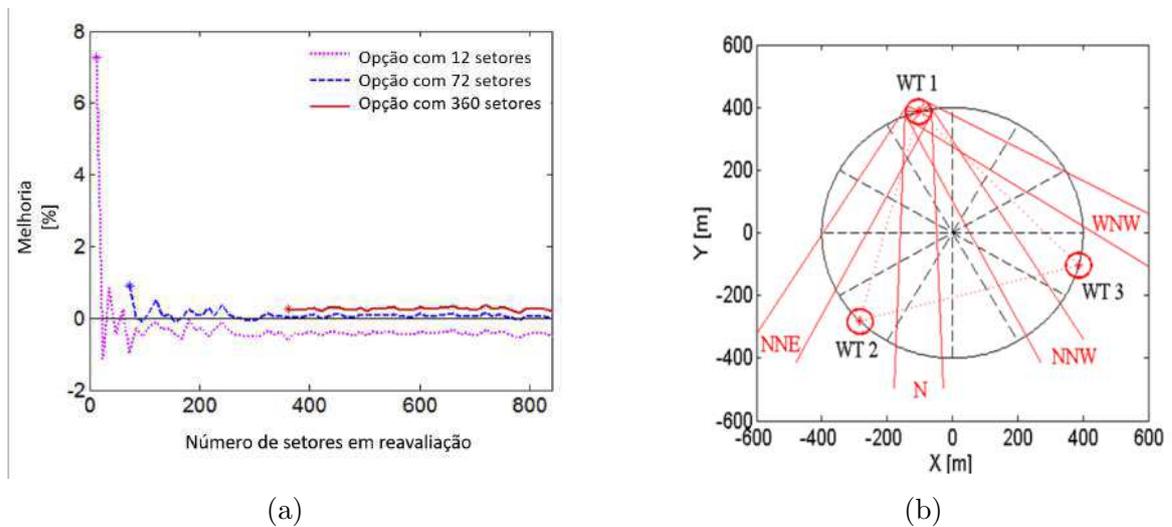


Figura 2.7: (a) Melhoria na potência gerada por um parque eólico com seu layout otimizado utilizando três opções de pré-processamento da discretização das direções do vento e reavaliados com um número maior de setores de direção do vento; (b) Zonas afetadas pela esteira de turbulência da turbina 1 (WT 1) para as direções do vento considerados na discretização com poucos setores. Percebe-se que as turbinas WT 2 e 3 não são afetadas para esta discretização da direção, quando na realidade serão afetadas adotando-se mais setores de direção do vento (cenário mais realista). Adaptado de Feng e Shen (2015b).

### 2.1.2 Perfil vertical de velocidades

A camada limite atmosférica, também conhecida como camada limite planetária, é a parte mais baixa da atmosfera e suas características são diretamente influenciadas pelo contato com a superfície da terra. Aqui, as quantidades físicas tais como velocidade, temperatura e umidade relativa podem mudar rapidamente no espaço e no tempo. Por exemplo, um parâmetro importante na caracterização do recurso do vento é a variação da velocidade do vento horizontal com altura acima do solo,  $u(z)$ . O comportamento observado é de

velocidade do vento nula na superfície terrestre e aumentando com a altura na camada limite atmosférica (ver Figura 2.8). Esta variação da velocidade do vento com a elevação é chamada de perfil vertical de velocidade do vento ou cisalhamento vertical do vento. Na engenharia de energia eólica, a determinação do perfil vertical de velocidades do vento é um parâmetro de projeto importante, pois: (i) determina diretamente a produtividade de uma turbina eólica que opera sobre uma torre de determinada altura, e (ii) pode influenciar fortemente a vida útil de uma pá do rotor da turbina. A vida útil das pás do rotor é influenciada pelas cargas cíclicas resultantes da rotação através de um campo de velocidades que varia na direção vertical (MANWELL; MCGOWAN; ROGERS, 2010).

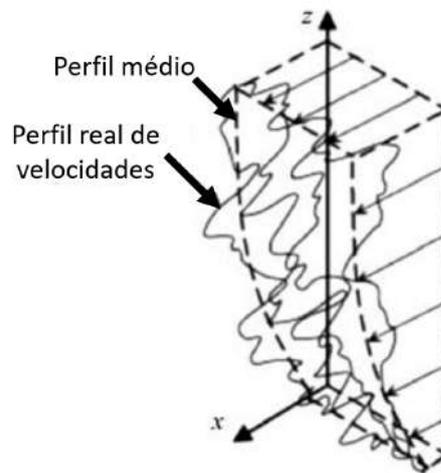


Figura 2.8: Perfil vertical de velocidades experimental. Adaptado de Tempel (2006)

Uma característica particularmente importante da atmosfera é sua estabilidade - a tendência a resistir ao movimento vertical ou a suprimir a turbulência existente (ARYA, 2001; PIMENTA et al., 2019). A estabilidade da camada limite atmosférica é um fator determinante para os gradientes de velocidade do vento (por exemplo, perfil vertical de velocidades) que são experimentados nas primeiras centenas de metros acima do solo. A estabilidade atmosférica é geralmente classificada como estável, neutra ou instável. A estabilidade da atmosfera terrestre é governada pela distribuição vertical da temperatura resultante do aquecimento ou resfriamento radiativo de sua superfície e a subsequente mistura convectiva do ar adjacente à superfície (MANWELL; MCGOWAN; ROGERS, 2010).

Para condições atmosféricas estáveis, o ar é normalmente resfriado de baixo para

cima (ou seja, oceano/superfície mais frio que a atmosfera). Isto melhora a estratificação atmosférica e suprime o movimento vertical de massas de ar, de modo que os perfis de vento tendem a apresentar um cisalhamento vertical mais forte. Por outro lado, durante condições instáveis a atmosfera é aquecida de baixo para cima (isto é, o oceano/superfície aquece a atmosfera). Isto promove a convecção e a troca vertical de quantidade de movimento, o que reduz o cisalhamento vertical do vento (ARYA, 2001; PIMENTA et al., 2019).

Sob condições neutras, o perfil do vento é controlado por atrito com a superfície apenas e geralmente modelado por uma equação logarítmica (Equação (2.11)) ou lei de potência (Equação (2.12)) (MANWELL; MCGOWAN; ROGERS, 2010):

$$U(z) = \frac{U^*}{\kappa} \ln \left( \frac{z + z_0}{z_0} \right) = U(z_r) \times \ln \left( \frac{z}{z_0} \right) / \ln \left( \frac{z_r}{z_0} \right) \quad (2.11)$$

$$\frac{U(z)}{U(z_r)} = \left( \frac{z}{z_r} \right)^\alpha, \quad (2.12)$$

onde  $U(z)$  é a velocidade do vento a uma altura  $z$ ,  $U(z_r)$  é a velocidade do vento a uma altura de referência  $z_r$ ,  $\kappa$  a constante de *von Karman* ( $\kappa = 0.4$ ),  $U^*$  a velocidade de fricção,  $z_0$  a rugosidade superficial, e  $\alpha$  o expoente da lei de potência, que pode ser avaliado de acordo com a velocidade e altura de referência, conforme Equação (2.13) (JUSTUS, 1978) ou como função da rugosidade superficial, Equação (2.14) (COUNIHAN, 1975):

$$\alpha = \frac{0.37 - 0.088 \ln(U_{ref})}{1 - 0.088 \ln\left(\frac{z_{ref}}{10}\right)} \quad (2.13)$$

$$\alpha = 0.096 \log_{10}(z_0) + 0.016(\log_{10}(z_0))^2 + 0.24. \quad (2.14)$$

É importante de se destacar que a velocidade do vento modelada pela função densidade probabilidade bivariada,  $p(U, \theta)$ , discutida na seção 2.1.1 é, na realidade, a velocidade de referência a uma dada altura de referência,  $U(z_r)$ , que será extrapolada para outras alturas,  $U(z)$ , de acordo com a altura da torre das turbinas estudadas, utilizando-

se a Equação (2.11) ou (2.12), de forma a acessar o desempenho das turbinas (ver seção 2.2). Um trabalho recente sobre este tópico, como o de Elkinton, Rogers e McGowan (2006), incluiu o uso de dados do vento de torres de medição, mostrou que não há uma diferença significativa entre o desempenho dos perfis logarítmicos e das leis de potência para prever o cisalhamento do vento; e, em algumas circunstâncias, como para modelar o perfil de velocidades em estratificações atmosféricas estáveis e/ou instáveis, o uso de qualquer um dos dois métodos pode resultar em previsões imprecisas da velocidade média do vento na altura do eixo das turbinas. De maneira geral, considera-se que o perfil vertical de velocidades varia conforme um número de variáveis, incluindo a rugosidade superficial, mudanças nas condições superficiais, forma do terreno e estabilidade atmosférica (MANWELL; MCGOWAN; ROGERS, 2010).

## 2.2 Turbinas eólicas e o modelo do disco atuador

O processo de conversão da energia cinética dos ventos em energia elétrica, em um parque eólico, ocorre através das turbinas eólicas, as quais operam como parte de um sistema integrado à rede elétrica. Uma turbina eólica consiste de uma torre e uma nacelle que é montada no topo da torre. A nacelle contém vários componentes, que contribuem cada um com sua função específica no processo de conversão da energia cinética dos ventos em energia elétrica (HANSEN, 2017a). A Figura 2.9 mostra os principais componentes de uma turbina eólica, incluindo o rotor, sistema de transmissão (caixa de engrenagens), gerador, cabos elétricos, transformador, e, finalmente, a sua conexão com a rede de transmissão elétrica.

O rotor da turbina é composto principalmente por um eixo e as pás, sendo que estas últimas são fixadas ao eixo por juntas mecânicas. As turbinas eólicas modernas têm normalmente duas ou três pás, compostas por uma matriz de fibra de vidro impregnadas de poliéster (MANDELL et al., ). Como ilustrado na Figura 2.9, a potência mecânica do rotor da turbina é transmitida para o gerador através de um sistema de transmissão, o qual geralmente consiste de um eixo, freios mecânicos, e uma caixa de engrenagens (HANSEN, 2017a). O principal propósito da caixa de engrenagens é agir como um multiplicador de velocidade; a caixa de engrenagens converte a baixa rotação com alto torque do eixo

do rotor da turbina para o eixo com maior rotação e baixo torque do gerador (HANSEN, 2017a). O gerador é um componente eletromecânico, que converte a potência mecânica do eixo em potência elétrica (HANSEN, 2017a), que então alimenta a rede de transmissão elétrica através de uma interface eletrônica (CHEN; GUERRERO; BLAABJERG, 2009). Como a interface eletrônica de potência é colocada entre o gerador da turbina eólica e a rede de transmissão, ela deve satisfazer os requerimentos de ambos (HANSEN, 2017a). Além disso, as turbinas eólicas são geralmente equipadas com um sistema de controle, necessário para garantir a operação apropriada da turbina sob todas as condições operacionais. O sistema de controle visa controlar e manter a turbina dentro de seus limites operacionais através de mecanismos passivos ou ativos. Controles passivos não necessitam de atuadores externos e funcionam através de forças naturais, como por exemplo quando o rotor “automaticamente” perde eficiência aerodinâmica (conhecido como efeitos de *Stall*), quando a velocidade do vento excede um certo nível crítico. Controladores ativos usam atuadores elétricos, mecânicos, hidráulicos ou pneumáticos e necessitam transdutores para medir as variáveis que determinarão se cada controlador será ativado para uma desejada correção na condição de operação da turbina (HANSEN, 2017a).

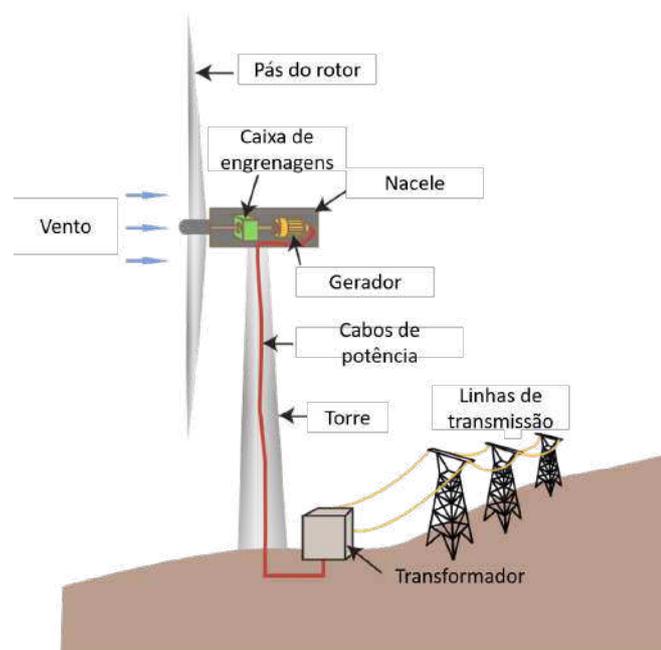


Figura 2.9: Componentes de uma turbina eólica

Como dito, a produção de energia eólica depende da interação entre o rotor e o vento, e a expertise do setor eólico tem mostrado que os principais aspectos do desempe-

nhos das turbinas eólicas (potência média e cargas médias) são determinados pelas forças aerodinâmicas geradas pelo vento médio, ou seja, condições aerodinâmicas em regime permanente (*steady state aerodynamics*) (MANWELL; MCGOWAN; ROGERS, 2010). Vários autores desenvolveram métodos para prever o desempenho dos rotores de turbinas eólicas em regime permanente. A análise clássica da teoria da quantidade de movimento da turbina eólica remonta há mais de 100 anos e foi desenvolvida por Froude e Rankine, mas também é atribuída a Betz (1926), e pode ser usada para determinar a potência de um rotor de turbina ideal, o empuxo do vento sobre o rotor ideal e o efeito da operação do rotor sobre o campo de velocidades local, onde a turbina é representada por um "disco atuador" uniforme dentro de um volume de controle (ver Figura - 2.10), que cria uma descontinuidade de pressão no "tubo" do fluxo (*stream tube*, montado a partir das linhas de corrente) de ar que passa por ele (MANWELL; MCGOWAN; ROGERS, 2010; BETZ, 1926).

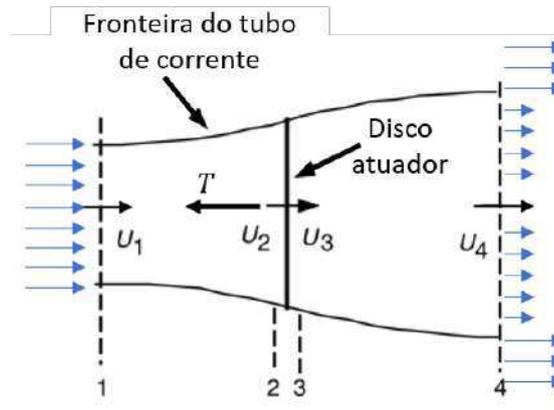


Figura 2.10: Modelo do disco atuador de uma turbina eólica;  $U$ , velocidade média do vento; 1, 2, 3, e 4 índices das posições analisadas e  $T$  a força de reação do empuxo provocada no disco atuador. Adaptada de Manwell, McGowan e Rogers (2010).

Aplicando a conservação da quantidade de movimento linear ao volume de controle que envolve todo o sistema, pode-se encontrar a força resultante sobre o conteúdo do volume de controle. Essa força é igual e oposta ao empuxo,  $T$ , que é a força do vento sobre a turbina eólica. A partir da conservação da quantidade de movimento linear para um escoamento unidimensional, incompressível e invariável no tempo, a força é igual e oposta à taxa de mudança de quantidade de movimento da corrente de ar:  $T = U_1(\rho AU)_1 - U_4(\rho AU)_4$ , onde  $\rho$  é a massa específica do ar,  $A$  é a área da seção

transversal do rotor da turbina,  $U$  a velocidade do vento, e os índices subscritos indicam os valores da velocidade nas secções transversais na Figura 2.10. Para escoamentos em regime estacionário,  $(\rho AU)_1 = (\rho AU)_4 = \dot{m}$ , onde  $\dot{m}$  é a taxa do fluxo de massa de ar. Portanto:  $T = \dot{m}(U_1 - U_4)$ . Aplicando a equação de Bernoulli ao longo das linhas de corrente da seção 1 até a 2, e, novamente, da seção 3 até a 4, assumindo que a pressão na saída tenha se recuperado para a pressão ambiente ( $p_1 = p_4$ ) e, também, que nenhuma energia mecânica seja dissipada em calor através do disco atuador ( $U_1 = U_4$ ) (HANSEN, 2017b; MANWELL; MCGOWAN; ROGERS, 2010), tem-se que:

$$p_1 + \frac{1}{2}\rho U_1^2 = p_2 + \frac{1}{2}\rho U_2^2 \quad (2.15)$$

$$p_3 + \frac{1}{2}\rho U_3^2 = p_4 + \frac{1}{2}\rho U_4^2 \quad (2.16)$$

O empuxo também pode ser expressado como a força resultante em cada um dos lados do disco atuador:  $T = A_2(p_2 - p_3) = A_2\Delta p$ , onde  $\Delta p$  pode ser obtido resolvendo as equações (2.15) e (2.16) (MANWELL; MCGOWAN; ROGERS, 2010), i.e.:  $T = \frac{1}{2}\rho A_2(U_1^2 - U_4^2) = \dot{m}(U_1 - U_4)$ , e reconhecendo que o fluxo mássico também é expressado por  $\rho A_2 U_2$ . Resolvendo para  $U_2$ , tem-se que:  $U_2 = \frac{U_1 + U_4}{2}$ . Manwell, McGowan e Rogers (2010) e Hansen (2017b) definem o fator axial de indução do rotor,  $a$ , como a diminuição fracionária na velocidade do vento entre o escoamento livre e o plano de rotação do rotor, i.e.:  $a = \frac{U_1 - U_2}{U_1}$ , e dessa forma as velocidades no plano de rotação do rotor  $U_2$  e velocidade de saída do volume de controle  $U_4$  podem ser definidas em função de  $a$  e da velocidade livre  $U_1$ :  $U_2 = U_1(1 - a)$  e  $U_4 = U_1(1 - 2a)$ .

Como não há fluxo de massa de ar através das linhas de corrente laterais que tocam a ponta do rotor, a potência extraída do vento,  $P$ , pode ser estimada em termos da conservação de energia:

$$P = \frac{1}{2}\dot{m}(U_1^2 - U_4^2) = \frac{1}{2}\rho U_2 A_2 (U_1^2 - U_4^2) = \frac{1}{2}\rho U_2 A_2 (U_1 + U_4)(U_1 - U_4), \quad (2.17)$$

assumindo que não há perda para o volume de controle confinado por estas linhas de corrente. Substituindo  $U_2$  e  $U_4$  por suas relações em função do fator de indução e velocidade

livre, tem-se:

$$P(U) = \frac{1}{2}\rho AU^3 4a(1-a)^2, \quad (2.18)$$

onde a área transversal do volume de controle na seção do rotor,  $A_2$ , é substituída por apenas  $A$ , a área do rotor, e a velocidade do escoamento livre,  $U_1$ , é substituída por  $U$ . Manwell, McGowan e Rogers (2010) e Hansen (2017b) caracterizam a curva de potência  $P(U)$  em função do coeficiente de potência  $C_P = 4a(1-a)^2$ .

Substituindo  $U_2$  e  $U_4$  em  $T = \frac{1}{2}\rho A_2 (U_1^2 - U_4^2)$  por suas relações em função do fator de indução e velocidade livre, tem-se o empuxo axial no disco atuador, dado por:

$$T(U) = \frac{1}{2}\rho AU^2 4a(1-a), \quad (2.19)$$

onde, de maneira similar à potência, o empuxo em uma turbina eólica pode ser caracterizado por um coeficiente adimensional  $C_T = 4a(1-a)$  (coeficiente de empuxo) (MANWELL; MCGOWAN; ROGERS, 2010).

Como descrito brevemente, uma turbina eólica é normalmente equipada com um sistema de controle, necessário para assegurar o funcionamento adequado da turbina eólica em todas as condições operacionais. As variáveis típicas que são monitoradas em um sistema de controle são velocidade do vento, velocidade do rotor, potência ativa e reativa, tensão e frequência do ponto de conexão da turbina eólica. Além disso, o sistema de controle deve ser capaz de parar a turbina eólica, se necessário (HANSEN, 2017a). A Figura 2.11 apresenta as regiões de operação de uma turbina eólica de forma a respeitar os limites operacionais dos componentes eletro-mecânicos, assim como critérios de segurança operacionais (MANWELL; MCGOWAN; ROGERS, 2010). Dessa forma, para cada velocidade  $U$ , o coeficiente de potência  $C_P$  irá assumir valores diferentes para manter a potência constante para velocidades maiores que a velocidade nominal  $U_{Rated}$ , i.e.:  $C_P = C_P(U)$ , em função dos sistemas de controle. Analogamente à variação de  $C_P$  com a velocidade, o coeficiente de empuxo,  $C_T(U)$ , também varia com a velocidade, alterando também os efeitos de esteira gerados pela turbina, conforme será abordado na Seção 2.3.

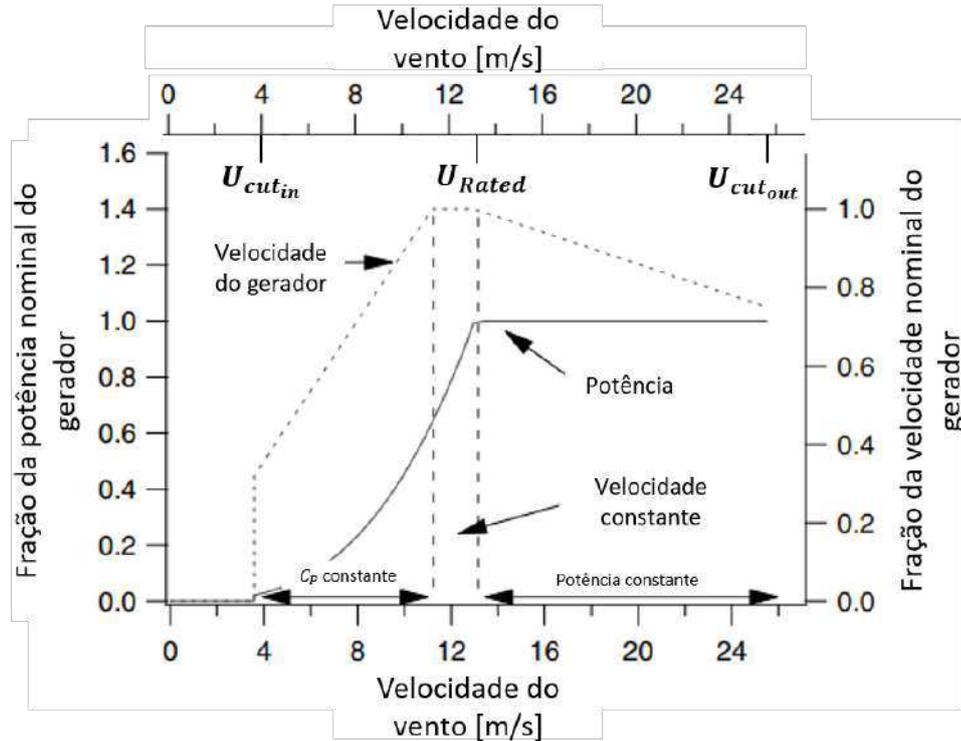


Figura 2.11: Exemplo de variação dos parâmetros operacionais de uma turbina eólica controlada por *Stall*;  $U_{cut\_in}$ , velocidade de acionamento do rotor;  $U_{Rated}$ , velocidade nominal de operação;  $U_{cut\_out}$ , velocidade de desacionamento do rotor. Adaptada de Manwell, McGowan e Rogers (2010).

## 2.3 Modelos de esteira de turbinas eólicas

A presença de uma turbina eólica afeta o fluxo de ar tanto à montante (*upstream*) como à jusante (*downstream*) da turbina, sendo a região a jusante da turbina, que é a região mais afetada e a de interesse deste trabalho, chamada de esteira (*wake*) (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). A própria esteira da turbina eólica é geralmente dividida em duas regiões (VERMEER; SORENSEN; CRESPO, 2003): (i) a região imediatamente após o rotor à jusante da turbina com um comprimento de 2-4 diâmetros do rotor, chamada de *near-wake*, e (ii) a região mais adiante, chamada de *far-wake*. A Figura 2.12 apresenta um esquemático das diferentes regiões do escoamento atmosférico afetadas pela presença da turbina eólica.

A região da *near-wake* é diretamente influenciada pela presença da turbina eólica, de modo que características da turbina, tais como o perfil da pá, o cubo do eixo e a geometria da nacele, podem afetar o campo de velocidades nesta região (CRESPO;

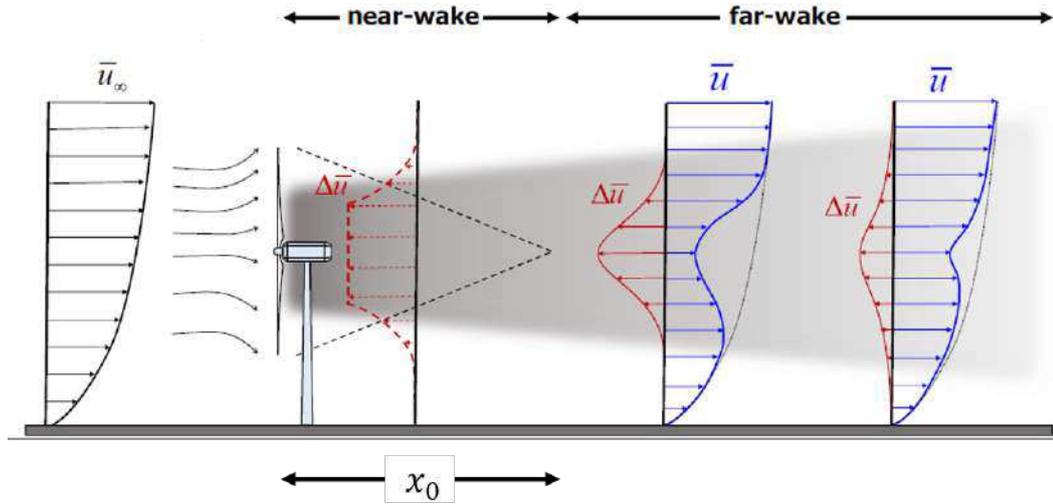


Figura 2.12: Regiões da esteira afetadas pela turbina eólica (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Perfil vertical de velocidades afetadas pelos efeitos de esteira da turbina na região da *far-wake*,  $\bar{u}$ , e perfil aproximadamente axissimétrico do déficit de velocidades,  $\Delta\bar{u}$ , da esteira da turbina na região da *far-wake*;  $x_0$  o comprimento da região de *near-wake*.

HERNÁNDEZ; FRANSEN, 1999). Como resultado, a *near-wake* é caracterizada por um escoamento altamente complexo, tridimensional (3D), e heterogêneo (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019) e, segundo Bastankhah e Porte-Agel (2016), a *near-wake* tem seu comprimento  $x_0$  definido pela equação 2.20:

$$\frac{x_0}{d_0} = \frac{\cos \gamma (1 + \sqrt{1 - C_T})}{\sqrt{2} [4\alpha I + 2\beta (1 - \sqrt{1 - C_T})]}, \quad (2.20)$$

sendo  $d_0$  o diâmetro do rotor;  $\gamma$  o ângulo de *yaw* (desalinhamento do eixo do rotor e a direção do vento), que no presente trabalho será adotado como  $\gamma = 0$ , i.e.: turbinas eólicas alinhadas com a direção do vento;  $\alpha = 0.58$ ,  $\beta = 0.077$  (BASTANKHAH; PORTE-AGEL, 2016; STANLEY et al., 2021), e  $I$  é a intensidade de turbulência incidente no rotor.

Em contraste, a região da *far-wake* é menos influenciada pelas características detalhadas da turbina eólica. Ao invés disso, os parâmetros globais da turbina eólica, tais como o coeficiente de empuxo,  $C_T$ , e potência  $C_P$ , e as condições do escoamento de entrada, são suficientes para prever a distribuição média das velocidades do vento nesta região (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Dado o fato de que o espaçamento entre as turbinas em parques eólicos geralmente se enquadra na faixa de 3 a

10 diâmetros de rotor, as turbinas eólicas geralmente operam na região da *far-wake* das turbinas eólicas à montante (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Como resultado, compreender a região *far-wake* é essencial para melhorar a previsão e otimização da potência das turbinas eólicas em parques eólicos (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Na revisão realizada por Porté-Agel, Bastankhah e Shamsoddin (2019), são apresentados diversos estudos, realizados nos últimos anos, do escoamento médio na região da *far-wake* através de medições experimentais em campo, experimentos em laboratório (túnel de vento) e simulações numéricas. Para a esteira de turbinas eólicas na camada limite atmosférica (turbulenta), embora a distribuição do campo de velocidades não mostre um comportamento axissimétrico (CHAMORRO; PORTÉ-AGEL, 2008) (perfil  $\bar{\mathbf{u}}$  na Figura 2.12), o déficit de velocidades gerado pela esteira no campo de velocidades tem um formato aproximadamente Gaussiano axissimétrico após uma certa distância à jusante (CHAMORRO; PORTÉ-AGEL, 2008; TROLDBORG; SØRENSEN; MIKKELSEN, 2007) (perfil  $\Delta\bar{\mathbf{u}}$  na Figura 2.12 da região *far-wake*). Este formato Gaussiano do déficit de velocidades têm sido observado por medições em túnel de vento (WU; PORTE-AGEL, 2012) e dados operacionais de parques eólicos (GAUMOND et al., 2014).

Os experimentos em túnel de vento, realizados por CHAMORRO e PORTÉ-AGEL (2008), estudam a turbulência após um modelo de turbina eólica em escala reduzida. O modelo foi colocado em uma camada limite de estratificação neutra (ver seção 2.1.2), desenvolvida sobre superfícies rugosas e lisas. Utilizou-se anemometria a fio quente para caracterizar a distribuição transversal da velocidade média e a intensidade da turbulência em diferentes distâncias ( $x = 3d_0, 5d_0, 10d_0$  e  $15d_0$ ) na direção do vento para ambos os casos de rugosidade superficial. Em cada uma das posições em que os anemômetros foram colocados, medições foram coletadas em um plano perpendicular à direção do escoamento. A Figura 2.13 ilustra a montagem do experimento. No plano com os sensores, medições foram realizadas em uma malha de pontos separados por  $dy = dz = 10mm$  (nas direções transversais - *spanwise* e vertical), totalizando mais de 1400 locais de medições considerados para caracterizar o escoamento na região da esteira gerada pela turbina (CHAMORRO; PORTÉ-AGEL, 2008).

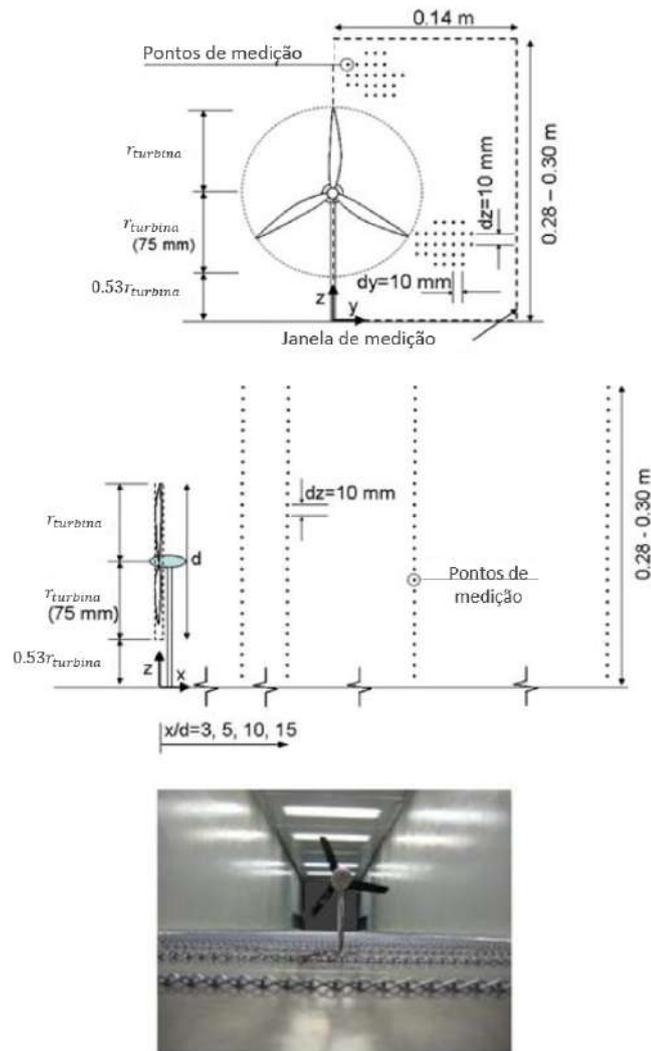


Figura 2.13: Esquemático do túnel de vento (vistas frontais e laterais), sistema de coordenadas e locais de medição (figura do topo e do meio), e fotografia da seção de teste do túnel de vento (figura de baixo). Adaptado de CHAMORRO e PORTÉ-AGEL (2008).

As Figuras 2.14 e 2.15 mostram a distribuição na seção transversal de medição (plano  $yz$ ) da velocidade média normalizada do escoamento  $U/U_{hub}$  e do déficit de velocidades normalizado  $\Delta U/U_{hub}$ . Os resultados mostram um comportamento simétrico da velocidade em relação ao plano vertical  $y = 0$ . Por esta razão as Figuras 2.14 e 2.15 apresentam os resultados das medições com enfoque em apenas um lado da esteira ( $y > 0$ ) (CHAMORRO; PORTÉ-AGEL, 2008).

A velocidade do vento afetada pela turbina é sobreposta à distribuição logarítmica de velocidade de entrada (perfil vertical do escoamento livre atmosférico), levando a uma esteira assimétrica. Entretanto, como mostrado na figura 2.15, o déficit de velocidades calculado em relação à distribuição de velocidade do vento de entrada,  $\Delta U = U(x >$

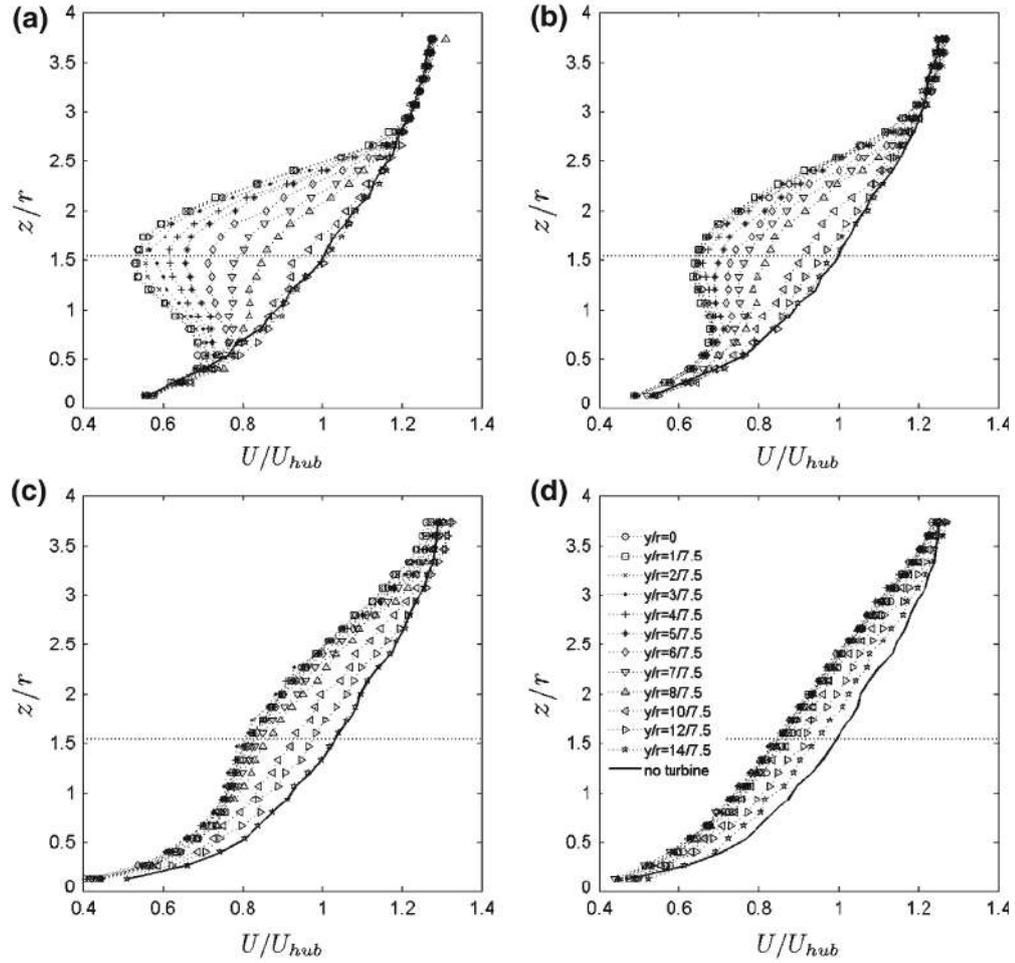


Figura 2.14: Distribuição transversal da velocidade média normalizada em diferentes posições à jusante da turbina para o caso com rugosidade superficial. **a**  $x/d_0 = 3$ ; **b**  $x/d_0 = 5$ ; **c**  $x/d_0 = 10$ ; e **d**  $x/d_0 = 15$ . A linha horizontal tracejada representa a altura do eixo da turbina.  $U$  velocidade do vento;  $U_{hub}$  velocidade do vento na altura do eixo da turbina;  $r$  raio do rotor da turbina (CHAMORRO; PORTÉ-AGEL, 2008).

$0, y, z) - U(x < 0, y, z)$ , é aproximadamente axissimétrico, com seu eixo de simetria localizado ligeiramente acima da altura do eixo do rotor. Isto é particularmente relevante, pois aponta para a possibilidade de generalizar formulações do déficit de velocidades (CHAMORRO; PORTÉ-AGEL, 2008).

Este comportamento da esteira de turbulência também é notado em simulações *LES - Large Eddy Simulation* realizadas por Wu e Porte-Agel (2012), também para estratificação atmosférica neutra em superfícies planas com diferentes rugosidades ( $z_0 = 0.5, 0.05, 0.005$  e  $0.00005m$ ). A Figura 2.16 apresenta os perfis logarítmicos de velocidade livre considerados no estudo numérico de Wu e Porte-Agel (2012).

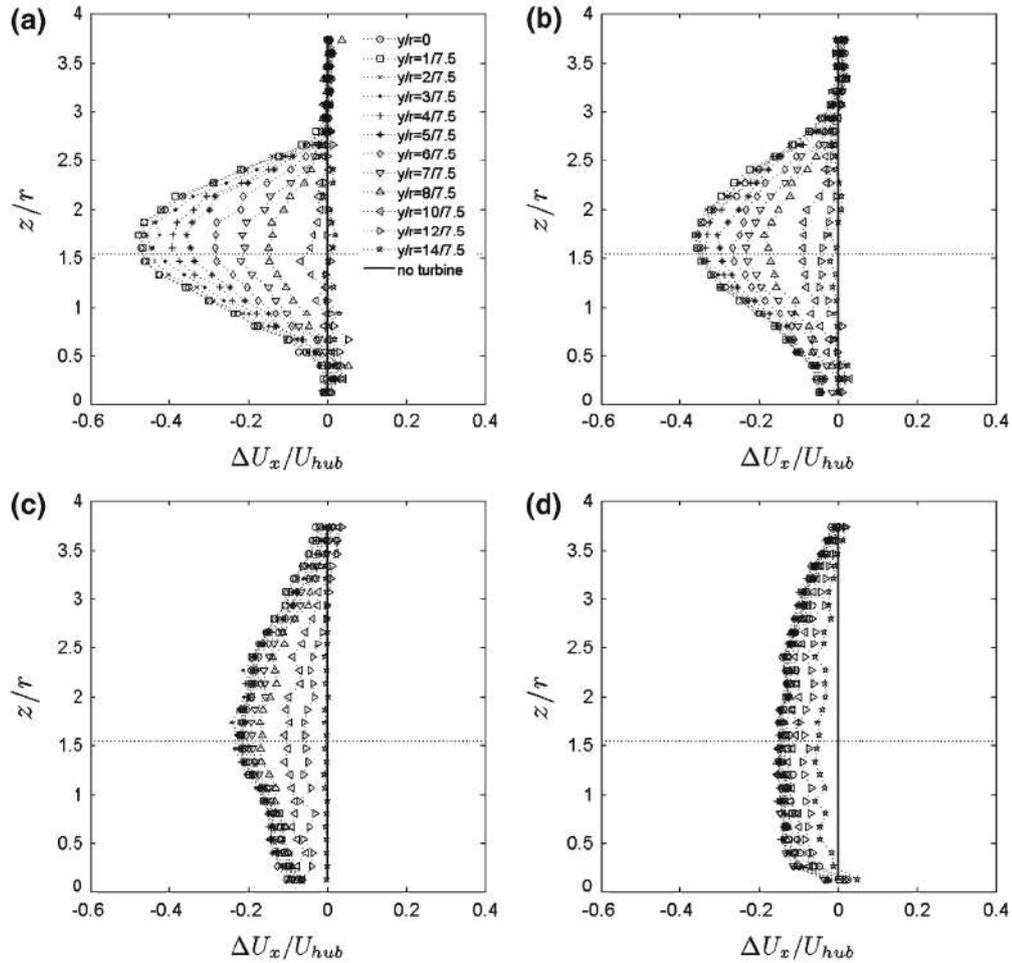


Figura 2.15: Distribuição transversal do déficit de velocidade normalizado em diferentes posições à jusante da turbina para o caso com rugosidade superficial. **a**  $x/d_0 = 3$ ; **b**  $x/d_0 = 5$ ; **c**  $x/d_0 = 10$ ; e **d**  $x/d_0 = 15$ . A linha horizontal tracejada representa a altura do eixo da turbina.  $\Delta U$  déficit de velocidade;  $U_{hub}$  velocidade do vento na altura do eixo da turbina;  $r$  raio do rotor da turbina (CHAMORRO; PORTÉ-AGEL, 2008).

A Figura 2.17 apresenta os perfis lateral e vertical dos déficits de velocidades calculados numericamente (via simulações em *LES*) por Wu e Porte-Agel (2012) em relação ao perfil logarítmico de velocidades livres (mostrado na Figura 2.16) para cada um dos casos de rugosidade superficial,  $z_0$ . Estes perfis também mostram um comportamento quase axissimétrico, com eixo de simetria localizado próximo ao eixo do rotor da turbina, o que são comportamentos em concordância com outros estudos numéricos (RÉTHORÉ et al., 2009) e experimentais (RADOS et al., 2001).

Recentemente, Doubrava et al. (2020) realizaram um estudo comparativo entre o desempenho de vários modelos na simulação da esteira de uma única turbina, quando comparado com as medições experimentais de alta resolução do campo de velocidades

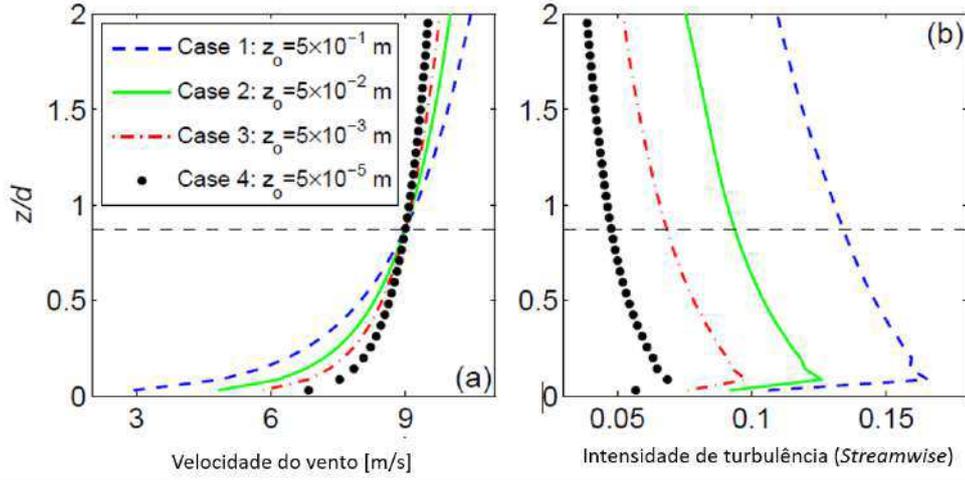


Figura 2.16: Perfis verticais de velocidade com  $U_{hub} = 9$  m/s na altura do eixo da turbina (a) velocidade média,  $u$  (m/s); (b) intensidade de turbulência,  $I_u$ . Adaptado de Wu e Porte-Agel (2012)

afetados pela esteira de uma turbina eólica. Os modelos aerodinâmicos para análise das turbinas variam: curvas de potência ( $C_P$ ) e coeficiente de empuxo ( $C_T$ ), como os discutidos na seção 2.2; disco atuador baseado em dados de aerofólio; ou linhas atuadores rotativas. Já os modelos de esteira considerados pertencem a uma das cinco categorias de modelo de esteira: analítico em regime permanente (SSA - *Steady State Analytical*); *dynamic wake meandering type* (DWMT); Reynolds-averaged Navier-Stokes parabólica (RANS-P) e elíptica (RANS-E); e LES. Um resumo das diferentes combinações de modelos de fluxo de entrada (escoamento atmosférico livre), turbina e esteira usados em cada simulação é apresentado na Tabela 2.2.

As comparações gerais da esteira para o *benchmark* de condições de fluxo atmosférico neutro revelaram uma classificação de desempenho dos modelos que segue a ordem de complexidade e fidelidade dos modelos, com os melhores resultados para a LES seguida por DWMT, RANS-E, SSA, e RANS-P (DOUBRAWA et al., 2020). É importante destacar que, segundo Doubrawa et al. (2020), quando as abordagens de simulação são consideradas individualmente, uma análise de desempenho da esteira média revela que modelos de menor fidelidade podem ser uma melhor escolha para aplicações que se concentram na esteira média e estão preocupadas com o custo computacional, de forma que as decisões sobre o *trade-off* entre precisão e custo computacional possam ser bem consideradas e apropriadas à aplicação pretendida. A Figura 2.18 apresenta um gráfico

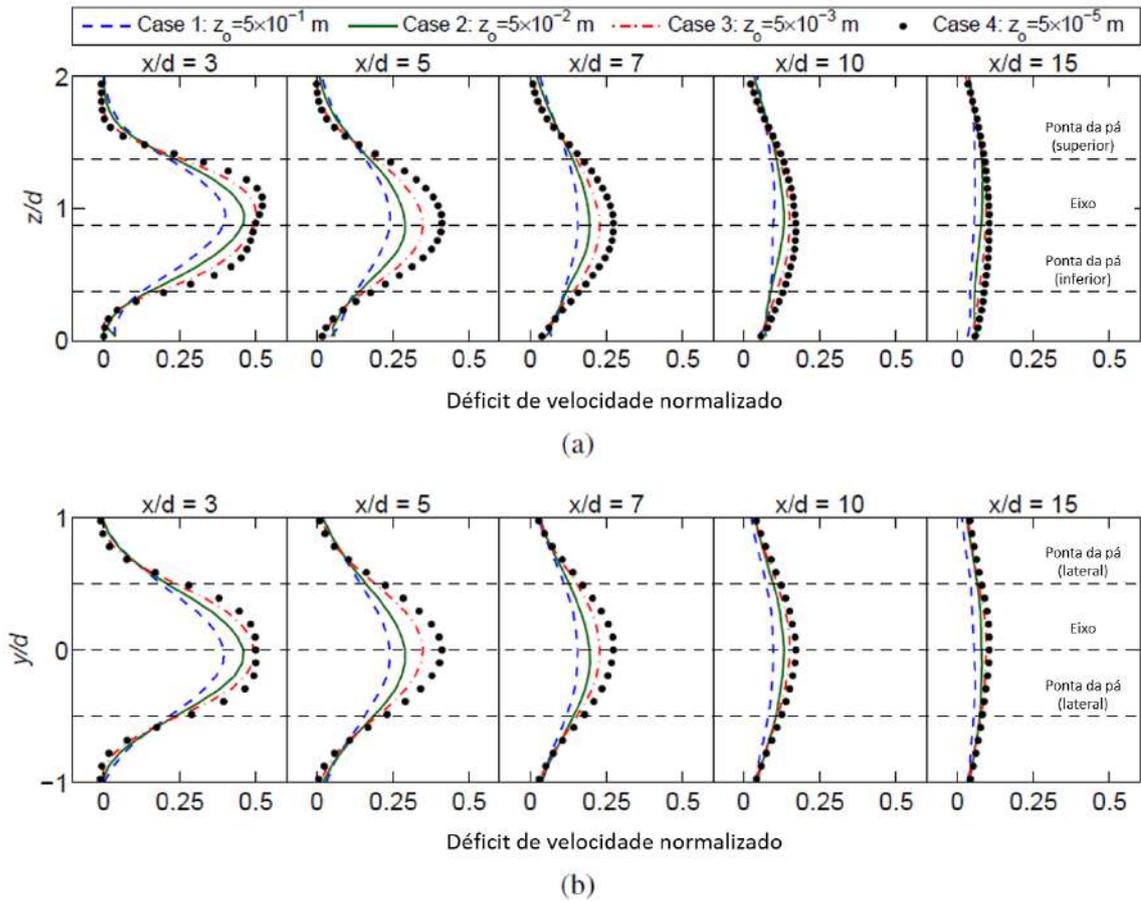


Figura 2.17: Comparação dos perfis vertical (a) e lateral (b) do déficit de velocidades normalizado  $\Delta U/U_{hub}$ . Adaptado de Wu e Porte-Agel (2012).

da relação custo computacional versus acurácia dos modelos no caso de condições atmosféricas neutra, condição atmosférica de interesse no presente trabalho.

Algumas aplicações, tais como a otimização do layout de parques eólicos exigem a previsão do campo de velocidades gerado pelas esteiras das turbinas para muitos (na ordem de milhares ou mais, dependendo da técnica de otimização) cenários, incluindo múltiplos layouts e variações na direção do vento e velocidade do vento (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Tais aplicações de otimização só podem ser obtidas utilizando modelos de esteira simples e computacionalmente com menor custo (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Dessa forma, como o presente estudo visa empregar os modelos de esteira (*wake*) em um problema de otimização, avaliando as condições de operação médias do parque eólico, optou-se por utilizar o modelo de esteira gaussiano que, dentre os de menor custo computacional, foi o que apresentou o menor *normalized difference norm of mean wake* (norma da diferença normalizada da

Tabela 2.2: Modelos comparados na simulação de esteira; O modelo de escoamento de entrada do tipo *Prescribed* equivale aos perfis logarítmicos/lei de potência da seção 2.1.2; os demais modelos são apenas considerados aqui a título de comparação; para maiores detalhes verificar Doubrava et al. (2020). O modelo de turbina do tipo  $C_P$ ,  $C_T$  são os apresentados na Seção 2.2; para maiores detalhes dos demais modelos, verificar referência. Adaptado de Doubrava et al. (2020).

Categoria/Nome da simulação	Modelo do escoamento de entrada	Modelo da turbina	Modelo de esteira	Instituição
SSA-FarmShadow	Prescribed	$C_P, C_T$	FarmShadow (SSA)	IFPEN
SSA-Gaussian	Prescribed	$C_P, C_T$	FLORIS (SSA)	NREL
SSA-GaussianIQ	Prescribed	$C_P, C_T$	FLORIS (SSA)	NREL
RANS-WakeBlaster	Prescribed	$C_P, C_T$	WakeBlaster (RANS)	PPE
RANS-EllipSys3D-MOST	MOST	Actuator Disk	EllypSys3D (RANS)	DTU
RANS-EllipSys3D-ABL	ABL	Actuator Disk	EllypSys3D (RANS)	DTU
DWMT-FASTFarm	Stochastic	BEM	FAST.Farm (DWMT)	NREL
DWMT-FASTFarm-LES	LES	BEM	FAST.Farm (DWMT)	NREL
LES-EllipSys3D	LES	Actuator Line	EllipSys3D (LES)	DTU
LES-PALM	LES	Actuator Line	PALM (LES)	ForWind
LES-NaluWind	LES	Actuator Line	Nalu-Wind (LES)	SNL
LES-SOWFA	LES	Actuator Line	SOWFA (LES)	IFPEN
LES-SOWFA-2	LES	Actuator Line	SOWFA (LES)	NREL

esteira média), conforme visto na Figura 2.18. Dessa forma, foi considerado o modelo Gaussiano de esteira de turbulência (SSA Gaussian - ver Tabela 2.2) (BASTANKHAH; PORTE-AGEL, 2014; BASTANKHAH; PORTE-AGEL, 2016), implementado na plataforma *Flow Redirection and Induction in Steady State* (FLORIS), implementado pelo *National Renewable Energy Laboratory* (NREL) do governo dos Estados Unidos da América (NREL, 2022).

De maneira resumida, a plataforma FLORIS/NREL modela o déficit de velocidades como uma função do coeficiente de empuxo do rotor,  $C_T$ , e um coeficiente de expansão linear da esteira,  $k$  (BASTANKHAH; PORTE-AGEL, 2014; BASTANKHAH; PORTE-AGEL, 2016), enquanto a expansão da esteira é modelada empiricamente em função da intensidade da turbulência,  $I$  (NIAYIFAR; PORTÉ-AGEL, 2016; BASTANKHAH; PORTE-AGEL, 2016). O coeficiente de empuxo vem de uma curva,  $C_T(U)$  (NREL, 2022), como exemplificado na Figura 2.30 mais adiante. A próxima seção apresenta a formulação matemática para o cálculo do déficit de velocidades nas posições à jusante da turbina.

### 2.3.1 Modelo do déficit de velocidade

Conforme observado nos resultados experimentais de CHAMORRO e PORTÉ-AGEL (2008) e mostrado nas Figuras 2.15 e 2.17, o déficit de velocidades calculado com relação

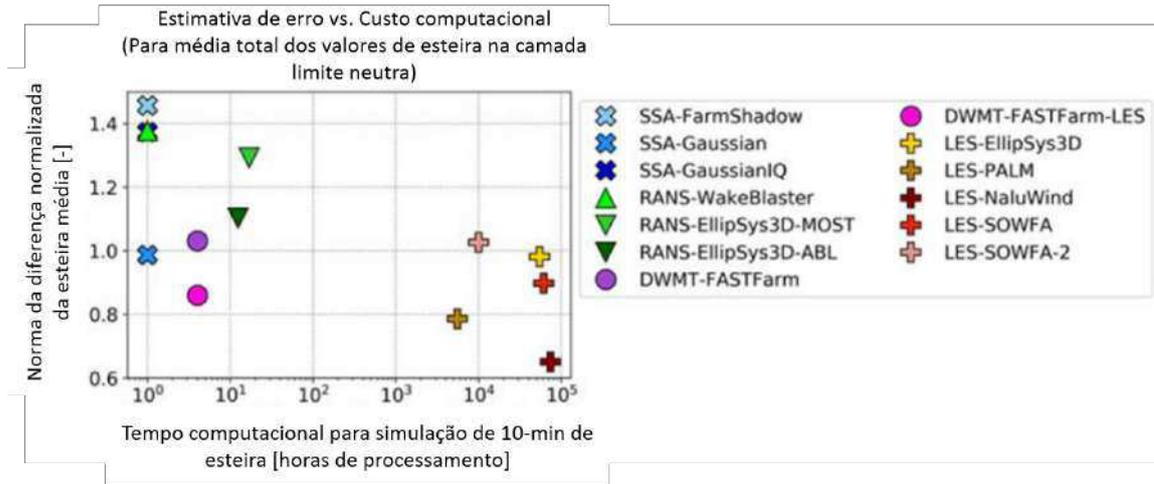


Figura 2.18: Estimativa de erro de cada abordagem de simulação como uma função do custo computacional para o *benchmark* de estratificação atmosférica neutra. A estimativa de erro é a norma da diferença normalizada dos perfis de déficit de velocidade unidimensional, com média de tempo nas direções vertical e horizontal e somada para todas as distâncias a jusante. O custo computacional é dado em horas de processamento para uma simulação da esteira com 10 minutos de duração e não inclui o custo de simulação de fluxo atmosférico de entrada e não levando em consideração o desempenho dos códigos de implementação em si (DOUBRAWA et al., 2020).

à distribuição da velocidade do vento do escoamento livre,  $\Delta U = U(x > 0, y, z) - U(x < 0, y, z)$ , é aproximadamente axissimétrico, com seu eixo de simetria localizado próximo da altura do cubo do eixo do rotor. Essa observação aponta para a possibilidade de generalizar formulações dos déficits de velocidade impostos às condições do escoamento livre e que sejam de baixo custo computacional (CHAMORRO; PORTE-AGEL, 2008). Esta subseção fornece uma breve descrição do modelo de déficit de velocidades Gaussiano utilizado no presente trabalho. Para maiores detalhes, verificar (BASTANKHAH; PORTE-AGEL, 2014; BASTANKHAH; PORTE-AGEL, 2016).

Usando o modelo de esteira Gaussiano, a velocidade da esteira atrás de uma turbina é calculada através das seguintes expressões analíticas:

$$\begin{aligned} \frac{\Delta U}{U_\infty} &= \frac{U(x, y, z) - U_\infty}{U_\infty} = C(x) e^{\frac{-r^2}{2(\sigma_y \sigma_z)^2}} \\ C(x) &= \left( 1 - \sqrt{1 - \frac{C_T \cos \gamma}{8 (\sigma_y \sigma_z / d_0^2)}} \right) \rightarrow \text{Déficit de velocidade máximo normalizado} \\ e^{\frac{-r^2}{2(\sigma_y \sigma_z)^2}} &= e^{-0.5(y-\delta/\sigma_y)^2} e^{-0.5(z-z_h/\sigma_z)^2} \rightarrow \text{Distribuição gaussiana (radial) do déficit} \\ &\text{de velocidade,} \end{aligned} \tag{2.21}$$

onde  $U(x, y, z)$  é a velocidade à jusante da turbina ( $x > 0$ ) em uma posição de interesse  $(x, y, z)$ , em que  $x$ ,  $y$  e  $z$  se referem às coordenadas ao longo da direção do vento, transversal à direção do vento e posição vertical com  $z = 0$  no solo, respectivamente;  $r$  uma posição radial em relação ao centro da esteira;  $U_\infty$  o perfil velocidades livre;  $y - \delta$  é a distância transversal à direção do vento entre o ponto de interesse  $(x, y, z)$  e o centro da esteira (em que  $\delta$  é a coordenada  $y$  do centro da esteira e é considerada como uma linha ao longo de  $x$  passando pela turbina, se o rotor não estiver desalinhado com o vento, i.e.:  $\gamma = 0$ ),  $z - z_h$  é a distância vertical entre o ponto de interesse  $(x, y, z)$  e o centro da esteira (onde o centro da esteira é considerado na altura do eixo da turbina,  $z_h$ );  $d_0$  é o diâmetro do rotor,  $C_T$  o coeficiente de empuxo,  $\gamma$  é o ângulo de desalinhamento do rotor com a direção do vento (*yaw angle*, que será considerado como 0 no presente trabalho);  $\sigma_y$  define a largura da esteira na direção  $y$ , e  $\sigma_z$  define a largura da esteira na direção  $z$ .

As larguras da esteira nas direções lateral ( $\sigma_y$ ) e vertical ( $\sigma_z$ ) são definidas, respectivamente, como:

$$\frac{\sigma_y}{d_0} = k_y \frac{(x - x_0)}{d_0} + \frac{\sigma_{y0}}{d_0}, \tag{2.22}$$

$$\frac{\sigma_z}{d_0} = k_z \frac{(x - x_0)}{d_0} + \frac{\sigma_{z0}}{d_0}, \tag{2.23}$$

onde  $x - x_0$  é a distância à jusante entre o ponto de interesse  $x$  e o início da região da *far-wake*,  $x_0$ ;  $\sigma_{y0}$  e  $\sigma_{z0}$  se referem à larguras da esteira no início da região de *far-wake*,  $k_y$  é a taxa de expansão da esteira na direção lateral ( $y$ ), e  $k_z$  a taxa de expansão da esteira na direção vertical ( $z$ ). O comprimento da região de *near-wake* é definido conforme equação

2.20. As variáveis  $\sigma_{y0}$  e  $\sigma_{z0}$  são dadas nas seguintes equações:

$$\frac{\sigma_{z0}}{d_0} = \frac{1}{2} \sqrt{\frac{u_R}{U_\infty + u_0}}, \quad (2.24)$$

$$\frac{\sigma_{y0}}{d_0} = \frac{\sigma_{z0}}{d_0} \cos \gamma, \quad (2.25)$$

onde  $u_R$  e  $u_0$  são definidos em termos do coeficiente de empuxo  $C_T$  e da velocidade livre  $U_\infty$ :

$$\frac{u_R}{U_\infty} = \frac{C_T}{2(1 - \sqrt{1 - C_T})} \quad (2.26)$$

$$\frac{u_0}{U_\infty} = \sqrt{1 - C_T}. \quad (2.27)$$

Para o presente estudo considera-se  $k_y$  e  $k_z$  iguais, o que significa uma expansão da esteira a uma mesma taxa nas direções lateral e vertical. Estes parâmetros são definidos como se segue (NIAYIFAR; PORTÉ-AGEL, 2016):

$$k_z = k_y = k_a I + k_b, \quad (2.28)$$

em que  $k_a = 0.38$ ,  $k_b = 0.004$  e  $I$  a intensidade de turbulência no rotor, fazendo com que a taxa local de crescimento da esteira seja baseada na intensidade de turbulência local, considerando assim os efeitos de turbulência no interior do parque eólico (NIAYIFAR; PORTÉ-AGEL, 2016). O aumento na intensidade de turbulência no interior do parque, devido às influências das esteiras, é discutido na Seção 2.3.2.

### 2.3.2 Modelo de turbulência

Em parques eólicos, a interferência no escoamento gerada pelas esteiras das turbinas levam a um aumento substancial no nível de intensidade de turbulência,  $\Delta I$ , em relação ao nível de turbulência do escoamento da camada limite atmosférica livre,  $I_0$ , (NIAYIFAR; PORTÉ-AGEL, 2016). Este efeito tem sido observado em vários estudos numéricos e experimentais (PORTE-AGEL; WU; CHEN, 2013; ABKAR; PORTÉ-AGEL, 2014; QUAR-

TON; AINSLIE, 1990a). Conforme mostrado na equação 2.28, os coeficientes de expansão da esteira ( $k_y$  e  $k_z$ ) variam conforme intensidade de turbulência experimentada pela turbina eólica. Dessa forma, torna-se importante a determinação dos incrementos na intensidade de turbulência gerados pelas esteiras das turbinas eólicas ao longo do parque eólico, de modo a se determinar os coeficientes de expansão,  $k$ , das turbinas que são afetadas pelas esteiras de outras turbinas mais à montante.

O valor de  $\Delta I$  atinge seu máximo a uma distância de 2 a 4 diâmetros de rotor à jusante da turbina, coincidindo com a transição entre as regiões de *near-wake* para *far-wake* (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). O pico de intensidade de turbulência dentro da esteira da turbina eólica ocorre mais cedo para as camadas limite atmosférica com maior intensidade de turbulência, uma vez que o comprimento da *near-wake* é mais curto neste caso (WU; PORTE-AGEL, 2012) (ver influência da intensidade de turbulência  $I$  no comprimento da *near-wake* conforme mostra Equação 2.20). Com o aumento da distância à jusante, o valor da intensidade de turbulência no interior da esteira,  $I_w$ , diminui monotonicamente com  $x$  na *far-wake* (CRESPO; HERNÁNDEZ, 1996; PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Diferentes modelos empíricos e semi-empíricos têm sido propostos na literatura para prever a variação de  $\Delta I$  com  $x$  na região da *far-wake* das turbinas (QUARTON; AINSLIE, 1990b; CRESPO; HERNÁNDEZ, 1996; XIE; ARCHER, 2015; QIAN; ISHIHARA, 2018).

Baseado em estudos numéricos, CRESPO e HERNÁNDEZ (1996) sugeriram a seguinte expressão semi-empírica para se caracterizar  $\Delta I$  em um regime operacional com  $5d_0 < x < 15d_0$ ,  $0.07 < I < 0.14$  e  $0.1 < a < 0.4$ , em que  $a = \left(\frac{1-\sqrt{1-C_T}}{2}\right)$  é o fator de indução:

$$\Delta I = 0.73 \left( \frac{1 - \sqrt{1 - C_T}}{2} \right)^{0.83} I_0^{0.0325} \left( \frac{x}{d_0} \right)^{-0.32}. \quad (2.29)$$

Em geral, estes modelos utilizam o coeficiente de empuxo,  $C_T$ , das turbinas e a intensidade da turbulência ambiente,  $I_0$ , para estimar a intensidade da turbulência acrescentada pela turbina eólica,  $\Delta I$ , e então, juntamente com a intensidade de turbulência incidente,  $I_0$ , avaliar a intensidade de turbulência presente na região de esteira,  $I_w$ , como

se segue:

$$I_w = \sqrt{I_0^2 + \Delta I^2} \quad (2.30)$$

Para a intensidade de turbulência local, Niayifar e Porté-Agel (2016) propuseram utilizar uma distribuição *top-hat* (ver Figura 2.19) com um diâmetro de  $4\sigma$ , a qual foi derivada semi-empiricamente através de simulações *LES* (PORTE-AGEL; WU; CHEN, 2013), onde  $\sigma$  representa o desvio padrão do perfil do déficit de velocidades, definido conforme equação 2.31 (BASTANKHAH; PORTE-AGEL, 2014):

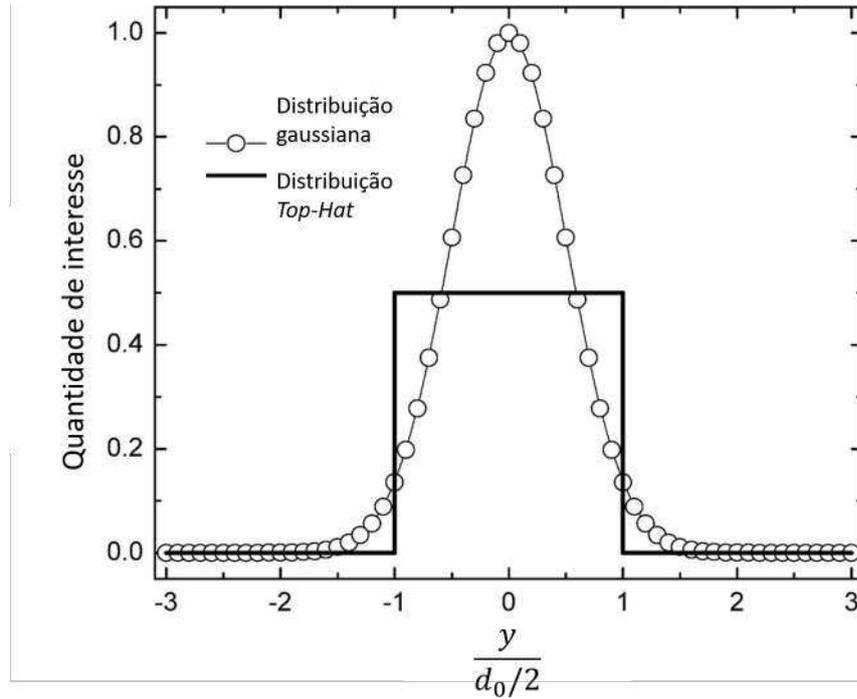


Figura 2.19: Ilustração da comparação entre o perfil gaussiano (utilizado para modelar distribuição radial do déficit de velocidades) e a distribuição do tipo *Top-hat* (utilizada para a intensidade de turbulência).

$$\frac{\sigma}{d_0} = k^* \frac{x}{d_0} + \epsilon, \quad (2.31)$$

sendo  $k^* = k_y = k_z$  e  $\epsilon = 0.25 \left( 0.5 \times (1 + \sqrt{1 - C_T}) / \sqrt{1 - C_T} \right)^{0.5}$  (BASTANKHAH; PORTE-AGEL, 2014). O nível de intensidade da turbulência, que aumenta no interior do parque eólico, alcança rapidamente um equilíbrio após 2-3 filas de turbinas eólicas (PORTE-AGEL; WU; CHEN, 2013). Um estudo anterior realizado por Frandsen e Thøgersen (1999) também mostrou que para prever a intensidade de turbulência após

uma determinada turbina, o único efeito importante é o das turbinas vizinhas à montante. Dessa forma, para cada turbina, é considerada apenas a intensidade de turbulência acrescentada pela turbina mais próxima à montante, cuja esteira tem o impacto mais significativo. Este conceito é implementado conforme equação 2.32 (NIAYIFAR; PORTÉ-AGEL, 2016):

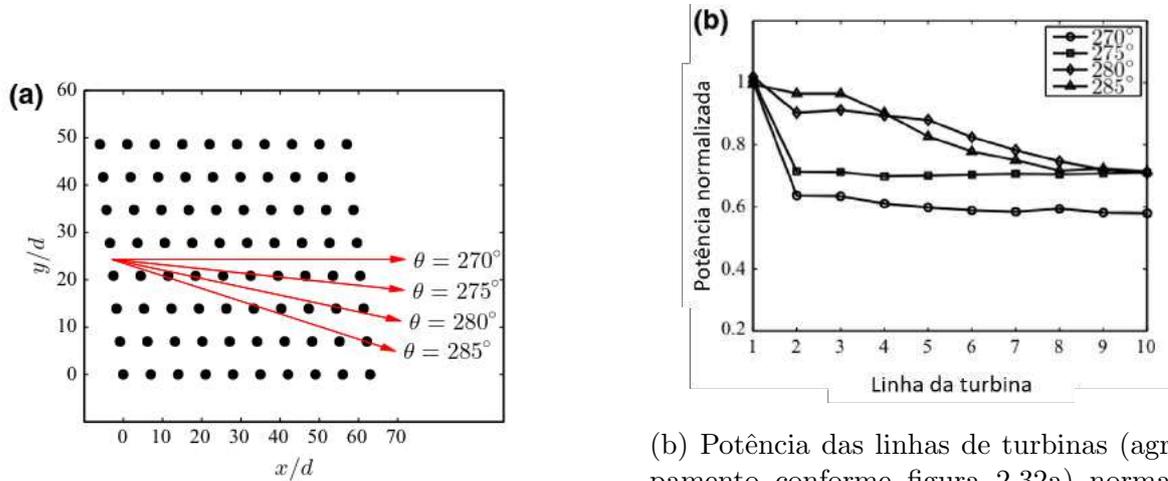
$$\Delta I_j = \max_k \left( \frac{A_w}{\pi d^2/4} \Delta I_{kj} \right), \quad (2.32)$$

onde  $\Delta I_j$  é a intensidade de turbulência adicionada pela turbina  $j$ ;  $A_w$  é a área de intersecção entre a esteira (*top-hat* neste caso - utilizando a equação 2.31) na posição  $x$  da turbina  $j$  afetada e a área do rotor da turbina  $j$ ; e  $\Delta I_{kj}$  é a intensidade de turbulência adicionada por uma turbina  $k$  a montante na turbina  $j$ .

### 2.3.3 Modelo de sobreposição de esteiras

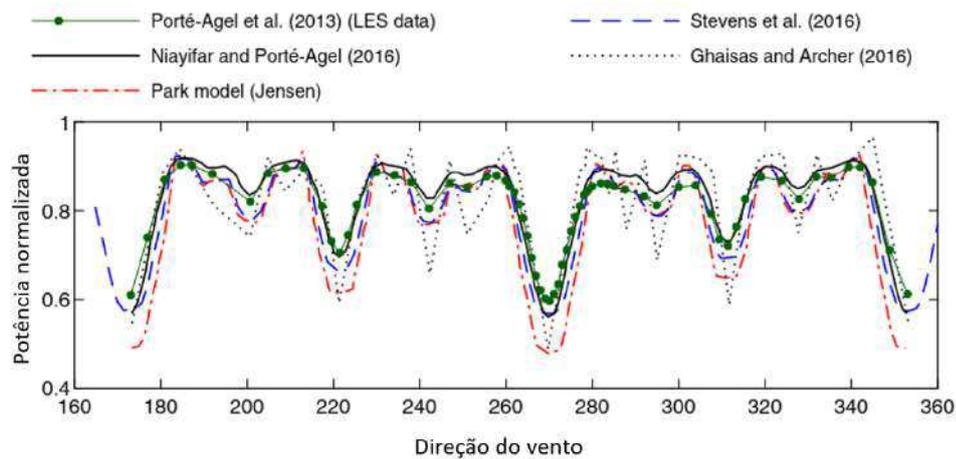
A região do escoamento atmosférico no interior dos parques eólicos é caracterizada por um escoamento de baixa velocidade com alta intensidade de turbulência, devido aos efeitos cumulativos das esteiras das turbinas eólicas (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Tanto o déficit de velocidades quanto o nível da intensidade de turbulência aumentam nas primeiras fileiras de turbinas, enquanto sua variação entre as fileiras subsequentes se torna progressivamente menor (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Para uma determinada configuração do parque eólico, o *layout* efetivo do parque (posições das turbinas em relação à direção do escoamento de entrada) muda com a direção do vento, i.e., a posição relativa das turbinas muda quando se considera o vento ocorrendo a direções diferentes. Vários estudos de campo em parques eólicos (BARTHELMIE et al., 2006; BARTHELMIE et al., 2009; BARTHELMIE; JENSEN, 2010) têm mostrado que a direção do vento e sua variabilidade têm grandes efeitos na potência gerada pelo parque eólico. A figura 2.20a mostra o layout do parque eólico de Horns Rev I (BARTHELMIE et al., 2010) (parque eólico offshore com 80 turbinas Vestas V80 - 2MW (JENSEN et al., 2011)) juntamente com a Figura 2.20b, que mostra a potência de saída do parque normalizada em função da primeira linha de turbinas eólicas para quatro direções de vento selecionadas. A distribuição da potência do parque para

um intervalo de diferentes direções de vento normalizada em função da potência nominal das 80 turbinas Vestas V80, é apresentada na Figura 2.20c. Os resultados da Figura 2.20b seguem o agrupamento das turbinas em linhas ilustrados na Figura 2.32a.



(a) Layout do parque eólico de Horns Rev I com 4 direções do vento.

(b) Potência das linhas de turbinas (agrupamento conforme figura 2.32a) normalizada em relação à potência da primeira linha.



(c) Potência de todo o parque eólico de Horns Rev I em função de um intervalo de direções do vento e normalizada pela potência nominal de produção da turbina eólica Vestas V80. Comparação entre diferentes modelos de esteira estudados por Porté-Agel, Bastankhah e Shamsoddin (2019)

Figura 2.20: Potência gerada pelo parque eólico de Horns Rev I com diferentes cenários de direção do vento. Adaptado de Porté-Agel, Bastankhah e Shamsoddin (2019), Barthelmie et al. (2009).

Esta forte sensibilidade na potência gerada pelo parque eólico com pequenas variações da direção do vento deve ser levada em conta para o controle e integração ótima do *layout* dos parques eólicos (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). A abordagem mais comum para modelar analiticamente os fluxos do parque eólico é modelar cada esteira de turbina usando um modelo analítico de déficit de velocidades,

conforme apresentado na Seção 2.3.1 e 2.3.2, enquanto aplicam-se métodos de sobreposição das esteiras para contabilizar a interação entre múltiplas esteiras sobrepostas (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019). Um resumo dos diferentes métodos de sobreposição de esteiras disponíveis para estimar a velocidade em uma determinada posição  $\mathbf{X} = (x, y, z)$  do parque eólico é dada na Tabela 2.3. Dessa forma, a velocidade em cada posição é uma função do déficit de velocidades induzido por todas as turbinas à montante (de  $i = 1$  até  $n$ ) cujas esteiras afetam o escoamento em tal posição, sendo  $u_\infty$  o perfil livre de velocidade,  $u_{in,i}$  a velocidade de incidência na turbina  $i$  e  $u_i(\mathbf{X})$  a velocidade da esteira da turbina  $i$  calculada na posição  $X$  através do modelo de esteiras usado (no presente trabalho conforme seção 2.3.1).

Tabela 2.3: Diferentes técnicas de sobreposição utilizadas na literatura para modelar as sobreposições de esteira em parques eólicos.

Modelos de superposição	Definição
(LISSAMAN, 1979)	$u(\mathbf{X}) = u_\infty - \sum_{i=1}^n \Delta u_i(\mathbf{X})$ , onde $\Delta u_i(\mathbf{X}) = u_\infty - u_i(\mathbf{X})$
(KATIC; HØJSTRUP; JENSEN, 1987)	$u(\mathbf{X}) = u_\infty - \sqrt{\sum_{i=1}^n \Delta u_i^2(\mathbf{X})}$ , onde $\Delta u_i(\mathbf{X}) = u_\infty - u_i(\mathbf{X})$
(VOUTSINAS; RADOS; ZERVOS, 1990)	$u(\mathbf{X}) = u_\infty - \sqrt{\sum_{i=1}^n \Delta u_i^2(\mathbf{X})}$ , onde $\Delta u_i(\mathbf{X}) = u_{in,i} - u_i(\mathbf{X})$
(NIAYIFAR; PORTÉ-AGEL, 2016)	$u(\mathbf{X}) = u_\infty - \sum_{i=1}^n \Delta u_i(\mathbf{X})$ , onde $\Delta u_i(\mathbf{X}) = u_{in,i} - u_i(\mathbf{X})$
(GUNN et al., 2016)	$u(\mathbf{X}) = u_\infty - \max_i \{\Delta u_i(\mathbf{X})\}$ , onde $\Delta u_i(\mathbf{X}) = u_{in,i} - u_i(\mathbf{X})$

As equações apresentadas na Tabela 2.3 definem a velocidade do vento,  $u(x, y, z)$ , em cada ponto de interesse no espaço  $(x, y, z)$ . O conjunto de pontos de interesse pode ser uma malha estruturada (*grid*) no domínio do parque, como nas verificações do modelo apresentadas na Seção 2.4; entretanto, em um processo de otimização de parques eólicos, avaliar a velocidade em todos os pontos do domínio do parque acaba tendo um grande custo computacional. Dessa forma, devido aos modelos serem analíticos, tem-se a opção de avaliar as velocidades apenas em determinados pontos de interesse, reduzindo assim o custo computacional. Para determinar a velocidade média do vento que incide no rotor, usado para calcular a produção de energia de uma turbina eólica, calcula-se a média das velocidades do vento amostradas em nove pontos distribuídos na região ocupada pelo rotor. A posição de cada um destes pontos são mostradas na figura 2.21.

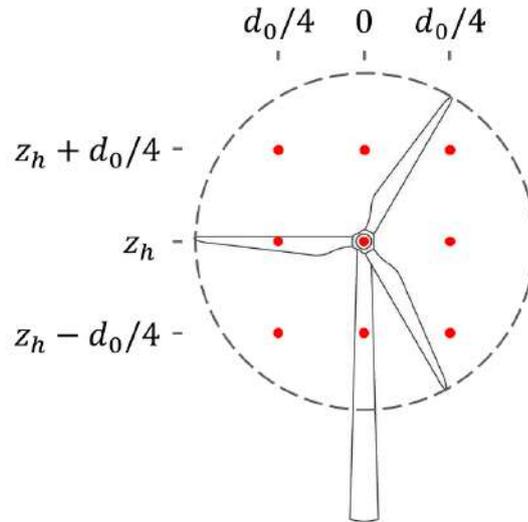


Figura 2.21: Distribuição dos 9 pontos de interesse na região do rotor da turbina em que as velocidades do vento são calculadas.  $d$  representa o diâmetro do rotor e  $z_h$  a altura do eixo da turbina. A velocidade efetiva do vento que incide na turbina é determinada como a média da velocidade do vento nestes pontos.

### 2.3.4 Procedimento de cálculo de velocidades nos pontos de interesse

De forma a integrar os modelos de déficit de velocidade (modelo Gaussiano - Seção 2.3.1), de turbulência - Seção 2.3.2 e o modelo de sobreposição das esteiras, da presente seção, apresenta-se o Algoritmo 1, o qual inicia recebendo os parâmetros de entrada do parque eólico, como: as informações e características das turbinas instaladas, **Turb**; o vetor de direções do vento,  $\Theta$ ; o vetor de velocidades do vento a uma dada altura de referência,  $\mathbf{U}_\infty(z_{ref.})$ ; as coordenadas  $\mathbf{x}, \mathbf{y}, \mathbf{z}$  dos pontos de interesse no interior do parque; e a intensidade de turbulência atmosférica,  $I_0$ . Para cada direção e velocidade livre do vento, aplica-se o modelo de sobreposição de esteiras de turbulência (NIAYIFAR; PORTÉ-AGEL, 2016), apresentado na tabela 2.3.

Como o modelo de sobreposição resolve o escoamento da turbina mais a montante para a mais a jusante, a ordenação das turbinas nesta ordem, para cada direção do vento, é necessária. Após a ordenação das turbinas, o algoritmo calcula, para cada turbina, o efeito de sua esteira nas turbinas mais a jusante. Esse efeito é armazenado no campo de velocidades **Campo<sub>veloc</sub>**, que contém os pontos de interesse do rotor de cada turbina para

a direção  $\theta \in \Theta$  e velocidade livre atmosférica  $U_\infty(z_{ref.}) \in \mathbf{U}_\infty(z_{ref.})$  considerada. Então o algoritmo dá sequência com a próxima turbina até a última turbina, para cada combinação de direção e velocidade do vento. Ao final da simulação do campo de velocidades para cada direção e velocidade, armazena-se os resultados do campo em um campo separado **Campo<sub>veloc</sub>**( $\theta, U_\infty(z_{ref.})$ ), o qual contém os resultados da simulação do parque para dada condição do vento ( $\theta, U_\infty(z_{ref.})$ ). Estes procedimentos são apresentados nos Algoritmos 1 e 2.

---

**Algoritmo 1:** Pseudo-código para cálculo das velocidades nos pontos de interesse de cada turbina eólica, para as condições do vento consideradas  $\mathbf{U}(\Theta, \mathbf{U}_\infty(z_{ref.}), \mathbf{x}, \mathbf{y}, \mathbf{z}, I_0)$  (NREL, 2022)

---

**Entrada:** • Turbinas eólicas, **Turb** • Direções do vento,  $\Theta$   
• Velocidades livres atmosférica a uma mesma altura de referência ( $z_{ref.}$ ),  $\mathbf{U}_\infty(z_{ref.})$   
• Coordenadas  $\mathbf{x}, \mathbf{y}, \mathbf{z}$  dos pontos de interesse de cada turbina (ver Figura 2.21)  
• Intensidade de turbulência ambiente,  $I_0$

**Saída:** Velocidades de incidência em cada ponto de interesse das turbinas eólicas para as condições do vento dadas  $\Theta$  e  $\mathbf{U}_\infty(z_{ref.})$

```

1 início
2   for cada  $\theta$  em  $\Theta$  do
3     for cada  $U_\infty(z_{ref.})$  em  $\mathbf{U}_\infty(z_{ref.})$  do
4       /*sistema de coordenadas dos pontos de interesse das turbinas
5         rotacionados em relação à direção do vento  $\theta$  e ordenação das
6         turbinas Montante  $\rightarrow$  Jusante*/
7        $\mathbf{x}, \mathbf{y}, \mathbf{z} = \text{rotacionar\_coordenadas}(\theta, \mathbf{x}, \mathbf{y}, \mathbf{z});$ 
8        $\mathbf{x}, \mathbf{y}, \mathbf{z} = \text{ordena\_turbinas}(\theta, \mathbf{x}, \mathbf{y}, \mathbf{z});$ 
9       /*Inicializa o campo de velocidades em todos os pontos  $\mathbf{x}, \mathbf{y}, \mathbf{z}$ 
10        conforme perfil vertical de velocidades - equação 2.11 ou 2.12*/;
11      Campoveloc = Campoveloc_amb =
12        inicializa_campo_velocidades( $\mathbf{x}, \mathbf{y}, \mathbf{z}, U_\infty(z_{ref.})$ );
13      /*inicializa o campo de velocidades afetado, preenchido com
14        zeros, com mesma estrutura de Campoveloc;
15      Campoesteira = zeros(Campoveloc);
16      /*inicializa o campo de intensidade de turbulência (IT) com a
17        intensidade fornecida,  $I_0$ 
18      CampoturbIntens = CampoambTurb = inicializa_campo_IT( $I_0$ );
19      /*salva separadamente o campo de velocidades do parque para a
20        condição do vento ( $\theta, U_\infty(z_{ref.})$ ), após sobreposição das esteiras
21        realizada pelo Algoritmo 2*/
22      Campoveloc  $\leftarrow$  Algoritmo 2
23      Campoveloc( $\theta, U_\infty(z_{ref.})$ )  $\leftarrow$  Campoveloc
24    end for
25  end for
26 fim

```

---

## 2.4 Verificação dos modelos de esteira

Com o intuito de estudar os modelos de déficit de velocidade e de superposição de esteiras, realizou-se dois estudos preliminares para verificação dos modelos. Conforme apresentado na Seção 2.4.1, uma turbina Vestas V80 (JENSEN et al., 2011) é sujeita a dois perfis verticais de escoamento livre e são avaliados as distribuições radial e longitudinal dos déficits de velocidades, comparando os resultados obtidos pelo autor em simulações no FLORIS/NREL (NREL, 2022). Já a Seção 2.4.2 apresenta uma verificação utilizando o modelo de déficit de velocidade da Seção 2.3.1, modelo de turbulência da Seção 2.3.2 e uma comparação dos três modelos de superposição (NIAYIFAR; PORTÉ-AGEL, 2016; GUNN et al., 2016; VOUTSINAS; RADOS; ZERVOS, 1990) disponíveis na plataforma FLORIS/NREL (NREL, 2022), em sua atual versão, para comparação com os resultados em *Large Eddy Simulation - LES* de (PORTE-AGEL; WU; CHEN, 2013) do parque eólico *offshore* de Horns Rev, avaliando a acurácia dos modelos de superposição e definir qual será utilizado na presente pesquisa para os estudos de otimização do *layout*. A Seção 2.4.2 finaliza apresentando uma análise mais detalhada dos níveis de produção do parque eólico de Horns Rev utilizando o modelo de superposição de esteira escolhido.

### 2.4.1 Déficit de velocidade para uma turbina

As Figuras 2.22 e 2.23 apresentam o plano vertical (*plano  $xz$*  - plano de corte vertical situado no centro da turbina ao longo de seu eixo) e o plano horizontal (*plano  $xy$*  - plano de corte horizontal na altura do eixo da turbina,  $z_h$ ), respectivamente, do campo de velocidades da esteira resultante de uma turbina eólica ( $d_0 = 80m, C_T(U = 9m/s) = 0.8, z_h = 70m$ ). Ao longo do eixo  $x$  são extraídos 4 perfis de velocidades (perfil vertical  $u(z)$  na Figura 2.22 e transversal  $u(y)$  na Figura 2.23) nas posições  $x/d_0 = 3, 5, 7$  e  $10$  para comparação com os resultados *Large Eddy Simulation - LES* de Wu e Porte-Agel (2012), Bastankhah e Porte-Agel (2014). As comparações realizadas são conforme o déficit de velocidade imprimido pela turbina em dois escoamentos atmosféricos livres diferentes, com  $z_r = 70m, U(z_r) = 9m/s$  para ambos e  $z_0 = 0.05m$  com  $I = 0.095$  (primeiro regime - Figura 2.24a) e  $z_0 = 0.005m$  com  $I = 0.07$  (segundo regime - Figura 2.24b). As Figuras 2.25 e 2.26 apresentam os perfis verticais dos déficits de velocidades imprimidos

---

**Algoritmo 2:** Pseudo-código para aplicação dos modelos de esteira, turbulência e sobreposição das turbinas ordenadas Montante  $\rightarrow$  Jusante (NREL, 2022)

---

**Entrada:** Todas as informações disponíveis no Algoritmo 1

**Saída:** Campo de velocidades **Campo<sub>veloc</sub>** do parque para a condição do vento  $(\theta, U_\infty(z_{ref.}))$

```

1 início
2   for cada turbina  $i$  Montante  $\rightarrow$  Jusante do
3     /*pegar as coordenadas dos pontos da turbina  $i$  e as velocidades em
4     cada um destes pontos*/
5      $\mathbf{x}_i, \mathbf{y}_i, \mathbf{z}_i =$  retirar_coordenadas( $\mathbf{x}, \mathbf{y}, \mathbf{z}$ );
6      $\mathbf{u}_i =$  retirar_velocidades(Campoveloc;  $\mathbf{x}_i, \mathbf{y}_i, \mathbf{z}_i$ );
7      $u_i =$  média( $\mathbf{u}_i$ ) /*velocidade de incidência na turbina  $i$  é a média
8     das velocidades da distribuição de pontos no rotor da turbina  $i^*$ /
9     /*obter o coeficiente de empuxo da turbina  $i$  através da curva do
10    coeficiente de empuxo,  $C_T(U)$  (ver seção 2.2)*/
11     $C_T^i =$  Turb  $\rightarrow$  curva- $C_T^i(u_i)$ ;
12    /*obter a intensidade de turbulência na turbina  $i^*$ /
13     $I =$  retirar_turbulência(CampoturbIntens);
14    /*pegar características geométricas da turbina  $i^*$ /
15     $z_h^i, d_0^i =$  retira_geometria(Turb)
16    /*calcular o deficit de velocidade imposto pela turbina  $i$  nos pontos
17    ( $\mathbf{x}_j, \mathbf{y}_j, \mathbf{z}_j$ ) das turbinas  $j$  à jusante de  $i$ , segundo modelo descrito na
18    seção 2.3.1*/
19    Deficitveloc = modelo_gaussiano( $\mathbf{x}, \mathbf{y}, \mathbf{z}, C_T^i, I, z_h^i, d_0^i$ );
20    /*calcula a intensidade de turbulência adicionada pela turbina  $i$  nas
21    turbinas  $j$  à jusante, segundo modelo da equação 2.29*/
22     $\Delta I_i =$  modelo_add_turbulência(CampoambTurb,  $\mathbf{x}, d_0^i, C_T^i$ );
23    /*calcula campo de intensidade de turbulência segundo equações
24    2.30 e 2.32*/
25    CampoturbIntens =
26    calcula_campo_turbulencia( $\Delta I, \mathbf{C}ampoambTurb);
27    /*calcula a sobreposição dos déficits de velocidades impostos pela
28    turbina  $i$  nas turbinas  $j$  à jusante segundo modelo de (NIAYIFAR;
29    PORTÉ-AGEL, 2016) da tabela 2.3*/
30    Campoesteira = modelo_superposição(Campoesteira,
31    Deficitveloc  $\times$  Campoveloc.amb);
32    /*atualiza o campo de velocidades como o campo de velocidades
33    ambiente menos o campo de déficits de velocidades da esteira de  $i^*$ /
34    Campoveloc = Campoveloc.amb - Campoesteira
35  end for
36 fim$ 
```

---

pela turbina no perfil de velocidades do escoamento livre nas posições em  $x$ , descritas conforme Figura 2.22.

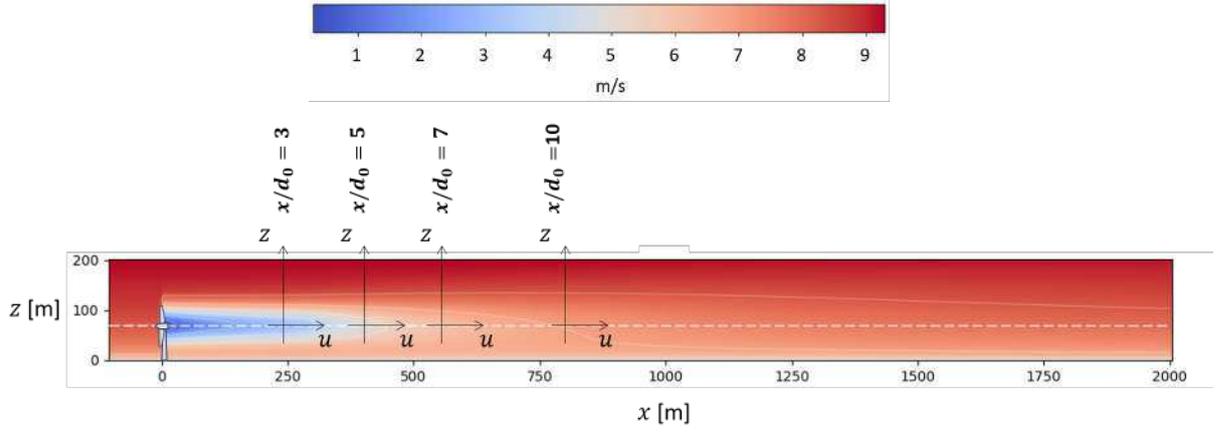


Figura 2.22: Plano  $xz$  - Vista lateral do campo de velocidades em  $y = 0$ .

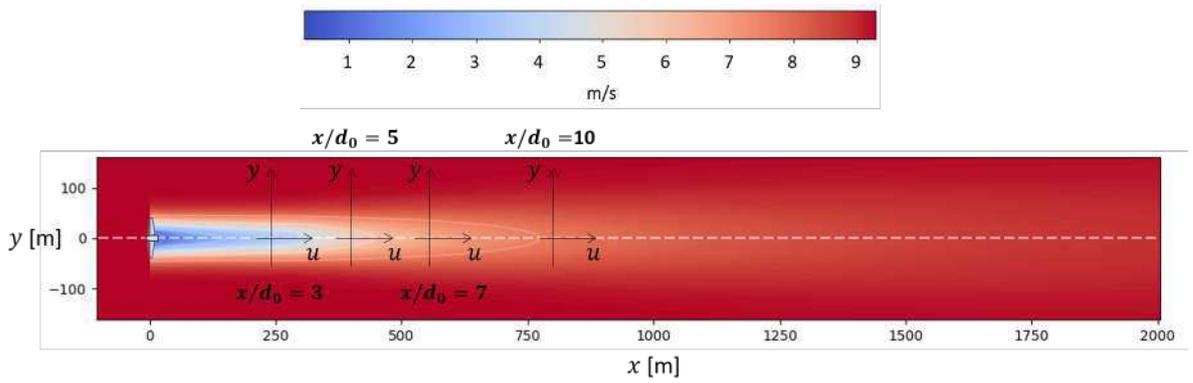


Figura 2.23: Plano  $xy$  - Vista superior do campo de velocidades em  $z = z_h$ .

As Figuras 2.27 e 2.28 mostram o déficit de velocidade máximo normalizado,  $C(x)$ , ao longo de  $x$  para ambos os casos, enquanto as figuras 2.29a e 2.29b apresentam a distribuição transversal, em  $y$ , dos déficits de velocidade em função da largura da esteira,  $r$ , ao longo das 4 posições em  $x$  acima apresentadas. Conforme realizado por Bastankhah e Porte-Agel (2014), normaliza-se a largura da esteira de acordo com a metade de sua largura  $r_{1/2}(x)$ , que também varia ao longo de  $x$ , devido às mudanças em  $\sigma_y$  e  $\sigma_z$ , definida como (BASTANKHAH; PORTE-AGEL, 2014):

$$\frac{\Delta U(r = r_{1/2})}{U_\infty} = \frac{1}{2} \frac{\Delta U_{max}}{U_\infty} = \frac{1}{2} C(x) \quad (2.33)$$

As Figuras 2.29a e 2.29b mostram que os perfis  $\Delta U/\Delta U_{max}$  plotados em função

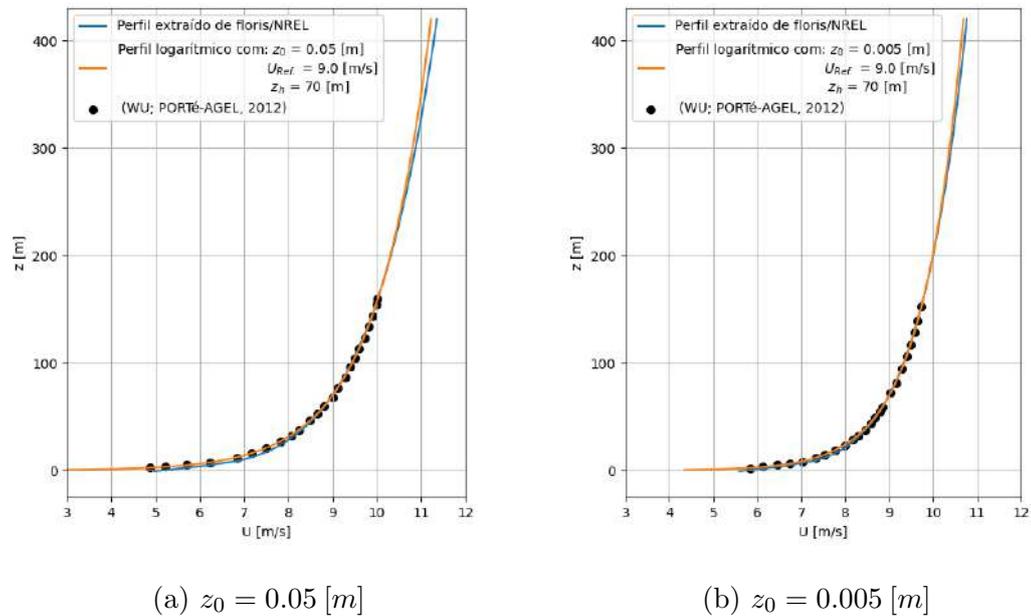


Figura 2.24: Comparação dos perfis verticais de velocidades do escoamento atmosférico livre - Condição de estabilidade Neutra - utilizados no presente trabalho (FLORIS/NREL, perfil logarítmico) com os utilizados por Wu e Porte-Agel (2012).

de  $r_{1/2}(x)$  recaem, aproximadamente, em um mesmo perfil gaussiano, o que tem uma maior variação apenas nas bordas do perfil (extremidades da esteira). Isso significa que é plausível assumir o perfil de déficit de velocidades como um perfil de formato *self-similar gaussian* após uma certa distância à jusante (região da *far-wake*) com  $x/d_0 \geq 3$  (BASTANKHAH; PORTE-AGEL, 2014).

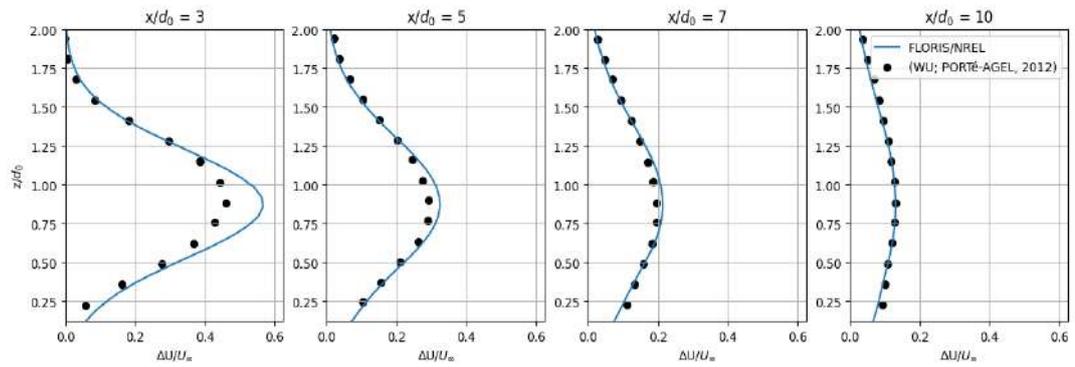


Figura 2.25: Perfis verticais do déficit de velocidades para condição  $z_0 = 0.05m$  e  $I = 0.095$

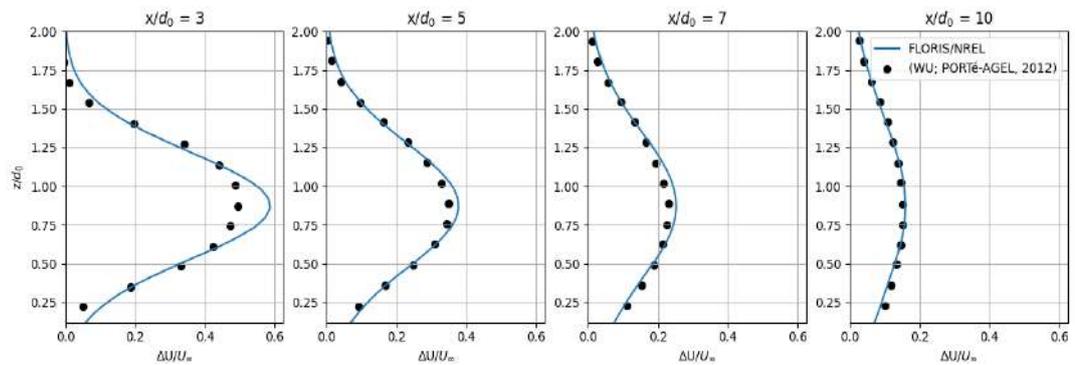


Figura 2.26: Perfis verticais do déficit de velocidades para condição  $z_0 = 0.005m$  e  $I = 0.07$

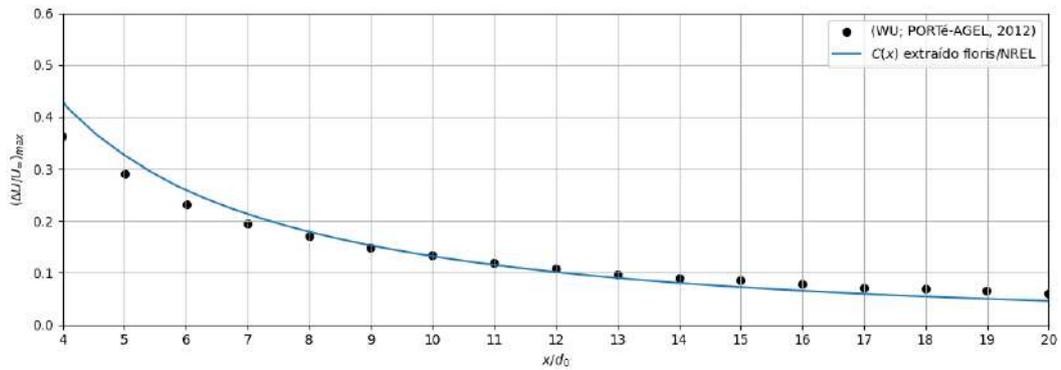


Figura 2.27: Perfil longitudinal do déficit de velocidades máximo normalizado para  $z_0 = 0.05 m$  e  $I = 0.095$

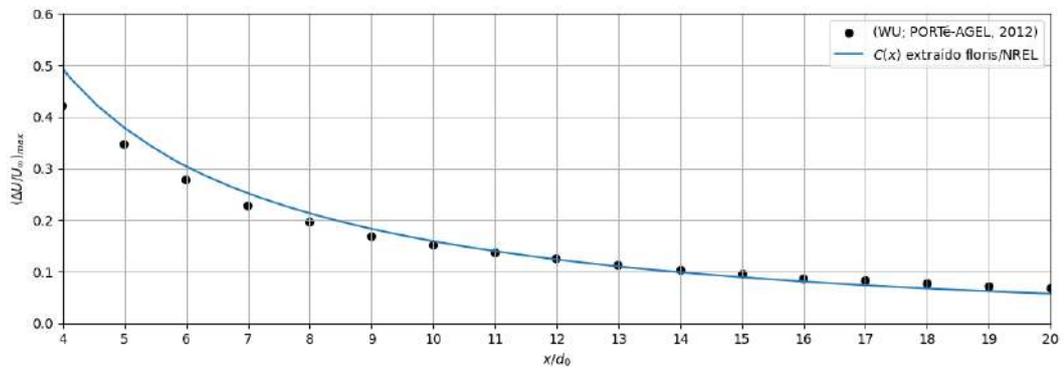
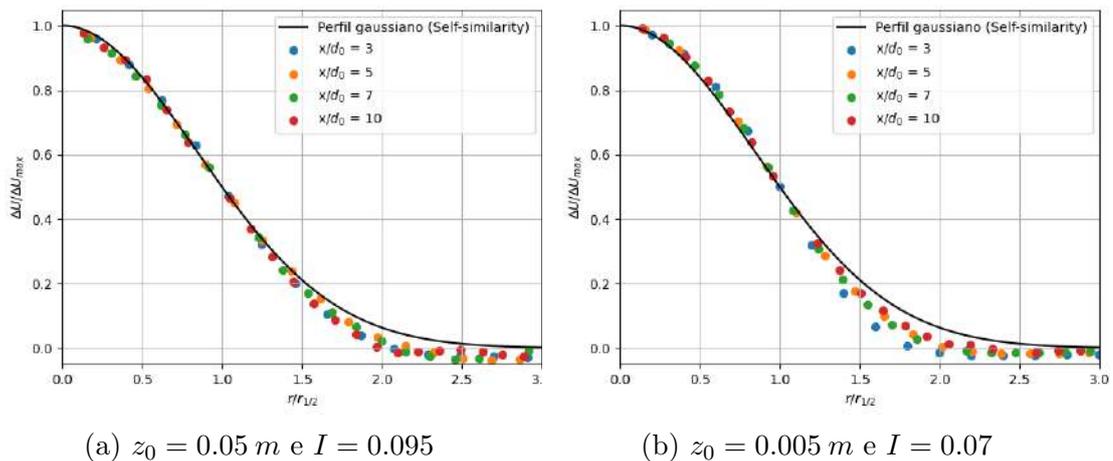


Figura 2.28: Perfil longitudinal do déficit de velocidades máximo normalizado para  $z_0 = 0.005 \text{ m}$  e  $I = 0.07$



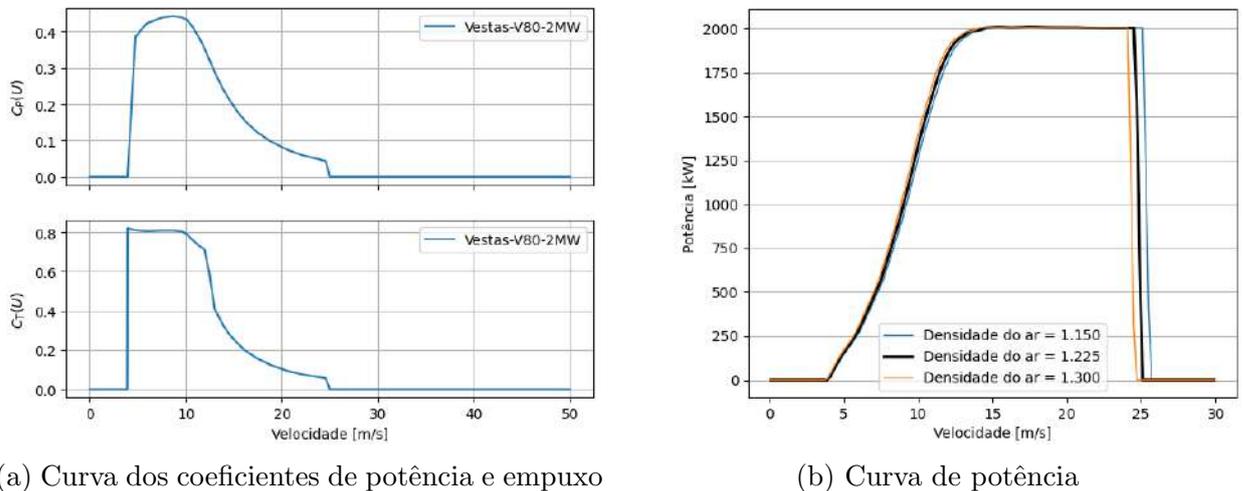
(a)  $z_0 = 0.05 \text{ m}$  e  $I = 0.095$

(b)  $z_0 = 0.005 \text{ m}$  e  $I = 0.07$

Figura 2.29: Perfil do déficit de velocidades normalizado em relação a  $r_{1/2}(x)$  de todas as posições, que recaem no mesmo perfil gaussiano (*gaussian self-similarity* em linha preta) - abordagem de comparação de acordo com (BASTANKHAH; PORTE-AGEL, 2014) - em comparação com os resultados em *LES* (WU; PORTE-AGEL, 2012) (pontos com coloração de acordo com a posição em  $x$ ) também normalizados em relação a  $r_{1/2}(x)$  para as duas condições de escoamento livre avaliadas.

### 2.4.2 Verificação parque eólico Horns Rev

As Figuras 2.30a e 2.30b apresentam as curvas dos coeficientes de potência e empuxo, assim como a curva de potência da turbina Vestas V80 - 2MW com informações retiradas de Jensen et al. (2011). A partir do *layout* do parque de Horns Rev (Figura 2.20a), reproduziu-se o gráfico de potência normalizada do parque eólico da Figura 2.20c. Os resultados são apresentados na Figura 2.31. É possível observar que o modelo de superposição de Niayifar e Porté-Agel (2016) apresentou um melhor desempenho em comparação com os resultados em *LES* e será o modelo de superposição de esteiras considerado nas seguintes análises e na aplicação do problema de otimização de parques eólicos do presente trabalho.



(a) Curva dos coeficientes de potência e empuxo

(b) Curva de potência

Figura 2.30: Turbina Vestas V80 - 2MW (JENSEN et al., 2011)

Por fim, é avaliado os resultados dos modelos de déficit de velocidades (seção 2.3.1), modelo de turbulência (seção 2.3.2) e agora com o modelo de sobreposição de esteira de Niayifar e Porté-Agel (2016), em um comparativo do desempenho do parque eólico de Horns Rev I, comparando com resultados experimentais de campo e resultados numéricos. As Figuras 2.32a, 2.32b e 2.32c apresentam a rotulação de algumas turbinas, agrupadas por linhas  $L$ . Em cada cenário o parque experimenta uma direção do vento diferente, onde os campos de velocidade resultantes da aplicação dos modelos são apresentados nas Figuras 2.33a, 2.33b e 2.33c para cada cenário, respectivamente. Por fim é comparado, nas Figuras 2.34, 2.35 e 2.36, os resultados do acoplamento dos 3 modelos (déficit de velocidades, turbulência e sobreposição de esteiras) utilizados no FLORIS/NREL com

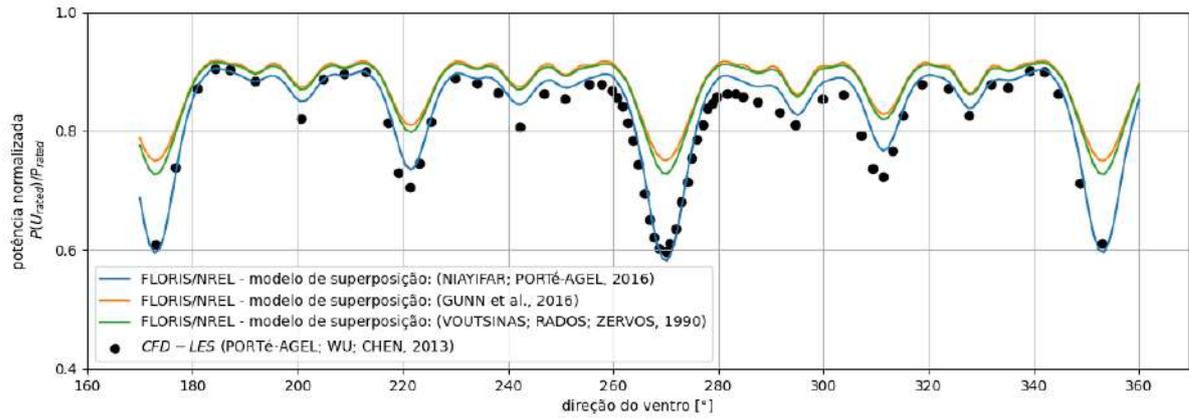
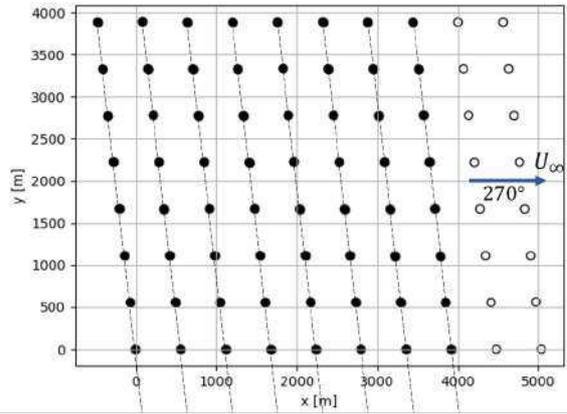
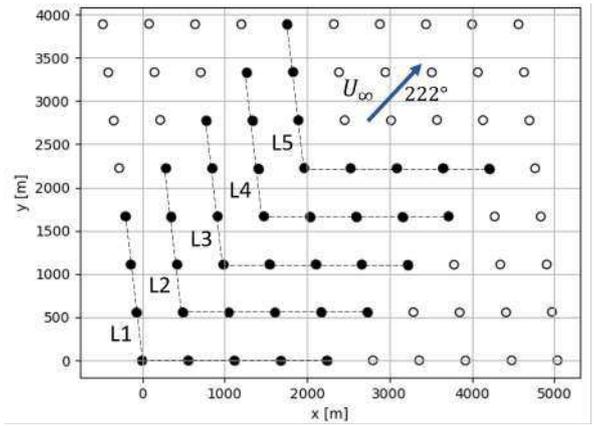


Figura 2.31: Distribuição da potência normalizada de Horns Rev I para diferentes direções de vento. Os resultados dos 3 modelos de superposição de esteiras (NIAYIFAR; PORTÉ-AGEL, 2016; GUNN et al., 2016; VOUTSINAS; RADOS; ZERVOS, 1990) disponíveis na plataforma FLORIS/NREL (NREL, 2022) são comparados com os resultados *LES* de (PORTE-AGEL; WU; CHEN, 2013)

os resultados experimentais de Barthelmie et al. (2009) e numéricos (CFD - RANS k-epsilon) de Naderi, Parvanehmasiha e Torabi (2018) nos valores das potências das linhas de turbinas, normalizadas em relação à primeira linha de cada cenário.

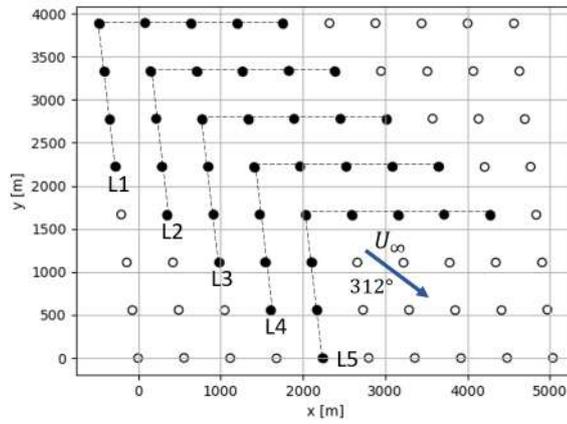


L1 L2 L3 L4 L5 L6 L7 L8



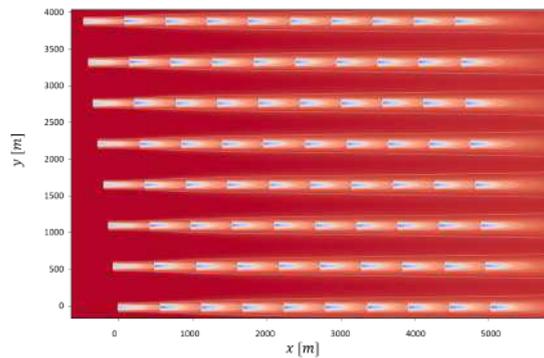
(a) Agrupamento turbinas para  $\theta = 270$

(b) Agrupamento turbinas para  $\theta = 222$

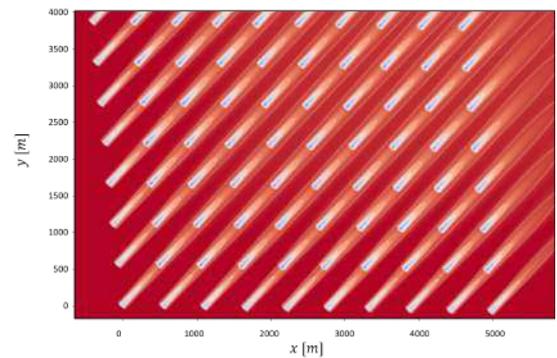


(c) Agrupamento turbinas para  $\theta = 312$

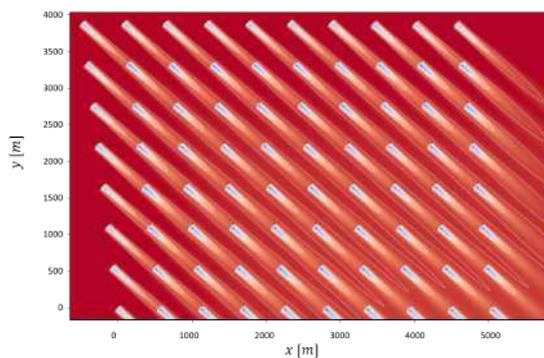
Figura 2.32: Agrupamento das turbinas de Horns Rev I



(a) Campo de velocidades no *plano* -  $xy$  a uma altura  $z = z_h$  com direção do vento  $\theta = 270^\circ$



(b) Campo de velocidades no *plano* -  $xy$  a uma altura  $z = z_h$  com direção do vento  $\theta = 222^\circ$



(c) Campo de velocidades no *plano* -  $xy$  a uma altura  $z = z_h$  com direção do vento  $\theta = 312^\circ$

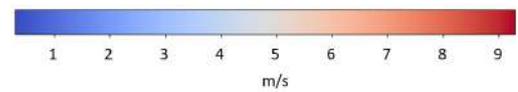


Figura 2.33: Campos de velocidade resultantes dos casos das figuras 2.32a, 2.32b e 2.32c, respectivamente

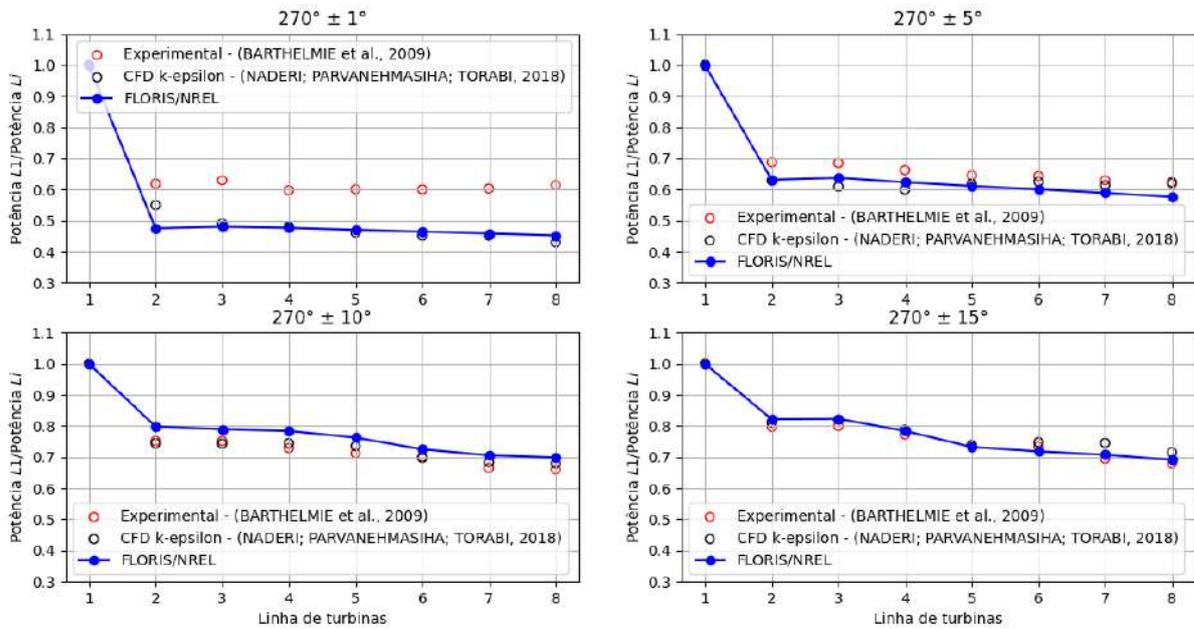


Figura 2.34: Comparação dos resultados de potências normalizadas, conforme agrupamento das turbinas da figura 2.32a, entre os modelos analítico (FLORIS/NREL) e RANS/k-epsilon (NADERI; PARVANEHMASIHA; TORABI, 2018), e os resultados experimentais (BARTHELMIE et al., 2009)

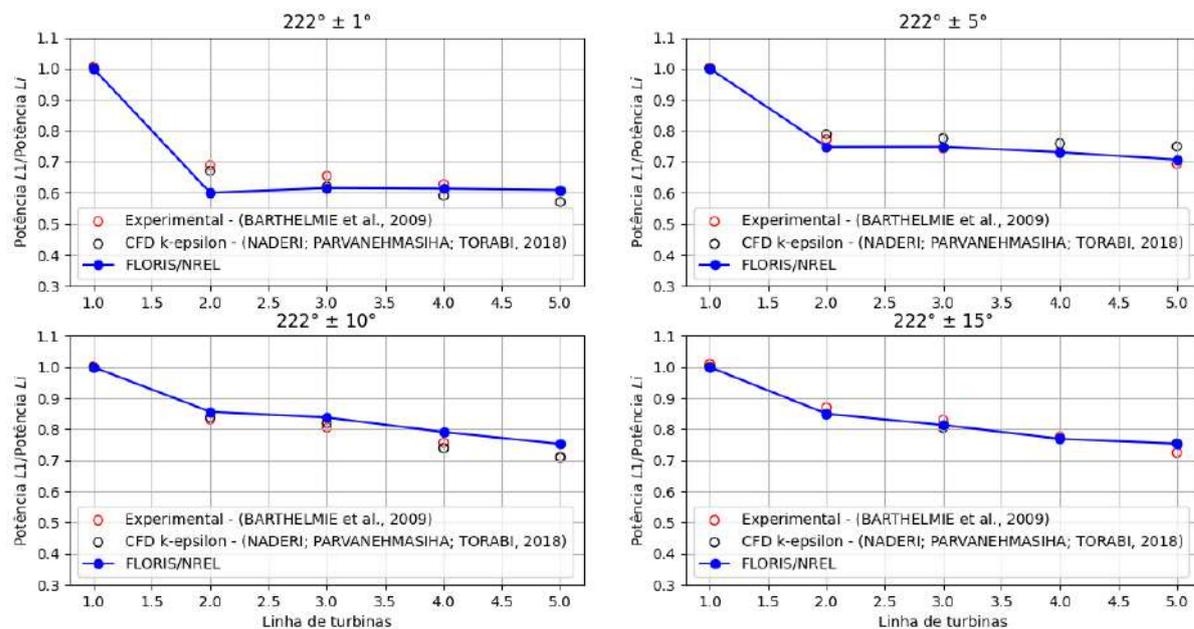


Figura 2.35: Comparação dos resultados de potências normalizadas, conforme agrupamento das turbinas da figura 2.32b, entre os modelos analítico (FLORIS/NREL) e RANS/k-epsilon (NADERI; PARVANEHMASIHA; TORABI, 2018), e os resultados experimentais (BARTHELMIE et al., 2009)

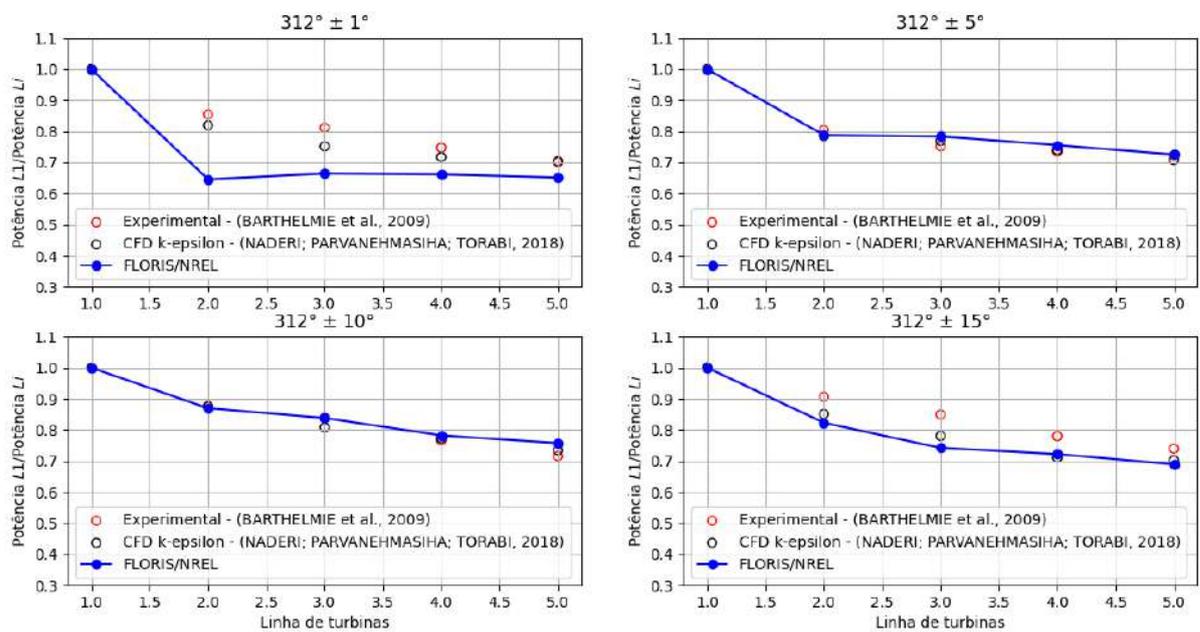


Figura 2.36: Comparação dos resultados de potências normalizadas, conforme agrupamento das turbinas da figura 2.32c, entre os modelos analítico (FLORIS/NREL) e RANS/k-epsilon (NADERI; PARVANEHMASIHA; TORABI, 2018), e os resultados experimentais (BARTHELMIE et al., 2009)

## 3 Indicadores dos parques eólicos

Neste capítulo, são avaliados critérios de desempenho do parque e critérios econômicos, que serão explorados via técnicas de otimização, a serem discutidas no Capítulo 4.

### 3.1 Avaliação de desempenho do parque eólico

*Micrositing* é uma técnica de avaliação de recursos utilizada para determinar a posição exata de uma ou mais turbinas eólicas em uma determinada região para otimizar a produção de energia (MANWELL; MCGOWAN; ROGERS, 2010). Um dos objetivos do *micrositing* é alocar as turbinas eólicas no parque eólico a fim obter o maior retorno financeiro, por meio do aumento da potência total de saída do parque eólico,  $P_{total}$  (CHEN et al., 2013; ABDULRAHMAN; WOOD, 2017; SUN; YANG; GAO, 2019), ou da produção de anual de energia (GONZALEZ-RODRIGUEZ et al., 2021; VASEL-BE-HAGH; ARCHER, 2017) ou do fator de capacidade ( $FC$ ) (RAHBARI et al., 2014; ABDULRAHMAN; WOOD, 2017).

Para o *micrositing* ser realizado de forma eficaz, o mesmo depende de uma combinação de informações detalhadas dos recursos eólicos para o local específico, conforme discutido na Seção 2.1, e também do uso de modelos de esteira para prever o campo detalhado do escoamento no parque eólico, incluindo efeitos de esteira das turbinas, apresentados na Seção 2.3. As saídas de cada um destes modelos é combinada em outro modelo que dá uma previsão da produção de energia do parque eólico ou outros indicadores de desempenho. As subseções seguintes explicam com mais detalhes as avaliações de desempenho do parque eólico adotadas neste trabalho.

#### 3.1.1 Produção anual de energia

A produção anual de energia é um cálculo cumulativo da produção de energia das turbinas com base em uma dada distribuição anual de densidade de probabilidades da velocidade e direção do vento. O valor da  $PAE$  pode ser ajustado para fatores como o coeficiente

de potência do rotor, perdas de conversão mecânica e elétrica, perdas por sujeira das pás, perdas na rede e disponibilidade de máquinas (FINGERSH; HAND; LAXSON, 2006).

De acordo com Gonzalez-Rodriguez et al. (2021), a energia anual produzida por um parque eólico pode ser obtida somando a energia,  $E_i$ , produzida por cada uma das  $N_t$  turbinas eólicas do parque, para cada direção do vento  $\theta$  e para cada velocidade do vento  $U$  que ocorre ao longo do ano. Logo, a produção anual de energia pode ser expressa como:

$$PAE = \sum_{i=1}^{N_t} E_i = T_{ano} \sum_{i=1}^{N_t} \int_{u_{cut-in}}^{u_{cut-out}} \int_{0^\circ}^{360^\circ} P_{c_i}(\nu_i(u, \theta, \mathbf{x}_i)) p(u, \theta) d\theta du, \quad (3.1)$$

onde  $T_{ano}$  é o tempo total de operação anual do parque eólico;  $N_t$  é o número de turbinas instaladas;  $u_{cut-in}$  e  $u_{cut-out}$  são as velocidades de acionamento (*cut-in*) e desacionamento (*cut-out*) das turbinas, respectivamente;  $P_{c_i}$  é a curva de potência da turbina  $i$  (ver Equação (2.18));  $\mathbf{x}_i$  é o vetor posição da turbina  $i$ ;  $\nu_i$  a velocidade de incidência no rotor da turbina  $i$ , considerando os efeitos de esteiras (a avaliação de  $\nu_i$  para cada condição do vento  $(u, \theta)$  é realizada conforme os modelos de esteira da Seção 2.3);  $u$  e  $\theta$  são a velocidade livre do vento (a uma altura de referência  $H$ ) e a direção do vento, respectivamente. Além disso,  $p(u, \theta)$  é a função densidade probabilidade conjunta de ocorrência de cada par  $(u, \theta)$  ao longo do ano, conforme discutido na Seção 2.1.1.

É possível aproximar numericamente a Equação (3.1), de maneira similar ao realizado por Feng e Shen (2015b):

$$PAE = T_{ano} \sum_{i=1}^{N_t} \sum_{j=1}^{N_{wd}} \sum_{k=1}^{N_{ws}} P_{c_i}(\nu_i(u_k, \theta_j, \mathbf{x}_i)) p(u_j, \theta_k) \Delta\theta \Delta U. \quad (3.2)$$

### 3.1.2 Fator de capacidade

Outra forma de medir o desempenho do parque eólico é através de seu fator de capacidade, que pode ser avaliado como (TAO et al., 2020):

$$FC = \frac{PAE}{T_{ano} \sum_{i=1}^{N_t} P_{Rated}^i} \times 100, \quad (3.3)$$

onde  $P_{Rated}^i$  é a potência nominal da turbina  $i$ . O denominador da Equação (3.3) se refere

à capacidade total de produção do parque eólico, i.e., assumindo que ele opera com cada uma de suas turbinas com potência nominal ao longo de todo ano.

### 3.1.3 Eficiência do layout

A terceira medida de avaliação do desempenho do parque eólico é através da eficiência do *layout* do parque,  $\eta$ , considerando a razão entre os efeitos de esteira (numerador da Equação (3.4)) e regime de operação sem efeitos de esteira (denominador da Equação (3.4)); ou seja, cada turbina eólica operando em condições livres do perfil de vento vertical (ver Seção 2.1.2). É importante destacar que, ao contrário do Fator de capacidade, que considera as turbinas operando em regime de potência nominal ( $P_{Rated}$ ), tais velocidades livres podem ser menores do que a velocidade que leva as turbinas a operarem em sua potência nominal, o que dependerá do regime anual de ventos, avaliado segundo função densidade de probabilidades. Desta forma,  $\eta$  quantifica a eficiência do *layout* do parque em termos dos impactos de esteira nas turbinas, apenas. De acordo com Tao et al. (2020), a seguinte equação é utilizada para acessar a eficiência do layout do parque eólico:

$$\eta = \frac{PAE}{T_{ano} \sum_{i=1}^{N_t} \int_{u_{cut-in}}^{u_{cut-out}} \int_{0^\circ}^{360^\circ} P_{c_i}(u_{fst}) p(u, \theta) d\theta du} \times 100. \quad (3.4)$$

onde  $u_{fst}$  é a velocidade do escoamento livre (perfil vertical de velocidades logaritmico) avaliado na altura do eixo da turbina. A eficiência do layout do parque eólico,  $\eta$ , mede a razão entre as condições operacionais do parque eólico contabilizando os efeitos de esteira e as condições operacionais não considerando os efeitos de esteira. De maneira similar ao realizado na equação 3.2, a equação 3.4 pode ser resolvida numericamente de acordo com a equação 3.5:

$$\eta = \frac{PAE}{T_{ano} \sum_{i=1}^{N_t} \sum_{j=1}^{N_{wd}} \sum_{k=1}^{N_{ws}} P_{c_i}(u_{fst}^k) p(u_k, \theta_j) \Delta\theta \Delta U} \times 100\%. \quad (3.5)$$

## 3.2 Economia e modelos de custos

Como discutido anteriormente e mostrado na Figura 2.9, as turbinas eólicas consistem de uma torre e uma nacela, que é montada no topo da torre. A nacela contém vários com-

ponentes, i.e., rotor da turbina, sistema de transmissão (caixa de engrenagens), gerador, cabos de força, transformador e sua conexão à rede. Estes componentes contribuem, cada um com sua função específica, no processo de conversão da energia cinética dos ventos em energia elétrica (HANSEN, 2017a).

Todos estes componentes agregam valor ao desempenho da turbina eólica, sob algum custo, dependendo de algumas características da turbina. Fingersh, Hand e Laxson (2006) desenvolveram um modelo de custo para avaliar o custo inicial de investimento nos componentes/subsistemas da turbina eólica, de forma que as estimativas de custo sejam realizadas em função de algumas características chave da turbina, como: potência nominal da turbina, diâmetro do rotor, altura do eixo (torre) e outros descritores chave da turbina. Tais funções estimatidas de custos foram desenvolvidas para os principais componentes e subsistemas. Estes modelos se destinam a fornecer projeções de custos confiáveis para turbinas de diferentes escalas e tamanhos, devido ao fato de que, ao avaliar qualquer mudança no projeto de uma turbina e/ou parque eólico, ou durante o projeto do parque eólico, é fundamental que o projetista avalie simultaneamente o impacto das escolhas de projeto no custo e desempenho do sistema. O projetista deve considerar vários elementos deste processo: custo inicial do capital (CIC), *balance of station* (BOS - que diz respeito a infraestrutura do empreendimento para além das turbinas), operações e manutenção (O&M), custo de energia nivelado (LCOE) e produção anual de energia (PAE). À medida que as turbinas eólicas se tornam mais sofisticadas e aumentam em tamanho, o impacto de projeto sobre esses elementos nem sempre é claro. Por exemplo, o aumento da PAE pode aumentar o CIC. Se uma etapa não equilibrar a outra, as melhorias propostas podem, na verdade, ter um impacto geral negativo.

O modelo de Fingersh, Hand e Laxson (2006) é uma ferramenta baseada em equações parametrizadas que utiliza relações de escala simples para projetar o custo de componentes e subsistemas de turbinas eólicas para diferentes tamanhos e configurações dos componentes. O modelo não lida com todas as configurações potenciais de turbinas eólicas, mas concentra-se nas configurações que são mais comuns na indústria e comércio. Esta configuração concentra-se nas turbinas eólicas de três pás, do tipo *upwind*, de sistema de controle *pitch-controlled* e de velocidade variável.

### 3.2.1 Custo inicial do capital

Os sistemas das turbinas eólicas podem ser divididos em quatro subsistemas principais, o sistema mecânico (como pá, caixa de engrenagens, etc.), sistema elétrico (incluindo gerador, conversor de energia e conexão elétrica), sistema de controle (sistema de segurança, controle de guinada *yaw control*, controle de torque e controle de passo (*pitch control*) e sistema auxiliar, como equipamento de resfriamento hidráulico, cubo e torre. Considerando turbinas eólicas de eixo horizontal de três pás, todo o custo inicial do capital para investimento nos sistemas da turbina,  $CIC_{WT}$ , é dado por (LUO et al., 2019; FINGERSH; HAND; LAXSON, 2006):

$$\begin{aligned}
CIC_{WT} = & 209.526P_r + 16.45P_r^{1.249} + 206.69R + 11.9174(2R)^{1.953} - 0.01069(2R)^{2.5} \\
& + 11.4354R^{2.5} + 2.00617R^{2.53} + 0.48017(2R)^{2.6578} + 0.01(2R)^{2.887} \\
& + 0.0678(2R)^{2.964} + 1.67458R^3 + 0.00432(2R)^{3.5} + 0.59595\pi R^2 z_h + 73990.5,
\end{aligned} \tag{3.6}$$

sendo o valor de  $CIC_{WT}$  determinado em função das características da turbina eólica correspondente à potência nominal  $P_r$ , o raio do rotor  $R = d_0/2$  e a altura do eixo (torre),  $z_h$ , i.e.,  $CIC_{WT} = CIC_{WT}(P_r, R, z_h)$ . É importante destacar que na construção do modelo de custo de Fingersh, Hand e Laxson (2006), os dados de custo dos componentes das turbinas foram coletados em diferentes anos. Para fins de consistência, todos os dados de custo foram convertidos para dólares de 2002 antes do desenvolvimento das equações que modelam o custo em função das características das turbinas. Dessa forma,  $CIC_{WT}$  é dado em 2002 US \$ e será convertido para 2022 US \$ no presente trabalho, assim como outras fontes de custos devido aos outros fatores para além das turbinas, a serem discutidas posteriormente. A fim de avaliar o custo de capital inicial de todo o parque eólico, devido às turbinas eólicas instaladas, que no presente trabalho podem ser de diferentes tipos, a seguinte equação será utilizada:

$$CIC_{WT_{WF}} = \sum_{i=1}^{N_t} CIC_{WT_i}(P_{r_i}, R_i, z_{h_i}) \tag{3.7}$$

O custo inicial do capital devido às parcelas de infraestrutura, para além das

turbinas eólicas,  $CIC_{BOS_{WT}}$ , envolve o custo de infraestrutura e engenharia *offshore*, e os modelos matemáticos detalhados para sua avaliação de custos são, de acordo com Yilmazlar et al. (2022), dados por:

$$CIC_{BOS_{WT}} = c_{found} + c_{instal} + c_{civil} + c_{eng} + c_{port} + c_{scour}, \quad (3.8)$$

onde  $c_{found}$  significa o custo devido às estruturas de fundação *offshore* para instalação das turbinas,  $c_{instal}$  os custos de instalação,  $c_{civil}$  o custo devido contingente civil,  $c_{eng}$  os custos de engenharia,  $c_{port}$  os custos portuários e equipamentos, e  $c_{scour}$  os custos devido à *scour protection*, respectivamente.

A parcela de custo  $c_{found}$  é avaliada de acordo com Yilmazlar et al. (2022) e Rosenauer (2014), dado em 2014 1000US \$, conforme:

$$c_{found} = 0.345e^{(0.182WD)} P_r, \quad (3.9)$$

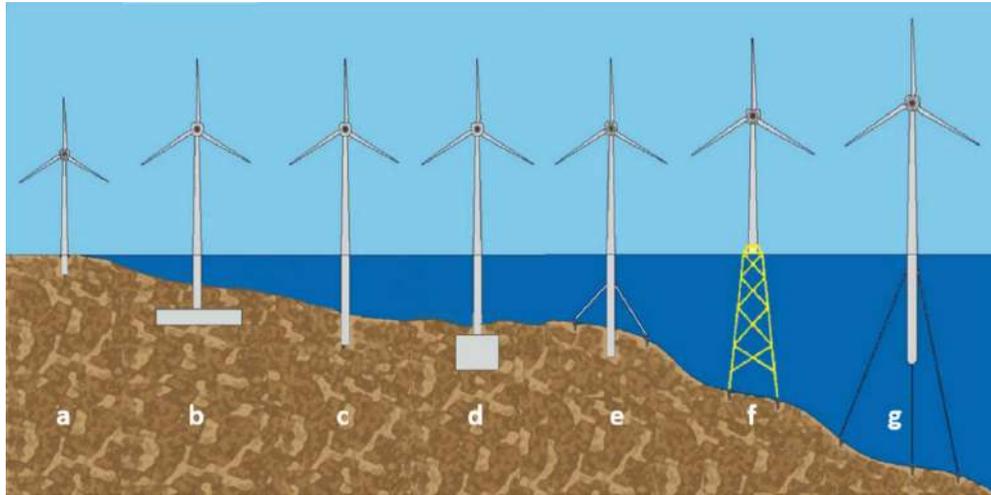


Figura 3.1: Esquemático de algumas estruturas de fundação para instalação de turbinas eólicas *offshore* (WANG et al., 2018a).

onde  $WD$  é a profundidade de água, em relação à superfície. A Figura 3.1 mostra um esquemático dos tipos de fundações para turbinas eólicas offshore, retirado de (WANG et al., 2018a). A Equação (3.9) é aplicada para fundações fixas (YILMAZLAR et al., 2022) (i.e., estruturas  $a$  a  $f$  da Figura 3.1). Para turbinas eólicas *offshore*, uma estimativa adequada do custo de instalação,  $c_{instal}$ , dado em 2010 1000US \$, é considerado conforme Yilmazlar et al. (2022) e Moreno (2019):

$$c_{instal} = 3.4(z_h + 50). \quad (3.10)$$

O custo de engenharia,  $c_{eng}$ , e de contingente civil,  $c_{civil}$ , dados em 2003 1000US \$, podem ser estimados conforme (YILMAZLAR et al., 2022):

$$c_{eng} = 0.037P_r, \quad (3.11)$$

$$c_{civil} = 60. \quad (3.12)$$

Por fim,  $c_{port}$  e  $c_{scour}$  podem ser estimados seguindo Yilmazlar et al. (2022), Fingersh, Hand e Laxson (2006):

$$c_{port} = 0.02P_r \quad (3.13)$$

$$c_{scour} = 0.055P_r. \quad (3.14)$$

Antes de se calcular  $CIC_{BOS_{WF}}$  com a Equação (3.8), todos os termos de contribuição têm de ser normalizados para a mesma moeda e reajustados para 2022 US \$, conforme descrito em Fingersh, Hand e Laxson (2006). De maneira similar ao realizado com  $CIC_{WT_{WF}}$ ,  $CIC_{BOS_{WF}}$  (custo inicial do capital de infraestrutura de todo o parque eólico) é avaliado como uma função das potências nominais das turbinas,  $P_r$ , da profundidade de água  $WD$  de instalação de cada turbina e a altura do eixo (torre) das turbinas  $z_h$ , de forma que o custo total das parcelas de infraestrutura do parque  $ICC_{BOS_{WF}}$  seja avaliado em função da contribuição de cada turbina, individualmente:

$$CIC_{BOS_{WF}} = \sum_{i=1}^{N_t} ICC_{BOS_{WT}^i}(P_{r_i}, WD_i, z_{h_i}) \quad (3.15)$$

Além das parcelas  $ICC_{WT_{WF}}$  e  $ICC_{BOS_{WF}}$ , o custo inicial de capital tem o custo das instalações elétricas do parque eólico,  $c_{elect}$ , o qual consiste da malha de cabos de conexão entre as turbinas no interior do parque e os cabos de transmissão para as subestações das redes de distribuição. Para os parques eólicos offshore, também deve ser incluído o

custo de cabeamento entre a subestação offshore e a em terra. Dessa forma, Yilmazlar et al. (2022) considera  $c_{elect}$  como:

$$c_{elect} = c_{elect_{install}} + c_{elect_{cabling}} + c_{elect_{transmiss}}, \quad (3.16)$$

onde  $c_{elect_{install}}$ ,  $c_{elect_{cabling}}$  e  $c_{elect_{transmiss}}$  são, respectivamente, o custo de instalações elétricas, custo dos cabos de interconexão das turbinas no parque e o custo dos cabos de transmissão para subestação em terra. Fingersh, Hand e Laxson (2006) sugere a seguinte estimativa do custo da interface elétrica para uma única turbina, em 2003 1000US \$:

$$c_{elec.interf} = 0.26P_r. \quad (3.17)$$

Para se contabilizar a instalação elétrica por parte de todas as turbinas eólicas do parque,  $c_{elect_{install}}$ , utilizou-se a expressão de Fingersh, Hand e Laxson (2006) com uma pequena alteração ( $c_{elec.interf}$  variando conforme  $P_r$  do modelo de cada turbina  $i$ ), conforme equação 3.18. Esta alteração se deu devido ao escopo do presente trabalho lidar com parques eólicos contendo mais de um modelo diferente de aerogerador.

$$c_{elect_{install}} = 0.47 \sum_{i=1}^{N_t} c_{elec.interf_i} \quad (3.18)$$

O custo dos cabos de interconexão das turbinas,  $c_{elect_{cabling}}$ , é avaliado de acordo com o comprimento total dos cabos,  $L_{cabling}$ , necessário para conectar todas as turbinas e o custo do cabo por unidade de comprimento  $c_{cable}$ , conforme apresentado na equação 3.19. A Figura 3.2 apresenta o layout de instalação das turbinas do parque eólico *offshore* de Thanet (Inglaterra) (Vattenfall group, 2021). A disposição das turbinas, gerada pela etapa de *micrositing* (ver Seção 3.1), e a sua interconexão por meio dos cabos afeta o comprimento total dos cabos  $L_{cabling}$  e, conseqüentemente, a parcela de custos  $c_{elect_{cabling}}$ .

$$c_{elect_{cabling}} = L_{cabling}c_{cable}. \quad (3.19)$$

O custo do cabo por unidade de comprimento, dado em 2016 1000€, é determinado de acordo com Gonzalez-Rodriguez (2017), conforme equação 3.20:

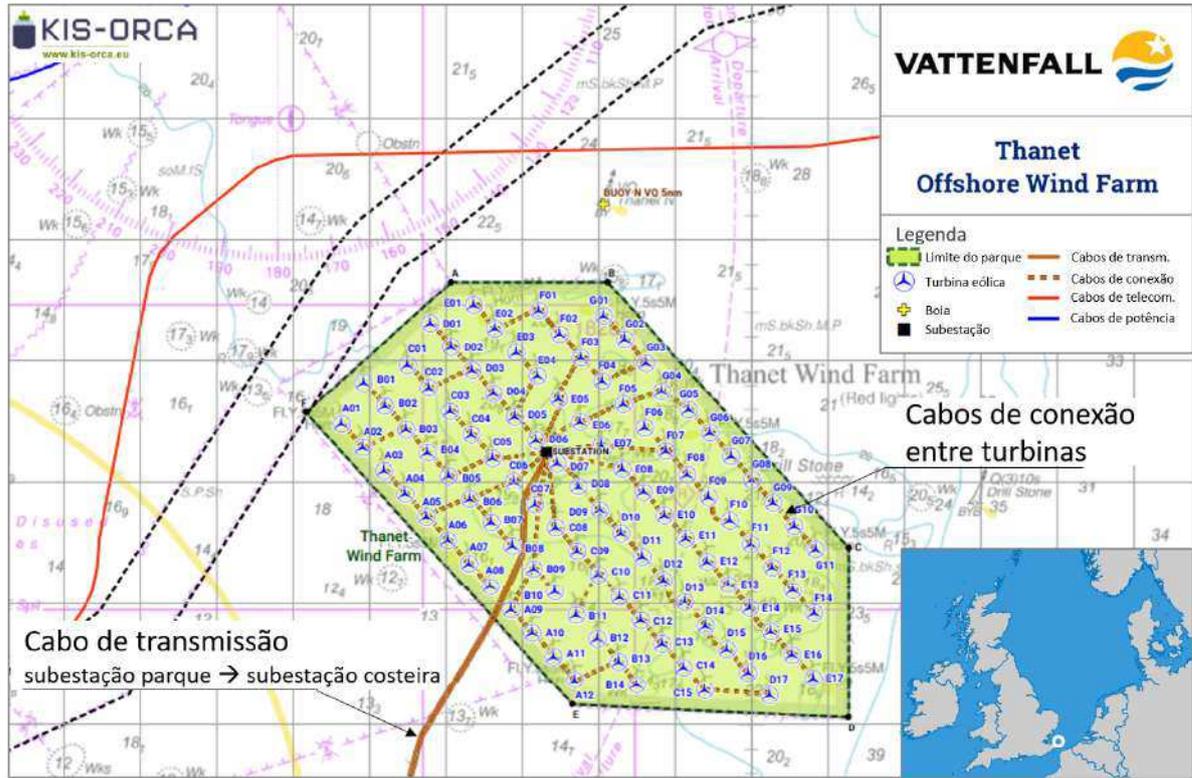


Figura 3.2: Esquema de instalação dos cabos elétricos de interconexão entre as turbinas eólicas do parque offshore de Thanet (na Inglaterra). Adaptado de Vattenfall group (2021).

$$c_{cable} = 4.26 \times 10^{-4} \times A + 2.324 \times 10^{-1}, \quad (3.20)$$

onde  $A$  é a área da seção transversal do cabo, considerada como um valor médio de  $A = 260 \text{ mm}^2$  dentre os valores apresentados por Gonzalez-Rodriguez (2017).

O comprimento total dos cabos,  $L_{cabling}$ , depende muito do layout das turbinas eólicas dentro do parque eólico. No presente trabalho, ele é calculado de acordo com a *minimum-spanning tree*, i.e., um subconjunto de um grafo conectado, onde todos os vértices estão conectados, ou seja, pode-se atravessar para qualquer vértice a partir de um determinado vértice com ou sem vértices intermediários. Além disso, o *minimum-spanning tree* não deve ter nenhum ciclo dentro dele. Assim, pode-se dizer que se houver  $N$  vértices em um grafo conectado, então o número de conexões que o *minimum-spanning tree* pode ter é  $N - 1$  (CORMEN et al., 2012). Considerando tais conexões entre os vértices do grafo conectado como todos os cabos de conexão possíveis entre as turbinas (ligando uma determinada turbina eólica a todas as outras), que juntos conectam todos os vértices

(turbinas eólicas), então minimizar a soma total dos pesos destas conexões (comprimento do cabo) é o objetivo do *minimum-spanning tree* (CORMEN et al., 2012). Este processo é realizado usando o algoritmo de Kruskal (KRUSKAL, 1956). O grafo resultante representa as turbinas eólicas conectadas entre si e a soma dos pesos das conexões representa o comprimento total de cabos de conexão do parque eólico  $L_{cabling}$ , o que será o mínimo (KRUSKAL, 1956), para o dado layout do parque. É importante considerar que esta abordagem não visa alocar a posição da subestação no parque eólico, mas apenas o grafo que representa o comprimento mínimo dos cabos para conectar todas as turbinas, dado o layout do parque.

O processo de funcionamento do algoritmo Kruskal segue os três passos seguintes:

i) Ordenar todas as possíveis conexões em ordem ascendente de seu peso (ou seja, o comprimento do cabo necessário para conexão). ii) Escolha a menor. Verifique se ela forma um ciclo com a *minimum-spanning tree* formada até o momento. Se o ciclo não for formado, inclua esta conexão. Caso contrário, descarte-a. iii) Repita o passo ii) até que haja  $N - 1$  bordas na *minimum-spanning tree* (KRUSKAL, 1956). A Figura 3.3 apresenta um exemplo do processo de construção do *minimum-spanning tree* realizado pelo algoritmo de Kruskal para o cálculo do comprimento total dos cabos  $L_{cabling}$ .

Finalmente, o custo devido à transmissão entre as subestações *offshore* e *onshore*,  $C_{electtransmiss}$ , dado em 2015 1000US \$, é também avaliado conforme Yilmazlar et al. (2022) usando a seguinte equação:

$$C_{electtransmiss} = 0.094 \times (0.0116d_{shore} + 0.5363) WindFarmP_{Rated}, \quad (3.21)$$

onde  $d_{shore}$  é a distância entre as subestações elétricas *offshore* e *onshore* em km. A Figura 3.2 também mostra o cabo de transmissão que liga a subestação do parque eólico *offshore* à subestação elétrica em terra.

Finalmente, o custo inicial do capital do parque eólico  $CIC_{WF}$  é avaliado como a soma do custo de capital inicial de todo o parque eólico, devido às turbinas eólicas instaladas  $CIC_{WT_{WF}}$ , o custo de infraestrutura (*base of station*) do parque eólico  $CIC_{BOS_{WF}}$  e a instalação elétrica do parque eólico  $c_{elect}$ , isto é:

$$CIC_{WF} = CIC_{WT_{WF}} + CIC_{BOS_{WF}} + c_{elect}. \quad (3.22)$$

### 3.2.2 Gastos anuais de operação

As despesas operacionais anuais (*AOE - Annual Operating Expenses*) incluem o custo de locação da terra ou região marítima (ou seja, as taxas de concessão ou locação cobradas para a instalação das turbinas na região), o custo de operação e manutenção, e o custo de descomissionamento do empreendimento. Como dito na Seção 3.1.1, o parque eólico produzirá um certo nível de energia elétrica, mas sob um certo custo anual, que é modelado pelas despesas operacionais anuais (YILMAZLAR et al., 2022):

$$AOE = \frac{LEASE + \frac{1}{\eta_{elec}} (DECOM + OM)}{PAE}, \quad (3.23)$$

onde *LEASE* é o custo da concessão da terra (ou do mar) para toda a região do parque, que é avaliado em função da *PAE*,  $LEASE = 0.00108PAE$ ;  $\eta_{elec}$  é a eficiência elétrica das instalações elétricas de todo o parque, que no presente trabalho é considerada como 1 (i.e., 100%); *OM* o custo de operação e manutenção do parque eólico e *DECOM* o custo de descomissionamento.

A parcela devido à operação e manutenção (*OM*) é expressada em unidades de \$/kWh. O custo *OM* normalmente inclui: mão-de-obra, peças e suprimentos para manutenção programada de turbinas; peças e suprimentos para manutenção não programada de turbinas; peças e suprimentos para manutenção de equipamentos e instalações e mão-de-obra para administração e suporte (FINGERSH; HAND; LAXSON, 2006).

O custo anual de operação e manutenção do parque eólico *OM*, dado em 2002 1000US \$, pode ser estimado, após o tratamento relatado em Fingersh, Hand e Laxson (2006), como função da produção anual de energia do parque, *PAE*, em MWh, para parques eólicos de estruturas de fixação fixas das turbinas (ver Figura 3.1), conforme a seguinte equação:

$$OM = 0.02PAE. \quad (3.24)$$

Para parques offshore com estruturas de fixação fixa das turbinas, seguindo a abordagem de Moreno (2019), *DECOM* é estimado, em 2010 1000US \$, como uma função do custo de instalação de cada uma das turbinas, conforme mostra a equação a seguir:

$$DECOM = 0.91 \sum_{i=1}^{N_t} c_{instal_i}. \quad (3.25)$$

### 3.2.3 Custo nivelado de energia

O custo nivelado de energia, que é comumente usado para avaliar a viabilidade econômica de parques eólicos, é calculado com base na vida útil, levando em conta a variação no tempo do valor monetário. O *LCOE*, que representa o custo por unidade de energia produzida (ou seja, US \$/MWh), permite uma comparação direta entre projetos considerando os tamanhos e a capacidade distintos dos parques eólicos. A formulação matemática do *LCOE* é dada por Fingersh, Hand e Laxson (2006):

$$LCOE = \frac{(FCR \times CIC_{WF})}{PAE} + AOE, \quad (3.26)$$

onde *FCR* é a taxa de encargos fixa (constante \$/ano). A taxa de encargos fixos é o montante anual por dólar do custo de capital inicial necessário para cobrir o custo de capital, um retorno sobre a dívida e o patrimônio e vários outros encargos fixos. Esta taxa é imputada a partir de um projeto hipotético, modelada conforme Fingersh, Hand e Laxson (2006). Para o modelo básico atual, o *FCR* inclui o financiamento de construção, taxas de financiamento, retorno sobre dívida e patrimônio, depreciação, imposto de renda, imposto sobre propriedade e seguro, e é fixado em 0.1158 por ano (FINGERSH; HAND; LAXSON, 2006).

### 3.2.4 Custo de energia

Um dos objetivos mais utilizados para a otimização do layout do parque eólico é minimizar o custo da energia, *COE*, que representa o custo necessário por unidade de energia produzida (FENG; SHEN, 2015b). Em alguns problemas de otimização, a *PAE* pode

não ser um objetivo adequado, pois não pondera o custo adicional ou complexidade necessária para obter os ganhos em  $PAE$  (STANLEY et al., 2021). Em uma situação como esta, pode ser mais apropriado realizar uma otimização multiobjetivo ou incluir tanto  $PAE$  quanto o custo,  $CIC_{WF}$ , em um único objetivo (STANLEY et al., 2021), sendo esta última abordagem a que define a relação de custo da energia, como mostrado pela expressão a seguir:

$$COE = \frac{CIC_{WF}}{PAE}. \quad (3.27)$$

É mostrado que um parque eólico, otimizado para minimizar o  $COE$ , tenha menos turbinas do que um otimizado para maximizar a  $PAE$ , em problemas de otimização onde o número de turbinas eólicas instaladas é uma das variáveis de decisão (STANLEY et al., 2021). As questões de otimização são o tópico principal do capítulo seguinte. Este objetivo (ou seja, minimizar  $COE$ ) considera fortemente os custos adicionais da adição de uma turbina ao parque eólico. As turbinas extras só são benéficas se os fatores econômicos, do ponto de vista de custos, superarem as perdas decorrentes da interferência adicional da esteira que é introduzida pela turbina extra (STANLEY et al., 2021).

Como o tipo da turbina eólica é uma das variáveis de decisão no presente trabalho e não o número de turbinas eólicas instaladas, espera-se que este objetivo considere fortemente o impacto da escolha de um tipo específico de turbina eólica, em vez de outros, relativos aos efeitos de interferência da esteira e também na capacidade de produção de cada tipo diferente de turbina eólica.

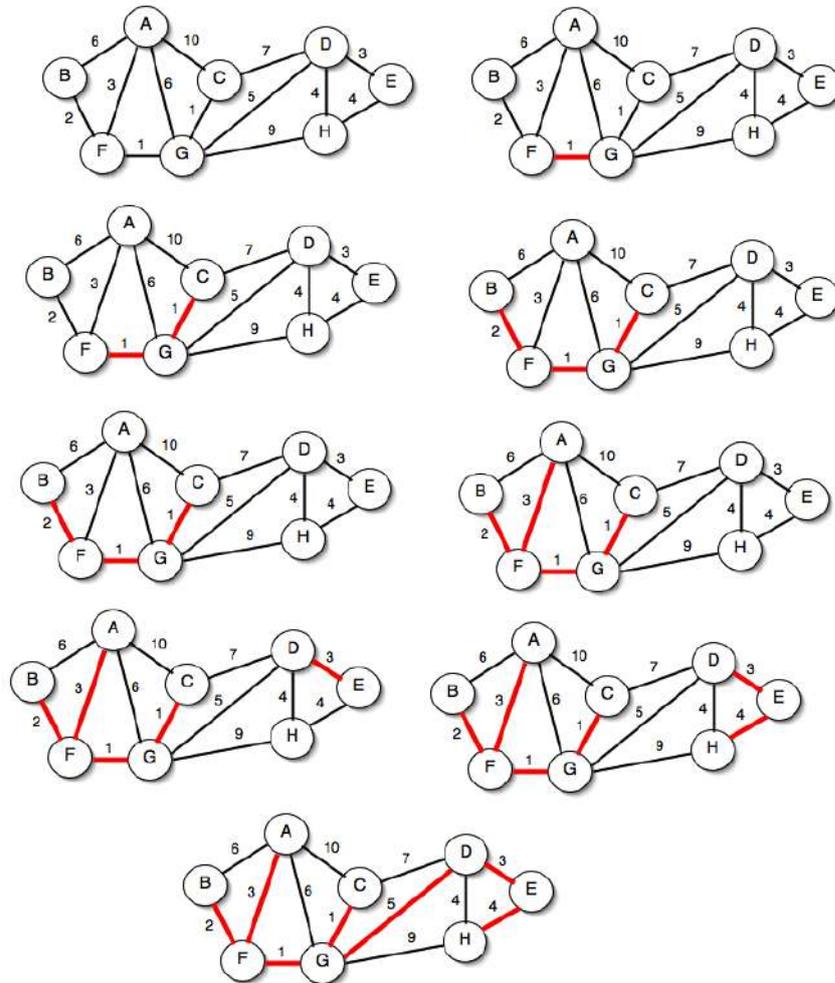


Figura 3.3: Processo de funcionamento do algoritmo de Kruskal (DOUG, 2013). Os nós A, B, C, D, E, F, G e H representam as turbinas e as arestas (em preto) representam as possíveis conexões (candidatas) consideradas para se construir o *minimum-spanning-tree*. Os pesos de cada aresta representam o comprimento de cabo necessário para a conexão das duas turbinas em questão, o que é dependente do layout das turbinas ao longo do parque. As arestas marcadas em vermelho são as conexões selecionadas pelo algoritmo para comporem a *minimum-spanning-tree* que representa os cabos de conexão entre as turbinas.

## 4 Algoritmos evolutivos para otimização multi-objetivo

Em projetos, construções e em manutenções de quaisquer sistemas de engenharia, os engenheiros têm de tomar diversos tipos de decisões, sendo elas de natureza tecnológica e/ou gerencial, nos diversos estágios do processo. Tais decisões têm como objetivo final minimizar o esforço necessário ou maximizar o benefício desejado para um determinado empreendimento. Dessa forma, otimização é o ato de se obter o melhor resultado sob determinadas circunstâncias. Desde que o esforço necessário ou o benefício desejado em quaisquer situações práticas possam ser expressados como uma função matemática, de certas variáveis de decisão, a otimização pode ser definida como o processo de encontrar as condições que possibilitam o máximo ou mínimo valor de tal função (RAO, 1996).

Em um problema de otimização, o *modelo* é conhecido, i.e., o conjunto de equações que modelam o comportamento físico do problema estudado, junto com as saídas desejadas (ou a descrição das saídas desejadas), e a tarefa é então encontrar as entradas que levam à saída desejada (maximização ou minimização de uma ou mais saídas)(EIBEN; SMITH, 2015), conforme mostra a Figura 4.1.

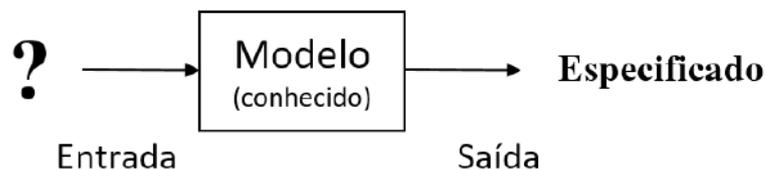


Figura 4.1: Um problema de otimização. O rótulo na saída se lê “especificado”, ao invés de “conhecido”, pois o valor específico ótimo pode não ser conhecido, apenas definido implicitamente (e.g., o menor valor possível) (EIBEN; SMITH, 2015).

Dessa forma, através da definição em termos quantitativos, do que seriam os objetivos de projeto, é possível auxiliar o projetista na escolha efetiva dos parâmetros de projeto adequados (entradas da Figura 4.1), pois isto permite comparar, de maneira

inequívoca, duas possíveis soluções, sendo possível determinar de maneira não-ambígua qual delas é melhor entre si (TAKAHASHI, 2007). Ademais, com esta ordenação das soluções em uma escala de piores e melhores, torna-se possível a automatização do processo, permitindo que um algoritmo de otimização encontre soluções que caminham para soluções cada vez melhores (TAKAHASHI, 2007), conforme ilustra a figura 4.2.

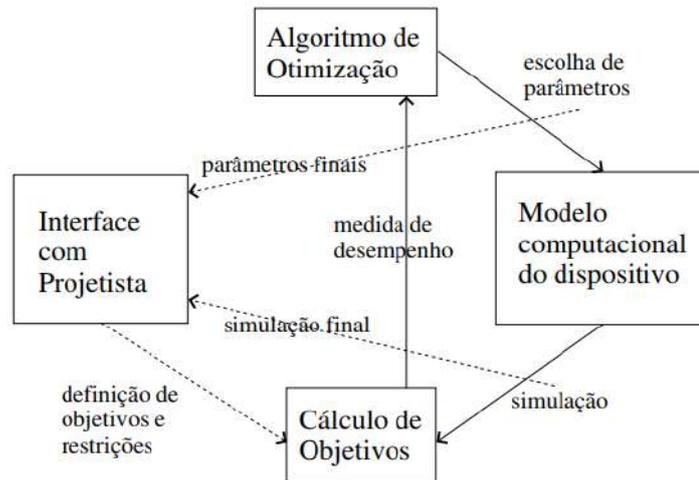


Figura 4.2: Diagrama de blocos de um sistema de projeto assistido por computador à base de um mecanismo de otimização. (TAKAHASHI, 2007)

É importante destacar que a etapa definida como **Modelo computacional do dispositivo**, ilustrada na Figura 4.2, diz respeito ao conjunto de equações que modelam o comportamento físico do problema estudado e no contexto deste trabalho são aquelas das seções 2.1, 2.2 e 2.3, assim como o conjunto de funções da etapa de **Cálculo de Objetivos**, abordado nas Seções 3.1 e 3.2. No presente capítulo serão discutidas as técnicas de otimização presentes na etapa de **Algoritmo de Otimização** da Figura 4.2.

## 4.1 Otimização multi-objetivo

Conforme dito, qualquer sistema ou componente em engenharia pode ser definido como um conjunto de parâmetros, dos quais alguns são tratados como variáveis durante a etapa de projeto, sendo estas a serem determinadas ao final do processo de otimização. Estas variáveis são chamadas de variáveis de projeto ou decisão  $x_i, i = 1, 2, \dots, n$ , sendo  $n$  o número de variáveis de projeto. Tais variáveis de projeto são representadas em conjunto como um vetor de projeto  $\mathbf{x} = [x_1, x_2, x_3, \dots, x_n]$  (DEB, 2001).

Dessa forma, considerando  $n, P \in \mathbb{N}$  e  $D \subseteq \mathbb{R}^n$ , pode-se definir, de uma forma geral, um problema de otimização (minimização) como (DEB, 2001):

$$\begin{aligned} \min \mathbf{f}(\mathbf{x}) &= [f_1(\mathbf{x}), \dots, f_P(\mathbf{x})], \\ \text{sujeito a : } \mathbf{x} &\in D, \end{aligned} \quad (4.1)$$

onde  $f_p : \mathbb{R}^n \rightarrow \mathbb{R}$  com  $p = 1, \dots, P$  são chamadas de funções objetivos. Um problema de otimização é dito sem restrições se  $D = \{\mathbf{x} \in \mathbb{R}^n \mid \underline{\mathbf{x}} \leq \mathbf{x} \leq \bar{\mathbf{x}}\}$  e com restrições se  $D = \{\mathbf{x} \in \mathbb{R}^n \mid g_j(\mathbf{x}) \leq 0, h_k(\mathbf{x}) = 0, \underline{\mathbf{x}} \leq \mathbf{x} \leq \bar{\mathbf{x}}\}$ , onde  $\underline{\mathbf{x}}, \bar{\mathbf{x}} \in \mathbb{R}^n$  e  $j = 1, \dots, J \mid k = 1, \dots, K$ . Os vetores  $\underline{\mathbf{x}}$  e  $\bar{\mathbf{x}}$  são chamados, respectivamente, de limites inferior e superior do vetor de variáveis de decisão  $\mathbf{x}$ . Em um problema de otimização com restrições,  $D$  é chamado de conjunto factível (ou viável) e as funções  $g_j(\mathbf{x})$  são chamadas de restrições de desigualdade, onde  $J$  é o número de restrições de desigualdade do problema, e  $h_k(\mathbf{x})$  as restrições de igualdade, onde  $K$  é o número de restrições de igualdade do problema (DEB, 2001; VARGAS, 2015).

Em se tratando de otimização multiobjetivo, i.e.,  $P \geq 2$ , trabalha-se com dois espaços, sendo o primeiro o espaço das variáveis de projeto,  $\mathbb{R}^n$  e o segundo o espaço dos objetivos,  $\mathbb{R}^P$ . O espaço das variáveis de projeto é onde, efetivamente, se faz a busca pelas soluções do problema, ou seja, é o domínio das variáveis do problema. Já o espaço dos objetivos é o espaço formado pela imagem do conjunto de soluções do problema, conforme ilustra a Figura 4.3.

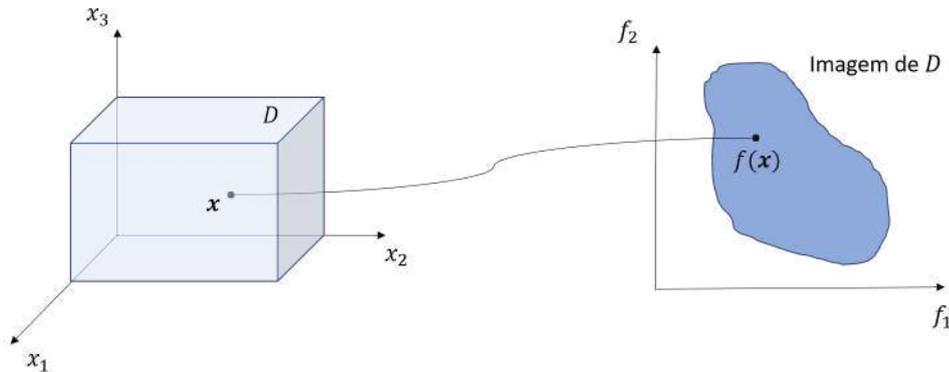


Figura 4.3: Vetor de variáveis de decisão  $\mathbf{x} \in D$  (sendo  $D \subseteq \mathbb{R}^3$  o espaço de busca das variáveis de decisão) com sua imagem no espaço das soluções, i.e.,  $f(\mathbf{x}) \in \mathbb{R}^2$ .

Para se definir uma solução de um problema de otimização multi-objetivo, se

faz necessário estabelecer uma relação de ordem vetorial, que é comumente baseada na noção de dominância introduzida por PARETO (1896), GOLDBERG (1989). Para tal, considerando dois vetores solução candidatos  $\mathbf{x}, \mathbf{y} \in D \subseteq \mathbb{R}^n$ , uma, e somente uma, das situações abaixo descritas ocorre (DEB et al., 2002; DEB, 2001):

- Se  $f_i(\mathbf{x}) \leq f_i(\mathbf{y})$  com  $i = 1, \dots, P$ , e existe um  $j$  natural entre 1 e  $P$  tal que  $f_j(\mathbf{x}) < f_j(\mathbf{y})$ , então  $\mathbf{x}$  domina  $\mathbf{y}$  (denota-se por  $\mathbf{x} \succ \mathbf{y}$ ).
- Se  $f_i(\mathbf{y}) \leq f_i(\mathbf{x})$  com  $i = 1, \dots, P$ , e existe um  $j$  natural entre 1 e  $P$  tal que  $f_j(\mathbf{y}) < f_j(\mathbf{x})$ , então  $\mathbf{y}$  domina  $\mathbf{x}$  (denota-se por  $\mathbf{y} \succ \mathbf{x}$ ).
- Caso contrário,  $\mathbf{x}$  e  $\mathbf{y}$  são ditos não-dominados entre si (denota-se por  $\mathbf{x} \not\succeq \mathbf{y}$  e  $\mathbf{y} \not\succeq \mathbf{x}$ ).

De maneira geral, objetivos conflitantes são usados e geralmente o conjunto de soluções ótimas contém mais de uma solução, devido ao fato da diminuição do valor de um objetivo implicar no aumento do valor de outro(s) objetivos e vice-versa. Dessa forma, o conjunto  $Q \subseteq D$  formado por todas as soluções de um problema de otimização multi-objetivo não-dominadas entre si, e que não são dominadas por nenhuma outra solução de  $D$ , é chamado de soluções de Pareto-Ótimas, conforme ilustra a figura 4.4.

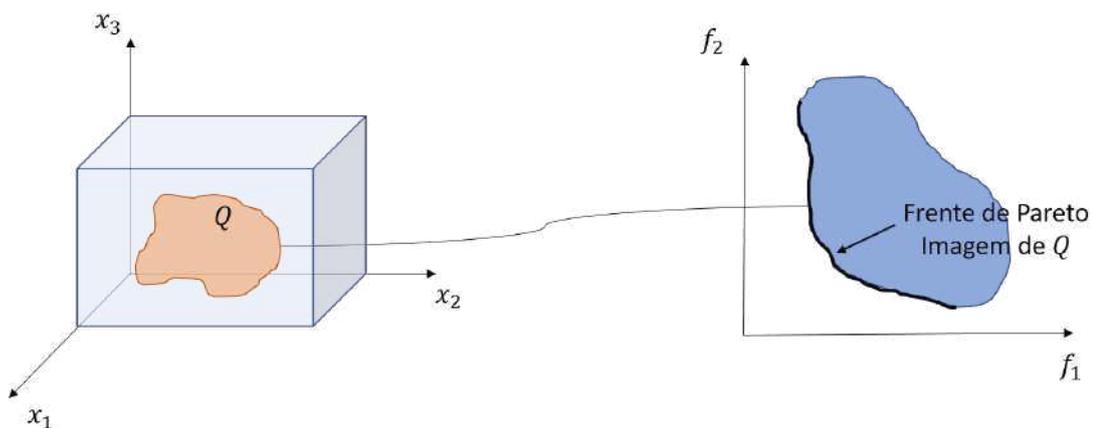


Figura 4.4: Frente de Pareto do exemplo da Figura 4.3, onde o objetivo é minimizar  $f_1$  e  $f_2$ .

Na presença de múltiplas soluções de Pareto-ótimas, não é trivial favorecer uma solução em relação a outra sem um conhecimento mais profundo sobre o problema. Todas as soluções ótimas de Pareto são igualmente importantes, então é de grande importância

encontrar o maior número possível de soluções de Pareto-ótimas para um dado problema. Assim, pode ser inferido que há duas principais ideias em um problema de otimização multi-objetivo (DEB, 2001):

- Encontrar um conjunto de soluções o mais próximas possível da frente de Pareto-ótima;
- Encontrar um conjunto de soluções o mais diverso possível.

Dada a dificuldade de se obter  $Q$  completamente, já que em geral ele contém infinitos elementos, métodos que o aproximam por um conjunto discreto são necessários. Para que um conjunto discreto  $Q'$  seja uma aproximação adequada de  $Q$ , sua imagem deve ser suficientemente próxima da frente de Pareto (convergência) e possuir maior diversidade possível sobre ela. A Figura 4.5 ilustra essas características de convergência e diversidade de  $Q'$ .

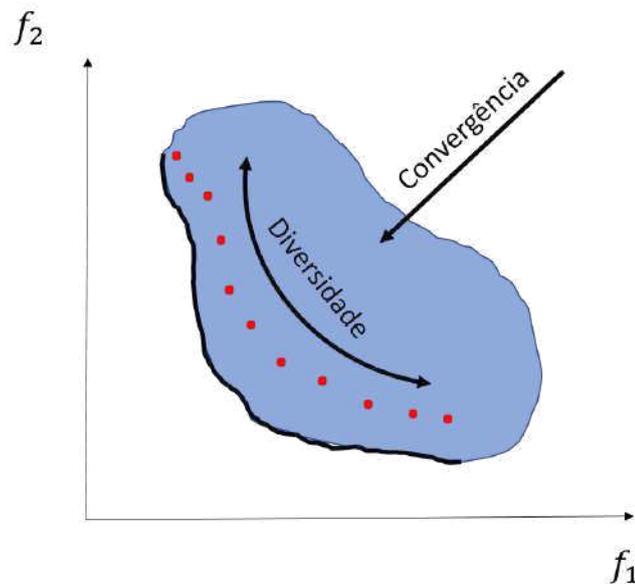


Figura 4.5: Ilustração das características de convergência e diversidade que a imagem de um conjunto discreto  $Q'$  (representado pelos pontos vermelhos) deve ter para que ele seja considerado uma boa aproximação de  $Q$  (VARGAS, 2015).

## 4.2 Algoritmos evolutivos

Conforme mencionado por Deb (2001), a forma clássica de se resolver problemas de otimização multi-objetivo se dá através da abordagem baseada em preferências, onde um

vetor de preferência relativo é usado para escalar múltiplos objetivos. Como a busca e métodos de otimização clássicos usam uma abordagem ponto-a-ponto, onde uma solução em cada iteração é modificada para uma diferente (de preferência melhor que a anterior), o que se tem ao utilizar um método clássico de otimização é uma única solução otimizada para aquele vetor de preferência relativa usado (DEB, 2001). Considerando este princípio de funcionamento dos métodos de otimização disponíveis, não seria de grande surpresa esperar que o desenvolvimento da abordagem baseada em preferências foi motivada pelo fato de que os métodos de otimização disponíveis poderiam encontrar apenas uma única solução otimizada em uma rodada. Como uma única solução otimizada poderia ser encontrada, foi, portanto, necessário converter a tarefa de encontrar múltiplas soluções em um problema de otimização multi-objetivo para uma de encontrar uma única solução de um problema de otimização mono-objetivo transformado (DEB, 2001).

A área de pesquisa de busca e otimização mudou ao longo dos anos com a introdução de uma série de algoritmos de busca e otimização não-clássicos, não-ortodoxos e estocásticos (DEB, 2001). Dentre estes, os algoritmos evolutivos (AE) imita os princípios de evolução da natureza para direcionar sua busca na direção de soluções ótimas. Uma das maiores diferenças a algoritmos de busca e otimização clássicos é que os AEs usam uma população de soluções candidatas (conjunto de vetores de variáveis de decisão) em cada iteração, ao invés de uma solução única. Como uma população de soluções candidatas são processadas em cada iteração, a saída de um AE também é uma população de soluções. Se um problema de otimização tem uma única solução ótima, espera-se que todos os membros da população do AE convirjam para a solução ótima. Entretanto, se um problema de otimização tem múltiplas soluções ótimas, um AE pode ser usado para obter múltiplas soluções em sua população final (DEB, 2001).

Conforme descrito por Eiben e Smith (2015), há duas características principais que formam a base de um algoritmo evolutivo:

- Operadores de variação (recombinação e mutação das soluções candidatas) criam a diversidade necessária dentro da população e, portanto, propiciam “novidade” dentre as soluções candidatas;
- Seleção age aumentando a qualidade média das soluções da população.

A aplicação combinada de técnicas de variação e seleção geralmente levam a melhorias dos valores das funções objetivos das soluções candidatas em populações consecutivas (EIBEN; SMITH, 2015). Em geral, um AE tem sua população de indivíduos manipulada por um conjunto de operadores e que é avaliada por uma função objetivo/aptidão (GOLDBERG, 1989). A reprodução de novos indivíduos e a seleção de uma nova geração estão entre os mecanismos comumente encontrados em um AE para evoluir a população (DEB, 2001). É importante destacar que muitos componentes de tais processos evolutivos são estocásticos (EIBEN; SMITH, 2015). Por exemplo, durante a seleção, os melhores indivíduos não são escolhidos deterministicamente, e geralmente até os indivíduos mais “fracos” têm alguma chance de se tornarem pais ou de sobreviverem para a próxima população. Durante o processo de recombinação, a escolha de quais partes dos pais serão recombinadas é feita de maneira aleatória. De maneira similar para a mutação, a escolha de quais partes serão alteradas na solução candidata, e quais partes a substituirão, são feitas aleatoriamente (EIBEN; SMITH, 2015). O esquema geral de um algoritmo evolutivo é dado no algoritmo 3.

---

**Algoritmo 3:** Pseudocódigo de um algoritmo evolutivo (EIBEN; SMITH, 2015).

---

```

1 início
2   Inicializa populacao com soluções candidatas aleatórias;
3   Avalia cada candidato na populacao;
4   while (CRITÉRIO DE PARADA não é satisfeito) do
5     |   Seleção pais;
6     |   Recombinação pais → filhos;
7     |   Mutação dos filhos resultantes;
8     |   Avalia os novos candidatos filhos;
9     |   Seleciona os indivíduos para a próxima geração nova_populacao em
10    |   {populacao ∪ filhos};
11  end while
12 fim

```

---

É possível notar que este esquema recai na categoria de algoritmos *generate-and-test* (gera soluções candidatas e as testa) (EIBEN; SMITH, 2015). A avaliação (aptidão ou *fitness*) possibilita uma estimativa heurística da qualidade da solução, e o processo de busca é guiado pelos operadores de variação e seleção (EIBEN; SMITH, 2015). Mesmo não sendo possível obter provas formais de que as soluções obtidas ( $Q'$ ) por métodos

heurísticos pertençam ou não a  $Q$  (TAKAHASHI, 2009), elas são consideradas aceitáveis (BENTLEY; WAKEFIELD, 1998). Os algoritmos evolutivos possuem um número de características que podem ajudar a posicioná-los dentre a família de métodos *generate-and-test*, conforme Eiben e Smith (2015) pontua:

- AEs são baseados em populações, i.e., eles processam toda a coleção de soluções candidatas simultaneamente;
- A maioria dos AEs usam recombinação, misturando informações de dois ou mais vetores de variáveis de decisão (soluções candidatas) para criar uma nova solução candidata;
- AEs são estocásticos, i.e., não são determinísticos.

Há um número de componentes, procedimentos, ou operadores que devem ser especificados de forma a definir um AE em particular. Conforme visto no Algoritmo 3, é possível listar os seguintes componentes caracterizam um AE: representação (definição da estrutura dos indivíduos que compõem a população), função de avaliação (aptidão ou *fitness*), população, mecanismo de seleção dos pais, operadores de recombinação e mutação e, por fim, mecanismos de seleção (substituição) dos indivíduos para a população da próxima iteração (ou geração) (EIBEN; SMITH, 2015). Nas Seções 4.3 e 4.5 serão descritos os algoritmos evolutivos utilizados no presente trabalho, bem como cada operador por eles empregados.

### 4.3 NSGA-II

O *Non-dominated Sorting Genetic Algorithm II* (NSGA-II), proposto por Deb et al. (2002), é considerado um dos mais populares, dentre os algoritmos evolutivos para otimização multi-objetivo existentes na literatura (LI; ZHANG, 2009), sendo ele uma versão do *Non-dominated Sorting Genetic Algorithm* (NSGA), proposto por Srinivas e Deb (1994). A ordenação de Pareto empregada consiste em classificar uma população  $R$  em  $d$  subconjuntos, tais que  $F_1 = \{\text{todos os indivíduos não-dominados, entre si, de } R \text{ e que não são dominados por nenhum outro de } R\}$  (posto 1 ou, no inglês, *rank 1*),  $F_2 = \{\text{todos os$

indivíduos não-dominados, entre si, de  $R \setminus F_1$  e que não são dominados por nenhum outro de  $R \setminus F_1$ } (posto 2 ou, no inglês, *rank 2*), ...,  $F_d = \{\text{todos os indivíduos não-dominados, entre si, de } R \setminus \{F_1 \cup F_2 \cup \dots \cup F_{d-1}\} \text{ e que não são dominados por nenhum outro de } R \setminus \{F_1 \cup F_2 \cup \dots \cup F_{d-1}\} \text{ (posto } d \text{ ou, no inglês, } \textit{rank } d\text{), onde } R = F_1 \cup F_2 \cup \dots \cup F_d \text{ (GOLDBERG, 1989; VARGAS, 2015). A Figura 4.6 mostra um exemplo da ordenação de Pareto em um problema com duas funções objetivos.}$

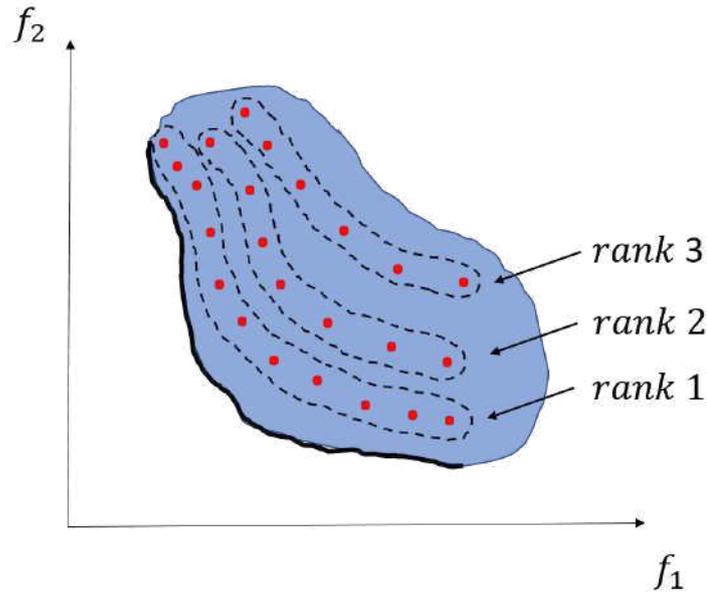


Figura 4.6: Exemplo da ordenação de Pareto em um problema com duas funções objetivos pelo procedimento proposto por GOLDBERG (1989).

Primeiramente, uma população inicial,  $P_0$ , de  $N$  indivíduos é criada aleatoriamente. A população é então ordenada baseada na não-dominância de Pareto. Cada solução candidata é alocada em um dos postos (*ranks*) igual ao seu nível de não-dominância (1 para os melhores, 2 para os seguintes e assim por diante). O processo que se segue é a seleção dos pais através do mecanismo de torneio-binário de seleção, recombinação e mutação, para criar a população de filhos  $Q_0$  também com  $N$  vetores candidatos (DEB et al., 2002).

O procedimento de seleção da população para a próxima geração que o algoritmo NSGA-II usa é simples e direto. Seja uma geração de número  $t$ , primeiramente uma população combinada  $R_t = P_t \cup Q_t$  é formada (estágio **A** da Figura 4.7), unindo a população atual  $P_t$  e a população de filhos gerada  $Q_t$ . Esta população combinada é de tamanho  $2N$ . Então, a população  $R_t$  é ordenada de acordo com os *ranks* de não-dominância (estágio **B**

da Figura 4.7), usando o algoritmo 4 apresentado em Deb et al. (2002). Como todos membros da população anterior e atual estão incluídos em  $R_t$ , o elitismo é garantido. Agora, soluções pertencentes ao melhor conjunto não-dominado (**rank** 1),  $\mathcal{F}_1$ , são as melhores soluções candidatas na população combinada e devem ser enfatizados mais do que quaisquer outras soluções candidatas na população combinada. Se o tamanho de  $\mathcal{F}_1$  é menor que  $N$ , definitivamente serão escolhidos todos os membros de  $\mathcal{F}_1$  para a nova população  $P_{t+1}$ . Os membros restantes da população  $P_{t+1}$  são escolhidos dos conjuntos subsequentes não-dominados na ordem de seus *ranks*. Assim, as soluções candidatas do conjunto  $\mathcal{F}_2$  são escolhidas na sequência, seguidas pelas soluções do conjunto  $\mathcal{F}_3$ , e assim por diante. Este procedimento se repete até que nenhum outro conjunto possa ser acomodado dentro de  $P_{t+1}$ , i.e., não mais do que  $N$  indivíduos. Considerando que o conjunto  $\mathcal{F}_l$  seja o último conjunto não-dominado além do qual nenhum outro conjunto mais possa ser acomodado. De maneira geral, o número de soluções em todos os conjuntos de  $\mathcal{F}_1$  até  $\mathcal{F}_l$  seriam maior do que o tamanho da população. Para se escolher exatamente  $N$  membros para a população, os membros do último conjunto  $\mathcal{F}_l$  são ordenados usando o operador de *crowded-comparison*  $\prec_n$  em ordem decrescente, escolhendo as melhores soluções para preencher as vagas remanescentes de  $P_{t+1}$  e eliminar o restante (estágio D/E da figura 4.7) (DEB et al., 2002).

Para descrever esta abordagem, primeiro é necessário definir uma métrica de estimativa da aglomeração de soluções candidatas e então apresentar o operador de *crowded-comparison*,  $\prec_n$ . Para se estimar a aglomeração das soluções candidatas ao redor de uma solução particular na população, é calculada a distância média de dois pontos em cada lado desta solução ao longo de cada um dos objetivos (ver Figura 4.8). Esta quantidade  $i_{distance}$  serve como uma estimativa do perímetro do cubóide formado usando os vizinhos mais próximos como vértices (chama-se *crowding distance* ou distância de aglomeração). Na Figura 4.8, o *crowding distance* da  $i$ -ésima solução no seu conjunto não-dominado (marcado com círculos preenchidos) é a média do comprimento de cada lado do cubóide (mostrado como uma retângulo tracejado). Para cada função objetivo, as soluções da extremidade (soluções com menores e maiores valores de função objetivo) são atribuídas uma distância infinita. A todas as outras soluções intermediárias são atribuídas uma distância

**Algoritmo 4:** fast-non-dominated-sort( $R_t$ ) (DEB et al., 2002)**Entrada:** População combinada, ( $R_t$ )**Saída:** Todos os conjuntos  $F$  não-dominados de  $R_t$ 

```

1 início
2   for cada  $p \in R_t$  do
3      $S_p = \emptyset$ ;
4      $n_p = 0$ ;
5     for cada  $q \in R_t | q \neq p$  do
6       if  $p \prec q$  then
7          $S_p = S_p \cup \{q\}$    Adiciona  $q$  ao conjunto de soluções
                                dominadas por  $p$ ;
8       else
9          $n_p = n_p + 1$    Incrementa o contador de dominância de  $p$ ;
10      end if
11    end for
12    if  $n_p = 0$  then
13       $p_{rank} = 1$     $p$  pertence ao primeiro conjunto ( $\mathcal{F}_1$ , i.e.,  $rank$ 
14      1;
15       $\mathcal{F}_1 = \mathcal{F}_1 \cup \{p\}$ ;
16    end if
17  end for
18   $i = 1$ ;
19  while  $\mathcal{F}_i \neq \emptyset$  do
20     $\mathcal{Q} = \emptyset$    Usado para armazenar os membros do próximo conjunto ;
21    for cada  $p \in \mathcal{F}_i$  do
22      for cada  $q \in S_p$  do
23         $n_q = n_q - 1$ ;
24        if  $n_q = 0$  then
25           $q_{rank} = i + 1$     $q$  pertence ao próximo conjunto;
26           $\mathcal{Q} = \mathcal{Q} \cup \{q\}$ ;
27        end if
28      end for
29    end for
30     $i = i + 1$ ;
31     $\mathcal{F}_i = \mathcal{Q}$ ;
32  end while
33 fim

```

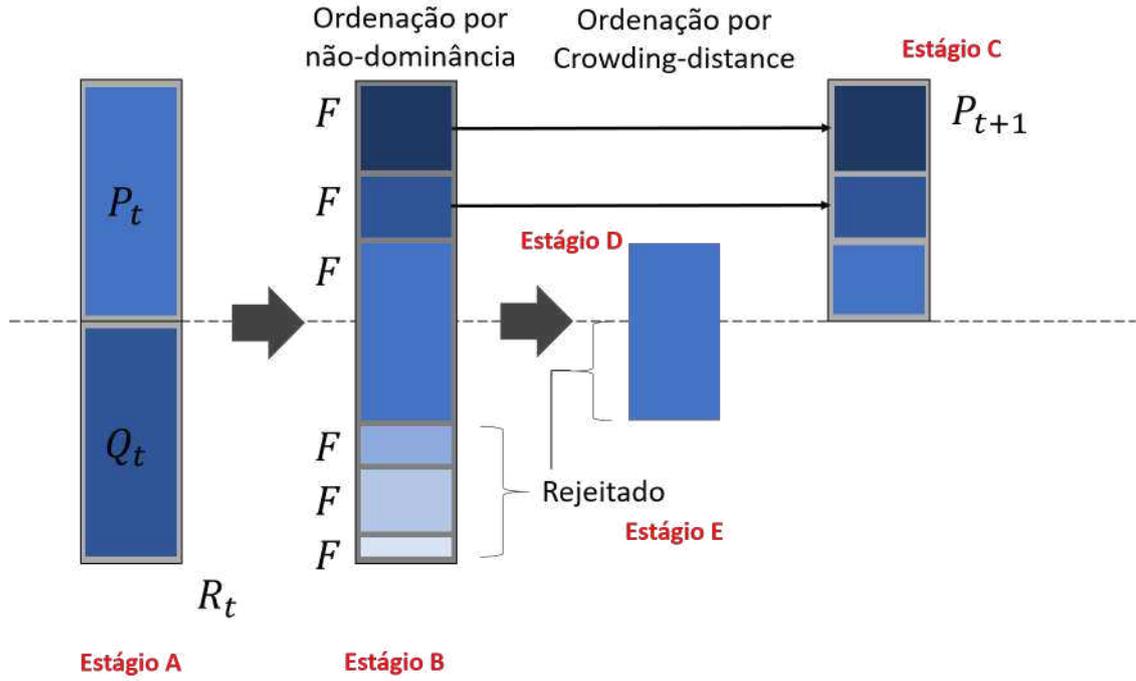


Figura 4.7: Esquema de seleção da próxima geração no NSGA-II (DEB et al., 2002).

igual à diferença normalizada dos valores de função objetivo das duas soluções adjacentes. Os valores de  $i_{distance}$  para cada indivíduo em  $\mathcal{F}_l$  são avaliados conforme descrito no Algoritmo 5 (DEB et al., 2002), onde  $\mathcal{J}[i].m$  refere ao  $m$ -ésimo valor de função objetivo do  $i$ -ésimo indivíduo no conjunto  $\mathcal{J}$  avaliado e os parâmetros  $f_m^{max}$  e  $f_m^{min}$  são os valores máximo e mínimo da  $m$ -ésima função objetivo. O operador  $\prec_n$  guia o processo de seleção nos vários estágios do algoritmo em direção de uma frente de Pareto ótima uniformemente distribuída. Assume-se que cada indivíduo na população terá dois atributos:

1.  $rank$  de não-dominância ( $i_{rank}$ )
2.  $crowding\ distance$  ou distância de aglomeração ( $i_{distance}$ ),

Agora definimos a ordenação parcial  $i \prec_n j$  se uma das situações ocorrem:

- $i_{rank} < j_{rank}$
- $i_{rank} = j_{rank} \ \& \ i_{distance} > j_{distance}$ .

que descreve o critério de seleção final mostrado no estágio C da Figura 4.7 (DEB et al., 2002). Finalmente, o processo todo de seleção da próxima geração empregado pelo NSGA-II é descrito conforme o Algoritmo 6.

**Algoritmo 5:** atribuição-crowding-distance( $\mathcal{J}$ ) (DEB et al., 2002)

---

**Entrada:** Conjunto avaliado para cálculo do crowding distance de suas soluções,  $\mathcal{J}$

**Saída:** *Crowding distance* para cada solução  $i \in \mathcal{J}$ ,  $i_{distance}$

```

1 início
2    $l = |\mathcal{J}|$     número de soluções em  $\mathcal{J}$ ;
3   para cada  $i$ , atribuir  $i_{distance} = 0$     inicializa as distâncias;
4   for cada objetivo  $m$  do
5      $\mathcal{J} = \text{ordena}(\mathcal{J}, m)$     ordena utilizando cada valor de função objetivo;
6      $i[\text{primeiro}] = i[\text{último}] = \infty$     de forma que os pontos da
        extremidade sejam sempre selecionados;
7     for  $i = 2$  até  $(l - 1)$  do
8        $i_{distance} = i_{distance} + (\mathcal{J}[i + 1].m - \mathcal{J}[i - 1].m) / (f_m^{max} - f_m^{min})$ 
9     end for
10  end for
11 fim

```

---

**Algoritmo 6:** Seleção da população para próxima geração,  $P_{t+1}$  (DEB et al., 2002)

---

**Entrada:** População combinada, ( $R_t = P_t \cup Q_t$ )

**Saída:** População combinada da próxima geração, ( $R_{t+1} = P_{t+1} \cup Q_{t+1}$ )

```

1 início
2    $\mathcal{F} = \text{fast-non-dominated-sort}(R_t)$      $\mathcal{F} = (\mathcal{F}_1, \mathcal{F}_2, \dots)$ , todas as
        frentes não dominadas de  $R_t$ ;
3    $P_{t+1} = \emptyset$  e  $i = 1$ ;
4   while  $|P_{t+1}| + |\mathcal{F}_i| \leq N$  do
5     /*Até que a população seja preenchida*/;
6     atribuição-crowding-distance( $\mathcal{F}_i$ )    calcula o crowding-distance
        em  $\mathcal{F}_i$ ;
7      $P_{t+1} = P_{t+1} \cup \mathcal{F}_i$     inclui a  $i$ -ésima frente não dominada na
        população;
8      $i = i + 1$     checa a próxima frente para inclusão;
9   end while
10  Ordena( $\mathcal{F}_i, \prec_n$ )    ordena em ordem decrescente usando  $\prec_n$ ;
11   $P_{t+1} = P_{t+1} \cup \mathcal{F}_i[1 : (N - |P_{t+1}|)]$     escolhe os primeiros  $(N - |P_{t+1}|)$ 
        elementos de  $\mathcal{F}_i$ ;
12   $Q_{t+1} = \text{gera-nova-população}(P_{t+1})$     usa seleção dos pais,
        recombinação e mutação para criar uma nova população  $Q_{t+1}$ ;
13   $t = t + 1$     incrementa o contador de gerações;
14 fim

```

---

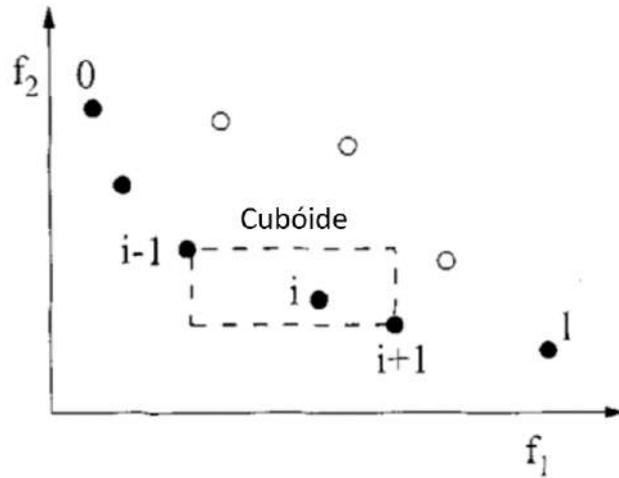


Figura 4.8: Cálculo do *Crowding-distance*. Os círculos preenchidos são soluções do mesmo conjunto não-dominado (DEB et al., 2002).

De maneira similar ao que foi discutido até aqui, no caso de problemas de otimização multi-objetivo com restrições, o que é o objetivo do presente trabalho, o método de tratamento de restrição usa a seleção por torneio binário, onde duas soluções são retiradas da população e a melhor solução é escolhida. Na presença de restrições, cada solução pode ser factível ou infactível. Assim, podem ocorrer apenas três situações: 1) ambas soluções são factíveis; 2) uma é factível e a outra não; 3) ambas são infactíveis. No contexto de otimização multi-objetivo, os últimos dois casos podem ser usados como já estão e o primeiro caso pode ser resolvido utilizando o operador de *crowded-comparison* como anteriormente. Para manter a modularidade no procedimento do NSGA-II, simplesmente é modificada a definição de dominância entre duas soluções  $i$  e  $j$ , onde de agora em diante uma solução  $i$  domina-com-restrições uma solução  $j$ , se uma das seguintes condições é verdadeira:

1. Solução  $i$  é factível e a solução  $j$  não é;
2. Soluções  $i$  e  $j$  são ambas infactíveis, porém a solução  $i$  tem uma menor violação total das restrições do que a solução  $j$ , i.e.  $\sum_{h=1}^H g_h(\mathbf{i}) < \sum_{h=1}^H g_h(\mathbf{j})$ .  $H$  é o número total de restrições do problema e as funções  $g_h$  são funções que representam o grau de violação das restrições por uma solução, i.e., quando  $g_h > 0$  assume valores positivos;

3. Soluções  $i$  e  $j$  são factíveis e a solução  $i$  domina a solução  $j$  com relação ao  $rank$  e  $i_{distance} (i \prec_n j)$ .

O efeito de usar esta dominância-com-restrições é que qualquer solução factível tem um menor  $rank$  de não-dominância que qualquer solução infactível. Todas as soluções factíveis são ranqueadas de acordo com seus  $rank$ s de não-dominância baseado nos valores das funções objetivo. Entretanto, entre duas soluções infactíveis, a solução com menor violação das restrições tem um melhor  $rank$  (DEB et al., 2002).

Conforme mencionado, há duas características fundamentais que formam a base de algoritmos evolutivos: variação e seleção (EIBEN; SMITH, 2015). Acima foi abordado o método de seleção dos indivíduos para a próxima geração em uma iteração do NSGA-II. Já nas próximas subseções serão discutidos os componentes do AE por traz da variação. A função **gera-nova-população** da linha 12 do algoritmo 6 contem as etapas de variação (seleção dos pais, recombinação e mutação) para criação de uma nova população de filhos  $Q_{t+1}$  e serão abordadas na sequência.

### 4.3.1 Seleção dos pais por torneio

Dois modelos de gerenciamento de população são encontrados na literatura: o modelo geracional (*generational model*) e o modelo de estado-estável (*steady-state model*) (EIBEN; SMITH, 2015). No modelo geracional, em cada geração inicia-se com uma população de tamanho  $\mu$ , da qual acontece a seleção dos pais (*mating pool*). Cada membro da *mating pool* é uma cópia de um indivíduo da população, porém com proporções diferentes, com (geralmente) mais cópias dos “melhores” pais. Em seguida,  $\lambda$  filhos são criados a partir desta *mating pool* através da aplicação de operadores de variação e avaliação dos indivíduos gerados. Após cada geração, a população toda é substituída por  $\mu$  indivíduos selecionados dos filhos mais a população de pais, denominando-se a próxima geração (EIBEN; SMITH, 2015), como discutido anteriormente. Neste estágio é importante reiterar que os operadores que são responsáveis por este elemento competitivo do gerenciamento da população funcionam no que diz respeito à aptidão do indivíduo. Como consequência direta, esses operadores de seleção e reposição funcionam independentemente da estrutura de representação do problema estudado (EIBEN; SMITH, 2015).

O operador de seleção dos pais para constituírem a *mating pool* é feito através de um torneio de seleção, o qual tem uma propriedade útil que não requer nenhum conhecimento geral da população (sua estrutura), nem medidas quantitativas de qualidade. Ao invés disso, o método requer apenas uma relação de ordenação que possa comparar o *rank* de quaisquer dois indivíduos. Portanto se trata de uma implementação conceitualmente simples e rápida de se aplicar. A aplicação do torneio de seleção para selecionar  $\lambda$  membros de uma *mating pool* dentre  $\mu$  indivíduos funciona de acordo com o procedimento mostrado no Algoritmo 7 (EIBEN; SMITH, 2015).

---

**Algoritmo 7:** Pseudocódigo do algoritmo do torneio de seleção dos pais (EIBEN; SMITH, 2015)

---

**Entrada:** População, ( $P_t$ )  
**Saída:** *Mating\_pool* para o processo de recombinação

```

1 início
2   /* Considerando que deseja-se selecionar  $\lambda$  membros para a mating pool
   dentre os  $\mu$  indivíduos da população */;
3   Defina current_member = 1;
4   while (current_member  $\leq$   $\lambda$ ) do
5     Pegue  $k$  indivíduos aleatoriamente, com ou sem reposição;
6     Compare (dominância-com-restrições) esses  $k$  indivíduos e selecione
       o melhor deles;
7     Denote esse indivíduo como  $i$ ;
8     Defina mating_pool[current_member] =  $i$ ;
9     Defina current_member = current_member + 1;
10  end while
11 fim
```

---

A probabilidade que um indivíduo será selecionado como resultado de um torneio depende de quatro fatores, sendo eles (EIBEN; SMITH, 2015):

- Seu *rank* na população. Efetivamente isso é estimado sem a necessidade de ordenar a população inteira;
- O tamanho,  $k$ , do torneio. O quão maior for o torneio, maior é a chance da *mating pool* conter membros de maior aptidão média e menor as chances de conter membros de menor aptidão. Assim a probabilidade de seleção dos membros de maior aptidão aumenta e a probabilidade dos membros de menor aptidão diminui, conforme  $k$  aumenta. Dessa forma é dito que aumentar  $k$  aumenta a pressão de seleção;

- A probabilidade  $p$  que os membros de maior aptidão sejam selecionados no torneio. Geralmente  $p$  é considerado como 1 (i.e., 100% - torneio determinístico), porém versões estocásticas também são usadas com  $p < 1$ . Como isso torna mais provável que membros com menor aptidão também sejam selecionados, a diminuição de  $p$  também diminui a pressão de seleção;
- Se indivíduos são selecionados com ou sem reposição. No segundo caso, com torneios determinísticos, os  $k - 1$  membros com menor aptidão da população podem nunca ser selecionados, devido ao outro membro do torneio ter maior aptidão. Entretanto, se os candidatos do torneio são selecionados com reposição (i.e., uma cópia deste é recolocada na população para poder ser selecionado para um novo torneio), é sempre possível até mesmo para os membros com menor aptidão da população serem selecionados.

### 4.3.2 Recombinação - *Simulated Binary Crossover* (SBX)

Uma vez que a *mating pool* dos pais é formada, o processo de variação (recombinação e mutação) acontece. Como os operadores de variação operam no nível “genético”, i.e., funcionam na estrutura de representação do vetor de variáveis de decisão  $\mathbf{x}$ , ao invés das próprias soluções, é dito que os objetos formando possíveis soluções dentro do contexto do problema original são referidas como fenótipos, enquanto sua codificação (representação do vetor de variáveis), i.e., os indivíduos dentro do AE, são chamados de genótipos. Conforme dito brevemente anteriormente, o genótipo para uma solução com  $k$  genes é agora um vetor  $\mathbf{x} = [x_1, x_2, x_3, \dots, x_k]$  com  $x_i \in \mathbb{R}$ , entretanto os genótipos também podem ter codificação binária, inteira, de permutação ou árvore (EIBEN; SMITH, 2015). Para o operador de recombinação (ou *crossover*), em se tratando da codificação real ( $x_i \in \mathbb{R}$ ) para o vetor de variáveis de decisão, ao invés dos tradicionais cromossomos binários, é muito comum na literatura encontrar trabalhos que utilizam o NSGA-II com o operador *Simulated Binary Crossover* (SBX) (DEB; AGRAWAL, 1995; DEB; KUMAR, 1995; DEB; SINDHYA; OKABE, 2007). O operador SBX utiliza dois vetores pais e aplica um operador de “mistura” (*blending operator*) variável por variável para criar duas soluções filhas (*offspring solutions*). O operador envolve um parâmetro chamado de índice

de distribuição ( $\eta_c$ ), o qual é mantido um valor fixo não-negativo ao longo de todo processo de simulação. Se um valor maior de  $\eta_c$  é escolhido, as soluções filhas resultantes serão mais próximo aos vetores pais. Em contrapartida, para pequenos valores de  $\eta_c$ , soluções mais afastadas dos pais são mais prováveis de serem geradas. Assim, esse parâmetro tem um efeito direto no controle de espalhamento das soluções filhas (DEB; SINDHYA; OKABE, 2007).

O procedimento de geração dos dois filhos  $x_i^{(1,t+1)}$  e  $x_i^{(2,t+1)}$  a partir das soluções pais  $x_i^{(1,t)}$  e  $x_i^{(2,t)}$  é descrita como se segue. Um fator de espalhamento (*spread factor*)  $\beta_i$  é definido como a razão entre a diferença absoluta dos valores das variáveis nos filhos em relação aos pais (DEB; SINDHYA; OKABE, 2007). Primeiramente, um número aleatório  $\mu_i \in [0, 1]$  é gerado. Após isto, a partir de uma função de distribuição de probabilidades, a ordenada  $\beta_i$  é encontrada de forma que a área sob a curva de probabilidades de zero até  $\beta_i$  seja igual ao número aleatório gerado  $\mu_i$ . A função de distribuição de probabilidades usada para criar um vetor filho é derivada de forma a ter uma capacidade de busca semelhante à abordagem *single-point binary-coded crossover* em algoritmos genéticos e é dada conforme Deb e Agrawal (1995).

$$\mathcal{P}(\beta_i) = \begin{cases} 0.5(\eta_c + 1)\beta_i^{\eta_c}, & \text{se } \beta_i \leq 1; \\ \frac{0.5(\eta_c+1)}{\beta_i^{\eta_c+2}}, & \text{caso contrário.} \end{cases} \quad (4.2)$$

A Figura 4.9 mostra a função de distribuição de probabilidades descrita na equação 4.2 com  $\eta_c = 2$  e 5 para criação de vetores filhos a partir de dois vetores pais ( $x_i^{(1,t)} = 2.0$  e  $x_i^{(2,t)} = 5.0$ ) de apenas uma variável de decisão cada. Nas expressões acima, o índice de distribuição  $\eta_c$  pode ser qualquer número real não-negativo. Um valor alto para  $\eta_c$  dá uma maior probabilidade de gerar vetores soluções próximo aos vetores pais (portanto permitindo uma busca localmente focada) e um valor menor para  $\eta_c$  permite que soluções filhas mais distantes sejam geradas (portanto permitindo uma busca mais diversa) (DEB; SINDHYA; OKABE, 2007). O fator de espalhamento  $\beta_i$  é determinado a partir da função de probabilidade acumulada, de forma que:  $\int_0^{\beta_i} \mathcal{P}(\beta) d\beta = \mu_i$  (DEB; KUMAR, 1995; DEB; SINDHYA; OKABE, 2007).

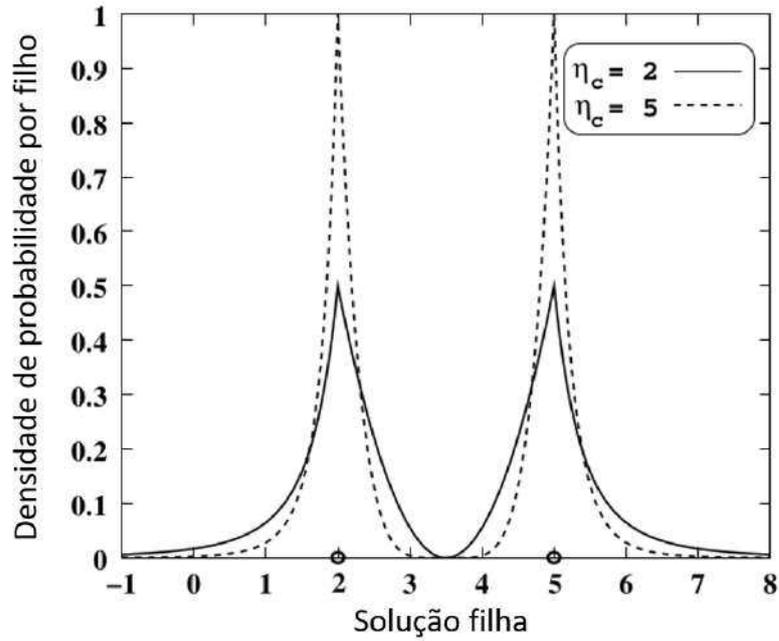


Figura 4.9: Função de densidade de probabilidade para criação dos vetores filhos a partir do operador SBX- $\eta_c$  (DEB; SINDHYA; OKABE, 2007).

Após a obtenção de  $\beta_i$  da distribuição de probabilidades acima, os vetores filhos são gerados conforme equação 4.3 (DEB; KUMAR, 1995; DEB; SINDHYA; OKABE, 2007):

$$\begin{aligned} x_i^{(1,t+1)} &= 0.5 \left[ (1 + \beta_i)x_i^{(1,t)} + (1 - \beta_i)x_i^{(2,t)} \right]; \\ x_i^{(2,t+1)} &= 0.5 \left[ (1 - \beta_i)x_i^{(1,t)} + (1 + \beta_i)x_i^{(2,t)} \right]. \end{aligned} \quad (4.3)$$

### 4.3.3 Mutaç o polinomial

O operador de muta o em algoritmos gen ticos   usado principalmente como um mecanismo para manter a diversidade na popula o (GOLDBERG, 1989; HOLLAND, 1975). Em contraste com os operadores de recombina o/crossover, um operador de muta o opera somente em um membro da popula o por vez e o modifica independentemente do restante dos membros da popula o (DEB; DEB, 2014). Embora o operador de muta o sozinho possa n o realizar uma busca eficiente, quando combinado com operador de recombina o, os operadores de muta o desempenham um papel importante em fazer o processo todo de busca eficiente (GOLDBERG, 1989). Para uma dada solu o

pai  $p \in [a, b]$ , a solução mutada  $p^*$ , para uma variável de decisão particular do vetor de variáveis (intervalo de busca para variável  $[a, b]$ ), é criada a partir de um número aleatório  $\mu \in [0, 1]$ , como se segue (DEB; DEB, 2014):

$$p^* = \begin{cases} p + \overline{\delta}_L(p - x_i^{(L)}), & \text{para } \mu \leq 0.5; \\ p + \overline{\delta}_R(x_i^{(R)} - p), & \text{para } \mu > 0.5. \end{cases} \quad (4.4)$$

Então, um dos dois parâmetros ( $\delta_L$  or  $\delta_R$ ) é calculado (DEB; DEB, 2014):

$$\begin{aligned} \overline{\delta}_L &= (2\mu)^{\frac{1}{1+\eta_m}} - 1, & \text{para } \mu \leq 0.5 \\ \overline{\delta}_R &= 1 - 2(1 - \mu)^{\frac{1}{1+\eta_m}}, & \text{para } \mu > 0.5, \end{aligned} \quad (4.5)$$

sendo  $\eta_m$  um parâmetro definido pelo usuário (DEB; DEB, 2014). Para ilustrar, a figura 4.10 mostra a densidade probabilidade de se criar um vetor filho mutado a partir de um vetor pai (considerando um vetor de apenas uma variável de decisão)  $p = 3.0$  com os limites inferior e superior da variável de decisão como  $[1, 8]$  e com  $\eta_m = 20$ .

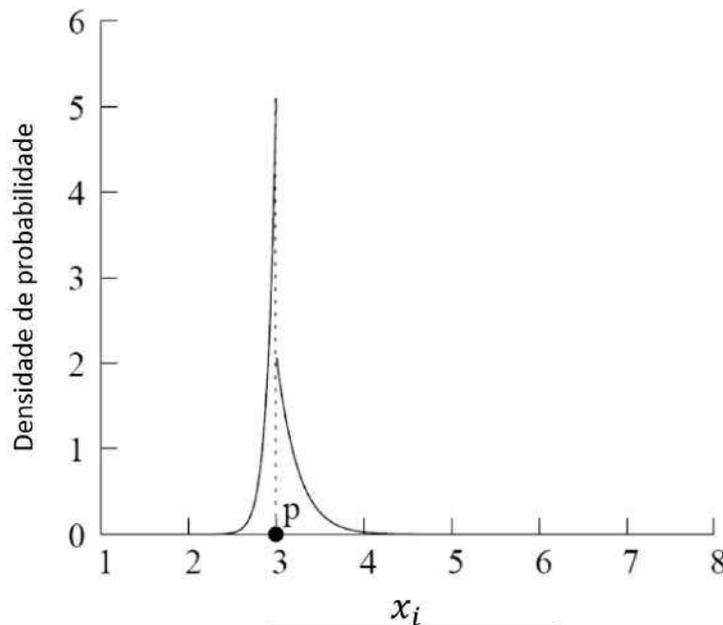


Figura 4.10: Função de densidade de probabilidade para criação de um vetor filho mutado utilizando o operador de mutação polinomial (DEB; DEB, 2014).

## 4.4 Métricas de desempenho

Como dito anteriormente, há dois propósitos distintos em otimização multi-objetivo: (i) Descobrir soluções o mais próximas possível da frente de Pareto real, e (ii) encontrar soluções o mais diversas possível na frente não-dominada (DEB, 2001; RIQUELME; LÜCKEN; BARAN, 2015). De certa forma, esses dois propósitos são ortogonais entre si (DEB, 2001). A primeira tarefa requer uma busca em direção à região da frente de Pareto ótima, enquanto a segunda tarefa requer uma busca ao longo da frente de Pareto ótima, como ilustra a Figura 4.11. A medida de diversidade pode também ser dividida em duas medidas diferentes: de extensão (medindo o espalhamento das soluções das extremidades) e distribuição (medindo a distância relativa entre as soluções) (ZITZLER; DEB; THIELE, 2000). Conforme afirmado por Deb (2001), um algoritmo evolutivo multi-objetivo (MOEA) será denominado um bom MOEA se ambos os propósitos são satisfeitos adequadamente. Assim, com um bom MOEA, o usuário espera encontrar soluções próximo à frente de Pareto ótima real (true Pareto-optimal front), assim como soluções que abranjam toda a região de Pareto ótima uniformemente. Na figura 4.12 é mostrado o desempenho de um MOEA ideal em um problema hipotético (DEB, 2001).

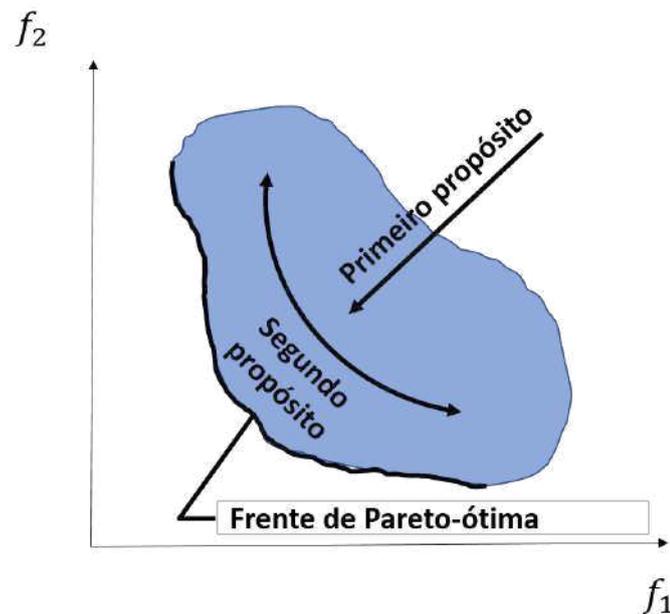


Figura 4.11: Os dois propósitos da otimização multi-objetivo (DEB, 2001).

A real importância de estudar tais métricas de desempenho se encontra em sua

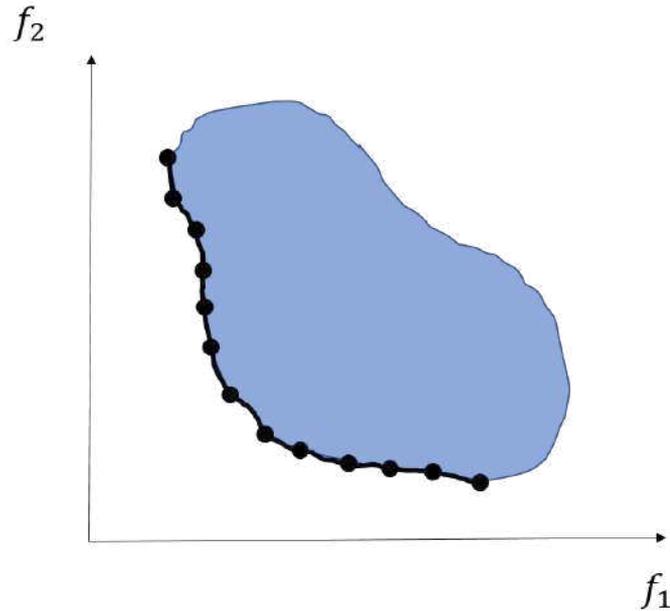


Figura 4.12: Um conjunto ideal de soluções não-dominadas (DEB; DEB, 2014)

vasta aceitação na comunidade com especialidade de performar estudos experimentais que são necessários para refletir, de certa forma, a qualidade da saída de diferentes algoritmos, assim como comparar diferentes abordagens (RIQUELME; LÜCKEN; BARAN, 2015). Análises prévias e revisões a respeito das métricas de desempenho podem ser encontradas em Okabe, Jin e Sendhoff (2003), Zitzler et al. (2003), Zitzler, Deb e Thiele (2000).

Um conjunto aproximado é definido como se segue (ZITZLER et al., 2003): seja  $A$  um conjunto de vetores objetivo.  $A$  é dito ser um conjunto aproximado se qualquer elemento de  $A$  não domina ou não é igual a qualquer outro vetor objetivo de  $A$ . O conjunto de todos os conjuntos aproximados é denominado como  $Z$ . Como mencionado acima, o resultado de se resolver um problema real de engenharia geralmente é um conjunto aproximado  $A$  e não a frente de Pareto-ótima real  $PF^*$  (RIQUELME; LÜCKEN; BARAN, 2015). Dados  $h$  conjuntos aproximados  $A_i \in Z$ ,  $i = 1, 2, \dots, h$ , uma métrica de desempenho (ou indicador de qualidade),  $I$ , é definida por Zitzler et al. (2003) como uma função  $I : Z^h \mapsto \mathbb{R}$  que atribui a cada conjunto  $(A_1, A_2, \dots, A_h)$  um valor real  $I(A_1, A_2, \dots, A_h)$ , geralmente usado para comparar a qualidade de diferentes algoritmos quando resolvendo problemas de otimização multi-objetivo (RIQUELME; LÜCKEN; BARAN, 2015). Há duas principais formas de métricas. O primeiro critério de classificação considera os aspectos que a métrica avalia os conjuntos aproximados em  $Z$ . Considerando um conjunto

aproximado  $A$ , as métricas podem ser agrupadas de acordo com tais aspectos que avalia, como (RIQUELME; LÜCKEN; BARAN, 2015):

- **Métricas de precisão (*Accuracy metrics*):** Este aspecto se refere diretamente à convergência de  $A$ . Em outras palavras, ela indica o quão distante está  $A$  da frente de pareto-ótima teórica  $PF^*$ . Perceba que quando a frente de pareto-ótima não é conhecida, um conjunto de referência é adotado. Este conjunto  $R$  de referência será apresentado no Capítulo 5 de resultados;
- **Métricas de diversidade (*Diversity metrics*):** A distribuição e espalhamento das soluções são dois fatores bastante relacionados, porém não representam as mesmas coisas (OKABE; JIN; SENDHOFF, 2003). A distribuição se refere à distância relativa entre as soluções em  $A$  (DEB, 2001) de (RIQUELME; LÜCKEN; BARAN, 2015), enquanto o espalhamento se refere ao intervalo de valores cobridos pelas soluções em  $A$  (ZITZLER; DEB; THIELE, 2000). O espalhamento também é conhecido como a extensão de um conjunto aproximado.

O segundo critério de classificação leva em consideração o número  $h$  de conjuntos aproximados que serão avaliados pela métrica. Dois tipos de métricas têm sido usadas pela literatura especializada (RIQUELME; LÜCKEN; BARAN, 2015):

- **Métricas unárias (*Unary metrics*):** A métrica é dita ser unária se ela recebe como parâmetro apenas um conjunto aproximado  $A$  para ser avaliado. Matematicamente, uma métrica unária é uma função denominada como  $I(A) : Z \mapsto \mathbb{R}$ ;
- **Métricas binárias (*Binary metrics*):** A métrica é dita ser binária se ela recebe como parâmetro dois conjuntos aproximados,  $A$  e  $B \in Z$ , para serem comparados. Matematicamente, uma métrica binária é uma função denominada como  $I(A, B) : Z^2 \mapsto \mathbb{R}$ .

Neste trabalho foram adotadas 2 medidas unárias (Inverted Generational Distance Plus e o Hipervolume), a serem discutidas a seguir.

#### 4.4.1 *Inverted Generational Distance Plus - IGD+*

Uma das medidas unárias utilizadas por Deb et al. (2002) para avaliar o desempenho do NSGA-II foi o *Generational Distance* (GD), proposta por Van Veldhuizen (1999). O GD trata-se de uma medida unária que se exige o conhecimento da frente de pareto real do problema em questão, ou de uma aproximação  $R$  (RIQUELME; LÜCKEN; BARAN, 2015). A medida *Generational Distance* é a média das distâncias de cada uma das soluções da frente de pareto aproximada ( $A$ ), que está sendo avaliada, até a solução da frente de Pareto real ( $Z$ ) mais próxima (Van Veldhuizen, 1999):

$$GD(A) = \frac{1}{|A|} \left( \sum_{i=1}^{|A|} d_i^p \right)^{1/p}, \quad (4.6)$$

onde  $d_i$  representa a distância euclidiana ( $p = 2$ , ver Equação 4.7) de  $\mathbf{a}_i \in A$  até o ponto mais próximo  $\mathbf{z}_i \in Z$ . Basicamente, isso resulta em uma distância média dos pontos em  $A$  para os pontos mais próximos destes na frente de Pareto-ótima real. A Figura 4.13 ilustra a ideia do procedimento de cálculo desta métrica.

$$d_i = \min_{k=1}^{|Z|} \sqrt{\sum_{m=1}^M (f_m^{(i)} - f_{*m}^{(k)})^2}, \quad (4.7)$$

onde  $f_{*m}^{(k)}$  é o valor da  $m$ -ésima função objetivo do  $k$ -ésimo membro de  $Z$ .

Coello e Sierra (2004) propõe a inversão do cálculo para que ela seja capaz de medir, além da convergência, a diversidade da frente de Pareto. Eles denominam essa inversão de *Inverted Generational Distance* (*IGD*). Assim, para cada solução da frente de pareto, *IGD* é a média das distâncias de cada uma das soluções da frente de Pareto real  $Z$  até a solução mais próxima da frente de Pareto encontrada pelo algoritmo  $A$ . Qualquer deficiência na convergência ou na diversidade a frente de Pareto aumenta o valor de *IGD*. Logo, quanto menor o valor de *IGD*, melhor é a convergência e diversidade da frente de Pareto em relação à frente de pareto real do problema. A Equação 4.8 apresenta a formula para o cálculo do *IGD*.

$$IGD(A) = \frac{1}{|Z|} \left( \sum_{i=1}^{|Z|} \hat{d}_i^p \right)^{1/p}, \quad (4.8)$$

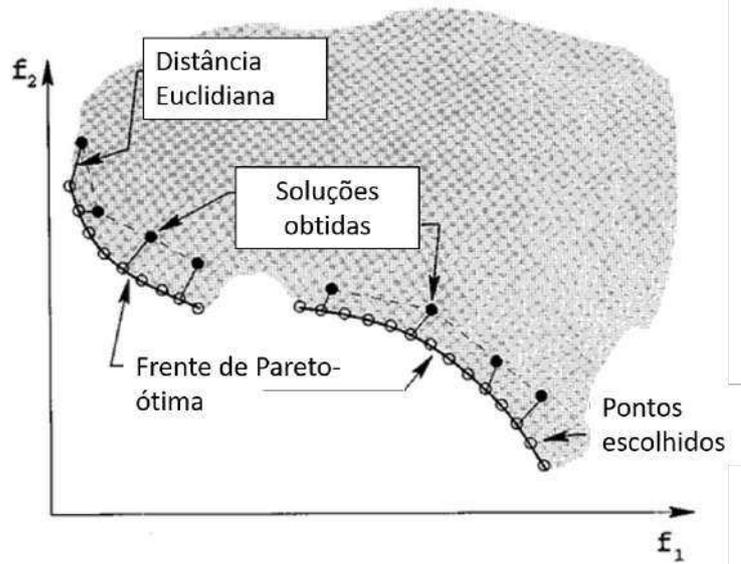


Figura 4.13: Pontos de interesse para avaliação da métrica *generational distance* (GD) (DEB et al., 2002).

onde  $\hat{d}$  representa a distância euclidiana ( $p = 2$ ) de  $z_i \in Z$  até o ponto mais próximo  $a_i \in A$ .

Finalmente, a métrica usada no presente trabalho, proposta por Ishibuchi et al. (2015), utiliza uma forma modificada da distância entre os pontos de  $A$  e  $Z$ , em comparação das utilizadas no *generational distance* (GD) e *inverted generational distance* (IGD). Esta forma de cálculo da distância leva em consideração a relação de dominância entre as soluções  $a_i \in A$  e os pontos de referência  $z_i \in Z$  quando calculando suas distâncias (ISHIBUCHI et al., 2015). Se a solução  $a_i \in A$  é dominada pelo ponto de referência  $z_i \in Z$ , a distância euclidiana é utilizada para o cálculo de sua distância sem nenhuma modificação (ver figura 4.14a e equação 4.7) (ISHIBUCHI et al., 2015). Entretanto, se os pontos avaliados  $a_i$  e  $z_i$  são não-dominados entre si, calcula-se a distância mínima do ponto de referência  $z_i$  para a região dominada pela solução  $a_i$  conforme  $d_i^+ = \max\{a_i - z_i, 0\}$ ,  $i = 1, 2, \dots, m$ , onde  $m$  é o número de objetivos do problema (ver figura 4.14b) (ISHIBUCHI et al., 2015). A figura 4.14 ilustra estes dois cenários para cálculo de  $d_i^+$ . Após isto, a métrica modificada de *inverted generational distance*, i.e., *inverted generational distance plus* ( $IGD^+$ ) é avaliada conforme equação 4.9 (ISHIBUCHI et al., 2015):

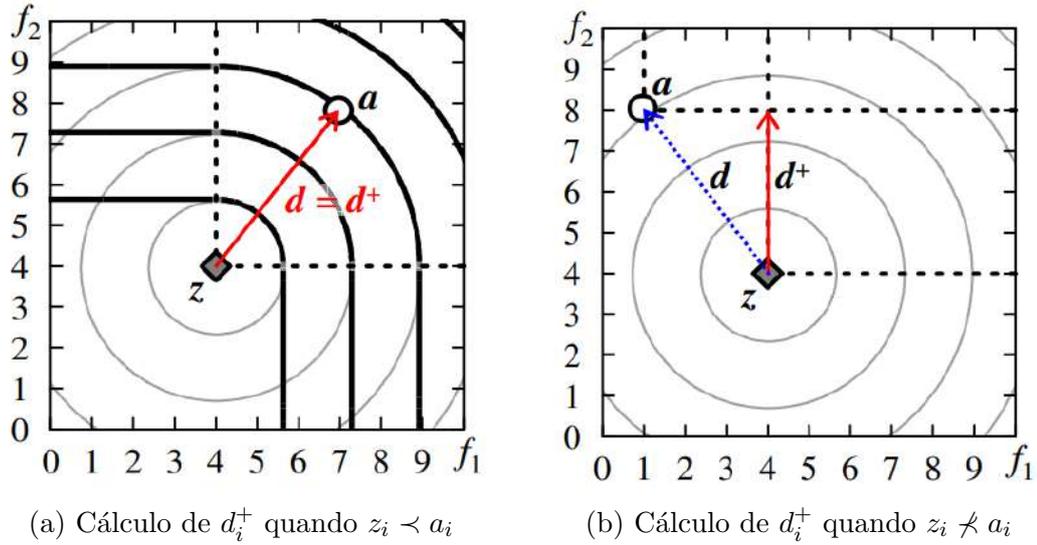


Figura 4.14: Ilustração dos dois vetores distância  $\mathbf{d}$  (distância euclidiana) e  $\mathbf{d}^+$  (ISHIBUCHI et al., 2015)

$$IGD^+(A) = \frac{1}{|Z|} \left( \sum_{i=1}^{|Z|} d_i^{+2} \right)^{1/2}, \quad (4.9)$$

#### 4.4.2 Hipervolume

Outra medida unária que avalia tanto a convergência quanto a diversidade da frente de pareto é o hipervolume, proposta por Zitzler e Thiele (1999) e ilustrado pela região hachurada da Figura 4.15 para problemas onde todos os objetivos são considerados problemas de minimização (Van Veldhuizen, 1999; ZITZLER; THIELE, 1998). Matematicamente, para cada solução  $a_i \in A$ , um hiper-cubo  $V_i$  é construído com um ponto de referência  $W$  fixo e uma solução  $a_i$  como os vértices diagonais do hiper-cubo. O ponto de referência pode ser simplesmente construído através de um vetor onde suas componentes são os piores valores de cada função objetivo encontrado pelo conjunto de soluções (DEB, 2001). A partir disso, a união de todos os hipercubos é encontrada e seu hipervolume (HV) é calculado:

$$HV = volume \left( \bigcup_{i=1}^{|A|} V_i \right). \quad (4.10)$$

Esta métrica não é livre de arbitrariedades da escala dos objetivos. Por exemplo, se a primeira função objetivo retorna valores com uma ordem de magnitude maior do que

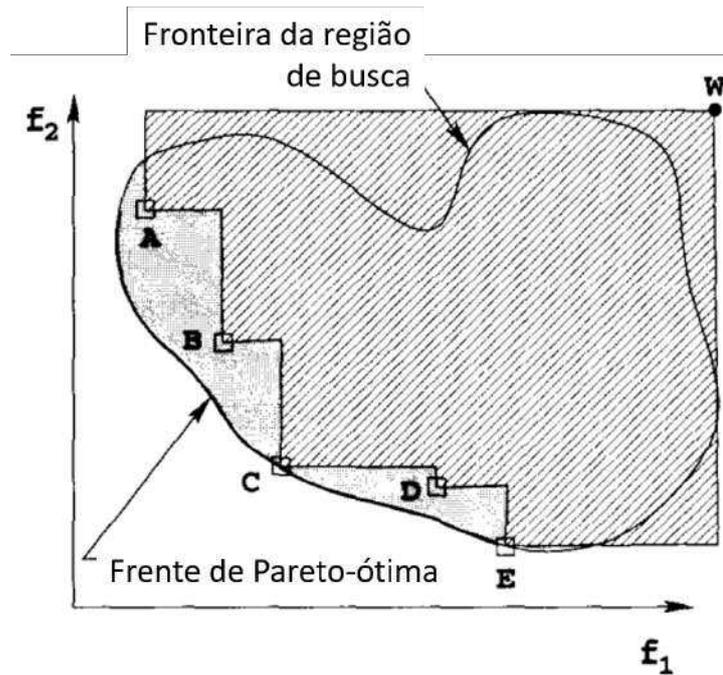


Figura 4.15: O hipervolume gerado pelas soluções não-dominadas (DEB, 2001).

a retornada pela segunda função objetivo, uma melhora unitária em  $f_1$  reduziria o HV muito mais do que uma melhora unitária em  $f_2$ . Assim, esta métrica irá favorecer um conjunto  $A$  que tenha soluções com melhor convergência para funções objetivo com menor escala (DEB, 2001). Para eliminar esta dificuldade, a métrica acima pode ser calculada utilizando os valores normalizados das funções objetivo (DEB, 2001). Para um problema onde todos os objetivos normalizados são de minimização, o melhor (i.e., máximo) valor do HV é de 1 (quando  $A = Z$ ).

## 4.5 SMS-EMOA

Conforme discutido anteriormente, a medida de do hipervolume HV ou métrica  $\mathcal{S}$  é de grande importância e é frequentemente aplicada como medida de qualidade para comparar resultados de algoritmos evolutivos em otimização multi-objetivo (*evolutionary multi-objective optimisation algorithms* - EMOA) (BEUME; NAUJOKS; EMMERICH, 2007). Em comparação com o NSGA-II, a ideia por trás do EMOA apresentado por Beume, Naujoks e Emmerich (2007), i.e., o  $\mathcal{S}$  *metric selection* EMOA (SMS-EMOA) é de focar explicitamente na maximização do hipervolume ao longo do processo de otimização. Um

algoritmo é proposto de forma a caracterizar um operador de seleção baseado na medida de hipervolume, ao invés do *crowding distance* aplicado no NSGA-II por Deb et al. (2002), combinado com o conceito já apresentado de ordenação por não-dominância. A seleção das soluções candidatas ocorre de acordo com a suas contribuições individuais para o hipervolume total (BEUME; NAUJOKS; EMMERICH, 2007) (i.e.,  $V_i$  apresentado na seção 4.4.2 anterior), que pode ser visualizado através do exemplo da figura 4.16; a contribuição no hipervolume favorece a solução  $y_8$  mais do que  $y_9$  (BEUME; NAUJOKS; EMMERICH, 2007). O motivo de se introduzir um segundo algoritmo de otimização é para comparar a performance de cada um (SMS-EMOA e NSGA-II) na resolução do problema a ser estudado no presente trabalho.

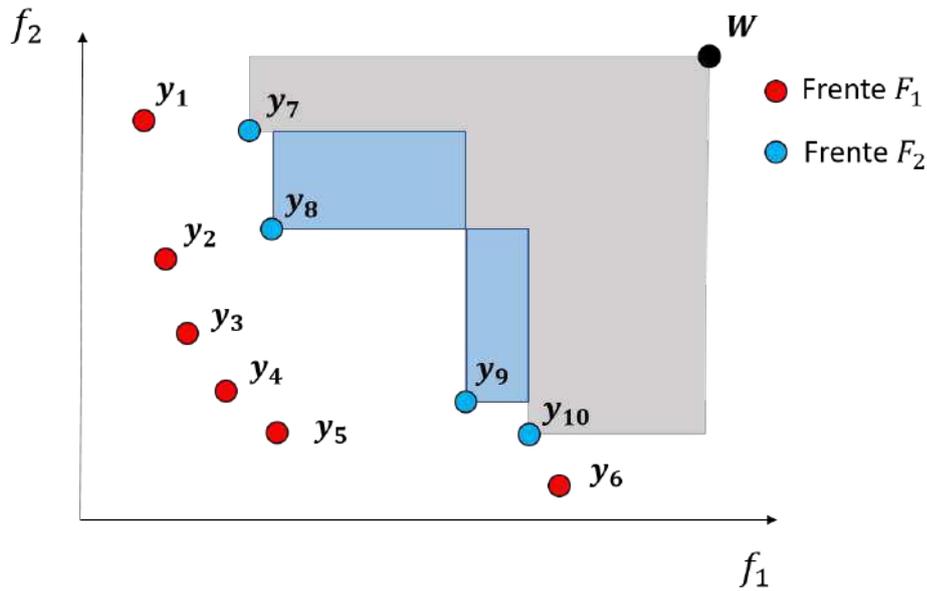


Figura 4.16: O hipervolume dominado pela frente  $\mathcal{F}_2 = \{y_7, \dots, y_{10}\}$  está colorido em cinza claro e as contribuições  $\Delta_{\mathcal{S}}(y_8, \mathcal{F}_2)$  e  $\Delta_{\mathcal{S}}(y_9, \mathcal{F}_2)$  são visualizadas pelos retângulos em azul (BEUME; NAUJOKS; EMMERICH, 2007).

Fleischer (2003) provou que, dado um espaço de busca finito e um ponto de referência, a maximização da medida do hipervolume é equivalente a encontrar a frente de Pareto. Portanto, um conjunto de soluções de tamanho limitado que obtenha o máximo valor da métrica  $\mathcal{S}$  que seja possível para um determinado tamanho do espaço, consiste apenas de soluções ótimas de Pareto (BEUME; NAUJOKS; EMMERICH, 2007). Foi observado empiricamente que, para um número fixo de pontos, a maximização da métrica do hipervolume produz subconjuntos da frente de Pareto que são bem distribuídos (KNO-

WLES; CORNE; FLEISCHER, 2003; EMMERICH; BEUME; NAUJOKS, 2005).

O SMS-EMOA foi desenvolvido para cobrir o máximo hipervolume com um número finito de pontos (BEUME; NAUJOKS; EMMERICH, 2007). Ele é um algoritmo baseado em dois pilares : (1) ordenação por não-dominância é usada como critério de ranqueamento e (2) o hipervolume é aplicado como critério de seleção para descartar o indivíduo que menos contribui com o hipervolume na frente pior ranqueada (BEUME; NAUJOKS; EMMERICH, 2007). O algoritmo é descrito de forma geral no Algoritmo 8, sendo bastante similar ao NSGA-II. No entanto eles diferem no processo de selecionar os indivíduos para a próxima geração (i.e., o método *Reduzir()* no Algoritmo 8). Começando com uma população de  $\mu$  indivíduos, novos indivíduos são gerados através dos operadores de variação já discutidos (*simulated binary crossover* (SBX) e mutação polinomial) (BEUME; NAUJOKS; EMMERICH, 2007). Um novo indivíduo se tornará membro da população da próxima geração se a sua inserção na população (i.e., o novo indivíduo substitui outro indivíduo da população) levar a um aumento da medida  $\mathcal{S}$ .

---

**Algoritmo 8:** Processo base de funcionamento do SMS-EMOA (BEUME; NAUJOKS; EMMERICH, 2007)

---

```

1 início
2   Inicializa  $P_0$  /*Inicializa a população de  $\mu$  individuos aleatoriamente*/;
3    $t \leftarrow 0$ ;
4   while CRITERIO DE PARADA não é satisfeito do
5     Gera  $q_{t+1} \leftarrow Gerar(P_t)$  /*gera os vetores filhos através dos
6     operadores de variação*/;
7     Reduzir  $P_{t+1} \leftarrow Reduzir(P_t \cup \{q_{t+1}\})$  /*seleciona os  $\mu$  melhores
8     individuos*/;
9      $t \leftarrow t + 1$ 
10  end while
11 fim

```

---

O procedimento *Reduzir()*, descrito em maiores detalhes no Algoritmo 9, seleciona os  $\mu$  indivíduos da população subsequente. O algoritmo *fast-nondominated-sort* usado no NSGA-II (descrito no Algoritmo 4) é aplicado para partição da população em  $\nu$  conjuntos  $\mathcal{R}_1, \dots, \mathcal{R}_\nu$  de acordo com a ordenação por *rank* de não-dominância. Em seqüência, um indivíduo é descartado da frente pior ranqueada. Sempre que esta frente consista de  $|\mathcal{R}_\nu| > 1$  indivíduos, o indivíduo  $s \in \mathcal{R}_\nu$  eliminado é aquele que minimiza a seguinte relação:

$$\Delta_s(s, \mathcal{R}_\nu) := \mathcal{S}(\mathcal{R}_\nu) - \mathcal{S}(\mathcal{R}_\nu \setminus \{s\}). \quad (4.11)$$

---

**Algoritmo 9:** Reduzir( $P$ ) (BEUME; NAUJOKS; EMMERICH, 2007)

---

**Entrada:** População a ser reduzida, ( $P$ )  
**Saída:**  $P \setminus \{r\}$   
**1** /\*sendo  $r$  o indivíduo eliminado \*/;  
**2 início**  
**3**     $\{\mathcal{R}_1, \dots, \mathcal{R}_\nu\} \leftarrow \text{fast} - \text{nondominated} - \text{sort}(P)$  /\* todas as  $\nu$  frentes  
       (diferentes *ranks*) de  $P$  \*/;  
**4**     $r \leftarrow \text{argmin}_{s \in \mathcal{R}_\nu} [\Delta_s(s, \mathcal{R}_\nu)]$  /\*  $s \in \mathcal{R}_\nu$  com menor  $\Delta_s(s, \mathcal{R}_\nu)$  \*/;  
**5**    **retorna** ( $P \setminus \{r\}$ )  
**6 fim**

---

O valor de  $\Delta_s(s, \mathcal{R}_\nu)$  pode ser interpretado como a contribuição exclusiva de  $s$  para o valor da métrica  $\mathcal{S}$  de sua determinada frente (i.e., *rank* na ordenação). Por definição de  $\Delta_s(s, \mathcal{R}_\nu)$ , um indivíduo, o qual domina outro é sempre mantido e nenhum indivíduo não-dominado é substituído por um indivíduo dominado. Essa medida mantém aqueles indivíduos que maximizam o valor da medida  $\mathcal{S}$  da população, o que implica que o hipervolume cobrido pela população não pode diminuir com a aplicação do operador de seleção *Reduzir()* (BEUME; NAUJOKS; EMMERICH, 2007). Assim, para o Algoritmo 8, o seguinte invariante se mantém:  $\mathcal{S}(P_t) \leq \mathcal{S}(P_{t+1})$  (BEUME; NAUJOKS; EMMERICH, 2007).

## 4.6 Critérios de convergência/parada

Sempre que um algoritmo é executado, é necessário decidir em cada iteração se a otimização deve continuar ou não. O término do procedimento de otimização é importante, pois rodar o algoritmo por um número de iterações não o suficiente pode levar a resultados insatisfatórios; entretanto, rodar com um número de iterações extenso demais pode desperdiçar avaliações da função objetivo, assim como recursos computacionais (Blank; Deb, 2020). Existem muitas formas diferentes, baseadas em uma série de critérios, de como se determinar quando a execução de um algoritmo deve ser finalizada.

O término pode ser simplesmente atingido fornecendo um limite superior do número de avaliações das funções objetivo *n\_max\_evals* ou o número de gerações/iterações

$n\_max\_gen$ . Em cada iteração, após a verificação do critério adotado, quando o número de avaliações das funções objetivo ou o número gerações for maior do que este limite, o algoritmo termina (Blank; Deb, 2020). Outros critérios comumente utilizados são os movimentos no espaço dos objetivos  $f\_tol$ , a convergência no espaço das restrições  $cv\_tol$  e as mudanças no espaço de busca das variáveis de decisão  $x\_tol$ , os quais são todos baseados em uma tolerância (Blank; Deb, 2020). Além disso, vale a pena mencionar que o critério de parada por tolerâncias é baseado em uma janela (*sliding window*) das últimas  $n\_last$  gerações, ao invés de apenas da última geração, para o cálculo dos critérios e comparação das tolerâncias definidas pelo usuários (Blank; Deb, 2020).

Ambos os algoritmos evolutivos apresentados anteriormente param quando o *CRITÉRIO DE PARADA* é alcançado. Em ambos os algoritmos, o critério de parada adotado é o mesmo e é apresentado conforme os Algoritmos 10 e 11 abaixo.

---

**Algoritmo 10:** critério de parada (Blank; Deb, 2020)

---

```

Entrada: termination.has_terminated() → retorna False
1 início
2   while termination.has_terminated() == False do
3     avaliação;
4     recombinação + mutação;
5     seleção;
6     :
7
8     termination.update()
9   end while
10 fim

```

---

Cada um dos critérios de parada acima mencionados possuem uma função `criterion.update()` diferente entre si, utilizada conforme Algoritmo 11. A medida que o algoritmo avança nas iterações, estas funções atualizam podendo alterar o valor retornado por `termination.has_terminated()` para `True`, atingindo assim o critério de parada. O critério  $n\_max\_gen\_criterio$  apenas verifica se a iteração/geração atual é maior do que o limite de gerações/iterações imposto pelo usuário, conforme Algoritmo 12 mostra. Os outros 3 critérios levam em consideração uma tolerância e verificam se as mudanças no espaço de busca, restrições e objetivos foram menores do que cada tolerância (para cada espaço) durante uma janela das últimas  $n\_last$  gerações. De maneira semelhante, todos

**Algoritmo 11:** `termination.update()` (Blank; Deb, 2020)

---

**Entrada:** `x_tol_critério`  
`cv_tol_critério`  
`f_tol_critério`  
`n_max_gen_critério`

```

1 início
2   critérios = [x_tol_critério, cv_tol_critério, f_tol_critério,
3               n_max_gen_critério];
4   p = [];
5   for cada critério em critérios do
6     | p.append(critério.update())
7   end for
8   if qualquer(p==True) then
9     | termination.has_terminated() → return True
10  end if
11 fim

```

---

funcionam de acordo com o procedimento descrito pelo Algoritmo 13, diferindo entre si apenas nos dados *prev* and *current* utilizados no cálculo de *delta* (mudança no espaço avaliado: de busca, dos objetivo e restrições) e na forma como se calcula *delta*.

**Algoritmo 12:** `criterion.update()` - `n_max_gen_critério` (Blank; Deb, 2020)

---

**Entrada:** Número da geração atual `n_gen`  
Limite de gerações `n_max_gen`

```

1 início
2   if n_gen > n_max_gen then
3     | return True /*critério de parada atingido*/
4   end if
5 fim

```

---

Conforme mencionado, a função `calculate_delta()` é diferente para cada critério de parada, assim como os dados utilizados das iterações/gerações atual e anterior. Estas diferenças são evidenciadas nos Algoritmos 14, 15 e 16, respectivamente.

## 4.7 Tomador de decisão multi-critério

Ao longo dos anos de pesquisa em algoritmos evolutivos em otimização multi-objetivo, os algoritmos têm mostrado amplamente que são capazes de encontrar múltiplas e diversas soluções de Pareto-ótimas (ou próximas da frente de Pareto-ótima) em uma única rodada. É comum questionar o seguinte: como se escolhe uma solução em particular do conjunto

---

**Algoritmo 13:** `criterion.update()` - `x_tol_critério`, `cv_tol_critério` e `f_tol_critério` (Blank; Deb, 2020)

---

**Entrada:** Dados da geração anterior, *prev*,  
 Dados da geração atual, *current*,  
 Tolerância definida pelo usuário, *tol*

```

1 início
2   delta = calculate_delta(prev, current) /*Calcula a variação entre
   iteração de acordo com o método de cada critério*/;
3   se delta ≤ tol então
4     Count = Count + 1;
5     if Count ≥ n_last then
6       retorna True /*critério de parada atingido*/
7     end if
8   senão
9     Count = 0;
10  fim se
11 fim
```

---



---

**Algoritmo 14:** `delta.calculate()` - `x_tol_critério` (Blank; Deb, 2020)

---

**Entrada:** Dados da geração anterior, *prev*,  
 Dados da geração atual, *current*.

```

1 início
2   prev.X      /*A matriz M por NX das variáveis de decisão da geração
   anterior. M indivíduos e NX variáveis de decisão*/;
3   current.X   /*Matriz das variáveis de decisão da geração atual*/;
4
5   problem.x.upper_bound /*O vetor de limites superiores das
   variáveis de decisão do problema*/;
6   problem.x.lower_bound /*O vetor de limites inferiores das variáveis
   de decisão do problema*/;
7
8   /*normaliza os valores das variáveis da matriz de variáveis de decisão
   em relação aos limites superior/inferior*/
9   current.Xnorm =
   normalize(current.X, problem.x.upper_bound, problem.x.lower_bound);
10
11  previous.Xnorm =
   normalize(previous.X, problem.x.upper_bound, problem.x.lower_bound);
12
13  /*calcula o IGD do conjunto de variáveis de decisão da geração anterior
   em relação ao conjunto da geração atual, i.e., mudança no espaço de
   busca de uma geração para a outra*/
14  delta_x = IGD(current.Xnorm, previous.Xnorm);
15  retorna delta_x
16 fim
```

---

**Algoritmo 15:** delta\_calculate() - cv\_tol\_critério (Blank; Deb, 2020)

---

**Entrada:** Dados da geração anterior, *prev*,  
 Dados da geração atual, *current*.

**1 início**

**2**    *prev.CV*        /\* O vetor 1xM do grau de violação das restrições da  
                       geração anterior. M indivíduos\*/;

**3**    *current.CV*    /\*O vetor do grau de violação das restrições da geração  
                       atual\*/;

**4**

**5**    *prev.CV* = **min**(*prev.CV*)    *current.CV* = **min**(*current.CV*)

**6**    **retorna** **max**(0, *prev.CV* - *current.CV*)

**7 fim**

---

de soluções não-dominadas encontradas? (DEB, 2001). A abordagem do vetor de pseudo-pesos é um dos diversos critérios de tomador de decisão, proposto por Deb (2001), e será a abordagem aplicada no presente trabalho.

Nesta abordagem, um vetor de pseudo-pesos é calculado para cada solução obtida na frente de Pareto e é considerado problema de minimização apenas (DEB, 2001). Das soluções obtidas, os valores mínimo  $f_i^{min}$  e máximo  $f_i^{max}$  de cada função objetivo  $i$  são apontados. Após isso, a seguinte equação é usada para calcular o peso  $w_i$  para o valor da  $i$ -ésima função objetivo em cada solução (DEB, 2001):

$$w_i = \frac{(f_i^{max} - f_i(\mathbf{x})) / (f_i^{max} - f_i^{min})}{\sum_{m=1}^M (f_m^{max} - f_m(\mathbf{x})) / (f_m^{max} - f_m^{min})}. \quad (4.12)$$

A Equação 4.12 calcula a distância relativa da solução até o pior valor (máximo) encontrado em cada função objetivo. Assim, para a melhor solução para o  $i$ -ésimo objetivo, o peso  $w_i$  é máximo. A parcela  $f_i^{max} - f_i(\mathbf{x})$  do numerador da Equação 4.12 garante que a soma do componente de todos os pesos para uma solução seja igual a um (DEB, 2001). A Figura 4.17 mostra um conjunto de soluções não-dominadas e seus pseudo-pesos para ambos os objetivos.

Uma vez que os vetores peso são calculados para todas as soluções da frente de Pareto, uma simples estratégia é necessária para se escolher a solução mais próxima a um vetor de pesos definido pelo usuário, segundo preferências de projeto para cada um dos objetivos. Como mostra a Figura 4.17, se um peso de 90% para o objetivo  $f_2$  e um peso de 10% para o objetivo  $f_1$  são desejados pelo usuário, a escolha correspondente a esta

**Algoritmo 16:** delta\_calculate() - f\_tol\_critério (Blank; Deb, 2020)

---

**Entrada:** Dados da geração anterior, *prev*,  
 Dados da geração atual, *current*.

- 1 **início**
- 2     *prev.F*       /\*A matriz MxN dos valores das funções objetivo da  
 geração anterior. M indivíduos e N funções objetivo\*/;
- 3     *current.F*   /\*matriz dos valores das funções objetivo da geração  
 atual\*/;
- 4
- 5     /\*avaliação dos pontos *ideal* e *nadir* da geração atual (ver figura 4.19  
 para visualização de tais pontos no espaço dos objetivos)\*/
- 6     *ideal\_C* = **min**(*Current.F*)   /\*valores mínimos de cada um dos N  
 objetivos considerando as M soluções\*/;
- 7     *nadir\_C* = **max**(*Current.F*)   /\*valores máximos de cada um dos N  
 objetivos considerando as M soluções\*/;
- 8     *norm* = *nadir\_C* - *ideal\_C*   /\*este é o intervalo entre os pontos *ideal*  
 e *nadir*\*/;
- 9
- 10    /\*pegando os pontos *ideal* e *nadir* da geração anterior\*/
- 11    *ideal\_P* = **min**(*previous.F*)   /\*valores mínimos de cada um dos N  
 objetivos considerando as M soluções\*/;
- 12    *nadir\_P* = **max**(*previous.F*)   /\*valores máximos de cada um dos N  
 objetivos considerando as M soluções\*/;
- 13
- 14    *delta\_ideal* = **max**(|((*ideal\_C* - *ideal\_P*)/*norm*)|)   /\* calcula a  
 mudança do ponto *ideal* anterior para o atual\*/;
- 15    *delta\_nadir* = **max**(|((*nadir\_C* - *nadir\_P*)/*norm*)|) /\* calcula a  
 mudança do ponto *nadir* anterior para o atual \*/;
- 16
- 17    /\*normaliza os valores das funções objetivos da geração anterior e atual  
 com relação aos pontos *ideal* e *nadir* atuais\*/
- 18    *c<sub>N</sub>* = *normalize*(*current.F*, *ideal\_C*, *nadir\_C*);
- 19    *p<sub>N</sub>* = *normalize*(*previous.F*, *ideal\_C*, *nadir\_C*);
- 20
- 21    /\*calcula o IGD da frente de pareto anterior com relação à frente atual,  
 i.e. mudança no espaço dos objetivos de uma geração para a outra\*/  
    *delta\_f* = *IGD*(*c<sub>N</sub>*, *p<sub>N</sub>*)
- 22    ;
- 23    **retorna** max(*delta\_ideal*, *delta\_nadir*, *delta\_f*)
- 24 **fim**

---

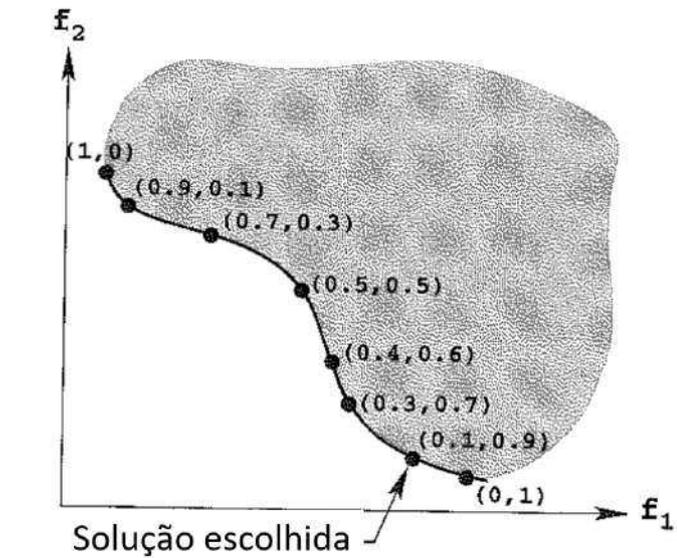


Figura 4.17: A solução ótima escolhida utilizando a abordagem dos vetores de pesos (DEB, 2001).

configuração é marcada na figura (DEB, 2001).

Também é importante mencionar que antes de se empregar qualquer técnica, deve-se notar que os objetivos têm uma escala diferente entre si. Como se pode observar na Figura 4.18, o primeiro objetivo irá dominar qualquer cálculo na distância no espaço dos objetivos em razão de sua maior escala. Lidar com objetivos de diferentes escalas é uma parte inerente de qualquer algoritmo multi-objetivo, e, assim, uma normalização dos valores é necessário (Blank; Deb, 2020). Uma forma comum de normalização dos valores das funções objetivo de uma frente de Pareto é utilizando os ditos pontos *ideal* e *nadir* (ver Figura 4.19). Entretanto, para o propósito do tomador de decisão e de forma a generalizar, assume-se que tais pontos *ideal* e *nadir* (também referidos como pontos de extremidade) assim como a frente de Pareto não são conhecidos. Tais pontos podem ser aproximados por:  $approx\_ideal = (f_1^{min}, f_2^{min}, f_3^{min}, \dots, f_M^{min})$  e  $approx\_nadir = (f_1^{max}, f_2^{max}, f_3^{max}, \dots, f_M^{max})$ . Normalizando os valores obtidos das funções objetivo com relação aos pontos de extremidade é relativamente simples fazendo a frente de Pareto normalizada  $F_{norm.} = (F_i - approx\_ideal) / (approx\_nadir - approx\_ideal)$ , onde  $F_i$  é cada solução na frente de Pareto originalmente obtida pelo algoritmo evolutivo (Blank; Deb, 2020).

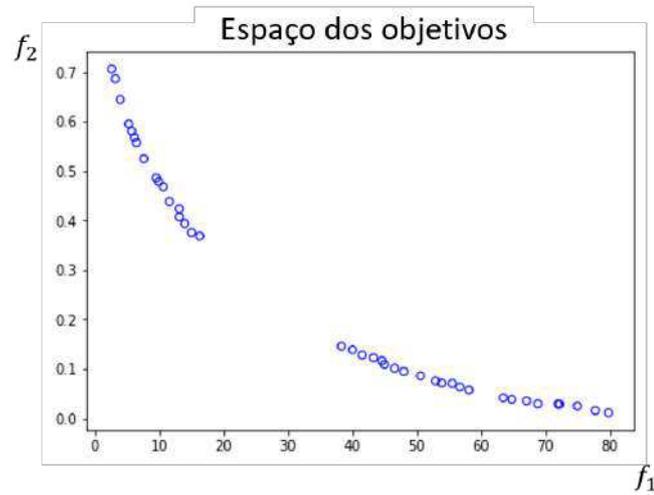


Figura 4.18: Comparação das diferentes escalas dos objetivos  $f_1$  e  $f_2$ . Os limites inferiores e superiores de ambos os objetivos são *Escala  $f_1$* : [2.5854948741290507, 79.76691689089954] e *Escala  $f_2$* : [0.011423710054466784, 0.7065147569542829] (Blank; Deb, 2020).

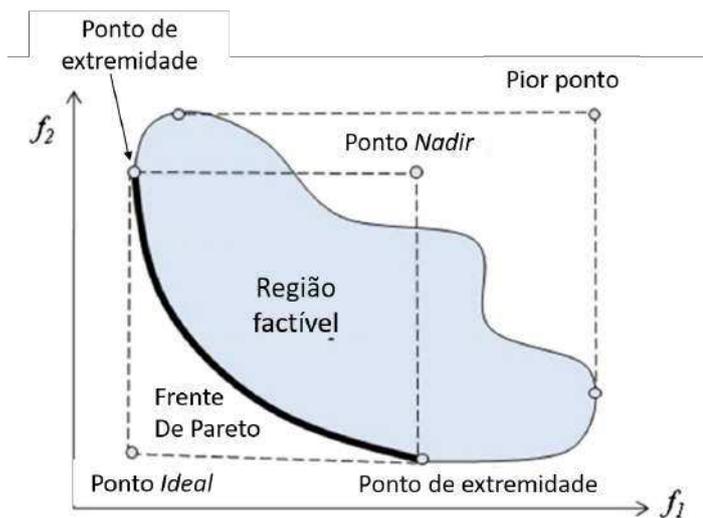


Figura 4.19: Ilustração dos pontos importantes para problemas de otimização multi-objetivo (WANG; HE; YAO, 2017)

## 5 Experimentos numéricos e resultados

No presente capítulo aplicam-se, em dois estudos de caso, os conceitos de modelagem do desempenho de parques eólicos, vistos nos Capítulos 2 e 3, e as técnicas de otimização, vistas no Capítulo 4, em um problema de otimização multiobjetivo da configuração de parques eólicos *offshore*. Em se tratando da configuração de um parque eólico, refere-se ao seu *layout*, i.e., a disposição das turbinas na região do parque, e os modelos de turbinas eólicas que irão operar no parque eólico otimizado. Para alcançar este objetivo, levantou-se, na Seção 5.1 do presente capítulo, um total de 25 modelos diferentes de turbinas eólicas *offshore* (ver Tabela 5.1), a serem consideradas pelos algoritmos evolucionários para a composição de um parque eólico, o qual irá contar com um total de 30 turbinas instaladas. O regime de ventos anual considerado, bem como a sua discretização, para ambos os estudos de caso, é abordado na Seção 5.2, assim como as considerações meteorológicas e de rugosidade superficial para composição do perfil atmosférico vertical de velocidades.

As Seções 5.3 e 5.4.3 abordam questões relevantes a serem consideradas em um projeto de otimização de parques eólicos. A Seção 5.3 considera uma restrição de proximidade entre turbinas eólicas a qual vai limitar, por razões de desempenho e segurança, a proximidade de duas turbinas adjacentes através de um distanciamento mínimo permitido, sendo assim necessário que o *layout* proposto pelos algoritmos de otimização respeite esta restrição para todas as turbinas instaladas no parque. Já a seção 5.4.3 considera, e tenta minimizar, o número de modelos diferentes de aerogeradores presentes nos parques eólicos. Esta consideração visa fazer um *trade-off* entre o ganho de desempenho e o número de diferentes modelos de turbinas. Esta situação proporciona a alocação de modelos de turbinas diferentes, sem que o parque eólico resultante da otimização tenha demasiados modelos diferentes de aerogeradores, o que gera problemas para operação e manutenção do empreendimento.

A formulação dos problemas de otimização de cada um dos dois estudos de caso está apresentada na Seção 5.4. Por fim, as Seções 5.5 e 5.6 apresentam os parâmetros utilizados nos algoritmos evolucionários (NSGA-II e SMS-EMOA) e os resultados obtidos

por cada caso, respectivamente.

## 5.1 Modelos de turbinas eólicas

Conforme mencionado, é propósito dos dois estudos de caso do presente trabalho determinar quais modelos de aerogeradores, dentre os 25 aqui pré-selecionados, serão escolhidos para compor a configuração do parque eólico, o qual contará com um total de 30 turbinas eólicas instaladas. A Tabela 5.1 apresenta os 25 modelos considerados.

Tabela 5.1: Modelos de turbinas eólicas pré-selecionadas

N° modelo	Modelo/Fabricante	Referência	$u_{cut_{in}} / u_{Rated} / u_{cut_{out}}$ [m/s]	$P_{Rated}$ [MW]	$d_0 / z_h$ [m]
0	VestasV80 2MW*	(JENSEN et al., 2011)	3.5 / 14.5 / 25	2	80 / 70
1	Siemens SWT-2.3-93	(THEWINDPOWER.NET, acessado 27 Jun 2022)	3.5 / 13 / 25	2.3	93 / 90
2	Nordex-N90 2.5MW	(THEWINDPOWER.NET, acessado 27 Jun 2022)	3.5 / 14 / 25	2.5	90 / 95
3	VestasV90 3MW	(THEWINDPOWER.NET, acessado 27 Jun 2022)	3.5 / 16.5 / 25	3	90 / 80
4	VestasV112 3MW*	(THEWINDPOWER.NET, acessado 27 Jun 2022)	3 / 12 / 25	3	112 / 94
5	Siemens SWT-3.6-107	(THEWINDPOWER.NET, acessado 27 Jun 2022)	3.5 / 16.5 / 25	3.6	107 / 88
6	Siemens SWT-3.6-120	(THEWINDPOWER.NET, acessado 27 Jun 2022)	3.5 / 14 / 25	3.6	120 / 90
7	Siemens SWT-4.0-130	(THEWINDPOWER.NET, acessado 27 Jun 2022)	2.5 / 12 / 25	4	130 / 90
8	Darwind 5MW*	(RODRIGUES et al., 2016)	4 / 25 / 14	5	115 / 92.5
9	NREL 5MW*	(NREL, 2022)	3 / 11.4 / 25	5	126 / 90
10	NREL 6MW	(NREL, acessado 27 Jun 2022)	4 / 12 / 25	6	150 / 100
11	Siemens SWT-7.0-154	(GROTHER; KäCHELE; WATERMEYER, 2022)	3 / 13 / 25	7	154 / 112
12	VestasV164 8MW*	(THEWINDPOWER.NET, acessado 27 Jun 2022)	4 / 13 / 25	8	164 / 107
13	NREL 8MW	(NREL, acessado 27 Jun 2022)	4 / 12 / 25	8	180 / 112
14	Leanwind 8MW*	(DESMOND et al., 2016)	4 / 12.5 / 25	8	164 / 110
15	Vestas V164/9500	(THEWINDPOWER.NET, acessado 27 Jun 2022)	3.5 / 14 / 25	9.5	164 / 110
16	Vestas V174/9.5MW	(GROTHER; KäCHELE; WATERMEYER, 2022)	3 / 15 / 25	9.5	174 / 110
17	DTU 10MW*	(DESMOND et al., 2016)	4 / 11.4 / 25	10	178.3 / 119
18	IEA 10MW*	(NREL, 2022)	4 / 11 / 25	10	198 / 119
19	NREL 10MW	(NREL, acessado 27 Jun 2022)	4 / 12 / 25	10	205 / 125
20	SiemensGamesa SG11.0-200	(GROTHER; KäCHELE; WATERMEYER, 2022)	3 / 14 / 25	11	200 / 130
21	NREL 12MW	(NREL, acessado 27 Jun 2022)	3 / 11 / 25	12	222 / 136
22	GE Haliade-X 13MW	(GROTHER; KäCHELE; WATERMEYER, 2022)	3 / 14 / 25	13	220 / 140
23	IEA 15MW*	(NREL, 2022)	3 / 10.6 / 25	15	240 / 150
24	NREL 15MW	(NREL, acessado 27 Jun 2022)	4 / 11 / 25	15	248 / 149

Além das informações disponíveis na Tabela 5.1, também são necessárias as curvas de coeficiente de potência,  $C_P(U)$ , para avaliação do desempenho e níveis de conversão das turbinas que operam no parque (ver Seção 2.2) e as curvas de coeficiente de empuxo,  $C_T(U)$ , para avaliação dos efeitos de esteira impostos pela turbina (ver Seção 2.3), que impactam diretamente nos níveis de conversão das demais turbinas à jusante. As Figuras 5.1 e 5.2 apresentam as curvas de coeficiente de potência e de empuxo, respectivamente, dos 25 modelos de turbinas eólicos pré-selecionados da Tabela 5.1.

As curvas de  $C_P(U)$  apresentadas na Figura 5.1 foram obtidas conforme referências de cada modelo de turbina apresentado na Tabela 5.1. Entretanto, as curvas de  $C_T(U)$  não são fornecidas na literatura e catálogos de fabricantes com tanta frequência como as curvas de potência, sendo obtidas apenas para os modelos de turbina marca-

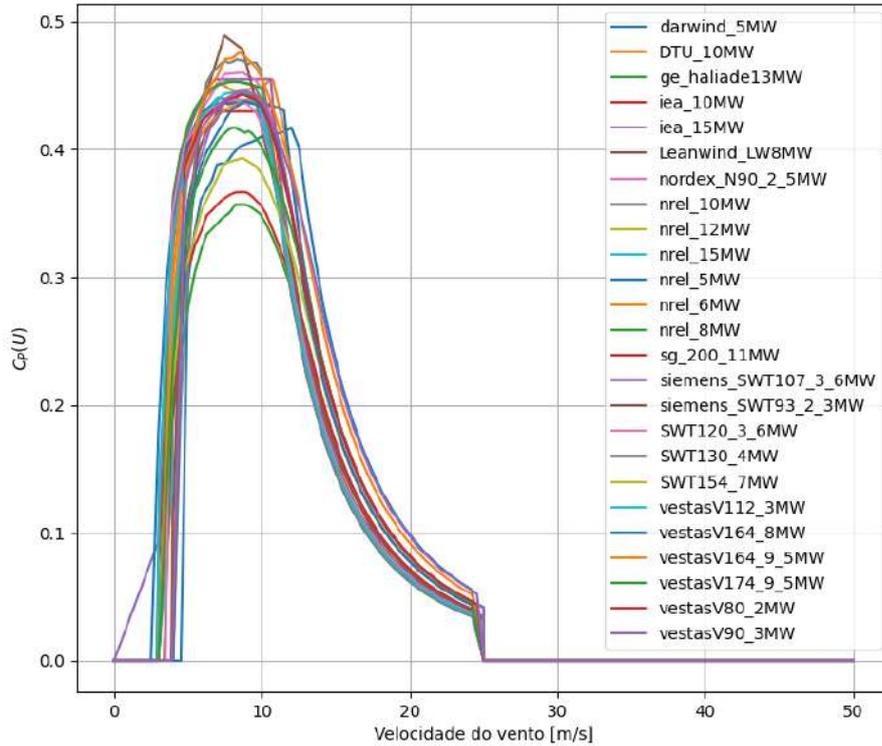


Figura 5.1: Curvas do coeficiente de potência,  $C_P(U)$ .

dos com um (\*) na Tabela 5.1. Com relação à curva de  $C_T(U)$  dos demais modelos, considerou-se uma aproximação por potência nominal  $P_{Rated}$  e/ou fabricante/desenvolvedor do modelo de aerogerador cuja curva de  $C_T(U)$  era conhecida.

## 5.2 Regime anual de ventos

Kirchner-Bossi e Porté-Agel (2018) consideram que a obtenção confiável da potência gerada de um parque eólico, em um dado *layout*, requer o uso de uma rosa dos ventos com uma alta resolução, com  $\Delta\theta = 3^\circ$  e  $\Delta U = 1$  m/s, em concordância com Feng e Shen (2015a). Esta rosa dos ventos com alta resolução leva a mais de 1500 regimes de ocorrência do vento, i.e. diferentes combinações de velocidades do vento e direções a serem avaliadas para cada indivíduo em cada geração ao longo do processo de otimização. Esta quantidade de avaliações de diferentes regimes de vento é algo computacionalmente custoso para aplicação em otimização do *layout* de parques eólicos utilizando-se algoritmos evolutivos. O trabalho de otimização realizado por Kirchner-Bossi e Porté-Agel (2018) resolve esta questão simplificando a rosa dos ventos em 72 setores de direção do vento ( $N_{wd} = 72$ ) e

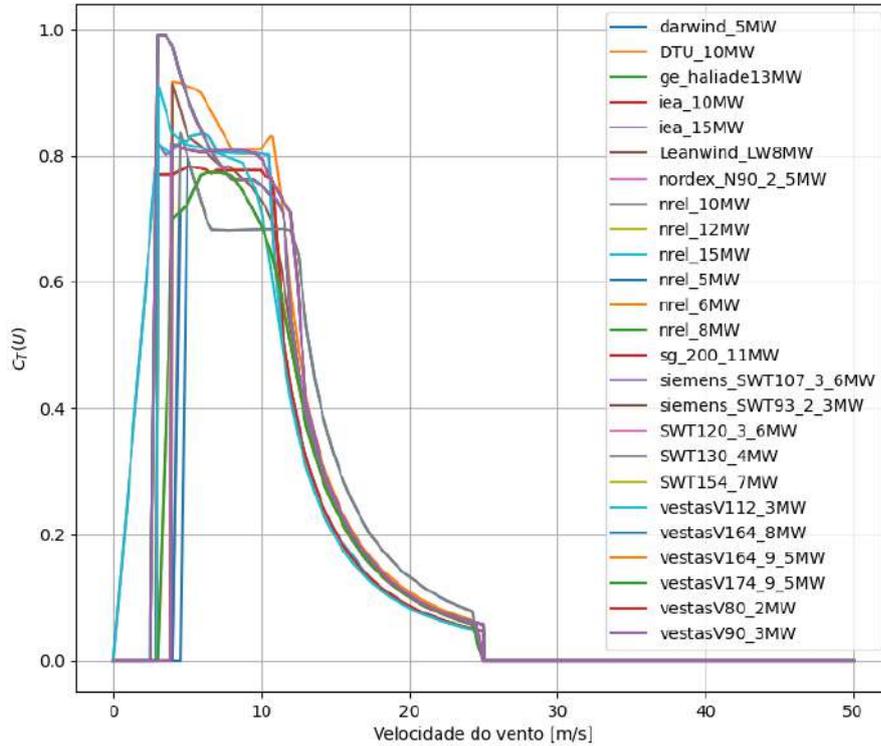


Figura 5.2: Curvas do coeficiente de empuxo,  $C_T(U)$ .

apenas uma velocidade de ocorrência em cada um dos setores ( $N_{ws} = 1$ ). Tendo em vista o escopo do presente trabalho, que além de otimizar o layout do parque eólico, conforme realizado por Kirchner-Bossi e Porté-Agel (2018), também visa otimizar a escolha dos modelos de turbinas eólicas, opta-se por utilizar uma rosa dos ventos discretizada com  $N_{ws} = 10$ , devido aos diferentes modelos de turbinas apresentarem desempenho e efeitos de esteira diferentes em função das velocidades de ocorrência no rotor, como discutido nas Seções 2.2 e 2.3, respectivamente. Também optou-se por uma configuração de rosa dos ventos com 36 setores de direção do vento ( $N_{wd} = 36$ ), ponderando os efeitos discutidos conforme Figura 2.7a e o custo computacional disponível para o desenvolvimento do presente trabalho, resultando assim em uma distribuição com 360 regimes de vento. A discretização dos  $N_{ws} \times N_{wd}$  cenários possíveis de vento é realizada entre um valor mínimo e máximo de velocidade [ $U_{min} = 5$ ,  $U_{max} = 23$ ] [m/s] e direção [ $\theta_{min} = 0$ ,  $\theta_{max} = 350$ ] [°], com incrementos de tamanho  $\Delta U = 2$  m/s para velocidade e  $\Delta \theta = 10^\circ$  para direção do vento. As escolhas dos limites mínimo e máximo de velocidade [ $U_{min}$ ,  $U_{max}$ ] ocorre devido ao regime de operação das turbinas, i.e., entre as velocidades de acionamento,  $u_{cut_{in}}$ , e desacionamento,  $u_{cut_{out}}$ , das turbinas, conforme mostrado na Figura 2.11 e também na

Tabela 5.1. A Figura 5.3 mostra a distribuição de probabilidades de ocorrência de cada regime de vento (combinação de velocidade e direção) ao longo do ano, construída conforme metodologia discutida na Seção 2.1.1 e valores da Figura 2.5 na localidade do parque eólico de Horns Rev.

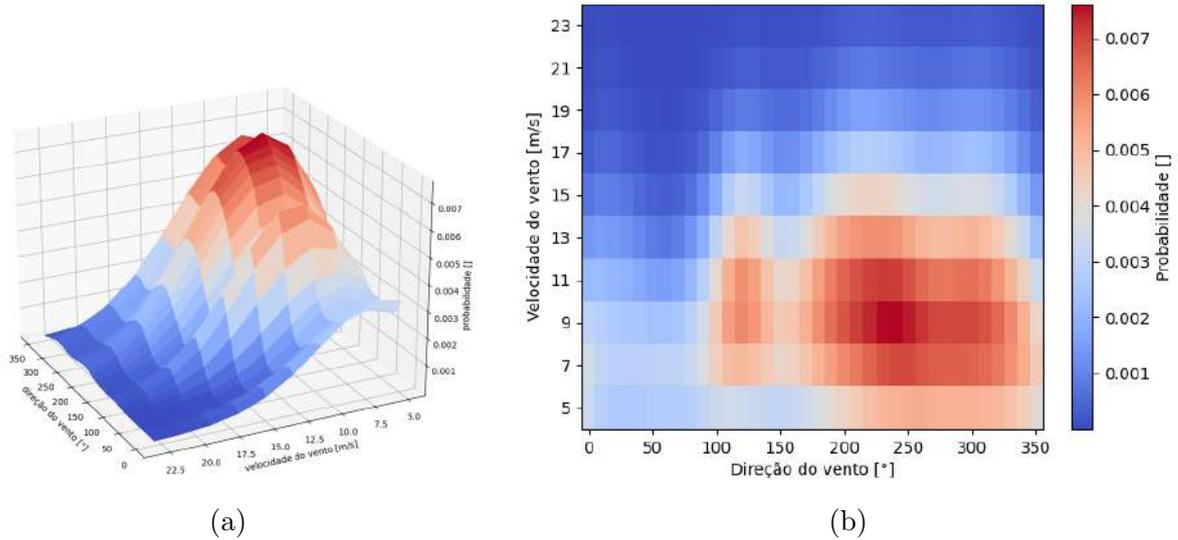


Figura 5.3: Função densidade de probabilidades utilizada nos estudos de caso,  $p(\theta, U(z_r))$ . As figuras mostram o regime anual de ventos no local de instalação do parque eólico.

Conforme descrito na Seção 2.1.2, as velocidades modeladas pela distribuição de probabilidades são as velocidades do vento a uma dada altura de referência, i.e.,  $U(z_r)$ . Para construção do perfil vertical de velocidades,  $U(z)$ , adotou-se um cenário para o parque eólico de estabilidade atmosférica neutra, embora a teoria de similaridade de Monin-Obukhov (ARYA, 2001) forneça uma abordagem semi-empírica para modelar a camada limite atmosférica sob os efeitos de troca de quantidade de movimento e empuxo, devido às condições estáveis ou instáveis (ARYA, 2001; CAPPES; ZENDER, 2009). Esta abordagem, todavia, foge do escopo proposto para o presente trabalho, podendo ser investigada em trabalhos futuros. A adoção de uma estabilidade atmosférica neutra é uma prática comum na avaliação do potencial eólico *offshore* na costa brasileira (de Assis Tavares et al., 2020; PIMENTA et al., 2019) e, conforme descrito na Seção 2.1.2, permite o uso dos perfis verticais segundo lei logarítmica ou de potência. Para o presente trabalho, os parâmetros a seguir foram considerados e a Figura 5.4 apresenta todos os perfis verticais de velocidade livre considerados para cada uma das velocidades de referência ( $U(z_r)$ )

presentes na distribuição de probabilidades anuais,  $p(\theta, U(z_r))$ .

Parâmetros:

- massa específica do ar:  $\rho = 1.225 \text{ kg/m}^3$ ;
- altura de referência:  $z_r = 70 \text{ m}$ ;
- coeficiente de cisalhamento perfil vertical de velocidades:  $\alpha = 0.1$  (Equação 2.13 ou 2.14);
- intensidade de turbulência ambiente:  $I_0 = 0.08$

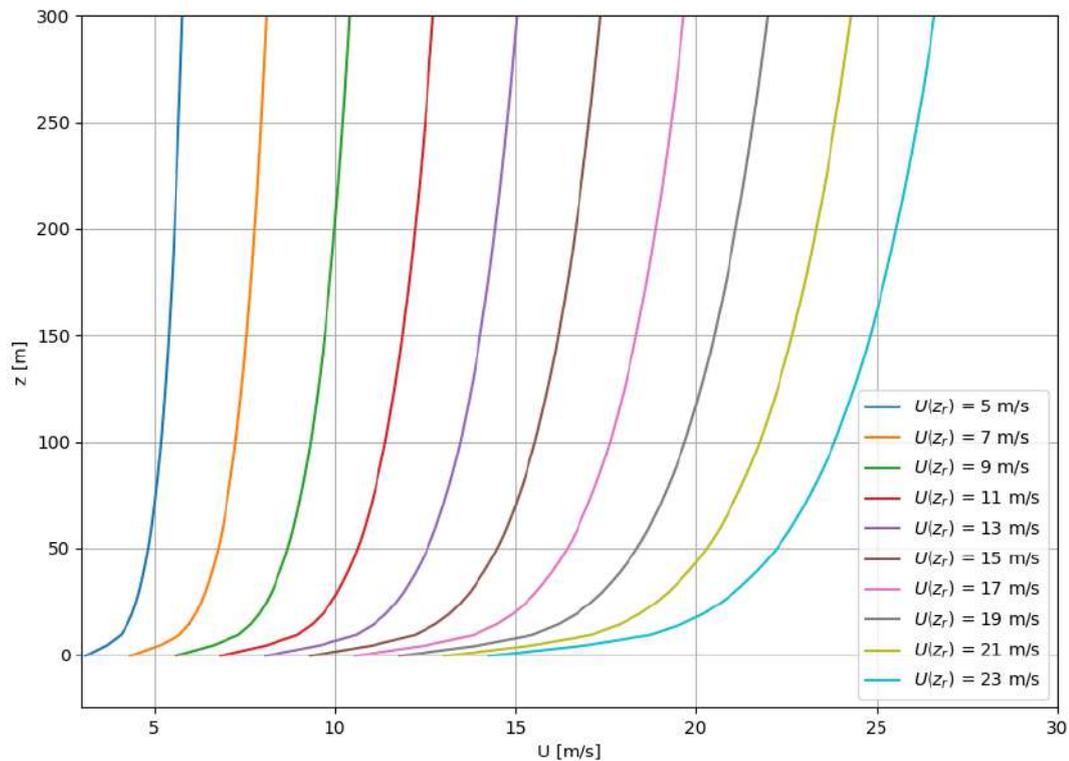


Figura 5.4: Perfis verticais de velocidade,  $U(z)$  extraído do FLORIS, (segundo lei de potência da Equação 2.12) para cada uma das  $N_{ws}$  velocidades ( $U(z_r)$ ) discretizadas em  $p(\theta, U(z_r))$  da Figura 5.3.

## 5.3 Restrição de proximidade entre turbinas

A instalação das turbinas em parques eólicos requer uma quantidade significativa de planejamento, coordenação e projeto. Antes que as turbinas eólicas possam ser instaladas e conectadas a um sistema elétrico, é necessário determinar os locais exatos para instalação das futuras turbinas. Uma das principais considerações é maximizar a captação de energia, porém inúmeras restrições podem limitar onde as turbinas poderão ser instaladas (MANWELL; MCGOWAN; ROGERS, 2010).

*Micrositing* é o uso de ferramentas de avaliação de recursos para determinar a posição exata de uma ou mais turbinas eólicas em uma região (*onshore* ou *offshore*) para maximizar a receita líquida de um empreendimento. Os códigos de projeto e análise de parques eólicos usados para *micrositing* usam dados do potencial eólico para o local, dados de turbinas e informações sobre as restrições do local para determinar um *layout* ideal para instalação das turbinas eólicas. O desenvolvimento de parques eólicos está sujeito a várias restrições, que podem ser devido a questões técnicas, de logística, ambiental, econômica ou mesmo de caráter social (FENG; SHEN, 2015b).

Uma vez que uma turbina esteja muito próxima de outra, esta primeira turbina introduzirá uma grande perda devido à esteira e alta intensidade de turbulência no rotor da segunda, o que por sua vez aumenta a fadiga das pás e encurta a vida útil dos rotores. Geralmente é necessário colocar as turbinas de acordo com uma restrição mínima de distância entre elas. A restrição pode ser fornecida pelos fabricantes e também depende da característica específica do local do parque e das características dos recursos eólicos (MANWELL; MCGOWAN; ROGERS, 2010; FENG; SHEN, 2015b).

No presente trabalho, a fim de mitigar a redução da vida útil das turbinas, devido aos efeitos de esteira (TAO et al., 2020), considera-se uma distância mínima permitida entre dois aerogeradores  $i$  e  $j$ , a qual é regida pela Equação (5.1), também utilizada por Feng e Shen (2015b), Kusiak e Song (2010). A restrição de proximidade é modelada desta forma devido à formulação do presente problema de otimização considerar a posição das turbinas eólicas como coordenadas  $(x, y)$  contínuas. Uma outra forma de garantir a proximidade mínima entre as turbinas é através da formulação do problema com o posicionamento das turbinas em um *grid* de posições pré-estabelecidas, como em Mosetti,

Poloni e Diviacco (1994), Gonzalez-Rodriguez et al. (2021), Luo et al. (2019), Stanley et al. (2021), Kunakote et al. (2021). Entretanto, esta segunda abordagem trata das variáveis de posição das turbinas como um vetor de variáveis binárias e não será adotada no presente trabalho. A restrição de distância mínima é definida como:

$$\sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \geq d_{min} \mid i, j = 1, 2, 3, \dots, N_t \quad \text{e} \quad i \neq j \quad (5.1)$$

Dessa forma, as soluções factíveis são todos os layouts possíveis, ou seja, todas as combinações possíveis do posicionamento das turbinas eólicas, de modo que não haja duas turbinas tão próximas quanto a distância mínima  $d_{min}$  permitida. Devido ao fato de que o espaçamento entre as turbinas em parques eólicos geralmente se enquadra na faixa de 3 a 10 diâmetros de rotor (PORTÉ-AGEL; BASTANKHAH; SHAMSODDIN, 2019) e, de acordo com o espaçamento médio apresentado na Tabela 5.2 de alguns parques eólicos *offshore* em operação, considerou-se para o presente trabalho  $d_{min} = 5d_0$ , sendo  $d_0$  o diâmetro do rotor da  $i$ -ésima turbina no parque para avaliação da restrição pela Equação (5.1).

Tabela 5.2: Distância média entre turbinas eólicas em parques eólicos offshore

Parque eólico	Distância média entre turbinas	Referência
Horns Rev I	$7d_0$	(BARTHELMIE et al., 2010)
Nysted	$\approx 8d_0$	(BARTHELMIE et al., 2010)
Lillgrund	$\approx 3.3d_0$	(HAMILTON et al., 2020)
Egmond Aan Zee (OWEZ)	$7d_0$	(DOEKEMEIJER; SIMLEY; FLEMING, 2022)
Westermest Rough	$6d_0$	(DOEKEMEIJER; SIMLEY; FLEMING, 2022)
Anholt	$5d_0$	(DOEKEMEIJER; SIMLEY; FLEMING, 2022)

## 5.4 Formulação dos problemas

O presente trabalho se propõe a realizar a otimização multiobjetivo de um parque eólico *offshore* cujas as condições anuais de vento são disponíveis e modeladas conforme a distribuição de probabilidades apresentada na Seção 5.2. Pretende-se otimizar o layout de instalação de um total de  $N_t = 30$  turbinas eólicas, a serem instaladas na região de domínio do parque apresentada a seguir. Além da otimização do layout, pretende-se também otimizar a escolha dos modelos comerciais dos 30 aerogeradores instalados, dentre os 25 modelos

pré-selecionados e apresentados na Seção 5.1, ponderando no processo de escolha dos modelos os seguintes pontos: regime anual de ventos, layout de instalação, desempenho e custos dos modelos de turbinas cadastrados. Uma abordagem de otimização é necessária para se lidar com esta complexidade, especialmente com a tendência atual de grandes áreas de parques eólicos com um número considerável de turbinas eólicas (CHARHOUNI; SALLAOU; MANSOURI, 2019b). Com o objetivo de analisar o impacto dos tipos de turbinas eólicas sobre os objetivos do parque eólico, o presente trabalho considera a escolha de modelos comerciais de aerogeradores de maneira livre, podendo, à cada turbina, ser atribuído um modelo diferente, conforme formalizado no vetor de variáveis de decisão da Equação (5.3), através das variáveis de decisão  $mod_i$ .

A busca de um projeto apropriado do layout de parques eólicos constitui uma tarefa complexa em um projeto (CHARHOUNI; SALLAOU; MANSOURI, 2019b), pois a otimização do layout das turbinas em um parque eólico já é um problema de otimização global contínuo, não-convexo, não-linear e com restrições (GRAF et al., 2016). No presente trabalho, conforme afirmado por Graf et al. (2016), é abordada a próxima geração de problemas de otimização de parques eólicos, acrescentando a complexidade de que há mais de um tipo de turbina a se escolher. A otimização se torna um problema de variáveis mistas (contínuas e discretas) não-linear, que é uma classe de problemas muito difícil de resolver (GRAF et al., 2016).

As formulações do problema discutidas na sequência são comuns aos dois estudos de caso apresentados nas Subseções 5.4.1 e 5.4.2.

Conforme visto anteriormente, os problemas de otimização estão geralmente sujeitos a restrições e, portanto, nem todas as soluções são viáveis. Os limites superior e inferior para as variáveis de projeto são a forma mais simples de restrições (ABDULRAHMAN; WOOD, 2017). Dessa forma, a área factível para planejamento do parque eólico,  $S_{fac}$ , é limitada pelas fronteiras impostas para instalação das turbinas no interior do parque. Se a forma desta região  $S_{fac}$  do parque é retangular (CHEN et al., 2013; CHOWDHURY et al., 2013; ABDULRAHMAN; WOOD, 2017; FENG; SHEN, 2017) ou quadrada (SONG; CHEN; WANG, 2018; TANG et al., 2018; TANG et al., 2017; POOKPUNT; ONGSAKUL, 2016; SUN; YANG; GAO, 2019), conforme considerada em

outros trabalhos de otimização de parques eólicos, os limites para as variáveis de busca pertinentes à posição das turbinas  $(x, y)$  é dada como (TAO et al., 2020):

$$S_{fac} = \{(x, y) \in \mathbb{R}^2 \mid x_{min} \leq x \leq x_{max}, y_{min} \leq y \leq y_{max}\}, \quad (5.2)$$

onde  $x_{min}, y_{min}$  e  $x_{max}, y_{max}$  são os limites mínimo e máximo da área factível para o planejamento do parque eólico. Para o presente trabalho, e para cada turbina  $i$ , considera-se como variável de decisão contínua a sua coordenada de instalação no domínio do parque  $(x_i, y_i \in \mathbb{R})$ , dos quais  $x_{min} \leq x_i \leq x_{max}$  e  $y_{min} \leq y_i \leq y_{max}$ . Também adotou-se um domínio quadrado que limita a região do parque eólico, de forma que:  $h = 2000$  m, com  $x_{min} = y_{min} = -h$  e  $x_{max} = y_{max} = h$ , conforme mostra Figura 5.5. É importante destacar que no presente estudo adotou-se uma região *offshore*, para instalação do parque, de profundidade constante  $WD = 10$  m a uma distância da costa  $d_{shore} = 20$  km, a serem consideradas nos modelos de custo da Seção 3.2.1.

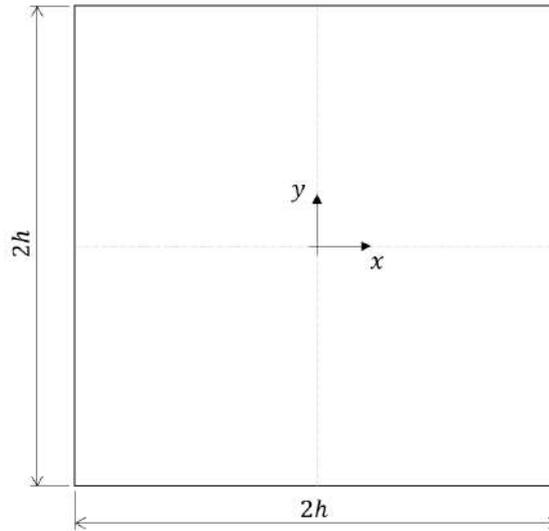


Figura 5.5: Espaço de busca das variáveis  $(x_i, y_i)$  para composição do *layout* do parque eólico.

Para se determinar os modelos de aerogeradores para cada uma das  $Nt = 30$  turbinas a serem instaladas no domínio do parque, algumas variáveis de decisão do vetor de variáveis,  $\mathbf{x}$ , devem ser, necessariamente, discretas. Estas variáveis discretas,  $mod_i \in \mathbb{N}$ , atuam como um ponteiro, as quais representam os modelos de aerogeradores selecionados para a turbina  $i$ . Estes ponteiros são utilizados para acessar uma tabela de

características geométricas e de desempenho do modelo de aerogerador por ele representado (a Figura 5.6 ilustra este conceito). Dessa forma, cada turbina tem como variável de decisão, referente ao seu modelo de aerogerador, a variável  $mod_i$  da seguinte forma:  $mod_i \in \mathbb{Z} \mid mod_{min} = 0 \leq mod_i \leq 24 = mod_{max}$ . Assim, para cada valor assumido por  $mod_i$ , no momento de se avaliar o desempenho do conjunto de turbinas selecionadas, assim como os efeitos de esteira e custos, as características de cada modelo de turbina são considerados individualmente, conforme informações e características das turbinas apresentadas na Seção 5.1. Por fim, a construção do vetor de variáveis de decisão,  $\mathbf{x}$ , para ambos os estudos de caso, assim como vetores de limite mínimo e máximo ( $\underline{\mathbf{x}}$  e  $\bar{\mathbf{x}}$ ) para as variáveis de decisão ficam da seguinte forma:

$$\mathbf{x} = \{x_1, y_1, mod_1, \dots, x_i, y_i, mod_i, \dots, x_{N_t}, y_{N_t}, mod_{N_t}\}^T \quad (5.3)$$

$$\underline{\mathbf{x}} = \{x_{min}, y_{min}, mod_{min}, \dots, x_{min}, y_{min}, mod_{min}\}^T \quad (5.4)$$

$$\bar{\mathbf{x}} = \{x_{max}, y_{max}, mod_{max}, \dots, x_{max}, y_{max}, mod_{max}\}^T \quad (5.5)$$

#### 5.4.1 Caso I - FC vs. LCOE

A respeito das funções objetivo utilizadas no presente estudo de caso, considerou-se uma combinação de dois objetivos conflitantes, sendo um deles com critério de performance do parque eólico (Fator de capacidade,  $FC$ , ver Equação (3.3)) e o outro com critério econômico (Custo nivelado de energia,  $LCOE$ , ver Equação (3.26)). A formulação do problema de otimização se dá conforme a Equação (5.6):

$$\begin{aligned} \min \quad & -FC(\mathbf{x}) \text{ e } LCOE(\mathbf{x}), \\ \text{sujeito a :} \quad & \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \geq d_{min} \mid i, j = 1, 2, 3, \dots, N_t \text{ e } i \neq j \\ & \underline{\mathbf{x}} \leq \mathbf{x} \leq \bar{\mathbf{x}}. \end{aligned} \quad (5.6)$$

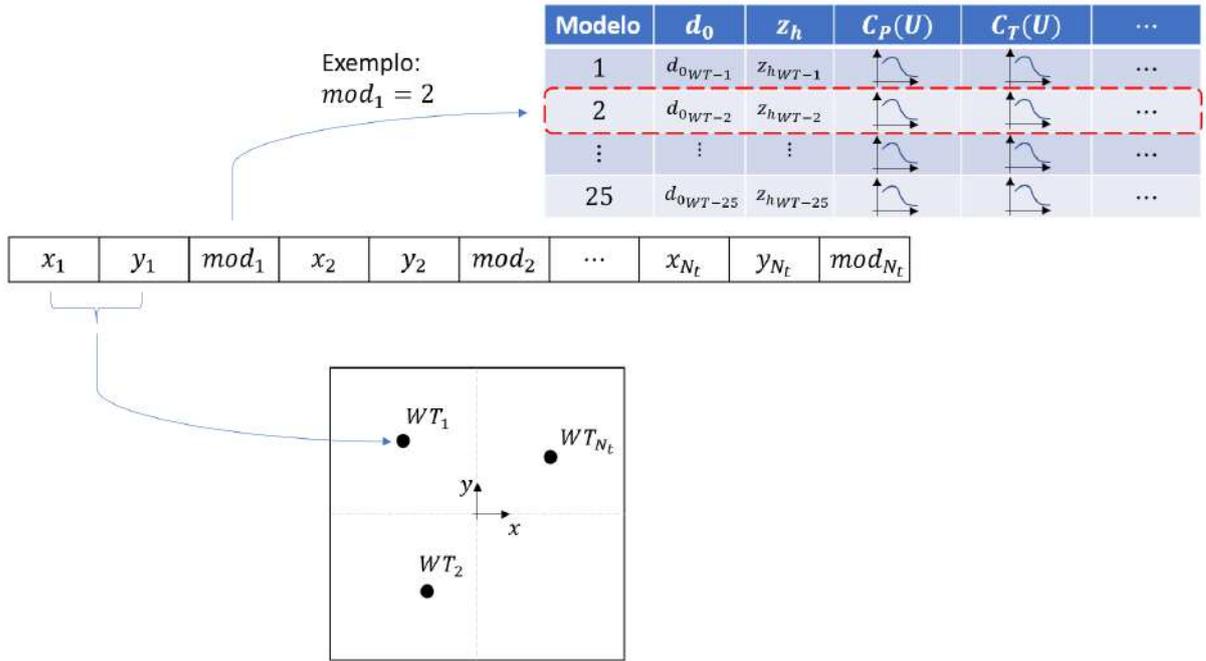


Figura 5.6: Vetor de variáveis de decisão e tabela com informações sobre os modelos de aerogeradores pré-cadastrados (Seção 5.1), acessados através dos ponteiros,  $mod_i$ .

### 5.4.2 Caso II - $\eta$ vs. COE

Neste estudo de caso, assim como no anterior, também considerou-se um objetivo de caráter econômico e outro a respeito do desempenho do parque eólico, sendo eles: custo de energia (*COE*, ver Equação (3.27)) e a eficiência de *layout* ( $\eta$ , ver Equação (3.4)). A Equação (5.7) apresenta a formulação do problema de otimização.

$$\begin{aligned} \min \quad & -\eta(\mathbf{x}) \text{ e } COE(\mathbf{x}), \\ \text{sujeito a : } & \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \geq d_{min} \mid i, j = 1, 2, 3, \dots, N_t \text{ e } i \neq j \\ & \underline{\mathbf{x}} \leq \mathbf{x} \leq \bar{\mathbf{x}}. \end{aligned} \quad (5.7)$$

### 5.4.3 Minimização do número de modelos diferentes de turbinas instaladas

Conforme revisado no Capítulo 1, é visto que várias abordagens sobre a otimização de parques eólicos foram propostas tendo em consideração a seleção e a instalação mista de tur-

binas eólicas com diversas dimensões físicas e várias curvas de potência (CHOWDHURY et al., 2012; CHOWDHURY et al., 2013; CHEN et al., 2013; ABDULRAHMAN; WOOD, 2017; VASEL-BE-HAGH; ARCHER, 2017; SONG; CHEN; WANG, 2018; TANG et al., 2018; FENG; SHEN, 2017; SUN; YANG; GAO, 2019). Alguns estudos anteriores sobre a otimização não uniforme (i.e., com modelos diferentes de aerogeradores) de parques eólicos são mencionados na Seção 1.2.2. Estes estudos revelam que a instalação híbrida de modelos de aerogeradores pode ajudar a aumentar a potência total do parque (CHOWDHURY et al., 2013; CHEN et al., 2013; ABDULRAHMAN; WOOD, 2017; VASEL-BE-HAGH; ARCHER, 2017), obter um menor custo de energia (CHEN et al., 2013; ABDULRAHMAN; WOOD, 2017; SONG; CHEN; WANG, 2018; TANG et al., 2018), melhorar a eficiência do layout (CHOWDHURY et al., 2012; RAHBARI et al., 2014) e homogeneizar os danos por fadiga (HUANG et al., 2020).

Em contrapartida, os problemas logísticos de se lidar com uma série de diferentes modelos de turbinas eólicas em um determinado parque eólico aumenta com o número de diferentes modelos utilizados, devido a complicações para instalação de turbinas de diferentes portes, as quais requerem embarcações e infraestruturas específicas para cada porte de aerogerador. Isto implica em um maior custo de instalação para o empreendimento, tendo em vista que os custos para instalação e operação de um parque eólico no mar (*offshore*) são substancialmente mais elevados. Além disso, a operação de turbinas eólicas de diferentes portes geram complicações de controle de potência na subestação *offshore*. Outra desvantagem de aumentar a quantidade demasiada de diferentes modelos de aerogeradores é que tanto sua gestão quanto o treinamento de pessoal especializado para as operações de manutenção se tornam despesas adicionais (MONTROYA et al., 2014). Estas questões irão refletir na viabilidade econômica do empreendimento e devem ser levadas em consideração. Por fim, é importante ponderar entre os ganhos de desempenho citados e o número de diferentes tipos de turbinas que levam aos problemas levantados neste parágrafo, sendo necessário um *trade-off* entre estes dois pontos

Uma abordagem possível para se otimizar parques eólicos com diferentes modelos de turbinas, sem com que muitos modelos diferentes de aerogeradores sejam escolhidos é discutida em Montoya et al. (2014), onde limitou-se na formulação do problema a

atribuição de, no máximo, dois modelos diferentes de turbinas eólicas (de uma lista de 26 modelos de turbinas disponíveis), a fim de se minimizar o desvio padrão da energia produzida ao longo do dia, enquanto maximiza-se a energia total produzida pelo parque eólico.

De forma a não impor aos algoritmos de otimização esta limitação de dois modelos diferentes, o presente trabalho propõe uma abordagem mais generalista, através da introdução de um objetivo de projeto adicional, além dos descritos nas Subseções 5.4.1 e 5.4.2, o qual visa minimizar o número de diferentes modelos de aerogeradores,  $N_{dma}$ , presentes nos parques eólicos. A avaliação desta nova função objetivo se dá conforme mostra o Algoritmo 17, o qual recebe um vetor de variáveis de decisão pertencente à população de indivíduos da atual geração,  $\mathbf{x} \in P_t$ .

---

**Algoritmo 17:** Avaliação do número de diferentes modelos de aerogeradores,  $N_{dma}$ , do parque candidato  $\mathbf{x} \in P_t$

---

**Entrada:** Vetor de variáveis de decisão,  $\mathbf{x} \in P_t$ .

**Saída:** Número de diferentes modelos de aerogeradores em  $\mathbf{x}$ ,  $N_{dma}$

**1 início**

**2**      $\mathbf{x}_{mod} = \text{Retira\_variáveis}(\mathbf{x})$      /\*Retira variáveis  $mod_i$  de todas as turbinas  $i$  em  $\mathbf{x}^*$ \*/;

**3**      $N_{dma} = \text{Tamanho}(\text{Valores\_únicos}(\mathbf{x}_{mod}))$      /\*Verifica os modelos de aerogeradores em  $\mathbf{x}$  e retorna o número de modelos diferentes presentes\*/;

**4 fim**

---

Dessa forma, o presente trabalho contribui com uma metodologia de otimização do layout de parques eólicos, permitindo otimizar, simultaneamente, a alocação e a seleção de turbinas para parques eólicos em escala comercial, que estão sujeitos a condições de vento variáveis. A metodologia evita as seguintes suposições tradicionais limitantes: (i) padrão de disposição em matriz/*grid*, (ii) condição de vento fixa, ou distribuição unimodal e univariada das condições de vento, e (iii) a especificação de um tipo fixo e uniforme de turbinas a serem instaladas no parque, ou mesmo a imposição de um número determinado de modelos diferentes de aerogeradores.

No presente trabalho são avaliados os resultados de otimização multiobjetivo de parques eólicos considerando objetivos usuais da literatura, conforme os Casos I e II apresentados nas Subseções 5.4.1 e 5.4.2, assim como os resultados dos mesmos conjuntos

de objetivos com o acréscimo da presente abordagem proposta, através de um terceiro objetivo, conforme mostra Equações 5.8 e 5.9, a fim de se comparar o *trade-off* entre o ganho em desempenho e o número de turbinas eólicas de modelos diferentes, a ser minimizado.

$$\begin{aligned} \min \quad & -FC(\mathbf{x}), LCOE(\mathbf{x}) \text{ e } N_{dma}, \\ \text{sujeito a :} \quad & \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \geq d_{min} \mid i, j = 1, 2, 3, \dots, N_t \text{ e } i \neq j \quad (5.8) \\ & \underline{\mathbf{x}} \leq \mathbf{x} \leq \bar{\mathbf{x}}. \end{aligned}$$

$$\begin{aligned} \min \quad & -\eta(\mathbf{x}), COE(\mathbf{x}) \text{ e } N_{dma}, \\ \text{sujeito a :} \quad & \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \geq d_{min} \mid i, j = 1, 2, 3, \dots, N_t \text{ e } i \neq j \quad (5.9) \\ & \underline{\mathbf{x}} \leq \mathbf{x} \leq \bar{\mathbf{x}}. \end{aligned}$$

## 5.5 Algoritmos e parâmetros

Para resolução dos problemas de otimização postulados na Seção 5.4, utilizou-se os algoritmos NSGA-II (Seção 4.3) e SMS-EMOA (Seção 4.5) disponíveis na plataforma *Multi-objective Optimization in Python - Pymoo* (Blank; Deb, 2020). Para ambos os estudos de caso, adotou-se uma população,  $P_t$ , com  $N = 100$  indivíduos. A inicialização dos  $N$  indivíduos da população inicial,  $P_0$ , se deu através de uma distribuição uniforme aleatória com limites inferior e superior  $[\underline{\mathbf{x}}, \bar{\mathbf{x}}]$  definidos na Seção 5.4.

Para os operadores de recombinação (*crossover* - Seção 4.3.2) e mutação (Seção 4.3.3), utilizou-se os parâmetros de probabilidade de ocorrência e índices de distribuição conforme mostra a Tabela 5.3. A seleção dos pais para etapa de recombinação se deu conforme descrito na Seção 4.3.1 com seleção através de torneio binário e com o critério de seleção por *rank* nas frentes de Pareto e *crowding distance*, assim como o critério de sobrevivência da população unificada de pais e filhos para a próxima geração. Este critério é discutido na Seção 4.3.

Para o critério de parada relacionado ao número máximo de gerações permitidas,

Tabela 5.3: Parâmetros dos operadores de recombinação e mutação *default* conforme Blank e Deb (2020)

Parâmetro	Definição	Operador	Valor
$p_{SBX}$	Probabilidade de ocorrência de <i>crossover</i>	SBX	0.9
$\eta_c$	Índice de distribuição	SBX	15
$p_{PM}$	Probabilidade de ocorrência da mutação polinomial	Mutação	$1/\text{tamanho\_do\_vetor}(\mathbf{x})$
$\eta_m$	Índice de distribuição	Mutação	20

adotou-se  $n_{max_{gen}} = 2000$ . Já para os critérios referentes às alterações nos espaços de busca,  $x_{tol}$ , e no espaço dos objetivos,  $f_{tol}$ , adotou-se as seguintes tolerâncias:  $x_{tol} = 0.0005$  e  $f_{tol} = 0.005$  para uma janela de avaliação das últimas  $n_{last} = 50$  gerações, conforme explicado na Seção 4.6.

Por fim, avaliou-se o desempenho de cada algoritmo (NSGA-II e SMS-EMOA) na resolução dos dois estudos de caso, bem como com a abordagem descrita na Seção 5.4.3, com um total de  $n_{runs}$  execuções independentes para cada configuração da Tabela 5.4.

Tabela 5.4: Experimentos numéricos

Estudo de caso	Algoritmo	$n_{runs}$
Caso I - FC vs. LCOE	NSGA-II	20
Caso II - $\eta$ vs. COE	NSGA-II	20
Caso I - FC vs. LCOE	SMS-EMOA	20
Caso II - $\eta$ vs. COE	SMS-EMOA	20
Caso I - FC vs. LCOE vs. $N_{mda}$	NSGA-II	20
Caso II - $\eta$ vs. COE vs. $N_{mda}$	NSGA-II	20
Caso I - FC vs. LCOE vs. $N_{mda}$	SMS-EMOA	20
Caso II - $\eta$ vs. COE vs. $N_{mda}$	SMS-EMOA	20

## 5.6 Resultados e discussões

Na presente seção são discutidos os resultados obtidos das simulações realizadas segundo cada um dos casos e suas variações apresentados na Tabela 5.4. Por se tratar de um problema com restrições (ver Seção 5.3), as técnicas de tratamento das mesmas, empregadas pelo NSGA-II e SMS-EMOA, são rigorosamente eficientes e robustas, gerando resultados factíveis para ambos os estudos de casos analisados. A Subseção 5.6.1 apresenta uma comparação detalhada dos resultados obtidos dos problemas formulados segundo Equações (5.6) e (5.8), referente aos objetivos de Fator de capacidade (*FC*) e custo nivelado de energia (*COE*) com e sem o tratamento de minimização do número de modelos diferentes

de aerogeradores, respectivamente. Discutem-se as características dos resultados possibilitados pela abordagem proposta na Seção 5.4.3. A Subseção 5.6.2, de maneira análoga, apresenta os resultados referentes aos casos das Equações (5.7) e (5.9), com relação aos objetivos de eficiência do *layout* do parque ( $\eta$ ) e custo de energia ( $COE$ ), com e sem a abordagem proposta na Seção 5.4.3.

### 5.6.1 Caso I - FC vs. LCOE

Conforme mostrado na Tabela 5.4, para cada configuração dos casos, executou-se um total de 20 execuções independentes de cada um dos algoritmos (NSGA-II e SMS-EMOA), de forma a se realizar uma análise estatística das métricas de desempenho das rodadas independentes, assim como unificar as diferentes frentes de Pareto encontradas. A Figura 5.7 mostra as frentes de Pareto obtidas para o Caso I - FC vs. LCOE, para cada uma das rodadas independentes, segundo cada um dos dois algoritmos empregados (NSGA-II e SMS-EMOA).

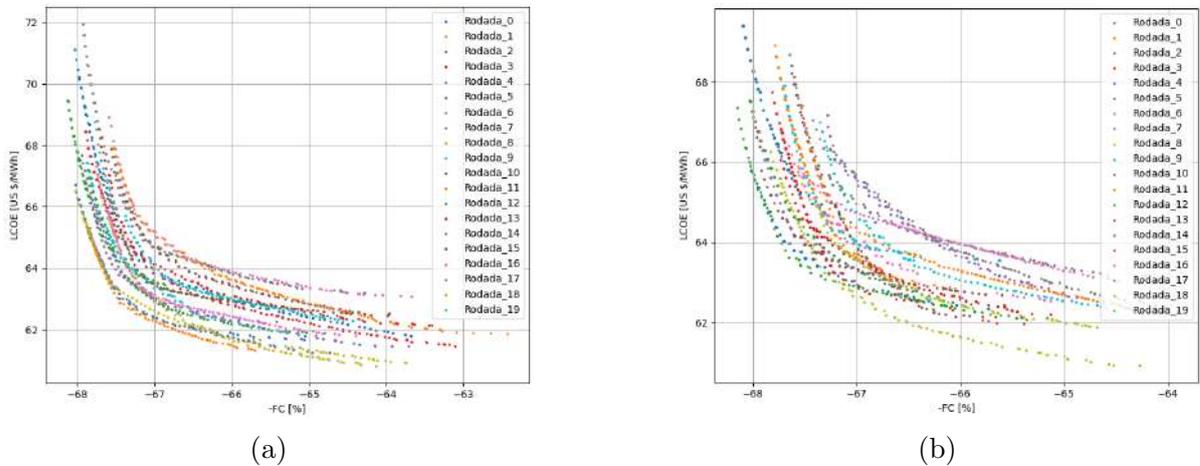


Figura 5.7: Frentes de Pareto resultantes das 20 rodadas independentes do Caso I - FC vs. LCOE: a) NSGA-II e b) SMS-EMOA.

É possível observar na Figura 5.7 que existem indivíduos resultantes de uma determinada rodada independente que dominam certos resultados de uma outra rodada independente, sendo necessário unificar os resultados não dominados do agrupamento das 20 frentes de Pareto resultantes em uma frente unificada,  $PF_{Uni}$ . Para este fim, uniu-se todas as frentes de Pareto resultantes, i.e.,  $PF = \{PF_1 \cup PF_2 \cup \dots \cup PF_{20}\}$ , e para que apenas os indivíduos não dominados sejam selecionados, aplicou-se o método

de seleção via *rank* e *crowding distance*, detalhado na Seção 4.3, para compor a frente de Pareto unificada  $PF_{Uni} = \text{critério\_de\_seleção}(PF)$ . É importante destacar que esta frente de Pareto unificada,  $PF_{Uni}$ , será utilizada como frente de Pareto de referência para o cálculo da métrica de desempenho  $IGD^+$ , para cada uma das rodadas independentes, descrita na Seção 4.4.1. A Figura 5.8 apresenta as frentes de Pareto unificadas para cada um dos dois algoritmos, assim como a frente unificada final entre as frentes unificadas de cada algoritmo. É possível observar na Figura 5.8a que o NSGA-II teve melhores resultados na região com menores LCOE e menores FC, enquanto o SMS-EMOA teve maiores contribuições na frente de Pareto final na região com maiores LCOE e FC.

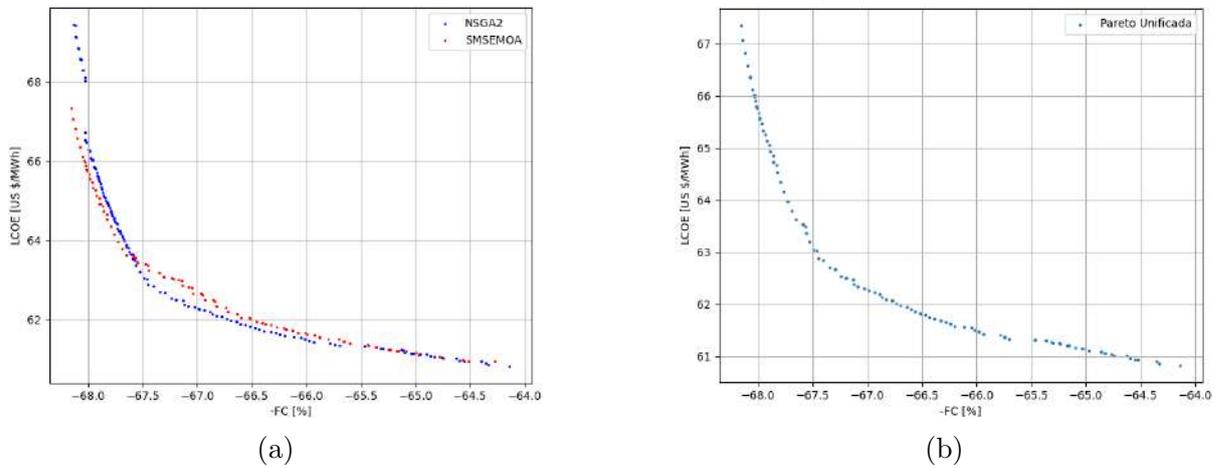


Figura 5.8: a) Frentes de Pareto Unificadas das 20 rodadas independentes do Caso I - FC vs. LCOE, conforme cada algoritmo e b) Frente de Pareto Unificada entre as frentes de Pareto de a).

Para a avaliação do Hipervolume, conforme explicado na Seção 4.4.2, é necessário apontar um ponto de referência,  $W$ . As Figuras 5.9a e 5.9b mostram o mesmo ponto de referência,  $W = (1.1, 1.1)$ , adotado para avaliação do Hipervolume para cada uma das rodadas independentes. É importante destacar que, para o cálculo das métricas de desempenho, normalizou-se os valores dos indivíduos das curvas de Pareto em razão dos pontos *nadir* e *ideal*, como ilustrado na Figura 4.19, pelo procedimento explicado na Seção 4.7. As curvas apresentadas nas Figuras 5.9c e 5.9d mostram a evolução e convergência do hipervolume e  $IGD^+$  ao longo das gerações de cada algoritmo. É importante destacar que cada curva corresponde a uma das 20 rodadas independentes dos algoritmos e têm a geração final (a qual atinge-se a convergência pelos critérios de parada - ver Seções 4.6 e 5.4) diferente, entre si, devido ao processo não ser determinístico. Os valores do hiper-

volume, calculados conforme Equação 4.10, são normalizados em função do hipervolume gerado pelo ponto *ideal*. Todo este processo de normalização aqui explicado também é empregado nas discussões dos resultados subsequentes.

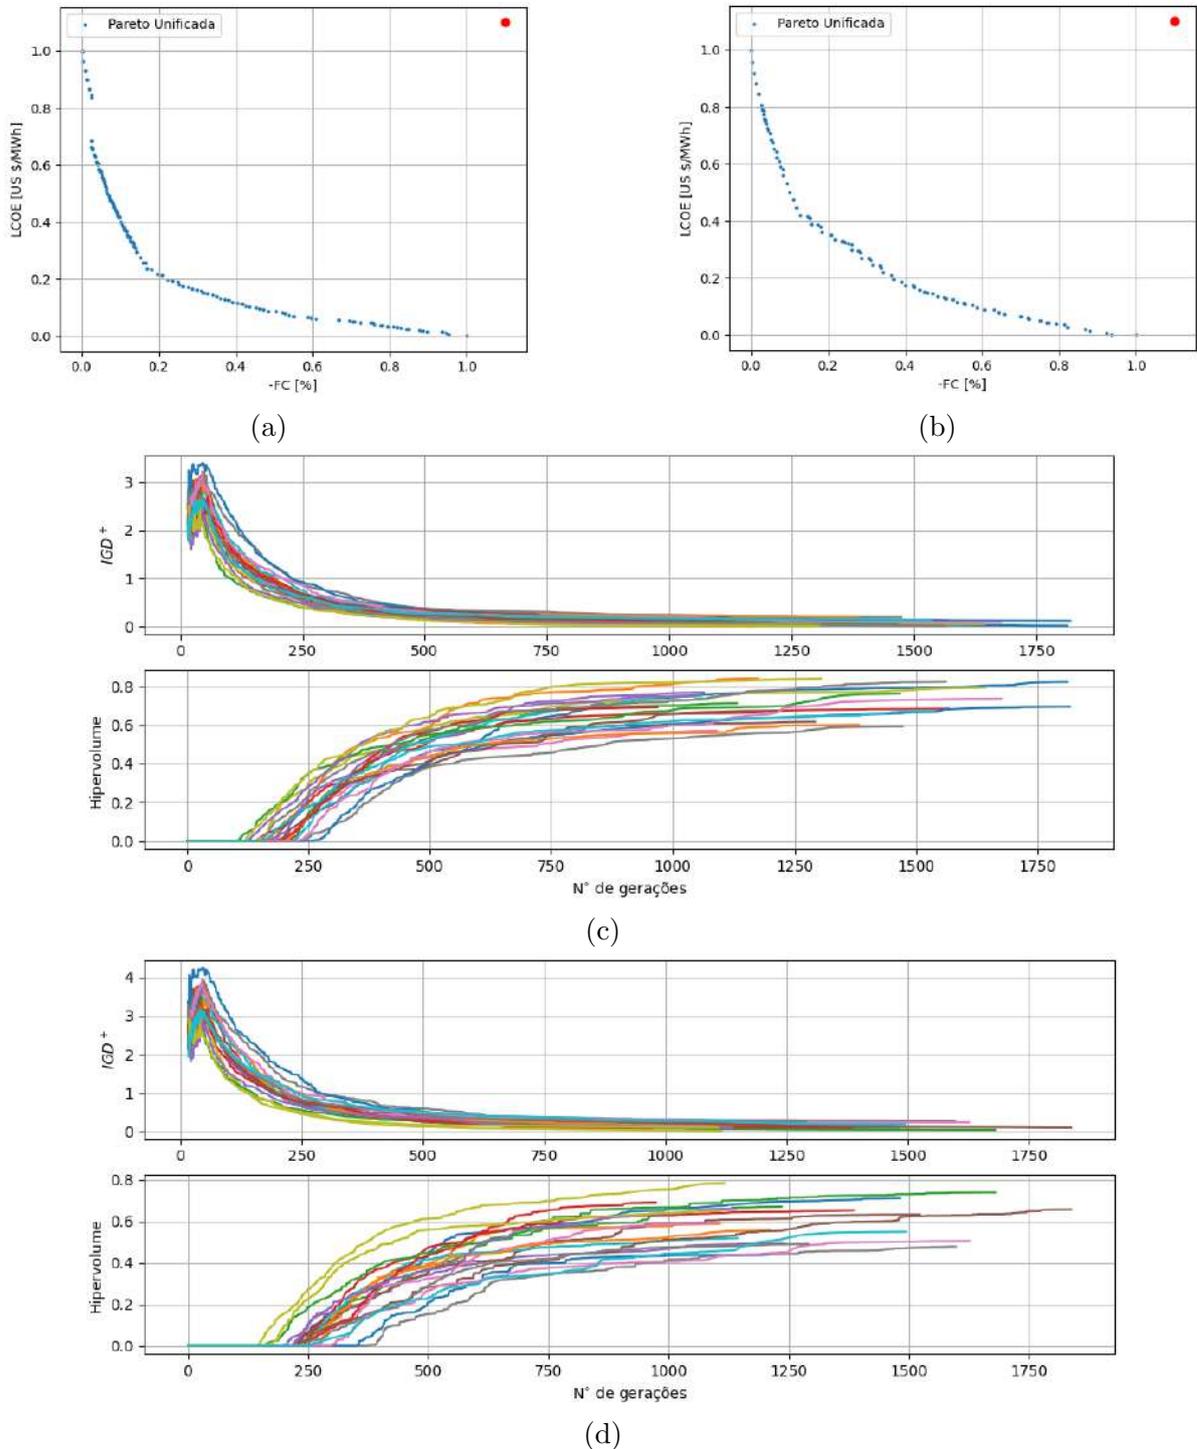


Figura 5.9: Ponto de referência,  $W = (1.1, 1.1)$  em vermelho, para o cálculo do Hipervolume das frentes de Pareto resultante das 20 rodadas independentes dos algoritmos a) NSGA-II e b) SMS-EMOA; Curvas de evolução das Métricas de desempenho ( $IGD^+$  e Hipervolume) ao longo das gerações de cada uma das 20 rodadas independentes dos algoritmos c) NSGA-II e d) SMS-EMOA.

Conforme observa-se nas Figuras 5.9c e 5.9d, os valores de  $IGD^+$  diminuem conforme avanço das gerações e o hipervolume aumenta, mostrando assim um comportamento simultâneo de convergência e diversidade das frentes de Pareto resultantes, ao longo das gerações, das rodadas independentes de cada algoritmo, conforme descrito na Seção 4.4.

A Tabela 5.5 apresenta uma breve análise estatística das métricas de desempenho utilizadas nas avaliações de convergência e diversidade das frentes de Pareto geradas pelos algoritmos, sendo os valores considerados nas análises da Tabela 5.5, os valores das métricas de desempenho ( $IGD^+$  e Hipervolume) na última geração de cada rodada independente, i.e., na geração da qual os critérios de parada foram atingidos. É possível observar na Tabela 5.5 que, devido aos baixos valores de  $\sigma_{IGD^+}$  e  $\sigma_{HV}$ , as 20 rodadas independentes de cada algoritmo tiveram níveis semelhantes de convergência e diversidade da frente de Pareto.

Tabela 5.5: Análise estatística das métricas de desempenho para as 20 rodadas independentes de cada um dos dois algoritmos (NSGA-II e SMS-EMOA) para o Caso I - FC vs. LCOE, onde:  $IGD_{media}^+$  e  $HV_{media}$  são a média da métrica  $IGD^+$  e do hipervolume, respectivamente, das 20 rodadas independentes;  $\sigma_{IGD^+}$  e  $\sigma_{HV}$  o desvio padrão das métricas de desempenho;  $IGD_{min}^+$  e  $IGD_{max}^+$  os valores mínimo e máximo do  $IGD^+$  dentre as 20 rodadas independentes e, de maneira análoga para os valores  $HV_{min}$  e  $HV_{max}$  do hipervolume.

	NSGA-II	SMS-EMOA
$IGD_{media}^+$	0.10019289	0.15670989
$\sigma_{IGD^+}$	0.06193965	0.07802309
$IGD_{min}^+$	0.00970515	0.02426651
$IGD_{max}^+$	0.21467472	0.28355657
$HV_{media}$	0.72032206	0.60268719
$\sigma_{HV}$	0.08129493	0.09390623
$HV_{min}$	0.57104187	0.43815319
$HV_{max}$	0.84138928	0.78359033

Após esta análise da qualidade, em termos de convergência e diversidade, da frente de Pareto, direciona-se agora para uma análise dos resultados em termos das variáveis de decisão, apontadas pelos indivíduos que constituem a frente de Pareto unificada da Figura 5.8b. A Figura 5.10a apresenta um histograma do número de indivíduos da frente de Pareto unificada final que apresentaram parques eólicos resultantes com o número de modelos de aerogeradores diferentes igual a 4, 5, ..., 10 modelos diferentes. A Figura 5.10b apresenta o número de ocorrências em que cada modelo, dentre os 25 disponíveis

para seleção, foi selecionado para cada uma das 30 turbinas em cada um dos indivíduos que constituem a frente de Pareto da Figura 5.8b.

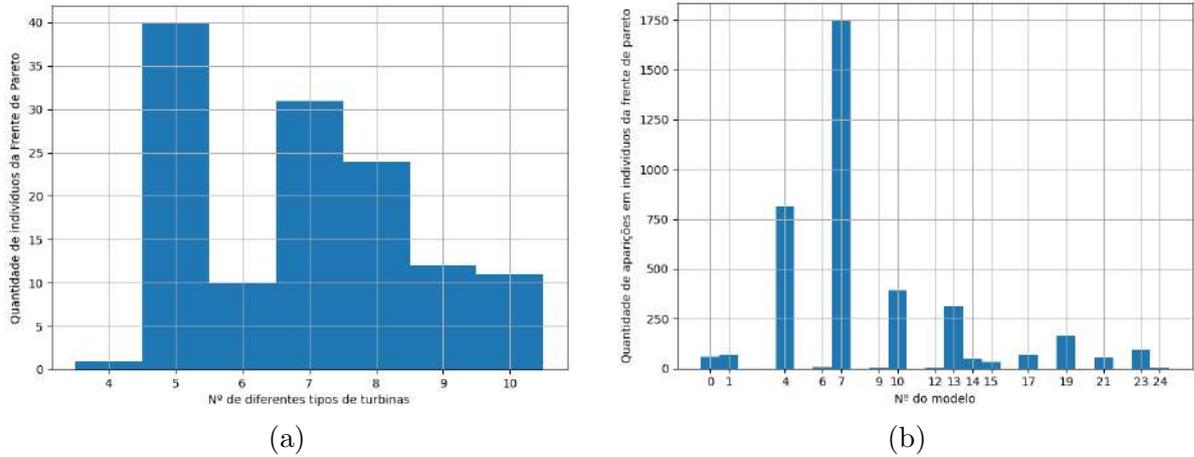


Figura 5.10: a) Histograma do número de indivíduos da frente de Pareto da Figura 5.8b que apresentaram parques eólicos com 4, 5, ..., 10 modelos diferentes de aerogeradores para o Caso I - FC vs. LCOE; b) Número de ocorrências em que cada modelo, dentre os 25 disponíveis para seleção, foi selecionado para cada uma das 30 turbinas em cada um dos indivíduos que constituem a frente de Pareto da Figura 5.8b

É importante destacar que, na Figura 5.10a, os indivíduos presentes na frente de Pareto do Caso I - FC vs. LCOE (Figura 5.8b) apresentam parques eólicos com, no mínimo 4 modelos diferentes de aerogeradores, sendo a maioria com 5 modelos. Isso ocorre devido aos benefícios citados no Capítulo 1 de parques eólicos com modelos diferentes de aerogeradores. Como neste caso não foi informado aos algoritmos de otimização nenhum mecanismo de ponderação do número de modelos diferentes de aerogeradores, os resultados da frente de Pareto tendem a apresentar indivíduos com mais modelos diferentes de aerogeradores em prol de melhores valores nas funções objetivo. Devido a este fato, estudou-se também no presente trabalho o mesmo caso com o acréscimo do terceiro objetivo de minimizar o número de modelos de aerogeradores diferentes,  $N_{dma}$ , i.e., Caso I - FC vs. LCOE vs.  $N_{dma}$ .

Antes de comparar os resultados da frente de Pareto de ambas as abordagens (Caso I - FC vs. LCOE e Caso I - FC vs. LCOE vs.  $N_{dma}$ ), avalia-se a qualidade dos resultados da abordagem do Caso I - FC vs. LCOE vs.  $N_{dma}$ , de maneira semelhante ao apresentado anteriormente para o Caso I - FC vs. LCOE. As Figuras 5.11a e 5.11b apresentam as frentes de Pareto unificadas para as 20 rodadas independentes, de cada um dos dois algoritmos (NSGA-II e SMS-EMOA), utilizadas para avaliação do  $IGD^+$ .

O processo de normalização e determinação do ponto de referência,  $W = (1.1, 1.1, 1.1)$ , são análogos aos descritos anteriormente. A Figura 5.11c já apresenta a frente de Pareto final unificada do Caso I - FC vs. LCOE vs.  $N_{dma}$ , considerando a unificação das frentes das Figuras 5.11a e 5.11b. É importante destacar que os pontos em azul na Figura 5.11 constituem a frente de Pareto, enquanto os pontos em preto representam a projeção dos pontos azuis no plano horizontal dos objetivos FC e LCOE. Estas projeções serão utilizadas mais adiante para comparação das duas abordagens (Caso I - FC vs. LCOE e Caso I - FC vs. LCOE vs.  $N_{dma}$ ). As Figuras 5.12a e 5.12b apresentam as curvas de evolução das métricas de desempenho ( $IGD^+$  e Hipervolume), ao longo das gerações, de cada uma das 20 rodadas independentes de cada algoritmo para o Caso I - FC vs. LCOE vs.  $N_{dma}$ . A Tabela 5.6 apresenta as estatísticas dos valores das métricas de desempenho para este caso de maneira análogada à apresentada na Tabela 5.5. As conclusões qualitativas e quantitativas a respeito dos valores e evolução das métricas de desempenho para esta variação do estudo de caso são iguais às expostas anteriormente.

Tabela 5.6: Análise estatística das métricas de desempenho para as 20 rodadas independentes de cada um dos dois algoritmos (NSGA-II e SMS-EMOA) para o Caso I - FC vs. LCOE vs.  $N_{dma}$ , onde:  $IGD_{media}^+$  e  $HV_{media}$  são a média da métrica  $IGD^+$  e do hipervolume, respectivamente, das 20 rodadas independentes;  $\sigma_{IGD^+}$  e  $\sigma_{HV}$  o desvio padrão das métricas de desempenho;  $IGD_{min}^+$  e  $IGD_{max}^+$  os valores mínimo e máximo do  $IGD^+$  dentre as 20 rodadas independentes e, de maneira análoga para os valores  $HV_{min}$  e  $HV_{max}$  do hipervolume.

	NSGA-II	SMS-EMOA
$IGD_{media}^+$	0.10297928	0.11151650
$\sigma_{IGD^+}$	0.04402666	0.05041864
$IGD_{min}^+$	0.03521541	0.03502555
$IGD_{max}^+$	0.18610553	0.24558657
$HV_{media}$	0.61450769	0.58018987
$\sigma_{HV}$	0.07457963	0.06757097
$HV_{min}$	0.50672612	0.46568618
$HV_{max}$	0.74649783	0.69167593

A Figura 5.13a apresenta o histograma para a nova abordagem (Caso I - FC vs. LCOE vs.  $N_{dma}$ ). É possível observar que, com a inserção do objetivo de se minimizar  $N_{dma}$ , a frente de Pareto resultante (Figura 5.11c) agora apresenta indivíduos com menores números de diferentes modelos de aerogeradores, embora ainda existam indivíduos com muitos modelos diferentes. A Figura 5.13b apresenta o número de ocorrências dos

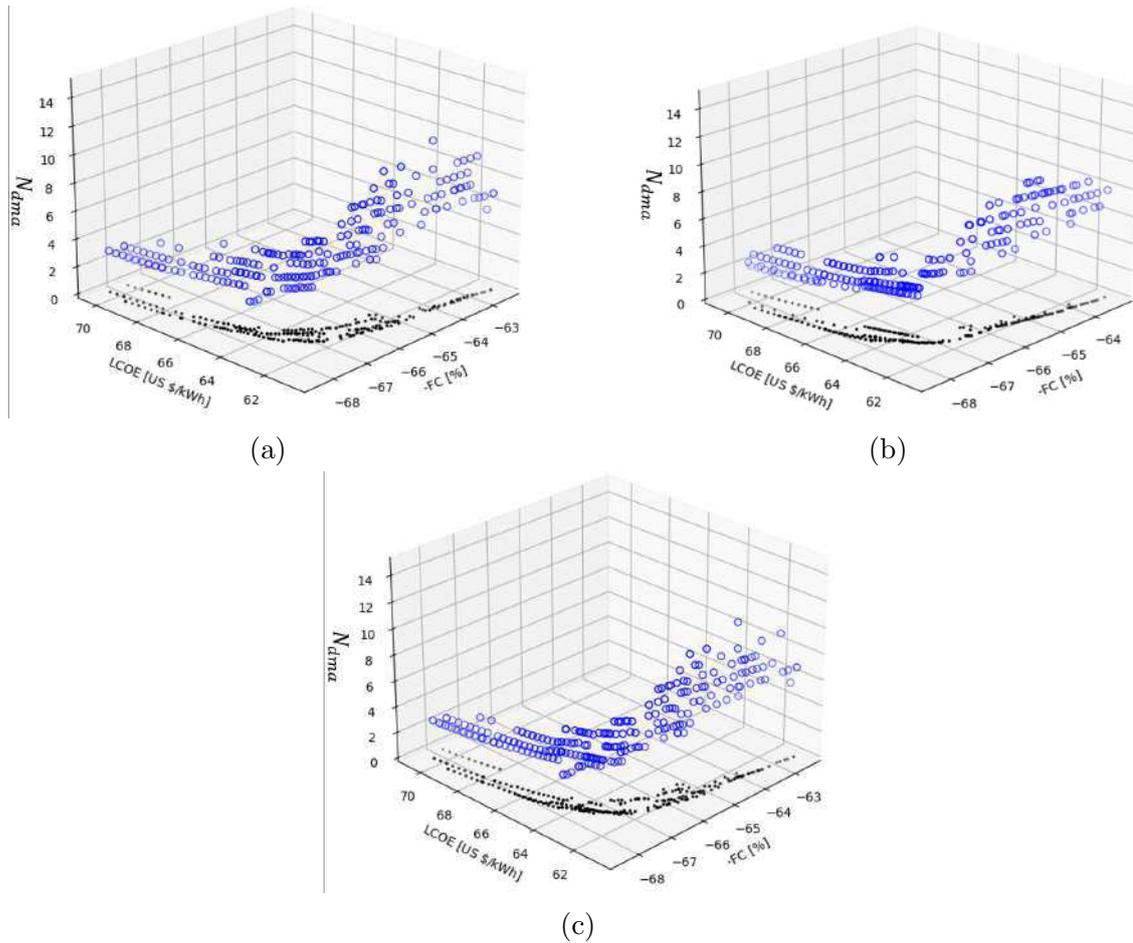


Figura 5.11: Frentes de Pareto unificadas das 20 rodadas independentes do Caso I - FC vs. LCOE vs.  $N_{dma}$  utilizando os algoritmos a) NSGA-II e b) SMS-EMOA. c) Frente de Pareto unificada entre as frentes de a) e b).

diferentes modelos de aerogeradores ao longo das 30 turbinas para cada indivíduo que constitui a frente de Pareto da Figura 5.11c. É possível observar que os modelos 7, 4, 10, 13 e 19 são os modelos com maiores aparições e estes modelos serão diferentes a depender das funções objetivos utilizadas, conforme será comparado entre os casos das Subseções 5.4.1 e 5.4.2.

Conforme comparado pelos histogramas das Figuras 5.10a e 5.13a, nota-se que a abordagem utilizando 3 objetivos leva a indivíduos da frente de Pareto final com menos modelos de aerogeradores diferentes. Agora compara-se o impacto desta abordagem com relação aos objetivos de interesse econômico e de performance dos parques eólicos, i.e., LCOE e FC. Para este fim, projeta-se os pontos da frente de Pareto da Figura 5.11c no plano dos objetivos FC vs. LCOE, conforme mostra a Figura 5.14. À primeira vista, pode parecer que as frentes de Pareto sobrepostas levam a resultados parecidos, entretanto, ao

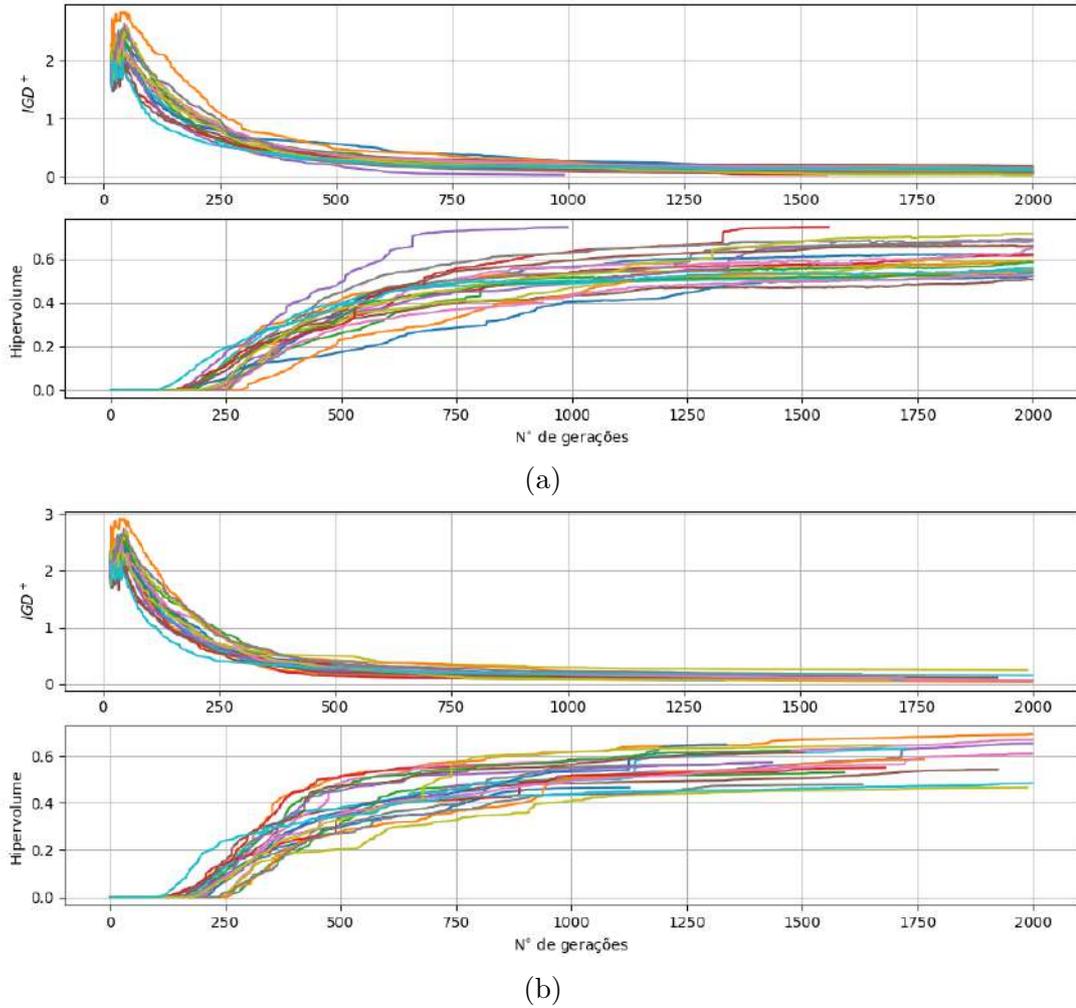


Figura 5.12: Curvas de evolução das Métricas de desempenho ( $IGD^+$  e Hipervolume) ao longo das gerações de cada uma das 20 rodadas independentes dos algoritmos a) NSGA-II e b) SMS-EMOA para o Caso I - FC vs. LCOE vs.  $N_{dma}$

se estabelecer uma distinção do número de modelos de aerogeradores diferentes em cada indivíduo das duas frentes de Pareto, é possível observar que a abordagem do Caso I - FC vs. LCOE vs.  $N_{dma}$ , devido ao objetivo de se minimizar  $N_{dma}$ , faz com que a sua frente de Pareto tenha desempenho semelhante ao da outra abordagem, em termos de FC e LCOE, porém com menos modelos de aerogeradores diferentes em seus indivíduos. Este comportamento é possível de ser observado na Figura 5.15, a qual apresenta os indivíduos das duas frentes de Pareto rotulados conforme o número de modelos diferentes de aerogeradores. É possível observar na Figura 5.15 que, embora os resultados de ambas as abordagens sejam semelhantes, quanto ao FC e LCOE, em uma região da frente de Pareto, o fato de utilizar a abordagem proposta no presente trabalho leva a atingir resultados semelhantes com um número menor de modelos de aerogeradores diferentes.

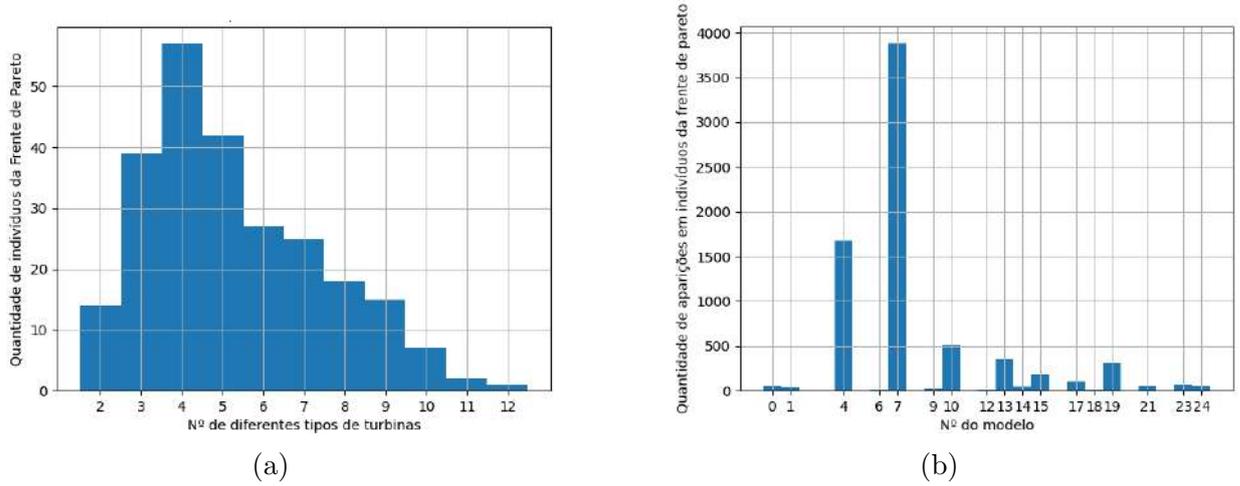


Figura 5.13: a) Histograma do número de indivíduos da frente de Pareto da Figura 5.11c que apresentaram parques eólicos com 2, 3, ..., 12 modelos diferentes de aerogeradores para o Caso I - FC vs. LCOE vs.  $N_{dma}$ ; b) Número de ocorrências em que cada modelo, dentre os 25 disponíveis para seleção, foi selecionado para cada uma das 30 turbinas em cada um dos indivíduos que constituem a frente de Pareto da Figura 5.11c

Após as comparações realizadas entre as abordagens do Caso I - FC vs. LCOE e Caso I - FC vs. LCOE vs.  $N_{dma}$ , na sequência são apresentadas as extrações de alguns resultados da frente de Pareto da Figura 5.11c, segundo os vetores de peso  $W = [w_{FC}, w_{LCOE}, w_{N_{dma}}]$  (ver Seção 4.7) para cada um dos 3 objetivos, conforme preferência do projetista. Para ilustrar as diferentes características de resultados conforme cada peso determinado, são consideradas as seguintes preferências de projetistas :

- $W_1 = [0.3333, 0.3333, 0.3333]$  → Peso equivalente para cada um dos 3 objetivos, sendo assim sem nenhuma preferência em especial;
- $W_2 = [0.3, 0.3, 0.4]$  → Maior preferência para parques com menos modelos diferentes de aerogeradores;
- $W_3 = [0.2, 0.4, 0.4]$  → Maior preferência para parques com menos modelos diferentes de aerogeradores e também com menores LCOE (interesse econômico de quem opera o parque eólico).

A Figura 5.16 apresenta a marcação na Frente de Pareto dos indivíduos escolhidos segundo o tomador de decisão multi-critério (Seção 4.7) utilizando-se os vetores de peso  $W_1$ ,  $W_2$  e  $W_3$ . A Figura 5.17 apresenta os *layouts* dos parques eólicos escolhidos, assim

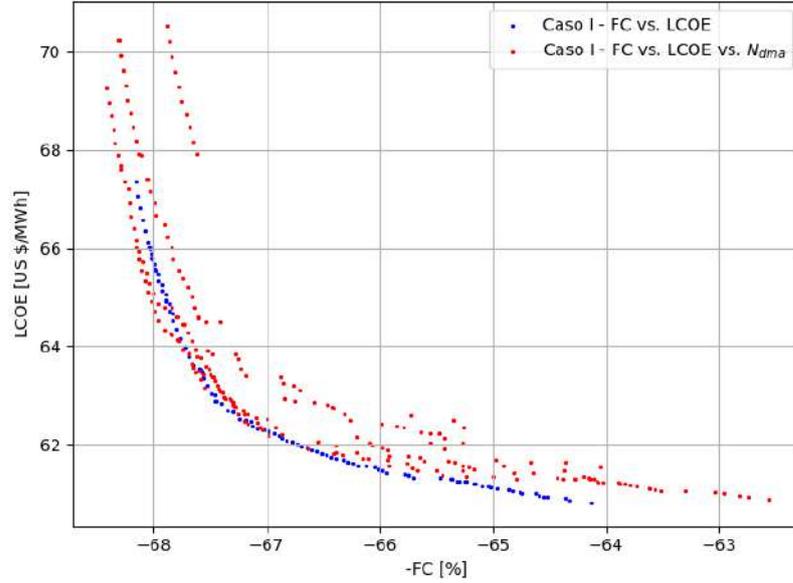


Figura 5.14: Comparação da frente de Pareto das abordagens do Caso I - FC vs. LCOE e Caso I - FC vs. LCOE vs.  $N_{dma}$  no plano dos objetivos FC vs. LCOE.

como os modelos dos aerogeradores escolhidos para compor a configuração das  $N_t = 30$  turbinas instaladas em cada parque.

A Figura 5.18 apresenta 3 condições de vento marcadas na distribuição anual de probabilidades de ocorrência. Estas condições são utilizadas para ilustrar o campo de velocidades dos parques eólicos selecionados (Figura 5.17) em cada uma destas condições, plotados através de simulações no *FLORIS*. As Figuras 5.19, 5.20 e 5.21 apresentam os campos de velocidades de cada um dos parques, sujeito a cada uma destas 3 condições de vento. A condição  $\mathbf{V}_{U_\infty, \theta}^1$  apresenta a condição do vento de maior probabilidade anual de ocorrência. A condição  $\mathbf{V}_{U_\infty, \theta}^2$  ilustra o parque eólico na sua condição de operação com maiores efeitos de esteira de turbulência, enquanto a condição  $\mathbf{V}_{U_\infty, \theta}^3$  apresenta o parque em operação no setor de direção do vento adjacente ao de  $\mathbf{V}_{U_\infty, \theta}^2$ .

A diferença de eficiência,  $\eta$ , entre as condições  $\mathbf{V}_{U_\infty, \theta}^2$  e  $\mathbf{V}_{U_\infty, \theta}^3$  pode ser observada na Figura 5.22, a qual mostra  $\eta$  em função das direções de ocorrência do vento. Esta variação considerável de  $\eta$  para setores adjacentes de direção do vento justifica a importância de se levar em consideração o número de setores de direção do vento na discretização para construção da função densidade de probabilidades em um processo de otimização de parques eólicos.

Também é possível observar na Figura 5.22 que as direções do vento com menores

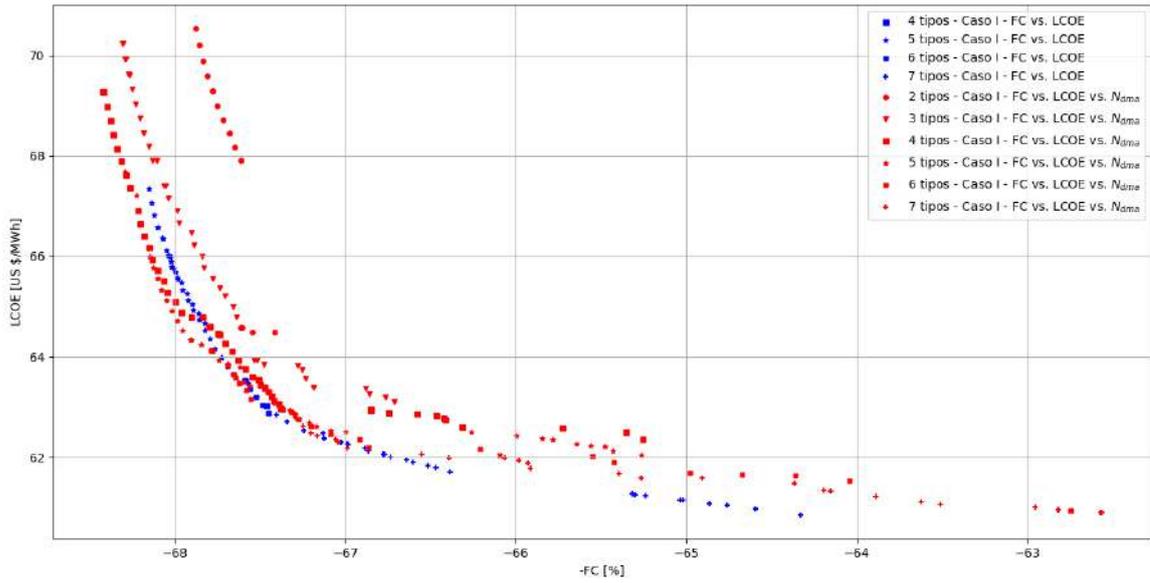


Figura 5.15: Comparação da frente de Pareto das abordagens do Caso I - FC vs. LCOE e Caso I - FC vs. LCOE vs.  $N_{dma}$  no plano dos objetivos FC vs. LCOE, utilizando uma rotulação nos indivíduos segundo seu número de modelos de aerogeradores diferentes,  $N_{dma}$ .

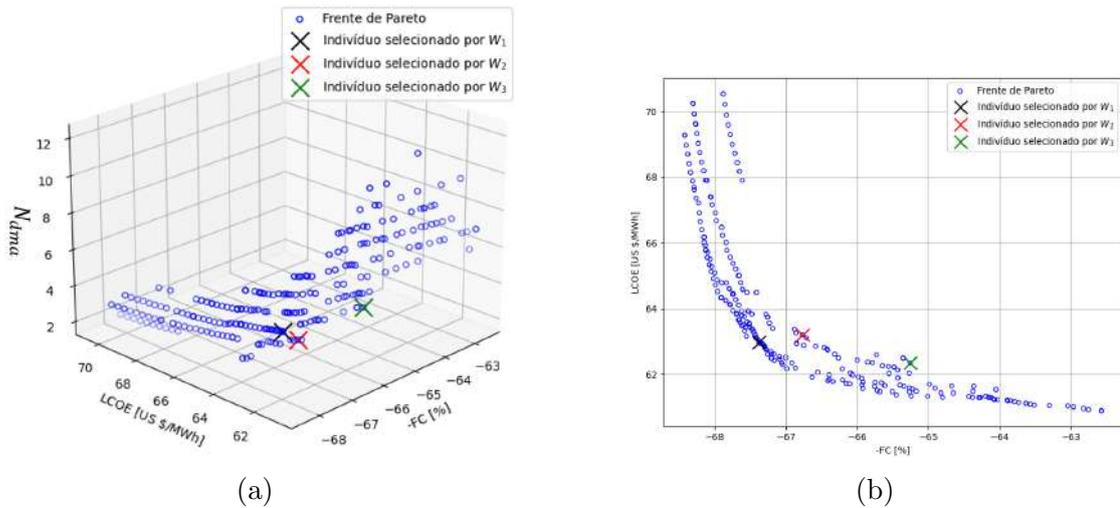


Figura 5.16: Indivíduos selecionados pelo tomador de decisão multi-critério, da Seção 4.7, segundo vetores de peso  $W_1$ ,  $W_2$  e  $W_3$ , marcados na a) frente de Pareto e na b) projeção da frente de Pareto no plano dos objetivos FC vs. LCOE.

valores de  $\eta$  são as direções alinhadas com os lados do domínio do parque, ao qual foi estipulada uma região quadrada (ver Seção 5.4), i.e.,  $\theta = 0^\circ, 90^\circ, 180^\circ$  e  $270^\circ$ . Isso revela que abordagens que forçam um formato pré-definido da região de domínio do parque eólico impactam nos resultados.

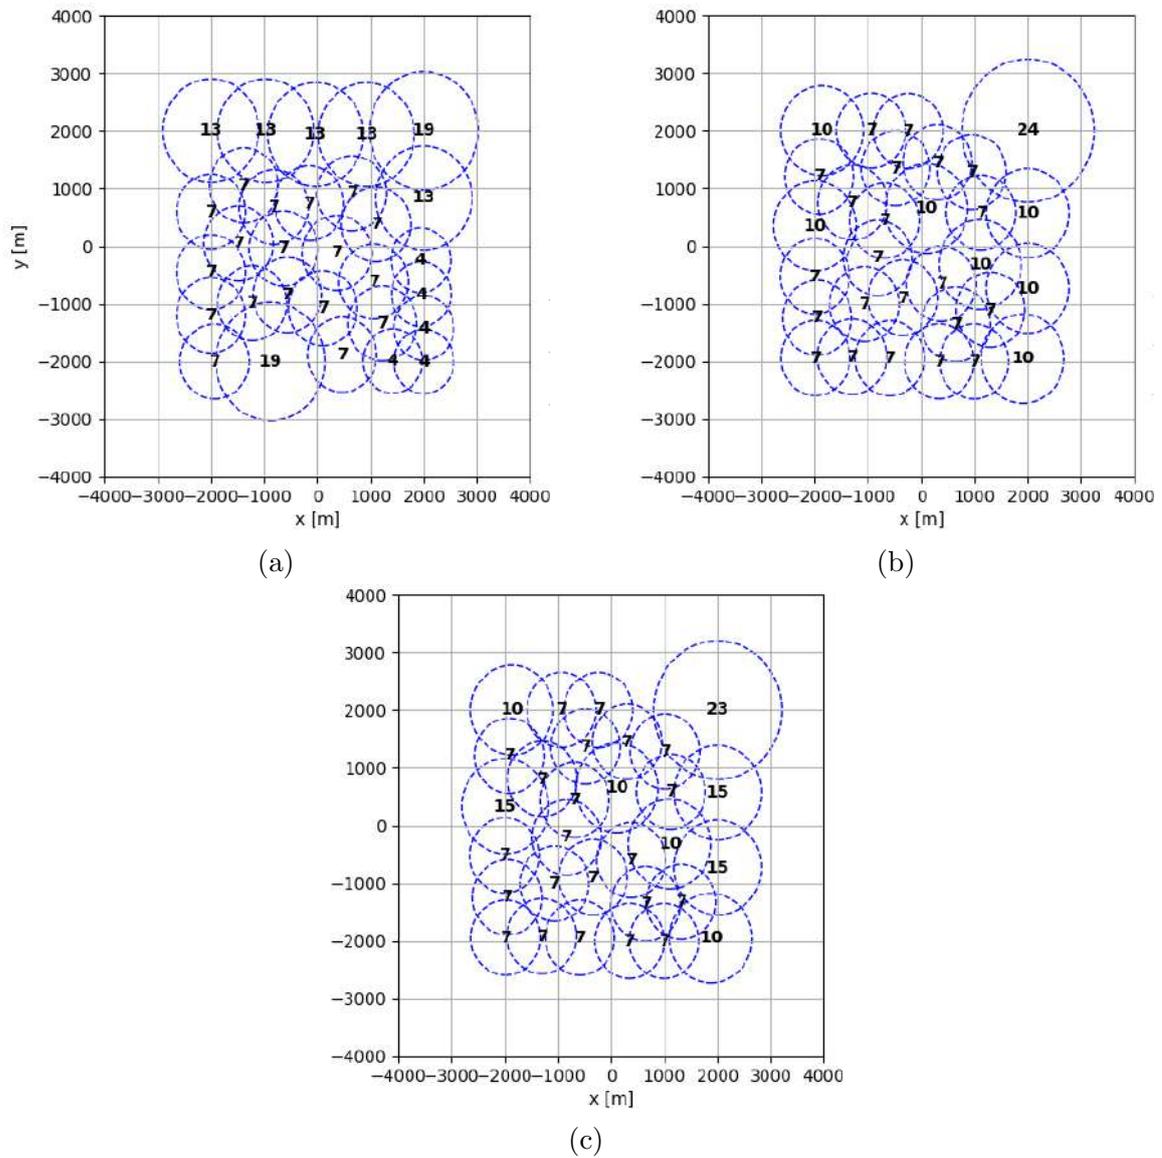


Figura 5.17: *Layout* dos parques eólicos escolhidos conforme vetores de peso a)  $W_1$ , b)  $W_2$  e c)  $W_3$ . Os números apresentam o modelo de cada aerogerador, dentre os 25 disponíveis da Tabela 5.1. A região delimitada pelos círculos azuis tracejados representa a região referente às restrições de proximidade (ver Seção 5.3) de cada uma das turbinas.

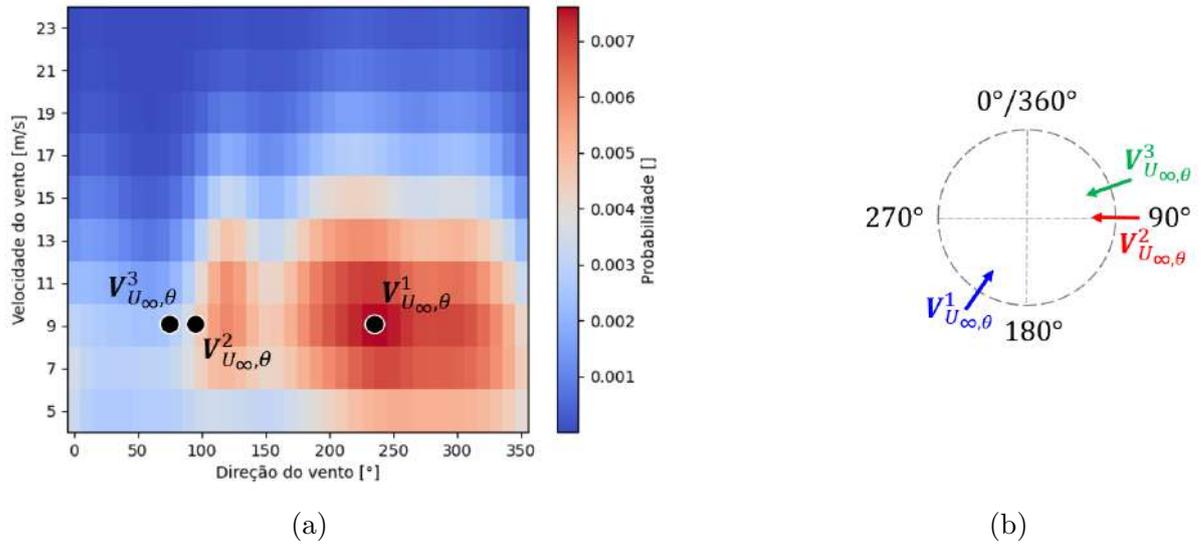


Figura 5.18: a) Marcação das 3 condições de vento utilizadas para ilustrar os campos de velocidades dos parques eólicos seleccionados pelo tomador de decisão multi-critério.  $\mathbf{V}_{U_{\infty},\theta}^1 = (U_{\infty} = 9 \text{ m/s}, \theta = 230^\circ)$ ,  $\mathbf{V}_{U_{\infty},\theta}^2 = (U_{\infty} = 9 \text{ m/s}, \theta = 90^\circ)$  e  $\mathbf{V}_{U_{\infty},\theta}^3 = (U_{\infty} = 9 \text{ m/s}, \theta = 70^\circ)$ ; b) Convenção do sistema de orientações das direções do vento, utilizada pelo *FLORIS*, e ilustrada conforme  $\mathbf{V}_{U_{\infty},\theta}^1$ ,  $\mathbf{V}_{U_{\infty},\theta}^2$  e  $\mathbf{V}_{U_{\infty},\theta}^3$ .

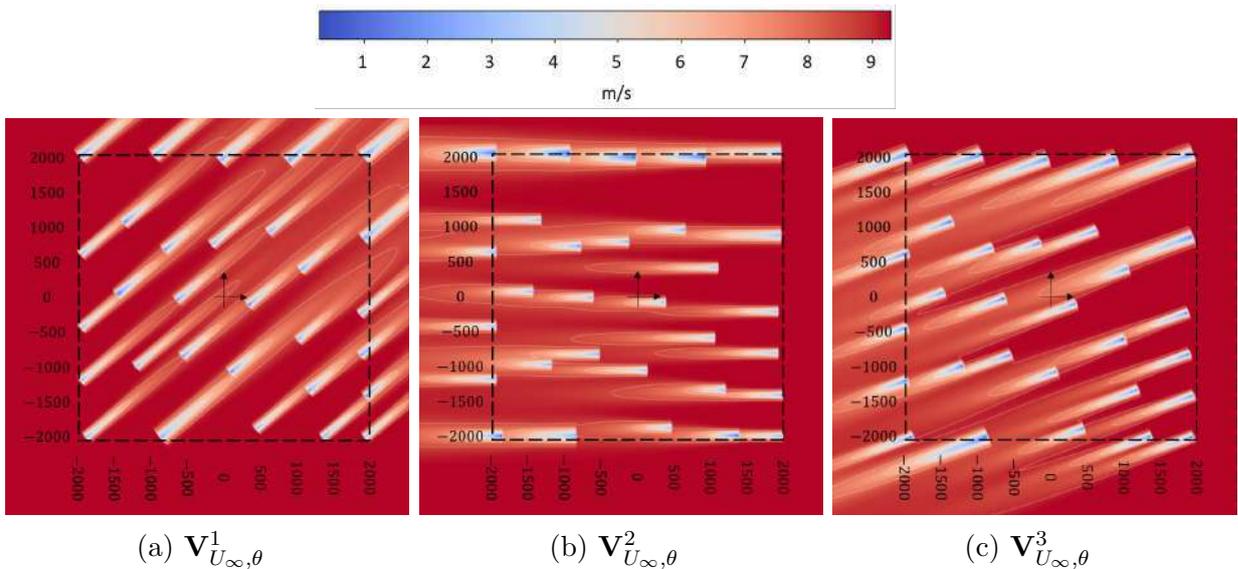


Figura 5.19: Campos de velocidades do parque eólico apontado pelo vetor de pesos  $W_1$  para cada uma das condições de vento seleccionadas na Figura 5.18a.

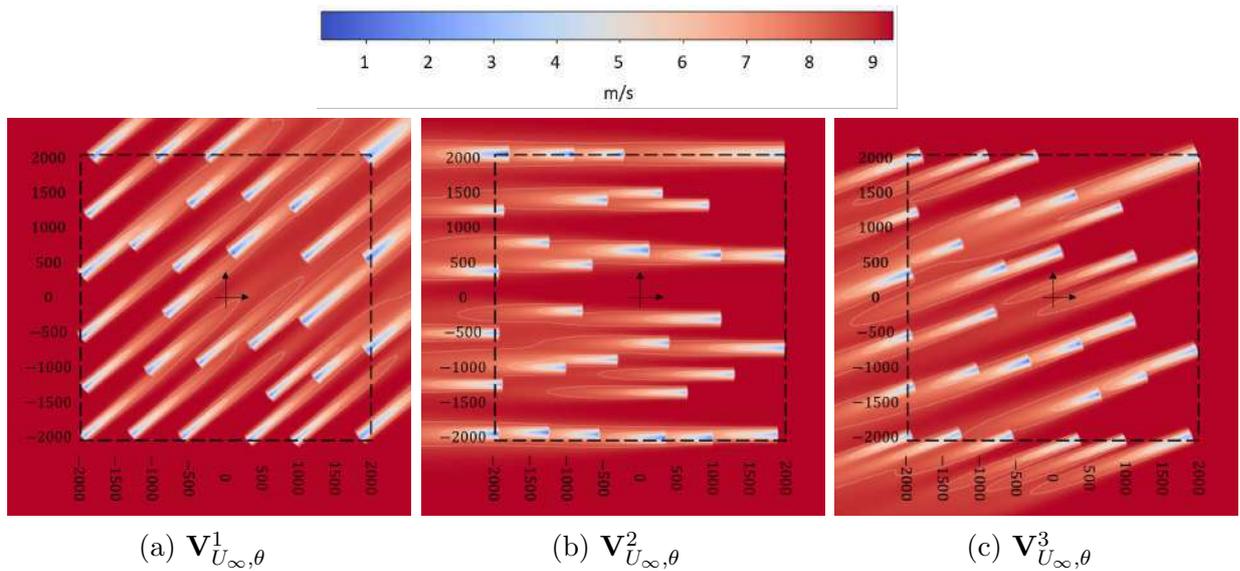


Figura 5.20: Campos de velocidades do parque eólico apontado pelo vetor de pesos  $W_2$  para cada uma das condições de vento selecionadas na Figura 5.18a.

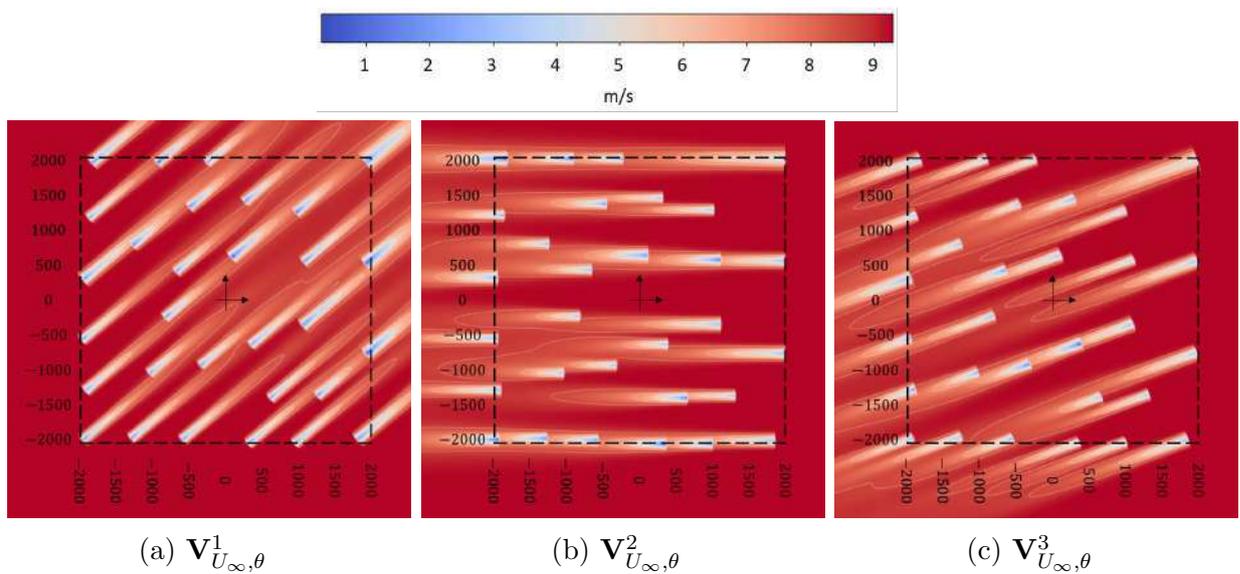


Figura 5.21: Campos de velocidades do parque eólico apontado pelo vetor de pesos  $W_3$  para cada uma das condições de vento selecionadas na Figura 5.18a.

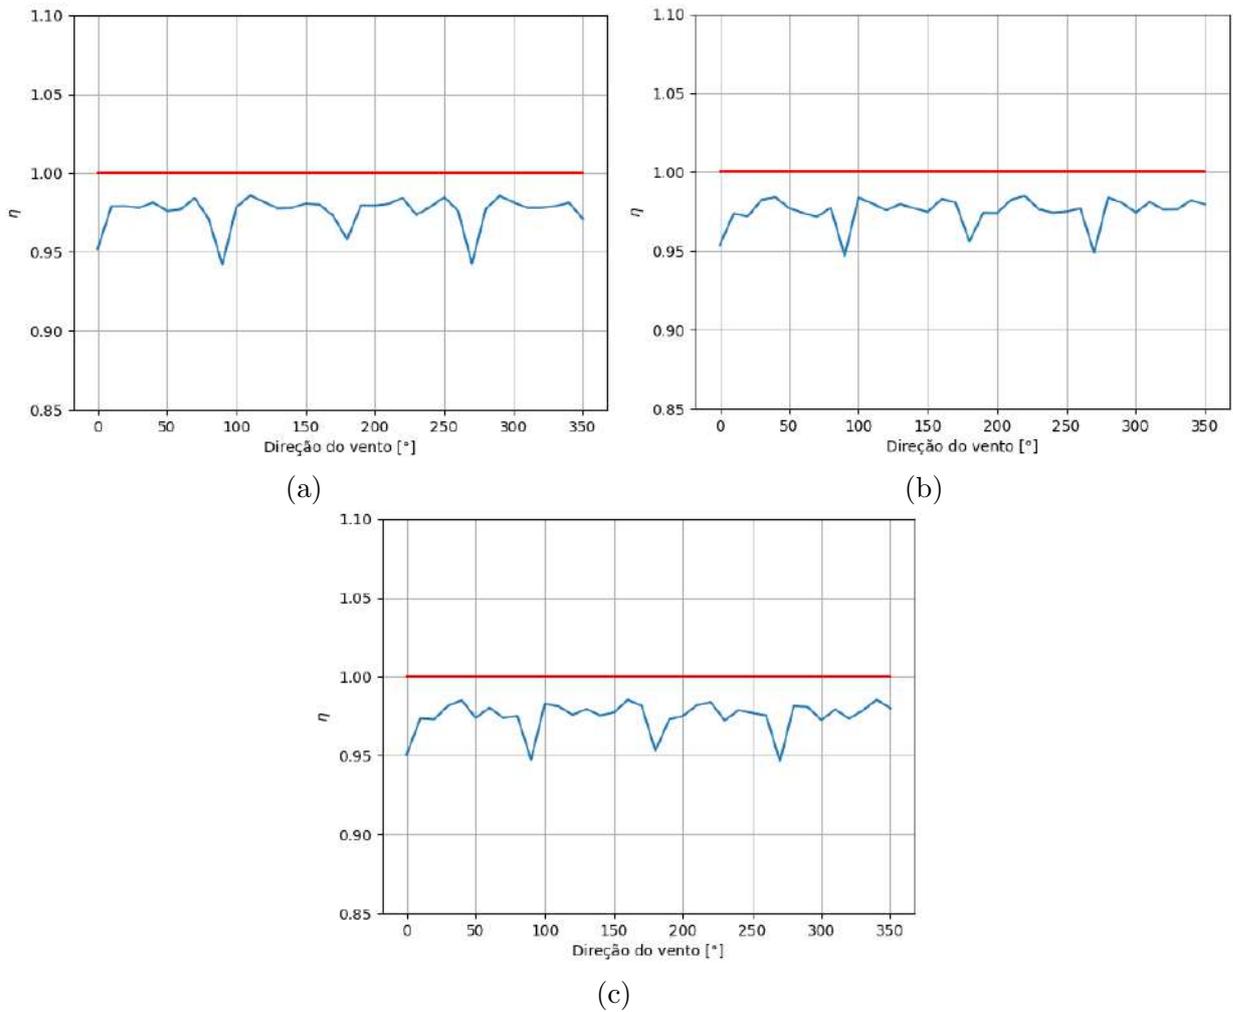


Figura 5.22: Eficiência do layout,  $\eta$  (Equação 3.4), dos parques eólicos a)  $W_1$ , b)  $W_2$  e c)  $W_3$  em função das direções do vento,  $\theta$ .

### 5.6.2 Caso II - $\eta$ vs. COE

A presente seção faz um comparativo semelhante ao realizado na seção anterior, porém com relação aos objetivos do Caso II, especificado conforme Seção 5.4.2. As Figuras 5.23a e 5.23b apresentam as frentes de Pareto obtidas para o Caso II -  $\eta$  vs. COE, para cada uma das rodadas independentes, segundo cada um dos dois algoritmos utilizados (NSGA-II e SMS-EMOA). Já a Figura 5.23c mostra as frentes de Pareto unificadas para cada um dos algoritmos, utilizadas para avaliação do  $IGD^+$ . Conforme mencionado na Seção 5.6.1, o processo de normalização e cálculo das métricas de desempenho são análogos ao da Seção anterior.

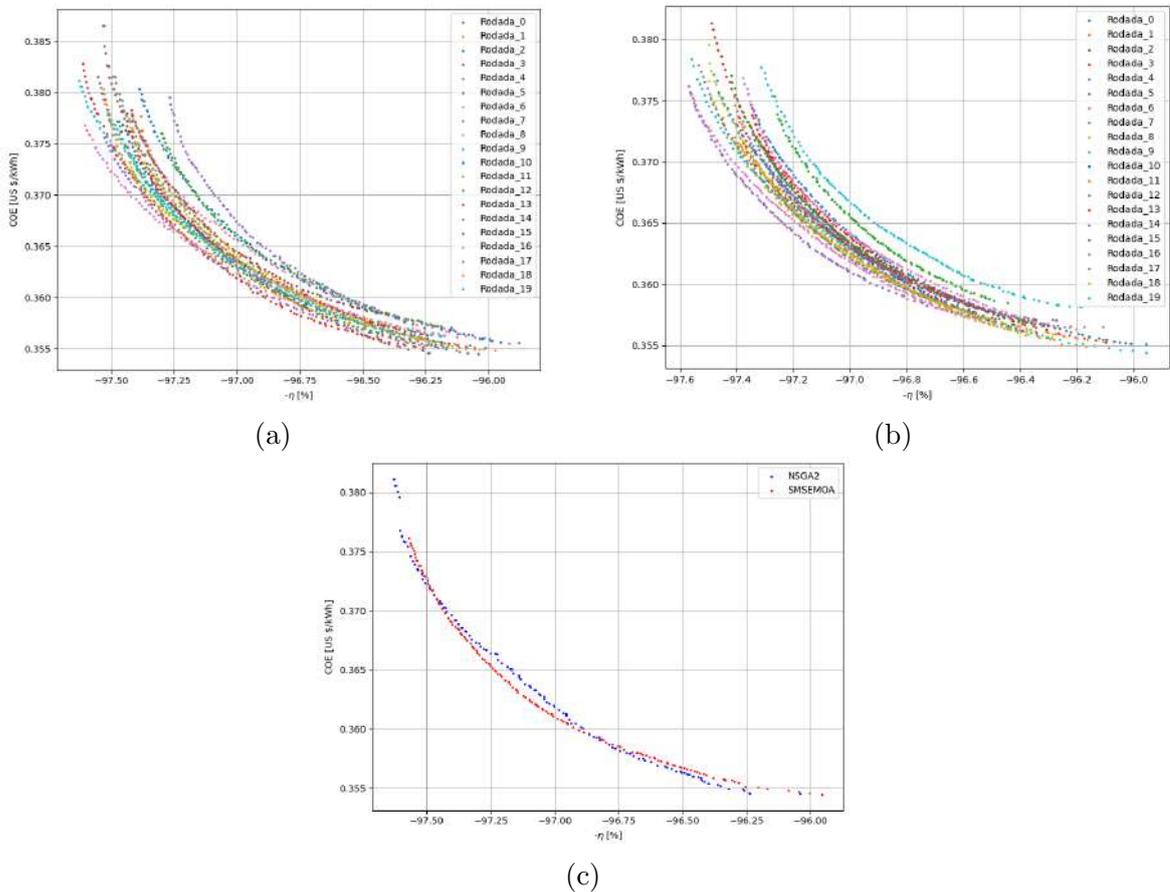


Figura 5.23: Frentes de Pareto das 20 rodadas independentes do Caso II -  $\eta$  vs. COE: a) NSGA-II e b) SMS-EMOA. c) Frentes de Pareto unificadas das 20 rodadas independentes do Caso II -  $\eta$  vs. COE, por algoritmo de a) e b).

As Figuras 5.24a e 5.24b apresentam as curvas de evolução das métricas de desempenho ( $IGD^+$  e Hipervolume) ao longo das gerações, para cada uma das 20 rodadas independentes de cada um dos dois algoritmos. Os valores da última geração (na qual atingem-se os critérios de parada dos algoritmos) são sumarizadas nas estatísticas apre-

sentadas na Tabela 5.7. Pode-se concluir dos baixos valores de  $\sigma_{IGD^+}$  e  $\sigma_{HV}$  que as 20 rodadas independentes de cada algoritmo tiveram níveis semelhantes de convergência e diversidade.

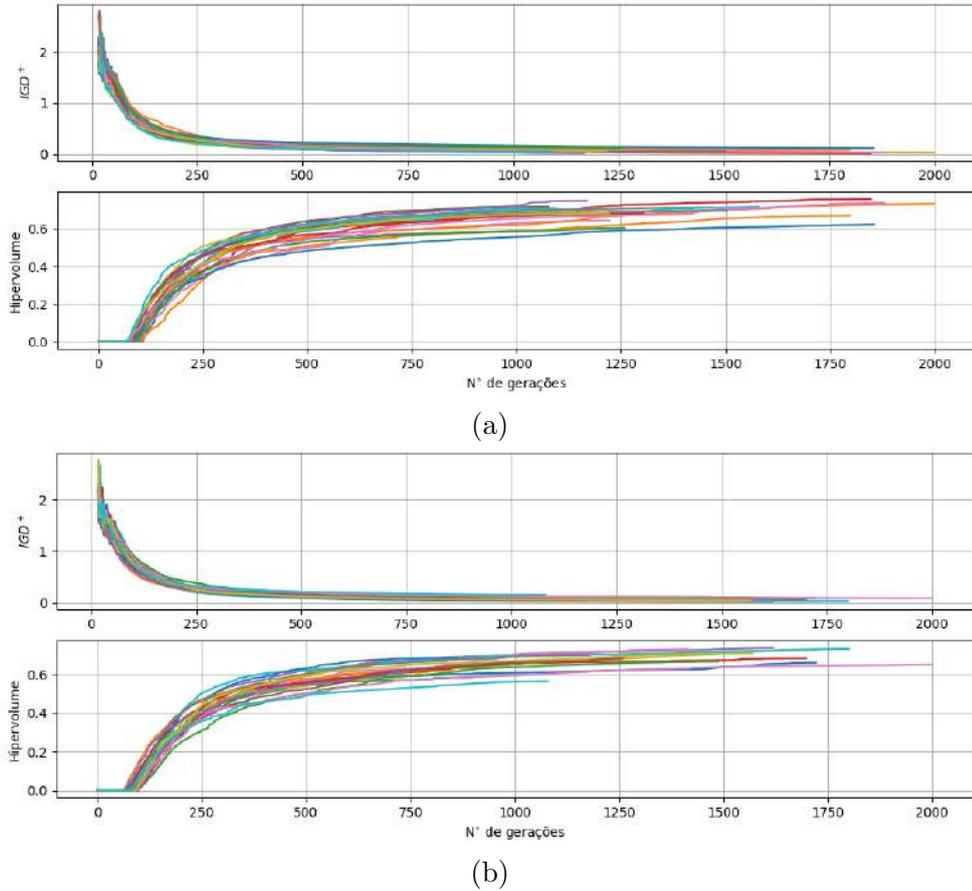


Figura 5.24: Curvas de evolução das métricas de desempenho ( $IGD^+$  e Hipervolume) ao longo das gerações de cada uma das 20 rodadas independentes dos algoritmos a) NSGA-II e b) SMS-EMOA.

A Figura 5.25a apresenta o histograma do número de modelos diferentes de aerogeradores presentes nos parques eólicos apontados por cada indivíduo da frente de Pareto unificada final, gerada pela unificação das frentes de Pareto da Figura 5.23c (ver Figura 5.25b). É possível observar que, embora a frente de Pareto apresente alguns resultados com 3 modelos diferentes de aerogeradores, a maior parte dos resultados permanece com parques utilizando 6 ou mais modelos diferentes de aerogeradores. Portanto, analisa-se também os resultados obtidos utilizando-se a abordagem proposta na Seção 5.4.3. As Figuras 5.26a e 5.26b apresentam as frentes de Pareto unificadas, para as 20 rodadas independentes, de cada algoritmo para o Caso II -  $\eta$  vs. COE vs.  $N_{dma}$ , utilizadas na avaliação do  $IGD^+$ , e com o ponto de referência  $W = (1.1, 1.1, 1.1)$  com processo de

Tabela 5.7: Análise estatística das métricas de desempenho para as 20 rodadas independentes de cada um dos dois algoritmos (NSGA-II e SMS-EMOA) para o Caso II =  $\eta$  vs. COE, onde:  $IGD_{media}^+$  e  $HV_{media}$  são a média da métrica  $IGD^+$  e do hipervolume, respectivamente, das 20 rodadas independentes;  $\sigma_{IGD^+}$  e  $\sigma_{HV}$  o desvio padrão das métricas de desempenho;  $IGD_{min}^+$  e  $IGD_{max}^+$  os valores mínimo e máximo do  $IGD^+$  dentre as 20 rodadas independentes e, de maneira análoga para os valores  $HV_{min}$  e  $HV_{max}$  do hipervolume.

	NSGA-II	SMS-EMOA
$IGD_{media}^+$	0.06333653	0.06326621
$\sigma_{IGD^+}$	0.03503011	0.03378971
$IGD_{min}^+$	0.01376731	0.01237554
$IGD_{max}^+$	0.14567273	0.15473606
$HV_{media}$	0.69025376	0.67896678
$\sigma_{HV}$	0.04698432	0.04418403
$HV_{min}$	0.58378758	0.56435677
$HV_{max}$	0.75943189	0.73714679

normalização equivalente ao apresentado na Seção 5.6.1. As Figuras 5.26c e 5.26d apresentam as curvas de evolução das métricas de desempenho, cujos valores na geração em que os critérios de parada são atingidos estão apresentados na Tabela 5.8. As conclusões qualitativas e quantitativas a respeito das curvas de evolução das métricas e da análise estatística dos valores é equivalente às discutidas anteriormente.

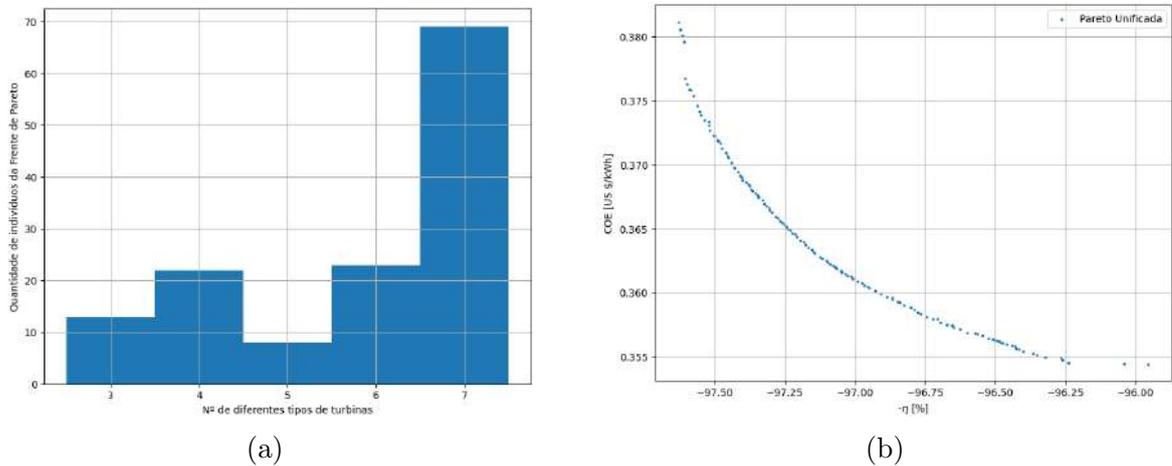


Figura 5.25: a) Histograma do número de indivíduos da frente de Pareto da Figura 5.8b que apresentaram parques eólicos com 3, 4, ..., 7 modelos diferentes de aerogeradores para o Caso I -  $\eta$  vs. COE; b) Frente de Pareto unificada final entre as frentes da Figura 5.23c.

A Figura 5.27a apresenta o histograma do número de modelos diferentes de aerogeradores presentes nos parques eólicos apontados por cada indivíduo da frente de Pareto unificada final, gerada pela unificação entre as frentes de Pareto das Figuras 5.26a e 5.26b (ver Figura 5.27c). É possível comparar os números de modelos diferentes de aerogera-

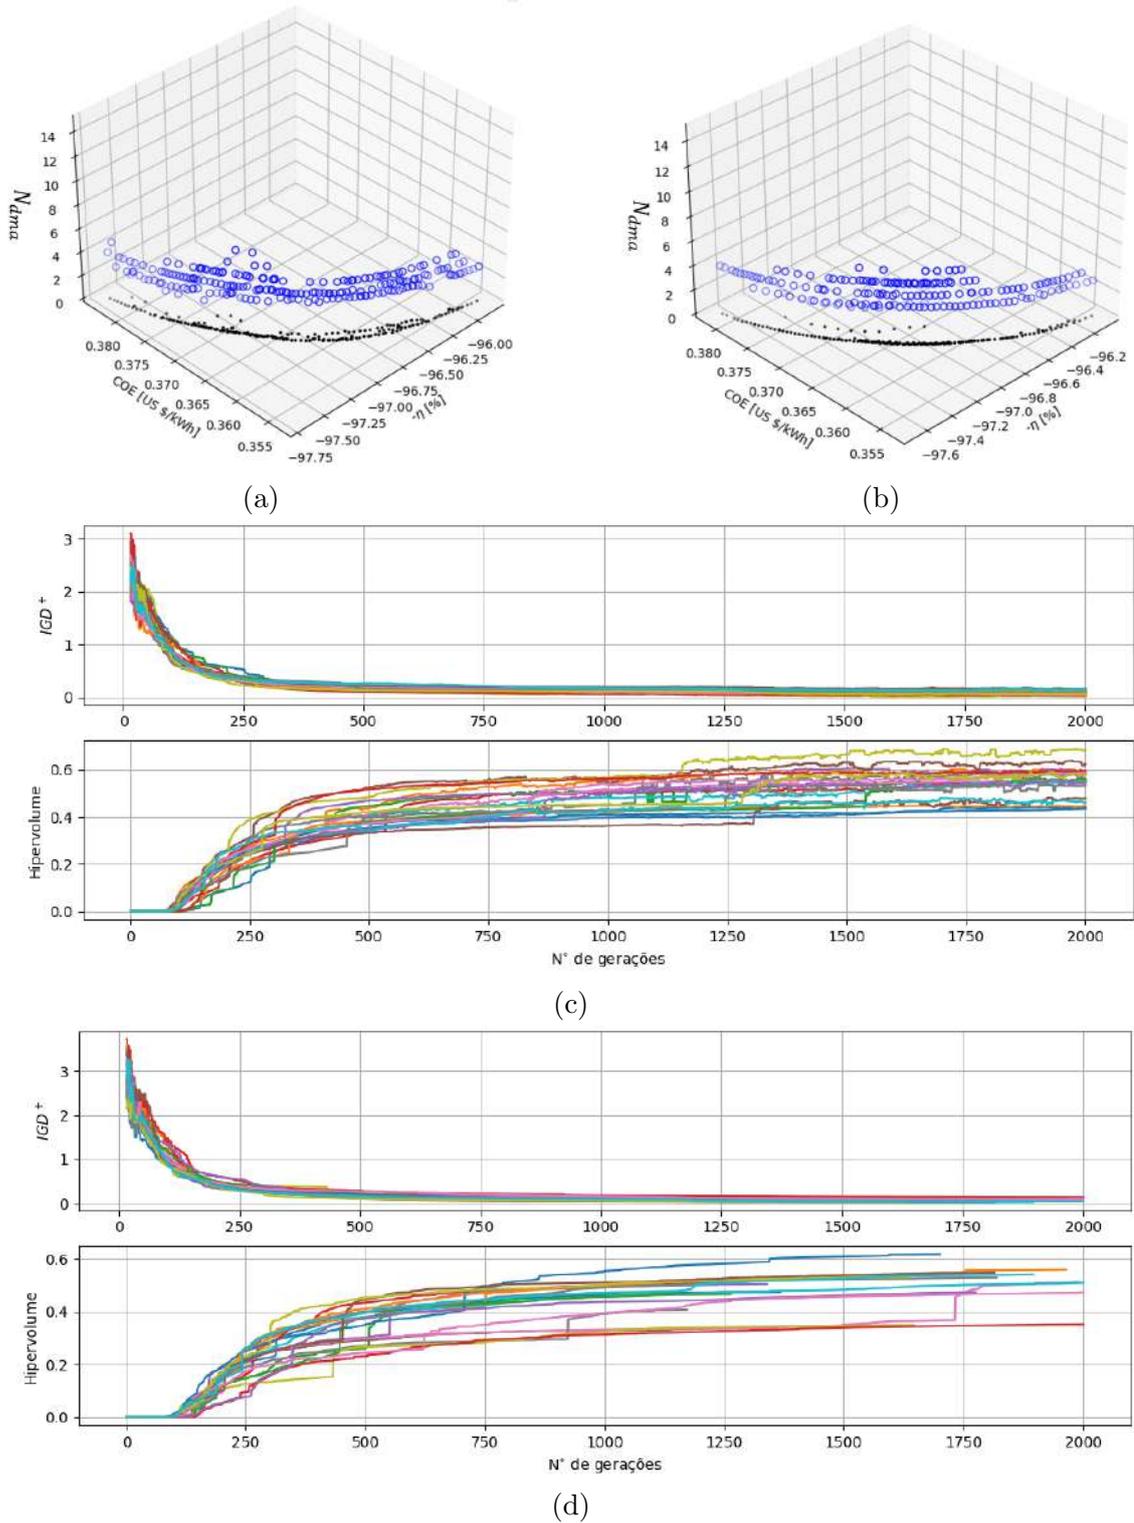


Figura 5.26: Frente de Pareto unificada das 20 rodadas independentes do Caso II -  $\eta$  vs. COE vs  $N_{dma}$ : a) NSGA-II e b) SMS-EMOA. Curvas de evolução das Métricas de desempenho ( $IGD^+$  e Hipervolume) ao longo das gerações de cada uma das 20 rodadas independentes dos algoritmos c) NSGA-II e d) SMS-EMOA.

dores empregados pelos indivíduos da frente de Pareto da Figura 5.25b, conforme mostra histograma da Figura 5.25a, com o número de modelos diferentes de aerogeradores empregados pelos resultados da abordagem da Figura 5.27c, conforme mostra a Figura 5.27a.

Tabela 5.8: Análise estatística das métricas de desempenho para as 20 rodadas independentes de cada um dos dois algoritmos (NSGA-II e SMS-EMOA) para o Caso II =  $\eta$  vs. COE vs.  $N_{dma}$ , onde:  $IGD_{media}^+$  e  $HV_{media}$  são a média da métrica  $IGD^+$  e do hipervolume, respectivamente, das 20 rodadas independentes;  $\sigma_{IGD^+}$  e  $\sigma_{HV}$  o desvio padrão das métricas de desempenho;  $IGD_{min}^+$  e  $IGD_{max}^+$  os valores mínimo e máximo do  $IGD^+$  dentre as 20 rodadas independentes e, de maneira análoga para os valores  $HV_{min}$  e  $HV_{max}$  do hipervolume.

	NSGA-II	SMS-EMOA
$IGD_{media}^+$	0.08477946	0.08268385
$\sigma_{IGD^+}$	0.03612328	0.04021408
$IGD_{min}^+$	0.01843645	0.03074638
$IGD_{max}^+$	0.15954240	0.16113799
$HV_{media}$	0.54422822	0.48471742
$\sigma_{HV}$	0.06249938	0.07174405
$HV_{min}$	0.43540113	0.33968213
$HV_{max}$	0.68231616	0.61745701

Percebe-se que a maioria dos resultados agora se encontra com 3 ou 4 modelos diferentes e com a presença de parques com 2 modelos diferentes apenas. Além disso, percebe-se pela Figura 5.27b que agora os aerogeradores do modelo 0 (Vestas V80 - 2MW) foram escolhidos com maior frequência. Isso é um reflexo direto da função objetivo  $\eta$ , devido a esta ser a turbina de menores dimensões e, por consequência, gerar menores efeitos de esteira que impactam nas demais.

A comparação seguinte é com relação aos valores dos objetivos de custo econômico e de performance - COE e  $\eta$ , respectivamente, comparando-se o impacto da abordagem do Caso II -  $\eta$  vs. COE vs.  $N_{dma}$ . Para este fim, projetam-se os pontos da frente de Pareto da Figura 5.27c no plano dos objetivos  $\eta$  vs. COE, conforme ilustra a Figura 5.28.

É possível observar que neste caso, na Figura 5.28, que a frente de Pareto do Caso II -  $\eta$  vs. COE domina a frente de Pareto do Caso II -  $\eta$  vs. COE vs.  $N_{dma}$  em uma boa extensão da frente. Entretanto, ao se estabelecer uma distinção do número de modelos de aerogeradores diferentes em cada indivíduo das duas frentes de Pareto, é possível observar que, apesar da nova abordagem apresentar indivíduos dominados em sua frente de Pareto, quando comparado com a abordagem anterior, a abordagem do Caso II -  $\eta$  vs. COE vs.  $N_{dma}$  faz com que a sua frente de Pareto tenha um desempenho pouco inferior ao da outra abordagem (com relação a valores de  $\eta$  e COE), porém com menos modelos de aerogeradores diferentes em seus parques, conforme ilustram as Figuras 5.29a

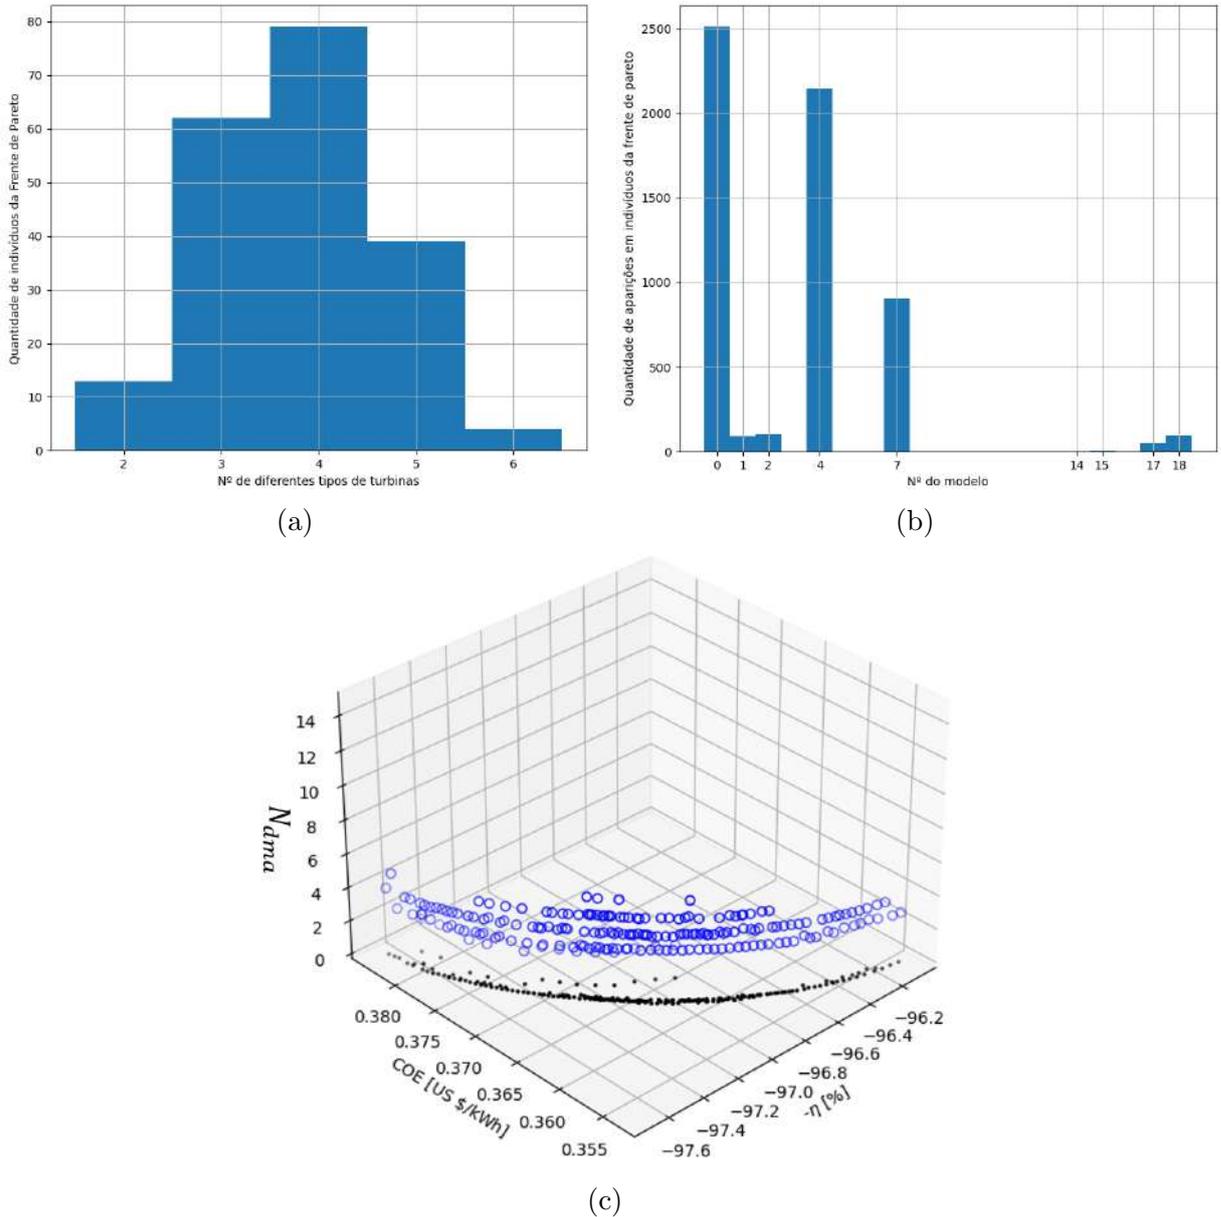


Figura 5.27: a) Histograma do número de indivíduos da frente de Pareto da Figura 5.27c que apresentaram parques eólicos com 2, 3, ..., 6 modelos diferentes de aerogeradores para o Caso II -  $\eta$  vs. COE vs.  $N_{dma}$ ; b) Número de ocorrências em que cada modelo, dentre os 25 disponíveis para seleção, foi selecionado para cada uma das 30 turbinas em cada um dos indivíduos que constituem a frente de Pareto da Figura 5.27c; c) Frente de Pareto unificada entre as frentes de Pareto das Figuras 5.26a e 5.26b.

e 5.29b.

Após as comparações realizadas entre as abordagens do Caso II -  $\eta$  vs. COE e Caso II -  $\eta$  vs. COE vs.  $N_{dma}$ , na sequência são apresentadas as extrações de alguns resultados da frente de Pareto da Figura 5.27c, segundo os vetores de peso  $W = [w_\eta, w_{COE}, w_{N_{dma}}]$  (ver Seção 4.7) para cada um dos 3 objetivos, conforme preferência do projetista. Para ilustrar as diferentes características de resultados conforme cada peso

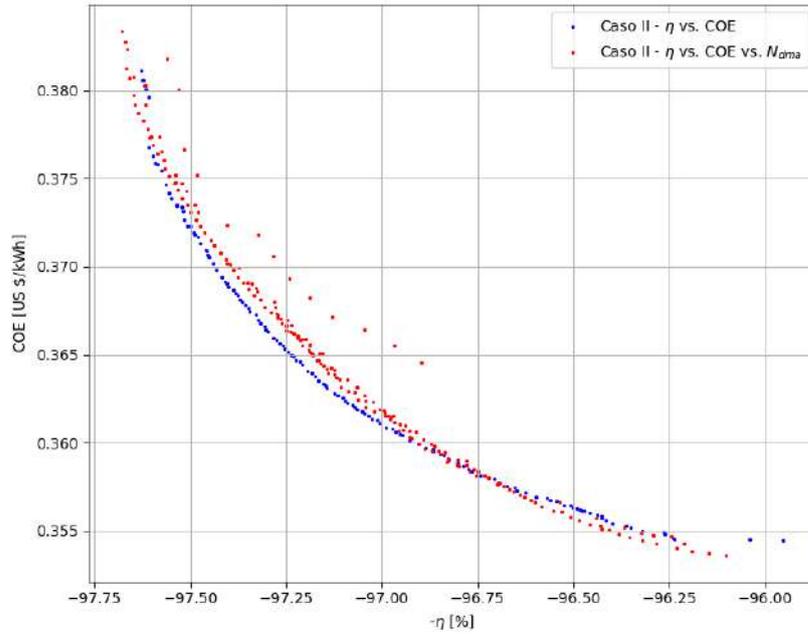
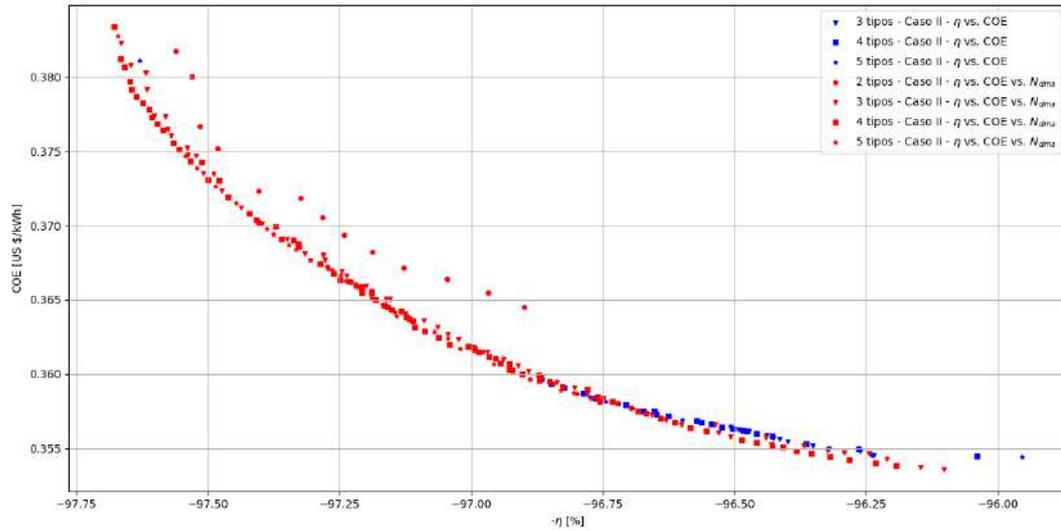


Figura 5.28: Comparação da frente de Pareto das abordagens do Caso II -  $\eta$  vs. COE e Caso II -  $\eta$  vs. COE vs.  $N_{dma}$  no plano dos objetivos  $\eta$  vs. COE.

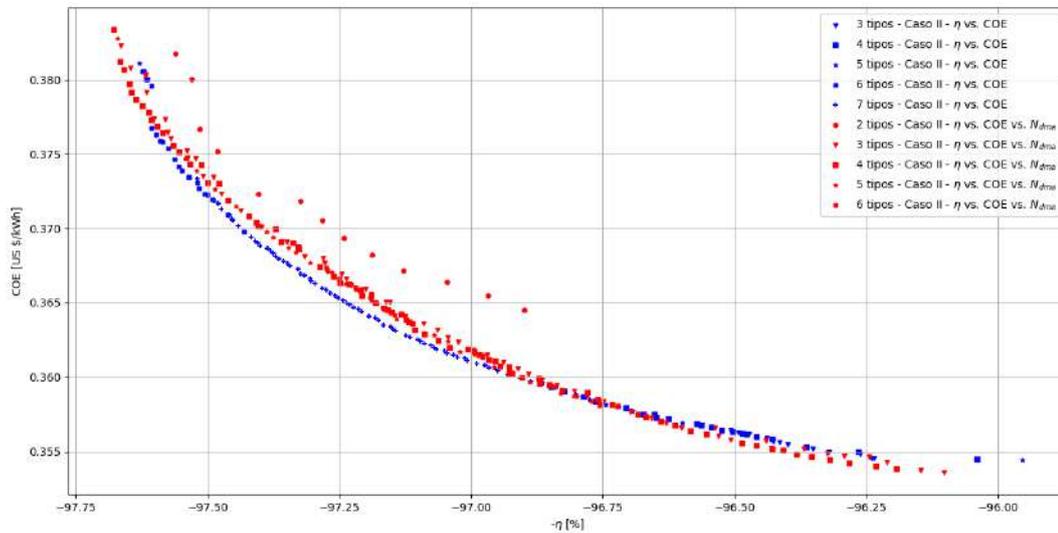
determinado, são considerados as seguintes preferências de projetistas :

- $W_1 = [0.3333, 0.3333, 0.3333]$  → Peso equivalente para cada um dos 3 objetivos, sendo assim sem nenhuma preferência em especial;
- $W_2 = [0.2, 0.4, 0.4]$  → Maior preferência para parques com menos modelos diferentes de turbinas e também com menores COE (custo de energia – Interesse econômico de investimento inicial vs. Capacidade de produção do parque);
- $W_3 = [0.4, 0.2, 0.4]$  → Maior preferência para parques com menos modelos diferentes de turbinas e também com maior eficiência do layout, i.e., menores efeitos de esteira nas turbinas (menor intensidade de turbulência nas pás e menores efeitos de fadiga nas estruturas das pás).

A Figura 5.30 apresenta a marcação na Frente de Pareto dos indivíduos escolhidos segundo o tomador de decisão multi-critério (Seção 4.7) utilizando-se os vetores de peso  $W_1$ ,  $W_2$  e  $W_3$ . A Figura 5.31 apresenta os *layouts* dos parques eólicos escolhidos conforme vetores de peso acima discutidos, assim como os modelos dos aerogeradores escolhidos para compor a configuração das  $N_t = 30$  turbinas instaladas em cada parque.



(a)



(b)

Figura 5.29: Comparação da frente de Pareto das abordagens do Caso II -  $\eta$  vs. COE e Caso II -  $\eta$  vs. COE vs.  $N_{dma}$  no plano dos objetivos  $\eta$  vs. COE utilizando rotulação nos indivíduos segundo seu número de modelos de aerogeradores diferentes,  $N_{dma}$ ; a) mostra os indivíduos da frente de Pareto que têm no máximo 5 modelos diferentes de aerogeradores, enquanto b) mostra os indivíduos com no máximo 7 modelos diferentes de aerogeradores.

De maneira semelhante à Seção 5.6.1, utilizou-se as três condições de vento marcadas na Figura 5.18. Estas condições são utilizadas para ilustrar o campo de velocidades dos parques eólicos selecionados (Figura 5.31) em cada uma destas condições. As Figuras 5.32, 5.33 e 5.34 apresentam os campos de velocidades de cada um dos parques, sujeito a cada uma destas três condições de vento.

De maneira análoga ao observado na Seção 5.6.1, também é possível observar na Figura 5.35 que as direções do vento com menores valores de  $\eta$  são as direções alinhadas

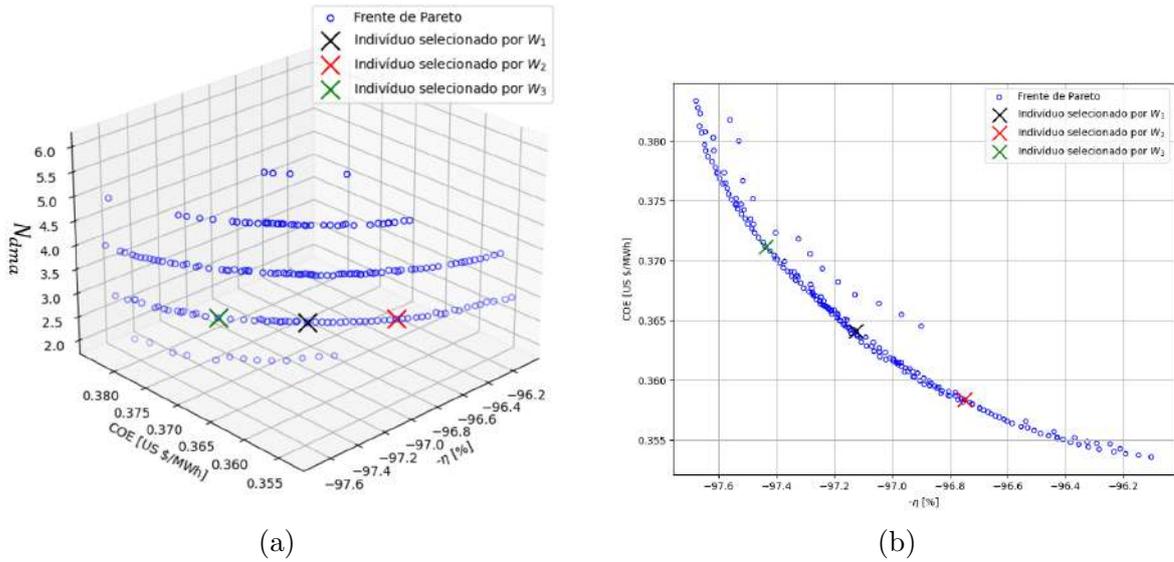


Figura 5.30: Indivíduos selecionados pelo tomador de decisão multi-critério, da Seção 4.7, segundo vetores de peso  $W_1$ ,  $W_2$  e  $W_3$ .

com os lados do domínio do parque, ao qual foi estipulada uma região quadrada (ver Seção 5.4), i.e.,  $\theta = 0^\circ, 90^\circ, 180^\circ$  e  $270^\circ$ . Isso revela que abordagens que forçam um formato pré-definido da região de domínio do parque eólico impactam nos resultados, independente das funções objetivo que se escolhe. Também é possível comparar, entre as Figuras 5.35 e 5.22, que para o caso desta seção, conseguiu-se uma média de valores de  $\eta$ , ao longo das direções do vento, ligeiramente maior do que o caso anterior (Seção 5.6.1), tendo em vista que a eficiência do layout,  $\eta$ , é uma das funções do presente trabalho, o que levou a escolha de turbinas do modelo número 0 (aerogerador de menor porte, ver Tabela 5.1) para minimizar os efeitos de esteira (aumentar  $\eta$ ) no domínio do parque, que é intensionalmente colocado com dimensões reduzidas.

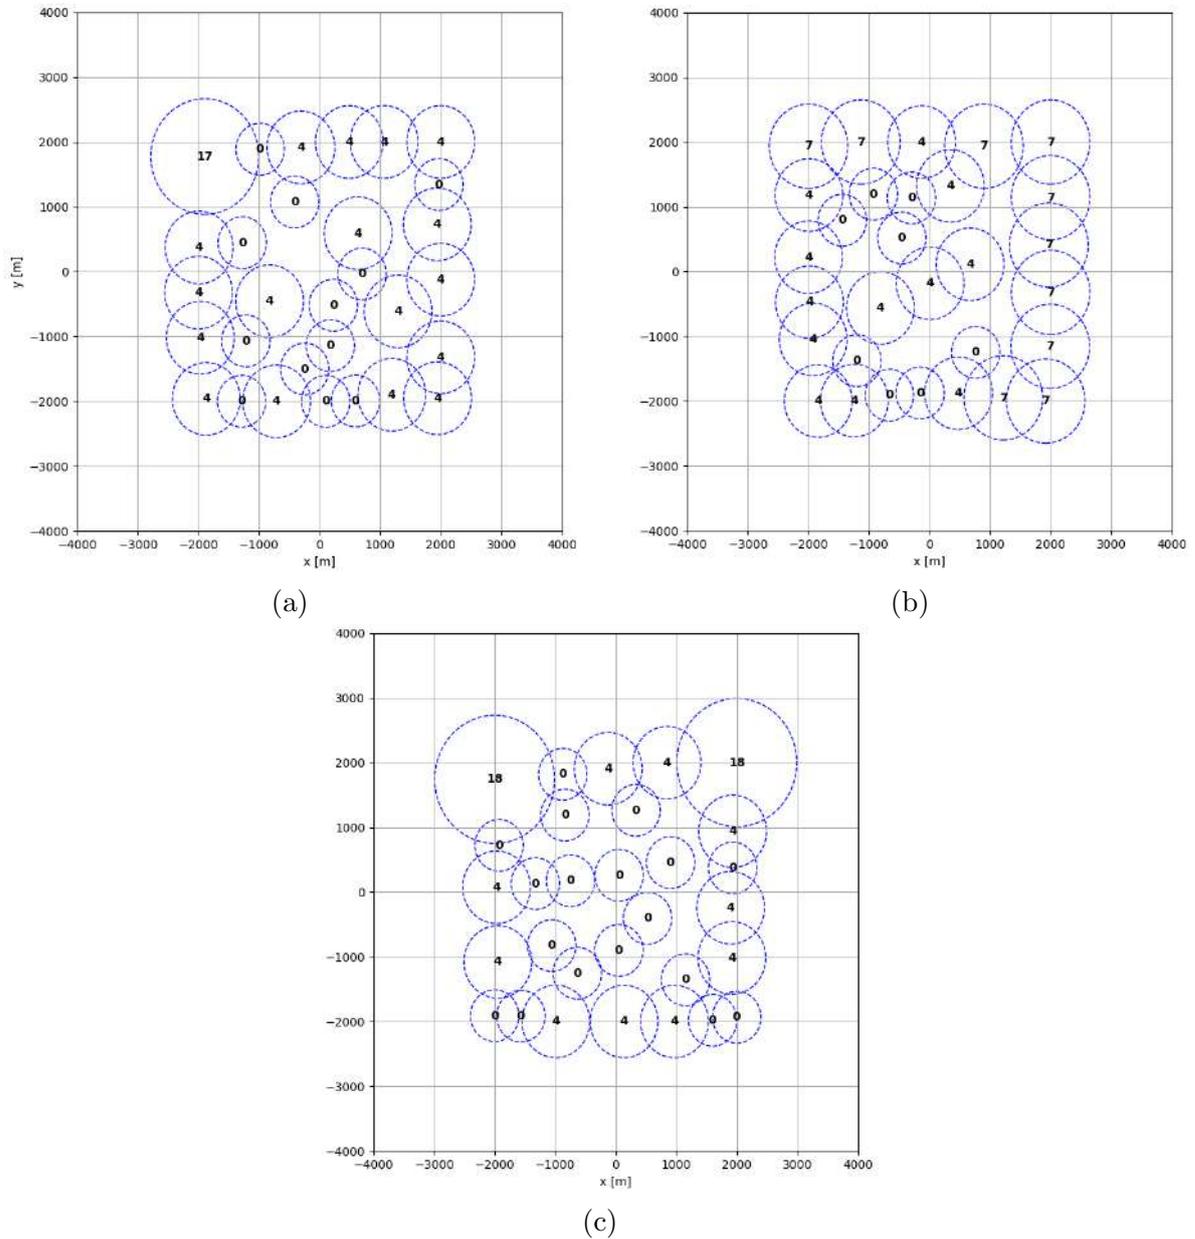


Figura 5.31: *Layout* dos parques eólicos escolhidos conforme vetores de peso a)  $W_1$ , b)  $W_2$  e c)  $W_3$ . Os números apresentam o modelo de cada aerogerador, dentre os 25 disponíveis da Tabela 5.1. A região delimitada pelos círculos azuis tracejados representa a região referente às restrições de proximidade (ver Seção 5.3) de cada uma das turbinas.

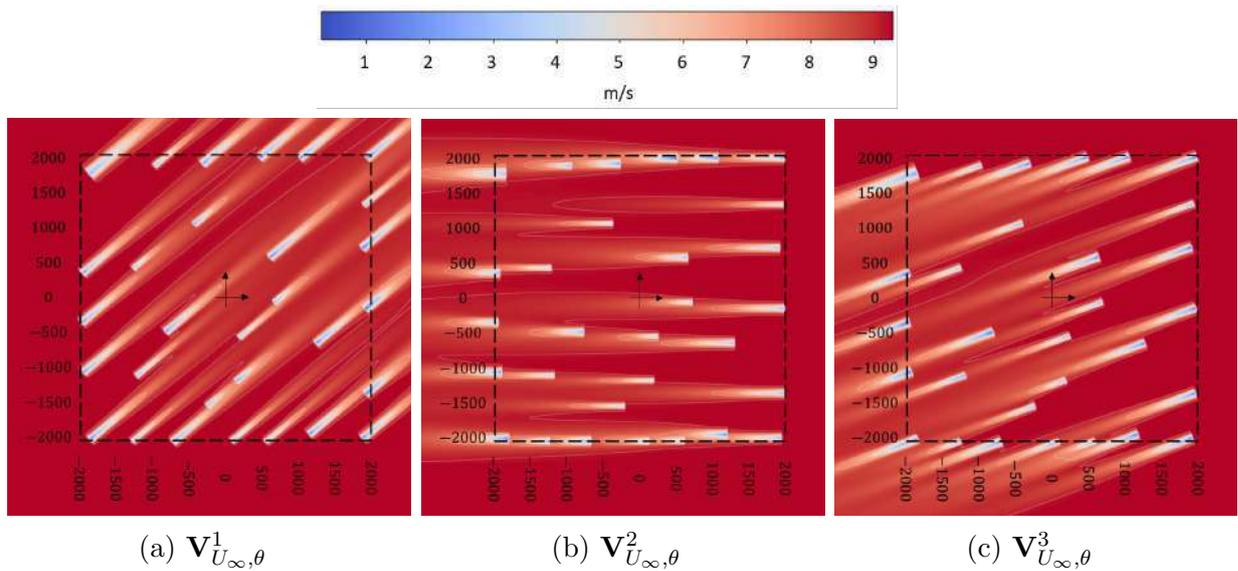


Figura 5.32: Campos de velocidades do parque eólico apontado pelo vetor de pesos  $W_1$  para cada uma das condições de vento selecionadas na Figura 5.18a.

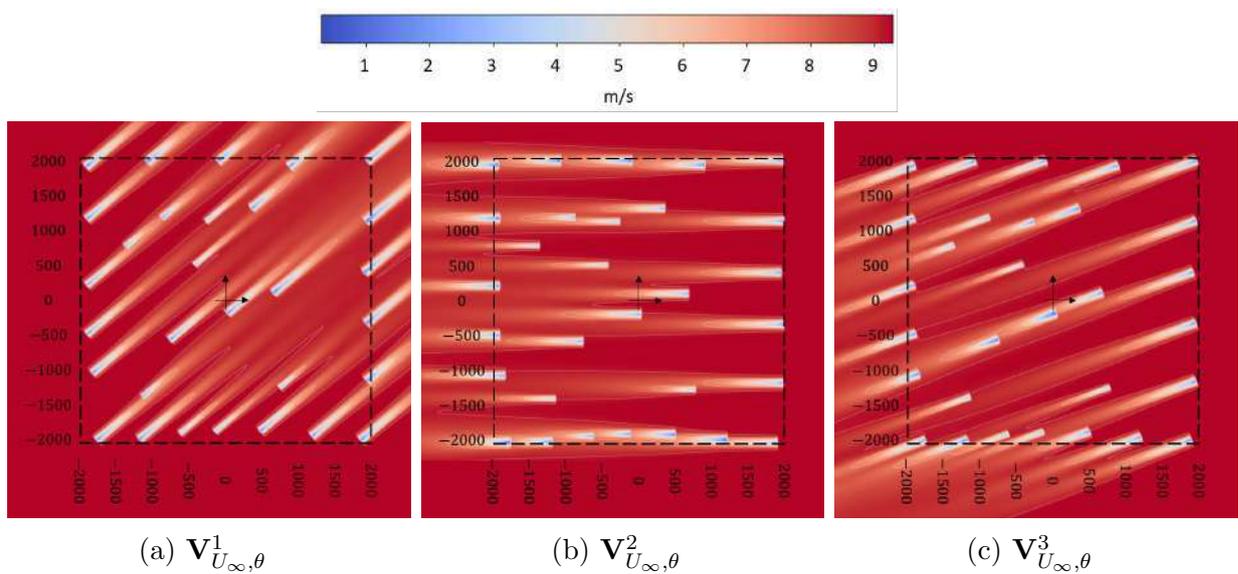


Figura 5.33: Campos de velocidades do parque eólico apontado pelo vetor de pesos  $W_2$  para cada uma das condições de vento selecionadas na Figura 5.18a.

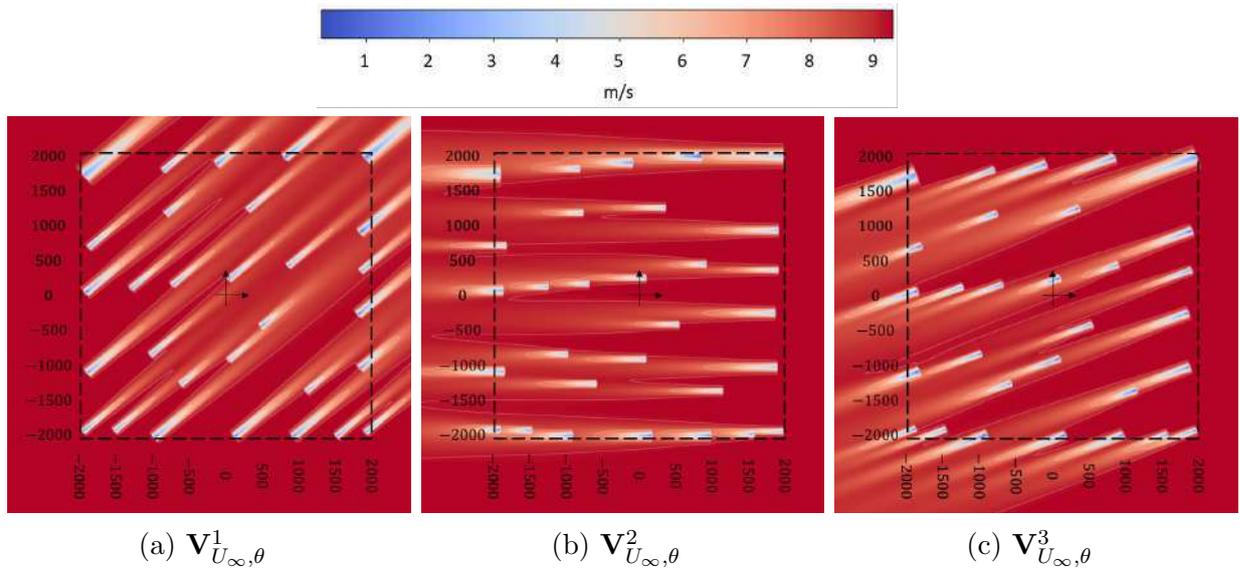


Figura 5.34: Campos de velocidades do parque eólico apontado pelo vetor de pesos  $W_3$  para cada uma das condições de vento selecionadas na Figura 5.18a.

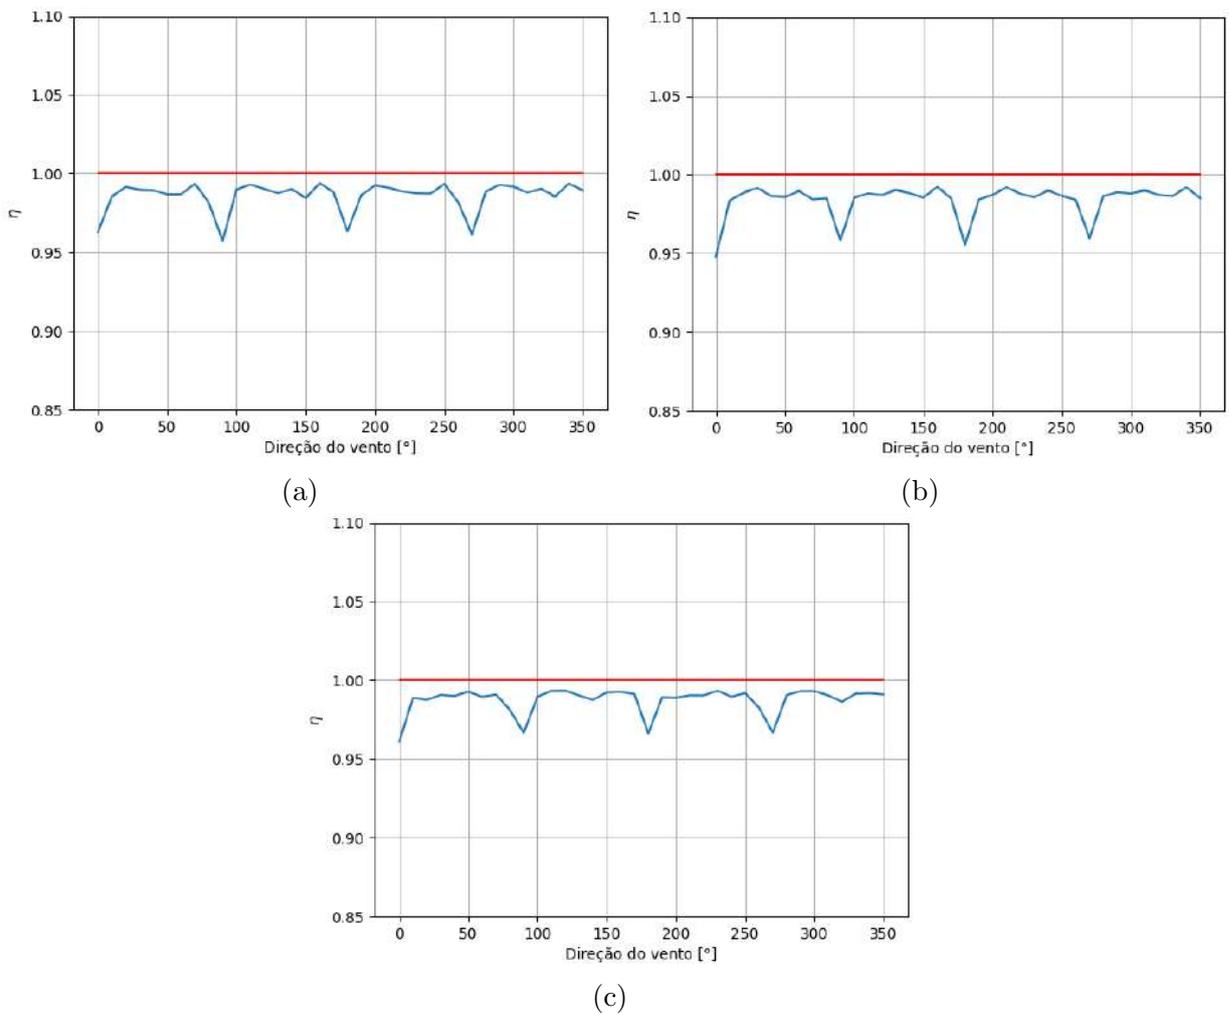


Figura 5.35: Eficiência do layout,  $\eta$  (Equação 3.4), dos parques eólicos a)  $W_1$ , b)  $W_2$  e c)  $W_3$  em função das direções do vento,  $\theta$ .

## 6 Conclusão

O trabalho apresentou uma nova abordagem no tratamento do escopo de projetos de parques eólicos *offshore* que utilizam diferentes modelos de aerogeradores na composição do mesmo. Conforme revisado por Tao et al. (2020), a instalação mista de modelos de aerogeradores diferentes pode ajudar a aumentar a potência total do parque, obter um menor custo de energia, melhorar a eficiência do layout e homogeneizar as cargas por fadiga. Em contrapartida, tal escopo de projeto leva a complicações logísticas de instalação, operação e manutenção do parque com estas características. O método insere um novo objetivo de projeto, o qual visa realizar um *trade-off* entre os ganhos de desempenho proporcionados por um arranjo com diversos modelos diferentes de turbinas, sem com que um número demasiadamente grande de modelos diferentes seja alocado pelos algoritmos de otimização empregados. Para tal, foram quantificados os desempenhos operacionais e econômicos (através das funções objetivo) de um parque eólico sujeito a condições reais de vento anual para avaliar os ganhos de projeto quando se aplica, e quando não se aplica, a abordagem aqui proposta em um projeto de parque eólico *offshore*. Modelos analíticos de esteira de turbulência foram empregados para modelagem do escoamento e interação das esteiras sobrepostas das turbinas eólicas no interior do parque, a fim de se obter as velocidades que cada turbina experimenta, em função do *layout* do parque, direção e intensidade dos ventos anuais, assim como das curvas de potência e empuxo de cada turbina em operação. Permitiu-se que o algoritmo de otimização atribuísse, de maneira independente para cada turbina, o modelo de aerogerador dentre um banco de 25 tipos aerogeradores pré-selecionados (destaca-se que os modelos de turbinas que compõe este banco podem ser facilmente alterados por um projetista). Para resolução do problema de otimização, empregou-se dois algoritmos evolucionários de otimização multiobjetivo e por fim, um tomador de decisão multi-critério foi utilizado para extração dos resultados da frente de Pareto, segundo preferências de projeto específicas.

Os estudos de caso apontaram que as abordagens do Caso I - FC vs. LCOE vs.  $N_{dma}$  e Caso II -  $\eta$  vs. COE vs.  $N_{dma}$ , i.e., abordagem com três objetivos de projeto

proposta no presente trabalho, apesar de apresentarem indivíduos de sua frente de Pareto ligeiramente dominados pelos indivíduos de seus respectivos contrapontos (i.e., abordagem sem adotar o terceiro objetivo  $N_{dma}$ ), os resultados da abordagem aqui proposta, em sua grande maioria, apresentam um número de modelos diferentes de aerogeradores alocados muito inferior, o que minimiza as complicações logísticas de instalação, operação e manutenção dos parques eólicos que adotem um escopo de projeto com tipos de turbinas diferentes. Conforme se pode observar nas Figuras 5.15 e 5.29, os valores em fator de capacidade e custo nivelado de energia (Caso I) e eficiência do *layout* e custo de energia (Caso II), obtidos através da abordagem aqui proposta, são competitivos aos resultados obtidos sem considerar  $N_{dma}$ , com o acréscimo de que os resultados da presente abordagem são obtidos utilizando menos modelos diferentes de aerogeradores. Tudo indica que a diferença entre as abordagens é que, devido aos Casos I - FC vs. LCOE e II -  $\eta$  vs. COE não terem nenhum mecanismo que pondera o número de diferentes modelos de aerogeradores, os resultados destes casos exploram a região de busca independente do número de modelos diferentes de turbinas que estão sendo alocados, enquanto na abordagem aqui proposta acontece esta ponderação por meio do terceiro objetivo inserido. É importante destacar que as questões referentes à viabilidade econômica de se implementar um parque eólico *offshore* com diferentes tipos de turbinas devem ser consideradas em decorrência de suas complicações logísticas de instalação, operação e manutenção, o que também pode-se atribuir ao mercado de energia eólica *offshore* ser muito recente, e que, com o tempo, as tecnologias envolvidas podem ter seus custos reduzidos, tornando a implementação e operação de parques eólicos com tipos diferentes de turbinas mais viável economicamente. A abordagem para tratamento do *trade-off* entre os ganhos de desempenhos, proporcionados por parques com este escopo, e a minimização do número de diferentes tipos de turbinas eólicas foi a principal contribuição do presente trabalho.

Por fim, destaca-se que a entrega deste trabalho configura um ferramental matemática capaz de realizar otimização multiobjetivo do *layout* de parques eólicos *offshore* com diferentes tipos de turbinas eólicas (podendo ser facilmente adaptado para escopos com apenas um tipo). Esta ferramenta permite sua parametrização com diferentes funções objetivos, alteração nos modelos de turbinas pré-cadastrados, alteração nas dis-

tribuições anuais de vento, diferentes domínios do parque eólico e restrições de modo a adequar a uma aplicação em projeto real, além de permitir a incorporação de novas características não contempladas no presente trabalho. Para acesso aos arquivos disponibilizados pelo autor, consultar o repositório do link: ([https://github.com/UnderMou/wind\\_farm\\_layout\\_optimization\\_framework](https://github.com/UnderMou/wind_farm_layout_optimization_framework)).

Algumas conclusões sobre os resultados levam a possíveis trabalhos futuros, os quais podem-se destacar:

- Abordar os dois estudos de caso sem a imposição de uma geometria para o formato do parque eólico (aqui considerado como uma região quadrada), restringindo apenas a área máxima permitida (podendo ser igual a aqui considerada) e comparar as frentes de pareto;
- Considerar o número de turbinas eólicas instaladas no parque também como uma variável de decisão de projeto;
- Considerar a profundidade de água no local de instalação de cada turbina individualmente, i.e., adotar no escopo do projeto a batimetria do local para instalação do parque;
- Usar algoritmos evolucionários com direções ou pontos de referência para explorar localmente regiões da frente de Pareto selecionadas pelo tomador de decisão multicritério;
- Por se tratar de um problema em que a restrição tem fortes influências nas primeiras iterações, utilizar diferentes algoritmos evolucionários que tenham um tratamento menos contundente para indivíduos/regiões ineficazes (como o caso dos mecanismos de seleção do NSGA-II e SMS-EMOA). A princípio sugere-se o DSPCMDE (*Dynamic Selection Preference-Assisted Constrained Multiobjective Differential Evolution*) (YU et al., 2022);
- Utilizar modelos de simulação da esteira capazes de captar efeitos como: estabilidade atmosférica e/ou terrenos complexos (parques eólicos *onshore*);

- 
- Comparar o tempo de otimização e qualidade dos resultados utilizando modelos analíticos tridimensionais de esteira com abordagens utilizando modelos *surrogate* (SUDRET; MARELLI; WIART, 2017) para otimização de parques eólicos *offshore*.

## Bibliografia

- ABDULRAHMAN, M.; WOOD, D. Investigating the power-coe trade-off for wind farm layout optimization considering commercial turbine selection and hub height variation. *Renewable Energy*, v. 102, p. 267–278, 2017. ISSN 0960-1481. Disponível em: [⟨https://www.sciencedirect.com/science/article/pii/S096014811630903X⟩](https://www.sciencedirect.com/science/article/pii/S096014811630903X).
- ABKAR, M.; PORTÉ-AGEL, F. Mean and turbulent kinetic energy budgets inside and above very large wind farms under conventionally-neutral condition. *Renewable Energy*, v. 70, p. 142–152, 2014. ISSN 0960-1481. Special issue on aerodynamics of offshore wind energy systems and wakes. Disponível em: [⟨https://www.sciencedirect.com/science/article/pii/S0960148114002146⟩](https://www.sciencedirect.com/science/article/pii/S0960148114002146).
- ACERO, J. F. H. et al. A review of methodological approaches for the design and optimization of wind farms. *Energies*, *Energies*, p. 6930–7016, 10 2014.
- ARCHER, C. L.; MIRZAEISEFAT, S.; LEE, S. Quantifying the sensitivity of wind farm performance to array layout options using large-eddy simulation. *Geophysical Research Letters*, Wiley Online Library, v. 40, n. 18, p. 4963–4970, 2013.
- ARYA, S. P. *Introduction to Micrometeorology*. Academic Press, 2001. v. 79. ISSN 0074-6142. Disponível em: [⟨https://www.sciencedirect.com/science/article/pii/S0074614201800292⟩](https://www.sciencedirect.com/science/article/pii/S0074614201800292).
- ASSIS TAVARES, L. F. et al. Influence of the wrf model and atmospheric reanalysis on the offshore wind resource potential and cost estimation: A case study for rio de janeiro state. *Energy*, v. 240, p. 122767, 2022. ISSN 0360-5442. Disponível em: [⟨https://www.sciencedirect.com/science/article/pii/S0360544221030164⟩](https://www.sciencedirect.com/science/article/pii/S0360544221030164).
- AZLAN, F. et al. Review on optimisation methods of wind farm array under three classical wind condition problems. *Renewable and Sustainable Energy Reviews*, v. 135, p. 110047, 2021. ISSN 1364-0321. Disponível em: [⟨https://www.sciencedirect.com/science/article/pii/S1364032120303385⟩](https://www.sciencedirect.com/science/article/pii/S1364032120303385).
- BANTA, R. M. et al. 3d volumetric analysis of wind turbine wake properties in the atmosphere using high-resolution doppler lidar. *Journal of Atmospheric and Oceanic Technology*, v. 32, n. 5, p. 904–914, 2015.
- BARTHELMIE, R. et al. Modelling the impact of wakes on power output at nysted and horns rev. In: *European wind energy conference*. [S.l.: s.n.], 2009. v. 2, p. 1351–1373.
- BARTHELMIE, R.; JENSEN, L. Evaluation of wind farm efficiency and wind turbine wakes at the nysted offshore wind farm. *Wind Energy*, JohnWiley & Sons Ltd., v. 13, n. 6, p. 573–586, 2010. ISSN 1095-4244.
- BARTHELMIE, R. J. et al. Flow and wakes in large wind farms in complex terrain and offshore. Industriales, 2008.
- BARTHELMIE, R. J. et al. Modelling and measuring flow and wind turbine wakes in large wind farms offshore. *Wind Energy*, v. 12, n. 5, p. 431–444, 2009. Disponível em: [⟨https://onlinelibrary.wiley.com/doi/abs/10.1002/we.348⟩](https://onlinelibrary.wiley.com/doi/abs/10.1002/we.348).

- BARTHELMIE, R. J. et al. Comparison of wake model simulations with offshore wind turbine wake profiles measured by sodar. *Journal of Atmospheric and Oceanic Technology*, American Meteorological Society, Boston MA, USA, v. 23, n. 7, p. 888 – 901, 2006. Disponível em: [https://journals.ametsoc.org/view/journals/atot/23/7/jtech1886\\_1.xml](https://journals.ametsoc.org/view/journals/atot/23/7/jtech1886_1.xml).
- BARTHELMIE, R. J. et al. Quantifying the impact of wind turbine wakes on power output at offshore wind farms. *Journal of Atmospheric and Oceanic Technology*, American Meteorological Society, Boston MA, USA, v. 27, n. 8, p. 1302 – 1317, 2010. Disponível em: [https://journals.ametsoc.org/view/journals/atot/27/8/2010jtecha1398\\_1.xml](https://journals.ametsoc.org/view/journals/atot/27/8/2010jtecha1398_1.xml).
- BASTANKHAH, M.; PORTE-AGEL, F. A new analytical model for wind-turbine wakes. *Renewable Energy*, v. 70, p. 116–123, 2014. ISSN 0960-1481. Special issue on aerodynamics of offshore wind energy systems and wakes. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0960148114000317>.
- BASTANKHAH, M.; PORTE-AGEL, F. Experimental and theoretical study of wind turbine wakes in yawed conditions. *Journal of Fluid Mechanics*, Cambridge University Press, v. 806, p. 506–541, 2016.
- BENTLEY, P. J.; WAKEFIELD, J. P. Finding acceptable solutions in the pareto-optimal range using multiobjective genetic algorithms. In: CHAUDHRY, P. K.; ROY, R.; PANT, R. K. (Ed.). *Soft Computing in Engineering Design and Manufacturing*. London: Springer London, 1998. p. 231–240. ISBN 978-1-4471-0427-8.
- BETZ, A. Das maximum der theoretisch moglichen auswendung des windes durch windmotoren. *Zeitschrift fur gesamte Turbinewesen*, v. 26, 1920.
- BETZ, A. *Windenergie und ihre ausnutzung durch wind-muhlen*. [S.l.]: Göttingen, Vandenhoeck u. Ruprecht, 1926. ISBN 978-3-922964-11-7.
- BEUME, N.; NAUJOKS, B.; EMMERICH, M. Sms-emoa: Multiobjective selection based on dominated hypervolume. *European Journal of Operational Research*, v. 181, n. 3, p. 1653–1669, 2007. ISSN 0377-2217. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0377221706005443>.
- Blank, J.; Deb, K. pymoo: Multi-objective optimization in python. *IEEE Access*, v. 8, p. 89497–89509, 2020.
- CALAF, M.; MENEVEAU, C.; MEYERS, J. Large eddy simulation study of fully developed wind-turbine array boundary layers. *Physics of Fluids*, v. 22, n. 1, p. 015110, 2010. Disponível em: <https://doi.org/10.1063/1.3291077>.
- CAO, L. et al. Wind farm layout optimization to minimize the wake induced turbulence effect on wind turbines. *Applied Energy*, v. 323, p. 119599, 2022. ISSN 0306-2619. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0306261922009060>.
- CAPPS, S. B.; ZENDER, C. S. Global ocean wind power sensitivity to surface layer stability. *Geophysical Research Letters*, v. 36, n. 9, 2009. Disponível em: <https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2008GL037063>.
- CHAMORRO, L.; PORTÉ-AGEL, F. A wind-tunnel investigation of wind-turbine wakes: Boundary-layer turbulence effects. *Boundary-Layer Meteorology*, v. 132, p. 129–149, 12 2008.

CHARHOUNI, N.; SALLAOU, M.; MANSOURI, K. Realistic wind farm design layout optimization with different wind turbines types. *International Journal of Energy and Environmental Engineering*, Springer, v. 10, p. 307–318, 2019.

CHARHOUNI, N.; SALLAOU, M.; MANSOURI, K. Realistic wind farm design layout optimization with different wind turbines types. *International Journal of Energy and Environmental Engineering*, v. 10, n. 3, p. 307–318, 4 2019.

CHEN, K. et al. Wind turbine layout optimization with multiple hub height wind turbines using greedy algorithm. *Renewable Energy*, v. 96, p. 676–686, 2016. ISSN 0960-1481. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0960148116304293>.

CHEN, Y. et al. Multi-objective genetic algorithm based innovative wind farm layout optimization method. *Energy Conversion and Management*, Elsevier, v. 105, p. 1318–1327, 2015.

CHEN, Y. et al. Wind farm layout optimization using genetic algorithm with different hub height wind turbines. *Energy Conversion and Management*, v. 70, p. 56–65, 2013. ISSN 0196-8904. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0196890413000873>.

CHEN, Z.; GUERRERO, J. M.; BLAABJERG, F. A review of the state of the art of power electronics for wind turbines. *IEEE Transactions on Power Electronics*, v. 24, n. 8, p. 1859–1875, 2009.

CHOWDHURY, S. et al. Unrestricted wind farm layout optimization (uwflo): Investigating key factors influencing the maximum power generation. *Renewable Energy*, v. 38, n. 1, p. 16–30, 2012. ISSN 0960-1481. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0960148111003260>.

CHOWDHURY, S. et al. Optimizing the arrangement and the selection of turbines for wind farms subject to varying wind conditions. *Renewable Energy*, v. 52, p. 273–282, 2013. ISSN 0960-1481. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0960148112006544>.

COELLO, C. A. C.; SIERRA, M. R. A study of the parallelization of a coevolutionary multi-objective evolutionary algorithm. In: MONROY, R. et al. (Ed.). *MICAI 2004: Advances in Artificial Intelligence*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004. p. 688–697. ISBN 978-3-540-24694-7.

COPERNICUS. *Climate Data Store (CDS) Toolbox - version 1.1.5 - Wind Rose Application*. 2016. Disponível em: [https://cds.climate.copernicus.eu/toolbox/doc/gallery/52\\_wind\\_rose.html](https://cds.climate.copernicus.eu/toolbox/doc/gallery/52_wind_rose.html).

CORMEN, T. H. et al. *Algorithms: theory and practice, 3rd*. [S.l.]: Elsevier, 2012. ISBN 978-0-262-03384-8.

CORTEN, G.; SCHAAK, P.; HEGBERG, T. Velocity profiles measured above a scaled wind farm. 2004.

COUNIHAN, J. Adiabatic atmospheric boundary layers: A review and analysis of data from the period 1880-1972. *Atmospheric Environment*, v. 9, n. 10, p. 871–905, jan. 1975.

- CRESPO, A.; HERNÁNDEZ, J. Turbulence characteristics in wind-turbine wakes. *Journal of Wind Engineering and Industrial Aerodynamics*, v. 61, n. 1, p. 71–85, 1996. ISSN 0167-6105. Disponível em: <https://www.sciencedirect.com/science/article/pii/S016761059500033X>.
- CRESPO, A.; HERNÁNDEZ, J.; FRANDBSEN, S. Survey of modelling methods for wind turbine wakes and wind farms. *Wind Energy*, v. 2, n. 1, p. 1–24, 1999. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/%28SICI%291099-1824%28199901/03%292%3A1%3C1%3A%3AAID-WE16%3E3.0.CO%3B2-7>.
- de Assis Tavares, L. F. et al. Assessment of the offshore wind technical potential for the brazilian southeast and south regions. *Energy*, v. 196, p. 117097, 2020. ISSN 0360-5442. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0360544220302048>.
- DEB, K. *Multiobjective Optimization Using Evolutionary Algorithms*. Wiley, New York. [S.l.: s.n.], 2001.
- DEB, K.; AGRAWAL, R. B. Simulated binary crossover for continuous search space. *Complex Systems*, v. 9, n. 2, p. 115–148, 1995.
- DEB, K.; DEB, D. Analysing mutation schemes for real-parameter genetic algorithms. *Int. J. Artif. Intell. Soft Comput.*, Inderscience Publishers, Geneva 15, CHE, v. 4, n. 1, p. 1–28, feb 2014. ISSN 1755-4950. Disponível em: <https://doi.org/10.1504/IJAISC.2014.059280>.
- DEB, K.; KUMAR, A. Real-coded genetic algorithms with simulated binary crossover: Studies on multimodal and multiobjective problems. *Complex Syst.*, v. 9, 1995.
- DEB, K. et al. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE Transactions on Evolutionary Computation*, v. 6, n. 2, p. 182–197, 2002.
- DEB, K.; SINDHYA, K.; OKABE, T. Self-adaptive simulated binary crossover for real-parameter optimization. In: *Proceedings of the 9th Annual Conference on Genetic and Evolutionary Computation*. New York, NY, USA: Association for Computing Machinery, 2007. (GECCO '07), p. 1187–1194. ISBN 9781595936974. Disponível em: <https://doi.org/10.1145/1276958.1277190>.
- DESMOND, C. et al. Description of an 8 mw reference wind turbine. *Journal of Physics: Conference Series*, IOP Publishing, v. 753, n. 9, p. 092013, sep 2016. Disponível em: <https://dx.doi.org/10.1088/1742-6596/753/9/092013>.
- DIJK, M. T. van et al. Wind farm multi-objective wake redirection for optimizing power production and loads. *Energy*, Elsevier, v. 121, p. 561–569, 2017.
- DOBRIC, G.; DURISIC, Z. Double-stage genetic algorithm for wind farm layout optimization on complex terrains. *Journal of Renewable and Sustainable Energy*, v. 6, n. 3, p. 033127, 2014. Disponível em: <https://doi.org/10.1063/1.4881684>.
- DOEKEMEIJER, B. M.; SIMLEY, E.; FLEMING, P. Comparison of the gaussian wind farm model with historical data of three offshore wind farms. *Energies*, v. 15, n. 6, 2022. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/15/6/1964>.

DOUBRAWA, P. et al. Multimodel validation of single wakes in neutral and stratified atmospheric conditions. *Wind Energy*, v. 23, n. 11, p. 2027–2055, 2020. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/we.2543>.

DOUG, B. *Minimum Spanning Trees*. 2013. Disponível em: <https://www.geneseo.edu/~baldwin/csci242/spring2013/0404mst.html>.

DUAN, B.; WANG, J.; GU, H. Modified genetic algorithm for layout optimization of multi-type wind turbines. In: IEEE. *2014 American control conference*. [S.l.], 2014. p. 3633–3638.

EIBEN, A.; SMITH, J. *Introduction to Evolutionary Computing*. [S.l.]: Springer, 2015. (Natural Computing Series). Gebeurtenis: 2nd edition. ISBN 9783662448731.

ELKINTON, M. R.; ROGERS, A. L.; MCGOWAN, J. G. An investigation of wind-shear models and experimental data trends for different terrains. *Wind Engineering*, v. 30, n. 4, p. 341–350, 2006. Disponível em: <https://doi.org/10.1260/030952406779295417>.

EMMERICH, M.; BEUME, N.; NAUJOKS, B. An emo algorithm using the hypervolume measure as selection criterion. In: COELLO, C. A. C.; AGUIRRE, A. H.; ZITZLER, E. (Ed.). *Evolutionary Multi-Criterion Optimization*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005. p. 62–76. ISBN 978-3-540-31880-4.

EPE. *Roadmap Eólica Offshore-Brasil. Perspectivas e caminhos para a energia eólica marítima*. [S.l.]: Empresa de Pesquisa Energética, Rio de Janeiro, BR, 140p, 2020.

EWEA. *Wind in our sails - the coming of Europe's offshore wind energy industry. Tech. rep. The European Wind Energy Association*. 2011.

FENG, J.; SHEN, W. Z. Modelling wind for wind farm layout optimization using joint distribution of wind speed and wind direction. *Energies*, v. 8, n. 4, p. 3075–3092, 2015. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/8/4/3075>.

FENG, J.; SHEN, W. Z. Solving the wind farm layout optimization problem using random search algorithm. *Renewable Energy*, v. 78, p. 182–192, 2015. ISSN 0960-1481. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0960148115000129>.

FENG, J.; SHEN, W. Z. Design optimization of offshore wind farms with multiple types of wind turbines. *Applied Energy*, v. 205, p. 1283–1297, 2017. ISSN 0306-2619. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0306261917311285>.

FINGERSH, L.; HAND, M.; LAXSON, A. Wind turbine design cost and scaling model. *report, December 1, 2006*, National Renewable Energy Lab.(NREL), Golden, CO (United States), 2006. Disponível em: <https://digital.library.unt.edu/ark:/67531/metadc886232/>.

FLEISCHER, M. The measure of pareto optima applications to multi-objective metaheuristics. In: FONSECA, C. M. et al. (Ed.). *Evolutionary Multi-Criterion Optimization*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003. p. 519–533. ISBN 978-3-540-36970-7.

FRANDSEN, S. et al. Analytical modelling of wind speed deficit in large offshore wind farms. *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology*, Wiley Online Library, v. 9, n. 1-2, p. 39–53, 2006.

FRANSEN, S.; THØGERSEN, M. Integrated fatigue loading for wind turbines in wind farms by combining ambient turbulence and wakes. *Wind Engineering*, SAGE Publications, v. 23, p. 327–339, 1999. ISSN 0309-524X.

GAUMOND, M. et al. Evaluation of the wind direction uncertainty and its impact on wake modeling at the horns rev offshore wind farm. *Wind Energy*, v. 17, n. 8, p. 1169–1178, 2014. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/we.1625>.

GOLDBERG, D. E. *Genetic Algorithms in Search, Optimization and Machine Learning*. 1st. ed. USA: Addison-Wesley Longman Publishing Co., Inc., 1989. ISBN 0201157675.

GONZALEZ-RODRIGUEZ, A. G. Review of offshore wind farm cost components. *Energy for Sustainable Development*, v. 37, p. 10–19, 2017. ISSN 0973-0826. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0973082616303647>.

GONZALEZ-RODRIGUEZ, A. G. et al. Realistic optimization of parallelogram-shaped offshore wind farms considering continuously distributed wind resources. *Energies*, v. 14, n. 10, 2021. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/14/10/2895>.

GRAF, P. et al. Wind farm turbine type and placement optimization. *Journal of Physics: Conference Series*, IOP Publishing, v. 753, n. 6, p. 062004, sep 2016. Disponível em: <https://dx.doi.org/10.1088/1742-6596/753/6/062004>.

GROTHER, O.; KÄCHELE, F.; WATERMEYER, M. Analyzing europe's biggest offshore wind farms: A data set with 40 years of hourly wind speeds and electricity production. *Energies*, v. 15, n. 5, 2022. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/15/5/1700>.

GUNN, K. et al. Limitations to the validity of single wake superposition in wind farm yield assessment. *Journal of Physics: Conference Series*, IOP Publishing, v. 749, n. 1, p. 012003, sep 2016. Disponível em: <https://dx.doi.org/10.1088/1742-6596/749/1/012003>.

GWEC. *Global offshore wind report. Tech. rep. Global Wind Energy Council*. 2021.

GWEC, G. W. E. C. *Global wind report 2019. Brussels: GWEC*, v. 637, 2017.

HAMILTON, N. et al. Comparison of modular analytical wake models to the lillgrund wind plant. *Journal of Renewable and Sustainable Energy*, v. 12, n. 5, p. 053311, 2020. Disponível em: <https://doi.org/10.1063/5.0018695>.

HAMILTON, N.; MELIUS, M.; CAL, R. B. Wind turbine boundary layer arrays for cartesian and staggered configurations-part i, flow field and power measurements. *Wind Energy*, Wiley Online Library, v. 18, n. 2, p. 277–295, 2015.

HANSEN, A. D. Chapter 8 - wind turbine technologies. In: LETCHER, T. M. (Ed.). *Wind Energy Engineering*. Academic Press, 2017. p. 145–160. ISBN 978-0-12-809451-8. Disponível em: <https://www.sciencedirect.com/science/article/pii/B9780128094518000084>.

HANSEN, M. O. Chapter 9 - aerodynamics and design of horizontal-axis wind turbines. In: LETCHER, T. M. (Ed.). *Wind Energy Engineering*. Academic Press, 2017. p. 161–184. ISBN 978-0-12-809451-8. Disponível em: <https://www.sciencedirect.com/science/article/pii/B9780128094518000096>.

- HANSEN, M. O. L. et al. State of the art in wind turbine aerodynamics and aeroelasticity. *Progress in aerospace sciences*, Elsevier, v. 42, n. 4, p. 285–330, 2006.
- HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. Ann Arbor, MI: University of Michigan Press, 1975. Second edition, 1992.
- HUANG, L. et al. 3-d layout optimization of wind turbines considering fatigue distribution. *IEEE Transactions on Sustainable Energy*, v. 11, n. 1, p. 126–135, 2020.
- IEA. *Technology Roadmap - Wind Energy 2013*. IEA Webstore. 2013. (<https://webstore.iea.org/technology-roadmap-wind-energy-2013>).
- IEA. *Global energy and CO2 status report 2017. Technical report*. International Energy Agency. 2018. (<https://www.iea.org/publications/freepublications/publication/GECO2017.pdf>).
- IEA. *International Energy Agency. Offshore wind outlook 2019*. 2019. (<http://119.78.100.173/C666/handle/2XK7JSWQ/270186>).
- ISHIBUCHI, H. et al. Modified distance calculation in generational distance and inverted generational distance. In: GASPAR-CUNHA, A.; ANTUNES, C. H.; COELLO, C. C. (Ed.). *Evolutionary Multi-Criterion Optimization*. Cham: Springer International Publishing, 2015. p. 110–125. ISBN 978-3-319-15892-1.
- JENSEN, L. E. et al. Wake measurements from the horns rev wind farm. In: . [S.l.: s.n.], 2011.
- JENSEN, N. A note on wind turbine interaction. *Riso-M-2411, Risoe National Laboratory, Roskilde, Denmark*, p. 16, 1983.
- JOHNSON, G. *Wind Energy Systems*. [S.l.]: Prentice Hall, Englewood Cliffs, NJ, 1985.
- JUSTUS, C. G. *Winds and wind system performance*. [S.l.]: Franklin Institute Press, Philadelphia, PA., 1978.
- KÄSLER, Y. et al. Wake measurements of a multi-mw wind turbine with coherent long-range pulsed doppler wind lidar. *Journal of Atmospheric and Oceanic Technology*, v. 27, n. 9, p. 1529–1532, 2010.
- KATIC, I.; HØJSTRUP, J.; JENSEN, N. A simple model for cluster efficiency. In: PALZ, W.; SESTO, E. (Ed.). *EWEC'86. Proceedings. Vol. 1*. [S.l.]: A. Raguzzi, 1987. p. 407–410. European Wind Energy Association Conference and Exhibition, EWEC '86 ; Conference date: 06-10-1986 Through 08-10-1986.
- KIRCHNER-BOSSI, N.; PORTÉ-AGEL, F. Realistic wind farm layout optimization through genetic algorithms using a gaussian wake model. *Energies*, v. 11, n. 12, 2018. ISSN 1996-1073. Disponível em: (<https://www.mdpi.com/1996-1073/11/12/3268>).
- KIRCHNER-BOSSI, N.; PORTÉ-AGEL, F. Wind farm area shape optimization using newly developed multi-objective evolutionary algorithms. *Energies*, v. 14, n. 14, 2021. ISSN 1996-1073. Disponível em: (<https://www.mdpi.com/1996-1073/14/14/4185>).
- KNOWLES, J.; CORNE, D.; FLEISCHER, M. Bounded archiving using the lebesgue measure. In: *The 2003 Congress on Evolutionary Computation, 2003. CEC '03*. [S.l.: s.n.], 2003. v. 4, p. 2490–2497 Vol.4.

- KRUSKAL, J. B. On the shortest spanning subtree of a graph and the traveling salesman problem. *Proceedings of the American Mathematical society*, JSTOR, v. 7, n. 1, p. 48–50, 1956.
- KUNAKOTE, T. et al. Comparative performance of twelve metaheuristics for wind farm layout optimisation. *Archives of Computational Methods in Engineering*, v. 29, p. 717–730, 2021.
- KUSIAK, A.; SONG, Z. Design of wind farm layout for maximum wind energy capture. *Renewable Energy*, v. 35, n. 3, p. 685–694, 2010. ISSN 0960-1481. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0960148109003796>.
- LI, H.; ZHANG, Q. Multiobjective optimization problems with complicated pareto sets, moea/d and nsga-ii. *IEEE Transactions on Evolutionary Computation*, v. 13, n. 2, p. 284–302, 2009.
- LI, W.; ÖZCAN, E.; JOHN, R. Multi-objective evolutionary algorithms and hyperheuristics for wind farm layout optimisation. *Renewable Energy*, Elsevier, v. 105, p. 473–482, 2017.
- LISSAMAN, P. B. S. Energy effectiveness of arbitrary arrays of wind turbines. *Journal of Energy*, v. 3, n. 6, p. 323–328, 1979. Disponível em: <https://doi.org/10.2514/3.62441>.
- LIU, Z. et al. Genetic-algorithm-based layout optimization of an offshore wind farm under real seabed terrain encountering an engineering cost model. *Energy Conversion and Management*, v. 245, p. 114610, 2021. ISSN 0196-8904. Disponível em: <https://www.sciencedirect.com/science/article/pii/S019689042100786X>.
- LOZER DOS REIS, M. M.; MITSUO MAZETTO, B.; COSTA MALATEAUX DA SILVA, E. Economic analysis for implantation of an offshore wind farm in the brazilian coast. *Sustainable Energy Technologies and Assessments*, v. 43, p. 100955, 2021. ISSN 2213-1388. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2213138820313837>.
- LUKO, S. A review of the weibull distribution and selected engineering applications. 09 1999.
- LUO, L. et al. Minimizing the energy cost of offshore wind farms by simultaneously optimizing wind turbines and their layout. *Applied Sciences*, v. 9, n. 5, 2019. ISSN 2076-3417. Disponível em: <https://www.mdpi.com/2076-3417/9/5/835>.
- LYSEN, E. H. *Introduction to Wind Energy*. [S.l.]: SWD Publication SWD 82-1, Amersfoort, NL, 1983.
- MA, Y. et al. Bi-objective layout optimization for multiple wind farms considering sequential fluctuation of wind power using uniform design. *CSEE Journal of Power and Energy Systems*, v. 8, n. 6, p. 1623–1635, 2022.
- MANDELL, J. et al. New fatigue data for wind turbine blade materials. In: \_\_\_\_\_. *41st Aerospace Sciences Meeting and Exhibit*. [s.n.]. Disponível em: <https://arc.aiaa.org/doi/abs/10.2514/6.2003-692>.
- MANWELL, J.; MCGOWAN, J.; ROGERS, A. *Wind Energy Explained: Theory, Design and Application*. Wiley, 2010. ISBN 9780470686287. Disponível em: [https://books.google.com.br/books?id=roaTx\\\_Of0vAC](https://books.google.com.br/books?id=roaTx\_Of0vAC).

MARKFORT, C. D.; ZHANG, W.; PORTÉ-AGEL, F. Turbulent flow and scalar transport through and over aligned and staggered wind farms. *Journal of Turbulence*, Taylor & Francis, v. 13, n. 1, p. N33, 2012.

MEHTA, D. et al. Large eddy simulation of wind farm aerodynamics: A review. *Journal of Wind Engineering and Industrial Aerodynamics*, Elsevier, v. 133, p. 1–17, 2014.

MITTAL, P.; MITRA, K.; KULKARNI, K. Optimizing the number and locations of turbines in a wind farm addressing energy-noise trade-off: A hybrid approach. *Energy conversion and management*, Elsevier, v. 132, p. 147–160, 2017.

MONTOYA, F. G. et al. Wind turbine selection for wind farm layout using multi-objective evolutionary algorithms. *Expert Systems with Applications*, v. 41, n. 15, p. 6585–6595, 2014. ISSN 0957-4174. Disponível em: <https://www.sciencedirect.com/science/article/pii/S095741741400267X>.

MORENO, S. P. *A guideline for selecting MDAO workflows with an application in offshore wind energy*. Tese (Doutorado) — Delft University of Technology, 2019. Disponível em: <https://doi.org/10.4233/uuid:ea1b4101-0e55-4abe-9539-ae5d81cf9f65>.

MORENO, S. R. et al. Multi-objective lightning search algorithm applied to wind farm layout optimization. *Energy*, v. 216, p. 119214, 2021. ISSN 0360-5442. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0360544220323215>.

MOSETTI, G.; POLONI, C.; DIVIACCO, B. Optimization of wind turbine positioning in large windfarms by means of a genetic algorithm. *Journal of Wind Engineering and Industrial Aerodynamics*, v. 51, n. 1, p. 105–116, 1994. ISSN 0167-6105. Disponível em: <https://www.sciencedirect.com/science/article/pii/0167610594900809>.

NADERI, S.; PARVANEHMASIHA, S.; TORABI, F. Modeling of horizontal axis wind turbine wakes in horns rev offshore wind farm using an improved actuator disc model coupled with computational fluid dynamic. *Energy Conversion and Management*, v. 171, p. 953–968, 2018. ISSN 0196-8904. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0196890418306538>.

NIAYIFAR, A.; PORTÉ-AGEL, F. Analytical modeling of wind farms: A new approach for power prediction. *Energies*, v. 9, n. 9, 2016. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/9/9/741>.

NREL. *FLORIS. Version 3.2*. GitHub, 2022. Disponível em: <https://github.com/NREL/floris>.

NREL. *NREL Turbine Archive - Offshore Wind Turbine Documentation*. acessado 27 Jun 2022. <https://nrel.github.io/turbine-models/Offshore.html>.

OKABE, T.; JIN, Y.; SENDHOFF, B. A critical survey of performance indices for multi-objective optimisation. In: *The 2003 Congress on Evolutionary Computation, 2003. CEC '03*. [S.l.: s.n.], 2003. v. 2, p. 878–885 Vol.2.

PARADA, L. et al. Wind farm layout optimization using a gaussian-based wake model. *Renewable Energy*, v. 107, p. 531–541, 2017. ISSN 0960-1481. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0960148117300952>.

PARETO, V. *cours d'economie politique : volume i and ii*. F.Rouge - Lausanne, 1896.

- PAUL, S.; RATHER, Z. H. A new bi-level planning approach to find economic and reliable layout for large-scale wind farm. *IEEE Systems Journal*, v. 13, n. 3, p. 3080–3090, 2019.
- PIMENTA, F. M. et al. Brazil offshore wind resources and atmospheric surface layer stability. *Energies*, v. 12, n. 21, 2019. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/12/21/4195>.
- POOKPUNT, S.; ONGSAKUL, W. Design of optimal wind farm configuration using a binary particle swarm optimization at huasai district, southern thailand. *Energy Conversion and Management*, v. 108, p. 160–180, 2016. ISSN 0196-8904. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0196890415010079>.
- PORTÉ-AGEL, F.; BASTANKHAH, M.; SHAMSODDIN, S. Wind-turbine and wind-farm flows: A review. *Boundary-Layer Meteorology*, v. 174, p. 1 – 59, 2019.
- PORTE-AGEL, F.; WU, Y.-T.; CHEN, C.-H. A numerical study of the effects of wind direction on turbine wakes and power losses in a large wind farm. *Energies*, v. 6, n. 10, p. 5297–5313, 2013. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/6/10/5297>.
- QIAN, G.-W.; ISHIHARA, T. A new analytical wake model for yawed wind turbines. *Energies*, v. 11, n. 3, 2018. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/11/3/665>.
- QUARTON, D.; AINSLIE, J. Turbulence in wind turbine wakes. *Wind Engineering*, Sage Publications, Ltd., v. 14, n. 1, p. 15–23, 1990. ISSN 0309524X, 2048402X. Disponível em: <http://www.jstor.org/stable/43749409>.
- QUARTON, D.; AINSLIE, J. Turbulence in wind turbine wakes. *Wind Engineering*, Sage Publications, Ltd., v. 14, n. 1, p. 15–23, 1990. ISSN 0309524X, 2048402X. Disponível em: <http://www.jstor.org/stable/43749409>.
- RADOS, K. et al. Comparison of wake models with data for offshore windfarms. *Wind Engineering*, v. 25, n. 5, p. 271–280, 2001. Disponível em: <https://doi.org/10.1260/030952401760177846>.
- RAHBARI, O. et al. Towards realistic designs of wind farm layouts: Application of a novel placement selector approach. *Energy Conversion and Management*, v. 81, p. 242–254, 2014. ISSN 0196-8904. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0196890414001198>.
- RAO, S. S. *Engineering optimization: theory and practice, third edition*. [S.l.]: John Wiley & Sons, Inc, 1996. ISBN 0471550345.
- RÉTHORÉ, P.-E. et al. Study of the atmospheric wake turbulence of a cfd actuator disc model. In: . [S.l.: s.n.], 2009.
- RIQUELME, N.; LÜCKEN, C. V.; BARAN, B. Performance metrics in multi-objective optimization. In: *2015 Latin American Computing Conference (CLEI)*. [S.l.: s.n.], 2015. p. 1–11.
- RIVAS, R. A. et al. Solving the turbine positioning problem for large offshore wind farms by simulated annealing. *Wind Engineering*, v. 33, n. 3, p. 287–297, 2009. Disponível em: <https://doi.org/10.1260/0309-524X.33.3.287>.

RODRIGUES, S.; BAUER, P.; BOSMAN, P. A. Multi-objective optimization of wind farm layouts – complexity, constraint handling and scalability. *Renewable and Sustainable Energy Reviews*, v. 65, p. 587–609, 2016. ISSN 1364-0321. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364032116303458>.

RODRIGUES, S. et al. A multi-objective optimization framework for offshore wind farm layouts and electric infrastructures. *Energies*, v. 9, n. 3, 2016. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/9/3/216>.

ROSENAUER, E. *Investment costs of offshore wind turbines. CSS Report, University of Michigan: Ann Arbor 1-27*. 2014. Disponível em: <https://css.umich.edu/publications/research-publications/investment-costs-offshore-wind-turbines>.

SANDERSE, B.; PIJL, S. van der; KOREN, B. Review of computational fluid dynamics for wind turbine wake aerodynamics. *Wind Energy*, v. 14, n. 7, p. 799–819, 2011. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/we.458>.

SHAKOOR, R. et al. Wake effect modeling: A review of wind farm layout optimization using Jensen's model. *Renewable and Sustainable Energy Reviews*, v. 58, p. 1048–1059, 2016. ISSN 1364-0321. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364032115016123>.

SNEL, H. Review of the present status of rotor aerodynamics. *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology*, Wiley Online Library, v. 1, n. S1, p. 46–69, 1998.

SNEL, H. Review of aerodynamics for wind turbines. *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology*, Wiley Online Library, v. 6, n. 3, p. 203–211, 2003.

SONG, M.; CHEN, K.; WANG, J. Three-dimensional wind turbine positioning using gaussian particle swarm optimization with differential evolution. *Journal of Wind Engineering and Industrial Aerodynamics*, v. 172, p. 317–324, 2018. ISSN 0167-6105. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0167610517304038>.

SORKHABI, S. Y. D. et al. The impact of land use constraints in multi-objective energy-noise wind farm layout optimization. *Renewable Energy*, Elsevier, v. 85, p. 359–370, 2016.

SPERA, D. A. *Wind Turbine Technology: Fundamental Concepts in Wind Turbine Engineering, Second Edition*. ASME Press, 2009. ISBN 9780791802601. Disponível em: <https://doi.org/10.1115/1.802601>.

SRINIVAS, N.; DEB, K. Multiobjective optimization using nondominated sorting in genetic algorithms. *Evolutionary Computation*, v. 2, n. 3, p. 221–248, 1994.

STANLEY, A. P. J. et al. Objective and algorithm considerations when optimizing the number and placement of turbines in a wind power plant. *Wind Energy Science*, v. 6, n. 5, p. 1143–1167, 2021. Disponível em: <https://wes.copernicus.org/articles/6/1143/2021/>.

STEVENS, R. J.; MENEVEAU, C. Flow structure and turbulence in wind farms. *Annual Review of Fluid Mechanics*, v. 49, n. 1, p. 311–339, 2017. Disponível em: <https://doi.org/10.1146/annurev-fluid-010816-060206>.

- SUDRET, B.; MARELLI, S.; WIART, J. Surrogate models for uncertainty quantification: An overview. In: IEEE. *2017 11th European conference on antennas and propagation (EUCAP)*. [S.l.], 2017. p. 793–797.
- SUN, H.; YANG, H.; GAO, X. Investigation into spacing restriction and layout optimization of wind farm with multiple types of wind turbines. *Energy*, v. 168, p. 637–650, 2019. ISSN 0360-5442. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0360544218322849>.
- TAKAHASHI, R. H. C. Otimização escalar e vetorial - volume 1: Conceitos preliminares. v. 1, 2007. Disponível em: <http://150.164.25.15/~taka/Download/OTEV-Vol1.pdf>.
- TAKAHASHI, R. H. C. Otimização escalar e vetorial - volume 3: Otimização vetorial. v. 3, 2009. Disponível em: <http://150.164.25.15/~taka/Download/OTEV-Vol3.pdf>.
- TANG, X. et al. Mixed installation to optimize the position and type selection of turbines for wind farms. In: LIU, D. et al. (Ed.). *Neural Information Processing*. Cham: Springer International Publishing, 2017. p. 307–315. ISBN 978-3-319-70136-3.
- TANG, X. et al. Optimisation of wind farm layout in complex terrain via mixed-installation of different types of turbines. *IET Renewable Power Generation*, v. 12, n. 9, p. 1065–1073, 2018. Disponível em: <https://ietresearch.onlinelibrary.wiley.com/doi/abs/10.1049/iet-rpg.2017.0787>.
- TAO, S. et al. Optimal micro-siting of wind turbines in an offshore wind farm using frandsen–gaussian wake model. *IEEE Transactions on Power Systems*, v. 34, n. 6, p. 4944–4954, 2019.
- TAO, S. et al. Nonuniform wind farm layout optimization: A state-of-the-art review. *Energy*, v. 209, p. 118339, 2020. ISSN 0360-5442. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0360544220314468>.
- TEMPEL, J. van der. Design of support structures for offshore wind turbines. *Duwind*, 2006. Disponível em: <http://resolver.tudelft.nl/uuid:ae69666e-3190-4b22-84ed-2ed44c23e670>.
- THEWINDPOWER.NET. *The wind power - Wind energy market intelligence*. acessado 27 Jun 2022. <https://www.thewindpower.net/index.php>.
- TINGEY, E. B.; NING, A. Trading off sound pressure level and average power production for wind farm layout optimization. *Renewable Energy*, Elsevier, v. 114, p. 547–555, 2017.
- TROLDBORG, N.; SØRENSEN, J.; MIKKELSEN, R. Actuator line simulation of wake of wind turbine operating in turbulent inflow. *Journal of Physics: Conference Series*, v. 75, p. 012063, 08 2007.
- UNITED NATIONS. *Sustainable Development Goals*. acessado 12 Fev 2023. <https://www.undp.org/sustainable-development-goals>.
- Van Veldhuizen, D. A. *Multiobjective Evolutionary Algorithms: Classification, Analysis, and New Innovations*. Tese (Doutorado) — Graduate School of Engineering, Air Force Institute of Technology, Wright-Patterson Air Force Base, Ohio, USA, jun. 1999.

VARGAS, D. Um algoritmo de evolução diferencial com penalização adaptativa para otimização estrutural multiobjetivo. *Doutorado em Modelagem Computacional (Teses)*, UFJF, Universidade Federal de Juiz de Fora, 2015.

VASEL-BE-HAGH, A.; ARCHER, C. L. Wind farm hub height optimization. *Applied Energy*, v. 195, p. 905–921, 2017. ISSN 0306-2619. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0306261917303306>.

Vattenfall group. *Thanet offshore wind farm*. 2021. Disponível em: <https://kis-orca.org/wp-content/uploads/2020/12/Chart-24-Thanet-2021.pdf>.

VERMEER, L.; SORENSEN, J.; CRESPO, A. Wind turbine wake aerodynamics. *Progress in Aerospace Sciences*, v. 39, n. 6, p. 467–510, 2003. ISSN 0376-0421. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0376042103000782>.

VINHOZA, A.; SCHAEFFER, R. Brazil's offshore wind energy potential assessment based on a spatial multi-criteria decision analysis. *Renewable and Sustainable Energy Reviews*, v. 146, p. 111185, 2021. ISSN 1364-0321. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364032121004731>.

VOUTSINAS, S.; RADOS, K.; ZERVOS, A. On the analysis of wake effects in wind parks. *Wind Engineering*, Sage Publications, Ltd., v. 14, n. 4, p. 204–219, 1990. ISSN 0309524X, 2048402X. Disponível em: <http://www.jstor.org/stable/43749429>.

WANG, H.; HE, S.; YAO, X. Nadir point estimation for many-objective optimization problems based on emphasized critical regions. *Soft Computing*, 05 2017.

WANG, H. et al. Joint distribution of wind speed and direction in the context of field measurement. *Wind and Structures*, v. 20, p. 701–718, 05 2015.

WANG, X. et al. A review on recent advancements of substructures for offshore wind turbines. *Energy Conversion and Management*, v. 158, p. 103–119, 2018. ISSN 0196-8904. Disponível em: <https://www.sciencedirect.com/science/article/pii/S019689041731213X>.

WANG, Y. et al. Differential evolution with a new encoding mechanism for optimizing wind farm layout. *IEEE Transactions on Industrial Informatics*, v. 14, n. 3, p. 1040–1054, 2018.

WU, Y.-T.; PORTE-AGEL, F. Atmospheric turbulence effects on wind-turbine wakes: An LES study. *Energies*, v. 5, n. 12, p. 5340–5362, 2012. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/5/12/5340>.

XIE, S.; ARCHER, C. Self-similarity and turbulence characteristics of wind turbine wakes via large-eddy simulation. *Wind Energy*, v. 18, n. 10, p. 1815–1838, 2015. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/we.1792>.

YILMAZLAR, K. et al. Development of engineering cost models for integrated design optimization of onshore and offshore wind farms. *Journal of Physics: Conference Series*, IOP Publishing, v. 2265, n. 4, p. 042042, may 2022. Disponível em: <https://dx.doi.org/10.1088/1742-6596/2265/4/042042>.

YU, K. et al. Dynamic selection preference-assisted constrained multiobjective differential evolution. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, v. 52, n. 5, p. 2954–2965, 2022.

ZITZLER, E.; DEB, K.; THIELE, L. Comparison of multiobjective evolutionary algorithms: Empirical results. *Evol. Comput.*, MIT Press, Cambridge, MA, USA, v. 8, n. 2, p. 173–195, jun 2000. ISSN 1063-6560. Disponível em: [⟨https://doi.org/10.1162/106365600568202⟩](https://doi.org/10.1162/106365600568202).

ZITZLER, E.; THIELE, L. Multiobjective optimization using evolutionary algorithms — a comparative case study. In: EIBEN, A. E. et al. (Ed.). *Parallel Problem Solving from Nature — PPSN V*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1998. p. 292–301. ISBN 978-3-540-49672-4.

ZITZLER, E.; THIELE, L. Multiobjective evolutionary algorithms: a comparative case study and the strength pareto approach. *IEEE Transactions on Evolutionary Computation*, v. 3, n. 4, p. 257–271, 1999.

ZITZLER, E. et al. Performance assessment of multiobjective optimizers: an analysis and review. *IEEE Transactions on Evolutionary Computation*, v. 7, n. 2, p. 117–132, 2003.

ZIYAEI, P. et al. Minimizing the levelized cost of energy in an offshore wind farm with non-homogeneous turbines through layout optimization. *Ocean Engineering*, v. 249, p. 110859, 2022. ISSN 0029-8018. Disponível em: [⟨https://www.sciencedirect.com/science/article/pii/S002980182200302X⟩](https://www.sciencedirect.com/science/article/pii/S002980182200302X).