

機械学習によるシミュレーション結果推定を用いた風力発電所向け風車配置最適化技術

Optimization of Wind Turbine Layout in Wind Farms via Machine Learning to Estimate Simulation Results

桐淵 大貴 KIRIBUCHI Daiki 松田 匠 MATSUDA Takumi

風力発電所の発電効率向上のため、複数の風車を、互いの距離などの制約を満たした上で、年間エネルギー生産量(AEP)の合計値が大きくなるように配置する必要がある。山間部のような複雑な地形では、AEPなどを求めるために時間の掛かる風況解析シミュレーションを行う必要があるため、人手で配置を変えながら試行錯誤する手法では、限られた時間で適切な配置を見つけることが難しい。

東芝グループは、機械学習によりシミュレーション結果を推定し、その推定結果を用いて最適な風車の配置を求める風車配置最適化技術を開発した。人手では3時間掛けても制約を満たす配置が得られなかった事例にこの技術を用いたところ、制約を満たした上で、合計AEPが人手での最大値より約33%大きい配置を自動設計できた。

To enhance wind farm power generation efficiency, the layout of each wind farm turbine must be adjusted to increase the total annual energy production (AEP) while taking into consideration the constraints on distances among multiple wind turbines. Installations in mountainous areas with complex terrain necessitate time-consuming wind condition analyses in order to calculate design parameters such as total AEP, making it difficult to find an appropriate layout via manual adjustments through trial and error in a limited period of time.

To rectify this situation, the Toshiba Group has developed a new design method using machine learning to optimize wind farm turbine layout by estimating wind condition analysis results. We have conducted simulation experiments using actual data and confirmed that this method can automatically find a layout with a maximum total AEP that is about 33% higher than that of the conventional manual method whereas the conventional method could not satisfy the constraints even in three hours.

1. まえがき

資源エネルギー庁では、2030年の我が国の風力発電の導入量が、2019年の4.5倍に増加すると予測しており、発電効率の向上が求められている。風力発電の風車1基ごとのAEPは、風車の位置(座標)によって変わる。また、風力発電所には複数の風車があり、風向きによっては、下流にある風車のAEPが、上流にある風車を通過した風の流れ(後流)の影響を受けることがある(風車間相互作用)。そのため、複数の風車をどこに配置するかが風力発電所全体の合計AEPを左右する。一方で、風車を安全な場所に現実的なコストで建設するために、必要な制約を満たした配置にする必要がある。

従来、AEPが大きい風車配置を求めるために、人手で風車位置を変えながら風況解析シミュレーションを繰り返していたが、時間が掛かる上に制約を満足する配置が得られないことがあった。これを解決するために、風車配置設計の自動化が求められている⁽¹⁾。

このような中、東芝グループは、機械学習でシミュレーション結果を推定して、最適配置を求める風車配置最適化

技術を開発した。ここでは、陸上の風力発電所における風車配置最適化⁽²⁾と、風車配置とケーブル接続の同時最適化技術⁽³⁾について述べる。

2. 風車配置の設計問題と従来手法

1章で述べたとおり、風車間相互作用でAEPが変わるため、後流を考慮しない各風車のAEPの単純な和として合計AEPを求めることはできない。また、風車配置の制約は次の三つである。まず、隣り合う風車が互いに干渉しないように、各風車間の距離を下限値より大きくする必要がある。次に、風車の耐風性能の制約として、各風車座標の極値風速(平均的に50年に一度発生する大きい風速)が、風車の設計上限値よりも小さいことが必要である。更に、各風車座標は現実的に建設可能な範囲に含まれる必要がある。これらの制約を全て満たした上で、合計AEPが大きい風車配置を求める。ここで、合計AEPや、各座標での極値風速は、風況解析シミュレーションで計算する必要がある。

従来は、勘と経験に基づいて、合計AEPが大きくなりそうな座標に人手で調整しながら、シミュレーションを繰り返し実行していた(図1)。このため、時間が掛かり、その結



図1. 人手での風車配置設計手法

各風車の位置をどの方向にどの程度動かせばAEPが大きくなるかは分からない。

Conventional method of manually wind turbine layout design

果、制約を満たす配置が得られないこともあった。

3. 風車配置最適化技術

3.1 技術の特長と最適化の流れ

風車配置最適化技術は、時間の掛かるシミュレーションを繰り返すのではなく、機械学習で構築した推定モデルで、後流を考慮しないAEPと極値風速を得ることが特長である。図2に示すとおり、ステップ1～3に従って風車配置を最適化する。

ステップ1では、建設可能範囲内から風車座標を複数サンプリングする。サンプリングした風車座標ごとに、AEPと極値風速を風況解析シミュレーションで算出する。

ステップ2では、ステップ1で風車座標ごとに算出したデータを用いて、各風車座標でのAEPを推定するAEP推定モデルと極値風速を推定する極値風速推定モデルを構築する。地形によってAEPや極値風速が複雑に変わるので、モデル構築には、複雑さに合わせた非線形回帰を行う機械学習手法であるガウス過程回帰を用いる。これらの推定モデルにより、風況解析シミュレーションを実施していない座標についてもAEPや極値風速が得られる。

ステップ3では、制約を満たし、かつ合計AEPが大きくなる風車配置を、最適化手法を活用して次のように2段階に分けて求める。まず、後流を考慮しない場合の最適な風車配置を求める。この場合は整数線形計画問題として定式化できるため、ソフトウェア(汎用の数理計画ソルバー)を使って最適な風車配置が求められる。次に、後流を考慮しない最適風車配置を初期解として逐次探索を行い、後流を考慮した合計AEPが最大となる風車配置を求める。二つの風車座標間の後流を考慮したAEPは、簡易的な物理モデルであるJensenモデルを用いて算出する。逐次探索では、風車配置の中から1基ずつ選択し、ほかの風車座標は変えずに、選択した風車座標だけを、後流を考慮した合計AEPが大きくなるように変更するという探索を、逐次的に繰り返す。これをどの風車座標を変更しても合計AEPが大きくなる風車配置になるまで繰り返す。逐次探索により、

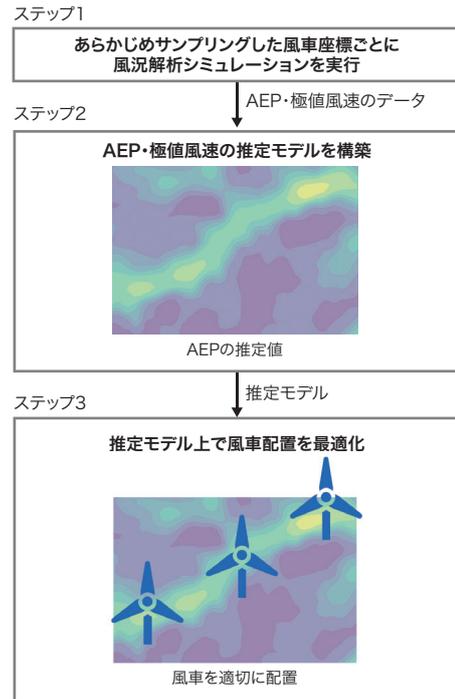


図2. 風車配置最適化技術のフローチャート

少ない座標点数のシミュレーション結果から、機械学習によりAEP推定モデルと極値風速推定モデルを構築し、風車配置を最適化する。

Process of optimizing wind turbine layout using machine learning

制約を満たし、後流を考慮した合計AEPの大きい風車配置が効率的に求められる。

3.2 風車配置最適化技術の評価

この技術の有効性を確認するため、東芝エネルギーシステムズ(株)が関わった風力発電所の事例を用いて、数値実験を行った。実験条件として、6基の風車の配置の設計を想定した。3,000個の風車座標を一様にサンプリングし、AEPと極値風速をそれぞれ風況解析シミュレーションで求めた。

次に、このデータを用いてAEP推定モデルと極値風速推定モデルを作成した。推定モデルから得られたAEPと極値風速を図3に示す。図3(b)の黒線は、極値風速の推定値が設計上限値と等しい座標を表す。黒線で囲われた尾根部分は、極値風速の推定値が設計上限値を超えるため、風車を配置できない。

更に、後流を考慮した風車配置最適化を行った結果が図4(a)である。この風車配置では、風車間距離や極値風速などの制約を全て満たす。主要な風向きと同方向に複数の風車が並ぶと、後流による損失量が大きくなる。後流を考慮した結果、風がよく吹く方向から見て風車が重ならない尾根に風車が配置された。

同じ条件の風車配置検討を、人手で行った結果を図4

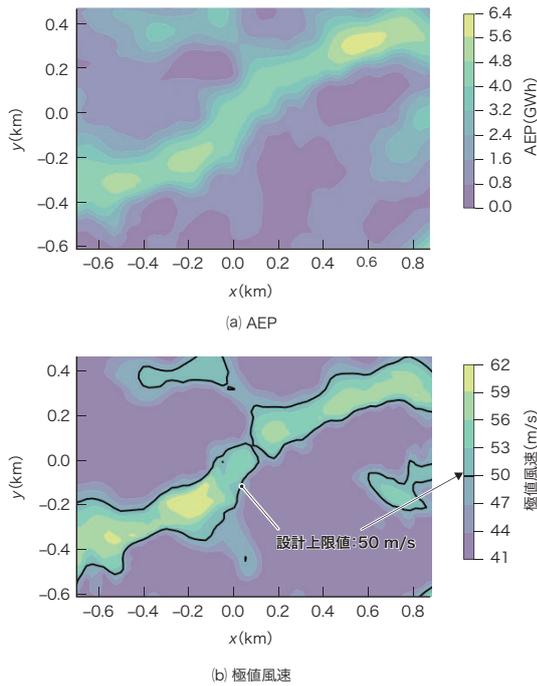


図3. 推定モデルによるAEPと極値風速の推定結果

極値風速が設計上限値より小さく、AEPが大きい座標に、風車を配置する必要がある。

Estimation results of AEP and extreme wind speed obtained using machine learning models

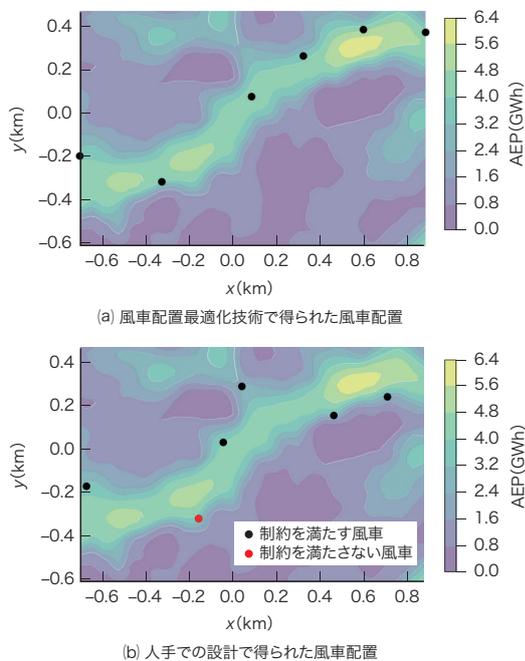


図4. 風車配置最適化技術と人手での設計で得られた風車配置の比較

人手では制約を満たさない風車があったが、風車配置最適化技術では全てが制約を満たし、合計AEPも約33%大きい配置が得られた。

Comparison of wind farm layouts obtained using conventional and new design methods

(b)に示す。風車配置最適化技術も人手も約3時間を掛けたが、人手では6基のうち1基が極値風速の制約を満たさない風車配置しか発見できなかった。また、人手での合計AEPは18.3 GWhであり、風車配置最適化技術の24.3 GWhは、人手よりも約33%大きかった。このように、人手による方法と比較して、風車配置最適化技術の有用性を確認できた。

4. 風車配置とケーブル接続の同時最適化技術

3章では合計AEPの大きい風車配置を求めたが、実際にはケーブル接続コストも考慮した風車配置を求めたいことがある。山間部のような複雑な地形ではAEPの大きい座標は点在しており、後流による損失量も風車間距離が大きいほど小さくなるため、合計AEPが大きい配置ではケーブル接続コストが大きいことが多い。そこで、合計AEPを大きくして、ケーブル接続コストを抑制するというトレードオフのある風車配置を求める。

ケーブル接続コストは総ケーブル長に比例すると仮定し、風車配置だけでなくケーブル接続も同時に設計して総ケーブル長を求める。全ての風車をケーブル接続により連系変電所につなぐ必要がある。ケーブルは許容値以上の電流を流せないため、例えば8基以下でグループ化して連系変電所につなぐ。ケーブルは、グループ内の風車をつなぐ風車間ケーブルと、それを連系変電所につなぐ風車・連系変電所間ケーブルがあり、総ケーブル長は全てのグループの風車間ケーブルと風車・連系変電所間ケーブルの長さの和である。

同時最適化では、3章のステップ3において、逐次探索の後に、合計AEP最大化と総ケーブル長最小化の二目的最適化を行う。具体的には、逐次探索で得られた風車配置を初期解として、遺伝的アルゴリズムNSGA-IIと、容量制約付き最小全域木問題の近似アルゴリズムEsau-Williams法により、風車配置とケーブル接続を同時に最適化する。NSGA-IIは各反復で複数の風車配置を出力する。これらの各風車配置について、推定モデルとJensenモデルを用いて合計AEPと制約を満たすか否かを算出する。また、Esau-Williams法を用いて各風車配置でのグループ分けと風車のつなぎ方を決定して、総ケーブル長を算出する。各風車配置で算出された合計AEP、総ケーブル長、及び制約を満たすか否かの情報をNSGA-IIに入力し、NSGA-IIは再び複数の風車配置を出力する。これを反復的に繰り返すことで、合計AEPと総ケーブル長のトレードオフのある複数の風車配置を自動的に設計できる。

3章とは異なる30基の風車配置の事例で、数値実験を

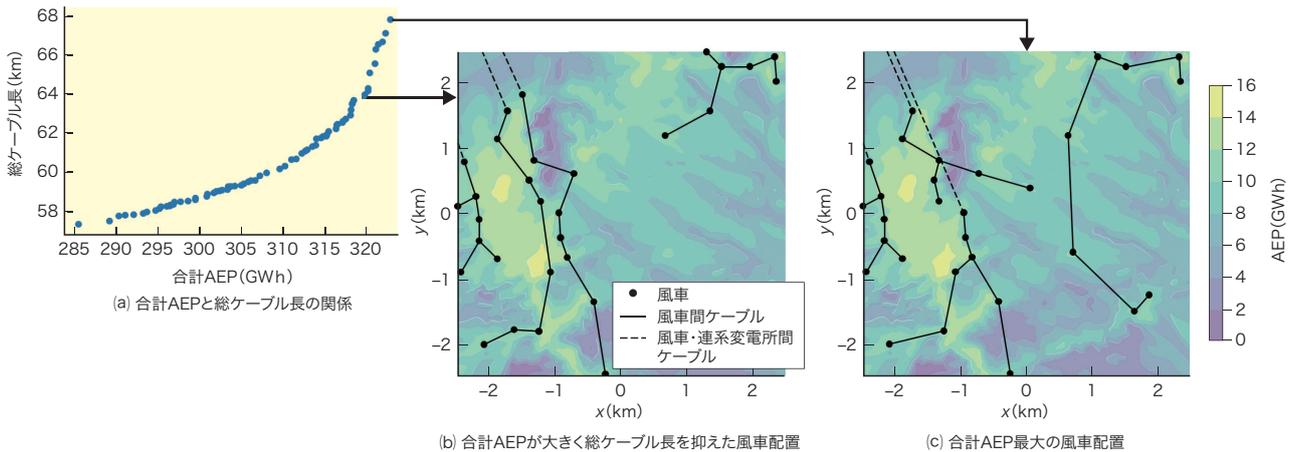


図5. 風車配置とケーブル接続の同時最適化技術で得られた風車配置の例

合計AEPと総ケーブル長のトレードオフのある風車配置を自動設計することで、より現実的な風車配置が得られる。

Relationship between total AEP and total cable length and examples of differences in wind turbine layout and cable wiring pattern simultaneously optimized by using new design method

行った。同時最適化技術で求めた複数の風車配置について、合計AEPと総ケーブル長の関係を図5(a)に示す。図5(b)は合計AEPと総ケーブル長のバランスが取れた配置であり、図5(c)は合計AEPが最大の配置である。図5(b)の配置は図5(c)の配置と比べて合計AEPが約0.8%小さいが総ケーブル長も約5.4%小さい。図5(c)の配置では風車が右下の位置に離れて配置されているためケーブル接続コストが大きく、現実的に建設するのが難しい。一方で、図5(b)の配置は風車がまとまって配置されているためケーブル接続コストが小さく、実際に建設可能な配置となっている。このように、風車配置とケーブル接続を同時最適化することで、より現実的な配置が得られる。

5. あとがき

風車配置最適化技術は、機械学習でシミュレーション結果を推定することで、制約を満たした上で、合計AEPが大きい風車配置を自動設計できる。また、風車配置とケーブル接続の同時最適化技術を提案し、合計AEP最大化と総ケーブル長最小化のトレードオフのある風車配置を設計できることを確認した。

今後は、陸上だけでなく洋上の風車配置最適化技術や、より実用的な風車建設可能範囲を考慮した最適化技術を開発し、風力発電所の発電効率向上、及び建設コスト抑制に貢献していく。

文献

- (1) Herbert-Acero, J. F. et al. A review of methodological approaches for the design and optimization of wind farms. *Energies*. 2014, **7**, 11, p.6930-7016.
- (2) 桐淵大貴, ほか. シミュレーション最適化技術を用いた風車配置最適化. *電気学会論文誌C (電子・情報・システム部門誌)*. 2023, **143**, 2, p.151-158.
- (3) Kiribuchi, D. et al. "Combined Layout Optimization of Wind Farm and Cable Connection on Complex Terrain Using a Genetic Algorithm". *Genetic and Evolutionary Computation Conference (GECCO '23)*. Lisbon, 2023-07. Special Interest Group on Genetic and Evolutionary Computation (SIGEVO), Association for Computing Machinery (ACM), 2023, p.1365-1373.



桐淵 大貴 KIRIBUCHI Daiki
 研究開発センター
 知能化システム研究所 システムAIラボラトリー
 電気学会会員
 System AI Lab.



松田 匠 MATSUDA Takumi
 東芝エネルギーシステムズ(株)
 エネルギーアグリゲーション事業部 風力発電技術部
 Toshiba Energy Systems & Solutions Corp.