

複数拠点向け太陽光発電量・余剰量予測サービス開発における データ活用手法と実用性評価

Data Utilization Methods and Practicality Evaluation in the Development of a Multi-Site Solar Power Generation and Surplus Forecasting Service

藤 本 容 子

要 約 カーボンニュートラルの実現に向けて再生可能エネルギーの導入拡大が加速する中、太陽光発電を持続的に社会へ定着させるためには、発電事業者を含む関係者にとって経済合理性のある運用を実現することが不可欠である。そのためには、発電販売計画の基礎となる発電量・余剰電力量を高精度に予測し、インバランス料金の抑制につなげることが重要となる。BIPROGY は、2023 年 4 月から提供している太陽光発電量・余剰量予測サービスにおいて、近年拡大しつつある低圧複数拠点モデルへの適用に向け、複数拠点を一括で予測するバルク予測を検討した。本稿では、複数のバルク予測方式について、予測精度・経済効果・開発コストの 3 軸から総合的に評価し、実運用に適した方式を選定した検討過程および検証結果について述べる。

Abstract As the deployment of renewable energy accelerates toward the realization of carbon neutrality, ensuring economically viable operations for all stakeholders, including power producers, is essential to the sustainable adoption of photovoltaic (PV) power generation in society. To achieve this, it is important to accurately forecast PV generation and surplus power, which serve as the basis for generation and sales planning, thereby reducing imbalance charges. To address this need, BIPROGY investigated within its PV Generation and Surplus Power Forecasting Service, which was launched in April 2023, an approach that performs bulk forecasting for multiple PV sites collectively, with a view to applying it in the emerging multi-site low-voltage PV model. This paper describes the evaluation process and verification results used to identify a practical forecasting method by comprehensively assessing multiple bulk forecasting approaches from three perspectives: forecasting accuracy, economic effectiveness, and development cost.

1. は じ め に

2050 年のカーボンニュートラル実現に向けた取り組みの一環として、再生可能エネルギーの導入拡大が加速する中、太陽光発電はその中心的な役割を担っている。太陽光発電の普及拡大は、脱炭素社会の実現だけでなく、将来的なエネルギー供給の安定化という社会課題の解決にも寄与する。一方で、出力変動に伴う需給調整コストの増加など、普及拡大に伴う新たな課題も顕在化している。太陽光発電を持続可能なエネルギーとして社会に定着させるには、これらの課題を解消し、関係者にとって経済合理性のある運用を実現することが不可欠である。

BIPROGY 株式会社（以降、BIPROGY）は、こうした課題の解決を支援するため、2023 年 4 月から AI 技術を活用した「太陽光発電量・余剰量予測サービス」を提供している。太陽光発電量・余剰量予測サービスは、太陽光発電量および余剰電力量を高精度に予測することで、電力需給の最適化や太陽光発電事業の収益性向上に貢献するものである。

発電事業者は予測結果を基に発電販売計画を策定している。計画と実際の発電量に乖離が生じた場合には、インバランス料金（計画のズレに対するペナルティ）が発生するため、予測精度の向上は、事業の収益性や安定性に直結する重要な要素となる。

太陽光発電量・余剰量予測サービスは従来、大型高压拠点を対象とした単体拠点向けに展開してきた。しかし、系統混雑や用地確保の課題から大型高压拠点の新規開発は減少傾向にある。

他方、大型高压拠点の課題を回避する新たな取り組みとして、低圧（小規模）の発電所を複数拠点まとめて開発する動きがはじまっている。低圧拠点は、地域の電力需要に応じた柔軟な設計ができるだけでなく、政府による分散型電源の導入促進や再生可能エネルギーの主力電源化に向けた制度整備の対象として位置づけられている。また、コーポレート PPA^{*1}の普及や企業による脱炭素経営の加速といった市場ニーズにも適合している。

こうした状況を踏まえ、BIPROGY は、低圧複数拠点モデルへの適用を見据え、複数の発電所を一括で予測するバルク予測に着目した。本稿では、複数のバルク予測方式について、予測精度に加え、インバランス料金低減による経済効果や運用コストの観点から評価を行い、実運用に適した方式を選定した検討過程および検証結果について述べる。まず 2 章でサービス概要とバルク予測について説明した後、3 章でバルク予測の課題、4 章で課題への対応策および実現パターンを整理し、5 章で検証条件および評価方法、6 章で検証結果と考察を述べる。

2. 太陽光発電量・余剰量予測サービスの概要と複数拠点化への対応

本章では、太陽光発電量・余剰量予測サービスの概要を説明した後、複数拠点化に向けた対応方法について説明する。

2.1 太陽光発電量・余剰量予測サービスの概要

太陽光発電量・余剰量予測サービス（以降、当該予測サービス）の概要図を図 1 に示す。当該予測サービスは、AI 技術の中でも機械学習を活用した予測モデルに基づき、過去の実績電力データと太陽光発電設備設置地点の気象データを組み合わせて予測を行っている。具体的には、日射量や気温、雲量、風速などの気象情報と発電設備ごとの発電履歴を基に、予測モデルが電力量の変動要因を学習し、将来の発電量や余剰電力量を高精度に予測している。




図 1 太陽光発電量・余剰量予測サービスの概要図

2.2 単体拠点から複数拠点化に向けた検討

今後、分散型の低圧拠点による太陽光予測のニーズの高まりが予想されることから、BIPROGY では複数拠点を対象とした太陽光予測サービスの開発を検討した。

開発にあたっては、単体拠点向けの既存サービスを活用・拡張する方針とした。この方針で、従来通りに複数拠点を個別に予測した場合、新たな開発費は不要である一方、対象拠点数の増加に伴い、拠点追加時の導入コストや運用管理コストの増大が懸念された。

そこで、拠点ごとに太陽光予測サービスを構築・運用するのではなく、複数拠点をまとめて管理できる予測方式が必要であると考えた。その方式として、複数拠点を統合して一つの予測対象として扱う予測（以降、バルク予測）に着目し、既存サービスの改修を試みた。バルク予測では一部の機能改修を要するものの、複数拠点を一括で管理できるため、拠点追加時の導入コストや運用負荷の大幅な削減が見込まれる。その結果、総合的には費用対効果が最も高いと想定されることから、本方式の適用を検討した。図2に予測方法のイメージを示す。




図2 太陽光予測方法のイメージ

3. バルク予測の課題

バルク予測の開発にあたっては、「予測精度を確保すること」と、「導入コストを抑制すること」の両立が重要となる。前者は複数拠点をどのようにまとめ、どの気象データを用いるかに大きく依存し、後者は既存サービスからの改修範囲に依存すると考えられる。これらの観点から、バルク予測の開発にあたり、以下三つの課題を整理した。

1) 予測対象拠点のグルーピング基準

予測精度を担保するためには、複数拠点の電力データをどのような基準でグルーピングして、一つの予測対象として扱うかを明確にしなければならない。

2) 予測に利用する気象地点の選定

バルクとして統合した拠点群に対して、どの気象地点のデータを用いるかが予測精度に影響するため、適切な選定方法を検討しなければならない（単体拠点では、拠点に最も近い気象地点を使用していた）。

3) 改修費用の低減方法

単体拠点向けの既存サービスを活用して、改修費用を最小限に抑える設計が求められる。

これらに対して複数の解決案を比較検討し、予測精度、経済効果および開発コストを評価指標として検証を行い、実運用に適した予測手法を選定した。

4. バルク予測の課題への対応策

前章で述べた課題に対応するため、複数拠点のグルーピングおよび気象地点について検討した。

4.1 課題1)、2)に対する拠点のグルーピングと気象地点の選定

バルク予測の開発にあたっての課題1)、2)に対して、以下の検討を行った。

拠点のグルーピング単位としては、予測出力の最大単位であるバランスンググループ*3（以降、BG）と、より細分化された都道府県単位を候補とした。また、気象地点としては、BGの中心地点および都道府県の中心地点を候補とした。

これらの拠点のグルーピングと気象地点の組み合わせについて、以下の四つのパターン（A～D）を設定し、予測精度およびコストのバランスを評価するため、Bを除く三つのパターンで比較検証を行った。各パターンの詳細は表1および図3に示す。

なお、コストの観点では、拠点を大きなグループでまとめる方が望ましいが、これまでの運用経験から、予測精度の観点では、より小さなグループの方が有利であることが示唆される。そのため、両者のバランスを考慮して最適な組み合わせを選定することが重要となる。

- ・パターンA：拠点をBG単位でグルーピングし、BGの中心地点の気象データを使用する。
- ・パターンB：拠点を都道府県単位でグルーピングし、BGの中心地点の気象データを使用する。ただし、気象地点がグルーピング単位外となり、予測対象の気象条件を適切に反映できないことから、精度の担保が困難であると想定されたため、検証対象から除外した。
- ・パターンC：拠点をBG単位でグルーピングし、各都道府県の中心地点の気象データを使用する。
- ・パターンD：拠点を都道府県単位でグルーピングし、各都道府県の中心地点の気象データを使用する。

表1 拠点のグルーピングと気象地点の組み合わせ

		気象地点	
		BG 中心地点	都道府県中心地点
拠点のグルーピング	BG 単位	パターン A	パターン C
	都道府県単位	パターン B (検証対象外)	パターン D




図3 拠点のグルーピングと気象地点の組み合わせイメージ

4.2 課題3)に対する改修費用を抑えた精度向上策

単体拠点向けの既存サービスでは、曜日情報の有無や学習期間の調整が予測精度の改善に寄与した実績がある。これらは既存の予測ロジックのパラメータ設定変更のみで実現でき、データ構造やモデル構造の改修を伴わないことから、課題3)（改修費用の低減方法）に合致する精度向上策と考えた。そこで、バルク予測においても同様の観点を取り入れ、改修費用を抑えつつ精度向上ができるかを検証した。

- ・曜日情報の有無：特徴量^{*4}として曜日情報を含めるか否かが予測精度に与える影響を検証した。
- ・学習期間の調整：予測モデルの学習に用いる過去データ期間が予測精度に与える影響を検証した。特に複数拠点を統合する場合、学習期間が長すぎると地点数の変動に追従しにくくなるため、適切な学習期間の設定が重要と判断した。

5. 検証条件および評価方法

本章では、検証方法、検証データおよび評価指標について述べる。

5.1 検証方法

本検証では、4章で整理した対応策の有効性を評価するため、予測シミュレーションを採用した。予測シミュレーションは、多様な条件下で複数の予測ロジックを同一条件下で比較でき、導入効果を事前に定量評価できるためである。検証にあたっては、パターンA、C、Dについて、曜日特徴量の有無および学習日数を組み合わせた条件で予測を行い、得られた結果を評価指標に基づき評価する。

5.2 検証データ

検証データには、単一の実運用環境から取得されたデータに基づくデータセットを用いた(表2)。当該データの分析および公開に際しては、企業等を識別できないよう厳格な匿名化および統計的集計処理を施して、プライバシーおよび機密性の保護を確保している。

表 2 検証データの詳細

項目	内容
実績電力量データ	某事業者より提供された過去 12 か月間（2023 年 8 月～2024 年 7 月）の実績電力量データで、発電電力量と余剰電力量の両方が含まれている。
予測シミュレーション期間	9 か月間（2023 年 11 月～2024 年 7 月） 2023 年 8 月～10 月は学習期間のため予測シミュレーション期間の対象外とする。
予測タイミング	前日 7:00 に翌日 24 時間分（00:00～23:30 の 48 コマ）を予測
地点数	126 地点（複数県に点在。期間中に拠点の増減がある。）

5.3 評価指標

予測シミュレーション結果を評価するために、以下三つの指標を設定し、これらをバルク予測の開発における総合的な判断材料とした。

1) 予測精度

MAPE（平均絶対パーセント誤差）^{*5}を用いて、予測精度を評価した。MAPE は機械学習モデルの予測精度を評価する指標の一つで、値が小さいほど予測誤差が小さく、高精度であることを示す。

2) 経済効果

発電インバランス料金を算出し、それが発電事業者に与える経済的影響について評価した。発電インバランス料金とは、発電計画値と実際の発電量の差異に応じて発生する調整費用であり、不足インバランス料金と余剰インバランス料金の和（発電インバランス料金＝不足インバランス料金＋余剰インバランス料金）として定義される。

不足インバランス料金は、発電計画よりも実績が少ない場合に発生し、その差分に不足インバランス単価を乗じた金額であり、発電事業者が系統運用者に支払う。一方、余剰インバランス料金は、発電計画よりも実績が多い場合に発生し、その差分に余剰インバランス単価を乗じた金額であり、発電事業者が受け取ることができる。

本検討では、発電インバランス料金がゼロに近いほど経済的に有利であると評価した^{*6}。

3) 開発コスト

各検証パターンの構築にかかる開発原価を評価した。

6. 検証結果と考察

本章では予測シミュレーションを用いた検証結果をまとめる。

6.1 検証結果

4.1 節の拠点のグルーピングと気象地点の組み合わせパターンと、4.2 節の曜日特徴量、学習日数の影響について検証した結果を記載する。

(1) 予測精度

図 4 に各パターンの曜日特徴量の有無（曜日無：点線・曜日有：実線）と学習日数（07, 14, 30, 60, 90）による 9 か月平均 MAPE の比較グラフを示す。

全ての学習日数において、曜日特徴量無しの方が、MAPE が低く、予測精度が高い結果

となった。学習日数が増えるにつれて MAPE は低下し、30 日間の学習が最も高い予測精度を示した。30 日以降は若干の精度低下が見られるものの、ほぼ安定した精度が維持されることが確認された。

曜日特徴量の寄与が低くなった要因としては、検証対象に自家消費のない発電所が多く含まれており、余剰量予測に比べて発電量予測の割合が大きかったことが挙げられる。発電量予測は主に気象条件に依存するため、曜日の影響を受けにくく、結果として曜日無しの方が高い予測精度を示したと推察した。

複数拠点の場合、拠点数および電力量は一度に増えるのではなく、日々増減がある。そのため、学習日数を長く設定すると、発電電力量の変動に対するモデルの追随性が低下する可能性が懸念された。しかしながら、実際には 30 日以降の学習でも予測精度への大きな影響は見られず、一定の安定性が保たれることが分かった。




図4 曜日特徴量、学習日数が予測精度に与える影響

この結果から、各パターンを同条件（曜日特徴量無し、学習日数 30 日）で比較した結果を表 3、図 5 に示す。

パターン C が最も MAPE が低く、高い精度であった。また、標準偏差も最小であり、月ごとのばらつきが小さい安定した予測となった。月別の結果でも全体的に MAPE が低く、特に冬季（1 月）や夏季（7 月）でも他より誤差が抑えられており、季節変動に強いモデルと評価できる。次点はパターン A で、C より劣るが良好なモデルである。パターン D は他と比べて精度・安定性ともに劣る結果となった。

もともと、パターン A は D に比べて広域の気象情報を扱うため、局地的な変動が捉えにくくなり、予測精度が劣ると想定していたが、今回の結果ではその予想に反して、パターン A の方が高い精度を示し、パターン D の方が低いという結果となった。

この要因としては、パターン D では実際の運用を想定し、発電拠点の初期分布ではなく県の中心地点を気象地点として設定している点が挙げられる。そのため、発電拠点の分布と気象地点に乖離が生じた場合、気象地点の局地的な気象現象（例：突発的な雨など）が強く

反映され、予測精度が低下した可能性がある。

一方、パターン A の BG 単位の広域的な気象情報では、局地的なばらつきがならされるため、結果的に予測精度が向上したと推察した。ただし、他のエリアや発電分布でも同様の傾向が得られるかどうかについては、今後の検証が求められる。

表 3 予測精度と安定性

パターン	9 か月 MAPE	標準偏差
A. 曜日無 30	0.219121	0.03823
C. 曜日無 30	0.213996	0.03396
D. 曜日無 30	0.231971	0.03757




図 5 パターン別 MAPE 推移

(2) 経済効果

図 6 に各パターンの曜日特徴量の有無（曜日無：点線・曜日有：実線）と学習日数（07, 14, 30, 60, 90）による 9 か月合計インバランス料金の比較グラフを示す。発電インバランス料金がゼロに近いほど経済的に有利と評価している。

学習日数にもよるが、特徴量として曜日無しの方が経済的に有利な傾向がある。学習日数では、短期学習日数（07 ～ 30 日）は損失が大きく、学習日数 60 日が最も経済的に有利な結果となった。




図6 曜日特徴量, 学習日数がインバランス料金に与える影響

以上の結果から、各パターンを同条件（曜日特徴量無し、学習日数 60 日）で比較した結果を表 4、図 7 に示す。

表 4 経済効果

パターン	インバランス料金月平均 (千円)
A. 曜日無 60	-69
C. 曜日無 60	-56
D. 曜日無 60	-74




図7 パターン別インバランス料金推移

パターン A, C, D のインバランス料金を月別に分析した結果, 最も経済効果が高いと評価できるのはパターン C であり, 次点はパターン A であった. パターン C はインバランス料金の平均値が最もゼロに近く, 全期間を通じて安定した経済効果を示している. 一方, パターン A と D はほぼ同様の傾向が見られた. 2 月から 5 月にかけては, パターン C よりも良好な結果を示している月もあったが, 全体を通して評価すると, パターン C が最も優れた経済効果を示したと結論づけられる.

さらに, 上位パターンである A, C について, 某事業者にサービスを提供した場合の月平均予測料金と実質予測料金を算出した結果を表 5 に示す. パターン A, C 間には大きな差は見られなかった.

予測料金とは, サービス提供時に発生するサービス利用料を指し, 実質予測料金とは, BIPROGY がインバランス料金を負担するサービスプランの場合に発生するサービス利用料金である. それぞれ以下の式で表される.

$$\text{予測料金} = \text{予測電力量 (kWh)} \times \text{ランニング費用単価 (円/kWh)}$$

$$\text{実質予測料金} = \text{予測料金} - \text{インバランス料金}$$

表 5 月平均予測料金および実質予測料金

パターン	実績電力量 (kWh)	予測電力量 (kWh)	インバランス料金 (比較指数)	予測料金 (比較指数)	実質予測料金 (比較指数)
A. 曜日無 60	354,590	340,375	1.000	1.000	1.000
C. 曜日無 60		339,867	0.807	0.999	0.964

(3) 開発コスト

パターン A, C, D の開発原価について評価した.

開発は, 既存の単体拠点向け予測を活用・拡張する方針を前提とし, 主にデータ構造の違いに着目した. なお, 特徴量や学習期間は設定値であり, 開発作業に直接的な影響はない.

既存の単体拠点向け予測では, 予測対象地点に対して 1 ヶ所の気象地点データを保持するデータ構造となっている (予測対象地点: 気象地点 = 1:1). バルク予測においては, パターン A および D では, 一つのバルクに対して使用する気象地点が 1 ヶ所である (予測対象地点: 気象地点 = 1:1) ため, 既存データ構造を流用できる部分が多く, 影響範囲は限定的である.

一方, パターン C では, 一つのバルクに対して複数の気象地点を使用する (予測対象地点: 気象地点 = 1:N) ため, データ構造が既存と異なる. この構造の変更により, テーブル設計やバッチ処理など, 広範な修正を要するため影響範囲が大きくなる. パターン C の開発原価はパターン A および D の約 3.25 倍と試算される.

6.2 考察

前節の検証結果を基に, 予測精度・経済効果・開発コストの三つの観点から各パターンを総合的に評価し, 実運用への適合性を判断した (表 6). 表 6 の評価記号は, 各評価観点におけるパターン間の相対的な優劣を示す. 予測精度については MAPE および月別の精度の安定性, 経済効果についてはインバランス料金の月平均額および月別推移, 開発コストについては既存

システムへの影響範囲および開発原価を評価指標として判定した。

予測精度および経済効果の両面において最も優れた結果を示したのはパターン C であり、特に季節変動に対する強さやインバランス料金の安定性が高く評価された。しかしながら、パターン C は複数の気象地点を扱うため、既存システムとの互換性が低く、データ構造の大幅な変更を要することから、開発コストが他パターンと比較して著しく高くなる。

予測精度や経済効果ではパターン C が最も優れていた。しかし、次点であるパターン A と比較すると、今回の規模の電力量における開発コストの回収期間は、パターン A が 1.7 年に対し、パターン C は 5.8 年と長期に及ぶ。

また、拠点数の増減が発生するタイミングで導入コストが発生する点も考慮した。単体拠点向け予測と比較すると、バルク予測では導入作業が軽微であり、導入コストは相対的に小さい。さらに、バルク予測のパターン A ～ D の比較においては、バルク規模が大きくなるほど運用コストは低減すると想定している。

経済効果の差に比べて、開発コストの差が非常に大きかったため、総合的に勘案すると、パターン A が有力な選択肢と判断した。

なお、本事例は開発コストと予測精度のバランスを重視した一例であり、精度・経済効果・開発コストのいずれを重視するかは、プロジェクトの目的や状況に応じて異なる点に留意が必要である。

表 6 総合評価

	パターン A	パターン C	パターン D
予測精度	○	◎	△
経済効果	○	◎	○
開発コスト	◎	△	◎

7. お わ り に

本稿では、AI を用いた予測機能の開発において、仮説検証のプロセスや評価指標を整理した。これにより、開発効率の観点から有用な知見を得られた。

仮説検証のプロセスや評価指標の整理は、関連技術の開発を進める上で応用可能な有用性を持っており、太陽光予測に限らず、他領域への応用も期待される。特に、予測精度そのものではなく、インバランス料金など事業収益への影響を経済効果として定量化し、開発コストと合わせて総合的に方式を選定するプロセスは、AI 予測モデルを実サービスとして展開する際に共通する評価の枠組みであり、電力領域におけるインバランス単価予測や市場価格予測、需要予測などに応用できる可能性がある。

今後は、本検証で得られた知見を基に、カーボンニュートラルの実現と電力需給の安定化という社会課題の解決に向けて、これらの予測領域への応用を進めていく予定である。最後に、本プロジェクトの遂行にあたりご協力いただいた関係者の皆様、ならびに本稿の作成にご尽力いただいた皆様に、心より感謝申し上げます。

- * 1 企業が再エネ発電事業者と直接契約し、長期的に電力を購入する仕組み。
- * 2 電力広域的運営推進機関は、電源の広域的な活用に必要な送配電網の整備を進めるとともに、全国大で平常時・緊急時の需給調整機能を強化するため、専門的知見と強い事業者間調整機能を有する組織として2015年4月に設立。電気事業法に基づく認可法人として、中立で公平な業務運営を行っている。OCCTO または広域機関と呼ばれる。
<https://www.occto.or.jp/occto/>
- * 3 電力の需給バランスを調整するために、複数の電力事業者や需要家が集まって形成するグループのこと。特に計画値同時同量制度の下で、インバランス（計画値と実績値の差）の精算単位となる事業者群を指す。
- * 4 機械学習モデルが予測を行うために判断材料として利用する入力データの要素。
- * 5 絶対誤差値（予測値－実績値の絶対値）を実績値で割り、その総和をデータ数で割って求めた平均値のこと。
- * 6 計画より発電量が少ない場合、発電事業者は不足インバランス料金を支払う必要がある。一方、多い場合は余剰インバランス料金を受け取れるが、その単価は通常、電力市場価格よりも低いいため、計画通りに売電した場合と比べて、収益性が劣る可能性がある。

- 参考文献** [1] 環境省、太陽光発電の導入支援サイト、2026年4月、
https://www.env.go.jp/earth/post_93.html
- [2] 太陽光発電量・余剰量予測サービス | AI 予測サービス, BIPROGY,
https://www.biprogy.com/solution/service/ems_power_prediction.html
- [3] BIPROGY ニュースリリース「独自の AI 技術で高精度のバルク予測を実現し、小売電気事業者と発電事業者の費用負担リスクを軽減」、BIPROGY、2025年6月、
https://www.biprogy.com/pdf/news/nr_250630.pdf

※ 上記注釈および参考文献に示した URL のリンク先は、2026年7月3日時点での存在を確認。

執筆者紹介 藤 本 容 子 (Yoko Fujimoto)

2023年 BIPROGY(株)入社。エネルギー領域における「太陽光発電量・余剰量予測サービス」の開発・保守・導入を担当。カスタマーサクセスエンジニアとして、課題分析と対応を通じてサービス価値の向上に取り組んでいる。

