

Day-ahead Planning and Shortfall Risk Assessment in the Balancing Market for Solar Power Plants

Jindan CUI^{*1‡}Xue FANG^{*2}Bo JIE^{*2}Takashi OOZEKI^{*3} Yuzuru UEDA^{*4}

太陽光発電所における需給調整市場の前日計画と不足発生リスク評価

崔 錦丹^{*1‡}方 雪^{*2}界 波^{*3}大関 崇^{*4}植田 譲^{*5}

Abstract

With increasing integration of renewable energy, especially photovoltaics (PV), maintaining supply-demand balance is a growing challenge. This study proposes a three-stage method to enable PV participation in the balancing market through day-ahead scheduling while managing imbalance risks. First, a headroom-setting algorithm is developed to absorb PV prediction errors. Second, a rare-event risk model identifies over/underestimation, supporting scenario-based bidding decisions. Third, a priority-based scheduling method is proposed for balancing market bidding. The approach is evaluated by examining feasible annual bids, shortage count, and expected revenue. In Scenario 1, application of the Linear-SVC model resulted in 524 feasible bids, with annual shortfalls reduced to 42—close to the target of 36—and improved revenue. This framework demonstrates the potential for PV systems to provide balancing reserve power while minimizing prediction risks and enhancing market participation outcomes.

Keywords: PV system, reserve power, day-ahead plan, headroom setting, polynomial surface, shortfall risk, machine learning
キーワード：太陽光発電、調整力、前日計画、headroom 設定、多項式曲面、不足発生リスク、機械学習

1. はじめに

再生可能エネルギー(以下、再エネ)の導入拡大に伴い、電力システムにおける需給バランスの維持に必要な「調整力」の重要性が高まっている。なかでも太陽光発電は、天候や時間帯、季節に依存して出力が大きく変動するため、従来の火力発電などとは異なる新たな需給調整の仕組みが求められている。これまで一般送配電事業者は、周波数制御や需給バランス調整に必要な調整力を公募により調達してきたが、より効率的かつ公平な調達を目的として、2021年4月に「需給調整市場」が創設され、市場メカニズムを通じた広域的な調整力の調達が開始された。本市場では応動時間や継続時間などの要件に基づき、「一次調整力」、「二次調整力①・②」、「三次調整力①・②」の5つの商

品に区分される。一次および二次調整力は主に周波数制御を目的としており、比較的迅速な応動が求められる。一方、三次調整力は需給バランスの維持を目的としており、そのうち「三次調整力②」はFIT(feed-in tariff)制度によって導入された再エネ電源の変動に対応する調整力であり、応動時間45分以内、継続時間30分(2025年度以降)という要件が設定されている^{1,2)}。

FIT制度の導入により、再エネの導入が加速し、日本政府が掲げる「2050カーボンニュートラル」の実現に向けて、再エネの主力電源化が不可欠となっている。そのため、2022年度よりFIP(feed-in premium)制度が導入された。FIP制度は、再エネ発電事業者が卸電力市場へ売電する際、市場価格に一定のプレミアムを上乗せすることで収益を確保する市場価格に連動する制度である^{3,4)}。しかしながら、

*1 Assistant Professor, Department of Electrical and Engineering, Faculty of Engineering, Tokyo University of Science, 6-3-1 Niijuku, Katsushika-ku, Tokyo 125-8585, Japan
 ‡e-mail: cui_jindan@rs.tus.ac.jp

*2 Research Institute for Science and Technology, Tokyo University of Science

*3 Department of Electrical and Engineering, Faculty of Engineering, Tokyo University of Science

*4 National Institute of Advanced Industrial Science and Technology, Fukushima Renewable Energy Institute, AIST (FREIA)

*5 Professor, Department of Electrical and Engineering, Faculty of Engineering, Tokyo University of Science

Received: April 28 2025, Accepted: July 1 2025

*1 東京理科大学 工学部 電気工学科 助教
 (〒125-8585 東京都葛飾区新宿 6-3-1)

‡e-mail: cui_jindan@rs.tus.ac.jp

*2 東京理科大学 総合研究院 プロジェクト研究員

*3 東京理科大学 工学部 電気工学科 客員研究員

*4 産業技術総合研究所 再生可能エネルギー研究センター
 太陽光発電システムチーム長

*5 東京理科大学 工学部 電気工学科 教授

(原稿受付: 2025年4月28日, 受理日: 2025年7月1日)

特に太陽光発電の急速な普及に伴い、日中の電力量が需要を上回る状況が発生しており、一部の地域では再エネ電源の出力制御が実施されている⁵⁾。加えて、電力エネルギー(kWh)を取引するスポット市場においても、日中の電力価格がゼロ円近くまで低下する日数が増加しており、その結果、FIP価格も相対的に低下する傾向にある。収益の改善のため、蓄電池を併設する発電所も増加しつつあるが、蓄電池導入を考慮しない場合は、スポット市場のみへの参入は発電所として採算性が確保できない事態となり得る⁶⁾。このような状況は、日中しか発電できない太陽光発電事業者の収益性を大きく損ねる要因となる事が懸念され、再エネのさらなる普及及び主力電源化の実現に向けた障壁となる可能性がある。以上の背景を踏まえ、本研究では、太陽光発電所におけるエネルギー価値や環境価値に加え、新たに需給調整市場における「調整力価値(ΔkW)」を創出することを目的とする。

これまでの検討として、太陽光発電所が安定的に調整力を供出するために、発電予測誤差を吸収する Headroom 設定モデルに関して多角的なアプローチを行ってきた。参考文献 7)では、発電電力予測値と過去実績との誤差との関係を統計的に評価するモデルを構築し、過去の過不足発生確率を考慮しつつ、過大/過小予測に対する誤差限界ラインを用いて解析を行った。さらに、サポートベクター回帰(SVR)に基づく誤差推定モデルを構築し、統計モデルとのコンバインドにより、発電電力予測値に対して Headroom を設定し、年間不足発生回数を算出してモデルを評価した。参考文献 8)では、SVR モデルの改良として、ランダムフォレスト(RF)を用いて Gini 係数を算出し、各特徴量の重要度を定量的に反映させた VI-SVR(Variable Importance-SVR)モデルを提案した。さらに、異なる初期時刻における予測値に重みを付加する SVR モデルの検討も行われた。また、参考文献 9)では、参考文献 7)の SVR モデルにおける特徴量の変化量と予測誤差の関係を分析し、参考文献 10)では、予測誤差の分類手法として深層強化学習を導入し、 ϵ -greedy 方策に基づく Deep Q-Network(DQN)を実装して、不足発生回数の低減を図った。

また、稀頻度リスク分析に関する先行研究では、RF モデルを用いて雲の動きや日射量の変化による日射量予測誤差の範囲を予測する手法が提案された¹¹⁾。需給調整市場(balancing market)における前日入札計画に関する先行研究では、継続時間が 3 時間である三次調整力②と、30 分単位で取引されるスポット市場(spot market)という、異なる時間スケールを持つ 2 つの市場へ同時参入し、収益の最適化を図る手法が提案された¹²⁾。

一方、海外における太陽光発電所の需給調整市場への参入に関する研究は極めて少なく、特に蓄電池や時間前市場(intra-day market)などの追加リソースを用いず、太陽光発電所単体で市場参入を行う事例はほとんど報告されていない。

本研究では、太陽光発電システムの特性を踏まえ、比較

的に参入しやすい三次調整力②への入札戦略に着目し、大きく 3 つの段階に分けてモデル構築した上、太陽光発電事業者による単体での調整力供出の可能性について分析及び評価を行う。本文の第 2 章では、本研究におけるアプローチおよび研究の流れについて概説する。第 3 章では、各段階におけるモデルの構成と評価指標について詳細に述べる。第 4 章では、太陽光発電電力の予測値と実測値を用いて複数のシナリオを設定し、数値シミュレーションを実施する。第 5 章では、各シナリオに基づくシミュレーション結果を示すとともにそれらに対する考察を行う。最後に第 6 章では、本研究の結論をまとめ、今後の課題や展望について述べる。

2. アプローチおよび研究の流れ

2.1 アプローチ

前日計画段階において利用可能な情報は、太陽光発電電力(30 分ごとの評価の場合、タイムスタンプの前 30 分間の平均発電電力。単位は kW)の予測値である。本研究では、発電所における追加投資(蓄電池の導入)や時間前市場調達などの補助的リソースを考慮しない前提のもと、予測誤差を吸収して確実な調整力を創出するために、出力を意図的に抑制する Headroom 設定を行うことを想定した。Headroom 確保により縮小された出力は、最終的に電力市場価格を踏まえ、需給調整市場又はスポット市場のいずれに入札するかを判断する。需給調整市場では、月あたり 3 回以上契約不履行となった場合、取引停止となり、事前審査を再実施される厳格なペナルティ制度¹³⁾が設けられているため、そのリスクを適切に回避することが重要であり、稀頻度リスク分析を実施し、より高度なリスクヘッジを図ることを目指した。Table1 に両市場の相違点を要約する^{1),6),13)}。

Table 1 Comparison of balancing and spot markets.

	Balancing market (Replacement reserve for FIT)	Spot market
Target	Supply-demand balance	Energy trading
Transaction value	kW	kWh
Transaction interval	30-min (from FY2025)	30-min
Bid price	• Reserve price (Max/aver./min price auction) • Energy price	Blind single-price auction
Main player	Power generator or electricity retailer	Aggregator or dispatchable resource
Assessment	Removal & re-evaluation triggered after ≥ 3 occurrences per month.	Imbalance settlement
Bid submission deadline	2:00 PM on the preceding day	10:00 AM on the preceding day

Fig. 1 に示すように、太陽光発電電力の予測値 P_f は、誤差吸収分の Headroom と、いずれかの計画値の合計となる。

$$P_f(t) = \begin{cases} H_e(t) + H_r(t), & \text{if } U_r(t) > \frac{U_s(t)}{2} \\ H_e(t) + P_p(t), & \text{if } U_r(t) < \frac{U_s(t)}{2} \end{cases} \quad (1)$$

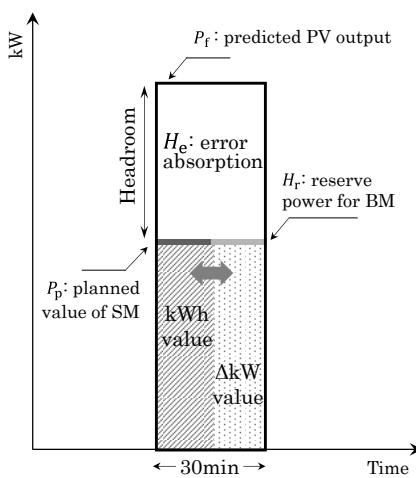


Fig. 1 Power flow in a 30-min section.

Note: BM and SM represent balancing market and spot market, respectively.

ここで、 H_r は需給調整市場への入札計画値[kW], P_p はスポット市場への入札計画値[kW], P_f は需給調整市場平均落札価格[円/kW・30min], U_s は30分のスポット市場価格[円/kWh]を表す。 t は時刻とし、2つ市場の取引単位に合わせて、30分単位で分析を行う。

式(1)を基に、 P_f に対する適切な H_e の算出、ならびに H_r と P_p の入札戦略を決定するアルゴリズムの構築を検討する。

2.2 研究の流れ

市場における前日入札計画の全体アルゴリズムフローを以下で説明する。

第1段階では、過去データを用いて太陽光発電電力の予測値の誤差分析を行い、発電電力予測値 P_f 毎に誤差吸収分の H_e を設定する。過去の発電電力予測値と実測値から予測誤差を算出し、全天日射量の予測値と大気外日射量に基づいて晴天指数を算出する。予測誤差を集合毎に分類し、それぞれに対してカーネル密度推定を適用することで、確率密度関数と累積分布関数を求める。累積確率に対する誤差の閾値を特定し、それに対応する発電電力予測値および晴天指数を探る。また、発電電力予測値と晴天指数を説明変数、予測誤差を目的変数とする多項式近似曲面を構築する。

第2段階では、 $k = [0,1]$ のバイナリ係数を設けて稀頻度リスク分析により需給調整市場参入可否を決定する。稀頻度リスク分析では、RF (random forest), SVC (support vector classification)、およびLSTM (long short-term memory) ネットワークといった機械学習や深層学習モデルを用いて、全天日射量の予測誤差を「極端な過小予測」、「過小予測」、「僅かな誤差」、「過大予測」、「極端な過大予測」の5つのクラスに分類するモデルを構築する。さらに、3つのシナリオを設定し、過大予測や極端な過大予測のクラスは需給調整市場へ入札しない、極端な過小予測は誤差吸収分のHeadroom設定が不要と判断する、といったバイナリ係数 k を決定する。

第3段階では、2つの市場価格を考慮した計画収益が最大になる計画を立てる。発電電力予測値 P_f 、予測誤差吸収分のHeadroom H_e 、稀頻度リスク分析によるバイナリ係数 k 、及び2つの市場価格を統合的に考慮し、翌日の市場への入札計画を策定する。本計画は、リスク回避と収益最大化のバランスをとることを目的とし、予測誤差と市場環境に応じた柔軟な戦略を図る。

最後に、発電電力実測値 P_m を用いて、前日計画に基づく入札可能回数、不足発生回数および計画収益を評価指標として用い、提案手法の有効性および実運用における適用可能性を検証する。

3. 前日入札計画作成アルゴリズム

本章では、第2章で述べた各段階におけるアルゴリズムについて詳細に説明する。

3.1 Headroom設定アルゴリズム

H_e を確保するためには、予測誤差と相關関係があり、かつ独立した特徴量を特定することが重要である。予測誤差は当然ながら発電電力予測値と密接な関係があり、太陽光発電電力は日射量と高い相関を示す¹⁴⁾⁻¹⁶⁾。しかし、同じ発電電力であっても、晴れと曇りでは予測精度が異なる場合がある。つまり、晴天時の予測は高い信頼性を持ち、曇天時の予測は精度が低い傾向があるため、発電電力予測値以外にも、天候を表す重要な指標である晴天指数(clearness index)を説明変数として追加する。

本研究では、太陽光発電の設備容量に対して、過去の発電電力予測値および実測値を正規化して、1kWあたりの予測誤差 e を算出する(式(2))。さらに、発電電力予測値を0.01kW刻みで区切って、それぞれの区間に応する予測誤差の集合 R_n を構築することで、発電電力予測値に対する予測誤差の分布特性を分析しやすい構造とする。

$$e(t) = P_f^L(t) - P_m^L(t) \quad (2)$$

$$(P_n^L, e) \in R_n, n \in \{0, 0.01, 0.02, 0.03, \dots\} \quad (3)$$

ここで、 P_f^L , P_m^L は過去の発電電力予測値と実測値を表し、単位はkWである。

一方、晴天指数 CI は式(4)で定義される¹⁷⁾。

$$CI(t) = \frac{H_g(t)}{H_0(t)} \quad (4)$$

ここで、 H_g は全天日射量、 H_0 は大気外日射量を表し、単位はkWh/m²である。

上述した各予測誤差集合 R_n に対して、四分位範囲の1.5倍以上を外れ値として除外し、確率分布およびカーネル密度推定に基づき、確率密度関数(probability density function, PDF)を求める(式(5))。

$$\hat{f}_h(e) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{e - e_i}{h}\right) \quad (5)$$

$$\hat{F}_h(e) = \int_{-\infty}^{e_{\max}} \hat{f}_h(e) de \quad (6)$$

$$e_{\text{th}} = \hat{F}_h^{-1}(\mu) \quad (7)$$

ここで、 e_i は集合のサンプル、 h はカーネルのスケールを表す帯域幅、 n はサンプル数、 K は平滑化関数を表す。本研究ではガウスカーネル関数を平滑化関数と使用する。式(6)は確率密度関数に基づいて推定された累積分布関数(cumulative distribution function, CDF)を表す。式(7)を用いて累積確率 μ に対する予測誤差の閾値 e_{th} を算出する。

また、予測誤差の集合 R_n から、閾値 e_{th} の最近傍誤差 e_n を選択して、それに対応する P_f^L および CI_f^L の値を用いる。そして、説明変数 P_f^L に対して2次関数、 CI_f^L に対して1次関数による多項式近似曲面を作成する。

$$e_n = f_{\text{py}}(P_f^L, P_f^{L^2}, CI_f^L) \quad (8)$$

Fig. 2 は累積確率 $\mu = 1.0$ 時の近似曲面を示す。Fig. 2 (a)より、予測誤差は説明変数の領域で最大値を持つ特性があり、前半と後半で散布特性が異なるため、最大値を基準に単調増加部分と単調減少部分に分割してそれぞれについて近似曲面を生成する (Fig. 2 (b)と(c))。これにより、近似曲面のバイアスをより低減することができる。

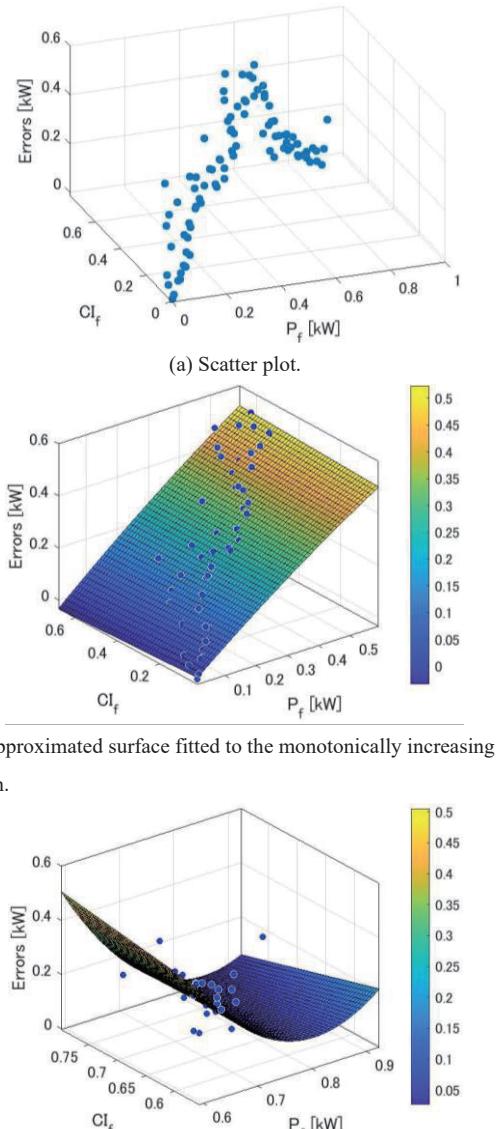
3.2 稀頻度リスク分析による入札意思決定

ペナルティが非常に厳しい需給調整市場には発電電力予測が過大になる場合は入札を行わない戦略が重要である。本節では、 H_e 設定に加え、さらなるリスクヘッジを考慮した稀頻度リスク分析を行い、誤差範囲を予め判定できる分類モデルを構築する。

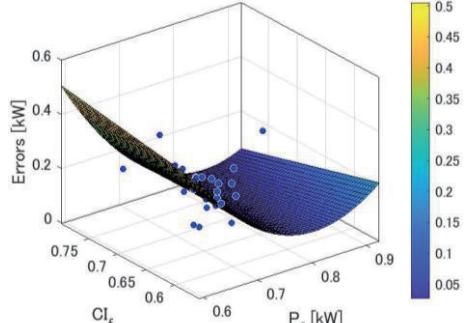
太陽光発電電力の予測には多くの要素が用いられるが、日射量はその中の最も重要な要素であり¹⁶、3.1節で述べた晴天指数も非常に重要な特徴量として考えられる。発電電力予測の精度において、日射量や晴天指数の値は重要な要素であるが、時系列的な変化が予測精度に与える影響も考慮する必要がある。また、雲の動きによる日射の遮蔽は日射量予測に重要な要因となるため、雲量の予測精度向上が重要である¹⁸。そこで、対象エリアの全雲量に加え、周辺エリアまで拡張した雲の動きを把握するために、空間的な雲量の変化量および周りの雲の状態を表す雲量の標準偏差を特徴量として使用する。Fig. 3 に示すように、中央の観測格子を太陽光発電所が所在するターゲット格子とし、その周りの格子に1から8までの番号を付けた。本研究における特徴量の抽出およびラベルの設定方法は参考文献11)を参考した。

3.2.1 特徴量(説明変数)

Table 2 では、時系列に関する特徴量、時間方向での変



(b) Approximated surface fitted to the monotonically increasing region.



(c) Approximated surface fitted to the monotonically decreasing region.

Fig. 2 Approximated surface when $\mu = 1.0$.

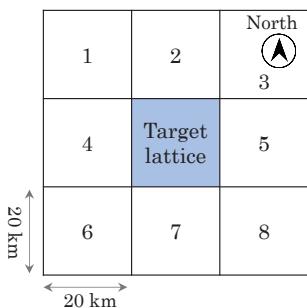


Fig. 3 Target location and neighboring grid points.

化量、空間方向での変化量に分けて特徴量を説明する。

- ・時系列に関する特徴量

a. 対象時刻 t のコサイン関数 : $T_{\cos} = \cos\left(\frac{t}{48}2\pi\right)$

b. 対象時刻 t のサイン関数 : $T_{\sin} = \sin\left(\frac{t}{48}2\pi\right)$

c. 対象日が属する月 M : ダミー変数として表す (one-hot

encoding)

d. 対象日の年間通し番号 d : ダミー変数として表す (one-hot encoding)

- ・時間方向での変化量

e. ターゲット地点の日射量予測値 $H_f^T(t)$ [Wh/m²] : 対象時刻 t から 30 分間の日射量の予測値を表す.

f. ターゲット地点の晴天指数予測値 $CI_f^T(t)$

g. 日射量予測値変化量 $\Delta H_f^T(t)$ [Wh/m²] : 対象時刻 t から 30 分前の日射量予測値の変化量を表す.

$$\Delta H_f^T(t) = H_f^T(t) - H_f^T(t-1) \quad (9)$$

h. 晴天指数予測値変化量 $\Delta CI_f^T(t)$: 対象時刻 t から 30 分前の晴天指数予測値の変化量を表す.

$$\Delta CI_f^T(t) = CI_f^T(t) - CI_f^T(t-1) \quad (10)$$

- ・空間方向での変化量

i. ターゲット地点の全雲量予測値 $TCC_f^T(t)$: 対象時刻 t の曇り程度をパーセンテージで表す指標であり、値が大きいほど曇りであることを表す.

j. ターゲット地点と周囲格子の全雲量の差の最大値 $TCC_f^{\max}(t)$

$$TCC_f^{\max}(t) = \max_{i=1,\dots,8} [TCC_i(t) - TCC_f^T(t)] \quad (11)$$

k. ターゲット地点に対する周囲格子の全雲量の標準偏差 $TCC_{sd}(t)$: 対象時刻 t におけるターゲット地点に対する周囲の全雲量の散らばり具合を表す.

$$TCC_{sd}(t) = \sqrt{\frac{\sum_{i=1}^8 [TCC_i(t) - TCC_f^T(t)]^2}{8}} \quad (12)$$

3.2.2 目的変数(ラベル)

入札意思決定では日射量の予測誤差分布を基に、稀に起きる過大予測や過小予測を検知し、過大予測又は極端な過大予測時は需給調整市場への入札を回避し、極端な過小予測時は H_e を確保しないことで収益を向上する手法を提案する。日射量の予測誤差は式(13)に示す。ここで、 $H_m^T(t)$ はターゲット地点の日射量実測値[Wh/m²]を表す。

$$e_H(t) = H_f^T(t) - H_m^T(t) \quad (13)$$

Fig. 4(左)は日射量誤差の分布図を示す。本研究では、分布の両端の稀頻度クラスのサンプル数が同等になるように、なおかつ、中央の 3 クラスについてもサンプル数に大きな偏りが出ないように調整するとともに、需給調整市場における入札計画値に対して $\pm 10\%$ の許容範囲¹³⁾を考慮し、曇天日においても日中の発電電力に換算した際にこの範囲に収まるよう、誤差幅 ± 30 を中心とした 5 つのクラスに分類し、目的変数とする。

$e_H(t) \leq -150$ の時、「極端な過小予測 (Class 1)」；

Table 2 Features.

	Feature vectors	Variable symbol
Time-based	a. Trigonometric function of time	T_{\cos}
	b. Trigonometric function of time	T_{\sin}
	c. Month	M
	d. Ordinal date	D
Temporal	e. Forecast solar radiation	$H_f^T(t)$
	f. Forecast clearness index	$CI_f^T(t)$
Spatial	g. One hour's change of forecast solar radiation	$\Delta H_f^T(t)$
	h. One hour's change of forecast clearness index	$\Delta CI_f^T(t)$
	i. Total cloud cover (TCC)	$TCC_f^T(t)$
	j. Maximum differences of surrounding lattice points' TCC	$TCC_f^{\max}(t)$
	k. Standard deviation of TCC	$TCC_{sd}(t)$

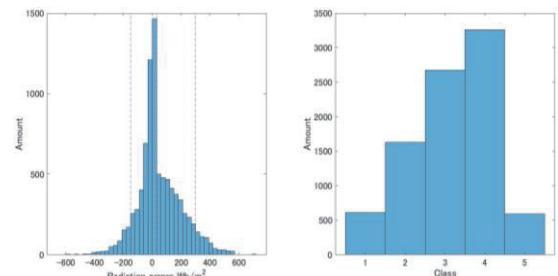


Fig.4 Error distribution and Class distribution.

$-150 < e_H(t) < -30$ の時、「過小予測 (Class 2)」；

$-30 \leq e_H(t) \leq 30$ の時、「僅かの誤差 (Class 3)」；

$30 < |e_H(t)| < 300$ の時、「過大予測 (Class 4)」；

$e_H(t) \geq 300$ の時、「極端な過大予測 (Class 5)」；

5 つのクラスに分類した分布図を Fig. 4(右)に示す。

3.2.3 学習モデル

本手法では、日射量の予測誤差範囲を判別することにより、稀頻度で発生するクラスを検知するモデルを構築する。主に RF, SVC, LSTM の異なる構造の学習モデルを使用してそれぞれの分類精度を比較する。SVC のカーネル関数はガウス(Gaussian-SVC)および線形(Linear-SVC)の 2 種類に分けて検討する。各モデルの詳細は Table 3 にまとめる。RF および SVC の特徴量は a~k を使用し、LSTM は長期にわたる時系列データの依存関係を保持しやすい構造を持つため、なおかつ特徴量数とサンプル数のバランスを考慮して時系列に関する特徴量は c のみを入力変数とする。RF および SVC は、サンプル数に対して特徴量ベクトルを持つ 2 次元のデータセットを入力する。一方、LSTM では、1 日 48 スポットの時系列情報を含む必要があるため、時系列次元を加えた 3 次元のデータセットを入力する。なお、過学習の抑制およびモデルの汎化性を確保するため、学習データの 80%を訓練データ、20%を検証データとして分割して k-fold 交差検証を行う。各モデルの分類結果と正解分布を Table 3 に示す。その結果、RF および Gaussian-SVC のクラス分布は正解分布と大きく異なり、

Table 3 Classification models.

	Random forest (RF)	Support vector classification (SVC)		Long short-term memory (LSTM)																																																																			
		Gaussian	Linear																																																																				
Features	a, b : Trigonometric fn. c, d : one-hot encoding e to k	a, b : Trigonometric fn. c, d : one-hot encoding e to k	a, b : Trigonometric fn. c, d : one-hot encoding e to k	c : one-hot encoding 3D (expanding the dataset with a time-series dimension)																																																																			
Dimensionality of features	2D	2D	2D																																																																				
Cross-validation	K-fold	K-fold	K-fold	K-fold																																																																			
Mean accuracy	0.531	0.581	0.622	0.490																																																																			
Class distribution	<div style="display: flex; justify-content: space-around;"> <div style="text-align: center;"> <p>Ground truth</p> <table border="1"> <thead> <tr> <th>Class</th> <th>Count</th> </tr> </thead> <tbody> <tr><td>0</td><td>~330</td></tr> <tr><td>1</td><td>~771</td></tr> <tr><td>2</td><td>~1824</td></tr> <tr><td>3</td><td>~1681</td></tr> <tr><td>4</td><td>~360</td></tr> <tr><td>5</td><td>0</td></tr> </tbody> </table> </div> <div style="text-align: center;"> <p>RF</p> <table border="1"> <thead> <tr> <th>Class</th> <th>Count</th> </tr> </thead> <tbody> <tr><td>0</td><td>~330</td></tr> <tr><td>1</td><td>~1182</td></tr> <tr><td>2</td><td>~3224</td></tr> <tr><td>3</td><td>0</td></tr> <tr><td>4</td><td>0</td></tr> <tr><td>5</td><td>0</td></tr> </tbody> </table> </div> <div style="text-align: center;"> <p>Gaussian-SVC</p> <table border="1"> <thead> <tr> <th>Class</th> <th>Count</th> </tr> </thead> <tbody> <tr><td>0</td><td>~8</td></tr> <tr><td>1</td><td>~123</td></tr> <tr><td>2</td><td>~573</td></tr> <tr><td>3</td><td>~13</td></tr> <tr><td>4</td><td>~369</td></tr> <tr><td>5</td><td>0</td></tr> </tbody> </table> </div> <div style="text-align: center;"> <p>Linear-SVC</p> <table border="1"> <thead> <tr> <th>Class</th> <th>Count</th> </tr> </thead> <tbody> <tr><td>0</td><td>~194</td></tr> <tr><td>1</td><td>~611</td></tr> <tr><td>2</td><td>~1174</td></tr> <tr><td>3</td><td>~2011</td></tr> <tr><td>4</td><td>~366</td></tr> <tr><td>5</td><td>0</td></tr> </tbody> </table> </div> <div style="text-align: center;"> <p>LSTM</p> <table border="1"> <thead> <tr> <th>Class</th> <th>Count</th> </tr> </thead> <tbody> <tr><td>0</td><td>~245</td></tr> <tr><td>1</td><td>~885</td></tr> <tr><td>2</td><td>~1192</td></tr> <tr><td>3</td><td>~1669</td></tr> <tr><td>4</td><td>~366</td></tr> <tr><td>5</td><td>0</td></tr> </tbody> </table> </div> </div>	Class	Count	0	~330	1	~771	2	~1824	3	~1681	4	~360	5	0	Class	Count	0	~330	1	~1182	2	~3224	3	0	4	0	5	0	Class	Count	0	~8	1	~123	2	~573	3	~13	4	~369	5	0	Class	Count	0	~194	1	~611	2	~1174	3	~2011	4	~366	5	0	Class	Count	0	~245	1	~885	2	~1192	3	~1669	4	~366	5	0
Class	Count																																																																						
0	~330																																																																						
1	~771																																																																						
2	~1824																																																																						
3	~1681																																																																						
4	~360																																																																						
5	0																																																																						
Class	Count																																																																						
0	~330																																																																						
1	~1182																																																																						
2	~3224																																																																						
3	0																																																																						
4	0																																																																						
5	0																																																																						
Class	Count																																																																						
0	~8																																																																						
1	~123																																																																						
2	~573																																																																						
3	~13																																																																						
4	~369																																																																						
5	0																																																																						
Class	Count																																																																						
0	~194																																																																						
1	~611																																																																						
2	~1174																																																																						
3	~2011																																																																						
4	~366																																																																						
5	0																																																																						
Class	Count																																																																						
0	~245																																																																						
1	~885																																																																						
2	~1192																																																																						
3	~1669																																																																						
4	~366																																																																						
5	0																																																																						

一方、Linear-SVC および LSTM は多少の誤差が生じるもの、正解分布と類似した分布を示した。本章では、Linear-SVC と LSTM の 2 つのモデルに焦点を当て、以降の分析および比較を行う。

3.3 前日入札計画と評価指標

2025 年度から需給調整市場の三次調整力②の継続時間が 30 分と変更され、スポット市場と同じ取引スロットになった。発電電力予測値 P_f から誤差吸収分の H_e を確保した $P_{f,rev}$ を 3.2 節で述べた入札意思決定により需給調整市場への入札可否を決定し、式(14)～(15)に示すように 2 つ市場の計画値を作成し計画収益 Π を求める(式(16))。

評価指標として、需給調整市場への入札可能回数 $BidC$ 、入札時の不足発生回数 $ImbC^-$ を用いる。需給調整市場への入札可能回数は、対象期間において、Headroom 確保後の計画値が正値となり、稀頻度リスク分析によるバイナリ係数 $k = 1$ の時、なおかつ需給調整市場価格がスポット市場を上回るスポット数の合計になる(式(17))。また、不足発生回数は、発電電力実測値が計画値を満たせないスポット数の合計になる(式(18))。

$$\begin{aligned} H_r(t) &= P_{f,rev}(t), \text{if } k = 1 \\ P_p(t) &= P_{f,rev}(t), \text{if } k = 0 \end{aligned} \quad (14)$$

$$P_{f,rev}(t) = P_f(t) - H_e(t), \forall t, P_{f,rev}(t) \geq 0 \quad (15)$$

$$\begin{aligned} \Pi &= \sum_{t=start}^{\text{end}} \frac{1}{2} \times U_s(t) \times P_{f,rev}(t) \times (1 - k) \\ &\quad + U_r(t) \times P_{f,rev}(t) \times k \end{aligned} \quad (16)$$

$$BidC = \sum_t t, \text{if } H_r(t) > 0 \& k = 1 \& U_r(t) > \frac{U_s(t)}{2} \quad (17)$$

$$ImbC^- = \sum_t t, \text{if } P_m(t) < H_r(t) \quad (18)$$

比較対象として、予測誤差吸収分の Headroom を設定しないで予測値 P_f のまま計画値としてスポット市場へ入札するケース、Headroom 設定のみ考慮したケース、Headroom 設定に加えて稀頻度リスク分析を取り入れたケースを比較して、太陽光発電所単体で需給調整市場への入札可否を評価する。

本研究では、2 つの市場のペナルティ制度が異なるため、スポット市場におけるインバランス清算を考慮しない。また、需給調整市場における発動指令時の実際のエネルギー供給に対する収益も考慮せず、計画段階における入札戦略による収益性に着目して比較・評価を行う。

4. 数値シミュレーション

4.1 使用したデータセット

本研究では、気象業務支援センターが提供する全球数值予報モデル GPV-GSM 日本域の地上面気象予報データ(最大 84 時間先)を用いた¹⁹⁾。使用した気象要素は、全天日射量 [kWh/m²]、風速 [m/s]、外気温 [°C] であり、これらの 1 時間値を取得し、全天日射量は SH 内挿法²⁰⁾、風速および外気温は線形補間を適用して電力市場の取引スロットに合わせて 30 分値に変換した。これらの気象データと物理モデル^{17), 21), 22)}を用いて、PV パネル設置条件として傾斜角 15°、方位角 0°(真南)を仮定し、設備容量 1kW における太陽光発電電力を推定し、発電電力予測値 P_f とした。初期時刻は、需給調整市場(入札締切り: 前日 14 時¹⁾およびスポット市場(入札締切り: 前日 10 時⁶⁾)の各市場における入札締切時刻に間に合うよう、前日の 9 時(日本標準時、JST)に設定し、データが取得可能となる直後からシミュレーションを実施することを想定した。一

方、気象庁が公開している気象観測地点における全天日射量 [kWh/m^2]、風速 [m/s]、外気温 [$^\circ\text{C}$] を入手し²³⁾、同様に内挿処理を施して物理モデルを用いて発電電力を推定し、発電電力実測値(相当) P_m とした。対象地点は茨城県つくば市館野(140.125°E, 36.057°N)とし、対象期間は 2020 年 1 月 1 日から 3 年間とし、最初の 2 年間をモデル構築に、残りの 1 年間をモデル検証に使用した。なお、対象時間帯は、太陽光発電が確実に得られる 9 時から 15 時(19~30 スポット)とした。設備容量は計算の便宜上 1kW とし、これは発電電力を設備容量で正規化したことと同様になる。また、晴天指数について GPV-GSM による全天日射量予測値と気象庁の全天日射量観測値(実測値)を用いて算出した。

4.2 シナリオ設定

本研究では、日射量の予測誤差を 5 クラスに分類した結果をもとに、需給調整市場への入札可否を判断するための 3 つのシナリオを設定し、それぞれの入札戦略について比較検討を行った。

Scenario 1: 「過大予測」と「極端な過大予測」のクラス(Class 4 と 5)に分類される場合、需給調整市場へ入札せず、スポット市場へ入札する。(保守的)

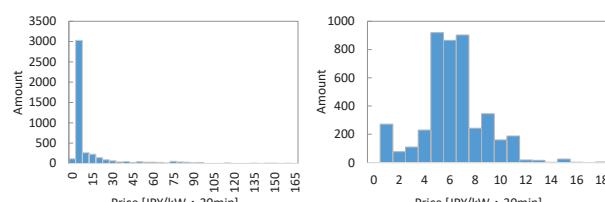
Scenario 2: 「極端な過大予測」(Class 5)に分類される場合、需給調整市場へ入札せず、スポット市場へ入札する。

Scenario 3: 「極端な過小予測」(Class 1)に分類される場合、不足が発生する可能性が低く、調整力価値をより生み出すために、予測誤差吸収分の Headroom を設定せず予測値をそのまま計画値として需給調整市場へ入札する。

Scenario 1 と 2 は Headroom 設定に加え、さらなるリスクヘッジを考慮して入札可否を決定するケースであり、Scenario 3 はリスクヘッジよりも、調整力価値の創出を重視する大胆な戦略である。

4.3 電力市場価格

本研究では、市場価格の予測値を用いることが望ましいが、提案手法における Headroom 設定アルゴリズムおよび入札意思決定手法を評価するため、市場価格予測に関するリスクを排除し、実績値を用いて検証を行った。需給調整市場価格は電力需給調整力取引所(EPRX)¹⁾の三次調整力②の電源属性別平均落札価格を使用し、スポット市場価格は日本卸電力取引所(JEPX)⁶⁾の前日スポット市場価格を使用した。需給調整市場は 2021 年度に開設され数年しか経過していないため、市場が可能な限り活発に動いたと



(a) Balancing market.

(b) Spot market.

Fig. 5 2024 market price distribution.

Linear-SVC					LSTM						
True Labels	1	2	3	4	5	True Labels	1	2	3	4	5
1	54	64	24	177	11	1	22	65	96	121	26
2	41	178	118	362	75	2	43	147	219	294	71
3	14	125	786	325	81	3	56	251	400	534	90
4	61	217	237	1023	157	4	110	372	425	630	158
5	24	27	21	136	42	5	14	51	68	96	21

Fig. 6 Confusion matrix for 5 classes.

		Scenario 1 Linear-SVC		Scenario 1 LSTM	
True Labels	0	TP	FN	TP	FN
		FP	TN	FP	TN
True Labels	1	1031	1358	905	1040
	1	42	208	21	229

		Scenario 2 Linear-SVC		Scenario 2 LSTM	
True Labels	0	TP	FN	TP	FN
		FP	TN	FP	TN
True Labels	1	324	42	3806	21
	1	345	208	3785	229

Fig. 7 Bid decision.

Table 4 Assessment of bidding decision performance under Scenarios 1 and 2.

	Scenario 1		Scenario 2	
	Linear-SVC	LSTM	Linear-SVC	LSTM
Accuracy	0.631	0.503	0.879	0.869
Precision	0.568	0.443	0.115	0.057
Risk	0.134	0.237	0.047	0.052

きの価格を反映するため、対象期間に限定せず、直近の 2024 年から 1 年間の価格データを使用した。価格選定地点は、対象地点と合わせて東京エリアの調整力平均落札価格とスポット価格を用いた。Fig. 5 に 2024 年 2 つ市場価格の分布を示す。年間対象スポット 4380 (365×12) のうち、需給調整市場の価格がスポット市場を上回る回数が 1386 回であった。

5. 結果および考察

Headroom 設定では、累積確率 $\mu = 1.0$ の時、すなわち過去の最大予測誤差を基に構築された多項式曲面 f_{py} を用いて、検証期間の発電電力予測値と晴天指数予測値を説明変数として H_e を算出した。

稀頻度リスク分析による意思決定では、Fig. 6 に 5 つのクラスの混同行列を示し、Fig. 7 に Scenario 1 と 2 にお

ける入札意思決定に関する混同行列を示す。混同行列において正解値を青系とし、それ以外を赤系で示す。また、それぞれ数値が大きい場合に濃い色で示す。Fig. 7では、クラス0は過大予測と判別し需給調整市場へ「入札しない」ことを、クラス1は「入札する」ことを表す。Table 4では、入札意思決定の混同行列を *Accuracy*(正解率), *Precision*(適合率), *Risk*(リスク指標)の3つの指標に基づいて比較・評価した。

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (19)$$

本研究の入札可否の意思決定モデルは、稀頻度で発生する過大予測に対して需給調整市場へ「入札しない」クラスを正確に判別することを目的とするため、TP(true positive)は、真のクラスが「入札しない」であり、かつ予測結果としても正しく「入札しない」と分類されたクラスと定義した。一方、TN(true negative)は、真のクラスが「入札する」であり、予測結果としても正しく「入札する」と分類されたクラスと定義した。また、FP(false positive)は、真値としては「入札する」クラスであるにもかかわらず、「入札しない」と誤分類されたクラス、FN(false negative)は、真値としては「入札しない」クラスであるにもかかわらず、「入札する」と誤分類されたクラスを示す。

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (20)$$

$$\text{Risk} = \frac{\text{FN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (21)$$

*Accuracy*は、TPとTNが全サンプルに対して正しく分類された割合を表し、値が大きいほどモデル精度が高いことを示す。全サンプルに対してClass 5の比率が小さいため、TNが非常に大きくなり Scenario 2では*Accuracy*が過大に評価された。

*Precision*は、「入札しない」と判断されたもののうち、正しく「入札しない」と判断された割合を表し、値が大きいほど高精度な判別ができたことを表す。Scenario 2では、「入札しない」と分類された中に誤分類が多く含まれているため、*Precision*は著しく低下している。

FPは、機会損失が増えることで不足発生リスクはない一方、FNは、実際の調整力不足が生じるリスクが高い。以上のリスク観点から、*Risk*は、リスクを増加させるFNが全サンプルで占める割合を評価する指標であり、値が小さいほど良いモデルであるといえる。以上の分析を踏まえ、Scenario 1のLinear-SVCモデルが他のシナリオ・モデルと比較して、正解率・適合率・リスクのバランスが比較的良好であると考えられる。

Table 5では、以下の3つのケースについて、需給調整

市場における年間入札可能回数、年間不足発生回数、および年間計画収益(2つ市場へ入札時はトータル計画収益)の結果を示す。

- ・比較対象として発電電力予測値 P_f そのままを計画値としてスポット市場へ入札するケース(Reference)
- ・提案手法の第一段階のHeadroom設定のみを考慮した $P_{f,rev}$ を計画値として需給調整市場へ入札するケース(Only Headroom)

- ・第一段階に加え第二段階の稀頻度リスク分析によるシナリオ毎に入札可否を決定したケース(Scenario 1~3)

Table 5の()内には、各ケースについて、価格動向に応じて柔軟に市場選択して価格が高い市場へ入札を行った場合の結果を示す。

比較対象ケースでは、計画段階での収益が最も高く見込まれる一方で、スポット数の過半が不足状態に陥っており、高額なインバランス清算の発生が予想される。これに対して、Headroom設定のみを考慮したケースでは、全対象期間にわたって入札が可能となり(欠損データの影響により4スポット分が除外された)、年間不足発生回数は194回まで低減された。

稀頻度リスク分析による各シナリオでは、過大予測が懸念されるスポットの入札を回避するため、Scenario 1では入札可能回数が減少したもの、不足発生回数はさらに低減された。Scenario 2では、入札可能回数が少しだけ減少したが、これに比べて不足発生回数はあまり削減できなかった。Scenario 3では、入札可能回数に変化は見られないものの、Headroom設定のみを考慮したケースと比較して不足発生回数が増加した。これは、極端な過小予測の検知が十分に機能しておらず、クラス分類精度の低下が前日計画に負の影響を与えている可能性を示唆している。

前日計画段階では、両市場の価格大小関係が把握可能であれば、市場の取引スロットが同じであるため、高価の市場に入札することより高い収益を得ることが期待される。Table 5(括弧内)より、全体的に入札可能回数が減少している一方、不足発生回数が大幅に減少していることが確認された。特に、Scenario 1のLinear-SVCモデルを用いた場合、年間42回まで低減することができた。また、収益面でも改善が見られて、太陽光発電所の需給調整市場への参入可能が示唆された。

Table 6に各ケースにおける月別の不足発生回数を示す。不足発生は中間期の3月～5月および9月の前後に集中しており、そのほかの月では概ね3回未満¹³⁾達成できていることが確認された。なかでも、いずれのケースにおいても4月は最も不足発生リスクが高く、リスク回避の視点からは、同月における需給調整市場への入札に対して特に慎重な対応が求められると考えられる。

Fig. 8は提案手法(Scenario 1のLinear-SVCモデル)に基づく需給調整市場における年間入札量の時系列推移を示しており、季節変動や市場動向に対する応動特性を確認することができた。

Table 5 Results: the case only considering the headroom setting case and the case based on rare-event risk analysis.

	Reference	Only Headroom	Scenario 1		Scenario 2		Scenario 3	
	P_f	$P_{f,rev}$	Linear-SVC for k	LSTM for k	Linear-SVC for k	LSTM for k	Linear-SVC for k	LSTM for k
Bid count for BM	4376*1	4376 (1385)*3	1987 (524)	2339 (745)	4010 (1226)	4011 (1241)	4376 (1385)	4376 (1385)
Shortage count for BM	2657*2		194 (83)	107 (42)	161 (49)	176 (68)	283 (70)	334 (144)
Total planned revenue [JPY/(kW · year)]	12,946	10,188 (18,637)	7,750 (9,780)	8,384 (10,032)	9,614 (12,365)	9,619 (12,51)	10,918 (19,344)	11,121 (19,545)
Remarks	Bid all in SM	Bid all in BM	Bid in BM & SM	Bid in BM & SM	Bid in BM & SM	Bid in BM & SM	Bid in BM & SM	Bid in BM & SM

*1 Bid count for SM *2 Shortage count for SM *3 The value in () indicates the bid for the higher-priced option.

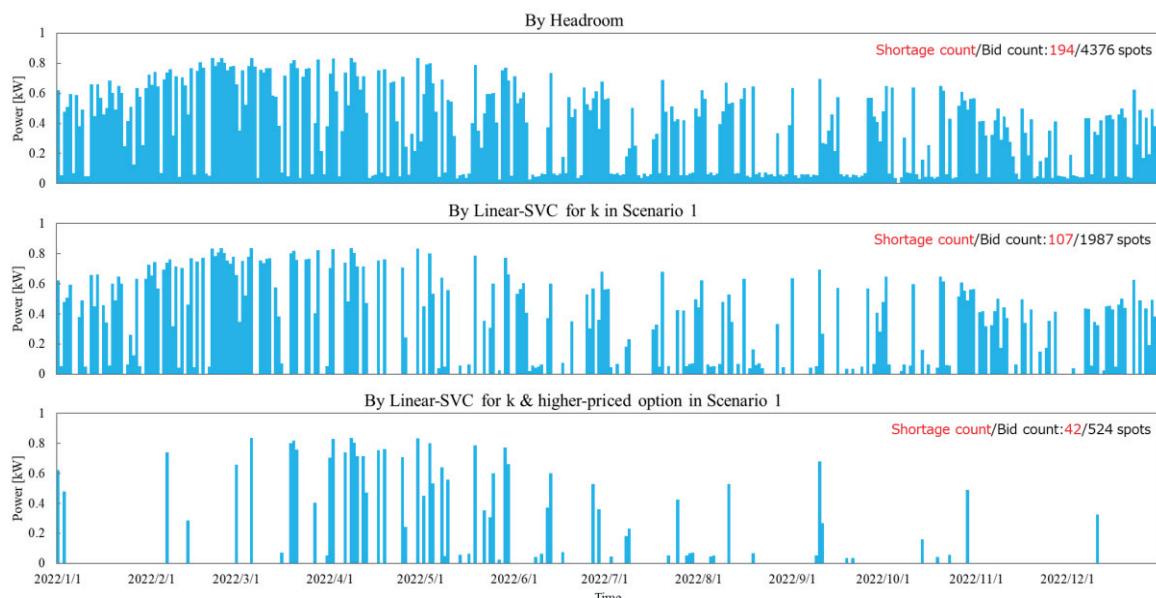


Fig. 8 Annual time series of bidding volume.

Table 6 Monthly shortage count for BM.
(Higher-priced option in 30-min intervals)

	Only Headroom	Scenario 1		Scenario 2		Scenario 3	
		P_f	Linear-SVC for k	LSTM for k	Linear-SVC for k	LSTM for k	Linear-SVC for k
Jan.	0	0	0	0	0	0	0
Feb.	2	2	0	2	2	2	3
Mar.	11	6	5	11	10	11	15
April	46	27	30	38	39	46	57
May	11	3	8	8	10	37	30
June	4	2	1	2	2	15	11
July	0	0	0	0	0	2	3
Aug.	2	2	1	2	1	9	3
Sept.	7	0	4	5	6	7	17
Oct.	0	0	0	0	0	0	5
Nov.	0	0	0	0	0	0	0
Dec.	0	0	0	0	0	0	0
Total	83	42	49	68	70	129	144

6. 結論と今後の課題

本研究では、太陽光発電所において蓄電池の導入や時間前市場からの調達などの追加リソースを用いることなく、需給調整市場への調整力供出の可能性について検討を行

った。

Headroom 設定のみを考慮したケースでは、全対象期間にわたって入札可能となり、年間入札可能回数 4376 回中、不足発生回数は 194 回であった。入札可否意思決定まで考慮すると、Scenario 1 の Linear-SVC モデルを適用することで、入札可能回数は 1987 回に減少したが、不足発生回数は 107 回まで抑制された。また、2 つ市場価格の大小関係が予測可能である前提のもとで、Scenario 1 の Linear-SVC モデルを用いた場合、入札可能回数 524 回に限定されるものの、年間不足発生回数を 42 回まで低減することができた。この結果は、月別に見ると月 3 回未満を 9 ヶ月間達成しており、収益面でも改善が見られたことから、最も不足発生が多かった 4 月を除く期間においては、太陽光発電所の需給調整市場への参入可能があることが示唆された。

今後は、稀頻度リスク分析による過大予測の検出モデルの高精度化、過小予測に特化した検出モデルの構築が不可欠である。また、需給調整市場における収益最大化およびリスク最小化を図る上で、両市場の相対的な価格関係を高

精度に予測するモデルの開発も重要な課題と考えられる。

また、複数地点における予測誤差の慣らし効果を活用したHeadroom設定アルゴリズムや過積載による不足発生回数のさらなる低減モデルの構築も検討課題としてあげられる。

また、収益性の検討において、スポット市場におけるインバランス清算ならびに需給調整市場における確率的な発動指令に基づくエネルギー価値の収益を考慮した、実態に即したモデルの構築と、不足発生回数と収益性のバランスに関する検討が求められる。

謝辞

本研究は、NEDO「太陽光発電主力電源化推進技術開発/太陽光発電の長期安定電源化技術開発/系統影響緩和に資する技術課題の検討及び実証(太陽光発電による調整力創出技術の実証研究)」によるものである。

参考文献

- 1) 需給調整力取引所 (EPRX) : 需給調整市場の概要・商品要件, 2024年4月1日 第4版
[gaiyoushounin_ver.4_20240401.pdf](https://www.eprx.jp/gaiyoushounin_ver.4_20240401.pdf)
- 2) 経済産業省 : 需給調整市場ガイドライン, 2025年3月24日
https://www.enecho.meti.go.jp/category/electricity_and_gas/electric/summary/regulations/pdf/jyukyuchosei-gl.pdf
- 3) 経済産業省 資源エネルギー庁:再エネを日本の主力エネルギーに! 「FIP制度」が2022年4月スタート, 2021年8月3日記事
<https://www.enecho.meti.go.jp/about/special/johoteikyo/fip.html>
- 4) 経済産業省 資源エネルギー庁:再生可能エネルギー:FIT・FIP制度ガイドブック 2023年度版
https://www.enecho.meti.go.jp/category/saving_and_new/saiene/data/kaitori/2023_fit_fip_guidebook.pdf
- 5) 九州電力送配電ホームページ :
<https://www.kyuden.co.jp/td.html>
- 6) 日本鉄電力取引所 (JEPX) : <https://www.jepx.jp/>
- 7) J. Cui, B. Jie, X. Fang, T. Oozeki and Y. Ueda, "Absorption of PV Power Prediction Errors with Headroom Control by Statistical, Machine Learning and Combined Models," IEEJ Transactions on Power and Energy (TEEE B), Vol.19 No.2 (Dec. 2023).
- 8) J. Cui, X. Fang, T. Oozeki, and Y. Ueda: "Absorption of PV Power Prediction Errors with Headroom Control by variable importance-considering SVR model with different initial values", 40th European Photovoltaic Solar Energy Conference and Exhibition (EU PVSEC), Lisbon, Portugal, (Sept. 2023).
- 9) J. Cui, X. Fang, T. Taniguchi, T. Oozeki, and Y. Ueda: "Absorption of PV power prediction errors with headroom control by SVR model using parameters variation of different initial values," 34th International Photovoltaic Science and Engineering Conference (PVSEC34), Shenzhen, China, (Nov. 2023).
- 10) K. Itoi, J. Cui, T. Oozeki, and Y. Ueda: "Forecast error estimation of PV power plants based on deep reinforcement learning", 33rd International Photovoltaic Science and Engineering Conference (PVSEC33), Nagoya, Japan, Nov. 2022.
- 11) Y. Tu, X. Fang, J. Cui, and Y. Ueda, "Prediction of radiation forecast error range due to GPV surrounding cloud conditions and changes in radiation forecast," Journal of Japan Solar Energy Society, 2022 Conference Proc., 279-282 (Nov. 2022).
- 12) B. Jie, J. Cui, X. Fang, T. Oozeki and Y. Ueda, "Optimization Bidding Strategy on Day Ahead and Balancing Market of PV Generator Considering Battery Integration," IEEJ Transactions on Power and Energy (TEEE B), Vol.18 No.2, June 2023.
- 13) 第11回需給調整市場検討小委員会 資料3:「三次調整力②のアセスメント・ペナルティ等について」, 2019年4月.
- 14) Y. Yamagishi, K. Saji, I. Aoki, R. Tanikawa, and Y. Fujii, Accuracy Verification of Irradiation Forecast using Numerical Weather Prediction Data by Japan Meteorological Agency, IEEJ Transactions on Power and Energy (TEEE B in Japanese), 132 (4), 334-340 (2011).
- 15) H. Otake, K. Shimose, J. Fonseca Junior, T. Takashima, T. Oozeki, and Y. Yamada, "Evaluation of Forecast Errors of the Global Solar Irradiance Obtained from the Japan Meteorological Agency Global Spectral Model", IEEJ Transactions on Power and Energy (TEEE B in Japanese), 134 (6), 501-509 (2014).
- 16) T. Oozeki, T. Izawa, K. Otani, and K. Kurokawa, "An Estimation Method of Irradiation Data for Evaluating PV Systems", IEEJ Transactions on Power and Energy (TEEE B in Japanese), 125 (1), 118-126 (2005).
- 17) 日本太陽エネルギー学会 (JSES) : [改訂版] 新・太陽エネルギー利用ハンドブック, 2015.
- 18) H. Otake, F. Uno, T. Oozeki, and Y. Yamada, "The Latest Update of JMA Numerical Weather Prediction Models and its Solar Power Forecasting Errors", IEEJ Transactions on Power and Energy (TEEE B in Japanese), 138 (11), 881-892 (2018).
- 19) 気象業務支援センター:「全球数値予報モデル GPV-GSM (全球域・日本域)」
<http://www.jmbsc.or.jp/jp/online/file/f-online10100.html>
- 20) 糸井久瑞実, 屠雨陽, 崔錦丹, 植田謙, PV発電量評価に向けたGPV(GSM)日射量1時間値の補間手法, 令和5年電気学会全国大会講演論文集, 令和5年3月.
- 21) 植田謙, 大竹秀明, 太陽光発電出力の推定・予測技術, 電気学会誌, 137(4), 220-223 (2017).
- 22) 日本産業規格:「JIS C 8907 太陽光発電システムの発電電力量推定方法」(2005).
- 23) 気象庁 : <https://www.jma.go.jp/jma/index.html>