

実務的な運用制約における電力インバランス量の確率的予測

Probabilistic Forecasting of Electricity Imbalance Volume Under Realistic Operational Constraints

郭 嘉 軒 *・ 前 匡 鴻 *・ 松 橋 隆 治 *
Jiaxuan Guo Masahiro Mae Ryuji Matsuhashi

Abstract

Day-ahead imbalance-volume forecasts in renewable-rich power systems need to describe not only the expected imbalance, but also the possible surplus and shortage tails. This paper focuses on Tokyo-area regional imbalance volume under a strict D-1 06:00 JST information constraint, before the JEPX spot-market deadline and the balancing-market bidding window. The proposed Weather Forecast Reliability Encoder with Tail Calibration (WFRE-TC) framework combines a weekly multi-quantile XGBoost backbone with a weather-forecast reliability encoder and tail calibration. The encoder uses cut-off-safe weather forecast revisions, historical forecast-error memory, and weather summaries available before the forecast origin. On the one-year test period from 1 April 2025 to 31 March 2026, WFRE-TC improves the Continuous Ranked Probability Score proxy (CRPS proxy) and reduces the q10-based uncovered shortage ratio relative to weekly XGBoost. The resulting forecast provides an upstream probabilistic risk signal for operational awareness, reserve readiness, and battery energy storage system planning before day-ahead market decisions are finalized.

Key words: Electricity imbalance; Day-ahead forecasting; Quantile regression; Weather-reliability; Machine Learning

1. 序論

再生可能エネルギーの導入拡大により、電力需給運用では天候に起因する不確実性が増大している。特に太陽光発電や風力発電は、気象条件の変化に大きく依存するため、前日に計画された需給バランスと実運用時の需給状態との間にずれが生じやすい。このずれはインバランス量として現れ、送配電事業者による調整力の発動やインバランス精算を通じて、系統運用および市場参加者の事業リスクに影響を与える。特に、一般送配電事業者(TSO)にとっては、日前時点で不足側の尾部リスクを把握することが、調整力の必要量や発動リスクを見積もるための基礎情報となる。さらに、日本では2022年にインバランス料金制度が変更され、系統全体の余剰・不足の方向と市場参加者の行動インセンティブの関係がより重要になった¹⁾。一方で、日本の時間前市場はスポット市場に比べて取引量が少なく、流動性も限られるため、受渡し直前の市場取引だけで需給ずれを十分に調整できるとは限らない。したがって、インバランスを単に平均的な誤差として捉えるのではなく、不足側・余剰側の大きさと不確実性を同時に把握する必要がある。

日本市場を対象とした既往研究として、Jiang and Yamada²⁾は、日本の電力市場におけるインバランスシグナル予測を機械学習により分析している。同研究は、翌日のインバランス状態を余剰・不足の二値分類問題として定式

化し、LightGBMやrandom forestとSHAPによる感度分析を用いて、過去のインバランス、気象変数、地域間の気象差、市場変数、時間パターンがシグナル予測に影響することを示している。この研究は、2022年以降の日本市場を明示的に扱う点で本論文と近い。一方で、方向シグナルだけでは、各30分コマでどの程度の不足量または余剰量が生じ得るかまでは表せない。

海外では、欧州の需給調整・インバランス市場を中心に、インバランス量やインバランス価格の予測研究が進められている。Browell and Gilbert³⁾は、インバランス価格・量予測の機会と課題を整理し、インバランス関連予測が他の短期電力市場予測に比べて発展途上であることを指摘している。Botticauら⁴⁾はsingle-price imbalance settlementにおけるvery-short-term probabilistic forecastingを扱い、Toubeauら⁵⁾やVan Gompelら⁶⁾は、ニューラルネットワークを組み込んだ確率的インバランス予測を検討している。これらの研究は、点予測ではなく分布予測を用いる意義を示しているが、多くは欧州市場やvery-short-term/intradayの設定を対象としており、日本の電力市場とは異なる。

また、蓄電池や需要家側リソースを対象に、JEPXスポット市場と需給調整市場への参加を最適化する研究もある。Caiら⁷⁾は、需要家側リソースの協調入札戦略を扱い、価格予測だけでなく市場特性や調整力需要の充足性を考慮する必要性を示している。このような研究は、本論文のDownstreamに位置する応用先として重要である。しかし、入札・運用最適化の前提となるインバランス量そのものの

*東京大学大学院工学系研究科電気系工学専攻

〒113-8656 東京都文京区本郷 7-3-1

E-mail : guo@enesys.t.u-tokyo.ac.jp




図 1 予測の時間軸




図 2 モデルの全体像

確率分布を、日前に利用可能な情報の範囲でどの程度予測できるかは別の問題である。

以上の研究はいずれも本論文の前提となるが、扱う段階が異なる。日本市場の研究は主に余剰・不足の方向判定を扱い、海外の確率的インバランス予測は欧州市場または別の問題設定が中心である。特に、日本の日前市場タイムラインを前提に、有限な情報下で翌日のインバランス量分布を予測する研究はまだ限られている。これに対して本論文は、運用の前段に位置する予測問題として、日前市場の意思決定前に得られる情報だけを用い、翌日48コマのインバランス量を複数分位点として予測する手法を提案する。

本論文の貢献は次の通りである：

- 情報制約を満たす入力のみを用いたインバランス量分位点予測問題の定式化と特徴量構築
- 予測時点までに得られる気象予報の修正量、過去の予報誤差、観測気象要約から気象予報信頼性を推定し、その信頼性に応じて予測区間の幅と不足・余剰側の裾を条件付きに補正する Weather Forecast

Reliability Encoder with Tail Calibration (WFRE-TC)の提案

本論文は、入札、調整力調達、蓄電池運用などのタスクに向けて、日前時点での不足側リスクを識別する確率的リスク情報を提供する予測層として位置づける。以下では、第2節で問題設定と分位点予測の定義を述べ、第3節で特徴量構築、分位点予測backbone、およびWFRE-TCを説明する。第4節で評価設計を示し、第5節で予測結果を考察する。第6節で結論と今後の課題を述べる。

2. 問題設定

対象日はD、30分コマを $t = 1, \dots, 48$ とする。予測時点はD-1 06:00 JST に固定し、この時点で利用可能な気象予報、市場履歴、過去のインバランス量、系統状態、カレンダー情報を入力 $X_{D,t}$ とする。目的変数は対象時刻の実イン




図 3 データ前処理の手順

バランス量 $Y_{D,t}$ である。正の値は余剰側、負の値は不足側のインバランスを表す。

本論文では、一点の期待値ではなく、条件付き分位点 $\hat{q}_\tau(X_{D,t})$ を出力する。分位点とは、データを小さい順に並べたときに、ある割合のデータがその値以下となる境界値である。ここで τ は分位レベルであり q_τ は、同様の情報条件の下で、実績値のうち τ の割合がその値を下回るようなしきい値である。例えば $q_{0.10}$ は下側10%のしきい値、 $q_{0.50}$ は中央値、 $q_{0.90}$ は上側10%リスクを表すしきい値として解釈できる。

出力する分位点集合は

$$Q = \{0.01, 0.05, 0.10, 0.25, 0.50, 0.75, 0.90, 0.95, 0.99\} \quad (1)$$

とする。 $q_{0.10}$, $q_{0.05}$ は不足側の、 $q_{0.90}$, $q_{0.95}$ は余剰側を与える。したがって、本論文の予測対象は、予測時点における翌日インバランス量の分位数分布である。


3. 提案手法

提案手法の全体構成を図2に示す。本手法は、D-1 06:00時点で利用可能なデータのみから特徴量を構築し、翌日48コマのインバランス量の基本的な予測分布を推定する分位点回帰モデルと、その予測分布を気象予報信頼性に基づいて補正するWFRE-TCから構成される。すなわち、第一段階（Quantile Regression backbone）では情報制約を満たす特徴量から基礎となる分位点曲線を推定し、第二段階（WFRE + WFRE-TC）では気象予報誤差リスクや不足・余剰状態に応じて予測区間と分布の裾を補正する。


3.1 データ前処理と特徴量構築

本論文で用いるデータは、インバランス量・精算関連データ¹⁾、JEPX市場データ⁸⁾、JMA MSM数値気象予報⁹⁾、気象庁の実績気象データ¹⁰⁾、系統状態・再生可能エネルギー実績、カレンダー情報から構成される。これらのデータを共通時刻軸に揃え、対象日Dの各30分コマ特徴量を作成する。ただし、特徴量として用いることができるのは、D-1

1. Pinball loss



2. Single-slot quantiles



3. Full-day interval




図 4 分位点予測の学習と出力の流れ

06:00時点で観測または入手可能な情報に限定する。

気象予報については、D-2 12UTCのMSM予報を対象日の主予報として用い、D-2 00UTCの予報との差分から予報修正量の特徴量を作成する。気象特徴量は東京電力エリア周辺の10代表地点から抽出し、需要感応を表す気温特徴量、太陽光発電（PV）出力に関係する日射・雲量特徴量、沿岸・内陸の風況特徴量、降水特徴量などを構築する。10地点は、東京電力エリア周辺の需要中心、内陸気温、PV大量導入した地域、沿岸風況を代表するように選定した。さらに、気温特徴量には都県人口¹¹⁾に基づく需要側の重みを、日射・雲量特徴量には都県別PV¹²⁾導入容量に基づく重みを用いる。実績気象は対象日の入力としては用いず、以前の観測気象を要約したWFRE用特徴量としてのみ利用する。

市場・系統関連の変数についても、同様に情報時刻を確認する。JEPXの過去市場情報、過去のインバランスマン、精算関連指標、需給状態、再エネ実績などは、ラグ特徴量、移動平均量、または予測時点以前に切り出した時点情報として用いる。検証期間における重要度と感度分析に基づき、主モデルの入力として209個の特徴量を選択した。

3.2 Quantile Regression Backbone

第一段階では、予測時点の情報から翌日48コマの基礎分位点を推定する。本論文では

$$Q = \{0.01, 0.05, 0.10, 0.25, 0.50, 0.75, 0.90, 0.95, 0.99\} \quad (2)$$

の9個の分位レベルを対象とする。各分位レベル τ に対して、入力特徴量 x_t から分位点を出力する関数 f_τ を学習する。学習では、通常の二乗誤差ではなく、図 4の左図のように、次のPinball Lossを最小化する。

$$\hat{f}_\tau = \arg \min_f \sum_{i \in \mathcal{T}_k} \rho_\tau(y_i - f(x_i)) \quad (3)$$

$$\rho_\tau(u) = \begin{cases} \tau u, & u \geq 0, \\ (\tau - 1)u, & u < 0. \end{cases} \quad (4)$$

ここで $u = y_i - f(x_i)$ は実現値と予測分位点の差である。例えば $\tau = 0.10$ の場合、実現値が予測値を下回る誤差には大きい重みが与えられ、実現値が予測値を上回る誤差には小さい重みが与えられる。そのため、損失を最小化するモデルは平均値ではなく、「同様の情報条件の下で約10%の実現値が下回る境界値」を学習する。同様に、 $\tau =$

0.50は中央値、 $\tau = 0.90$ は上側90%分位点に対応する。

この学習を9個の分位レベルに対して行くと、図 4の中央図のように、一つの半時間コマに対して複数の分位点が得られる。低い分位点は不足側、高い分位点は余剰側のリスク範囲を表し、これらを並べることでその時刻の条件付き予測分布を表現できる。さらに、同じ処理を翌日の48コマすべてに適用すると、図 4の右図のように、時間方向に連続した予測区間が得られる。すなわち、本論文のバックボーンは、一点予測値ではなく、各時刻の分位点集合

$$\hat{q}_{\tau,t}^{\text{base}} = f_{\tau,k}(X_{D,t}), \quad \tau \in Q \quad (5)$$

を出力する。

主モデルでは、週次再学習型のXGBoostを用いる。予測週 $\mathcal{W}_k$ ごとに、その週より前のデータ $\mathcal{T}_k$ のみを用いて、各 $\tau \in Q$ に対するGradient Boosting木モデル $f_{\tau,k}$ を個別に学習する。

これら9個の分位点を並べることで、翌日48コマに対する基礎的な予測分布を構成する。XGBoostを主モデルとするのは、第5節で示すように、WFRE-TCと組み合わせた場合に、予測分布全体の精度、Coverageと不足側リスクの抑制のバランスが最も良かったためである。比較モデルとして用いるLightGBM、MLP、TSMixerも、同じ特徴量集合と同じ分位点集合に基づいて学習する。

3.3 WFRE Encoder, WFRE-TC

第二段階では、Weather Forecast Reliability Encoder with Tail Calibration (WFRE-TC)により、基礎分位点曲線を気象予報信頼性に応じて補正する。WFREはインバランスマンを直接予測するモデルではなく、気象予報誤差リスクを表すスコアを推定するサポートモデルである。入力 z_t には、予報修正量、予報全体の傾向、過去同時刻の予報誤差履歴、および D-1 06:00 以前の観測気象要約を用いる。WFREはLightGBMの回帰ヘッドとして実装し、正規化された信頼性スコア

$$r_t = g(z_t), \quad r_t \in [0,1] \quad (6)$$

を出力する。 r_t が大きいほど、対応する時刻の気象予報が不安定であることを表す。

WFRE-TCでは、この学習されたスコアに加えて、予報修正量と過去予報誤差から作る区間幅スコア w_t を用いる。 $x_{c,t}$ を気象不確実性成分、 s_c を検証データにおける経験的

表 1 WFRE-TC の主なパラメータ数値

パラメータ	値
β	0.18
r_0^-/r_0^+	0.25/0.50
p_0^-/p_0^+	0.70/0.60
w_0	0.22
α^-/α^+	0.75/0.24
$a_{.01}, a_{.05}, a_{.10}$	1.65, 1.10, 0.70
$a_{.90}, a_{.95}, a_{.99}$	0.70, 1.10, 1.65

90%点とすると、

$$w_t = \frac{1}{|C_w|} \sum_{c \in C_w} \min\left(\frac{|x_{c,t}|}{s_c + \epsilon}, 3\right) \quad (7)$$

と定義する。ここで C_w には、重み付き気温、太陽光発電の導入容量に重み付き日射、地域平均風速、降水域割合に関する予報修正量と過去予報誤差を含める。 w_t は一般的な気象不確実性に応じて予測区間を広げる役割を持つ。

まず、基礎分位点曲線の q10-q90 幅を $W_t = \hat{q}_{0.90,t}^{\text{base}} - \hat{q}_{0.10,t}^{\text{base}}$ とし、分位点を

$$\tilde{q}_{\tau,t} = \hat{q}_{\tau,t}^{\text{base}} + s(\tau)\beta w_t |0.5 - \tau| W_t \quad (8)$$

により補正する。ここで $s(\tau) = -1$ は $\tau < 0.5$ の場合、 $s(\tau) = 1$ は $\tau > 0.5$ の場合、 $s(0.5) = 0$ であり、検証期間で選択された β は 0.18 である。この補正は気象不確実性が高いときに分布の上下幅を広げる。

次に、不足側・余剰側の裾補正を行う。不足日スコア p_t^{short} と余剰日スコア p_t^{surplus} は、D-1 06:00 以前の集約特徴量から、対象日に少なくとも一つ不足または余剰コマが生じるかを学習した日単位の分類である。これらは半時間ごとの発生確率ではなく、裾補正を起動するためのゲートとして用いる。下側・上側ゲートを

$$G_t^- = \mathbf{1}\{p_t^{\text{short}} \geq p_0^-, r_t^- \geq r_0^-, w_t \geq w_0\}, \quad (9)$$

$$G_t^+ = \mathbf{1}\{p_t^{\text{surplus}} \geq p_0^+, r_t^+ \geq r_0^+, w_t \geq w_0\}. \quad (10)$$

と定義する。ゲートが開いた場合にのみ、 $q_{0.01}$, $q_{0.05}$, $q_{0.10}$ を下方に、 $q_{0.90}$, $q_{0.95}$, $q_{0.99}$ を上方に移動する。裾の移動量は、基礎分位点曲線の下の幅 $L_t = \hat{q}_{0.50,t}^{\text{base}} - \hat{q}_{0.10,t}^{\text{base}}$ および上側幅 $U_t = \hat{q}_{0.90,t}^{\text{base}} - \hat{q}_{0.50,t}^{\text{base}}$ に比例させる。 e_t^- と e_t^+ は、しきい値を超えた WFRE スコアの超過分を [0,1] に正規化したものである。

$$\Delta_t^- = \alpha^- G_t^- L_t (0.25 + 0.75 e_t^-) (0.35 + 0.65 w_t), \quad (11)$$

$$\Delta_t^+ = \alpha^+ G_t^+ U_t (0.25 + 0.75 e_t^+) (0.35 + 0.65 w_t). \quad (12)$$

最終的に、下側分位点は $\tilde{q}_{\tau,t} - \alpha_{\tau} \Delta_t^-$ 、上側分位点は $\tilde{q}_{\tau,t} + \alpha_{\tau} \Delta_t^+$ として補正する。ここで、 β は区間幅拡張の強さ、 r_0 , p_0 , w_0 は各ゲートのしきい値、 α は裾補正の強度、 α_{τ} は分位点ごとの裾重みを表す。具体的な値を表 2 に示す。これらは検証期間のみで選択した。補正後は分位点の単調性を保つために単調化を行う。

4. 評価設計

評価では、2022年6月18日から2024年12月31日までをト

レーニング期間 (Training Set)、2025年1月1日から2025年3月31日までを検証期間 (Validation Set)、2025年4月1日から2026年3月31日までを評価期間 (Test Set) とした。検証期間には、特徴量選択、モデル選択、および WFRE-TC のしきい値・パラメータ選択にのみ用いる。評価期間ではこれらを固定し、共通の有効サンプルに対して各モデルを比較する。

4.1 評価指標

評価指標は、予測分布全体の適合度、予測区間の信頼性、および不足側リスクの見逃しを区別して設計する。

CRPS proxy (Continuous Ranked Probability Score proxy) は複数分位点に対する平均 Pinball Loss であり、予測分布全体の効果を評価する。

$$\text{CRPS}_Q = \frac{1}{|Q|} \sum_{\tau \in Q} \rho_{\tau}(y - \hat{q}_{\tau}). \quad (13)$$

また、q10-q90 coverage (被覆率) は 80% 予測区間が実績値を含む割合であり、区間幅はその平均幅である。ただし、被覆率は区間を広げるだけでも上昇するため、被覆率と区間幅は同時に評価する必要がある。

不足側の評価には Uncovered Shortage Ratio (未被覆不足率) を用いる。実際の不足量を $S_t = \max(0, -y_t)$ 、q10 に基づく不足側予備量を $R_t = \max(0, -\hat{q}_{0.10,t})$ とすると、未被覆不足量は $\max(0, S_t - R_t)$ である。これを検証期間の実現不足量で割ることで、どの程度の不足量が q10 で覆われなかったかを表す比率を得る。

$$\text{Uncovered Shortage Ratio} = \frac{\sum_t \max(0, S_t - R_t)}{\sum_t S_t}. \quad (14)$$

余剰側の非被覆率 (Uncovered Surplus Ratio) も併せて評価するが、本論文では需給調整や予備力準備に関わる運用リスクとして、不足側のを主要な実用指標として扱う。

4.2 比較対象

比較は二つの部分行う。Quantile regression モデルの違いを確認するため、LightGBM^[13]、MLP、TSMixer^[14]、XGBoost^[15] に同じ WFRE-TC 補正を適用した結果を比較する。これにより、提案する補正層が特定の予測モデルだけに依存するものではないかを確認する。

さらに、XGBoost を基礎分位点モデルとした場合について、TC なし、Global quantile shift、WFRE-TC を比較する。Global quantile shift は検証期間の残差に基づいて各分位点を一律に補正するものである。これと比較することで、WFRE-TC の改善が単なる全体的な保守化ではなく、気象予報信頼性と不足・余剰状態に応じた条件付き補正によるものかを検証する。

表 2 Backbone 別の性能比較

Backbone + TC	CRPS proxy ↓	q10-q90 coverage ↑	Width (MW)	Uncovered shortage ratio ↓
LightGBM + WFRE-TC	107034	0.621	801	0.482
MLP + WFRE-TC	103856	0.778	1220	0.302
TSMixer + WFRE-TC	104826	0.764	1203	0.323
XGBoost + WFRE-TC	102030	0.824	1379	0.236

表 3 TC 手法別の性能比較

XGBoost pipeline	CRPS proxy ↓	q10-q90 coverage ↑	Width (MW)	Uncovered shortage ratio ↓
TC	105114	0.675	911	0.448
Global quantile shift	102698	0.799	1191	0.355
WFRE-TC	102030	0.824	1379	0.236

5. 結果と考察

5.1 Backbone 別の性能比較

表 2に, WFRE-TCを異なる分位点回帰モデルに適用した結果を示す。各モデルでは, 同じ特徴量集合と同じ分位点集合を用い, WFRE-TCのパラメータはそれぞれ検証期間で選択した。結果として, XGBoostを基礎モデルとしたWFRE-TCが, 予測全体のバランスにおいて最も良い結果を示した。

5.2 XGBoost における Tail Calibration 手法の比較

表 3 に, XGBoost を基礎分位点モデルとした場合の補正手法の比較を示す。補正なしのXGBoostは区間幅が狭く, q10-q90 coverage (被覆率) とUncovered Shortage Ratioに課題がある。Global quantile shiftは, 検証期間に基づいて分位点を補正することで被覆率を改善するが, 現在時刻の気象予報信頼性を考慮しない。これに対してWFRE-TCは, 気象予報誤差リスクと不足・余剰状態に応じて, 区間幅と分布の裾を条件付きに補正する。

5.3 WFRE-TC のメカニズム例

図 5に, WFRE-TC のメカニズムを確認するための事例を示す。この図はモデル選択には用いておらず, 表3の結果を補足するものである。

上段は気象予報信頼性が高い日の例であり, tail gateは48コマ中0コマで閉じている。この場合, WFRE-TCは下側・上側の裾を大きく補正せず, 過度な保守化を避けている。

一方, 下段は気象リスクが高い日の例であり, tail gateは48コマ中42コマで開いている。破線はTC前のq10とq90を表し, 青色の帯はWFRE-TC後の予測区間を表す。緑色の点は, 補正前には下側分位点で覆えなかった不足がWFRE-TCによって覆われたコマである。この日では5コマがrescued slotsとなり, q10-q90 coverageは約1607 MWから1899MWに拡大した。

5.4 感度分析

WFRE-TCの不足側補正に関わる4つのパラメータについて, 一つずつ値を変え, 他の値を固定して評価した。対象

としたのは, WFRE下側スコアしきい値 r_0^- , 不足状態しきい値 p_0^{short} , 気象由来の区間幅スコアしきい値 w_0 , 下側補正強度 α^- である。

設定では, uncovered shortage ratioは0.236, 平均q10-q90区間幅は1379 MWであった。 p_0^{short} を0.70から0.55に下げると, 下側ゲートが開きやすくなり, uncovered shortage ratioは0.223まで低減したが, 区間幅は1417 MWまで広がった。一方, p_0^{short} を0.85まで上げると, 区間幅は1352 MWまで狭くなるが, uncovered shortage ratioは0.252まで増加した。 α^- についても同様に, 0.75から1.05に強めると uncovered shortage ratioは0.231に低下する一方, 区間幅は1395 MWまで広がった。

これに対して, r_0^- と w_0 の周辺では結果の変化は比較的小さかった。特に $w_0 = 0.18$ から0.26の範囲では, uncovered shortage ratioとCRPS proxy はほとんど変化しなかった。したがって, 採用設定は特定の値だけで性能が急に良くなる不安定な設定ではなく, 補正を強めれば uncovered shortage ratioは下がるが区間幅やCRPS proxyが悪化しやすい, という連続的なトレードオフがある。

6. 結論

本論文では, 日本の日前市場タイミングを考慮し, 市場締切前に利用可能な情報のみを用いて, 東京エリアの翌日48コマのインバランス量を分位点として予測する手法を提案した。分位点予測により, 一点予測では捉えにくい不足側・余剰側のリスク幅を表現し, 日前段階で利用可能な予測分布を構成した。

提案する手法は, 基礎分位点曲線の推定と, 気象予報信頼性に基づく分布補正を分離する。気象リスクが高いと判断される場合に予測区間の裾を補正することで, 実データ評価では, 予測分布の精度, 区間の被覆と幅, uncovered shortage ratioのバランスを改善することを確認した。

今後は, 用途に応じてq10-q90, q05-q95, q01-q99など参照する分位点範囲を選択し, 価格, 発動確率, 蓄電池の充




図5 WFRE-TCの作動メカニズム例

電状態、劣化費用を含む入札・調整力調達・蓄電池運用モデルと接続することが課題である。また、他エリアへの適用可能性についても追加検証が必要である。

参考文献

- Electricity and Gas Market Surveillance Commission (EMSC), METI. Regarding the imbalance price system (インバランス料金制度等について). Technical report, Ministry of Economy, Trade and Industry (METI), Japan, 2022. URL: https://www.egc.meti.go.jp/info/public/pdf/2022_0117001c.pdf.
- Jiang, Kaiyao, and Yuji Yamada. "A Comprehensive Analysis of Imbalance Signal Prediction in the Japanese Electricity Market Using Machine Learning Techniques." *Energies* 18.11 (2025): 2680.
- Browell, Jethro, and Ciaran Gilbert. "Predicting electricity imbalance prices and volumes: Capabilities and opportunities." *Energies* 15.10 (2022): 3645.
- Botticau, Jérémie, et al. "Very-short-term probabilistic forecasting for a risk-aware participation in the single price imbalance settlement." *IEEE Transactions on Power Systems* 35.2 (2019): 1218-1230.
- Toubeau, Jean-François, et al. "Interpretable probabilistic forecasting of imbalances in renewable-dominated electricity systems." *IEEE Transactions on Sustainable Energy* 13.2 (2021): 1267-1277.
- Van Gompel, Jonas, Bert Claessens, and Chris Develder. "Probabilistic forecasting of power system imbalance using neural network-based ensembles." *Applied Energy* 401 (2025): 126714.
- Cai, Sinan, Masahiro Mae, and Ryuji Matsushashi. "Cooperative Optimal Bidding Strategy for Demand-side Responses Participating in JEPX Spot Market and Replacement Reserve Market." *IEEE Transactions on Power and Energy* 146.3 (2026): 194-204.
- Japan Electric Power Exchange (JEPX). Electricity Trading Guide (卸電力取引ガイド), 2019. URL https://www.jepx.jp/electricpower/outline/pdf/Guide_2.00.pdf. Version 2.00.
- Japan Meteorological Agency. Numerical Weather Prediction Activities. <https://www.jmbc.or.jp/jp/online/file/f-online10200.html>, 2026. Accessed April 27, 2026.
- Japan Meteorological Agency. 過去の気象データ・ダウンロード. <https://www.data.jma.go.jp/risk/obsdl/index.php>, 2026. Accessed April 27, 2026.
- Statistics Bureau of Japan. 人口推計 (2023年(令和5年)10月1日現在), 2024. URL: <https://www.stat.go.jp/data/jinsui/2023np/index.html>. Accessed: 2026-04-27.
- Agency for Natural Resources and Energy. Electricity Survey Statistics: Number and Capacity of Power Plants by Prefecture. https://www.enecho.meti.go.jp/statistics/electric_power/ep002/results.html, 2024. Table 1-(2), prefectural number and capacity of power plants; accessed 2026-04-27.
- Ke, Guolin, et al. "Lightgbm: A highly efficient gradient boosting decision tree." *Advances in neural information processing systems* 30 (2017).
- Chen, Si-An, et al. "Tsmixer: An all-mlp architecture for time series forecasting." *arXiv preprint arXiv:2303.06053* (2023).
- Chen, Tianqi, and Carlos Guestrin. "Xgboost: A scalable tree boosting system." *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*. 2016.