

天気概況予報と天気別周期性トレンドに基づく太陽光発電事業者のための予測手法

松本 拓史 山田 雄二
筑波大学

(受理 2018 年 6 月 21 日; 再受理 2019 年 2 月 14 日)

和文概要 太陽光発電の導入が加速し、電力系統に与える影響が拡大している昨今、太陽光発電出力や関連する日射量予測のニーズが一層高まってきている。本研究では、日射量観測値を時間帯別・天気別に分けた場合に存在する滑らかな周期性トレンドに着目し、トレンドの推定値と気象庁の発表する天気概況予報を用いた日射量および太陽光発電出力の予測手法を提案する。まず、周期ダミー変数と天気概況実績値を説明変数とする一般化加法モデル (GAM) を構築し、晴、雨、曇などの天気概況シナリオに対する日射量、および太陽光発電出力の季節性トレンドを抽出する。さらに、実務等で用いられる天気概況の予測シナリオを、あたかもそのシナリオが実現するかのように直接代入する手法は、予報が外れる場合の確率が考慮されないため予測値がバイアスをもつ可能性を指摘した上で、天気概況予報に基づく各シナリオの実現確率 (条件付期待値) を多項ロジットモデルによって推定する。これらを、GAM の季節性トレンドの推定値と組み合わせることで、日射量と出力の予測値を算出する新たな予測モデルを構築する。また、実データを用いて、先行研究における予測手法、および予測シナリオを直接代入した手法と比較し、本研究で提案する手法の予測誤差低減化における優位性を検証する。

キーワード: エネルギー, データ解析, 予測

1. はじめに

太陽光発電の導入が急速に進められ、電力系統に与える影響が拡大している昨今、電気事業者にとっては、太陽光発電出力や関連する日射量予測のニーズが一層高まってきている。発電設備の大量導入が進むに従い、雲の通過等に由来する短周期の出力変動は平滑化される一方で、広域的な天気の変化がもたらす日々の出力変動は、著しく拡大を続けている。例えば、2017 年 4 月各日の 12 時から 13 時における国内電力需要に占める太陽光発電出力の割合は、最も低かった 4 月 11 日で 4 % に留まった一方、最も高かった 4 月 23 日では 37 % にまで到達した¹。電気事業者は、太陽光発電等の自然変動電源の出力予測誤差が損失リスクに直結する事業構造を持っているため、このような状況下では、損失リスク回避策としての予測精度の向上が重要な課題となっている²。本研究では、太陽光発電事業への新規参加が増加した近年の状況を踏まえ、公開情報のみを用いた実用性の高い日射量・太陽光発電出力の予測手法を提案する。

日射量・太陽光発電出力の予測に関する先行研究は、大きく 2 つに分類できる。1 つ目は一般的に広く公開されている天気予報値を用いたもの [3, 8, 11, 13, 14, 24, 25, 29, 31, 33, 34, 39], 2 つ目は、三次元数値気象モデルを用いて時空間的にきめ細かく日射量を予測したものであ

¹電力広域的運営推進機関「系統情報サービス」(<https://www.occto.or.jp/>) のデータを用いて算定している。なお、4 月 23 日のエリア別需要に占める太陽光発電出力割合は、四国エリアで 66 %, 九州エリアで 75 % を記録した。

²出力予測誤差が損失リスクに直結する理由については、第 2.2 節で後述する。

る。2つ目の例としては、利用データにGPV (Grid Point Value) と呼ばれるメッシュ毎の数値予報を用いるもの [5, 10, 16, 22, 32, 42, 43] や、物理法則に基づく数値気象シミュレーションから日射量を直接予測する手法を用いるもの [17, 19, 20, 38] などがある。しかし、これらの予測手法は、利用データが有償であることや、計算量が膨大であることなどの実用的な課題があるため、本論文では1つ目に分類されるような、公開されている天気予報に基づく予測手法を提案する。ただし、同種の先行研究において提案されてきた、ニューラルネットワーク、遺伝的アルゴリズム、時系列モデル等の手法は、複雑なアルゴリズムや煩雑な条件分け等の手順を要するなどの課題がある。そこで、本研究では、年次周期ダミー変数と天気概況実績値を説明変数とする一般化加法モデル (Generalized Additive Model; GAM[7]) を構築し、晴、雨、曇などの天気概況シナリオに対する日射量、および太陽光発電出力の季節性トレンドを抽出するといったアプローチを用いることで、比較的容易に実装可能な利便性の高い予測手法を提案する。また、実測値から構築した回帰式の説明変数に予報値を直接代入することは予測値がバイアスをもつことにつながるが、この点に留意している研究は見受けられない。そのため、本研究では、天気概況予報に基づく各シナリオの実現確率を多項ロジットモデル (Multinomial Logit Model; MNL[21]) によって別途推定し、これらを合成した新たな予測モデルを提案する。

本論文の構成は以下のとおりである。第2節では、日射量・太陽光発電出力予測に関する先行研究レビューを行うとともに、電気事業者における発電出力予測の必要性を明らかにする。第3節では、日射量・太陽光発電出力の提案予測手法を詳述するとともに、実データを用いて、先行研究における予測手法、および予測シナリオを直接代入した手法と比較し、本研究で提案する手法の予測誤差低減化における優位性を検証する。第4節では、まとめを述べる。

2. 日射量等予測に関する先行研究レビューと発電出力予測の必要性

本節では、主要結果を述べる前に、本研究の特徴と意義をより明確化するため、日射量・太陽光発電出力予測に関する先行研究レビューを行うとともに、電気事業者における発電出力予測の必要性について説明する。

2.1. 日射量・太陽光発電出力予測に関する先行研究レビュー

前述のとおり、日射量及び太陽光発電出力の予測に関しては、これまで様々な手法が提案されてきた。特に近年では、太陽光発電の大量導入に伴い世界各国で研究が進められており、利用データの種類や予測手法別に整理したサーベイ研究にもいくつかの報告がある [1, 18, 27]。これらの先行研究のうち、本研究と同じく天気予報に基づいた予測手法を提案しているものについて見ると、表1に示すとおり、線形回帰モデルやカテゴリー別の平均値を用いる簡便な手法から、ニューラルネットワーク等のパターン認識手法、遺伝的アルゴリズムによる近似解探索アプローチ、スイッチングカルマンフィルタ等の時系列予測に至るまで多様な手法が提案されてきている。

冒頭で述べたとおり、本研究の目的は、近年急増した太陽光発電の新規参加者が容易に扱えるような利便性・実用性の高い予測手法を提案することであるため、以下では、表1に示す先行研究のうち、複数の説明変数を用いて複雑なアルゴリズムや煩雑な条件分け等の手順を必要とするもの [3, 11, 13, 25, 28, 31, 34] を除き、一般的な天気予報のみを用いて比較的簡易に予測できる手法に焦点を当ててレビューを行う。これらの手法は、季節トレンドの扱い方に着目すると、次のような3つのアプローチに大別される。すなわち、(1) 直近数十日程

表 1: 天気予報を用いた日射量・太陽光発電予測の先行研究の概要

先行研究	[文献]	予測対象	手法	説明変数
織田ら (1997)	[25]	日射量	多段階ニューラルネット	天気 (晴・雨フラグ), 平均気圧, 気圧差, 晴天指数, 気温
工藤ら (2007)	[14]	日射量・発電出力	線形回帰モデル	天気 ※日射量等を大気外日射量で除算
嶋田ら (2007)	[33]	日射量	カテゴリー別平均値 (天気変化パターンを加味)	天気 (3 区分) ※月別に区分
Sharma. et al (2011)	[31]	発電出力	サポートベクターマシーン	気温, 露天温度, 風速等
細田ら (2012)	[8]	発電出力	スイッチングカルマンフィルタ	天気 (3 区分) ※直近過去 90 日
Detyniecki. et al (2012)	[3]	発電出力	ファジー決定木	天気 (48 区分)
山田ら (2012)	[39]	日射量・発電出力	灰色理論・ニューラルネットワーク	日射量, 気温 ※直近過去 12 日
中村ら (2013)	[24]	発電出力	カテゴリー別平均値 (日付幅内で重みを考慮)	天気 (4 区分), 雲量 ※45 日間の日付幅で区分 (日付幅は収束計算で決定)
川崎ら (2015)	[11]	日射量	遺伝的アルゴリズム	天気, 気温, 降水量, 風力
白上ら (2016)	[34]	日射量	パターンマッチング	天気 (3 区分), 降水量, 気温, 前後天気等
Kim. et al (2017)	[13]	発電出力	自己適応型時系列モデル	天気, 日射量, 気温
佐々木ら (2017)	[29]	発電出力	カテゴリー別平均値 (天候変化文字列を加味)	天気 (5 区分) ※月別に区分
Qing. et al (2018)	[28]	日射量	LSTM ネットワーク	天気, 気温, 露天温度, 湿度, 風速等

度のトレンドを外挿するもの [8, 39], (2) 一定期間の実測値から時期区分別のパターンに当てはめるもの [24, 29, 33], (3) 大気外日射量³で除算した日射量（太陽光発電出力）指数に対して線形回帰を行うもの [14] があるが、いずれの方法も次のような課題があると考えられる。まず、(1) については、サンプルサイズが小さいことによる信頼性の課題や、日射量・太陽光発電出力のトレンドの変化に起因する誤差が生じ得るといった課題がある。また、(2) については、サンプルサイズを確保するために時期区分を一定の長さで設ける必要性が生じるが、その長さに応じて期間内のトレンド変化が平準化されてしまうこと、時期区分の境目で誤差が大きくなることなどの課題がある。(3) については、確定的な季節性トレンドによって正規化した日射量指数を用いることで季節依存性を低減できるものの、天気毎の季節性トレンドの違いが反映できない⁴。（言い換えると、日射量指数に対する天気現象の効果の季節性が考慮できない）などの課題が挙げられる⁵。そこで、本研究では、日射量・太陽光発電出力が、時間帯別・天気別に分けた場合に年間を通して滑らかな季節性トレンドを持っていることに着目し、周期性ダミー変数と天気概況実績値を説明変数とする GAM を適用することにより、上記の課題の解決を図る。

さらに、天気概況の実測値から構築した回帰式の説明変数に予報値を直接代入することは、予報値がバイアスをもつ可能性があることに留意し、本研究では、天気概況予報に基づく各シナリオの実現確率を多項ロジットモデルによって別途推定し、これらを合成した新たな予測モデルを提案する。なお、ロジットモデルを同様の枠組みで用いることは、先行研究では見受けられないため、新たな試みであると考えられる。

また、太陽光発電出力の予測に際しては、天気概況予報値等から直接予測するものの他、日射量と太陽光発電出力量には一定の関係があることから、日射量予測値を用いて日射量と発電出力との相関式から予測する方法 [39] も提案されている。しかし、ここで用いられる日射量が太陽光パネルの傾斜面日射量ではなく、全天日射量の場合には、注意が必要である⁶。すなわち、太陽光発電出力は、パネルの傾斜面日射量にほぼ比例する [15] のであるが、傾斜面日射量は、全天日射量が同一であっても太陽の高度や方位角（時間帯や季節）によって変化する。このため、全天日射量のみによる太陽光発電出力の予測は、時点毎の入射角差に起因する誤差を含む可能性が考えられる。したがって、本研究における太陽光発電出力の予測は、全天日射量の予測を介さずに、天気概況と上述の周期性トレンドを用いて直接モデル化することとする（ゆえに、本研究で提案する日射量及び太陽光発電出力の予測手法は同型になることから、次節以降では、両者に共通する事項については、日射量を代表させて論じることとする）⁷。

以上をまとめると、本研究は、関連する既往研究と比較して次のような利点がある。

- 日射量等を時間帯別・天気別に分けた場合に存在する季節性トレンドを用いる点で、パターン認識等の複雑なアルゴリズムを用いた手法よりもモデルの構造が明快かつ解釈が容易であるため、実務において扱いやすいこと

³大気の散乱や吸収を受けない日射量であり、日時、緯度・経度を用いた数式によって理論的に算定される。

⁴天気別の季節性トレンドの違いは第 3.1 節で後述する。

⁵この他にも、指数化をより精緻に行う場合、大気透過率の季節・時刻依存のトレンド補正（太陽光発電出力の場合は、これに加えて水平面日射量をパネル傾斜面日射量に変換する補正）を別途考慮する必要があることなどが挙げられる。

⁶全天日射量とは、太陽からの直達日射量（水平面成分）と大気によって散乱された散乱日射量を合計したものの。

⁷なお、日射量についてはデータが気象庁から公開されているので検証可能であるが、太陽光発電については検証できるデータの量は少ない。

- サンプルサイズ確保の点に関しては、GAMを用いた平滑化スプライン関数の推定を行う（日毎に変化するトレンドに平滑化条件を課す）ことにより、頑健性を確保しながら欠損日の補完を行いつつ、効率的に季節性トレンドの抽出が可能となること
- 実測値の原系列にGAMを適用してモデル化を行うため、日射量や太陽光発電出力の変動要因となる様々な季節性トレンド（大気外日射量、大気透過率、太陽光パネル入射角に依存するトレンド差）を個別に考慮する必要性がないこと
- 実測値から構築した回帰式に天気予報値を代入するのではなく、天気予報に基づくシナリオの実現確率を多項ロジットによって別途推定し、これらを組み合わせた新たな手法を構築することで更なる予測誤差の低減化が図れること（第3.4節で検証）
- 予測に用いる説明変数は、日付・時刻データと天気概況値のみであるため、データの整形に要する手順が簡便であることに加え、条件分岐や収束計算等のアルゴリズムを新たに実装する必要がない点で、計算が容易であり利便性に優れていること

2.2. 電気事業者における発電出力予測の必要性

本節では、太陽光発電を保有または調達している特定の発電・小売電気事業者が、太陽光発電の出力予測誤差に応じて損失を負う事業構造を持っていることを示すことにより、前日以前において精度の高い出力予測を行うことの必要性を明確化する。図1に、各時間断面における発電事業者及び小売電気事業者の電源運用・調達の流れを模式的に示す。

まず、火力発電機等の代替電源を保有する発電事業者は、前日以前において、需要や太陽光発電出力の予測を行い、火力発電機等の必要起動台数や起動停止時刻を決定している。このため、例えば、予測誤差を大きめに評価すれば、発電コストを犠牲にしても火力発電機を多めに稼働させることになり、逆に誤差を小さく見積もった時には太陽光の発電量が予想を大きく下回ってしまうと需要を満たすだけの電力が供給できなくなる[40]。つまり、代替電源によって需給調整を行う発電事業者にとっての予測誤差は、不経済な電源運用を招く点で損失リスクに直結している。

また、代替電源を保有しない小売電気事業者も、同様の収益構造を持っている。小売事業者は、日々、需要・発電出力予測を行った上で翌日の需給計画を策定・提出し、それを達成させる義務（同時同量義務）を負っている。一部の特例制度を選択している小売事業者は、当日において、再生可能エネルギーの予測変動により需給計画からかい離した供給力（インバランス量）は、予見不可能でかつ価格変動リスクが大きいインバランス料金によって精算されることになるため、このような小売事業者にとっても出力予測誤差は、損失リスクに繋がっている⁸。

このように、太陽光発電を保有または調達している特定の発電・小売電気事業者は、太陽光発電出力の予測誤差に応じて損失を負う構造となっている。本論文の目的は、このような予測誤差損失リスクを回避するための、実用的かつ十分な精度の予測手法を開発することである。

⁸現行制度では、小売事業者が本文中に示すようなインバランスリスクを負わない特例制度を選択することも可能となっているが、需給バランスを一致させるインセンティブが十分に機能しておらず、再生可能エネルギーの予測変動に対する調整力コストの増加が課題となっていることから、現在、小売事業者にも一定の調整を行わせることを含め、当該制度の見直しに係る検討が進められている[12]。

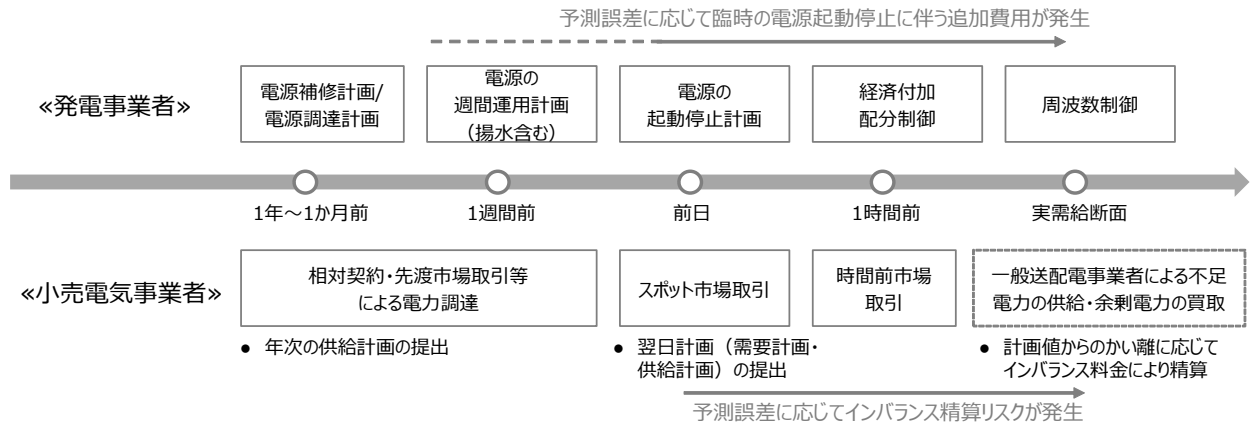


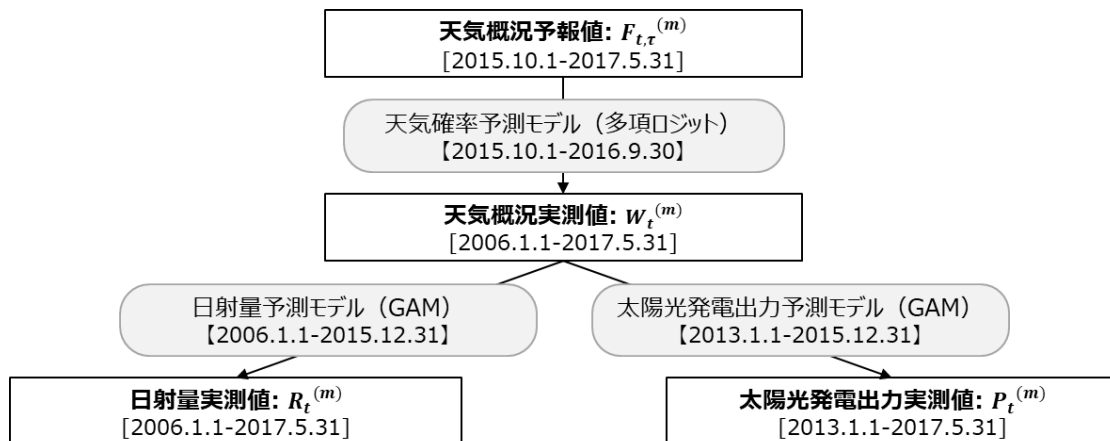
図 1: 各時間断面における発電事業者・小売電気事業者の電源運用・調達の流れ

3. 日射量・太陽光発電出力予測モデル

冒頭で、実務等で用いられる天気概況の予測シナリオを、あたかもそのシナリオが実現するかのように直接代入する手法は、予報が外れる場合の確率が考慮されないため予測値がバイアスをもつ可能性について述べたが、本節ではまず、具体的な例を用いてそのことを説明する。ここでは簡単のため、翌日の日射量の値が、天気が晴の場合に10、曇の場合に5、雨の場合に0であるものとしよう。このとき、翌日の天気予報が雨である場合に、日射量の予測値はどのように推定されるのであろうか。仮に、翌日の天気が雨という事象が確定的に実現するのであれば、日射量の予測値は0であるが、実際には、予測が外れて晴や曇りとなる確率が存在する。ここでは、このような確率、すなわち、翌日の予報が雨にも関わらず晴となる確率を0.1、曇りとなる確率を0.3、予報が当たって雨となる確率を0.6とする。これらの値は、前日予報に基づく翌日の天気の状態条件付確率であり、本例における翌日日射量の条件付期待値は $10 \times 0.1 + 5 \times 0.3 + 0 \times 0.6 = 2.5$ によって計算される。このような条件付期待値は、前日天気予報を所与とした際の翌日日射量予測値に対する最小分散不偏推定量を与え、分散最小化の意味で最適性条件を満たしている [37]。一方、前日予報をあたかも確定的なシナリオとみなして予測値を算出する手法が不偏推定量であるためには、各天気が予報される確率（例えば天気予報が晴となる確率）が実際の天気の確率（例えば実際の天気が晴となる確率）に等しいという条件が必要である。後程、実証分析で示すように、気象庁が発表する予報は、万が一の災害等を想定して、実際の天気よりも悪い方向の予報を出す傾向にある。このことは、日射量予測値を算出する際に予報値を直接代入する手法は、バイアスをもつ可能性を示唆する。この点については、第3.4.3節の数値実験で再度検証する。

本論文で提案する具体的なモデルとデータの関係は図2に示すとおりであり、それぞれ、以下の手順によってモデルを構築する。まず、GAMの手法を用いて、日射量・太陽光発電出力の時間帯別・天気概況実測値別の季節性トレンドを推定する（第3.1節）。つぎに、多項ロジットモデルを用いて、天気概況予報値が与えられた場合の、天気概況実測値の条件付確率分布を推定する（第3.2節）。これらのモデルの推定結果を合成することにより、天気概況予報値から日射量・太陽光発電出力の予測値を求める式が得られることになる（第3.3節）。なお、本節におけるモデル構築は、すべて図2に示すイン・サンプル期間の実データを用いて行い、第3.4節（予測精度の検証）で利用する日射量・太陽光発電出力の予測値には、同図中のアウト・オブ・サンプル期間における、モデルから得た算定値を用いることと

する⁹.



注: []内は取得データ期間を, 【】内はモデルの学習期間 (イン・サンプル) をそれぞれ表す.
各モデルの予測期間 (アウト・オブ・サンプル) は, いずれも2016.6.1-2017.5.31としている.
なお, 各データの文字表記は次節以降で説明する.

図 2: 利用データとモデルの関係

3.1. GAM による日射量・太陽光発電出力予測モデルの構築

日射量や太陽光発電出力は, 主に, 時刻によって決まる太陽高度 (入射角) と, 気象条件による影響を受けると考えられる. しかし, 太陽高度と気象条件が日射量等に与える効果は, 相加的な関係でないことには留意が必要である. すなわち, 例えば, 気象条件が日射量に及ぼす効果は, 太陽高度によって異なるため, 時間帯・季節を通じて一定ではないことが想定される. そこで, 日射量や太陽光発電出力を, 同一時間帯別・気象条件別にみた場合, それぞれ1年間の決まった周期性 (周期性トレンド) を持つことが考えられる. したがって, 本論文では, 日射量や太陽光発電出力を時間帯別・気象条件別に, 周期性トレンドを平滑化スプライン回帰 (付録 A 参照) によってモデル化するアプローチを採用する¹⁰. 具体的には, 第 t 日の時刻 m における個別時間日射量 $R_t^{(m)}$ 及び発電出力量 $P_t^{(m)}$, $m = 5, \dots, 19$ に対し, 以下の GAM を構築する¹¹.

$$R_t^{(m)} = \sum_{j=1}^4 f_j^{(m)} (Seasonal_t) I_{j,t}^{(m)} + \varepsilon_{r,t}^{(m)} \quad (3.1)$$

⁹本論文で用いる天気概況の実測値は, 気象庁のホームページ (<http://www.data.jma.go.jp/gmd/risk/obsdl/>) より, 予報値は, 気象庁の週間天気予報 (<http://www.jma.go.jp/jp/week/>) の過去の公表値を記録しているウェブサイト (<http://weather-transition.gger.jp/>) より, それぞれ取得している. また, 太陽光発電出力の実測値は, 所有者の許可を得て, 広島市内の自家用屋根置き発電設備 (多結晶型) のデータを利用している. なお, 多結晶型の発電モジュールは, 産業用設備の主流となっている単結晶型に比べて発電効率が低い.

¹⁰なお, 気象庁の発表しているデータには, 日照時間や降水量などがあるが, 雲の厚さが考慮されないことに加え, 実績値が0となる時間コマが多いことなどから扱いが難しいため, 本論文では天気概況実績値を GAM の説明変数とすることとした. また, 日照時間や降水量等の説明変数を天気概況と併用して説明力を上げる方法も考えられるが, 広く公表されている天気概況予報のみを用いた簡便な予測手法を提案する本論文においては, これらの変数を扱わないこととした.

¹¹時刻 m は, 日射量実測値または発電量実測値がある時間帯 (5時から19時) のみを対象としている.

$$P_t^{(m)} = \sum_{j=1}^4 g_j^{(m)} (Seasonal_t) I_{j,t}^{(m)} + \varepsilon_{p,t}^{(m)} \quad (3.2)$$

ただし、 $Seasonal_t$ は周期性トレンドを表す年次周期ダミー変数 ($= 1, \dots, 365$ (or 366)), j は天気概況を表す変数 (晴: 1, 雨: 2, 曇: 3, 雪: 4), $f_j^{(m)}$ 及び $g_j^{(m)}$ は GAM で推定する平滑化スプライン関数, $I_{j,t}^{(m)}$ は, 第 t 日, 時刻 m の天気概況実測値 $W_t^{(m)}$ が j のときに 1, それ以外で 0 となるダミー変数, $\varepsilon_{r,t}^{(m)}$ 及び $\varepsilon_{p,t}^{(m)}$ は平均値が 0 となる残差項を表す。

なお, 年次周期ダミーは, データの起点から 1 年周期で順番に 1 から 365 (割り当て期間に 2 月 29 日が含まれる場合は 366) を順次割り当てた変数であるが, ダミー変数の始点と終点においてスプライン関数が接続しないという問題に対応するため, 論文 [41] で提案された年次周期ダミー変数の割り当て手法を採用する (付録 B 参照)。

このようにして, 天気概況実績値別の日射量・太陽光発電出力の推定値が得られる。ここでは, 天気概況実績値別の日射量の推定結果を図 3 に示す (広島市, 12 時)¹²。図中の曲線のうち, 実線は, 横軸が与える年次周期ダミー変数に対する周期性トレンド関数 f の推定結果, 点線は 95 % 信頼区間を表す (なお, 図の縦軸は, 12 時のサンプル全体の平均値 $\mu^{(12)}$ からの差分を表示している)。ただし, 周期性トレンド f としては, ダミー変数の値が $1, 2, \dots, 365$ (366) の場合の平滑化スプライン関数を採用することに注意する。このようにして抽出した周期性関数においては, 晴及び曇の天気では夏至の 6 月末頃, 日射量のトレンドが最大化されることが分かる¹³。

3.2. 多項ロジットモデルによる天気確率予測モデルの構築

天気確率の予測モデルは, 天気概況予報値を説明変数, 天気概況実測値を応答変数として構成する。気象庁で公表している天気概況実測値は, 表 2 で定めるようなカテゴリー値となっているため, サンプルサイズ確保の観点から, これを晴, 曇, 雨, 雪の 4 つのカテゴリーに再構成する。なお, 天気概況の実測値は 3 時間ごとの間隔で公表されているため, 前後 1 時間は同一の天気で補完する。また, 気象庁で公表している天気概況予報値は, 日別に与えられ, 「曇昼前から雨」「曇昼過ぎから時々晴」のような文字列データとなっている。このうちの時間細分に係る用語は, 表 3 に示すように 3 時間ごとの時間帯別に定義されている。このため, 天気概況予報は, 時間別の値に分解することができる。

表 2: 気象庁の天気概況と再分類

気象庁	項番	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
	天気概況	快晴	晴	薄曇	曇	煙霧	砂塵嵐	地吹雪	霧	霧雨	雨	みぞれ	雪	あられ	ひょう	雷
変換後	天気分類	晴			曇				雨			雪		雨		
	j	1			2				3			4		3		

時間別の予報データは, すべて「 A 時々 B 一時 C 」という形の情報に集約されるため, 第 t 日の時刻 m における天気概況に対する τ 日前時点の予報値は, 次式に示すように, $\{A, B, C\}$

¹²本論文における統計分析は R3.3.3 (<https://cran.r-project.org/>) を使用しており, 平滑化スプライン関数はパッケージ mgcv に含まれる関数 gam() を, 多項ロジスティック回帰はパッケージ VGAM に含まれる関数 glm() を用いて行われている。

¹³雨天では, 晴及び曇の天気と異なり, 夏季の日射量が低くなる傾向がみられる。この理由としては, 夏季の雨天時は積乱雲等により雲の層が厚くなることなどが考えられる。

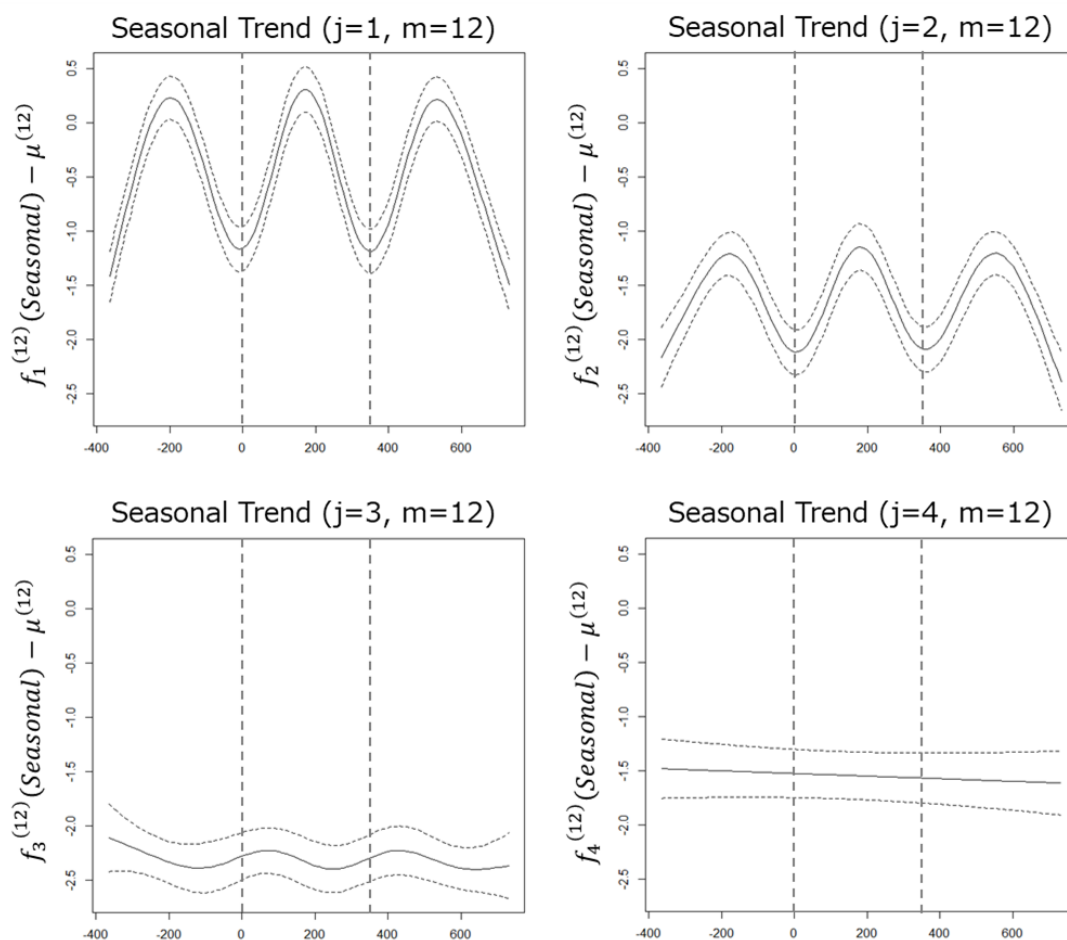


図 3: 天気別の周期性トレンド推定結果 (広島市日射量, 12 時)

表 3: 気象庁の天気概況予報に含まれる時間細分用語の定義

時刻	0	3	6	9	12	15	18	21	24
区分	1	2	3	4	5	6	7	8	
	未明	明け方	朝	昼前	昼過ぎ	夕方	夜のはじめ頃	夜遅く	
用語	午前中				午後				
				日中			夜		

の3つの名義変数に対応するダミー変数ベクトルで表現することができる（以下、便宜的に A を「主天気」、 B を「時々天気」、 C を「一時天気」と呼ぶこととする）。

$$\mathbf{F}_{t,\tau}^{(m)} = \left[A_1 \ A_2 \ A_3 \ A_4 \ B_0 \ B_1 \ B_2 \ B_3 \ B_4 \ C_0 \ C_3 \ C_4 \right]^T \quad (3.3)$$

ここで、 A_j, B_j, C_j は、それぞれ、天気概況予報の主天気、時々天気、一時天気に対応し、第 t 日の時刻 m における天気概況に対する τ 日前時点の予報値が $j \in \{0: \text{該当なし}, 1: \text{晴}, 2: \text{曇}, 3: \text{雨}, 4: \text{雪}\}$ の場合に 1、それ以外の場合に 0 となるダミー変数を表す¹⁴。なお、便宜的に、第 t 日の時刻 m における天気概況に対する τ 日前時点の予報値の主天気 $\tilde{F}_{t,\tau}^{(m)}$ を、同時点における主天気予報のカテゴリー値（すなわち、 $A_{j,t,\tau}^{(m)} = 1$ を満たす $j \in \{1, \dots, 4\}$ ）を返す値として、別途定義しておく。

以下では、多項ロジットモデルの手法を用いて、天気概況実測値の条件付確率予測モデルを構築する。多項ロジットモデルとは、目的変数がカテゴリー変数として与えられる場合に、その確率分布を推定するための統計手法である。もともとは、複数の選択肢に対して意思決定者が効用を最大化するような選択を行うといった効用最大化の理論に立脚して開発されたものであるが、これまでには、選択行動の予測のみならず、様々な分野での応用研究がなされている（詳細は付録 C を参照）。

まず、モデルを導出するにあたり、以下のような天気概況の実現確率を考える。ただし、本節において、以下では表記を簡潔にするため、予測ホライズン τ を省略して表記する。

$$\text{Prob} \left(W_t^{(m)} = j \right) = \text{Prob} \left(S_{jt}^{(m)} \geq S_{kt}^{(m)}, \forall k \neq j \right) \quad (3.4)$$

ここで、 $\text{Prob} \left(W_t^{(m)} = j \right)$ は、第 t 日の時刻 m における天気概況実測値 $W_t^{(m)}$ が j となる確率、 $S_{jt}^{(m)}$ は、第 t 日の時刻 m において実現する天気が j となる可能性を決定する変数（以下、天気可能性指標）を示す¹⁵。すなわち、天気概況毎に与えられた天気可能性指標のうち、それが最も高くなる天気概況が天気概況実測値として決定されることになる。この確率を推定するため、天気可能性指標を、天気概況予報値ベクトル $\mathbf{F}_t^{(m)}$ を用いた線形関数として、次式のように定式化する。

$$S_{jt}^{(m)} = \boldsymbol{\theta}_j^T \mathbf{F}_t^{(m)} + \varepsilon_{jt}^{(m)} \quad (3.5)$$

ただし、 $\boldsymbol{\theta}_j$ は推定パラメータのベクトル¹⁶、 $\varepsilon_{jt}^{(m)}$ は、観測不能な要素で天気可能性指標に影響を与える誤差項を示す。ここで、 $\boldsymbol{\theta}_j^T \mathbf{F}_t^{(m)}$ の項は天気可能性指標の観測可能な決定項（天気予報値によって確定する値）である。

(3.4) 式及び (3.5) 式から、以下のような式が導出できる。

$$\text{Prob} \left(W_t^{(m)} = j \right) = \text{Prob} \left(\boldsymbol{\theta}_j^T \mathbf{F}_t^{(m)} - \boldsymbol{\theta}_k^T \mathbf{F}_t^{(m)} \geq \varepsilon_{kt}^{(m)} - \varepsilon_{jt}^{(m)}, \forall k \neq j \right) \quad (3.6)$$

¹⁴ A は {晴, 曇, 雨, 雪} の 4 通り、 B は {該当なし, 晴, 曇, 雨, 雪} の 5 通り、 C は {該当なし, 雨, 雪} の 3 通りのいずれかに当てはまる。なお、(3.3) 式中の A_j, B_j, C_j は、日付 t 及び時刻 m 及び予測ホライズン τ に依存する変数であるが、これらの添字を省略して表示している。

¹⁵ 消費者の選択行動予測に用いられる場合、 S_{jn} は、個人 n が選択肢 j を選ぶ効用として定義される。

¹⁶ なお、 $\boldsymbol{\theta}_j$ は t に依存する値として設定する方法も考えられるが、本研究では、天気予報データが得られた期間が 2 年分にも満たないため、サンプルサイズ確保の観点と、影響度合いを総合的に勘案し、 $\boldsymbol{\theta}_j$ は t に依存しない値としている。

ここで、それぞれの誤差項 $\varepsilon_{jt}^{(m)}$ に、独立で同一なガンベル分布を仮定する¹⁷と、天気概況実測値が j となる確率は、次のような閉じた式によって定式化される [21].

$$Prob(W_t^{(m)} = j) = \frac{\exp(\theta_j^T F_t^{(m)})}{\sum_{j=1}^4 \exp(\theta_j^T F_t^{(m)})} \quad (3.7)$$

この式の自然対数を取り、サンプルについて足し合わせると対数尤度関数が得られ、それを θ_j について最大化すると、最尤推定値 $\hat{\theta}_j$ が得られる。

このようにして求められた天気概況の確率分布の予測結果を図4に示す。推定された天気の確率は、天気概況予報における主天気と同じになる確率が支配的となるが、一時や時々で予報された天気の影響も一定程度受けていることが分かる。また、天気予報が主天気のみで与えられた場合でも、他の天気になる確率が相当程度あること（例えば、天気予報が曇の時に曇以外になる場合は48%程度あることなど）も確認できる。




図 4: 多項ロジットモデルによる条件付確率分布の推定結果 (広島市)

3.3. GAMと多項ロジットモデルの合成による日射量・太陽光発電出力予測

本節では、第3.1節で定式化した、天気概況実測値を入力値とした日射量・発電出力の予測モデル (GAM) と、第3.2節で定式化した、天気概況予報値を入力値とした天気概況実測値の確率分布の予測モデル (多項ロジットモデル) を合成することにより、天気概況予報値

¹⁷ここで、より自然な正規分布を想定した場合には多項プロビットモデルとして定式化されるが、パラメータ推定が煩雑となることが知られている (付録C参照)。本論文では、取り扱いの容易性に鑑みて、多項選択モデルで広く用いられている、ガンベル分布を前提とした多項ロジットモデルを採用することとしている。天気確率分布を加味する場合としない場合とを比較する本論文においては、分布の想定の妥当性や結果の違いに関する分析までは取り扱わないこととする。

と時刻情報のみから日射量・太陽光発電出力を予測する式を構築する．すなわち，第 t 日，時刻 m の日射量 $R_t^{(m)}$ に対する， τ 日前時点の予測値 $\hat{R}_{t,\tau}^{(m)}$ は，GAM(3.1), (3.2) で推定された，第 t 日，時刻 m における天気概況の実測値 $W_t^{(m)}$ が j となる場合の日射量の周期トレンド $f_j^{(m)}$ ($Seasonal_t$) と，(3.7) 式で導出された，第 t 日，時刻 m の天気概況に係る予報値 $\mathbf{F}_{t,\tau}^{(m)}$ が与えられた場合に，実際の天気 $W_t^{(m)}$ が j となる確率を用いて，次のように書き表すことができる（太陽光発電出力予測値 $\hat{P}_{t,\tau}^{(m)}$ も同様）．

$$\hat{R}_{t,\tau}^{(m)} = \sum_{j=1}^4 f_j^{(m)}(Seasonal_t) \frac{\exp\left(\boldsymbol{\theta}_j^T \mathbf{F}_{t,\tau}^{(m)}\right)}{\sum_{j=1}^4 \exp\left(\boldsymbol{\theta}_j^T \mathbf{F}_{t,\tau}^{(m)}\right)} \quad (3.8)$$

$$\hat{P}_{t,\tau}^{(m)} = \sum_{j=1}^4 g_j^{(m)}(Seasonal_t) \frac{\exp\left(\boldsymbol{\theta}_j^T \mathbf{F}_{t,\tau}^{(m)}\right)}{\sum_{j=1}^4 \exp\left(\boldsymbol{\theta}_j^T \mathbf{F}_{t,\tau}^{(m)}\right)} \quad (3.9)$$

以上のように，日射量・発電出力の予測は，天気概況実測値を介した2つのモデルの合成によって構築したが，このような段階的な予測を行うことによる効果を後節にて検証するため，以下では天気概況予報値を GAM の式に直接入力する方法を考える．すなわち，第 t 日の時刻 m の天気に対する τ 日前の主天気予報値 $\tilde{F}_{t,\tau}^{(m)}$ が $j \in \{1: \text{晴}, 2: \text{曇}, 3: \text{雨}, 4: \text{雪}\}$ で与えられたとき，これをそのまま天気概況実測値から構築した GAM(3.1), (3.2) に代入することによって日射量・発電出力の予測値を得るという方法である．この場合の同時点における日射量・発電出力予測値をそれぞれ $\tilde{R}_{t,\tau}^{(m)}$, $\tilde{P}_{t,\tau}^{(m)}$ と表記すると，これらは，それぞれ以下のようなになる．

$$\tilde{R}_{t,\tau}^{(m)} \left(\tilde{F}_{t,\tau}^{(m)} = j \right) = f_j^{(m)}(Seasonal_t) \quad (3.10)$$

$$\tilde{P}_{t,\tau}^{(m)} \left(\tilde{F}_{t,\tau}^{(m)} = j \right) = g_j^{(m)}(Seasonal_t) \quad (3.11)$$

以下，便宜的に，後者の方法（式 (3.10), (3.11)）によって求めた予測を「予報値代入法」，前者の方法（式 (3.8), (3.9)）によって求めた予測を「予測確率加重平均法」と呼ぶことにする．

3.4. 予測モデルの誤差の検証

本節では，アウト・オブ・サンプル期間（2016年6月1日から2017年5月31日まで）における，日本国内9都市の日射量実測値，広島市内の太陽光発電システムの出力量実測値，天気概況予報値と前節の予測式から算定した日射量・太陽光発電出力の予測値を用いて，予測確率加重平均法の予測誤差を検証する．

検証に当たっては，第3.3節で導入した2つの方法による予測誤差を比較するほか，予測実施時点から予測対象時点までの期間（予測ホライズン）別の誤差の比較もあわせて行う．ここでは，第 t 日の時刻 m における日射量実測値 $R_t^{(m)}$ に対する τ 日前の2通りの予測値 $\tilde{R}_{t,\tau}^{(m)}$, $\hat{R}_{t,\tau}^{(m)}$ に対し，予測誤差の平均二乗誤差率（Percent Root Mean Square Error: PRMSE）を以下の式に基づいて計算することで，それぞれの予測精度について考察する¹⁸．発電出力

¹⁸第3節で，前日予報に基づく翌日日射量の条件付期待値は分散最小化の意味で最適性条件を満たしていると述べたことに即し，多項ロジットモデルを用いたことによる効果については分散最小化の観点から検証するため，ここでの予測誤差は分散に対応する平均二乗誤差率を用いて評価している．

予測についても同様に検証することとする。

$$PRMSE_{r,\tau} = \frac{\sqrt{\frac{1}{N} \sum_{t,m} (\hat{R}_{t,\tau}^{(m)} - R_t^{(m)})^2}}{\text{Mean}(R_t^{(m)})}, PR\tilde{M}SE_{r,\tau} = \frac{\sqrt{\frac{1}{N} \sum_{t,m} (\tilde{R}_{t,\tau}^{(m)} - R_t^{(m)})^2}}{\text{Mean}(R_t^{(m)})} \quad (3.12)$$

$$PRMSE_{p,\tau} = \frac{\sqrt{\frac{1}{N} \sum_{t,m} (\hat{P}_{t,\tau}^{(m)} - P_t^{(m)})^2}}{\text{Mean}(P_t^{(m)})}, PR\tilde{M}SE_{p,\tau} = \frac{\sqrt{\frac{1}{N} \sum_{t,m} (\tilde{P}_{t,\tau}^{(m)} - P_t^{(m)})^2}}{\text{Mean}(P_t^{(m)})} \quad (3.13)$$

なお、本節では参考文献から他の予測手法との誤差の比較を行うが、予測対象となる地点や時間範囲は同一ではないため、単純に予測精度の良悪をつけることはできない。

3.4.1. 日射量予測の誤差の検証

まず、日射量予測の誤差の検証を行う。日射量については、気象庁の公表データベースから、複数地点の実測値を得ることができるため、ここでは、札幌、仙台、東京、名古屋、富山、大阪、広島、高松、福岡各都市の9地点のデータを用いて誤差の検証を行った。図5におけるグレーの実線は、予報値代入法による予測の平均二乗誤差率 $PR\tilde{M}SE_{r,\tau}$ 、黒の実線は予測確率加重平均法による予測の平均二乗誤差率 $PRMSE_{r,\tau}$ を、それぞれ異なる τ について計算したものである¹⁹。なお、点線は、天気概況実測値をスプライン回帰モデルに代入して得られた予測値の誤差であり、天気予報の誤差を取り除いた日射量予測誤差と言い換えることができる。分析結果から、予測ホライズンが短くなればなるほど予測誤差が小さくなり、天気予報誤差除外後の予測誤差に近づいていることが読み取れる。また、いずれの地点または予測ホライズンにおいても、予測確率加重平均法の方が予報値代入法よりも誤差が小さくなっていることが分かる。

以下では、予測誤差の原因を切り分けて分析してみよう。例えば、広島市の日射量予測の平均二乗誤差について見ると、予測確率加重平均法の前日予測誤差は43%（1週間前予測では54%）であるのに対し、予報値代入法の前日予測誤差は45%（1週間前予測では61%）となっている。他方、実測値を代入した場合の誤差34%はGAMの当てはまりに起因するものであるから、予報値代入法の誤差45%からそれを差し引いた11%が、天気予報が外れたことによって生じた誤差となる。この天気予報由来の誤差11%のうち、予測値代入法と予測確率加重平均法の差異である2%が、天気予報の外れる確率をモデル化したことによって低減化できた誤差に該当する。同様に、1週間前予測では、天気予報由来の誤差20%のうち、予測確率加重平均法によって低減化できた分は7%と比較的高い値になっている。これは、予測ホライズンが長いほど、天気予報の外れる確率が大きくなることから、その確率を加味した予測確率加重平均法の優位性がより一層高くなるためと解釈することができる。

なお、先行研究における予測精度との比較を行うため、平均絶対誤差率（Percent Mean Absolute Error: PMAE）による評価もあわせて行った²⁰。提案予測手法による時間別日射量の前日予測のPMAEは、広島市で31.4%（名古屋市で30.0%）であり、天気、気温、降

¹⁹ただし、予測ホライズン $\tau = 1$ は前日朝時点の予測、 $\tau = 0$ は前日夜時点の予測の誤差を計算している

²⁰先行研究との比較においては、本稿と同様の予測条件で平均二乗誤差率を使ったものが見受けられないため、平均絶対誤差率を用いる。また、平均絶対誤差率PMAEは、次式により算定している。 $PMAE = \frac{1}{n} \sum_{i=1}^n \frac{|S_i - A_i|}{A}$ （ただし、 S_i は時点 i における日射量の予測値、 A_i は時点 i における日射量の実測値、 A は A_i の平均値を表す。）

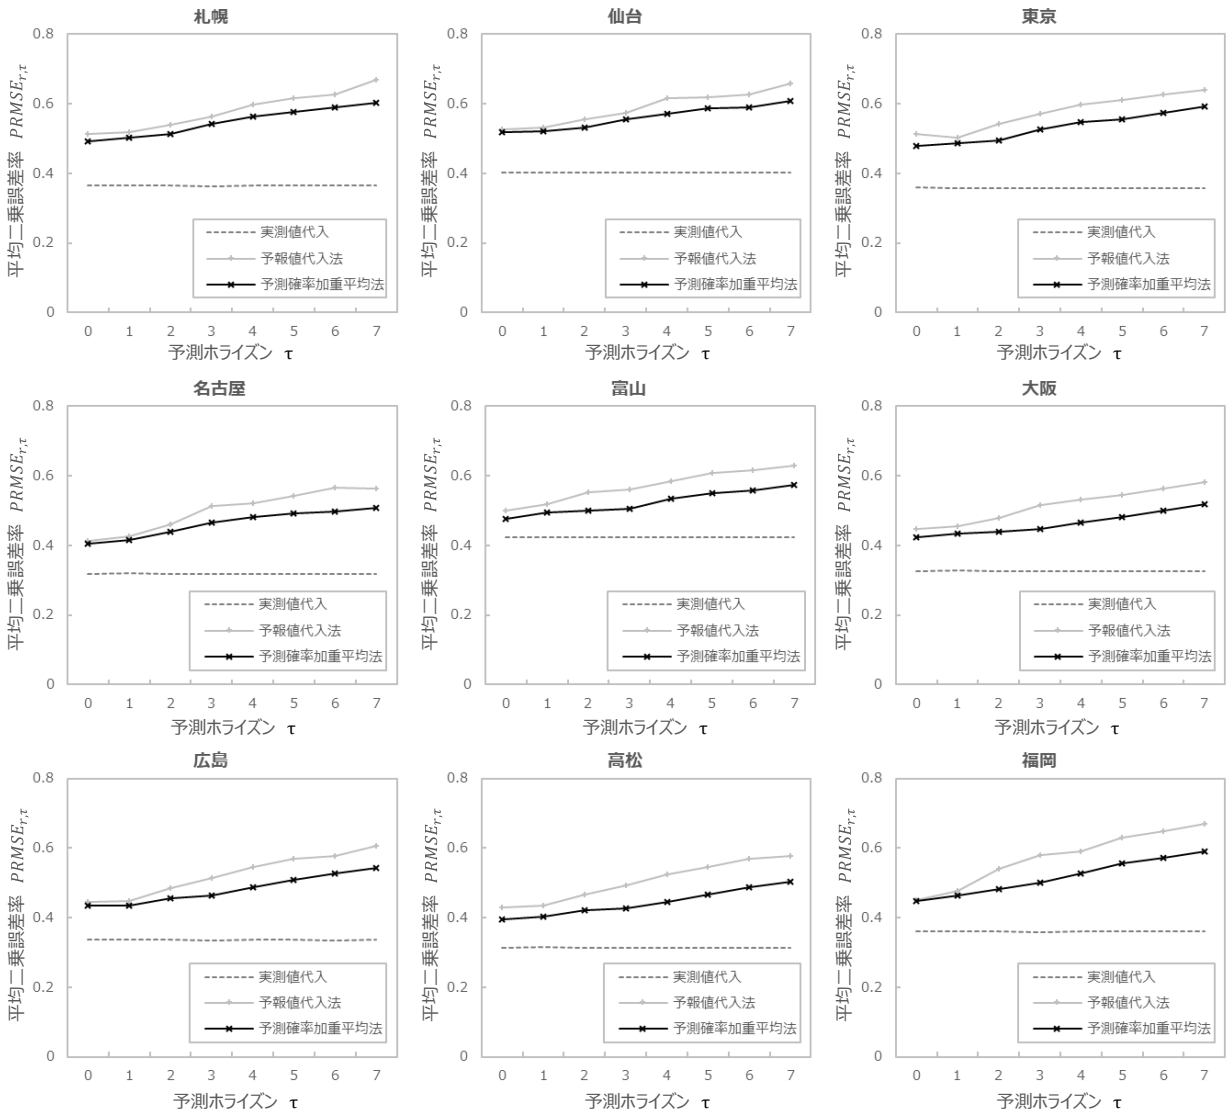


図 5: 日射量予測の平均二乗誤差率 (9 地点)

水量，風力から遺伝的アルゴリズムを用いて予測している文献 [11] の 31.5 %（福井県）や数値気象予報を用いた文献 [42] の 32.9 %（福井県）と比較してもエリア等の違いはあるものの，同等以下の予測誤差となっていることが確認できた。

3.4.2. 太陽光発電出力予測の誤差の検証

太陽光発電出力予測については，広島市のデータを用いて予測誤差の検証を行った．前節の図 5 と同様，図 6 におけるグレーの実線は，予報値代入法による予測の平均二乗誤差率 $PRMSE_{p,\tau}$ ，黒の実線は予測確率加重平均法による予測の平均二乗誤差率 $PRMSE_{p,\tau}$ ，点線は，天気概況実測値をスプライン回帰モデルに代入して得られた予測値の誤差を示している．分析結果から，太陽光発電出力予測についても，日射量予測同様，予測ホライズンが短くなればなるほど予測誤差が小さくなり，天気予報誤差除外後の予測誤差に近づいていることが読み取れる．また，いずれの予測ホライズンにおいても，予測確率加重平均法の方が予報値代入法よりも予測誤差が小さくなっていることが分かる．




図 6: 太陽光発電出力予測の平均二乗誤差率（広島市）

なお，提案予測手法による日積算発電量の前日予測の PMAE は，25.8 %（広島市）であり，天気の前報から翌日の日積算発電量を予測している文献 [14] の 26～39 %（愛知県 3～9 月），天気と雲量の情報から作成したカテゴリ別の平均値を用いて予測している文献 [24] の約 30～40 %（函館市 4～10 月）と比較しても，エリアや対象期間等の違いはあるものの，同等以下の予測誤差となっていることが確認できた²¹。

3.5. 予測手法別の誤差の違いに関する考察

前小節・前々小節で示したように，日射量・太陽光発電出力予測ともに，主天気予報値を直接 GAM の回帰式に代入する予測方法（予報値代入法）よりも，天気の条件付確率分布予測を別途考慮した方法（予測確率加重平均法）の方が，予測誤差が小さくなった．これに関しては，次のような理由が考えられる．すなわち，予測確率加重平均法では，多項ロジットモ

²¹類似研究における誤差の検証では，時間帯別発電量の精度検証に平均絶対誤差率を用いたものが見られなかったため，日積算発電量の平均絶対誤差率により比較している．

デルの活用により、主天気以外（時々天気・一時天気）の予測情報を加味することが可能となったことに加え、天気概況の実測値が予報値と異なる場合の確率も考慮したモデルとなっていることが挙げられる。

後者の点について言い換えると、予報値代入法は、予報どおりの天気の実現する確率を1に、その他を0にすることに対応するので、確率の推定の観点からは適切ではないということである。すなわち、例えば、翌日の天気が晴という天気予報が与えられた場合、予報値代入法では、天気が100%晴となる条件下での日射量等の期待値を算定していることになるが、本来起こり得るはずの曇や雨の確率（晴天時よりも低い日射量の実現する確率）が考慮されない点で、上方バイアスをもつことになる。また、同様に、天気予報が雨の場合における予報値代入法の日射量予測値は、下方バイアスをもつことになる。

以下では、このようなバイアスの発生傾向について、アウト・オブ・サンプルにおける予測誤差の実データを用いて考察する。ここでは、第3.4.1節で用いた広島市の日射量の前日予測の誤差 $\hat{R}_{t,1}^{(m)} - R_t^{(m)}$ について、雨天の予報が多くなる6月を例にとって説明する。実際に、2016年6月の予測誤差の平均値は、予測確率加重平均法が -0.036 (MJ/m^2) であったのに対して、予報値代入法では、 -0.121 (MJ/m^2) と拡大していたが、この理由は次のとおりである。この期間における天気予報（主天気）別の天気実績の発生頻度についてみると、図7に示すとおり、予報が晴だったときに実際の天気が悪化した時間帯の頻度が10%に留まったのに対し、予報が雨であったときに実際の天気が好転した時間帯の頻度は46%に上っていたことが確認される。これはすなわち、予報値代入法において、前段で述べたような、雨天予報の場合に生じる下方バイアスが、晴天予報の場合に生じる上方バイアスより強く影響したため、月全体で下方の予測誤差が拡大したものと考えられる。




図7: 天気予報別の天気実績発生頻度（広島市・2016年6月）

第3節の冒頭で述べたとおり、予報値代入法で得た予測値が不偏推定量であるためには、各天気が予報される確率が実際の天気の確率に等しいという条件が必要であるが、上記で示

したように、気象庁の予報が実際の天気よりも悪い方向に偏っている場合、予報値代入法による予測値はバイアスをもつことにつながる。

このように、予報値代入法がバイアスもつ可能性があることや、説明変数の確率分布を考慮したモデルの方が予測誤差低減化の点で優位であるという結果は、実務での活用局面において有益な示唆を与えているものと考えられる。

4. まとめ

本論文では、気象庁が定期的に発表している天気概況予報を用いた日射量・太陽光発電出力の予測手法を新たに提案し、その有効性を示した。また、実データを用いて、先行研究における予測手法、および予測シナリオを直接代入した手法と比較し、本研究で提案する予測確率加重平均法の予測誤差低減化における優位性を検証した。

本研究における予測のアプローチでは、時間帯別・天気別に分けた場合に存在する滑らかな季節性トレンドに着目したことにより、既往の手法のような複雑なアルゴリズムや煩雑なパターン分類の条件設定等を要することなく、簡便かつ十分な予測精度のモデル構築が可能となった。また、予測確率加重平均法は、実装や計算が比較的容易であることに加え、一般的に公開されている天気概況予報のみを用いている点において、近年増加した太陽光発電事業への新規参入者にとっては扱いやすく、実用性に優れていると考えられる。

さらに、実測値から構築した回帰式の説明変数に予報値を直接代入する方法によって得た予測値がバイアスをもち得ることに着目し、多項ロジットモデルを用いて説明変数の確率分布予測を別途行い、それらを組み合わせることによって予測誤差が低減することを示した研究は新しく、実運用の局面において有益な示唆を与えるものと考えられる。

謝辞

本研究は、JSPS 科研費基盤研究 (A) 課題番号 16H01833 「電力市場活性化のための需給予測型取引戦略とリアルタイム取引実験環境の構築」(研究代表者: 山田雄二) の助成を受けたものです。

参考文献

- [1] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca, F. Martinez-de-Pison and F. Antonanzas-Torres: Review of photovoltaic power forecasting. *Solar Energy*, **136** (2016), 78–111.
- [2] N. H. Augustin, L. Beevers and W. T. Sloan: Predicting river flows for future climates using an autoregressive multinomial logit model. *Water Resources Research*, **44-7** (2008).
- [3] M. Detyniecki, C. Marsala, A. Krishnan and M. Siegel: Weather-based solar energy prediction. *Proceedings of the 2012 IEEE Congress on Computational Intelligence* (Brisbane, Australia, 2012), 587–593.
- [4] W. Feller: *An Introduction To Probability Theory And Its Applications, Volume II* (Wiley, New York, 1971).
- [5] J. Fonseca, T. Oozeki, H. Ohtake, K. Shimose, T. Takashima and K. Ogimoto: Regional forecasts and smoothing effect of photovoltaic power generation in Japan: an approach with principal component analysis. *Renewable Energy*, **68** (2014), 403–413.

- [6] W. H. Greene: *Econometric Analysis* (Engelwood Cliffs, 1993).
- [7] T. Hastie and R. Tibshirani: *Generalized Additive Models* (Wiley Online Library, 1990).
- [8] 細田康彦, 滑川徹: スイッチングカルマンフィルタとクラスタリングによる短期太陽光発電予測. 自動制御連合講演会, (2012).
- [9] 加茂憲一, 嘉戸昭夫, 吉本敦: 離散データに対する回帰モデルによる冠雪害の解析. 統計数理, **61-2** (2013), 189–200.
- [10] 片岡裕次郎, 藤原耕二, 石原好之: 雲量の数値予報データを用いた日射量予測. 太陽/風力エネルギー講演論文集, (2009), 127–130.
- [11] 川崎章司, 田岡久雄, 長尾泰気, 大中奎佑: 遺伝的アルゴリズムによる日射量予測手法の開発. 電気学会論文誌 B, **135-2** (2015), 89–96.
- [12] 経済産業省: 効率的かつ安定的な電力需給バランスの確保に向けた制度環境整備について. 総合資源エネルギー調査会 電力・ガス事業分科会 電力・ガス基本政策小委員会 (第8回) 資料6, (2018).
- [13] J. Kim, D. Kim, W. Yoo, J. Lee and Y. B. Kim: Daily prediction of solar power generation based on weather forecast information in Korea. *IET Renewable Power Generation*, **11-10** (2017), 1268–1273.
- [14] 工藤満, 竹内章, 野崎洋介, 遠藤久仁, 角田二郎: エネルギーネットワークにおける太陽光発電予測技術. 電気学会論文誌 B, **127-7** (2007), 847–853.
- [15] 黒川浩助, 若松清司: 太陽光発電システム設計ガイドブック (オーム社, 1994).
- [16] E. Lorenz, J. Hurka, G. Karampela, D. Heinemann, H. G. Beyer and M. Schneider: Qualified Forecast of ensemble power production by spatially dispersed grid-connected PV systems. *Measurement*, (2007).
- [17] P. A. Jimenez, J. P. Hacker, J. Dudhia, S. E. Haupt, J. A. Ruiz-Arias, C. A. Gueymard, G. Thompson, T. Eidhammer and A. Deng: WRF-Solar: Description and clear-sky assessment of an augmented NWP model for solar power prediction. *Bulletin of the American Meteorological Society*, **97-7** (2016), 1249–1264.
- [18] 加藤丈佳: 太陽光発電の出力予測技術の開発動向. 電気学会誌, **137-2** (2017), 101–104.
- [19] E. Lorenz, J. Remund, S. C. Muller, W. Traunmuller, G. Steinmaurer, D. Pozo, J. A. Ruiz Arias, V. Lara Fanego, L. Ramirez and M. Gaston: Benchmarking of different approaches to forecast solar irradiance. *24th European photovoltaic solar energy conference* (Hamburg, Germany, 2009), 21–25.
- [20] P. Mathiesen, C. Collier and J. Kleissl: A high-resolution, cloud-assimilating numerical weather prediction model for solar irradiance forecasting. *Solar Energy*, **92** (2013), 47–61.
- [21] D. McFadden: Conditional logit analysis of qualitative choice Behavior. *Frontiers in Econometrics*, (1974), 105–142.
- [22] A. Mellit and A. M. Pavan: A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy. *Solar Energy*, **84-5** (2010), 807–821.
- [23] H. Mori and M. Okada: An ANN-based design for weather derivatives in consideration

- of meteorological uncertainties. *2016 IEEE Innovative Smart Grid Technologies-Asia* (2016), 1002-1007.
- [24] 中村勇太, 三島裕樹: 雲量情報を利用した太陽光発電の翌日出力予測. 平成 25 年電気学会全国大会論文集, (2013), 191-192.
- [25] 織田慎一郎, 見目喜重, 中川重康, 榊原建樹: 多段型ニューラルネットを用いた日射量予測. 電気学会論文誌 B, **117-8** (1997), 1146-1151.
- [26] 大政謙次, 恒川篤史, 町田聡: 気候変動によるアジア・太平洋地域の植生分布の将来予測に関する研究. 地球環境, **4-1** (1999), 105-113.
- [27] S. Pelland, J. Remund, J. Kleissl and T. Oozeki: Photovoltaic and solar forecasting: state of the art. *International Energy Agency, Report IEA PVPS T14-10* (2013).
- [28] X. Qing and Y. Niu: Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM. *Energy*, **148** (2018), 461-468.
- [29] 佐々木三郎, 福永青空, 太田豊: 天候数値化簡易手法による太陽光発電の地域別および全国大の発電量の解析. エネルギー・資源, **38-5** (2017), 1-9.
- [30] V. Shankar and F. Mannering: An exploratory multinomial logit analysis of single-vehicle motorcycle accident severity. *Journal of Safety Research*, **27-3** (1996), 183-194.
- [31] N. Sharma, P. Sharma, D. Irwin and P. Shenoy: Predicting solar generation from weather forecasts using machine learning. (2011), 528-533.
- [32] 嶋田進, 劉媛媛, 吉野純, 小林智尚, 和澤良彦: 気象モデルによる日射予測その 2: カルマンフィルターによる予測の高精度化. 太陽エネルギー, **39-3** (2013), 61-67.
- [33] 嶋田尊衛, 黒川浩助: 天気予報と天気変化パターンを用いた日射予測. 電気学会論文誌 B, **127-11** (2007), 1219-1225.
- [34] 白上敬一, 川原耕治: 類似日を探るパターンマッチングを用いた太陽光発電の日射量予測手法. 電気設備学会誌, **36-12** (2016), 875-880.
- [35] L. D. Smith and E. C. Lawrence: Forecasting losses on a liquidating long-term loan portfolio. *Journal of Banking and Finance*, **19-6** (1995), 959-985.
- [36] L. D. Smith, S. M. Sanchez and E. C. Lawrence: A comprehensive model for managing credit risk on home mortgage portfolios. *Decision Sciences*, **27-2** (1996), 291-317.
- [37] 竹内啓: 統計的予測の形式と方法 (特集: 予測). オペレーションズ・リサーチ: 経営の科学, **24-1** (1979), 31-34.
- [38] 田村英寿, 平口博丸, 西澤慶一: 太陽光発電のための日射量予測手法の開発 (その 2) 予測誤差の分析と精度改善法の検討. 電力中央研究所報告. 研究報告. 電力中央研究所地球工学研究所 編, (2014), 1-3.
- [39] 山田富士宏, 和澤良彦, 小林和弘, 三輪靖, 金納朋輝, 雪田和人, 後藤泰之, 一柳勝宏: 灰色理論とニューラルネットワークによる翌日の太陽光発電量予測手法. 電気学会論文誌 B, **134-6** (2014), 494-500.
- [40] 山田芳則: 太陽光発電における気象予測の重要性 (特集: 流体力学とエネルギー). ながれ: 日本流体力学会誌, **35-1** (2016), 7-11.
- [41] 山田雄二, 牧本直樹, 高嶋隆太: 一般化加法モデルを用いた JEPX 時間帯価格予測と入札量-価格関数の推定. JAFEE ジャーナル, **14** (2015), 8-39.

- [42] 山岸良雄, 佐治憲介, 青木功, 谷川亮一, 藤井康正: 気象庁数値気象予報データを用いた日射量予測手法の精度検証. 電気学会論文誌 B, **132-4** (2012), 334-340.
- [43] 與那篤史, 千住智信, 舟橋俊久, 関根秀臣: ニューラルネットワークを用いた太陽光発電設備の24時間先発電電力予測. 電気学会論文誌 B, **128-1** (2008), 33-40.

付録

A. 平滑化スプライン回帰手法

平滑化スプライン回帰は, 回帰関数の形を有限個のパラメータによって規定せずに推定するための統計技法であるノンパラメトリック回帰手法の一つである. いま, 次式のように系統変動 $h(x_n)$, 残差変動 ϵ_n という説明変数で被説明変数 y_n を表現した際に, ϵ_n の分散を最小にするような平滑化スプライン関数 f を考える.

$$y_n = \text{系統変動} + \text{残差変動} = h(x_n) + \epsilon_n, n = 1, \dots, N$$

$$\text{Mean}[\epsilon_n] = 0, \text{Var}[\epsilon_n] = \sigma^2$$

仮に, 通常の方法で h を推定しようとする, データ点を直接補完する曲線を得てしまう. そこで, 代替的に残差平方和に関数の平滑度を表すペナルティー項を加えたペナルティー付き残差平方和 (PRSS: Penaralized Residual Sum of Squares)

$$PRSS = \sum_{i=1}^n \{y_n - h(x_n)\}^2 + \lambda \int \{h''(x)\}^2 dx$$

を最小にする h をもとめ, これを推定関数とする. この最適化により, スプライン平滑化が自然に導かれる. λ は平滑化パラメータと呼ばれ, この値を大きく選ぶほど, 推定されるスプライン回帰係数は滑らかになる [7].

B. 年次周期ダミー変数の割り当て手法

年次周期ダミー (周期性ダミー) は, データの起点から1年周期で順番に1から365 (ダミー変数を割り当てる期間に2月29日が含まれる場合は366) を順次割り当てた変数である. このような周期性ダミー変数についての平滑化スプライン関数 $f_j^{(m)}, g_j^{(m)}$ は, GAM(3.1),(3.2) をそのまま適用した場合, ダミー変数の始点と終点においてスプライン関数が接続しないという問題がある. また, うるう年の2月29日を含む場合に周期が366日となり, 厳密には1年は同一周期でないことも考慮する必要がある.

本論文では, これらの課題に対応するため, 論文 [41] で提案された周期性トレンドの抽出手法を採用し, ダミー変数の始点と終点で平滑化スプライン関数 $f_j^{(m)}, g_j^{(m)}$ が近似的に接続するように, GAM(3.1),(3.2) を構築することを考える. 具体的な手順を以下に示す.

1. Y を被説明変数の標本ベクトル, $S^{(i)}$ を1年周期が下記 (a), (b), (c) で定義される $Seasonal_t^{(i)}$ ($i = 1, 2, 3$) の標本ベクトルとする.
 - (a) 2月29日を含む期間:
 $Seasonal_t^{(1)} = -365, \dots, 0, Seasonal_t^{(2)} = 1, \dots, 366, Seasonal_t^{(3)} = 366, \dots, 731$
 - (b) (a) の翌期:
 $Seasonal_t^{(1)} = -364, \dots, 0, Seasonal_t^{(2)} = 1, \dots, 365, Seasonal_t^{(3)} = 367, \dots, 731$

(c) 上記以外:

$$Seasonal_t^{(1)} = -364, \dots, 0, Seasonal_t^{(2)} = 1, \dots, 365, Seasonal_t^{(3)} = 366, \dots, 730$$

2. 次式で考えられる被説明変数及び説明変数の標本ベクトルの組について, GAM(3.1),(3.2)を当てはめる.

$$\begin{bmatrix} Y \\ Y \\ Y \end{bmatrix}, \begin{bmatrix} S^{(1)} \\ S^{(2)} \\ S^{(3)} \end{bmatrix}$$

3. $Seasonal_t^{(2)} = 1, \dots, 365$ (366) の場合のスプライン関数を周期関数として採用する.

C. 多項ロジットモデル (多項ロジスティック回帰)

多項ロジットモデルは, もともとは, 複数の離散的かつ悉皆的な選択肢に対して意思決定者が効用を最大化するような選択を行うという効用最大化の理論に立脚しており, マーケティング, 心理学, 経済学, 交通計画などの様々な分野において研究が行われてきた. 現在では, 消費者の選択行動の予測のみならず, 企業の信用リスクや自然現象の予測などにも応用されている. 例えば, 融資が取り得る状態を正常支払, 延滞, 破たん等に分類し, その間の状態遷移確率を推定したもの [35, 36], 単車事故による段階別の重傷度の確率を, 環境要因, 道路状況, 運転態度等から推定したもの [30], 気温と降水量の気候条件から将来の植生分布を予測したもの [26], 気象要因や地形要因等から, 森林の冠雪害の形態の確率を予測したもの [9], 気温と降水量の実測値から, 階級別の河川流量の確率分布を予測したもの [1] などがある.

なお, 類似の確率的多項選択モデルとして, (3.6) 式における誤差項の分布に正規分布を仮定した多項プロビットモデルがあるが, 自然な仮定を置いている反面, 選択確率を表す式に積分形が残るオープンフォームであるため, パラメータ推定は煩雑になる. 他方, 多項ロジットモデルは, 積分形のないクローズドフォームを導く分布形となるため, モデルが取り扱いやすく, 解釈面でも優れているため, 実務において今日広く一般的に利用されている [6].

松本拓史
 筑波大学
 ビジネス科学研究科
 〒112-0012 東京都文京区大塚 3-29-1
 E-mail: s1745014@s.tsukuba.ac.jp

ABSTRACT

**PREDICTION METHOD FOR SOLAR POWER BUSINESS BASED ON
FORECASTED GENERAL WEATHER CONDITIONS AND PERIODIC
TRENDS BY WEATHER**

Takuji Matsumoto Yuji Yamada
University of Tsukuba

With the introduction of photovoltaics rapidly accelerating and its influence on the electric power system expanding, there is a growing demand for the prediction of solar power output and solar radiation. In this paper, we present a method to predict solar radiation and solar power output using an estimated trend and general weather forecasts reported by the national meteorological agency, taking particular note of a smooth periodic trend identified when dividing the measured value of solar radiation by the hourly time zone and weather. First, by constructing a generalized additive model (GAM) in which the periodic dummy variable and actual general weather conditions are used as explanatory variables, we extract the seasonal trends of solar radiation and solar power output for different general weather scenarios, such as sunny, rainy and cloudy. Next, we estimate the probability (conditional expected value) of actualizing each weather scenario given a forecasted weather condition by using a multinomial logit model, noting that the prediction method used in common practice, in which the forecast values are directly submitted as if they were actualized, possibly brings bias to the predicted values because it excludes the probabilities that the weather forecast is wrong. Then, in combination with seasonal trends estimated by GAM, we construct a new prediction model calculating prediction values of solar radiation and power output. Finally, this study also verifies the superiority of this proposed prediction method in the reduction of prediction error by comparing it with preceding methods and the prediction method that directly substitutes forecast scenarios.