

論文 / 著書情報
Article / Book Information

題目(和文)	機械学習に基づく電力市場における前日計画法 — 再生可能エネルギーの不確かさのもとでの取引戦略 —
Title(English)	
著者(和文)	渡邊郁弥
Author(English)	Fumiya Watanabe
出典(和文)	学位:博士(工学), 学位授与機関:東京工業大学, 報告番号:甲第11424号, 授与年月日:2020年3月26日, 学位の種別:課程博士, 審査員:井村 順一,藤田 政之,三平 満司,山北 昌毅,早川 朋久
Citation(English)	Degree:Doctor (Engineering), Conferring organization: Tokyo Institute of Technology, Report number:甲第11424号, Conferred date:2020/3/26, Degree Type:Course doctor, Examiner:,,,,,
学位種別(和文)	博士論文
Type(English)	Doctoral Thesis



Tokyo Institute of Technology

博士論文

機械学習に基づく電力市場における前日計画法
— 再生可能エネルギーの不確かさのもとでの取引戦略 —

著者

渡邊 郁弥

指導教員

井村 順一 教授

東京工業大学

工学院

システム制御系

2020年2月3日

目次

第 1 章	序論	1
1.1	研究の背景	1
1.2	研究の目的	3
1.3	論文の構成	4
1.4	記法	5
第 2 章	問題設定	7
2.1	はじめに	7
2.2	前日計画と計画関数	7
2.3	アグリゲータの利益の定式化	8
2.4	望ましい計画関数と予測に基づく前日計画法	9
2.5	機械学習に基づくパラメトリックな計画関数モデルの構築	10
2.6	本章のまとめ	10
第 3 章	線形なパラメータを持つ計画関数モデルと凸最適化に基づく学習法	13
3.1	はじめに	13
3.2	凸最適化に基づく計画関数モデルの学習法	13
3.3	計画関数モデルの学習問題の単純化	15
3.4	線形なパラメータを持つ計画関数モデルの例	17
3.5	数値例	18
3.6	本章のまとめ	24
第 4 章	ニューラルネットワークを用いた計画関数モデルと勾配降下法に基づく学習法	27
4.1	はじめに	27

4.2	ニューラルネットワークを用いた計画関数モデルと勾配降下法に基づく学習法	27
4.3	勾配の計算法と学習のアルゴリズム	29
4.4	数値例	34
4.5	本章のまとめ	38
第5章	結論	39
5.1	研究のまとめ	39
5.2	今後の課題	40
参考文献		41
研究業績 (本論文該当)		45
研究業績 (本論文該当以外)		47

表目次

3.1	データを収集した都道府県	21
-----	------------------------	----

目次

3.1	蓄電池の充放電量に関するコスト関数	19
3.2	達成し得る最大の平均利益からの差	23
3.3	理想的な計画値に対する二乗平均平方根誤差	23
3.4	理想的な計画値からの差分に対するヒストグラム	25
4.1	学習データ数に対する達成し得る最大の平均利益からの差	35
4.2	平均利益の内訳	36

第 1 章

序論

1.1 研究の背景

東日本大震災による福島原子力発電所事故を契機として、原子力への依存からの脱却を目指し、分散型電源や再生可能エネルギーといった多種多様な電源の活用が求められるようになってきている。これまでは地域独占型の電力会社が個々に需給管理を行っていたが、全国的に分布する多様な電源を柔軟に活用していくことで、電力供給力不足といったリスクからの脱却を図ろうとしている。これと同時に、電気料金の抑制と需要家の異なったニーズに対する多様な電力供給の選択肢の提供が課題となっている [1]。このような背景から、電力小売事業および発電事業の自由化、すなわち電力自由化が進んでいる。電力自由化により多種多様な事業者が電力関連事業に参入することが可能となり、競争原理に基づく電気料金の抑制と多様な事業者の持つ新技術による発電や需要抑制策の導入が期待されている。実際、新たに参入する多種多様な事業者による全国的な電力融通を可能にするために、電力広域的運営推進機関 [2] が設置されるなど、安定な電力供給と電力自由化の両立が図られている。

電力自由化を軸とした新しい電力システムの構築に向けて、重要な役割を担うと考えられているのがアグリゲータである [3]。アグリゲータは需要家たちの電力需要を集約し、電力を供給する役割を担う。アグリゲータは、電力の需給バランス調整のために、自らが所有する蓄電池や制御可能な発電機の運用を行うほか、電力市場 [4] での取引により不足電力を購入、あるいは余剰電力を売却する。このように、アグリゲータは需要家個人と電力設備運用および電力市場を仲介する役割を持っている。アグリゲータの役割を担う多様な事業者が多数参入することで、電力自由化が促進されるとともに、次世代の電力システムが構成されていくと想定される。事業者がアグリゲータとして電力事業に参入することを促すためには、アグリゲータが十分大きな利益を上げることができることを示す必要がある。そのためには、アグリゲータの電力市場における望ましい取引戦略を考えることが重要な課題であるといえる。

電力市場取引の形式にはいくつかの種類がある。その中でも、本論文では、電力市場の形式として一般的な一日前市場 [3] を考える。一日前市場においては、実際に電力を受け渡す 24 時間前までに電力取引量の計画値を入札を行う。本論文では、一日前市場においてアグリゲータが電力取引量の計画値を決定することを前日計画と呼ぶ。一日前市場に参加し計画値を決定したアグリゲータは、所有する発電機や蓄電池、再生可能エネルギー発電装置などを入札した翌日に運用し、計画値どおりに電力を受け渡すことを目指す。もし、計画値通りに電力の受け渡しを行えず、実際に受け渡す電力量と計画値との差（インバランス）が生じてしまった場合には、そのインバランスを調整するためのペナルティを支払う必要があると考えられる。一般に、一日前市場における計画値の取引価格よりもペナルティ価格は高額であると考えられ、インバランスが生じてしまうと大きな不利益を被ってしまう。

上述した電力システムに対する社会的な要請と同時に、地球温暖化の対策やエネルギー資源の確保といった観点から、太陽光や風力を代表とした再生可能エネルギーの導入が求められている。このことから、アグリゲータが運用する電力設備の中にも再生可能エネルギーによる発電装置が多数導入されていくと考えられる。一方で、再生可能エネルギーによる発電量は気象条件などに大きく影響されるため、その発電出力は制御不可能かつ不確かであるという問題がある。このように、再生可能エネルギーが大量に導入された状況下では、アグリゲータの発電能力は気象条件に依存して大きく変化する。すなわち、再生可能エネルギーによる発電量の不確かさが大きいときには、大きなインバランスによる、多額のペナルティを支払うリスクがある。ペナルティの支払いを回避するためには、アグリゲータの翌日の発電能力を予測しつつ、翌日に達成可能な前日計画を行うことが重要である。

再生可能エネルギーによる発電量の不確か性に対処するために、気象や発電量の予測を用いた前日計画法が提案されている [5, 6, 7, 8, 9, 10]。例えば、文献 [5] では、風力発電設備を持つ発電事業者の一日前市場における取引戦略を考えている。ここでは、風速と風向の予測からいくつかの風力発電量の予測値シナリオを計算し、確率的最適化のアプローチで前日計画を行っている。文献 [7] では、風力発電に加え太陽光発電や負荷の予測値のシナリオを用いて、確率的最適化により計画を行っている。文献 [8] では、太陽光発電の予測値の複数のシナリオを用いた計画を行っており、コストが最悪となるシナリオを用いて計画を行う場合と、すべてのシナリオの平均値を用いて計画を行う場合の比較が行われている。他にも、文献 [9] では、風力発電量の確率分布を利用した場合の最適な前日計画法を述べている。文献 [10] では、風速の予測値を単にシナリオ生成に用いるのではなく、ある時間帯の発電量が多いか少ないかを大まかに判定する分類器を学習し、その結果を前日計画に用いるといった方法を提案している。

気象や発電量の予測を前日計画に用いる場合、その予測精度が最終的な利益に影響する。前日計画だけでなく、当日の火力機の制御といった場面でも発電量の予測が重要である。気象や発電量の予測精度

向上に向けて、近年では機械学習の方法を取り入れた研究が行われている。機械学習を用いた予測の研究では、用いる入力の種類と用いるモデルによって様々な種類の手法が存在する。太陽光日射量の予測を行っている研究としては、文献 [11, 12, 13, 14, 15] などがある。例えば、文献 [14] では、日付や時刻、外気温、湿度、日照時間を入力とし、ニューラルネットワークとランダムフォレストを用いて日射量の予測を行い、比較している。文献 [15] では、ニューラルネットワーク型のモデルに対し、地表データだけでなく数値気象データや衛星データを予測時の入力に用いることで精度向上を目指している。太陽光による発電量を予測する研究としては、文献 [16, 17, 18] などがある。例えば、文献 [18] では、ニューラルネットワークやサポートベクター回帰を用いており、変数選択により複数の入力の候補から有用な入力を決定している。これらの研究は、予測誤差の最小化が目指されており、アグリゲータの前日計画とは独立した研究となっている。一方で、文献 [19] によれば、気象庁が利用する予測モデルでは、快晴時の予測精度は高いものの、降水をもたらさない雲が多い場合には予測精度が悪くなることが指摘されている。この観点から、あらゆる天候状況において日射量や発電量を完全に予測することは困難であり、予測の大外れが生じる場合にも対応できる前日計画法が求められていると考えられる。

また、機械学習の方法に基づいて作成された予測値を元に前日計画を行う研究がいくつか提案されている。文献 [20] では、ニューラルネットワークを用いて再生可能エネルギーの発電量や負荷、価格の予測を行い、それを前日計画のために用いている。文献 [21] では、燃料電池自動車に対する水素の供給に必要な電力を電力市場で購入することを目的として、回帰型ニューラルネットワークを用いて水素消費量を予測を行い、前日計画を行っている。

他にも、強化学習の方法を用いた前日計画に関連する研究が報告されている。例えば、文献 [22] ではビル内エネルギーの運用計画を行う研究が行われているほか、文献 [23] では電力市場取引を含めた電気自動車の充放電計画を強化学習に基づいて行っている。また、文献 [24] では、複数の参加者が強化学習を用いて市場取引戦略を決定する市場について解析している。強化学習に基づいて前日計画を行う場合は、実際の運用を繰り返しながら学習を進めるか、シミュレータによる事前学習の必要がある。この観点から、過去に収集したデータのみを用いて学習できる方法が望ましいと考えられる。

1.2 研究の目的

本論文では、再生可能エネルギーの不確かさを考慮に入れながら、アグリゲータの利益を最大化する前日計画法を考える。前節で述べてきたように、これまで研究されてきた多くの前日計画法は、再生可能エネルギーの予測に基づいて行われてきた。しかし、一般に再生可能エネルギーの完全な予測は困難であり、大外れが生じた場合には大きなインバランスが生じ、アグリゲータは大きな損失を被る可能性

がある。これに対し、本論文では、再生可能エネルギーの予測値に基づいた方法ではなく、アグリゲータの利益を最大化する計画値を出力するブラックボックスを構築する。すなわち、再生可能エネルギーの予測と、その予測値に基づいた最適化による前日計画を行うのではなく、計画値を直接決定するモデルを提案する。特に、計画値を決定するモデルを構築するために、本論文ではアグリゲータの利益を評価関数として用いた機械学習を行う。もし、学習に用いるデータの中に大外れが生じているケースが一定数含まれていれば、大外れが生じる中でもできる限り利益を大きくするような計画値を決定するモデルを学習できることが考えられる。

本論文では、計画値を出力するモデルとして、パラメトリックなブラックボックスモデルを用いる。具体的には、線形なパラメータを持つモデルとニューラルネットワーク型のモデルの2種類を考え、それぞれに対して学習アルゴリズムを示す。まず、計画関数モデルのパラメータが線形となる場合には、最適パラメータを探索する問題は凸最適化問題として定式化できることを示す。さらに、インバランスに対するペナルティを表す関数と発電機や蓄電池の運用コストを表す関数が区分的アフィンな凸関数であるとき、計画関数モデルの学習問題を線形計画問題として、 \mathcal{L}_2 正則化が導入されている場合には2次計画問題として定式化できることを示す。しかし、凸最適化に基づく学習法を用いると、最適パラメータの探索問題の凸性が保証されるが、計算に必要なメモリ容量が学習データ数の増加に対して2乗のオーダーで増加してしまうという問題が生じる。これに対し、ニューラルネットワークは、凸性が保証されない代わりに、学習データ数の増加に対して有効であることが知られている [25]。そこで、本論文では計画関数モデルとしてニューラルネットワークを用いる場合の学習法も示す。ニューラルネットワークでは、一般に勾配降下法に基づいてモデルの学習を行う。ここでは、アグリゲータの利益に基づいてモデルの学習を行うため、利益のパラメータに対する勾配を計算する方法を示す。

1.3 論文の構成

第2章では、一日前市場における前日計画からアグリゲータの利益が確定するまでの流れを述べる。続いて、アグリゲータの利益を最大化する理想的な前日計画法について考察を行う。その上で、理想的な前日計画を近似的に達成するために、計画関数をパラメトリックなブラックボックスのモデルとして定義し、過去のデータに対して利益を最大化するモデルを探索する問題を定式化する。

第3章では、線形なパラメータを持つ計画関数モデルの学習法を述べる。特に、計画関数モデルがモデルを特徴づけるパラメータに対して線形であるという仮定のもとで、最適なパラメータの探索問題を凸な最適化問題として定式化できることを示す。さらに、ペナルティ関数と運用コスト関数が区分的アフィンな凸関数であるとき、パラメータの探索問題を線形計画問題へ、 \mathcal{L}_2 正則化が導入されている場

合には 2 次計画問題へ簡単化できることを示す。最後に、数値例を通して利益を直接評価することの重要性を示す。

第 4 章では、ニューラルネットワークを用いた計画関数モデルの学習法を述べる。ここでは、勾配降下法に基づいてニューラルネットワークを学習させるために、利益のパラメータに対する勾配を計算する方法を示す。特に、ペナルティ関数と運用コスト関数が区分的アフィンな凸関数で表されるとき、線形計画問題の強双対性に基づく勾配の計算方法を示す。その上で、ニューラルネットワークを用いた場合の計画関数モデルの学習アルゴリズムを述べる。最後に、多数データの利用可能性とその効果という観点で、ニューラルネットワークを用いた方法と第 3 章で述べる凸最適化に基づく方法を、数値例を通して比較する。

第 5 章では本研究の総括を行い、今後の課題を述べる。

1.4 記法

本論文では次の記法を用いる。

\mathbb{R}	実数の集合
\mathbb{R}_+	正の実数の集合
I_n	n 次の単位行列
O_n	n 次の零行列
$\mathbf{1}_n$	全要素が 1 である n 次元列ベクトル
$\mathbf{0}_n$	全要素が 0 である n 次元列ベクトル
$M \succeq O_n$	n 次の半正定行列 M
$A \otimes B$	行列 A, B の Kronecker 積

第 2 章

問題設定

2.1 はじめに

本章では，一日前市場における前日計画とアグリゲータが得る利益の定式化を行い，望ましい前日計画の方法について考察する．そして，望ましい前日計画を近似的に達成することを目指して，機械学習の方法に基づいて計画関数モデルを構築することを提案する．特に，計画関数モデルとしてパラメトリックなモデルを導入することで，計画関数モデルの学習問題を最適パラメータの探索問題として定式化する．また，過去データに対するアグリゲータの利益の平均値を評価値として用いることで，利益最大化を目指した計画関数モデルの学習を行うことを提案する．

2.2 前日計画と計画関数

まず，一日前市場に参加するアグリゲータの電力の取引について考える．一日前市場においては，アグリゲータは翌日受け渡す電力量の計画値を決定し，その計画値に基づいて収入が決定する．

アグリゲータは， i 日目に受け渡す電力量の計画値 $\hat{x}_i \in \mathbb{R}^n$ を $(i-1)$ 日目に決定する．ここで， n は 1 日に取引する回数を表し， $24/n$ 時間の単位で取引が行われるものとする．アグリゲータは，計画値決定のために $(i-1)$ 日目の段階で入手可能な情報 $u_i \in \mathbb{R}^m$ を用いる．例えば，計画値決定のために i 日目の気温の予測値 $\hat{T}_i \in \mathbb{R}_+^n$ と日射量の予測値 $\hat{r}_i \in \mathbb{R}^n$ を $(i-1)$ 日目までに入手して用いる場合， $u_i = \begin{bmatrix} \hat{T}_i^\top & \hat{r}_i^\top \end{bmatrix}^\top$ と設定する．アグリゲータは， u_i を引数とする計画関数 f を用いて，計画値 \hat{x}_i を

$$\hat{x}_i = f(u_i) \quad (2.1)$$

と決定する．ここで， \hat{x}_i の要素が正の値であるときは売却する電力量を表し，負の値であるときは購入する電力量を表す．

2.3 アグリゲータの利益の定式化

本研究の目的は、アグリゲータの利益を最大化するような計画関数を求めることである。本節では、計画関数の望ましさを評価するために、アグリゲータの利益を定式化する。

まず、受け渡し当日 (i 日目) にアグリゲータが受け渡すことができる電力量を定式化する。 i 日目には、アグリゲータは電力機器を運用し、 $(i-1)$ 日目に決定した計画値どおりに電力を受け渡すことを目指す。本論文では、アグリゲータは調整可能な発電機、負荷、再生可能エネルギー発電装置、蓄電装置を扱うものと仮定する。ここで、 $g_i \in \mathbb{R}_+^n$ を調整可能な発電機の発電量、 $l_i \in \mathbb{R}_+^n$ を負荷、 $p_i \in \mathbb{R}_+^n$ を再生可能エネルギー発電量、 $q_i \in \mathbb{R}_+^n$ を再生可能エネルギー発電の抑制量、 $\delta_i^{\text{in}} \in \mathbb{R}_+^n$ および $\delta_i^{\text{out}} \in \mathbb{R}_+^n$ をそれぞれ蓄電装置の充電量と放電量とする。また、蓄電装置の充放電量をまとめて、 $\delta_i := [(\delta_i^{\text{in}})^\top (\delta_i^{\text{out}})^\top]^\top$ と表す。調整可能な発電機の発電量は $g_i \in \mathcal{G}_i$ を満たす必要があるとする。ただし、 \mathcal{G}_i は発電機の物理的制約によって決定される既知の集合である。同様に、蓄電池の充放電量は、 $\delta_i \in \mathcal{D}_i$ を満たす必要があるとする。ただし、 \mathcal{D}_i は蓄電池やインバータの容量などによって決定される既知の集合である。そして、再生可能エネルギー発電の抑制量はその発電量を超えることはできないため、 $\mathbf{0}_n \leq q_i \leq p_i$ を満たす必要がある。この制約をみたす q_i の集合を

$$\mathcal{Q}_i(p_i) := [\mathbf{0}_n, p_i] \quad (2.2)$$

と定義する。ここでは、アグリゲータが操作できる量をまとめて $v_i := (g_i, \delta_i, q_i) \in \mathcal{G}_i \times \mathcal{D}_i \times \mathcal{Q}_i(p_i)$ 、操作できない不確かな量をまとめて $w_i := (l_i, p_i) \in \mathbb{R}_+^n \times \mathbb{R}_+^n$ と表す。上記の表現を用いると、アグリゲータの i 日目に実際に受け渡す電力量は

$$x_i(v_i; w_i) := g_i - l_i + p_i - q_i - \frac{1}{\eta^{\text{in}}} \delta_i^{\text{in}} + \eta^{\text{out}} \delta_i^{\text{out}} \quad (2.3)$$

と表すことができる。ただし、 η^{in} および η^{out} はそれぞれ充放電効率を表す 1 以下の正の定数である。

実際に受け渡す電力量が決まると、アグリゲータが得る利益を求めることができる。アグリゲータが得る利益は、前日計画による収入から、計画値と実際に受け渡す電力量の差分（インバランス）に応じて支払うペナルティと発電装置や蓄電装置の運用に必要なコストを差し引いたものである。まず、一日前市場における収入を考える。取引価格を $\hat{\lambda}_i \in \mathbb{R}^n$ とする。このとき、アグリゲータが一日前市場で計画値を取引することで得られる収入は $\hat{\lambda}_i^\top \hat{x}_i$ と表すことができる。ただし、一般に取引価格 $\hat{\lambda}_i$ はアグリゲータが決定する \hat{x}_i に応じて変化する量であるが、本論文では簡単のために既知の定数であるとする。この仮定は、一日前市場で入札される電力量の計画値に比べ、アグリゲータが入札する計画値が十分小さく、プライステイカーであることを意味する。次に、インバランスに対するペナルティを考える。ア

グリゲータは、計画値 \hat{x}_i と実際に受け渡す電力量 $x_i(v_i; w_i)$ とのインバランスの大きさに応じて、ペナルティ $E_i(\hat{x}_i - x_i(v_i; w_i))$ を支払うものとする。ただし、ペナルティ関数 E_i は既知であるとする。最後に、電力機器の運用によるコストを考える。ここでは、発電量 g_i と充放電量 δ_i を達成するためにかかる運用コストを $F_i(g_i, \delta_i)$ とする。ただし、運用コスト関数 F_i は発電機の燃料費や蓄電池のサイクル劣化の速さなどから決まり、既知の関数であるとする。以上の表記を用いると、計画値 \hat{x}_i と操作可能な量 v_i が決定したときにアグリゲータが得る利益は、

$$J_i(\hat{x}_i, v_i; w_i) := \lambda_i^\top \hat{x}_i - E_i(\hat{x}_i - x_i(v_i; w_i)) - F_i(g_i, \delta_i) \quad (2.4)$$

と表すことができる。ここで、 \hat{x}_i は $(i-1)$ 日目にアグリゲータが決定するものであり、 v_i と w_i は i 日目に決まる量であることに注意する。ここで、アグリゲータは当日の電力の受け渡しするとき、利益を最大化するように v_i を決定すると仮定する。このとき、ある計画値 \hat{x}_i を決めたとときに得る利益は、

$$J_i^*(\hat{x}_i; w_i) := \max_{v_i \in \mathcal{G}_i \times \mathcal{D}_i \times \mathcal{Q}_i(p_i)} J_i(\hat{x}_i, v_i; w_i) \quad (2.5)$$

となる。ここで、 w_i は i 日目に決まる、 $(i-1)$ 日目には不明な量であるため、 J_i^* を $(i-1)$ 日目に求めることはできないことに注意する。

2.4 望ましい計画関数と予測に基づく前日計画法

まず、アグリゲータの利益を最大化する理想的な計画関数として、 $u_i = w_i$ である場合、翌日の再生可能エネルギー発電量と負荷が正確に予測できる状況を考える。この状況においては、理想的な計画関数 f_{ideal} は明らかに

$$f_{\text{ideal}}(u_i) = \arg \max_{\hat{x}_i} J_i^*(\hat{x}_i; u_i) \quad (2.6)$$

であることが分かる。しかし、現実的には w_i は前日計画を行う $(i-1)$ 日目には不明であり、式 (2.6) で与えられる理想的な計画関数 f_{ideal} は実現不可能である。そのため、理想的な計画関数を何らかの方法で近似する必要がある。

この問題に対し、 w_i の予測値 \hat{w}_i を $(i-1)$ 日目に求め、真の w_i の代わりに用いるという方法が考えられる。すなわち、利用可能な情報 u_i から w_i の予測値 \hat{w}_i を出力する関数 $\hat{w}_i = f_w(u_i)$ を事前に構築し、

$$f_{\text{pred}}(u_i) = \arg \max_{\hat{x}_i} J_i^*(\hat{x}_i; f_w(u_i)) \quad (2.7)$$

として前日計画を行うことが考えられる。本論文では、この方法を予測法と呼ぶことにする。この手法では、 w_i と \hat{w}_i との誤差を小さくするように関数 f_w を構築することで、利益の減少を抑えることを目指している。

2.5 機械学習に基づくパラメトリックな計画関数モデルの構築

2.4節において、理想的な計画関数を実現することは不可能であることを述べた。本論文では、予測を行う関数 f_w を構築するのではなく、利用可能な情報 u_i から計画値を直接出力する関数を構築することを提案する。すなわち、予測と前日計画を2段階に分けて考えるのではなく、前日計画を直接出力するブラックボックスの構築を行う。特に、機械学習の方法に基づいて、過去のデータを元にアグリゲータの利益を最大化する関数を学習により構築する。本節では、このことを問題として定式化する。

過去の $i = 1, \dots, N$ 日における $w_i = (p_i, l_i)$ のデータが得られているとする。このとき、ある計画関数 f に対する過去の利益の平均値は

$$\mathcal{J}[f] = \frac{1}{N} \sum_{i=1}^N J_i^*(f(u_i); w_i)$$

と計算できる。本論文では、 $\mathcal{J}[f]$ を最大化する計画関数の探索を行う。すべての関数の中から $\mathcal{J}[f]$ を最大化する f を見つけることは一般に困難である。この観点から、本論文ではパラメータ θ を用いたパラメトリックな計画関数モデル $f(u_i, \theta)$ を用いて、過去の利益の平均値を最大化する最適なパラメータ θ^* を求めるものとする。この問題を次のように定式化する。

問題 1. $i = 1, \dots, N$ に対し、 u_i と $w_i := (l_i, p_i)$ が得られていると仮定する。このとき、

$$\theta^* = \arg \min_{\theta} L(\theta) \quad (2.8)$$

を求めよ。ここで、損失関数 $L(\theta)$ は

$$L(\theta) := -\frac{1}{N} \sum_{i=1}^N J_i^*(f(u_i, \theta); w_i) \quad (2.9)$$

であり、負の平均利益を表す。

2.6 本章のまとめ

本章では、前日計画とアグリゲータの利益モデルを定式化し、問題設定を行った。

まず、一日前市場におけるアグリゲータの前日計画の流れを述べた。アグリゲータは、入手可能な情報から計画関数を介して計画値を決定するものとして定義した。次に、得られた計画値から利益を計算する方法について述べた。当日実際に受け渡す電力量は、調整可能な発電装置の発電量、蓄電装置の充

放電量，再生可能エネルギー発電の抑制量からなるアグリゲータが操作できる量と，再生可能エネルギー発電量と負荷からなる不確かな量から決まる．アグリゲータは利益を最大化するように操作できる量を決定するとき，アグリゲータの利益は式 (2.5) で表される最適化問題の最適値として表される．

アグリゲータの前日計画と利益の定式化を受けて，アグリゲータの利益を最大化する望ましい計画関数について述べた．しかし，望ましい計画関数は実現不可能であるため，何らかの形で近似が必要であることを述べた．これに対し，機械学習のアプローチに基づいて理想的な計画関数の近似を行うことを提案した．具体的には，過去の再生可能エネルギー発電量と負荷のデータが得られていると仮定し，過去の利益の平均値を最大化する計画関数を求める．ここでは，計画関数をパラメトリックなブラックボックスモデルとして定義し，過去の利益の平均値を最大化するパラメータを探索する問題として，計画関数モデルの学習問題を定式化した．

第 3 章

線形なパラメータを持つ計画関数モデル と凸最適化に基づく学習法

3.1 はじめに

本章では、2.5 節で述べたブラックボックスモデルとして、パラメータに対して線形な計画関数モデルを考える。特に、パラメータに対して線形な計画関数モデルを考えると、最適なパラメータの探索問題が凸最適化問題として表すことができることを示す。さらに、ペナルティ関数や運用コスト関数が区分的アフィンな凸関数で表されているとき、線形計画問題を解くことで学習できることを述べる。また、損失関数に \mathcal{L}_2 正則化の項が含まれる場合は、2 次計画問題を解くことで学習できることを述べる。最後に、数値例を通して本章で提案する手法と予測法の比較を行い、利益を直接評価することの重要性を示す。

3.2 凸最適化に基づく計画関数モデルの学習法

本節では、計画関数モデルがパラメータに対して線形であることを仮定すると、問題 1 で定義した最適パラメータを探索する問題が凸最適化問題となることを示す。その上で、ペナルティ関数や運用コスト関数が区分的アフィンな凸関数であるという仮定を導入すると、最適パラメータを探索する問題が線形計画問題となることを示す。さらに、損失関数に \mathcal{L}_2 正則化の項が含まれる場合には、2 次計画問題へと帰着できることを示す。

パラメータを探索する問題は、式 (2.9) で表される損失関数 $L(\theta)$ を最小化する θ を求める問題である。損失関数 $L(\theta)$ は式 (2.5) で表される J_i^* の $i = 1, \dots, N$ に関する総和であり、 J_i^* は最適化問題に

対する最適値という形で求まるため、式 (2.8) は 2 段階最適化問題となっている。この 2 段階最適化問題は、最小値を最小化する問題であるため、実際には 1 つの最適化問題と等価であるとみなすことができる。すなわち、決定変数 $v_i = (g_i, \delta_i, q_i)$ と θ の両方を決定変数とした最適化問題

$$\min_{\theta, v_1, \dots, v_N} L'(\theta, v_1, \dots, v_N) \quad (3.1)$$

を考えればよい。ただし、

$$L'(\theta, v_1, \dots, v_N) := -\frac{1}{N} \sum_{i=1}^N J_i(f(u_i, \theta), v_i; w_i) \quad (3.2)$$

である。

最適化問題 (3.1) に対し、計画関数モデルがパラメータ θ に対して線形であることを仮定すると、次の定理を導くことができる。

定理 1. 計画関数モデル $f(u_i, \theta)$ を、パラメータ $\theta \in \mathbb{R}^{n_\theta}$ を用いて

$$f(u_i, \theta) := U(u_i)\theta \quad (3.3)$$

と与える。ただし、

$$U : \mathbb{R}^m \rightarrow \mathbb{R}^{n \times n_\theta}$$

である。このとき、すべての $i = 1, \dots, N$ に対し運用コスト関数 $F_i(g_i, \delta_i)$ が $\mathcal{G}_i \times \mathcal{D}_i$ 上で凸関数で、かつペナルティ関数 E_i が \mathbb{R}^n 上で凸関数であると仮定する。このとき、式 (3.2) で表される損失関数 L' は、 $(\theta, v_1, \dots, v_N) \in \mathbb{R}^{n_\theta} \times \mathcal{G}_1 \times \mathcal{D}_1 \times \mathcal{Q}_1 \times \dots \times \mathcal{G}_N \times \mathcal{D}_N \times \mathcal{Q}_N$ に関して凸関数である。

証明. 式 (3.3) で与えられる $f(u_i, \theta)$ はパラメータ θ に対して線形であり、式 (2.3) で与えられる $x_i(v_i; w_i)$ は v_i に対するアフィン関数である。よって、ペナルティ関数 $E_i(f(u_i, \theta) - x_i(v_i; w_i))$ の引数 $f(u_i, \theta) - x_i(v_i; w_i)$ は、 θ と v_i に対してアフィンである。したがって、関数

$$E_{\text{ave}}(\theta, v_1, \dots, v_N) := \frac{1}{N} \sum_{i=1}^N E_i(f(u_i, \theta) - x_i(v_i; w_i))$$

は、 $(\theta, v_1, \dots, v_N) \in \mathbb{R}^{n_\theta} \times \mathcal{G}_1 \times \mathcal{D}_1 \times \mathcal{Q}_1 \times \dots \times \mathcal{G}_N \times \mathcal{D}_N \times \mathcal{Q}_N$ に関して凸である。また、運用コスト関数 $F_i(g_i, \delta_i)$ の引数 g_i, δ_i はそれぞれ、明らかに v_i に対してアフィンである。したがって、関数

$$F_{\text{ave}}(\theta, v_1, \dots, v_N) := \frac{1}{N} \sum_{i=1}^N F_i(g_i, \delta_i)$$

は, $(\theta, v_1, \dots, v_N) \in \mathbb{R}^{n_\theta} \times \mathcal{G}_1 \times \mathcal{D}_1 \times \mathcal{Q}_1 \times \dots \times \mathcal{G}_N \times \mathcal{D}_N \times \mathcal{Q}_N$ に関して凸である. したがって, 凸関数の和は凸関数であるため, 損失関数 L' は $(\theta, v_1, \dots, v_N) \in \mathbb{R}^{n_\theta} \times \mathcal{G}_1 \times \mathcal{D}_1 \times \mathcal{Q}_1 \times \dots \times \mathcal{G}_N \times \mathcal{D}_N \times \mathcal{Q}_N$ に関して凸関数である. \square

定理 1 から, 損失関数に \mathcal{L}_2 正則化の項が加わっている場合に関しても, 同様の結論をただちに示すことができる.

系 1. 定理 1 における仮定を満たしているものとする. このとき, 損失関数 $L'_{\text{reg}}(\theta, v_1, \dots, v_N)$ がある正の定数 $\alpha > 0$ と半正定値対称行列 $R \succeq O_{n_\theta}$ を用いて

$$L'_{\text{reg}}(\theta, v_1, \dots, v_N) := L'(\theta, v_1, \dots, v_N) + \alpha \theta^\top R \theta \quad (3.4)$$

と定義されているとき, 損失関数 L'_{reg} は $(\theta, v_1, \dots, v_N) \in \mathbb{R}^{n_\theta} \times \mathcal{G}_1 \times \mathcal{D}_1 \times \mathcal{Q}_1 \times \dots \times \mathcal{G}_N \times \mathcal{D}_N \times \mathcal{Q}_N$ に関して凸関数である.

以上の結果から, 線形なパラメータを持つ計画関数モデルを学習するとき, ペナルティ関数 E_i が \mathbb{R}^n 上で, 運用コスト関数 F_i が $\mathcal{G}_i \times \mathcal{D}_i$ 上でそれぞれ凸関数であれば, 最適なパラメータ θ^* を凸最適化アルゴリズムにより求めることが可能であることが示された.

3.3 計画関数モデルの学習問題の簡単化

定理 1 で述べた仮定に加え, ペナルティ関数 E_i および運用コスト関数 F_i がそれぞれ区分的アフィンな凸関数として式 (3.5), (3.6) で定義されているという仮定を追加すると, 最適パラメータを求める最適化問題 (3.1) を, 次の線形計画問題へと簡単化することができる. それを示すために, 本節ではまずアグリゲータの利益を計算する問題を線形計画問題へと簡単化する方法について述べ, その方法にしたがって計画関数モデルの学習問題を線形計画問題へと簡単化する. さらに, \mathcal{L}_2 正則化項が加わっている場合には, 2 次計画問題となることを示す.

2.3 節において述べたように, アグリゲータの利益は式 (2.5) で表される最適化問題の最適値として求めることができる. ここで, \mathcal{G}_i や \mathcal{D}_i が線形不等式を満たす量の集合として表現されていると仮定する. さらに, ペナルティ関数 E_i および運用コスト関数 F_i が区分的アフィンな凸関数で定義されていると仮定する. このとき, E_i と F_i はそれぞれ, $a_1^{E_i}, \dots, a_{n_{E_i}}^{E_i} \in \mathbb{R}^n, a_1^{F_i}, \dots, a_{n_{F_i}}^{F_i} \in \mathbb{R}^{3n}$ と $b_1^{E_i}, \dots, b_{n_{E_i}}^{E_i}, b_1^{F_i}, \dots, b_{n_{F_i}}^{F_i} \in \mathbb{R}$ を用いて,

$$E_i(\hat{x}_i - x_i(v_i; w_i)) = \max_{j=1, \dots, n_{E_i}} \left((a_j^{E_i})^\top (\hat{x}_i - x_i(v_i; w_i)) + b_j^{E_i} \right), \quad (3.5)$$

$$F_i(g_i, \delta_i) = \max_{j=1, \dots, n_{F_i}} \left((a_j^{F_i})^\top [(g_i)^\top (\delta_i)^\top]^\top + b_j^{F_i} \right) \quad (3.6)$$

と表すことができる。ここで、 n_{E_i}, n_{F_i} はそれぞれ E_i と F_i の区間ごとの直線の数である。このとき最適化問題 (2.5) は、変数 $\eta_i, \xi_i \in \mathbb{R}$ を導入することで、次の最適化問題へ帰着できる [26]。

$$\begin{aligned} & \max_{v_i, \eta_i, \xi_i} && \tilde{J}_i(\hat{x}_i, v_i, \eta_i, \xi_i) && (3.7) \\ & \text{subject to} && v_i \in \mathcal{G}_i \times \mathcal{D}_i \times \mathcal{Q}_i(p_i), \\ & && A^{E_i}(\hat{x}_i - x_i(v_i; w_i)) + b^{E_i} \leq \eta_i \mathbf{1}_{n_{E_i}}, \\ & && A^{F_i}[(g_i)^\top (\delta_i)^\top]^\top + b^{F_i} \leq \xi_i \mathbf{1}_{n_{F_i}} \end{aligned}$$

ただし、

$$\begin{aligned} A^{E_i} &:= \begin{bmatrix} a_1^{E_i} & \dots & a_{n_{E_i}}^{E_i} \end{bmatrix}^\top, \quad A^{F_i} := \begin{bmatrix} a_1^{F_i} & \dots & a_{n_{F_i}}^{F_i} \end{bmatrix}^\top, \\ b^{E_i} &:= \begin{bmatrix} b_1^{E_i} & \dots & b_{n_{E_i}}^{E_i} \end{bmatrix}^\top, \quad b^{F_i} := \begin{bmatrix} b_1^{F_i} & \dots & b_{n_{F_i}}^{F_i} \end{bmatrix}^\top \end{aligned}$$

である。また、

$$\tilde{J}_i(\hat{x}_i, v_i, \eta_i, \xi_i) := \hat{\lambda}_i^\top \hat{x}_i - (\eta_i + \xi_i) \quad (3.8)$$

である。このとき、調整可能な発電量 g_i 、蓄電装置の充放電量 δ_i それぞれに関して、 $\mathcal{G}_i, \mathcal{D}_i$ の条件が線形不等式で表されているとき、最適化問題 (3.7) の制約条件はすべて線形不等式で表現可能となる。したがって、上記の仮定のもとで最適化問題 (3.7) は線形計画問題となる。

最適パラメータを求める最適化問題 (3.1) についても、上述の仮定を導入すると同様に次の線形計画問題へと簡単化することができる。

$$\begin{aligned} & \min_{\theta, v_1, \eta_1, \xi_1, \dots, v_N, \eta_N, \xi_N} && L'_{\text{lin}}(\theta, v_1, \eta_1, \xi_1, \dots, v_N, \eta_N, \xi_N) && (3.9) \\ & \text{subject to} && v_i \in \mathcal{G}_i \times \mathcal{D}_i \times \mathcal{Q}_i(p_i), \\ & && A^{E_i}(\hat{x}_i - x_i(v_i; w_i)) + b^{E_i} \leq \eta_i \mathbf{1}_{n_{E_i}}, \\ & && A^{F_i}[(g_i)^\top (\delta_i)^\top]^\top + b^{F_i} \leq \xi_i \mathbf{1}_{n_{F_i}}, \\ & && (i = 1, \dots, N) \end{aligned}$$

ただし、

$$L'_{\text{lin}}(\theta, v_1, \eta_1, \xi_1, \dots, v_N, \eta_N, \xi_N) := -\frac{1}{N} \sum_{i=1}^N \tilde{J}_i(f(u_i, \theta), v_i, \eta_i, \xi_i), \quad (3.10)$$

である。また、 \mathcal{L}_2 正則化項を導入する場合は、上記の手続きに加え

$$L'_{\text{quad}}(\theta, v_1, \eta_1, \xi_1, \dots, v_N, \eta_N, \xi_N) := L'_{\text{lin}}(\theta, v_1, \eta_1, \xi_1, \dots, v_N, \eta_N, \xi_N) + \alpha \theta^\top R \theta \quad (3.11)$$

と損失関数を変更すればよい。このとき、最適パラメータを求める最適化問題は2次計画問題となる。以上より、ペナルティ関数や運用コスト関数が区分的アフィンな凸関数であるという仮定のもとで、計画関数モデルの学習問題を線形計画問題へと帰着でき、 \mathcal{L}_2 正則化を導入する場合には2次計画問題へと帰着できる。この結果を用いることで、線形計画問題や2次計画問題のソルバを用いた学習が可能である。

3.4 線形なパラメータを持つ計画関数モデルの例

前節では、計画関数モデルがパラメータ θ に対して線形となるときの、凸最適化により学習が可能であることを述べた。本節では、線形なパラメータを持つ計画関数モデルの例を紹介する。

まず、線形回帰モデル [27] について述べる。線形回帰による計画関数モデルは、パラメータ $\theta \in \mathbb{R}^{n_b}$ を用いて

$$f(u, \theta) := (I_n \otimes \varphi(u)^T) \theta \quad (3.12)$$

と定義するものである。ただし、 n_b は基底関数の個数を表し、 $\varphi(u)$ は

$$\varphi(u) := \begin{bmatrix} \phi_1(u) & \cdots & \phi_{n_b}(u) \end{bmatrix}^T \in \mathbb{R}^{n_b}$$

である。ただし、 $\phi_1(u), \dots, \phi_{n_b}(u)$ は基底関数であり、

$$\phi_i : \mathbb{R}^m \rightarrow \mathbb{R}, \quad i = 1, \dots, n_b$$

である。

続いて、カーネル法に基づくモデル [27] について述べる。カーネル法に基づく計画関数モデルは、パラメータ $\theta := [\theta_1^T, \dots, \theta_N^T]^T$, $\theta_i \in \mathbb{R}^n$, ($i = 1, \dots, N$) を用いて、

$$f(u, \theta) := \sum_{i=1}^N \theta_i k(u, u_i) \quad (3.13)$$

と定義するものである。ただし、 $k : \mathbb{R}^m \times \mathbb{R}^m \rightarrow \mathbb{R}_+$ はカーネル関数 [27] であり、事前に指定する関数である。カーネル法に基づくモデルを採用する場合、一般に損失関数に2次形式の正則化項 $\alpha \theta^T R \theta$ を導入する。ただし、行列 R は $R = K \otimes I_n$ であり、 $K \succeq O_N$ は Gram 行列 [27] である。Gram 行列

K は、入力の過去データ u_1, \dots, u_N を用いて

$$K := \begin{bmatrix} k(u_1, u_1) & k(u_1, u_2) & \cdots & k(u_1, u_N) \\ k(u_2, u_1) & k(u_2, u_2) & \cdots & k(u_2, u_N) \\ \vdots & \vdots & \ddots & \vdots \\ k(u_N, u_1) & k(u_N, u_2) & \cdots & k(u_N, u_N) \end{bmatrix}$$

と定義される。

3.5 数値例

3.5.1 検証する内容

本節では、数値実験の結果を示し、その考察を述べる。具体的には、本章で提案した方法による前日計画と、2.4節で述べた予測法による前日計画をそれぞれ実施し、比較を行うことでアグリゲータの利益を直接評価することの重要性について検証する。また、参考のために式(2.6)で表される理想的な計画関数を用いて、達成し得る利益の最大値を計算する。

予測法では、利用可能な情報 u_i を用いて再生可能エネルギー発電量の予測値 \hat{p}_i と負荷の予測値 \hat{l}_i を推定し、その予測値をもとに計画値 \hat{x}_i を決定する。具体的には、まず u_i から再生可能エネルギー発電量の予測値 \hat{p}_i と負荷の予測値 \hat{l}_i を出力するモデルをそれぞれ

$$\begin{aligned} \hat{p}_i &:= f_p(u_i, \theta_p), \\ \hat{l}_i &:= f_l(u_i, \theta_l) \end{aligned}$$

と定義する。ただし、 θ_p, θ_l はそれぞれのモデルのパラメータである。モデルのパラメータ θ_p, θ_l を決定するときには、過去の u_i のデータと、真の再生可能エネルギー発電量 p_i と負荷 l_i のデータを用いて、次の2乗誤差で表される損失関数

$$\begin{aligned} L_p(\theta_p) &:= \frac{1}{N} \sum_{i=1}^N (\|p_i - f_p(u_i, \theta_p)\|^2), \\ L_l(\theta_l) &:= \frac{1}{N} \sum_{i=1}^N (\|l_i - f_l(u_i, \theta_l)\|^2) \end{aligned}$$

がそれぞれ最小となるように θ_p, θ_l を決定する。ただし、 N はデータの個数である。最後に、予測法による計画関数 f_{pred} を

$$f_{\text{pred}}(u_i) = \arg \max_{\hat{x}_i} J_i^*(\hat{x}_i; \hat{w}_i)$$

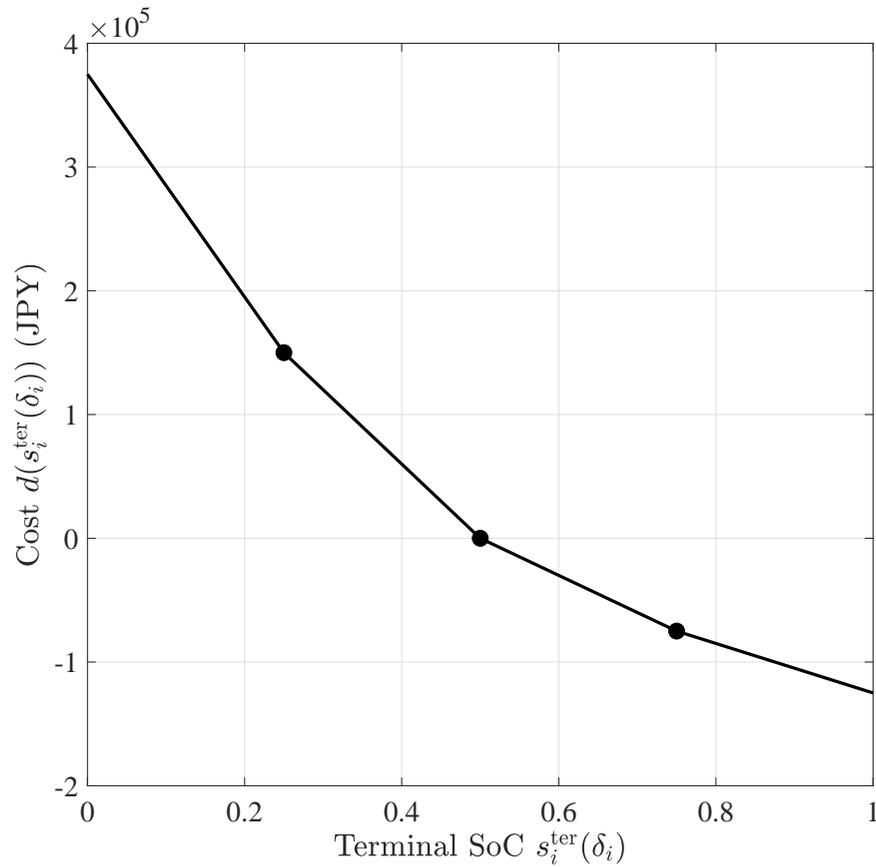


図 3.1 蓄電池の充放電量に関するコスト関数

とすることで、計画値 $\hat{x}_i = f_{\text{pred}}(u_i)$ を決定する。ただし、 $\hat{w}_i := (f_l(u_i, \theta_l), f_p(u_i, \theta_p))$ である。

本数値例では、提案手法における計画関数モデル $f(u_i, \theta)$ と、予測法における予測モデル $f_p(u_i, \theta_p), f_l(u_i, \theta_l)$ の構造として、いずれも線形回帰モデルを用いる。また、ここでは基底関数として

$$\varphi(u) = \begin{bmatrix} 1 & u^T \end{bmatrix}^T$$

を用いるものとする。

3.5.2 想定する状況

この数値例では、1日に6回、4時間ごとに取引が行われる一日前市場を想定する。本数値例では、アグリゲータは太陽光発電装置と蓄電装置のみを持ち、工場やビルといった産業向けの需要家を800件取り扱っている状況を考える。ここで、アグリゲータは電気自動車およそ1000台分相当の蓄電池を持

つと想定し、最大蓄電容量 C_{bat} は 30 MWh とし、蓄電池用インバータ容量 C_{inv} は 5 時間で満充電となる 6 MW と設定する。

アグリゲータは前日計画の段階で、翌日の太陽光日射量の予測値 $\hat{r}_i \in \mathbb{R}^n$ 、気温の予測値 $\hat{T}_i \in \mathbb{R}^n$ 、取引価格 $\hat{\lambda}_i \in \mathbb{R}^n$ 、充電率 (state of charge, SoC) の初期値 $s_i^0 \in [0, 1]$ が利用可能であると仮定する。すなわち、前日計画に利用可能な情報を $u_i = [\hat{r}_i^\top \ \hat{T}_i^\top \ \hat{\lambda}_i^\top \ s_i^0]^\top$ と設定する。

ペナルティ関数 E_i は、

$$E_i(\hat{x}_i - x_i(v_i; w_i)) = \gamma_i^\top |\hat{x}_i - x_i(v_i; w_i)| \quad (3.14)$$

と定義する。ただし、 $\gamma_i \in \mathbb{R}^n$ はペナルティ価格を表し、既知の定数とする。ここで、 $|\cdot|$ はベクトルの要素ごとの絶対値を表す。このとき、 E_i は \mathbb{R}^n に対して区分的アフィンな凸関数であることに注意する。

蓄電装置の充放電コスト関数 D_i を、1 日の最終的な SoC に応じてインセンティブを与えるように定義する。各時刻の SoC $s_i(\delta_i)$ は、

$$s_i(\delta_i) := \frac{1}{C_{\text{bat}}} (s_i^0 \mathbf{1}_n + A_{\text{cum}}(\delta_i^{\text{in}} - \delta_i^{\text{out}})) \quad (3.15)$$

と計算できる。ただし、

$$A_{\text{cum}} := \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 1 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & 0 \\ 1 & 1 & \cdots & 1 \end{bmatrix}$$

である。このとき、1 日の最終的な SoC $s_i^{\text{ter}}(\delta_i)$ は、 $s_i(\delta_i)$ の n 番目の要素である。この $s_i^{\text{ter}}(\delta)$ に対し、充放電コスト関数 $D(s_i^{\text{ter}}(\delta))$ を図 3.1 のように定義する。ただし、図中の黒点は折れ点を表しており、 $D(s_i^{\text{ter}}(\delta))$ は区分的アフィンな凸関数であることに注意する。最後に、蓄電池の容量や蓄電池用インバータ容量に関する充放電量制約を

$$\mathcal{D}_i := \{\delta_i \in \mathbb{R}^{2n}: \mathbf{0}_{2n} \leq \delta_i \leq C_{\text{inv}} \mathbf{1}_{2n}, \mathbf{0}_n \leq s_i(\delta_i) \leq \mathbf{1}_n\} \quad (3.16)$$

と与える。

3.5.3 使用するデータセット

本節では、数値実験に用いるデータセットの出典について述べる。太陽光発電量の実測データ p_i は、太陽放射コンソーシアム提供の AMATERASS 日射量実測データ [28] から計算した。負荷の実測デー

表 3.1 データを収集した都道府県

ケース番号	都道府県
1	青森, 岩手, 宮城
2	秋田, 山形, 福島
3	茨城, 栃木, 群馬
4	埼玉, 千葉, 東京
5	神奈川, 新潟, 富山
6	石川, 福井, 山梨
7	長野, 岐阜, 静岡
8	愛知, 三重, 滋賀
9	京都, 大阪, 兵庫
10	奈良, 和歌山, 鳥取
11	島根, 岡山, 広島
12	山口, 徳島, 香川
13	愛媛, 高知, 福岡
14	佐賀, 長崎, 熊本
15	大分, 宮崎, 鹿児島

タ l_i は、文献 [29, 30] の手法に基づき、電力需要の気温応答モデルを作成し、電力需要を計算した。ただし、気温応答モデルは一般社団法人環境共創イニシアチブが提供するエネルギーマネジメントシステムオープンデータと気象庁が提供する AMeDAS 気温実測データに基づいて作成した。取引価格のデータ $\hat{\lambda}_i$ は、3.5.2 節で述べた前日計画を行うアグリゲータと同程度の規模の需要を扱うアグリゲータ 47 件と、火力機を所有し電力供給能力を持つアグリゲータ 6 件が市場に参加すると仮定し、文献 [31] の手法を用いて計算した。この条件のもとでは、前日計画を行うアグリゲータが参加する場合と参加しない場合で取引価格は大きく変化せず、このアグリゲータをプライステイカーとみなすことができる。ペナルティ料金 γ_i は、一日前市場の取引価格の 3 倍として与えた。前日計画の際に利用可能なデータとして用いる日射量と気温の予測データは、気象庁提供のデータを利用した。最後に、SoC の初期値 s_i^0 は 0 から 1 の範囲の一様乱数で与えた。

本数値例では、2016 年 4 月 1 日から 2017 年 3 月 31 日の範囲で 3 都道府県分のデータを収集し、それに基づいてモデルを構築する。特に、表 3.1 のようにデータ収集の対象の都道府県を変えた 15 ケースについてシミュレーションを行う。ここでは、欠損を除いた 242 日分のデータが利用可能であり、ランダムに抽出した 193 日分を学習用データとして利用し、残り 49 日分を検証用データとして利用した。したがって、3 都道府県分で学習用データとして 579 個、検証用データとして 147 個のデータを用いた。

3.5.4 結果と考察

それぞれの手法によって 193 日分を学習用データから計画関数を構築し、それぞれの計画関数を用いて、学習に用いていない 49 日分の検証用データからアグリゲータの利益を計算し、1 日あたりの利益の平均値を算出した。また、式 (2.6) の理想的な計画関数を用いて、達成し得る最大の平均利益も同様に算出した。

図 3.2 に、達成し得る最大の平均利益とそれぞれの手法で算出した平均利益との差を示す。図中の淡灰色の棒が本章で提案する手法を用いた場合の結果であり、濃灰色の棒が予測法を用いた場合の結果である。この図から、実験を行った 15 ケースのすべてにおいて、本章で提案する手法を用いたほうが予測法による計画を用いるよりも平均利益が大きく、最大の平均利益に近づいていることがわかる。

続いて、本章で提案する手法が行っている計画について考察する。まず、式 (2.6) により得られた理想的な計画値 \hat{x}_i^* と、それぞれの手法ごとに得られた計画値 \hat{x}_i に対し、

$$\text{RMSE} := \sqrt{\frac{1}{N} \sum_{i=1}^n \|\hat{x}_i - \hat{x}_i^*\|^2}$$

で定義される二乗平均平方根誤差 (root mean square error, RMSE) を計算した。その結果を図 3.3 に

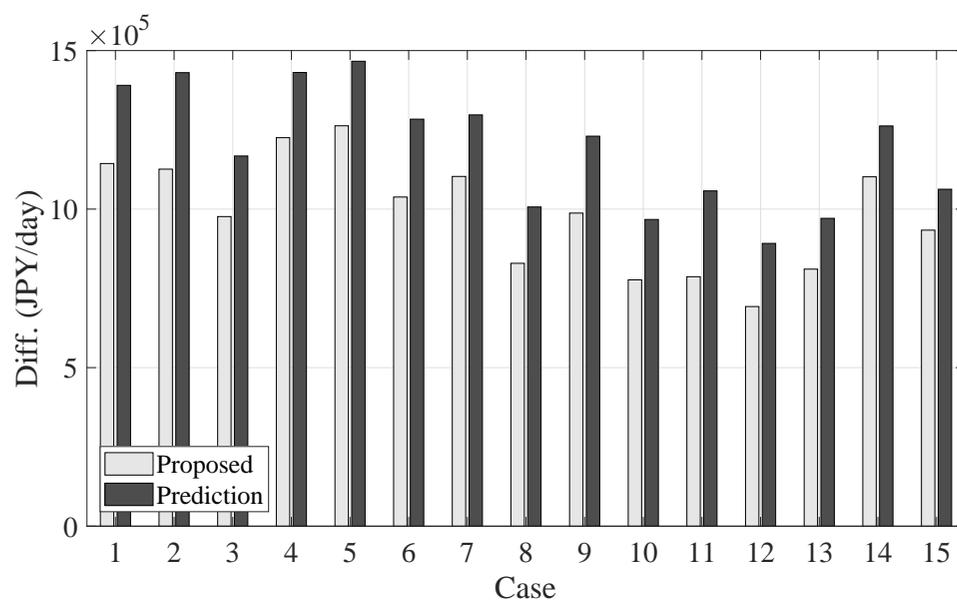


図 3.2 達成し得る最大の平均利益からの差

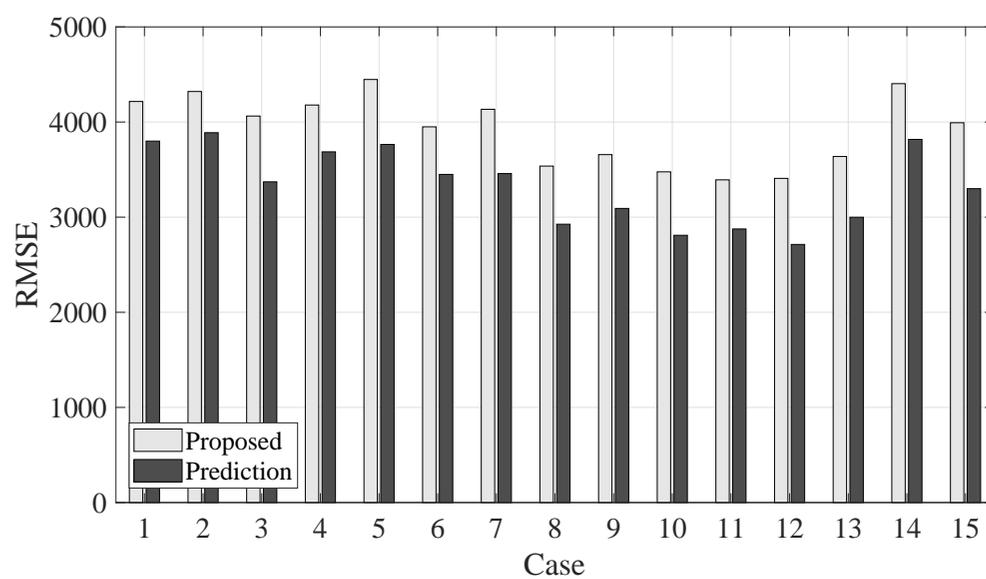


図 3.3 理想的な計画値に対する二乗平均平方根誤差

示す。図 3.3 から、15 ケースのすべてにおいて、提案手法のほうが予測法に比べて RMSE が大きいことが分かる。すなわち、提案手法は理想的な計画値とは異なる計画値を出力していることがわかる。図 3.2 の結果と図 3.3 の結果は、計画値そのものの類似度を高めることが利益の向上に直接的には影響していないということを示唆している。

それぞれの手法により得られる計画値が理想的な計画値 \hat{x}_i^* と比べてどのように異なるのかを調べるため、各手法ごとに得られた計画値 \hat{x}_i との誤差の 1 日の総和を

$$\epsilon_i := \mathbf{1}_n^\top (\hat{x}_i - \hat{x}_i^*)$$

と計算した。ここで、 ϵ_i が正の値であるときは理想的な計画値よりも購入する電力量が少ないことを表し、負の値であるときは理想的な計画値よりも購入する電力量が多いことを表す。各手法ごとに計算した ϵ_i のヒストグラムを図 3.4 に示す。図 3.4 から、予測法を用いた場合は ϵ_i のヒストグラムが 0 を中心にほぼ左右対称であり、正となる場合と負となる場合がほぼ同数で分布していることがわかる。一方で、提案法を用いた場合はやや負の値の方向に分布する様子を見ることができる。したがって、提案法による計画を行うと、理想的な計画に比べて多くの電力を買うことが多い傾向にあることがわかる。この現象は、余った電力は再生可能エネルギー発電を抑制することでコストなしに調整ができるが、不足した電力はペナルティを支払うことでしか調整できないことが要因となっていると考えられる。すなわち、理想的な計画値との誤差が利益に与える影響は正の場合と負の場合で非対称的であると考えられる。以上の結果から、計画関数モデルの学習にアグリゲータが得る利益を評価関数として用いることの有用性が示された。

3.6 本章のまとめ

本章では、線形なパラメータを持つ計画関数モデルとその学習法について述べた。まず、線形なパラメータを持つ計画関数モデルに対して、計画関数モデルの学習問題が凸最適化問題となることを示した。さらに、ペナルティ関数や運用コスト関数が区分的アフィンな凸関数であるという仮定を追加すると、計画関数モデルの学習問題が線形計画問題へと簡単化されることを示した。また、損失関数に \mathcal{L}_2 正則化項を導入した場合、計画関数モデルの学習問題は 2 次計画問題を示した。最後に、数値例を通して、利益を直接評価することの重要性を示した。特に、利益を評価関数とした学習により構築した計画関数モデルは、予測法により構築した計画関数よりも大きな利益を得る前日計画を達成したことを確認した。さらに、提案手法による計画関数モデルは、電力不足による損失に対応するために電力を事前に多めに買うように計画値を出力する傾向にあることが分かった。

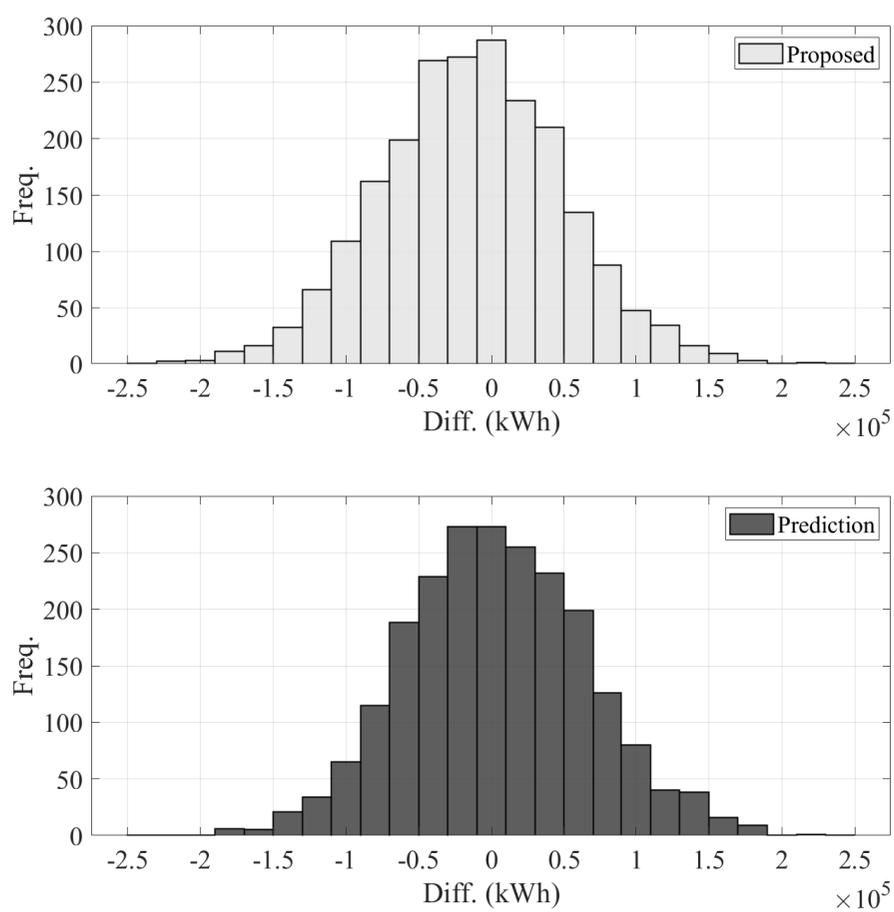


図 3.4 理想的な計画値からの差分に対するヒストグラム

第 4 章

ニューラルネットワークを用いた計画関数モデルと勾配降下法に基づく学習法

4.1 はじめに

第 3 章では，計画関数の形式としてパラメータに関して線形なモデルを仮定し，凸計画問題に帰着することを提案した．これにより，問題 1 で表される計画関数モデルの学習問題の最適パラメータが大域的最適解であることを保証できた．しかし，凸最適化に基づく方法では，最適パラメータを求める最適化問題の計算時間と必要メモリ容量がデータ数の増加に対して 2 乗のオーダーで増加し，大量のデータの利用が困難であるという問題点がある．これに対して，本章では十分に良い局所最適解を得られれば良いという立場をとり，データ数の増加に対応可能なニューラルネットワークを用いることを提案する．まず，ニューラルネットワークを用いた計画関数モデルを定義し，その学習の流れを述べる．特に，勾配降下法に基づいてニューラルネットワークを学習させるために，式 (2.9) で表される損失関数のパラメータに対する勾配を求める方法を示す．その上で，ニューラルネットワークの学習アルゴリズムを示す．最後に，多数データの利用可能性とその効果という観点から，本章で提案する手法と第 3 章で提案する凸最適化に基づく方法で数値例を通して比較を行い，その有用性を検証する．

4.2 ニューラルネットワークを用いた計画関数モデルと勾配降下法に基づく学習法

本節では，ニューラルネットワークを用いた計画関数モデルを定義し，ニューラルネットワークの学習で一般的に用いられる勾配降下法に基づくパラメータ探索法について述べる．

まず、 n_l 個の層をもつニューラルネットワークを用いた計画関数モデルを

$$f(u, \theta) := y^{(n_l)}(u, \theta) \quad (4.1)$$

と定義する。ただし、 $j = 2, \dots, n_l$ に対し、 $y^{(j)}$ を

$$y^{(j)}(u, \theta) := \sigma\left(W^{(j)}y^{(j-1)}(u, \theta) + b^{(j)}\right) \quad (4.2)$$

と定義し、

$$y^{(1)}(u, \theta) := u \quad (4.3)$$

とする。ここで、 $\sigma(\cdot)$ は活性化関数を表し、ユーザが事前に定義する関数である。このモデルにおけるパラメータ θ は

$$\theta := \left(W^{(2)}, \dots, W^{(n_l)}, b^{(2)}, \dots, b^{(n_l)}\right)$$

である。ただし、 $W^{(2)} \in \mathbb{R}^{m_2 \times m}$, \dots , $W^{(n_l)} \in \mathbb{R}^{n \times m_{n_l-1}}$, $b^{(2)} \in \mathbb{R}^{m_2}$, \dots , $b^{(n_l)} \in \mathbb{R}^n$ であり、 m_2, \dots, m_{n_l-1} はそれぞれ各層におけるニューロンの数を表す。

ここでは、最適なパラメータの探索法として、勾配降下法を用いる。勾配降下法では、初期パラメータ θ_0 を設定し、勾配 $\partial L / \partial \theta$ の方向にパラメータを更新する。 k 回目の更新時におけるパラメータを

$$\theta_k := \left(W_k^{(2)}, \dots, W_k^{(n_l)}, b_k^{(2)}, \dots, b_k^{(n_l)}\right)$$

と表したとき、パラメータを

$$\begin{cases} W_{k+1}^{(j)} &= W_k^{(j)} + \Delta W_k^{(j)} \\ b_{k+1}^{(j)} &= b_k^{(j)} + \Delta b_k^{(j)} \end{cases} \quad (4.4)$$

と更新する。ここで、 $j = 2, \dots, n_l$ に対して、 $\Delta W_k^{(2)}, \dots, \Delta W_k^{(n_l)}$ と $\Delta b_k^{(2)}, \dots, \Delta b_k^{(n_l)}$ はパラメータの更新量を表す。例えば、勾配降下法として最急降下法を用いる場合は、ユーザが事前に設定する学習率 $\alpha > 0$ を用いて

$$\begin{aligned} \Delta W_k^{(j)} &= -\alpha \frac{\partial L}{\partial W_k^{(j)}}, \\ \Delta b_k^{(j)} &= -\alpha \frac{\partial L}{\partial b_k^{(j)}} \end{aligned}$$

と計算する。また、近年では ADAM (adaptive moment estimation) [32] などのよりよい更新量の決定法が提案されている。これらの手法においても、一般に勾配 $\partial L / \partial \theta_k$ を用いて更新量を決定する。

上述したように、勾配降下法を用いる場合、一般に更新量決定のために勾配 $\partial L/\partial\theta_k$ が必要となる。勾配 $\partial L/\partial\theta_k$ は、微分の連鎖律に基づき、

$$\begin{aligned}\frac{\partial L}{\partial\theta_k} &= -\frac{1}{N} \sum_{i=1}^N \frac{\partial J_i^*}{\partial\theta_k} \\ &= -\frac{1}{N} \sum_{i=1}^N \frac{\partial\hat{x}_i}{\partial\theta_k} \frac{\partial J_i^*}{\partial\hat{x}_i}\end{aligned}\quad (4.5)$$

と計算することができる。ただし、

$$\hat{x}_i = y^{(n_i)}(u_i, \theta_k) \quad (4.6)$$

である。式 (4.5) のうち、 $\partial\hat{x}_i/\partial\theta_k$ は逆伝播法 [27] により計算できる。したがって、勾配降下法によりパラメータ更新を行うためには、 $\partial J_i^*/\partial\hat{x}_i$ を求めることが必要である。

4.3 勾配の計算法と学習のアルゴリズム

前節で述べたように、勾配降下法によりパラメータの更新を行うために、勾配 $\partial J_i^*/\partial\hat{x}_i$ を計算する必要がある。式 (2.5) で表される J_i^* は、最適化問題の最適値として表現されるため、一般に勾配 $\partial J_i^*/\partial\hat{x}_i$ は明らかでない。そこで本論文では、3.3 節で述べたように、ペナルティ関数 E_i および運用コスト関数 F_i がそれぞれ区分的アフィンな凸関数である場合、 J_i^* を求める問題が線形計画問題へ簡単化されるという事実に着目する。そして、線形計画問題における強双対性を考え、勾配 $\partial J_i^*/\partial\hat{x}_i$ を計算する方法を示す。その上で、本節の最後にニューラルネットワークを用いた計画関数モデルの学習アルゴリズムを示す。

まず、ペナルティ関数 E_i および運用コスト関数 F_i がそれぞれ区分的アフィンな凸関数として式 (3.5), (3.6) で定義されていると仮定する。 $\hat{x}_i = \hat{x}_{i,0}$ において線形計画問題 (3.7) が唯一解をもつ場合、勾配 $\partial J_i^*/\partial\hat{x}_i$ は次の命題に基づいて計算できる。

命題 1. $\hat{x}_i = \hat{x}_{i,0}$ において線形計画問題 (3.7) が唯一解 $(v_i^*, \eta_i^*, \xi_i^*)$ をもつと仮定する。このとき、

$$\left. \frac{\partial \tilde{J}_i^*(\hat{x}_i)}{\partial \hat{x}_i} \right|_{\hat{x}_i = \hat{x}_{i,0}} = \hat{\lambda}_i - (A_i^E)^\top d_i^* \quad (4.7)$$

が成立する。ただし、

$$\tilde{J}_i^*(\hat{x}_i) := \max_{v_i, \eta_i, \xi_i} \tilde{J}_i(\hat{x}_i, v_i, \eta_i, \xi_i)$$

である。また、 $d_i^* \in \mathbb{R}^{n_{E_i}}$ は不等式 $A^{E_i}(\hat{x}_i - x_i(v_i; w_i)) + b^{E_i} \leq \eta_i \mathbf{1}_{n_{E_i}}$ に関する双対変数の最適値である。

証明. 線形計画問題における強双対性 [26] から,

$$\tilde{J}_i^*(\hat{x}_{i,0}) = \hat{\lambda}_i^\top \hat{x}_{i,0} - (d_i^*)^\top A^{E_i} \hat{x}_{i,0} - \Delta \quad (4.8)$$

が成立する. ここで, Δ は線形計画問題 (3.7) の制約条件によって定まる, \hat{x}_i に依存しない量である. したがって, 式 (4.8) の勾配を求めることで, 命題は成立する. \square

注意 1. 線形計画問題 (3.7) の制約条件は \hat{x}_i によって決まり, \hat{x}_i の値によっては線形計画問題 (3.7) は無数の解を持つことがある. $\hat{x}_i = \hat{x}_{i,1}$ において解が無数に存在するとき, $\tilde{J}_i^*(\hat{x})$ は $\hat{x}_i = \hat{x}_{i,1}$ において微分不可能となり, その点において勾配を定義することができない. ただし, 関数 \tilde{J}_i^* は, \hat{x}_i に対して区分的アフィンな凹関数となるという事実 [33] から, 不等式 $A^{E_i}(\hat{x}_i - x_i(v_i; w_i)) + b^{E_i} \leq \eta_i \mathbf{1}_{n_{E_i}}$ に関する双対変数の最適値のうちの一つ \bar{d}_i^* を求めることができれば,

$$\hat{\lambda}_i - (A^{E_i})^\top \bar{d}_i^* \quad (4.9)$$

は凹関数 \tilde{J}_i^* の $\hat{x}_i = \hat{x}_{i,1}$ における劣勾配の要素のひとつとなる [34]. ここで, 凹関数 $f: \mathbb{R}^n \rightarrow \mathbb{R}$ に対し,

$$\partial f(x) := \{a \in \mathbb{R}^n \mid f(y) \leq f(x) + a^\top (y - x), \forall y \in \mathbb{R}^n\}$$

を $x \in \mathbb{R}^n$ における劣勾配 $\partial f(x)$ と呼ぶ. この観点から, ここでは唯一解をもたない点 $\hat{x}_i = \hat{x}_{i,1}$ において, 式 (4.9) を勾配の代わりに用いる. この方法は劣勾配法 [35] として知られており, 更新履歴の中の評価値が最小となるパラメータを選ぶことで, 局所的な最適値へと近づくことが知られている.

命題 1 を用いると, 勾配 $\partial J_i^* / \partial \hat{x}_i |_{\hat{x}_i = \hat{x}_{i,0}}$ を求めることができる. この勾配を用いて, 最適なパラメータ θ^* を Algorithm 1 に基づいて探索する.

第3章で述べた凸最適化に基づく方法では, 最適なパラメータ θ^* を求めるために式 (3.9) で表される, すべてのデータを用いた大規模な線形計画問題を解く必要があった. これに対し, 本章で提案するニューラルネットワークを用いる手法では, 日ごとのデータに対して式 (3.7) で表される線形計画問題を解けばよいため, 凸最適化に基づく方法に比べ必要なメモリ容量が削減される. これにより, ニューラルネットワークを用いることで, 多数のデータを学習に利用できると考えられる.

注意 2. 一般に, 勾配降下法に基づいてパラメータの更新を行う場合, 極小点に代表される, 勾配が 0 となる点で学習が進まなくなる. これに対し, 深層学習の研究においては, 真の最小点でなくとも, 十分に評価関数値が小さい極小点が求まっていれば十分な性能を示すことが報告されている [36]. しかし, 評価関数値が大きな極小点に留まってしまう場合もあり, これを避けることが望ましいと考えられ

る。この問題を避けるために、パラメータ更新量 $\Delta W_k^{(2)} \dots \Delta W_k^{(n_l)}$ と $\Delta b_k^{(2)} \dots \Delta b_k^{(n_l)}$ の計算に確率的な要素を加えることが考えられる。そのような方法の中ではミニバッチ学習と呼ばれる手法が広く用いられている。ここでは、ミニバッチ学習の流れを述べる。

まず、ミニバッチ $\mathcal{B}_1, \dots, \mathcal{B}_{n_B}$ を、

$$\bigcup_{j=1}^{n_B} \mathcal{B}_j = \{1, \dots, N\}$$

かつ、互いに素となるようにランダムに設定する。そして、ミニバッチ \mathcal{B}_j に対する評価関数を

$$L^j(\theta) := -\frac{1}{|\mathcal{B}_j|} \sum_{i \in \mathcal{B}_j} J_i^*(f(u_i, \theta); p_i, l_i) \quad (4.10)$$

と設定し、 $\partial L/\theta_k$ を用いる代わりに $\partial L^j/\theta_k$ を用いてパラメータを更新する。ただし、 $|\mathcal{B}_j|$ は \mathcal{B}_j に含まれる要素の個数である。すべてのミニバッチ $\mathcal{B}_1, \dots, \mathcal{B}_{n_B}$ を用いてパラメータを更新したあと、ミニバッチ $\mathcal{B}_1, \dots, \mathcal{B}_{n_B}$ の要素をランダムに決定しなおす。以上の手続きをまとめると、Algorithm 2 となる。本章で提案する手法においても、ミニバッチ学習を行ったほうが効率的に学習が進む場合が多いため、以下で述べる数値例においてもミニバッチ学習を利用する。

Algorithm 1 Training of scheduling model

Require: $u_i, p_i, l_i, \hat{\lambda}_i$ for each $i = 1, \dots, N$ and $\epsilon > 0$

- 1: Set $\theta_0 := (W_0^{(2)}, \dots, W_0^{(n_l)}, b_0^{(2)}, \dots, b_0^{(n_l)})$
 - 2: Set $k = 0$
 - 3: **repeat**
 - 4: **for** $i = 1, \dots, N$ **do**
 - 5: Compute $\hat{x}_i = y^{(n_l)}(u_i, \theta_k)$
 - 6: Compute $J_i^*(\hat{x}_i; w_i)$ by solving the linear programming (3.7)
 - 7: Compute $\partial J_i^*/\partial \hat{x}_i$ by (4.7)
 - 8: **end for**
 - 9: Compute $\partial L/\partial \theta_k$ by the back propagation method
 - 10: Compute $L(\theta_k)$ by (2.9)
 - 11: Update the parameter by (4.4)
 - 12: $k \leftarrow k + 1$
 - 13: **until** $|L(\theta_k) - L(\theta_{k-1})| < \epsilon$
 - 14: Return $\theta^* = \theta_k$
-

Algorithm 2 Mini batch training

Require: $u_i, p_i, l_i, \hat{\lambda}_i$ for each $i = 1, \dots, N$ and $\epsilon > 0$

- 1: Set $\theta_0 := (W_0^{(2)}, \dots, W_0^{(n_l)}, b_0^{(2)}, \dots, b_0^{(n_l)})$
 - 2: Set $k = 0$
 - 3: Set $\mathcal{B}_1, \dots, \mathcal{B}_{n_b}$
 - 4: **repeat**
 - 5: **for** $j = 1, \dots, n_B$ **do**
 - 6: **for** $i \in \mathcal{B}_j$ **do**
 - 7: Compute $\hat{x}_i = y^{(n_l)}(u_i, \theta_k)$
 - 8: Compute $J_i^*(\hat{x}_i; w_i)$ by solving the linear programming (3.7)
 - 9: Compute $\partial J_i^* / \partial \hat{x}_i$ by (4.7)
 - 10: **end for**
 - 11: Compute $\partial L^j / \partial \theta_k$ by the back propagation method
 - 12: Update the parameter by (4.4)
 - 13: $k \leftarrow k + 1$
 - 14: **end for**
 - 15: Reset $\mathcal{B}_1, \dots, \mathcal{B}_{n_b}$
 - 16: **until** $|L(\theta_k) - L(\theta_{k-1})| < \epsilon$
 - 17: Return $\theta^* = \theta_k$
-

4.4 数値例

4.4.1 検証内容

本節では、ニューラルネットワークを用いた計画関数モデルの有用性を、学習データ数の増加による効果という観点から検証する。すなわち、本数値例では学習に利用するデータの個数を変化させながら、利益の変化の様子を調べる。さらに、3.2節で述べた凸最適化に基づく方法により線形回帰型の計画関数モデルを構築し、ニューラルネットワークを用いた計画関数モデルと比較を行う。

ここでは、隠れ層が4層の $n_l = 5$ となるニューラルネットワークを考える。各隠れ層のサイズはそれぞれ $m_2 = 50, m_3 = 60, m_4 = 50$ と設定する。これらの値は、学習時間を数時間以内に収めつつ、十分な性能となるよう、試行錯誤を行い決定した。また、活性化関数 $\sigma(y)$ として、

$$\sigma(y) := \max\{y, ay\}$$

と表される Leaky rectified linear unit を用いる。ただし、 a はスカラーのパラメータであり、一般によく用いられる値として $a = 0.2$ と設定した。そして、ニューラルネットワークのパラメータ $W^{(2)}, \dots, W^{(5)}, b^{(2)}, \dots, b^{(5)}$ の更新には、ADAM [32] を用いる。

凸最適化に基づく線形回帰モデルは、3.5.1節で述べた、線形基底による計画関数モデルを用いる。また、最適なパラメータは、式 (3.9) で表される最適化問題を解くことにより求める。

最後に、参考値として達成し得る平均利益の最大値を式 (2.6) から求める。

4.4.2 想定する状況と使用するデータセット

この数値例では、1日に12回、2時間ごとに取引が行われる一日前市場を想定する。本数値例におけるアグリゲータの想定は、3.5.2節で述べたものと同じである。本数値例で用いるペナルティ関数 E_i と運用コスト関数 F_i も、3.5.2節で用いたものと同じ関数を用いる。

太陽光発電量の実測データ p_i 、負荷の実測データ l_i 、取引価格のデータ $\hat{\lambda}_i$ 、ペナルティ料金 γ_i 、充電率の初期値 s_i^0 の出典および計算方法は、3.5.3節で述べたものと同様である。3.5.3節で述べたように、上記のデータは2016年4月1日から2017年3月31日の範囲のうち、欠損を除いた242日分のデータが利用可能である。本数値例では、ランダムに抽出した218日分を学習用データとして利用し、残り24日分を検証用データとして用いた。これらのデータを47都道府県分集め、学習用データとして最大10246個、検証用データとして1128個のデータを用いた。

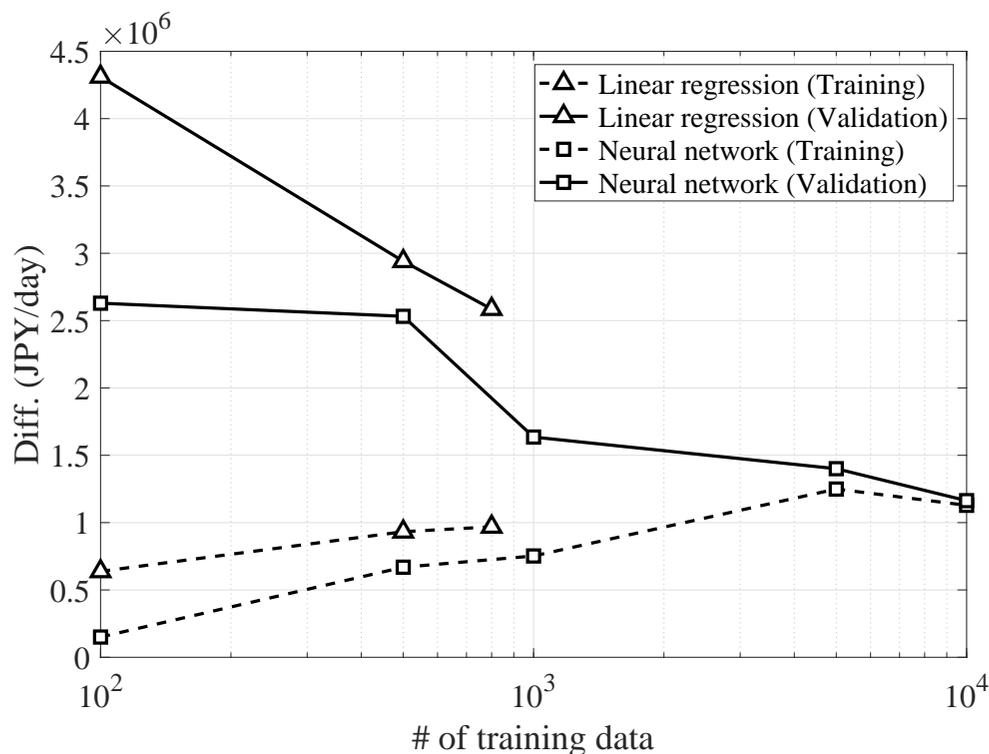


図 4.1 学習データ数に対する達成し得る最大の平均利益からの差

4.4.3 結果と考察

ニューラルネットワークを用いた計画関数モデルと、凸最適化に基づく線形回帰を用いた計画関数モデルに対し、学習用データと検証用データを用いてそれぞれ平均利益を計算した。それぞれの手法で計算した平均利益に対し、達成し得る最大の平均利益からの差を計算した。利用した学習データの個数に対する達成し得る最大の平均利益からの差の推移を図 4.1 に示す。図中の実線は検証用データに対する結果であり、破線は学習用データに対する結果を表す。また、三角の点によるプロットは凸最適化を用いた線形回帰による結果であり、四角の点によるプロットはニューラルネットワークによる結果である。図 4.1 から、どちらの手法においても、学習用データの個数が増加すると、未知の検証用データに対する平均利益が増加し、達成し得る平均利益へ近づく傾向にあることがわかる。逆に、学習用データに対する平均利益と達成し得る平均利益との差が広がる傾向にあることがわかる。ここで、学習用データが最も少ない場合、学習用データに対する達成し得る平均利益からの差が最も近いことがわかる。これは、学習用データの個数が少ないときには、数少ないデータに対して過学習していることを意味している。逆に言えば、学習用データの個数を増やすことによって、過学習が抑制されていると考えられる。

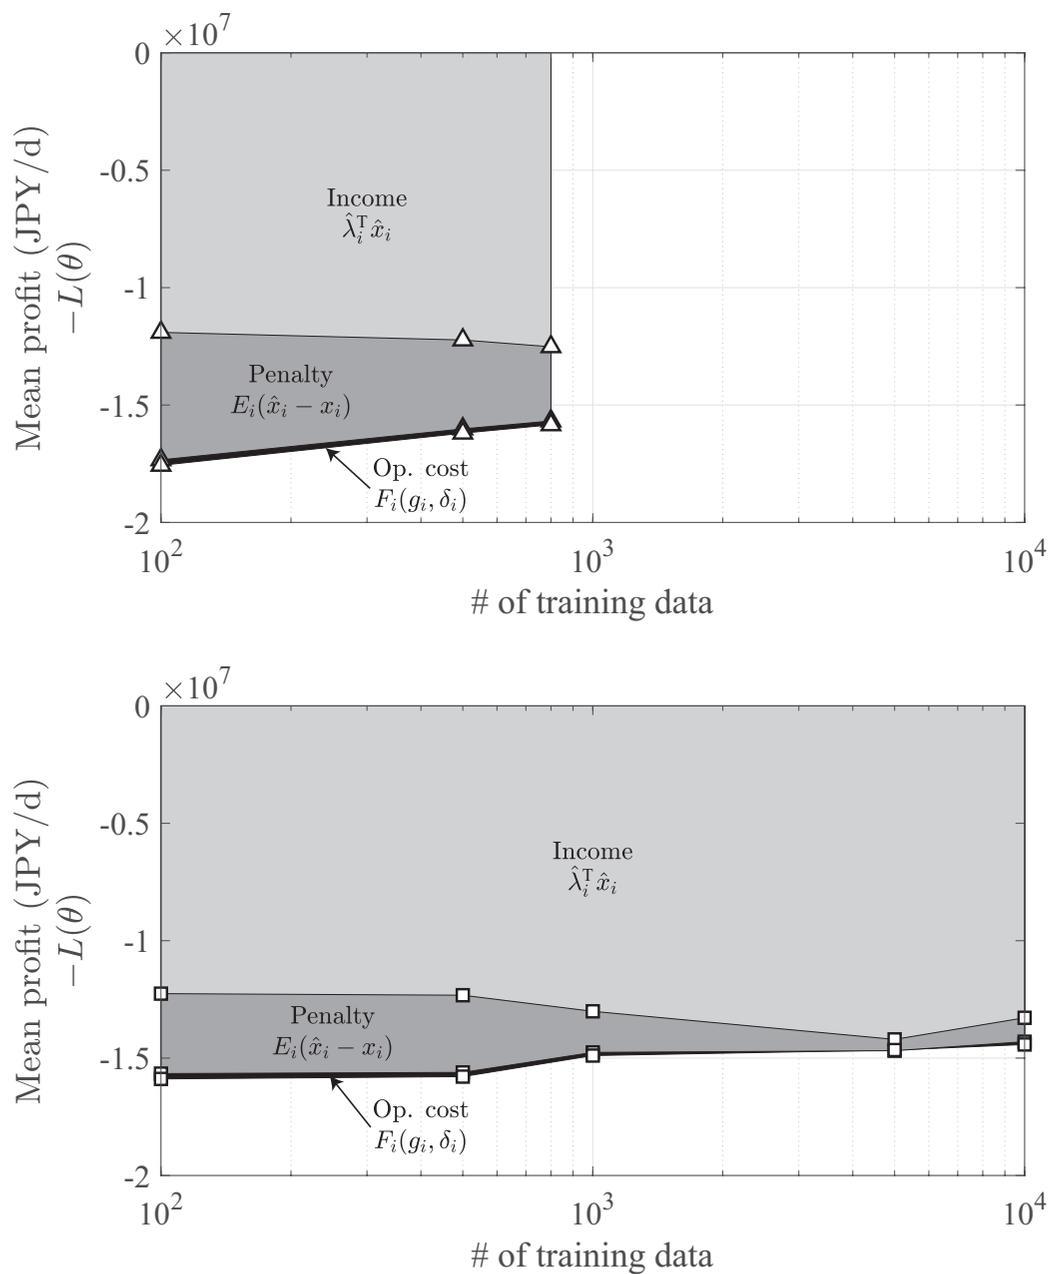


図 4.2 平均利益の内訳

本数値実験は合計 192 GB のメモリを搭載したワークステーション上で実施している。この計算機環境で凸最適化に基づく方法を用いて線形回帰モデルを学習させた場合、学習用データが 800 個より大きい範囲ではメモリ容量が不足し、学習できなかった。メモリが不足する原因として、凸最適化に基づく方法では、すべての学習用データを用いた最適化問題 (3.9) を解かなければならないことが考えられる。本数値例の場合、制約条件の数は $N(4n + n_E + n_F)$ であるため、線形不等式制約の表現に必要な行列を保存するために必要なメモリ容量が制約条件の数の 2 乗のオーダーで増加してしまう。したがって、学習用データの個数の 2 乗のオーダーで必要メモリ容量が増加してしまう。一方で、ニューラルネットワークを用いて学習を行う場合は、日ごとの学習用データに対する最適化問題 (3.7) を解くだけでよい。本数値例の場合、制約条件の数は $4n + n_E + n_F$ であり、学習用データの個数の増加に対して必要なメモリの容量は増加しない。したがって、本章で提案する手法では多数の学習データを用いた学習を行うことができる。その結果、多数データの利用によって過学習が抑制され、検証データに対するアグリゲータの平均利益が増加したと考えられる。

さらに、学習用データが 800 個より少ない領域を見ると、線形基底を用いた線形回帰モデルよりもニューラルネットワークを用いたほうが平均利益が増大している傾向にあることがわかる。この結果から、ニューラルネットワークの非線形性を用いることで、より良い計画関数を表現できたと考えられる。

次に、本数値例で計算した平均利益の内訳として、収入とペナルティコスト、運用コストを図 4.2 に示す。図 4.2 において、上段のプロットが線形回帰モデルによる結果、下段のプロットがニューラルネットワークによる結果である。また、淡灰色のエリアが収入、濃灰色のエリアがペナルティコスト、黒色のエリアが運用コストを表している。この図から、利益のうち運用コストが占める割合は非常に小さく、収入とペナルティコストが利益に対して支配的であることがわかる。また、データ数の変化に対する収入とペナルティコストの変化を見ると、支出（負の収入 $-\hat{\lambda}_i^T \hat{x}_i$ ）が増加しているのに対して、ペナルティコストは減少傾向にあることがわかる。この結果から、学習データ数を増加させると、電力を多めに購入するように計画する代わりにインバランスが抑えられるような学習が行われていると考えられる。この傾向は、3.5.4 節で述べた結果と一致している。一方で、ニューラルネットワークの結果の図において、学習データ数が 10000 個と 5000 個の場合に注目すると、10000 個の場合はペナルティが大きくなっているのに対して支出は小さくなっている。これは、市場から購入する電力量を大きくしてペナルティを抑えることが必ずしも平均利益の向上につながるわけではないことを意味しており、収入とペナルティのバランスをうまく調整するように計画するべきであることを示唆している。ここでは、多様なデータを用いた学習により、よりバランスの良い計画を行うモデルが得られたと考えられる。

最後に、パラメータの探索に関する考察を述べる。本章で提案したニューラルネットワークによる計画関数モデルは、凸最適化に基づく方法と異なり、学習により得られるパラメータが大域的な最適解と

なる保証がない。本章で述べた学習アルゴリズムによって得られるパラメータの性質を調べるために、ニューラルネットワークのパラメータの初期値を異なる乱数により5種類用意して学習し、同様の実験を行った。その結果、10000個の学習データを用いたとき、検証データに対する平均利益はそれぞれ 1.44×10^7 , 1.43×10^7 , 1.45×10^7 , 1.44×10^7 , 1.43×10^7 JPY/day となった。なお、ここで用いている10000個の学習データは、図4.1の結果で用いているものと同じものである。これに対し、図4.1の検証データに対する平均利益は 1.44×10^7 JPY/day であった。以上の結果から、異なる初期値から学習を行ったとしても得られる利益に大きな変化はないことがわかる。したがって、図4.1の結果は特別に良い局所解から採用しているわけではなく、同等の結果を得られるパラメータは比較的容易に求めることができると考えられる。

4.5 本章のまとめ

本章では、ニューラルネットワークを用いた計画関数モデルを提案し、その学習アルゴリズムについて述べた。特に、ニューラルネットワークの学習を勾配降下法に基づいて行うために、利益のパラメータに対する勾配の計算方法を述べた。具体的には、ペナルティ関数や運用コスト関数が区分的アフィンな凸関数であるという仮定のもとで、利益を計算する線形計画問題の強双対性に基づいて勾配を求める方法を示した。最後に、数値例を通してニューラルネットワークを用いた場合の多数データ利用可能性とその効果を検証した。この検証により、ニューラルネットワークを用いると、非線形性に対応しながら多数の学習データを用いることが可能となることを確認した。さらに、学習データを多数用いることで過学習が抑制され、未知のデータに対しても良好な性能を示すことがわかった。

第 5 章

結論

5.1 研究のまとめ

本論文では、再生可能エネルギーの不確かさのもとで、機械学習の手法を応用した一日前市場における前日計画法を提案した。

まず、第 2 章では一日前市場における前日計画とアグリゲータの得る利益を定式化した。その上で、アグリゲータの利益を最大化する理想的な前日計画法を考え、それを近似的に達成するために、過去のデータに対する利益を最大化するような計画関数モデルを機械学習に基づいて構築することを提案した。そして、計画関数モデルをパラメトリックなブラックボックスモデルとして定義し、計画関数モデルの学習問題を、利益を最大化するパラメータの最適化問題として定式化した。

第 3 章では、計画関数モデルとして線形なパラメータを持つモデルを用いた場合における学習法について述べた。このとき、最適パラメータを探索する問題は、凸最適化問題として定式化できることを示した。また、ペナルティ関数と運用コスト関数が区分的アフィンな凸関数で表せるという仮定を追加すると、最適パラメータの探索問題は線形計画問題となることを示した。さらに、学習の評価関数の中に \mathcal{L}_2 正則化の項を追加した場合は、2 次計画問題となることを示した。最後に、数値例を通して利益を直接評価することの重要性を確認した。その結果、提案手法による計画を行うことで、再生可能エネルギーや負荷の予測を用いた計画よりも大きな利益を得ることができることを確認した。さらに、提案手法を用いた計画では、予測を用いた計画に比べて事前に多くの電力を買うように計画することで、電力不足による損失へ対応している傾向にあることが分かった。

第 4 章では、計画関数モデルにニューラルネットワークを用いた場合における学習法について述べた。第 3 章で述べた凸最適化に基づく方法では、解くべき最適化問題の計算時間と必要メモリ容量がデータ数の増加に対して 2 乗のオーダーで増加するため、多数のデータを用いることが困難であること

が問題であった。そこで、データ数の増加に対して有効なニューラルネットワークを計画関数モデルとして用いることを考え、その学習法を述べた。特に、勾配降下法によってニューラルネットワークの学習を行うために、利益のパラメータに対する勾配の計算方法を述べた。具体的には、ペナルティ関数や運用コスト関数が区分的アフィンな凸関数であるという仮定のもとで、利益を計算する線形計画問題の強双対性に基づいて勾配を計算する方法を示した。最後に、多数データの利用の観点から、勾配降下法により学習したニューラルネットワークを用いた計画関数モデルと、凸最適化により学習した線形なパラメータを持つ計画関数モデルを、数値例を通して比較した。この検証により、ニューラルネットワークを用いることで、非線形性に対応しながら多数の学習データを用いることが可能となることを確認した。さらに、多数の学習データを用いることで過学習が抑制され、未知のデータに対しても平均利益が向上することがわかった。

5.2 今後の課題

本論文で提案した手法は、アグリゲータがプライステイカーであり、取引価格が事前に与えられることを仮定していた。しかし、アグリゲータが扱う電力の規模が大きくなると、アグリゲータが取引する電力量や当日の電力運用によって取引価格やペナルティ料金が変動する。また、系統全体の安定性を保つために、アグリゲータの取引量の調整を意図して市場の運営者が取引価格を調整する場合がある。これらの観点から、価格の変動や複数の市場参加者を考慮した前日計画法を考えることが今後の課題である。また、エネルギーの有効活用の観点から、ペナルティ回避のために再生可能エネルギーの発電抑制を行うことは望ましくない。この観点から、再生可能エネルギーの活用を促進するためには、アグリゲータが発電抑制を回避しながらインバランスを抑えるように計画することが望ましいと言える。アグリゲータが自発的に発電抑制を回避するように計画するためには、当日の余剰電力を少額で買い取るなど、余剰電力を有効利用することがアグリゲータの利益につながるような仕組みが必要であると考えられる。再生可能エネルギーの有効活用を促進する電力市場メカニズムを考えることも今後の課題である。

参考文献

- [1] 資源エネルギー庁：電力システムに関する改革方針， (2013)
- [2] 電力広域的運営推進機関， <https://www.occto.or.jp/>
- [3] 井村， 原：太陽光発電のスマート基幹電源化， 日刊工業新聞社 (2019)
- [4] 八田達夫：電力競争市場の基本構造， RIETI Discussion Paper Series, **04-J-029** (2004)
- [5] J. Matevosyan and L. Soder: Minimization of Imbalance Cost Trading Wind Power on the Short-term Power Market, IEEE Transactions on Power Systems, **21-3**, 1396/1404 (2006)
- [6] J. Morales, A. Conejo and J. Pérez-Ruiz: Short-Term Trading for a Wind Power Producer, Power Systems, IEEE Transactions on, **25**, 554 / 564 (2010)
- [7] L. Shi, Y. Luo and G. Tu: Bidding strategy of microgrid with consideration of uncertainty for participating in power market, International Journal of Electrical Power & Energy Systems, **59**, 1 / 13 (2014)
- [8] T. Bo, T. Ishizaki, M. Koike, N. Yamaguchi and J. Imura: Optimal Bidding Strategy for Multiperiod Electricity Market with Consideration of PV Prediction Uncertainty, in 2017 56th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE), 293/298 (2017)
- [9] E. Y. Bitar, R. Rajagopal, P. P. Khargonekar, K. Poolla and P. Varaiya: Bringing Wind Energy to Market, IEEE Transactions on Power Systems, **27-3**, 1225/1235 (2012)
- [10] A. Giannitrapani, S. Paoletti, A. Vicino and D. Zarrilli: Bidding Wind Energy Exploiting Wind Speed Forecasts, IEEE Transactions on Power Systems, **31-4**, 2647/2656 (2016)
- [11] Y. Chu, M. Li, H. T. Pedro and C. F. Coimbra: Real-time prediction intervals for intra-hour DNI forecasts, Renewable Energy, **83**, 234 / 244 (2015)
- [12] H. T. Pedro and C. F. Coimbra: Short-term irradiance forecastability for various solar micro-climates, Solar Energy, **122**, 587 / 602 (2015)

- [13] E. Akarslan and F. O. Hocaoglu: A novel adaptive approach for hourly solar radiation forecasting, *Renewable Energy*, **87**, 628 / 633 (2016)
- [14] I. A. Ibrahim and T. Khatib: A novel hybrid model for hourly global solar radiation prediction using random forests technique and firefly algorithm, *Energy Conversion and Management*, **138**, 413 / 425 (2017)
- [15] L. M. Aguiar, B. Pereira, P. Lauret, F. Díaz and M. David: Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting, *Renewable Energy*, **97**, 599 / 610 (2016)
- [16] J. Liu, W. Fang, X. Zhang and C. Yang: An Improved Photovoltaic Power Forecasting Model With the Assistance of Aerosol Index Data, *IEEE Transactions on Sustainable Energy*, **6-2**, 434/442 (2015)
- [17] A. Vaz, B. Elsinga, W. van Sark and M. Brito: An artificial neural network to assess the impact of neighbouring photovoltaic systems in power forecasting in Utrecht, the Netherlands, *Renewable Energy*, **85**, 631 / 641 (2016)
- [18] M. Rana, I. Koprinska and V. G. Agelidis: Univariate and multivariate methods for very short-term solar photovoltaic power forecasting, *Energy Conversion and Management*, **121**, 380 / 390 (2016)
- [19] 大竹, 宇野, 大関, 山田: 最新の気象庁現業数値予報モデルの日射量予測の検証, *電気学会論文誌B (電力・エネルギー部門誌)*, **138-11**, 881/892 (2018)
- [20] T. T. Teo, T. Logenthiran, W. L. Woo and K. Abidi: Near-Optimal Day-Ahead Scheduling of Energy Storage System in Grid-Connected Microgrid, in *2018 IEEE Innovative Smart Grid Technologies*, 1257/1261 (2018)
- [21] Y. Luo, M. Xian, M. Mohanpurkar, B. P. Bhattarai, A. Medarn, R. Kadavil and R. Hovsopian: Optimal Scheduling of Electrolyzer in Power Market with Dynamic Prices, in *2018 IEEE International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*, 1/6 (2018)
- [22] E. Mocanu, D. C. Mocanu, P. H. Nguyen, A. Liotta, M. E. Webber, M. Gibescu and J. G. Sloopweg: On-Line Building Energy Optimization Using Deep Reinforcement Learning, *IEEE Transactions on Smart Grid*, **10-4**, 3698/3708 (2019)
- [23] Z. Wan, H. Li, H. He and D. Prokhorov: Model-Free Real-Time EV Charging Scheduling Based on Deep Reinforcement Learning, *IEEE Transactions on Smart Grid*, **10-5**, 5246/5257

- (2019)
- [24] A. Rahimi-Kian, B. Sadeghi and R. J. Thomas: Q-learning Based Supplier-agents for Electricity Markets, in IEEE Power Engineering Society General Meeting, 2005, 420/427 Vol. 1 (2005)
- [25] D. Peteiro-Barral and B. Guijarro-Berdiñas: A Study on the Scalability of Artificial Neural Networks Training Algorithms Using Multiple-Criteria Decision-Making Methods, in Artificial Intelligence and Soft Computing, 162/173 (2013)
- [26] S. Boyd and L. Vandenberghe: Convex Optimization, Cambridge University Press (2004)
- [27] C. Bishop: Pattern Recognition and Machine Learning, Springer (2006)
- [28] H. Takenaka, T. Y. Nakajima, A. Higurashi, A. Higuchi, T. Takamura, R. T. Pinker and T. Nakajima: Estimation of Solar Radiation Using a Neural Network Based on Radiative Transfer, Journal of Geophysical Research, **116** (2011)
- [29] 石塚, 渡邊, 川口, 石崎, 井村, 佐々木, 植田: 業務用電力需要のクラスタリングと気温応答モデルの構築, 第6回制御部門マルチシンポジウム, IF2-5 (2019)
- [30] 石塚, 渡邊, 川口, 石崎, 井村, 佐々木, 植田: 気温応答性を考慮した業務用電力需要データセットの作成, 平成31年電気学会全国大会, 6-137 (2019)
- [31] T. Ishizaki, M. Koike, N. Yamaguchi, Y. Ueda and J. Imura: Day-Ahead Energy Market as Adjustable Robust Optimization: Spatio-Temporal Pricing of Dispatchable Generators, Storage Batteries, and Uncertain Renewable Resources, ArXiv e-prints, 1803.04751 (2019)
- [32] D. P. Kingma and J. Ba: Adam: A Method for Stochastic Optimization, ArXiv e-prints (2014)
- [33] F. Borrelli, A. Bemporad and M. Morari: Geometric Algorithm for Multiparametric Linear Programming, Journal of Optimization Theory and Applications, **118-3**, 515/540 (2003)
- [34] 福島雅夫: 非線形最適化の基礎, 朝倉書店 (2001)
- [35] S. Boyd, L. Xiao and A. Mutapcic: Subgradient Methods, notes of EE392o, Stanford University (2003)
- [36] A. Choromanska, M. Henaff, M. Mathieu, G. Ben Arous and Y. LeCun: The loss surfaces of multilayer networks, Artificial intelligence and statistics, **38**, 192/204 (2015)

研究業績（本論文該当）

- [1] F. Watanabe, T. Kawaguchi, T. Ishizaki, H. Takenaka, T. Y. Nakajima and J. Imura: Machine Learning Approach to Day-ahead Scheduling for Multi-period Energy Markets under Renewable Energy Generation Uncertainty, in 57th IEEE Conference on Decision and Control, 4020/4025 (2018)
- [2] F. Watanabe, T. Kawaguchi, T. Ishizaki, H. Takenaka, T. Y. Nakajima and J. Imura: Day-ahead Strategic Marketing of Energy Prosumption: A Machine Learning Approach Based on Neural Networks, in 2019 European Control Conference, 3910/3915 (2019)
- [3] 渡邊, 川口, 石崎, 竹中, 中島, 井村: 電力市場のための機械学習に基づく前日スケジューリング, 計測自動制御学会論文集, **55-10**, 593/601 (2019)
- [4] 渡邊, 川口, 石崎, 竹中, 中島, 井村: ニューラルネットワークを用いた電力市場における前日計画法 — 再生可能エネルギーの不確かさのもとでの取引戦略 —, 計測自動制御学会論文集, **56-2** (2020, 掲載予定)

研究業績（本論文該当以外）

- [1] F. Watanabe, T. Sadamoto, T. Ishizaki and J. Imura: Average state kalman filters for large-scale stochastic networked linear systems, in 2015 European Control Conference, 2818/2823 (2015)
- [2] 渡邊, 定本, 石崎, 井村: 大規模線形ネットワークシステムに対する平均値カルマンフィルタ, 計測自動制御学会論文集, **52**-8, 419/427 (2016)

謝辞

本研究を進めるにあたり，指導教員の井村順一先生には研究内容や論文・発表の内容など，多大なご指導を頂きました。心より深く感謝し，御礼を申し上げます。また，本論文の副査をしていただきました藤田政之先生，三平満司先生，山北昌毅先生，早川朋久先生に御礼を申し上げます。

私が所属する井村研究室の皆様には，研究に関して様々なアドバイスをいただきました。特に，石崎孝幸先生，川口貴弘先生には，日頃から研究内容の相談，論文の書き方など非常に多くのご指導を頂きました。心から感謝いたします。また，研究生活を送る上でともに頑張ってきた井村研究室，早川研究室および中臺研究室の学生の皆様に感謝いたします。

本論文における数値実験を行うにあたり，データ取得の部分でご協力をいただきました宇宙航空研究開発機構・竹中栄晶様，東海大学・中島孝先生，産業技術総合研究所・大竹秀明様，東京理科大学・山口順之先生に感謝いたします。また，電力需要データの作成に協力していただいた井村研究室の石塚諒君に感謝いたします。

最後に，長い学生生活を支えてくださった両親に深く感謝いたします。