

# AHSES (Adjusting to Human Smart Energy System) の開発 その2 電力需要予測の高度化およびAHSES トライアル版の開発

宮川 忠明<sup>\*1</sup>・村石 辰徳<sup>\*2</sup>・森 一顕<sup>\*3</sup>・岩本 吉隆<sup>\*3</sup>

エネルギーマネジメントシステムにおいて、電力需要の予測は重要な機能の一つである。前報(その1:2016)<sup>1)</sup>にて述べた自己回帰による予測モデルは、気象要因や建物の利用状況等、明らかに電力需要と相関関係を持つ要因を考慮できないことが課題だった。このような課題を解決するため、機械学習手法であるディープラーニングに着目し、新たな電力需要予測システムを構築した。また、建物で使用する電力の特性にあわせた太陽電池・蓄電池の利用効果を、設備導入の検討段階で建物利用者自身が容易に把握できる再エネ・蓄エネ導入支援システム『AHSES トライアル版』を開発した。

キーワード：EMS, AHSES, 電力需要予想, ディープラーニング, ニューラルネットワーク, 最適化

## 1. はじめに

2015年12月12日、パリで開催された国連気候変動枠組条約第21回締約国会議(COP21)において、世界の気温上昇を2度未満に抑えるための取り組みが合意され、パリ協定が採択された。その後、55か国以上が参加すること、世界の温室効果ガス総排出量のうち55%以上をカバーする国が批准することという条件が満たされ、2016年11月4日、同協定が発効された。2017年8月時点では、159か国・地域(世界の温室効果ガス排出量の約86%)が批准している。

温室効果ガス排出量シェアを国別で見ると、1位中国(23.2%)、2位米国(13.6%)、3位EU(10.0%)、インド、ロシア、インドネシア、ブラジルと続き、日本は8位で2.7%である<sup>2)</sup>。このパリ協定の枠組みを受けて、日本では、2030年度の温室効果ガスの排出を2013年度の水準から26%削減することが目標として定められた。

この目標を達成するためには、再生可能エネルギーの導入を増やすなどの施策が必要であり、2018年7月3日に発表となった「第5次エネルギー基本計画」において、2030年のエネルギーの姿を示した「エネルギーミックス」の中で、再生可能エネルギー比率の目標値が示された。図-1に2030年のエネルギーミックスを示す。再生可能エネルギーの比率を、2016年度の15%に対し、2030年度は22%~24%まで増やす計画である。

このように、低炭素社会の実現に向け、再生可能エネルギーの普及が課題となっていることを踏まえ、我々は太陽電池と蓄電池を組み合わせるエネルギーを賢く運用するスマートエネルギーシステム「AHSES」の開発に取り組んでいる。前報(その1:2016)では、AHSESの構

成やシステムの根幹である需要予測と最適運転計画の手法、実証試験において17%のピークカットが実現され、性能が確認できたことを報告した。

本報では、電力需要予測において、自己回帰による予測モデルとニューラルネットワークを用いて気象要因や建物の利用状況を考慮した新たな予測モデルの比較検証結果、および、太陽電池・蓄電池の導入を支援するトライアル版を開発した背景とその特長、蓄電池を最大限活用したピークカット運転の運用アルゴリズム、実建物での実証試験の結果について報告する。




図-1 2030年のエネルギーミックス(出所:経済産業省)

\*1 エネルギー事業推進室 \*2 先端技術開発部 \*3 先端・環境研究部

## 2. 電力需要予測の高度化に関する検証

### 2.1 ニューラルネットワーク手法の導入

AHSESにおける電力需要予測手法は、文献1)にて述べた自己回帰による予測モデルを利用してきた。自己回帰による予測モデルは、気象要因や建物の利用状況等、明らかに電力需要と相関関係を持つ要因を考慮できず、季節や建物利用状況が変化したときに大きな誤差を生じてしまうことが課題だった。このような課題を解決するため、機械学習手法であるディープラーニングに着目し、新たなAHSESの電力需要予測システムを構築した。本システムで用いるニューラルネットワーク(NN)の概略図を図-2に示す。過去の実績から学習済みNNを構築する学習ステップと、学習済みNNを用いて30分毎の電力需要値を算出する予測ステップを経て電力需要値を算出する。

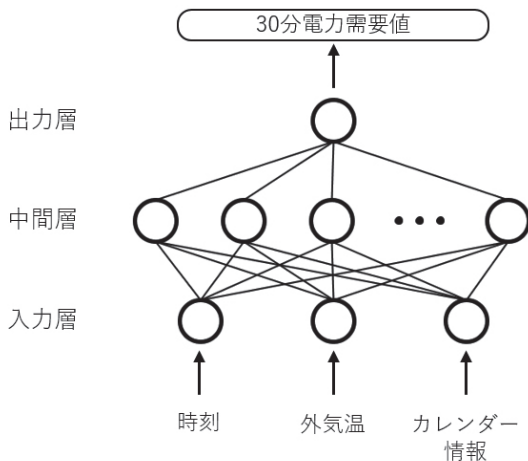


図-2 NNの概略図

### 2.1 学習ステップ

学習ステップでは、過去に蓄積されたデータを用い、NNに入力する説明変数と出力の関係を学習させ、学習済みNNを構築する。NNへの入力時刻・外気温・休日等のカレンダー情報とし、出力は30分電力需要値とした。これらの過去30分毎の実績セットを教師データとしてNNに学習させた。新たな実績データが蓄積されるにつれて、都度新しい学習済みNNを構築するために、学習ステップは週1回行う設定にした。このNNの学習頻度は変更可能である。

### 2.2 予測ステップ

図-3に24時間分の電力需要予測値を示す。学習ステップにて構築した学習済みNNを用いて、24時間分30分毎の電力需要予測値を得る。NNに時刻と、その時刻の外気温予測値及びカレンダー情報を入力することで、30分電力需要予測値を得ることができる。各時刻の外気温予測値は、外部機関より提供されるCSVファイルをダウンロードして利用する。予測ステップの実行は30分毎とし24時間先までの電力需要を予測するように設定した。

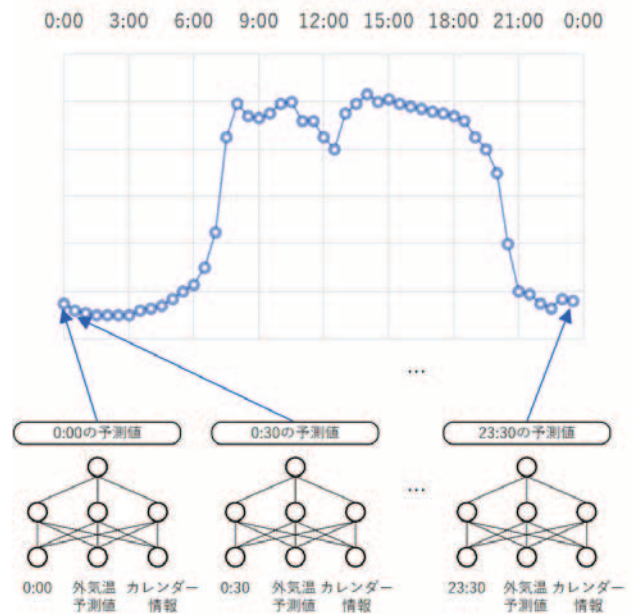


図-3 24時間分の電力需要予測値例

### 2.3 学習済みNNの構築と予測精度の比較

安藤ハザマ技術研究所で蓄積したデータを用いて、電力需要予測モデルの構築とその精度評価を行った。表-1に電力需要予測の比較ケースを示す。同表に示した3つのケースで比較を行った。建物利用状況を説明変数に加えることによる効果を検証するため、一事例として技術研究所本館棟内で行われている研修の有無をカレンダー情報として説明変数に加えた場合(Case A)と加えなかった場合(Case B)で比較した。数度の試行を通じ、精度が得られる設定として、それぞれのNNの中間層数は2層、各中間層のユニット数は64、学習回数は400回でモデルを構築した。また、NNを用いない電力需要予測の比較対象として、冒頭に述べた自己回帰による予測モデルを用いた(Case C)。表-2に比較に用いた実績データを示す。各ケースで、同表に示された2014年10月20日から2016年11月7日までの実績データを元にモデルを構築し、2016年11月8日の電力需要値を予測し比較を行った。

表-1 電力需要予測の比較ケース

Case A	NNによる予測モデル(研修カレンダーあり)
Case B	NNによる予測モデル(研修カレンダーなし)
Case C	自己回帰による予測モデル

表-2 比較に用いた実績データ

場所	技術研究所本館棟(茨城県つくば市)
期間	2014/10/20 ~ 2016/11/07
内容	30分毎の電力需要実績値
	30分毎の外気温実績値
	本館棟休日カレンダー(休日:1 平日:0)
	本館棟研修カレンダー(研修有:1 無:0)

図-4~図-6に各ケースにおける電力需要予測値(predicted)と実績値(actual)の比較を示す。また、表-3に各ケースにおける予測値と実績値の平均絶対誤差を示す。平均絶対誤差はCase Aが最も小さくCase Cが最も大きくなった。Case Cはピーク時間である8:30付近に着目すると大きく誤差が生じているが、Case Aの誤差は比較的少なく予測することができている。また、Case AはCase Bと比べて昼間(8:00~17:00)の電力需要を大きく予測している。研修の有無を説明変数に入れたことで、研修時に電力需要が高くなる傾向を学習させることができた。

表-3 平均絶対誤差の比較

	Case A	Case B	Case C
平均絶対誤差	3.90	4.21	5.53

NNによって外気温やカレンダー情報を説明変数として取り込むことが、電力需要予測の精度向上に寄与することを確認した。

今回の検証では、カレンダー情報の一例として研修の有無を用いたが、電力需要との高い相関が見込まれる会議室の利用状況や建物利用人数など、より詳細な情報を説明変数とすることで、さらなる精度の向上が期待できる。今後は、入退室管理システムやスケジュール表などを取り込み、建物利用者の行動から電力需要を予測することができるモデルを構築し精度を高めていきたい。

また、NNによる電力需要予測モデルは、自己回帰モデルに比べて、多くの過去実績を必要とするため、新築等の過去の実績が揃っていない建物ではNNによるモデルの精度は期待することができない。運用として、過去の実績が少ない時期には自己回帰モデルを用い、ある程度の実績を蓄積した後に、双方の予測精度を比較したうえでNNによる電力需要予測モデルに切り替えていくといった実態に即したシステムとして構築することも今後の課題と捉えている。




図-4 Case A の電力需要予測値と実績値の比較




図-5 Case B の電力需要予測値と実績値の比較



図-6 Case C の電力需要予測値と実績値の比較



### 3. AHSES トライアル版の開発

#### 3.1 開発の背景

地球温暖化防止、電気料金の削減、BCP 対策などを目的に太陽電池・蓄電池の導入を検討する事例が増えている。導入に当たっては、建物で使用する電力の時間帯毎の変化（電力特性）の把握や、それに基づく太陽電池・蓄電池の容量・出力の検討が重要である。しかしながら、建物利用者自身で詳細な検討を行うことは難しく、また、短期間の計測結果や契約電力を基にした検討では導入の効果が見えにくいため、結果として設備導入に慎重になるケースが多い。このような状況を踏まえ、AHSES を活用し、建物で使用する電力の特性にあわせた太陽電池・蓄電池の利用効果を、設備導入の検討段階で建物利用者自身が容易に把握できる再エネ・蓄エネ導入支援システム『AHSES トライアル版』を開発した。

#### 3.2 本システムの特長

図-7 に再エネ・蓄エネ導入支援システム『AHSES トライアル版』の概要を示す。今回開発した再エネ・蓄エネ導入支援システムは、対象建物に電力計等のセンサを設置し、実際の使用電力に対する仮想太陽電池・仮想蓄電池によるリアルタイムの電力アシスト状況や電力需要

予測を専用ホームページの「見える化画面」により提供するものである。仮想設備の容量・出力は利用者の要望や建物の電力需要に合わせてカスタマイズが可能であり、また、学習機能により電力需要予測には建物利用状況が適切に反映される。建物利用者は、電力需要のピークカットなどの運用状況を「見える化画面」で視覚的に確認することで、太陽電池・蓄電池の導入効果を容易に把握することができる。以下に3つの機能を示す。

#### (1) 仮想設備容量のカスタマイズ

本機能は、太陽電池容量、蓄電池容量、インバータ定格等を可変することができ、導入時の下記の課題に答えるものである。

##### 導入にあたっての課題

- ・太陽電池は何 kW 設置する？
- ・蓄電池は何 kWh 設置する？
- ・インバータ等の装置の構成は？
- ・電気料金はどれだけ削減できる？
- ・CO2 排出量はどれだけ削減できる？

##### ➡最適なシステム構成は？

仮想太陽電池・蓄電池の容量をいろいろ試し、その結果をリアルタイムにシミュレーションすることで導入効果を視覚的に確認でき、実感することができる。

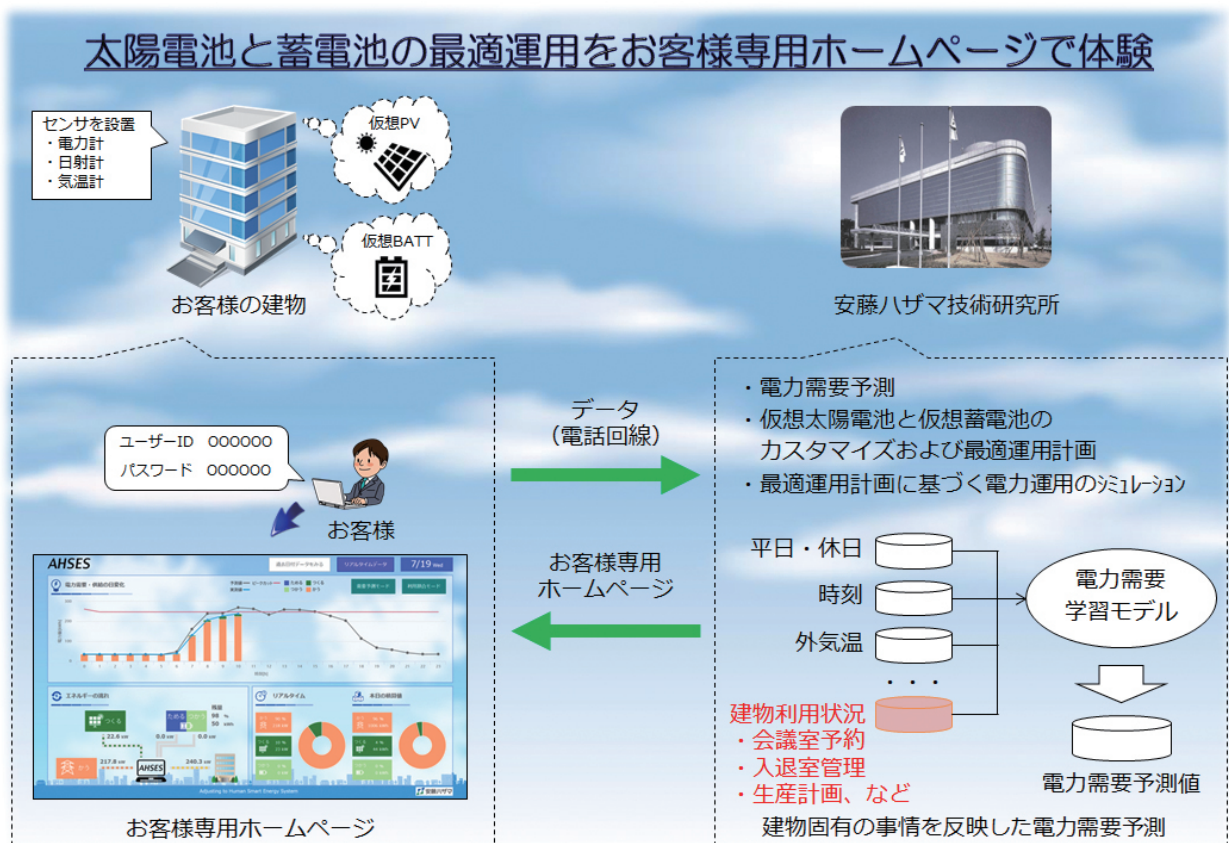


図-7 再エネ・蓄エネ導入支援システム『AHSES トライアル版』の概要

図-8に電力需要特性に対する蓄電池容量の設定例を示す。例えば、電力需要特性のピークがなだらかな建物Aと急峻な建物Bがある場合、電力X(kW)をピークカットできる蓄電池容量は、それぞれ異なり、Y(kWh)、Z(kWh)となる。ここで、 $Y(kWh) > Z(kWh)$ である。このように、お客様の要望や建物の電力需要特性に合わせて各設備容量を適切に設定することが可能である。



図-8 電力需要特性に対する蓄電池容量の設定例

### (2) NNの説明変数のカスタマイズ

図-9に建物固有の事情を反映した電力需要予測モデルを示す。本機能は、電力需要予測値の算出にあたり、平日・休日、時刻、外気温等の基本情報に加え、会議室予約、入退室管理、生産計画等の建物固有の事情を考慮することにより、予測精度を高めるものである。




図-9 建物固有の事情を反映した電力需要予測モデル

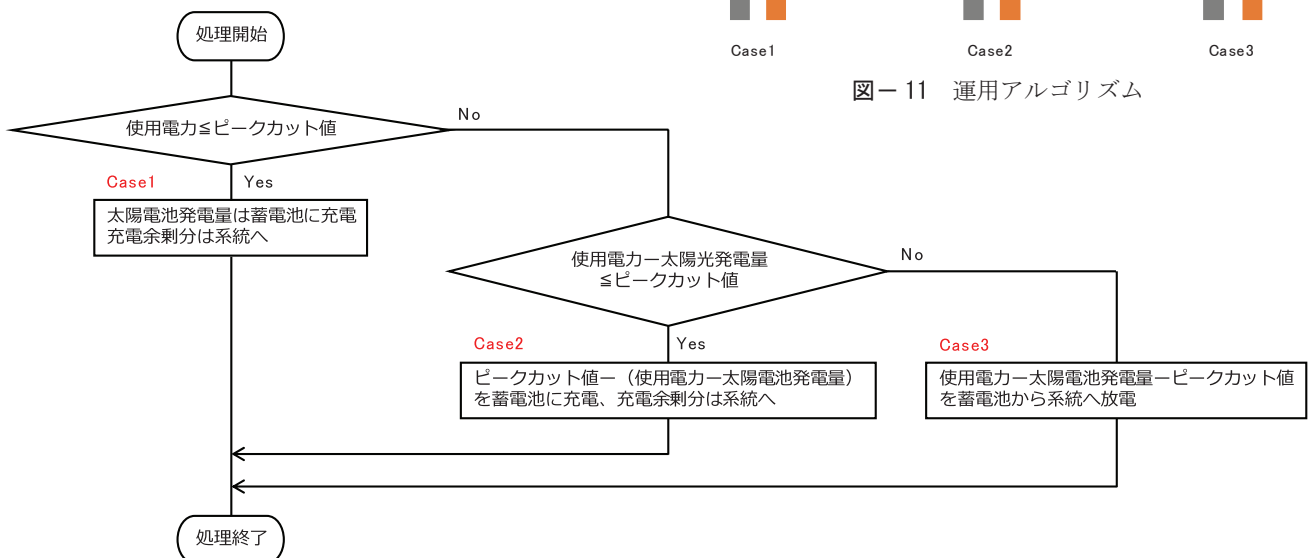


図-12 運用アルゴリズムフローチャート

### (3) 建物用途別電力需要データベースの構築

図-10に建物用途別電力需要データベースの構築を示す。AHSESトライアル版を展開していくことにより、用途別の電力需要データベースの構築が可能となる。これらのデータベースを活用すれば実績値が存在しない新築物件でも、予測精度の向上が期待できる。




図-10 建物用途別電力需要データベースの構築

### 3.3 運用アルゴリズム

図-11に運用アルゴリズム、図-12に運用アルゴリズムフローチャートを示す。ここでの運用は、蓄電池を最大限活用したピークカット運転を行うものとする。図-11に




図-11 運用アルゴリズム

示すように、使用電力、太陽光発電電力、ピークカット値の関係から Case1 ~ Case3 に分け、図-12 に示すように、それぞれ蓄電池の充放電を定義した。この他、30分毎のリセット処理、蓄電池充放電制限、バッテリーコントローラ入出力制限、インバータ出力制限、カットできなかった分の処理等の制御や設備機器の効率も考慮し、ほぼ実際と同等の結果が得られるようにした。

### 3.4 実建物での実証試験

本システムは、2017年10月より安藤ハザマ技術研究所に導入し実証試験を行っている。図-13 に仮想太陽電池と仮想蓄電池の最適運用例(蓄電池を最大限活用したピークカット効果)を示す。図の使用電力および太陽光発電は実測データである。各設備容量を図中右上のシステム構成例のように設定し、最も効果的にピークカットを行うことができた例である。この日は快晴であり、太陽光発電は最大限に発電している。使用電力が落ち込んだ9:30、12:30、14:00には、ピークカットに使用しない太陽光発電は蓄電池に充電され、使用電力が大きくなる10:00 ~ 11:30、13:30、15:00以降はそれを放電し、適切にピークカ

ットが行われている。このように、仮想太陽電池と仮想蓄電池の最適運用が適切に行われていることを確認した。

### 4. おわりに

ニューラルネットワーク手法を用いた電力需要予測により、気象要因や建物の利用状況を考慮することで、予測精度の向上が図れることを確認した。また、太陽電池・蓄電池の導入を支援するトライアル版を開発し、実証試験の結果から蓄電池を最大限活用したピークカットの運用が適切に行われることを確認した。今後、エネルギー産業は5つのD(自由化, 脱炭素化, 分散化, デジタル化, 人口減少)によりUtility3.0へ変革していく。このため、Peer to Peer, ブロックチェーン技術を活用した電力取引も視野に入れたEMSの開発を進めていく。

### 参考文献

- 1) 安藤ハザマ研究年報 Vol.4 2016 AHSESの開発 その1 開発概要と実証試験
- 2) CO2 EMISSIONS FROM FUEL COMBUSTION2016(IEA)

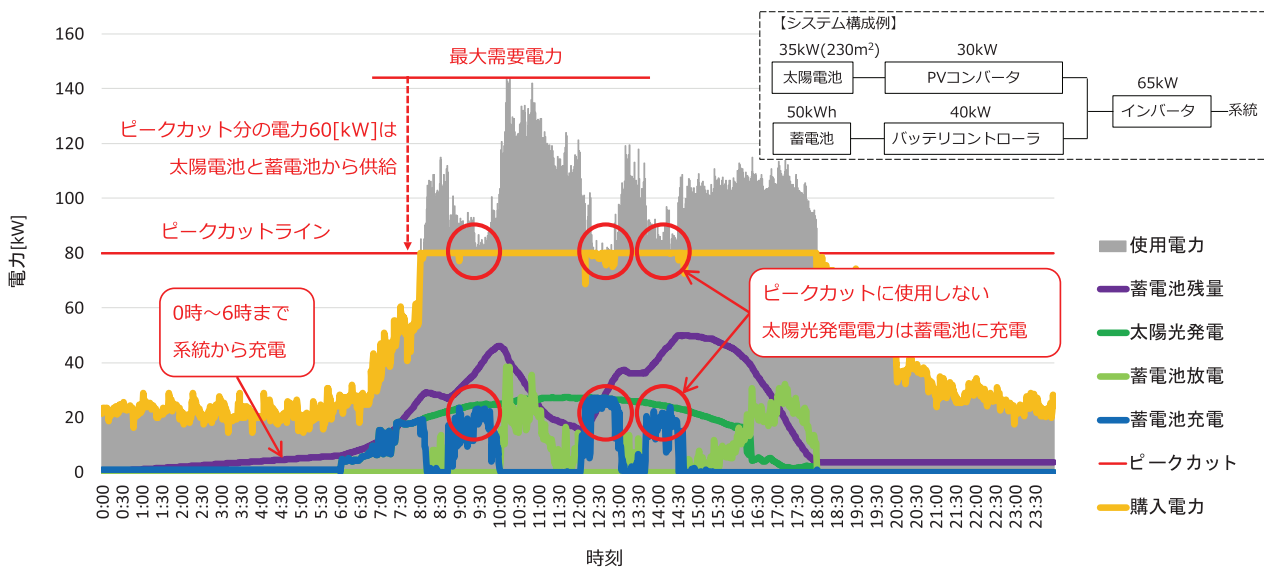


図-13 仮想太陽電池と仮想蓄電池の最適運用例(蓄電池を最大限活用したピークカット効果)

## Development of AHSES(Adjusting to Human Smart Energy System) Part 2. Improve prediction of electricity demand and development of AHSES trial version

Tadaaki MIYAGAWA, Tatsunori MURAISHI, Kazuaki MORI and Yoshitaka IWAMOTO

The prediction of electricity demand is the most important function in energy management systems. The autoregressive prediction model described in the previous report (part 1: 2016) was unable to take into consideration weather factors and the building usage situation. In order to solve such problems, we focused on deep learning which is a machine learning method and constructed a new power demand prediction system. We developed the "AHSES trial version" in which the user can see the effect of introducing the facilities at the planning stage.