

# ディープラーニングを用いた熱負荷予測アルゴリズムの開発に関する研究

谷川 悠

## 1. はじめに

近年、省エネルギー化に対する意識の向上から、建築物に対する省エネ性能の要求は高まってきており、冷暖房負荷を最小限に抑えた設計が強く求められるようになってきた。しかし、建築物の冷暖房負荷に影響を与えるパラメーターは多岐に渡り、それらを総合的に捉えて熱負荷の数値を予測することは非常に複雑で困難なことである。そこで、本研究では、近年研究が進み実務での活用もされ始めているディープラーニングを用いた建築物の熱負荷予測を行い、予測精度の評価を行う。実際の熱負荷予測でモデルを活用するためには計算機の性能制約を受けることや、パラメーターの種別・数などに応じて応用可能なアルゴリズムである必要があることを考慮して、汎用プログラミング言語である Python を用いて予測アルゴリズムを構築することとした。

ディープラーニングとは、脳機能を模したモデルであるニューラルネットワークを多層に接続し、与えた課題に対して学習を行わせる機械学習の手法の一つである。ニューラルネットワークは、パーセプトロンが原型となって考案された。パーセプトロンの概念図を図 1 に示す。入力層は複数のニューロン、出力層は一つのニューロンで構成されており、ニューロンから入力された特徴量に重みを掛けたものを足し合わせて合計値を算出する。この合計値を活性化関数に通したものを、出力層のニューロンの出力値とする。ニューラルネットワークでは、入力層と出力層のニューロンを互いに接続し、パーセプトロンと同様に入力値に重みを掛けて合計値を活性化関数へ通すことによって、次の層へ渡す出力値とする。中間層（隠れ層）を複数持つニューラルネットワークを用いた機械学習のことをディープラーニングと呼ぶ。

ディープラーニングでは、モデルからの出力値とテストデータとの間の誤差を計算して、ノードの重みを更新することで学習を進める。また、中間層を増やすことによって、多数のパラメーターや非線形な課題に対しても、精度良く予測することが可能となるという特徴を持つ。本研究ではシミュレーションソフトを用いて、モデル建物を構成するパラメーターを説明変数

として期間熱負荷を計算したものを学習データとし、ディープラーニングのモデルに対して学習を実行させる。次に、学習後のモデルに対して予測精度の評価を行い、熱負荷予測への応用可能性について検討する。また、変数として用いるパラメーターを変えた場合のモデルの適合性や学習データの個数に応じた予測精度の変化についても明らかにする。

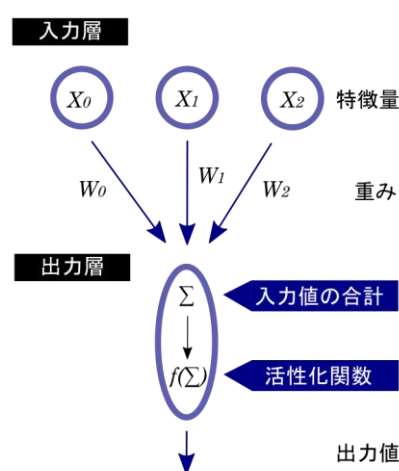


図 1 パーセプトロンの概念図

## 2. THERB を用いた数値計算

### 2.1. 使用ソフト並びに計算対象モデル

本研究では、ディープラーニングのモデルに学習させる学習データを作成するために、熱環境シミュレーションソフトとして THERB for HAM を用いた。

対象建物は床面積が 16m<sup>2</sup>、地盤面からの高さが 0.5m、高さが 3m の単純な形態の居室を想定したものである。平面図と立面図を図 2 及び図 3 に示し、これを基本構成とする。また、各部材の仕様は表 1 のように設定した。本研究では基本構成を基に、壁面積に対する窓面積の割合、居室の縦横比、1 時間ごとの空調スケジュールデータを変えたモデルをプログラムで自動生成し、THERB に読み込ませて熱負荷計算を行った。




図 2 計算対象建物の平面図




図 3 計算対象建物の立面図

表 1 対象建物の構成要素の仕様

部材	構成
外壁	RC (120mm)
床	RC (120mm)
屋根	RC (120mm)
窓	複層ガラス (3mm・12mm・3mm)

## 2.2. THERB を用いた学習データの作成

THERB に読み込ませる構成データの作成は、学習データとして大量のデータが必要となるため、Node.js のプログラムを作成して自動で行った。説明変数とするパラメーターをプログラム内で指定して、生成した乱数が構成データ内の該当位置に入るようにした。

続いて、THERB による熱負荷計算時の計算条件を表 2 に示す。本研究では、気象データとして福岡における標準年 (2001 年～2010 年) のアメダスデータを用い、対象建物に対して 8 月の熱負荷計算を行った。計算の時間間隔は 3600 秒とした。

それぞれの構成データに対して THERB による計算を行い、出力された 1 時間間隔の熱負荷データをもとに

8 月の期間熱負荷を算出した。次に、計算時に指定したパラメーターと統合して一つの CSV ファイルとして出力した。正確な評価を行うために、モデルの学習や評価を行う際は CSV ファイルを新たに生成し、学習と評価で別々のデータを用いるようにした。

表 2 THERB による予測時に用いた計算条件

項目	内容
使用ソフト	THERB for HAM
建物モデル	床面積：16m <sup>2</sup> 高さ：3m 直方体居室を想定
計算対象期間	8月1日～8月31日
気象データ	福岡・標準年 (2001年～2010年)
計算間隔	3600秒

## 3. ディープラーニングを用いた学習

### 3.1. モデルの概要

本研究では、ディープラーニングを用いた学習及び予測を行うために、Python 上で動作するニューラルネットワークライブラリである Keras を用いた。Keras は機械学習ソフトウェアライブラリとして用いられている Tensorflow 上で動作し、ディープラーニングで使用可能なレイヤーや活性化関数などが予め準備されている。本研究で用いた各種ソフトウェアの動作確認バージョンを表 3 に示す。

学習に用いたモデルの構造を図 4 に示す。中間層が直列に接続された構造となっており、これを Sequential モデルと呼ぶ。Dense は全結合ニューラルネットワークを表すものであり、今回の学習に用いたモデルでは、4 層の中間層を全て Dense として配置した。

活性化関数には ReLU を用いた。この関数の特徴として、勾配消失問題を抑制することができる、計算量が少ない、発火しないニューロンを表現できるといった点が挙げられる。また、勾配消失や勾配爆発を防ぐために BatchNormalization を中間層の出力に対して適用した。結果として学習率を上げることができ、学習速度を上げることが可能となった。本研究では入力層のパラメーター数は可変とし、様々な値を説明変数として使えるように設計を行った。モデルからの出力は、期間熱負荷の実数値とする。

表 3 使用したソフトウェアのバージョン

ソフトウェア名	バージョン
Python	3.8.6
scikit-learn	0.24.0
tensorflow-gpu	2.4.0

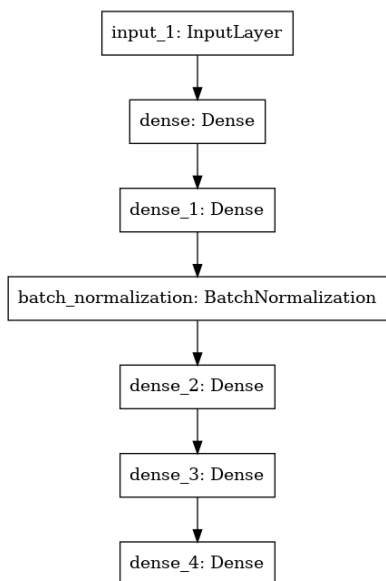


図 4 学習に用いたモデルの構成

### 3.2. 学習の手順

2章の THERB による期間熱負荷の予測結果と、それぞれの条件時のパラメータを一つの CSV ファイルに統合して入力データとした。入力データの 8 割を訓練データ、残りの 2 割はテストデータとして学習後のモデルの評価のために用いることとした。ディープラーニングモデルの学習ではエポック数を 100 とし、学習が完了したモデルの構造データとノードの重みを再現可能な状態で保存した。

## 4. ディープラーニングによる数値予測の結果

### 4.1. モデルの予測精度に対する評価手法

本研究では、ディープラーニングを用いて学習させたモデルの予測精度を評価するために、重回帰分析による期間熱負荷の予測精度との比較を行うこととした。まず始めに、3.2 節で学習が完了したモデルの保存データを読み取り、データを入力できる状態に展開した。次に、学習データとは別に準備した評価用データをモデルに入力し、出力を期間熱負荷の予測値として得た。

重回帰分析の予測には、scikit-learn の LinearRegression クラスを用いた。ディープラーニングと同様の学習データを用いて重回帰分析モデルの学習を行い、学習後のモデルに対して評価用のデータを入力し、期間熱負荷の予測を行った。

予測精度の評価は、評価用のデータに含まれた期間熱負荷の計算値に対する予測値の誤差を割合として算出し、全評価データに対する誤差割合の標準偏差を、予測精度に対する評価基準として用いることとした。

## 4.2. ディープラーニングモデルによる予測結果

### 4.2.1. 窓面積割合と熱負荷との関係

3.1 節で述べたモデルを用いて、対象建物の東西南北各方位の壁面積に対する窓面積の割合を変化させたデータをディープラーニングのモデルに学習させた。学習データの個数は 1000 とした。学習回数と損失関数との関係を図 5 に示しており、学習が進むにつれ、予測値の誤差が小さくなっていることが読み取れる。また、同様のデータを用いて重回帰分析による予測も行い、予測精度の比較を行った。比較結果を表 4 に示す。ディープラーニングを用いたモデルの予測誤差は平均で 1.76%、重回帰分析のモデルでは 1.65%となり、ディープラーニングと重回帰分析の間で大きな差は見受けられなかった。これは、窓面積割合と熱負荷との関係が直線に近い分布になっており、ディープラーニングと比較して、式が一意に定まる重回帰分析も精度良く予測できたからであると考えられる。




図 5 ディープラーニングにおける学習回数と損失関数との関係

表 4 窓面積割合をパラメータとしたときの予測精度の比較

回数	ディープラーニングによる予測精度	重回帰分析による予測精度
1	1.80%	1.64%
2	1.51%	1.69%
3	2.77%	1.70%
4	1.33%	1.51%
5	1.38%	1.71%
THERB 予測値に対する誤差の平均値	1.76%	1.65%

### 4.2.2. 居室の縦横比と熱負荷との関係

次に、床面積を一定に保った状態で居室の縦横比を

変更して、熱負荷予測を行った。学習データ数は 1000 とし、モデルの予測精度を評価するために、4.2.1 節と同様にディープラーニングと重回帰分析による予測精度の比較を行った。計算結果を表 5 に示す。ディープラーニングによる予測誤差は 0.64%、重回帰分析による予測の誤差は 1.37%であり、ディープラーニングを用いたモデルの方が精度が良いことが示された。

表 5 居室の縦横比をパラメーターとしたときの予測精度の比較

回数	ディープラーニングによる予測精度	重回帰分析による予測精度
1	1.14%	1.33%
2	0.50%	1.41%
3	0.58%	1.50%
4	0.42%	1.29%
5	0.56%	1.30%
THERB 予測値に対する 誤差の平均値	0.64%	1.37%

#### 4.2.3. 空調スケジュールと熱負荷との関係

さらに、THERB に一時間ごとの空調スケジュールデータとして 0 時～23 時の 24 個のパラメーターを説明変数として渡し、熱負荷の予測を行った。パラメーター数が多いため、学習データは 5000 件用意した。結果を表 6 に示す。ディープラーニングによる誤差は 2.21%、重回帰分析による誤差は 8.58%であり、重回帰分析と比較して 3～4 倍精度が良いことが判明した。これは、躯体の蓄熱効果などによる複雑な非線形現象をディープラーニングのモデルが精度良く予測できたからであると考えられる。

表 6 空調スケジュールをパラメーターとしたときの予測精度の比較

回数	ディープラーニングによる予測精度	重回帰分析による予測精度
1	2.05%	8.72%
2	1.90%	9.11%
3	1.85%	8.38%
4	1.89%	7.78%
5	3.38%	8.91%
THERB 予測値に対する 誤差の平均値	2.21%	8.58%

#### 4.3. 学習データの個数と予測精度との関係

最後に、学習データの個数とディープラーニングモデルによる予測精度の関係について実験を行った。1 時間ごとの空調スケジュールを説明変数とした学習データを用意し、学習データ数が 1000、5000、10000 件の 3 パターンについてそれぞれの予測誤差を測定した。

図 6 に学習データ数と予測精度との関係を示す。グラフから、学習データ数が 1000 から 5000 まで増加すると精度が大きく上昇するが、以後は精度がほとんど上昇しないことが判明した。本条件ではパラメーター数が 24 と多いが、全ての組み合わせを網羅出来ていない条件でも、一定の個数を満たした段階で予測精度は高くなり、それよりデータが増えた場合の精度向上は緩やかになるということが説明できる。




図 6 学習データの個数と予測精度との関係

#### 5. むすび

本研究では、ディープラーニングを建物の熱負荷予測に用いる際の、予測モデルの構成についての検討と予測精度の評価を行った。以下に得られた知見を示す。

- (1) 4 層の中間層を持つ全結合ニューラルネットワークで、活性化関数に ReLU を使い、BatchNormalization を適用したモデルの予測精度が高かった。
- (2) 説明変数として用いる建築物のパラメーターの種類や数が増え変化しても、ディープラーニングによって自動的に重み付けが行われ、重回帰分析と比較して精度良く予測可能である。
- (3) 空調スケジュールデータのように 0 と 1 で表されるワンホットなデータに対しても誤差の少ない予測が可能である。

今後の課題として、学習データの範囲を超えたパラメーターを入力として与えられたときの予測値の誤差を調査することや、実際の建物における熱負荷予測にモデルを適用する場合の学習データの収集手法の確立などが挙げられる。

#### 【参考文献】

- 1) Sebastian Raschka 著、株式会社クイープ訳『[第2版] Python 機械学習プログラミング 達人データサイエンティストによる理論と実践』インプレス、2018