

転移学習を用いた最高気温予測モデルの検討 Maximum temperature prediction using transfer learning

土橋 秀昭[†] 浦野 昌一[†]
Hideaki Dobashii Shoichi Urano

1. はじめに

近年、異常気象が世界規模で発生しており気候変動に注目が集まっている。その中でも昨今の気温上昇は世界各地で起こっており、一般的には気温上昇に伴う大規模な干ばつなどの自然災害の発生が拡大していると言われている。特に干ばつなどの自然災害の影響は、先進国ではなく発展途上国で深刻な問題となっている。そのような状況においても、企業は農作物の出荷量や需要量などの見積もりを高精度に行うことが求められている。天候などに影響を受ける農作物の育成には気温が大きく影響しているため、気温をあらかじめ高精度に予測しておくことが必要とされている。発展途上国や農村で気温予測を行うには以下の課題がある。

- 1) 観測所の維持が難しい
- 2) 入力カテゴリに制限がある

またこの問題は国内における小さな農村でも同じよう課題があると考えられる。

そこで本稿では転移学習を用いた時系列データ予測について提案する。本研究ではまず比較的入手しやすい入力変数から予測モデルに重要であるカテゴリを抽出する。また入力変数の抽出後、気温データを用いてソースドメインを作成する。その後、異なる気温データ予測をターゲットとして転移学習を行い、少ないデータ量から精度の高いモデルの作成を目指す。

2. 気温予測

気温予測は企業における品質管理、需要量などの見積もりに必要であると共に、天候に影響を受ける農作物などの早期対応のためにも高精度化が求められる。例えば、ある農作物の出荷量は、例年の出荷量から平均して予測値を算出していたが、気温予測を用いて出荷量を最適化した事例が存在する。

気温予測は全国各地に存在する観測所の観測データを収集し、その地点の予測を行う。しかし、発展途上国や農村においては、観測所の設置やその後の維持管理のための費用を支出することが困難であるため必要とするデータが十分蓄積出来ない問題が存在する。そのため高精度な予測モデルを作成するために必要なデータ量を満たすことが出来ない。また入力変数の多さは複雑なモデルの説明に必要なが、観測所の性能によってデータ収集能力に差が生じており、地点ごとで予測精度の差が発生している。

3. 予測手法

3.1 ニューラルネットワーク

ANN(Artificial Neural Network)は神経回路網を模倣した数理モデルであり、パターン分類や時系列解析・予測などに

[†] 明治大学先端数理科学研究科 Meiji University
Advanced Mathematical Sciences

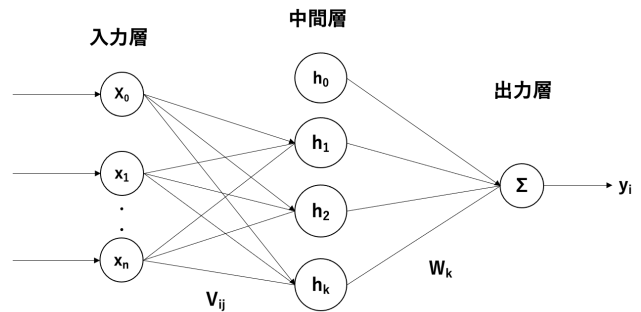


図1 MLPの概要図

応用されてきた。本稿では研究の第一段階の ANN として、多層パーセプトロン(以後, MLP(Multi-Layer Perceptron)と略記)を用いる。MLP は、学習データに教師信号を用いる教師付き学習法の ANN である。MLP は図 1 に示す「入力層」「隠れ層」「出力層」によって構成され、通常は 3 層から成る。MLP では、学習データを用いて教師信号と出力信号の誤差の 2 乗を最小化するように、ニューロン間の重み、即ち、各層の重みを誤差逆伝搬法(バックプロパゲーション)を用いて決定する。MLP の評価関数を(1)式で示す。

$$E = \frac{1}{2} \sum_{i=1}^I (T_i - y_i)^2 \quad (1)$$

ただし、E:評価関数、 y_i :i 番目の出力層の出力、 T_i :i 番目の教師番号、I:入力データ数

MLP では(1)式の誤差から中間層と出力層の重みを更新する。以下(2)式、(3)式は中間層出力と出力層出力である。

$$y_i = Z \left(\sum_{j=0}^J w_k h_{ij} \right) \quad (2)$$

ただし、 y_i :i 番目の出力層出力、 w_k :中間層と出力層間の重み、 h_{ij} :中間層出力、 $z()$:シグモイド関数、J:中間層のニューロン数

$$h_{ij} = Z \left(\sum_{j=0}^J V_{ij} x_i \right) \quad (3)$$

ただし、 h_{ij} :中間層出力、 V_{ij} :入力層と中間層間の重み、 x_i :i 番目の入力データ、J:中間層のニューロン数、 $z()$:シグモイド関数

3.2 転移学習

転移学習は 1995 年に Stevo Bozinocski 氏と Ante Fulgosi 氏によって言及され、画像認識や自然言語処理分野において発展してきた機械学習手法の 1 つである。転移学習が他の機械学習手法に比べて優れている点は

- 1) 限られたデータの活用ができる
- 2) 短時間で学習が可能である

の 2 つである。昨今の IoT 化によりデータの収集、蓄積が容易になってきている。一般に精度が良いモデルを作成す

るには大量のデータが必要であるとされている。しかし発展途上国や農村などのデータ収集が難しい場所では、観測装置の設置が困難であることから、大量のデータを収集するのは難しくなる。転移学習は少量のデータから高精度のモデルを作成することが可能であると言われている。しかし知識の転移を行う際に精度が悪くなる「負の転移」が存在する。負の転移が起こらないようにするために

- 1)何を転移させるのか
- 2)いつ転移するか
- 3)どのような方法で転移させるか

が重要である。

本研究では転移学習手法の1つであるネットワークベース手法²⁾を利用し、ある大規模データセット A によって作成されたモデル A のパラメータを少量のデータセットにおけるパラメータの初期値として利用する。この際、パラメータを全て更新するのではなく、中間層から出力層にかけてのパラメータを更新し、残りのパラメータをモデル A のパラメータで固定する。

4. シミュレーション

本研究では、最初に入力変数についての検討を行う。先行研究²⁾において様々な変数を用いて転移学習を行なっているが、使用できるカテゴリは発展途上国の観測所で観測が可能であることを基準にする。気象庁によると広く一般的に設置されている観測装置で取得できるカテゴリは気温、降水量、気圧、相対湿度である。発展途上国や農村において高機能な観測所を設置することは敷居が高いため、以上のカテゴリから入力変数を検討する。カテゴリを選択後、東京における同じ変数を用いてモデルの学習を行う。その後転移学習を行い、横浜の入力データを用いて予測精度の検討を行う。本研究のシミュレーションフローを図 2 に示す。

4.1 入力変数の選定

まず入力変数の検討として気温、降水量、気圧、相対湿度から適切な入力変数を選択する。ここで入力変数をいくつかの条件に分けてシミュレーションを行う。表 1 は条件を 4 つに分けた入力変数一覧である。また本シミュレーションでは気温データから得られた加速度を用いる。加速度は連続している時系列データにおいて差分を取ったものを速度とし、求められた速度の差分を取ったものを加速度として用いる。

<シミュレーション条件>

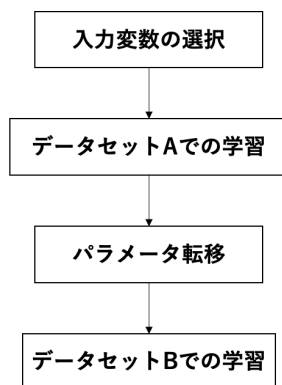


図 2 シミュレーションフロー

表 1 入力変数の条件

	入力変数1	入力変数2	入力変数3	入力変数4	入力変数5
i	X_t	X_{t-1}	X_{t-2}	—	—
ii	X_t	X_{t-1}	X_{t-2}	Z_t	Z_{t-1}
iii	X_t	X_{t-1}	X_{t-2}	日射量	降水量
iv	X_t	気圧	相対湿度	日射量	降水量

X_t :時刻 t における気温、 X_{t-1} :時刻 t-1 における気温、 X_{t-2} :時刻 t-2 における気温、 Z_t :教師データと時刻 t の気温データから算出した加速度、 Z_{t-1} :時刻 t と時刻 t-1 の気温データから算出した加速度

入力データ：気象庁が公開している 2019 年 7 月 1 日から 2020 年 6 月 31 日間の大手町における 1 時間ごとのデータ(8778)

テストデータ：同じく気象庁より得た 2020 年 7 月 1 日から 2020 年 9 月 31 日間の大手町における 1 時間ごとのデータ(1463)

入力変数：表 1 の条件に準ずる

出力値：1 時間後の気温予測値

4.2 転移学習による気温予測

入力変数の選定より精度が一番良いものをソースドメイン A とする。このソースドメイン A におけるパラメータをターゲットドメイン A の初期値とする。また転移学習を用いない学習モデルと性能比較を行う。以下はシミュレーション条件である

<シミュレーション条件>

ソースドメイン A：気象庁が公開している 2019 年 7 月 1 日から 2020 年 6 月 31 日間の大手町における 1 時間ごとのデータ(8778)

ターゲットドメイン B 学習データ：気象庁が公開している 2020 年 7 月 1 日から 2020 年 7 月 31 日間の横浜市における 1 時間ごとのデータ(744)

ターゲットドメイン B テストデータ：気象庁が公開している 2020 年 8 月 1 日から 2020 年 8 月 15 日間の横浜市における 1 時間ごとのデータ(361)

入力変数：入力変数の選定結果に従う

出力値：1 時間後の気温予測値

5. まとめ

本稿では少ないデータ数から精度の良いモデルを作成するために、まず限られた入力変数のカテゴリから精度が良い入力変数を選択した。また転移学習を用いた時系列データ予測について検討した。

今後は、時系列データ予測における対象範囲の拡大や適切な転移学習モデルの選択なども検討していく予定である。

参考文献

- [1] Chuanqi Tan, Fuchun Sun, Tao Kong, Wenchang Zhang, Chao Yang, Chunfang Liu “A Survey on Deep Transfer Learning”, The 27th International Conference on Artificial Neural Networks(ICANN 2018), p 1-9.
- [2] Yujiao Chen, Zheming Tong, Yang Zheng, Holly Samuelson, Leslie Norford “Transfer learning with deep neural networks for model predictive control of HVAC and natural ventilation”, Journal of Cleaner Production ,volume 254,p.1-9