

深層学習を用いた収穫日予測手法の検証

Verification of the harvesting date prediction method using deep learning

三好健悟*¹

Kengo Miyoshi

村上幸一*¹

Yukikazu Murakami

*¹独立行政法人 国立高等専門学校機構 香川高等専門学校

National Institute of Technology, Kagawa College

Contract farming has a managerial advantage that farmers can directly negotiate prices with business partners. And it is necessary to predict harvesting date of agricultural crops precisely for contract farming. Conventionally, this precondition has been solved only by experience rule of experienced farmers. However, for new farmers who do not have experiential rules or for large-scale field managers, contract farming is difficult management method. In order to solve this problem, we proposed automatic harvesting date prediction method using statistical model by deep learning. We confirmed that deep learning models exceed the accuracy of non-deep learning models.

1. はじめに

農業の経営手法の一種である契約栽培は、営農者が取引先との価格交渉を直接行えるという利点がある。しかし契約栽培では多くの場合において農作物の収穫日や収量を正確に予測することが前提条件であり、これには技術的あるいは技能的な予測手法が必要となる。

従来この問題は熟練営農者の経験則によって解決されてきた。しかし新しく農産業に参加する新規営農者にとっては経験則に依る手法は意味を持たない。また熟練営農者にとっても異なる品種、圃場、作業日程で複数の作物を管理する場合、それらすべての収穫日予測を行うことは困難である。本研究グループではこれまで、深層学習の一種であるディープニューラルネットワークによる自動的な収穫日予測手法について提案してきた。本論では提案手法の予測精度について検証する。

2. 理論

本研究では収穫日予測を行う回帰出力モデルとしてディープニューラルネットワーク [1](以下,DNN) を主に用いる。DNN は人間などが持つ情報処理システムの中核である脳神経系を模倣した数理的モデルであるニューラルネットワーク [1] (以下,NN) を深層化したものであり、その構造は図 1 に示される。




図 1: ディープニューラルネットワーク

DNN は誤差逆伝播法によって各層の結合重みが更新され、学習を進める。しかし DNN の深層化は勾配消失問題を引き起こす可能性を持つ。問題によりノード間の結合重みの更新量が小さくなりすぎると学習が停滞する。

3. 要素技術

(1) MXNet

MXNet [2] は種々のホスト言語にサポートされているマシニング (以下,ML) フレームワークの一つである。提案手法はこれを R で用い、DNN を設計する。MXNet は他の ML フレームワークと比べて計算機リソースによるスケーリングの効率やホスト言語の多さなどで優れる。

(2) ベイズ最適化とランダムサーチ

本研究では DNN のハイパーパラメータ探索を行う作業工程にベイズ最適化とランダムサーチを用いる。

4. 予測手法の設計

DNN の設計にあたり、以下の手順を踏んで予測モデルを構築した。

1. 収集した計 35 サイクルのレタス栽培データをデータセットとして用いた。各サイクルの収穫日を出力パラメータ、またそれ以外の各作業日程と気象データを入力パラメータとして設定した。各パラメータは正規化した。
2. K-fold cross validation 法を用いてデータセットを訓練データとテストデータに分割した。分割サイズは 10 分割とした。モデルの精度は 10 回分の出力における MAE を算出し、それらを平均した平均 MAE で評価した。MAE は (1) 式により求められる。ここでは、真の値は出力された予測値、N は予測値の数である。

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (i = 1, 2, \dots, N) \quad (1)$$

3. MXNet を用いてデータセットを元に回帰出力を行う NN, DNN を設定した。

連絡先: 村上幸一, (独) 国立高等専門学校機構 香川高等専門学校, 香川県高松市勅使町 355, 087-869-3917, 087-869-3909, murakami@t.kagawa-nct.ac.jp

5. 予測手法の設計

収穫日予測手法として、DNN を用いた深層学習で高精度な結果が得られるかを以下の手順で実験した。

- 中間層が 1 層の NN と中間層が 2 ～ 5 層の DNN について、バイズ最適化とランダムサーチによるハイパーパラメータの決定を行う。
- 上記の 5 種類の NN, DNN を用いてレタス栽培データセットの回帰出力モデルを構築する。
- 学習回数を 10 ～ 1500 回の範囲において 10 回刻みで変化させ、学習回数ごとに出力される平均 MAE を記録する。
- (a) の工程と (c) の工程を通して記録された 平均 MAE の中で最も値が小さな学習回数のモデルを、最適な NN, DNN として評価する。

6. 実験結果

実験結果を表 1 に示す。深層化した DNN の中で最良な平均 MAE を持つモデルは前節 (a) でベストチューニングが得られた中間層が 4 層の場合であった。図 2 に前節 (c) でベストチューニングが得られた 3 層 DNN の平均 MAE-学習回数の関係を示す。また図 3 に 3 層 DNN の MAE が最小になった学習回数 980 回時点での各テストデータに対応する MAE を示す。図 3 においてその標準偏差は 1.774 であった。図 4 に、今回の実験で得られた中間層の構造を示す。実験では 3 層 DNN のうち 2 層目のノードが少なくなる特徴的なネットワークの獲得を確認した。

表 1: 実験結果

モデル	MAE [day]
1 層 NN	2.346
2 層 DNN	2.264
3 層 DNN	2.050
4 層 DNN	2.013
5 層 DNN	2.099




図 2: 3 層 DNN における平均 MAE-学習回数の関係

7. 考察

表 1 より、中間層が 2 ～ 5 層の DNN による平均 MAE は全てが中間層数 1 の NN の平均 MAE より優れた結果を得た。




図 3: 3 層 DNN における学習回数 980 回時の各テストデータ MAE




図 4: 3 層 DNN における特徴的な中間層構造

このことは提案した DNN の設計手法が局所最適解や勾配消失の問題を堅実に回避することができることを示す。また 4 層 DNN による MAE は 5 層 DNN による 平均 MAE より優れていた。このことは 5 層 DNN のチューニングが不十分であることを示す。この問題は、中間層数の増加による、学習時の計算コストの増大に起因すると考えられる。計算コストの増大はハイパーパラメータ探索に多大な時間を要し、時間的制約により最適解を見つける可能性を低める。これを解消するためには、本実験より多くの計算機リソースの使用や実験の効率化が必要である。

8. 結論

本研究では、深層学習を用いた収穫日予測手法としての DNN モデルと、深層化されない NN モデルの予測精度を比較し、深層学習を用いた収穫日予測手法がより優れた精度を持つことを確認した。今後の課題として、学習を多数の高性能な計算機リソース上で分散実行させ、予測精度がより高いモデルを探索することがあげられる。

参考文献

- [1] 麻生 英樹・安田 宗樹・前田 新一・岡野原 大輔・岡谷 貴之・久保 陽太郎・ボレガラ ダヌシカ (2015) 『深層学習-Deep Learning-』, 近代科学社
- [2] Tianqi Chen, Mu Li, Yutian Li, Min Lin, Naiyan Wang, Minjie Wang, Tianjun Xiao, Bing Xu, Chiyuan Zhang, and Zheng Zhang. "MXNet: A Flexible and Efficient Machine Learning Library for Heterogeneous Distributed Systems". arXiv preprint arXiv:1512.01274, 2017.