

深層学習を用いた在庫数量判定方式の提案

川中天馬[†] 工藤司[†]

静岡理工科大学 情報学部 情報デザイン学科[†]

1. はじめに

製造業では、様々な部品の在庫を管理している。正確な在庫数量を把握するために棚卸を行わなければならない、多数の部品を手で数える必要があり非常に手間がかかっている。この効率化のため、在庫棚の画像の目視確認により、生産計画で算出された必要在庫の充足有無を判定する方式が提案されている[1]。この方式では、オフィスから画像のみで充足度を判定できるものの、多数の在庫の充足判定を人間が行うという手間は残っている。

一方、近年では、人工知能分野での画像認識精度の向上が報告されており、深層学習を用いて画像から自動的に判定することで効率化が期待できる。本研究では、この実現性を評価した。

2. 提案方式

本研究は、製造現場で在庫棚の状況をカメラで監視し、生産計画の必要在庫と照合することで、自動的に部品の調達指示を行う在庫管理システムを提供することを目標とする。この実現に向けて、本稿では、まず、在庫棚を撮影した画像から深層学習を利用して数量判定を行い、その結果を利用して調達指示の要否を判断する方式を提案する。具体的には、判定した数量が必要在庫を一定以上、上回る場合には充足していると判定し、下回る場合は自動調達する。なお、両者が近い場合には管理者に確認を依頼する。これにより、充足有無が明らかな場合には、人間の作業を不要にする。

深層学習では、教師あり学習を使用する。学習を行うために、大量のデータを集めたデータセットの作成を行う。そのデータ全てに正解ラベルを結びつけたものを使用する。

3. 実験

3.1 実験環境

企業では使用する部品としてボルトやナットなど様々な形状の物が存在するが、本研究では基本的な形状である球体のビー玉を使用した。また、本研究では学習を行うにあたり、DeepLearning用フレームワークとしてkerasを使

用して実行した。kerasはPythonで書かれた高水準のニューラルネットワークライブラリであり、容易に記述が出来るという特徴を持つ。

3.2 データセットの作成

機械学習に使用する学習データセットとして、発泡PSP容器の上にビー玉を5個区切りに80個まで各100枚、計1600枚の画像撮影を行った。ここでの画像は容器上からの俯瞰画像である。また、汎化性能を上げるために、撮影のたびにビー玉の位置を変更し、なるべく同じ画像をなくすように撮影を行った。その後、画像の回転や反転によりデータの水増しを行い、計8000枚の画像データ全てに正解ラベルが割り振られたデータセットを作成した。画像は前処理として100×100のサイズに縮小して使用した。

3.3 モデルの構築

本研究ではConvolutional Neural Network(以下、CNN)を用いた学習を行った。CNNは、画像認識分野において現在最も顕著な成功を収めている手法の1つである。

使用したCNNのモデルは、Convolutional層5層、Pooling層3層、Dropout層2層、Flatten層1層、Fully Connected層3層の組み合わせである。モデルの構造を、図1に示す。



図1 使用モデル

3.4 学習

学習では、データセットの8000枚の画像のうち6000枚を訓練データ(内600枚を検証用データとして使用)、2000枚をテストデータとして使用した。学習の回数は30回とし、バッチサイズを32とした。各種パラメータとしては、最適化アルゴリズムにrmsprop、誤差関数にcategorical_crossentropyを使用した。

図2は学習の遷移を示すグラフである。縦軸は正解率を表しており、横軸は学習回数を示す。太線は訓練データであり、細線は検証用データである。グラフが右上方向に収束化していることから、学習が進んでいると判断できる。

Proposal of Required Amount Satisfaction Determination Method Using Deep Learning

[†]Tenma KAWANAKA [†]Tsukasa KUDO

[†]Shizuoka Institute of Science and Technology

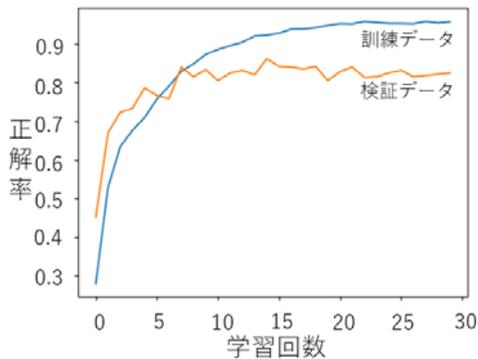


図2 学習遷移

4. 評価

4.1 精度の評価

深層学習による画像からの自動数量判定と、人間による画像からの数量判定の比較評価を行った。人間の被験者は17名である。評価に使用した実験用サンプル画像は、5個区切りに5個から80個の個数が写った画像32枚である。また、評価手順は、以下の通りである。1)被験者に画像と個数の対応のサンプルを覚えてもらう(図3)。2)サンプル以外の画像を、PC上で約10秒提示する。3)個数を回答してもらい、正解・不正解の割合で正解率を評価する。

深層学習では、3節のテストデータを使用して学習によって出力された結果と、正解ラベルの一致により正解率を評価する。

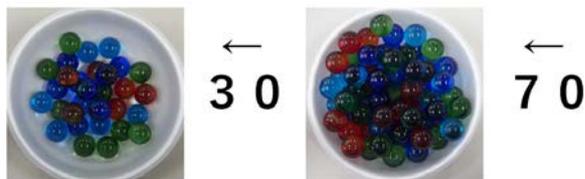


図3 被験者が確認したサンプル画像一例

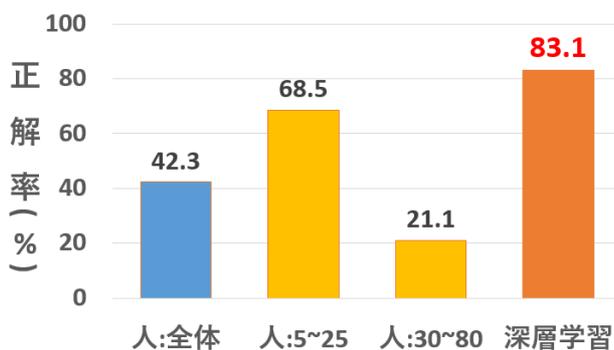


図4 人間と深層学習の正解率比較

評価結果としては、人間(人)の正解率は42.3%であり、深層学習の正解率は83.1%であった。また、人間においてはビー玉が重なっていない5~25個の画像であれば正解率は68.5%に達した。

一方、ビー玉が重なり合っている30~80個の画像データでは大きく減少し、21.1%の正解率しか得ることが出来なかった(図4)。

4.2 適用に関する評価

次に、充足度判定に適用する際の出カデータの分散度合いについて評価した。この事例では40個の画像データ500枚をテストデータとして使用した。図5は自動数量判定結果の分散を示す。30個から50個の間に98%のデータが含まれていた。すなわち、55以上では充足、30~45では目視での確認が必要、25以下では不足のため調達を行わなければならない、という判定が可能であった。従って、例えば、必要在庫数40で、55以上の結果を得た場合、この在庫は充足していると判定できる。なお、図5の65の様に外側に大きく外れて出力された結果があった。このような結果は判定対象から除外するものとした。

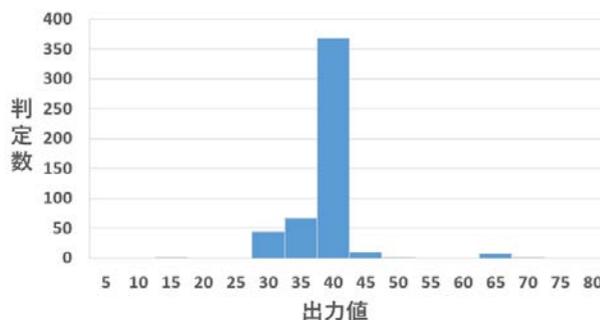


図5 自動数量判定結果の分散

5. 考察とまとめ

本稿では、深層学習を用いた在庫数量判定方式を提案した。人間では部品が重なっている画像であると認識精度は大きく低下するが、深層学習ではこの場合も十分な認識精度を得ることが出来、より高い精度で在庫数量判定を行えるということが分かった。また、学習済みモデルから出力された値と必要在庫数を比較することによって充足度判定が可能であった。

従って、深層学習を用いて数量を自動判定することは有効性が高いと考えられる。今後の課題として、部品の形状による正解率の変動評価がある。

なお、本研究はJSPS 科研費15K00161の助成を受けたものです。

参考文献

[1] T. Kudo, et al.: An Application of MongoDB to Enterprise System Manipulating Enormous Data, Int. Journal of Informatics Society, Vol. 9 (in press).