

深層学習を用いたチェックマーク式アンケートの自動認識に関する一検討

岩佐 英彦*、宮崎 勢三**

A Study on Automatic Recognition of Checkmark Questionnaire Using Deep Learning

Hidehiko IWASA, Seizo MIYAZAKI

Since the implementation of school evaluation questionnaires at public elementary and junior high schools has become compulsory, teachers have been burdened with counting questionnaires. On the other hand, in public schools, it is difficult to purchase a mark sheet reading device and mark sheet paper due to budget constraints. In this study, we investigate a method of totalizing questionnaires using a commercially available scanner using questionnaire paper that can be printed with a general printer. We propose a method using deep learning for check mark recognition, and show that sufficient recognition accuracy can be obtained by learning about 1000 samples.

Keyword Deep learning, Checkmark recognition, Automatic survey aggregation

1. 緒言

日本国内の公立小中学校においては、学期ごとの学校評価アンケートの実施、ならびに集計結果の公表が義務付けられており、多くの小中学校においては集計結果を学校のホームページなどで開示している。この実現のためにはアンケート結果の集計が必要となるが、多くの学校においては教員が集計作業を多忙な校務の合間に行っているのが現状である。

アンケートの集計の負担を低減するためには、アンケートをWEB化するなどデジタル化して集計を自動化する方法、マークシートを用いて集計をほぼ自動化する方法などの方法が有効である。小中学校における教職員のICTスキルには課題が多く、ほとんどの小中学校でデジタル化は行われていない。保護者が対象に含まれていることが多いために、デジタル化すると紙を提出してもらう場合と比較して回答率が低下してしまうこともデジタル化が普及しない一因となっている。

*近畿大学工業高等専門学校

総合システム工学科 制御情報コース

**独立行政法人 国立印刷局

マークシートを用いる方法としては、OMR(Optical Marksheet Reader)を用いる方法と、スキャナを用いる方法が主流である。一般的にOMRは高価であることから、公立の小中学校に導入することは困難であり、初等中等教育機関においては、センター試験対策などを学校内で行うこととなる高等学校などでの利用に限られている。

スキャナを用いる方法には、専用のマークシートを購入する方法があるが、専用のマークシートが1枚あたり15円程度の価格であることや、専用のマークシートの書式に合わせてアンケートを作成しなくてはならない点が不便であることなどから広く普及するには至っていない。

第一著者は、2015年までの約10年間、スキャナで読み取れるマークシート「スキャネットシート」の企画・開発・販売に従事していた経験を有するため、現場におけるアンケート集計の省力化に対するニーズの高さを実感しており、専用のシートを購入しなくても、学校の教員自身が一般的な文書作成ソフトを使用して作成することができて、なおかつスキャナで読み取ることによって集計処理が自動化できるシステムの必要性を認識している。

そこで本稿では、画像認識の分野で近年注目が高まっている深層学習の手法を用いることによって、文書作成ソフトで作成したアンケート用紙の自動集計の実現が可能か

についての検証を目的として実験を行い、実用的な認識精度を確認した結果について報告する。

2. 深層学習を用いたチェックマーク画像の認識手法について

2. 1 チェックマーク画像の特徴

チェックマークとは、「☑」のように、所定枠内にレ点を記入することによって回答を得るマーク形式のことである。入学試験等においては、楕円の枠内を鉛筆で塗りつぶす形式のものが多く、アンケートにおいては記入者の負担軽減を目的としてチェックマークが用いられることが多い。

チェックマークを用いたアンケートの特徴としては、第一に筆記用具が多様多様である点があげられる。入学試験等においては、鉛筆の濃さを指定し、楕円の枠内を一定程度以上の濃度で塗りつぶすことが指示できるために、認識対象となるマークの濃度は均一化されている。一方で、チェックマークの場合は、鉛筆、シャープペンシル、油性ボールペン、水性ボールペンなど多種多様な筆記用具が用いられるため、スキャナで画像化した場合の画素値は大きく変動する。

第二の特徴としては、チェックマークのレ点の形状の多様性があげられる。楕円の内部を塗りつぶす方式とは異なり、チェックマーク形式の場合は印刷された正方形のガイドラインを基準として様々な形状のチェックマークが記入される。このため従来の画像からのストローク抽出などに基づく手法ではチェックマークの認識精度を高めることは困難である。

ストローク抽出を用いずに、正方形のガイドライン近傍の画素値濃度分布等の情報に基づいてチェックマークの有無を判別する方法も考えられるが、専用用紙ではなく、普通紙に様々なプリンタを用いて印刷することを前提とした場合には、環境ごとでのキャリブレーション操作が必要となり、小中学校での導入を前提とした場合には困難が予想される。

以上の検討より、小中学校において使用するチェックマークシート方式のアンケート集計システムにおいては、チェックマーク記入時の多様性と、プリンタ等の印刷環境の多様性に依存せず、安定した認識精度を有する手法が必要であることがわかる。

2. 2 深層学習によるチェックマーク認識手法

従来のストローク抽出などの特徴抽出に基づく画像認識手法の性能限界を突破するアプローチとして、深層学習(Deep Learning)に基づく画像認識手法に注目が集まっている。深層学習とは、多層にわたるニューラルネットワーク(NN)を用いることによって、画像処理における画像の認識

問題(教師あり学習)や画像の分類(クラスタリング)問題(教師無し学習)を解決するアプローチである。

深層学習が様々な画像の認識・分類問題において卓越した認識精度を達成している理由として、畳み込み層とプーリング層と呼ばれる2種類のNNを多段接続することによって、多数の学習サンプルを用いても過学習することなく、自動的に所与の学習サンプルを識別するための汎用的な画像特徴を自動的に発見できることが指摘されている。

このような深層学習の特徴は、本検討が対象としているチェックマークの認識と言う問題におけるチェックマーク記入方式の多様性、ならびにチェックマーク記入のためのガイドラインの印刷を行うプリンタの多様性という問題に対して、多種多様な学習サンプルに基づいて汎用的な識別器を学習できる可能性があることを示唆している^[1]。

2. 2 畳み込み層とプーリング層

次に深層学習における畳み込み層とプーリング層について簡単に説明する。まず、畳み込み演算とは、与えられた画像領域($n \times m$)に対して、画像領域よりもサイズの小さい小領域($i \times j$)を設定し、その小領域を画像領域の全範囲に対して走査し、その位置毎に、画像領域と小領域の重複している領域の画素の値の積の和を求める計算のことである。このとき、小領域の画素値を0~1で正規化すると、小領域の値のパターンが特定の画像形状を表すこととなり、畳み込み演算の位置毎の計算値は、その位置における画像特徴の有無を表す指標となる。

次に、プーリング演算について説明する。同じ画像特徴を有する画像であっても、その画像特徴が出現する位置が少しでも上下左右に平行移動すれば、畳み込み演算によって得られる指標の値は変化するため、多数の画像サンプルからの学習においては識別器の過学習がおこりやすく汎化能力の低下に結びついてしまう。そこで、入力画像のぼかし処理に相当する演算処理、すなわち、近傍画素の画素値の平均値を求めたり、近傍画素の最大値を代表値として選択したりすることによって、画像の平行移動の効果を吸収しようとするのがプーリング演算である^[2]。

深層学習においては、入力画像に対して畳み込み演算を行う畳み込み層と、プーリング演算を行うプーリング層を多層的に組み合わせることによってNNを構成する。古典的なNNが全結合のネットワークを用いているのに対して、深層学習で用いられるNNでは畳み込み層とプーリング層という部分結合型のNNとなっているため、多層化された場合であっても逆伝搬学習法によるNNの重み学習が局所最適解に陥ることなく行われ、なおかつ過学習も回避することができることが報告されている。次節において深層学習を用いたチェックマークの認識実験について報告する。

3. 実験結果および考察

深層学習を用いたチェックマーク認識の実用性を検証するために実験を行った。まず、認識の対象とするチェックマーク画像について述べる。まず、アンケート用紙はMicrosoft社のWordを用いて作成し、「□」（しかく、と入力して変換）をチェックマークのガイドラインとして用いた。フォントサイズは標準的な10.5ptとした。この用紙をレーザープリンターを用いて印刷し、色々の筆記用具を用いてチェックマークを記入し、学習サンプルとした。図1に、学習サンプルとして用いたチェックマーク画像の例を示す。



図1. チェックマーク画像の例

このようなチェックマーク画像を500個用意し、教師あり学習における「マークあり」の教師画像として使用した。図1の右端のチェックマークの無い画像についても、画像の切り出し位置の異なるものを500個用意し、「マークなし」の教師画像とした。

図2に実験に用いたNNの構成を示す。入力画像はスキヤナの解像度とは関係なく、正方形のガイドラインの近傍を含む領域を30×30の正方形領域で切り出した900画素256階調のグレースケール画像である。

この入力画像に対して、畳み込み層とプーリング層による処理を交互に3回ずつ繰り返し、最終的な出力は1×1の128個の画像となるように設定した。畳み込み層の画像サイズが入力画像より2小さくなっているのは、畳み込み演算に3×3の小領域を用いているためである。また、プーリングは入力画像を4分割した4領域に対する平均値を用いて行った。最終的に、128個の値の多数決処理によって、「マークあり」と「マークなし」の識別を行った。なお、畳み込み層の出力には活性化関数（ReLU関数）を用い、畳み込み演算の結果を入力として0～1に正規化された値を出力とした。



図2. 学習・認識に用いたNNの構成

図3に実画像を用いてNNを学習させて行った認識実験の結果を示す。点で表示されているのが訓練データを用いた認識結果であり、線で表示されているのが訓練データには含まれていない画像データを用いた認識結果である。横軸は、学習データによる反復学習の回数（エポック数）を示している。

図3の結果より、訓練データの認識精度がエポックスの増加に伴って上昇しているものの100%には達しておらず、過学習が発生していないことが確認できる。そして、未知データに対する認識結果が訓練データの認識精度よりを上回っており、学習されたNNが高い汎化能力を有していることが確認できる。

表1に本実験に用いた未知画像の枚数の内訳と認識精度を示す。図1に示したような多種多様なチェックマーク画像を認識対象とし、非常にシンプルな畳み込み層とプーリング層を用いたNNを用いた基礎的検討において、マークあり画像の認識精度が99.2%に達したことは、深層学習を用いたチェックマークの認識のアプローチが有効であることを確認できた。




図3. NNを用いた学習過程と認識精度

表1: 実験に用いた画像での分類認識精度

種類	未知画像	正答数	誤答数	認識率(%)
全画像	1000	996	4	99.6
マークあり	500	496	4	99.2
マークなし	500	500	0	100

4. 結言

本稿では、小中学校における学校評価アンケートが抱える諸問題を指摘し、学校の教職員が一般的な文書作成ソフトを用いてアンケート用紙を作成し、スキャナを用いて自動的に集計することが可能な仕組みが必要であることを示した。そのうえで、チェックマークの認識には深層学習を用いた画像認識が適していることを考察したうえで、実験を通じてその有効性を示した。

実験の結果は、多様な筆記用具を用いて記入される様々な形状のチェックマークの認識に深層学習によって学習された NN が適切に機能していることを示すものであった。今後は、今回の実験で得られた 99.2% というマークあり画像の認識精度を高めるために、さらに大量の画像を用いた認識実験を行い、認識精度に資する NN の構成の変更や、畳み込み処理、プーリング処理のパラメータの最適化を行う。

また、Windows で動作するアプリケーション、あるいは WEB アプリケーションとして認識システムを開発し、広く全国の小中学校において使用可能なシステムとして公開することを目指して研究を進める予定である。

謝辞

本研究を実施するにあたり、深層学習の研究に必要不可欠である GPU を搭載したワークステーションなどの購入のために、近畿大学工業高等専門学校校内研究助成金の補助を頂いた。ここに感謝の意を表する。

参考文献

- [1] “A Fast Learning Algorithm for Deep Belief Nets”, G. E. Hinton, et al, Neural Computation, 2006.
- [2] “Deep LEARNIG(邦題 深層学習)”, Ian Goodfellow, Yoshua Bengio, Aaron Courville, pp.237-267, 2018.