

データ統合による CNN を用いた訪問介護支援システムの構築

Construction of Home Visit Nursing Care Support System
using CNN with Data Integration小森 一誠[†]
Issei Komori秦 優哉[†]
Yuya Hata高橋 大成[‡]
Taisei Takahashi大枝 真一[‡]
Shinichi Oeda

1. はじめに

一般的な訪問介護では、介護士は実際の活動内容と要介護者の健康状態等を紙媒体の記録用紙に記入し、他の介護士と情報共有を行っている。しかし、この記録用紙は介護施設内でファイリングされるため、訪問先への持ち出しや閲覧ができない。また、閲覧の際にはファイリングされた大量の記録用紙から必要な情報を探し出さなければならない。そこで、本研究では CNN による文字認識を利用した携帯情報端末を用いた訪問介護支援システムを構築する。本システムは画像化した記録用紙から日付と苗字を文字認識することによってデータ ID を作成し、これを用いて記録用紙をデータベースに登録する。記録用紙を閲覧する際には携帯情報端末を用いることで問題の解決を図る。また、現場の介護士の方々に特化したシステムにするため、学習用データとなる苗字の手書き文字を書くことを直接依頼する。しかし、データを大量に採取する場合、この作業自体が介護士の負担となるため、得られるデータは少ないと考えられる。そこで、介護士以外の人々が作成した学習データを加えてデータ統合を行うことで学習データの総数を増加させる。また、手書きの苗字画像のデータ構造を明らかにするために、主成分分析を用いてそのデータが持つ情報量から判断を行った。

2. 先行研究

訪問介護の現場では、要介護者に関する情報を介護士同士が事業所内で頻りに連絡を取り合うため、記録・伝達作業は介護の品質を左右する重要な要素である。この作業を紙媒体で行うため、時間がかかり、介護士の負担となっているのが現状である。これらの問題は記録用紙の電子化によって解決できると考えられる [1, 2]。

本研究と関連した研究の例として、矢口ら [3] 内山ら [4] 和田ら [5] 今井ら [6] 川崎ら [7] 加藤ら [8] が行った研究が挙げられる。これらの研究は、本研究と同様に記録用紙を電子化することを目的としている。

矢口らは、作成した Web システムを通じてパソコンやその他様々な端末から記録用紙の入力・閲覧ができるシステムの構築を行なった [3]。内山らは、同様のシステムを用い、パソコンからの記録用紙の入力をしやすくするため、クリック入力や各項目に大きなアイコンを用いるといった工夫を行なった [4]。和田らは、同様

に Web システムを用いてパソコンから記録用紙への入力を可能にしたが、従来の記録用紙ではなく Web システム向けに変更を加えた専用の記録用紙を用いた [5]。今井らは、端末の画面上にデジタルペンを用いて文字を直接記入し、OCR による文字認識によって記録用紙への入力を可能にしたシステムを構築した [6]。川崎らは、携帯情報端末を用いて電子化された記録用紙へのデータ入力と保存および検索・閲覧が可能なシステムを構築した [7]。これらの研究では、記録用紙の記入に関して従来の方法では用いなかった端末等からの入力を行っている。しかし、介護士が端末等の操作に慣れるまでの期間を要するため、負担となる可能性がある。そこで加藤らは、従来通り紙媒体の記録用紙と通常のペンを入力媒体とし、閲覧のみに携帯情報端末を利用するシステムを構築した。このシステムでは記録用紙内に新たにマークシートを設け、そこから読み取った番号から記録用紙のデータ ID を作成し、画像化した記録用紙をデータベースに保存していた。このデータ ID は、記録用紙の検索・閲覧の際にも用いる。しかし、作成したデータ ID がどの要介護者の記録用紙に対応しているのかを全て把握する必要があることや、マークシートの記入が煩雑であるという問題点が残った [8]。

これらの研究を踏まえ、本研究では、変更を一切加えていない紙媒体の記入用紙と通常のペンを入力媒体とし、マークシートを用いずにデータ ID を作成することでこれらの問題解決を試みる [9, 10]。データ ID の作成には CNN による要介護者の苗字・日付の文字認識を行うことで、検索が比較的容易なデータ ID の作成を試みる。

3. 訪問介護支援システム

構築する訪問介護支援システムの概要を以下に示す。また、その概略図を図 1 に示す。

1. 記録用紙をスキャンし、画像化する。
2. 画像が Web サーバに送られ、テンプレートマッチングによる特定領域の抽出が行われる。
3. 抽出された画像を入力とする CNN で文字認識が行われる。
4. 文字認識の結果からデータ ID を作成、画像に名前が付けられる。
5. 画像がデータベースに登録される。
6. 携帯情報端末からデータベースにアクセスすることで、訪問先で記録用紙が閲覧できるようになる。

[†]木更津工業高等専門学校 制御・情報システム工学専攻, Advanced Course of Control and Information Engineering, National Institute of Technology, Kisarazu College

[‡]木更津工業高等専門学校 情報工学科, Department of Information and Computer Engineering, National Institute of Technology, Kisarazu College

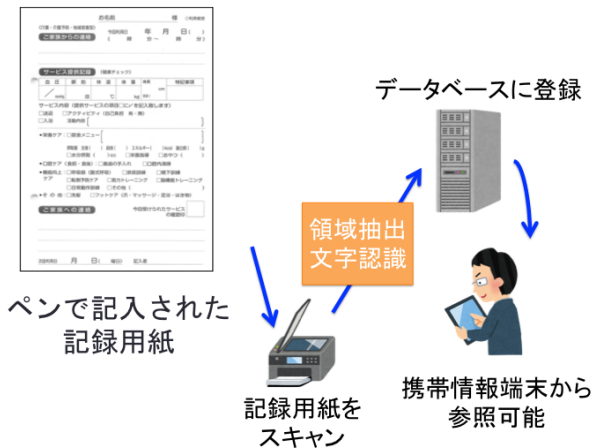


図 1: 構築する訪問介護支援システムの概略図

訪問介護の現場でのデータ参照を可能とするため、画像化された記録用紙をデータベースに登録し、携帯情報端末を用いて閲覧する。記録用紙をデータベースに登録するために CNN による文字認識の結果を用いてデータ ID を作成し、データ ID を画像に対応付けてデータベースに登録する。このデータベースを検索・参照することで記録用紙の閲覧を行う。

本研究では要介護者の名前と日付を入力として設定し、対応する記録用紙の画像が閲覧できる iOS アプリを開発することで実現を図る。

4. CNN による文字認識

CNN (Convolutional Neural Network) [11] はニューラルネットワークの応用手法である Deep Learning の手法の 1 つで、画像認識に特化したものである。CNN は、認識する画像データ群を用いて学習を行うことで、データの特徴量抽出や未知のデータを高精度に識別できる [12-14]。構築する訪問介護支援システムでは、スキャナ等によって記録用紙を画像化し、日付と要介護者の苗字の記入欄を画像認識することでデータ ID を自動的に作成する。作成したデータ ID は画像化された記録用紙をデータベースに保存・携帯情報端末からの検索・閲覧に利用する。

4.1. ニューラルネットワーク

ニューラルネットワークは、人間や動物の脳神経系を模した並列的な情報処理の数理モデルである。脳は、ニューロンと呼ばれる神経細胞がシナプスと呼ばれる結合部位を介して多数結合されている。ニューラルネットワークはこの構造を模して、多入力 1 出力のニューロンを 1 つのノードとして階層的にノードが接続されている。ニューロンのモデルを図 2 に示す。

図 2 中の x は観測された多次元の入力、 w はシナプスの結合重み、 θ は閾値である。 x および w の積の和と θ の差を活性化関数と呼ばれる関数 $a(\cdot)$ によって算出した y がニューロンの出力となる。活性化関数は図 2 中に示すようなシグモイド関数 $a(x) = \frac{1}{1+\exp(-x)}$ が




図 2: ニューロンのモデル




図 3: 階層型ニューラルネットワークのモデル

よく用いられる。このニューロンが階層型に接続されたものを図 3 に示す。階層型ニューラルネットワークでは、図 3 のように計算の向きは入力層から出力層に向かって一定である。

ニューラルネットワークは学習によって入力情報を正確に認識できるようになる。画像認識では教師あり学習を行う。教師あり学習とは、入力 x とそれに対応する正解出力 t の対になった集合 $\{(x_j, t_j); (j = 1, 2, \dots, M)\}$ を学習データとして、 x_j を入力したときの出力が t_j に近づくように結合重み w の値を修正することである。結合重みの修正には確率的勾配法を用いる。ネットワークの層数を N 、第 n 層の第 k ノードから第 $n+1$ 層の第 j ノードへの結合重みを $w_{kj}^{(n+1)}$ とするとき、結合重み w は以下の式で更新される。

$$w_{kj}^{(n+1)} \leftarrow w_{kj}^{(n+1)} - \eta \frac{\partial R(W)}{\partial w_{kj}^{(n+1)}} \quad (1)$$

ここで、 W はネットワーク全ての結合重みをまとめたものであり、 η は学習係数という更新する値の割合を示す正の小数である。 $R(\cdot)$ は誤差評価を行う関数で、例として二乗和誤差 $R(W) = \frac{1}{2} \sum_j (t_j - y_j^{(N)})^2$ とすると、式 (1) は以下ようになる。

$$w_{kj} \leftarrow w_{kj}^{(n+1)} - \eta \delta_j^{(n+1)} y_k^{(n)} \quad (2)$$

ここで、 $y_k^{(n)}$ は第 n 層の第 k ノードの出力である。 $\delta_j^{(n+1)}$ は、出力層での二乗和誤差 $\frac{1}{2} \sum_j (t_j - y_j^{(N)})^2$ か




図 4: 畳み込み層の構造

ら得られる $\delta_j^{(N)}$ から出発して以下のように再帰的に計算できる.

$$\delta_j^{(N)} = -(t_j - y_j^{(N)})y_j^{(N)}(1 - y_j^{(N)}) \quad (3)$$

$$\delta_j^{(n)} = \left\{ \sum_{k=1}^{K_{n+1}} \delta_j^{(n+1)} w_{kj}^{(n+1)} \right\} y_j^{(n)}(1 - y_j^{(n)}) \quad (4)$$

ここで K_{n+1} は、第 $n+1$ 層のノードの数である. この計算過程は、出力層での誤差を入力層へと向かって伝播させてゆく形で行われるため、誤差逆伝播法と呼ばれる.

4.2.CNN

CNN は畳み込み層とプーリング層という層が重なった構造をしており、活性化関数には収束性が良好な ReLU 関数 $a(x) = \max(x, 0)$ がよく用いられる. クラス分類を行う場合、最終層のノード数はクラス数 n と同じになる. 活性化関数にはノードへの入力 u_j をもとにソフトマックス関数 $P = \frac{\exp(u_j)}{\sum_{k=1}^n \exp(u_k)}$ を用いて P_j が最大になる j を推定クラスとする. CNN は特殊な形の階層型ニューラルネットワークであるため、学習は誤差逆伝播法で行うことができる.

4.2.1. 畳み込み層

畳み込み層では、畳み込み層のノードは下位層の全てではなく局所的受容野として 1 部のノードのみと結合している. また、その結合重みは各ノードで共有する構造となっている. 畳み込み層の構造を図 4 に示す. 以下、入力画像の縦横サイズを S 、チャンネル数を N とし、入力を x_{ijk} ($(i, j, k) \in [0, S-1] \times [0, S-1] \times [1, N]$) とする. 入力の各チャンネルごとに $L \times L$ サイズの 2 次元フィルタ w_{ijk} ($(i, j, k) \in [0, L-1] \times [0, L-1] \times [1, N]$) を畳み込み、その結果 u_{ij} を全 N チャンネルにわたって加算する. この計算は以下の式で表される.

$$u_{ij} = \sum_{k=1}^N \sum_{(p,q) \in P_{ij}} x_{pqk} w_{p-i, q-j, k} + b_k \quad (5)$$

ここで、 P_{ij} は画像中の画素 (i, j) を頂点とするサイズ $L \times L$ 画素の正方領域

$$P_{ij} = \{(i+i', j+j') \mid i' = j' = 0, \dots, L-1\} \quad (6)$$

である. b_k はバイアス項であり、各チャンネル k ごとに全出力ノード間で共通の値である. u_{ij} はその後活性化

表 1: 作成するデータの詳細

項目	詳細
種類	20
大きさ	縦 80, 横 123
次元数	9840

関数を通じて出力 y_{ij} となる. これによって 1 つのフィルタ w_{ijk} につき入力 x_{ijk} と縦横サイズが等しい $S \times S$ の 1 チャンネル出力 y_{ij} を得る. 学習では畳み込み層のフィルタの係数 w_{ijk} と出力ノードのバイアス b_k を決定する.

4.2.2. プーリング層

プーリング層の役割は、画像内に現れる特徴の微小な位置変化を吸収することである. 畳み込み層の後に置かれる層であるため、入力サイズは $S \times S \times N$ となる. プーリング層のノード (i, j) は畳み込み層と同じくその入力側の層に局所的受容野 P_{ij} を持つ. プーリングの処理は画像の縦横 (i, j) 間隔に間引いて行われるためその範囲となる s を設定する. $s = 2$ の場合、出力は入力の縦横半分のサイズになる. 受容野 P_{ij} 内のノードからの入力を以下の式による最大プーリング法で 1 つのノードに集約する.

$$y_{ijk} = \max_{(p,q) \in P_{ij}} x_{pqk} \quad (7)$$

プーリング層の出力はこの y_{ijk} であり、活性化関数を通すことはない. また、学習によって変化する重みが存在しない.

5. データ統合実験

5.1. データ統合

CNN に画像認識させる苗字の手書き文字画像の作成について、学習データ総数を増やすために介護士の方々だけでなく介護士以外の人々が作成した学習データを加えるデータ統合を行うことで、認識精度向上を目指す.

5.2. 実験概要

データ統合によって手書き文字認識精度がどのように変化するか明らかにするため、以下の実験を行った. 実験に用いるデータは 20 種類の手書きの苗字画像とし、木更津工業高等専門学校の学生に作成を依頼した. 依頼した学生のうち、16 人を介護士とみなしたグループ 1 とし、30 人を無関係者とみなしたグループ 2 とした. データは 1 人につき 20 種類の苗字を 2 回作成し、学習用・テスト用・統合用の 3 種類に分けた. 作成するデータの詳細を表 1 に、作成したデータの詳細を表 2 にそれぞれ示す.

実験方法を以下に示す.

1. 学習用データを用いて CNN を学習させる.
2. テスト用データを用いて苗字の認識精度を測定する.

表 2: 作成したデータの詳細

種類	作成者	データ数
学習用	グループ 1 (16 人)	640
テスト用	グループ 1 (16 人)	640
統合用	グループ 2 (30 人)	1200




図 5: データ統合による認識精度の変化

3. 統合用データから 5 人分のデータを学習用データに加える。
4. 手順 1. に戻り, 同様に実験を行う。

5.3. 実験結果

実験結果を図 5 に示す. 図 5 より, 統合したデータの数が多くなると認識精度が最高でおよそ 90% ほどまで高くなった. つまり, データ統合が有効であったことがわかる. しかし, 統合数が 20 人分のときから認識精度は向上せず, 下がることもあった. この結果を踏まえ, データ統合が学習用データに与えた影響について分析を行った.

6. 画像データ構造の分析実験

データ統合によって認識精度はある程度まで向上したが, 認識精度が下がることがあった. データ統合によって学習用データ構造にどのような変化が起きたのかを明らかにするため, 主成分分析を用いて観察を行った.

6.1. 主成分分析

主成分分析 [15] は, 観測された多次元データのもつ情報をできるだけ失わずにもとの変数の線形結合で表される新たな変数へ集約する手法である. データの特徴を高次元から低次元へ射影することで, 新たな意味を持つ変数を算出することができる. 本研究では採取したデータを主成分分析によって低次元化し, その累積寄与率を求めることで学習データが持つデータ構造について検討する.

各データ個体の特徴を表す p 個の変数を $\mathbf{x} = (x_1, x_2, \dots, x_p)^T$ とする. この p 個の変数に関して観測

された n 個の p 次元データを

$$\mathbf{x}_1 = \begin{pmatrix} x_{11} \\ x_{12} \\ \vdots \\ x_{1p} \end{pmatrix}, \mathbf{x}_2 = \begin{pmatrix} x_{21} \\ x_{22} \\ \vdots \\ x_{2p} \end{pmatrix}, \dots, \mathbf{x}_n = \begin{pmatrix} x_{n1} \\ x_{n2} \\ \vdots \\ x_{np} \end{pmatrix} \quad (8)$$

とし, これに基づいて, 標本分散共分散行列

$$\begin{aligned} S &= \begin{pmatrix} s_{11} & s_{12} & \cdots & s_{1p} \\ s_{21} & s_{22} & \cdots & s_{2p} \\ \vdots & \vdots & & \vdots \\ s_{p1} & s_{p2} & \cdots & s_{pp} \end{pmatrix} \\ &= \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \\ s_{jk} &= \frac{1}{n} \sum_{i=1}^n (x_{ij} - \bar{x}_j)(x_{ik} - \bar{x}_k) \end{aligned} \quad (9)$$

を求める. $\bar{\mathbf{x}}$ は p 次元標本平均ベクトルである. まず, p 個の変数の線形結合で表される射影軸

$$y = w_1 x_1 + w_2 x_2 + \dots + w_p x_p = \mathbf{w}^T \mathbf{x} \quad (10)$$

上に n 個の p 次元データを射影して, 1 次元データ $y_i = \mathbf{w}^T \mathbf{x}_i (i = 1, 2, \dots, n)$ を得る. この平均が $\bar{y} = \frac{1}{n} \sum_{i=1}^n \mathbf{w}^T \mathbf{x}_i = \mathbf{w}^T \bar{\mathbf{x}}$ となるため, 分散は

$$\begin{aligned} s_y^2 &= \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 \\ &= \frac{1}{n} \sum_{i=1}^n (\mathbf{w}^T \mathbf{x}_i - \mathbf{w}^T \bar{\mathbf{x}})^2 \\ &= \mathbf{w}^T \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \mathbf{w} \\ &= \mathbf{w}^T S \mathbf{w} \end{aligned} \quad (11)$$

と表される. つまり, $\mathbf{w}^T S \mathbf{w}$ を最大化するように射影軸を決めることになる. このとき, $\|\mathbf{w}\| \rightarrow +\infty$ によって分散が発散しないように $\mathbf{w}^T \mathbf{w} = 1$ の制約を設ける. 最大化にはラグランジュの未定数乗数法を用いて解く. λ をラグランジュ乗数として

$$L(\mathbf{w}, \lambda) = \mathbf{w}^T S \mathbf{w} + \lambda(1 - \mathbf{w}^T \mathbf{w}) \quad (12)$$

について

$$\frac{\partial L(\mathbf{w}, \lambda)}{\partial \mathbf{w}} = 0 \quad (13)$$

を解く. このとき, 以下のベクトル微分公式

$$\frac{\partial (\mathbf{w}^T S \mathbf{w})}{\partial \mathbf{w}} = 2S \mathbf{w} \quad (14)$$

$$\frac{\partial (\mathbf{w}^T \mathbf{w})}{\partial \mathbf{w}} = 2\mathbf{w} \quad (15)$$

を用いると、式 (13) は、以下ようになる。

$$\begin{aligned}\frac{\partial L(\mathbf{w}, \lambda)}{\partial \mathbf{w}} &= 0 \\ S\mathbf{w} - \lambda\mathbf{w} &= 0 \\ (S - \lambda I_p)\mathbf{w} &= 0\end{aligned}\quad (16)$$

I_p は p 次元の単位行列である。上記より、射影したデータの分散を最大とする係数ベクトルは標本分散行列 S の最大固有値 λ に対応する固有ベクトル \mathbf{w} として与えられる。

$|S - \lambda I_p| = 0$ の解として与えられる p 個の固有値を

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_i \geq \dots \geq \lambda_p \geq 0 \quad (17)$$

とする。また、各固有値に対応する長さを 1 に正規化した p 次元固有ベクトルを、それぞれ

$$\mathbf{w}_1 = \begin{pmatrix} w_{11} \\ w_{12} \\ \vdots \\ w_{1p} \end{pmatrix}, \mathbf{w}_2 = \begin{pmatrix} w_{21} \\ w_{22} \\ \vdots \\ w_{2p} \end{pmatrix}, \dots, \mathbf{w}_p = \begin{pmatrix} w_{p1} \\ w_{p2} \\ \vdots \\ w_{pp} \end{pmatrix} \quad (18)$$

とする。これらの固有ベクトルには長さ 1 のベクトルの正規化 $w_i^T w_i = 1$ と直交化 $w_i^T w_j = 0 (i \neq j)$ が成り立っている。このとき、もとの変数 x との線形結合で表される射影軸を主成分と呼び、各主成分を $y = (y_1, y_2, \dots, y_p)$ で表すとき、以下の式で求めることができる。

$$\begin{aligned}\text{第 1 主成分 } y_1 &= w_{11}x_1 + \dots + w_{1p}x_p = \mathbf{w}_1^T \mathbf{x} \\ \text{分散 } \text{var}(y_1) &= \lambda_1 \\ \text{第 2 主成分 } y_2 &= w_{21}x_1 + \dots + w_{2p}x_p = \mathbf{w}_2^T \mathbf{x} \\ \text{分散 } \text{var}(y_2) &= \lambda_2 \\ &\vdots \\ \text{第 } p \text{ 主成分 } y_p &= w_{p1}x_1 + \dots + w_{pp}x_p = \mathbf{w}_p^T \mathbf{x} \\ \text{分散 } \text{var}(y_p) &= \lambda_p\end{aligned}\quad (19)$$

以上の式によって新たな意味を持った変数を算出できる。次元圧縮によって次元数を減らすとその分だけ元の情報を損失してしまい、元のデータを表現することが困難になる。主成分分析ではこの情報損失が少なくなるように射影したデータの分散が最大になる軸を探している。第 i 主成分に含まれる情報量を寄与率 C_i といひ、式 (19) の分散を用いて以下の式で得られる。

$$C_i = \frac{\lambda_i}{\lambda_1 + \lambda_2 + \dots + \lambda_p} \quad (20)$$

また、第 k 主成分までの寄与率の総和を、累積寄与率 C_{all} と呼び、以下の式で得られる。

$$C_{all} = \frac{\lambda_1 + \lambda_2 + \dots + \lambda_k}{\lambda_1 + \lambda_2 + \dots + \lambda_k + \dots + \lambda_p} \quad (21)$$

累積寄与率は次元数 k までに元のデータの何割の情報量を持つかを示す指標である。少ない次元数で高い累積寄与率が得られれば、そのデータの構造が複雑ではなく、表現しやすいものであると考えられる。




図 6: 累積寄与率が 80% を超えるときの次元数の変化

6.2. 実験概要

実験手順を以下に示す。

1. 学習用データを主成分分析を用いて低次元化する。
2. 累積寄与率が 80% を超えるときの次元数を測定する。
3. 統合用データから 5 人分のデータを学習用データに加える。
4. 手順 1. に戻り、同様に実験を行う。

6.3. 実験結果および考察

実験結果を図 6 に示す。図 6 より、統合したデータの数が増えると累積寄与率が 80% を超えるときの次元数は増加したことがわかった。これは、グループ 2 の人々が作成したデータが混ざったことによって苗字の書き方が多様化したため、画像データ構造が複雑になったために多くの次元数が必要になったからだと考えられる。この仮説を検証するためには、グループ 1 の学習用データをグループ 2 と同じ人数分だけ増やし、同様の実験を行う必要がある。

6.4. 仮説の検証

データ統合による学習データの複雑化を検証するため、統合するデータをグループ 1 が作成したデータとした場合について以下の実験を行った。実験手順を以下に示す。

1. グループ 1 から新しく作成した手書き苗字画像を統合用データとして用意する。
2. 学習用データを主成分分析を用いて低次元化する。
3. 累積寄与率が 80% を越えるときの次元数を測定する。
4. 新たに用意した統合用データから 5 人分のデータを学習用データに加える。
5. 手順 2. に戻り、同様に実験を行う。




図 7: 累積寄与率が80%を超えるときの次元数の変化

6.5. 仮説の検証結果および考察

実験結果を図7に示す。図7より、統合するデータがグループ1から作成したものであっても必要な次元数は増加していくが、グループ2のデータを統合したときに比べて必要な次元数の増加を抑えられることがわかった。このことから、同じ苗字画像でも作成者が異なるデータが混ざるとデータ構造がより複雑化してしまい、学習が困難となってしまうと考えられる。これが5.3において認識精度が下がった原因と考えられる。

7. まとめ

訪問介護支援システムの構築について、CNNによる手書き文字認識を用いた改善案を提案した。また、認識精度を向上させるためにデータ統合を試み、このときの学習用データが持つデータ構造の変化を明らかにするため、主成分分析を用いた次元圧縮と累積寄与率が80%を越えるときの次元数を観察し、考察を行った。考察の結果から、作成者の異なるデータの統合によって学習用データが複雑化してしまったため、これによって学習が困難になったと考えられる。

今後の課題としては、認識精度向上のために学習用データの複雑化を抑えながらデータ統合を行う方法の検討などが挙げられる。

謝辞

本研究は、木更津商工会議所 医療・福祉・教育部会および、株式会社 R.O.F., 富沢産業株式会社との共同研究です。また、株式会社 宙 SOLA の寄付金助成を受けているものです。

参考文献

- [1] 竹内英二, “介護の質を高める ICT の活用”, 日本政策金融公庫調査月報, 第 89 号, pp. 4-15, (2016).
- [2] 厚生労働省 平成 28 年度 訪問介護雇用管理事務推進委託事業, “訪問介護事業所のための事務効率化 Q&A~これからの訪問介護を目指す事務効率化ガイド~”, 公益財団法人 介護労働安定センター, (2017).

- [3] 矢口隆明, 岩田彰, 白石善明, “在宅介護サービスにおける現場知を基にしたチームケアの知識流通システムの開発と評価”, 情報文化学会誌/情報文化学会編集委員会編, 第 16 巻, 第 2 号, pp. 12-20, (2009).
- [4] 内山映子, 宮川祥子, “在宅介護を前提とした小規模コミュニティにおける情報流通と管理”, KEIO SFC JOURNAL, Vol.4, No.1 (2005).
- [5] 和田成晃, 小出哲久, 矢口隆明, 白石善明, 岩田彰, “介護業務支援システム「アイケア」の開発”, 電子情報通信学会技術研究報告, 第 2008 巻, 第 70 号, pp. 65-70, (2008).
- [6] 今井雄一, 秋山直人, 菅沼満, 高橋賢司, 久下谷正行, 土屋洋之, 米田奈美子, 五藤寿樹, “訪問介護サービス管理における IT 活用とその実証実験について”, 日本社会情報学会 (JSIS&JASI) 合同研究大会研究発表論文集, 第 2007 巻, pp. 294-297, (2007).
- [7] 川崎直輝, 大枝真一, “携帯情報端末を用いた特別養護老人ホームの利用者データの電子化とその有効性の検証”, 情報処理学会第 70 回全国大会, 2ZF-7, (2008).
- [8] 加藤雄大, 大枝真一, “介護現場で用いる記録用紙の電子データ化システムの構築”, 情報処理学会第 74 回全国大会, 1ZJ-2, (2012).
- [9] 小森一誠, 秦優哉, 大枝真一, “Deep Learning を用いた訪問介護のデイ日誌の電子化”, 情報処理学会第 79 回全国大会, 5ZB-02, (2016).
- [10] 秦優哉, 小森一誠, 大枝真一, “CNN による文字認識を用いた訪問介護支援システムの構築”, 電子情報通信学会, B-18-29, (2016).
- [11] 岡谷貴之, “画像認識のための深層学習”, 深層学習 -Deep Learning- (人工知能学会学会監修), 近代科学社, pp. 153-188, (2015).
- [12] Alex Krizhevsky, *et al.*, “ImageNet Classification with Deep Convolutional Neural Networks”, NIPS'12 Proceedings of the 25th International Conference on Neural Information Processing Systems, pp. 1097-1105, (2012).
- [13] Quoc V. Le, *et al.*, “Building High-level Features Using Large Scale Unsupervised Learning”, ICML'12 Proceedings of the 29th International Conference on International Conference on Machine Learning, pp. 507-514, (2012).
- [14] David Silver, *et al.*, “Mastering the Game of Go with Deep Neural Networks and Tree Search”, Nature 529, pp. 484-489, (2016).
- [15] 小西貞則, “主成分分析”, 多変量解析入門 -線形から非線形へ-, 岩波書店, pp. 225-259, (2014).