

スケッチした pictorial symbols のディープラーニング のための部分的弾性変形を用いた形状学習データ生成

佐藤 信¹

概要: スケッチした pictorial symbols をディープラーニングを用いて学習するために、形状学習データの生成手法を提案する。提案手法では、SVG 形式で表現された pictorial symbols を基準形状として用いる。始めに、基準形状に部分的な弾性変形をおこなうことにより、多様な類似性をもつ形状を生成する。次に、形状の類似性を表現するための基準量に基づいて、生成した類似形状のなかから学習に用いる形状を選択する。そして、選択した類似形状を学習データとしてディープラーニングをおこなう。

Shape Learning Set Generation Using Partial Elastic Deformation for Deep Learning of Sketched Pictorial Symbols

MAKOTO SATOH¹

Abstract: This paper presents a learning set generation method for learning sketched pictorial symbols with deep learning. In the method, pictorial symbols represented using SVG format are used as base shapes. First the base shapes are deformed using partial elastic deformations so as a variety of similar shapes to be generated. Then learning shapes are selected from the generated shapes based on a criterion to represent shape similarity. The selected shapes will be used as shape learning sets for deep learning.

1. はじめに

本稿では、スケッチした pictorial symbols [11] をディープラーニングにより学習することを目的として、予め与えた少数の基準形状を基にして学習データを生成するための手法を提案する。

私たちの身の周りでは、各種の pictorial symbols が用いられている。pictorial symbols は、情報を直感的に伝達することを目的として用いられる。例として、各種の図中に用いられる簡潔な図形要素、ロゴ・タイプをシンボル化したロゴ・マーク、および、シンボル・マーク、ブランド・マークおよびトレード・マークなどの各種のマークを挙げることができる。

これらの pictorial symbols をスケッチした形状を、ディープラーニングなどの手法を用いて機械学習をするためには、大量の形状学習データが必要となる。提案手法では、

形状学習データを生成するための基準形状として、SVG 形式 [15] で表現した pictorial symbols を用いる。そして、基準形状に部分的な弾性変形 [14] をおこなうことにより類似形状を生成する。基準形状に弾性変形をおこなうことにより生成した類似形状を学習データとして用いる研究には、Fu 等 [4] がある。Fu 等 [4] では、Simard 等 [14] と同様の弾性変形をおこなっている。一方、本稿の手法では、形状を構成する部分形状ごとに弾性変形をおこなうことにより、Fu 等 [4] と比較してさらに多様な類似性をもつラフ類似形状を生成する。そしてさらに、ラフ類似形状のなかから、基準形状の学習形状として適する形状を選択する手法を提案する。

これ以降の構成について、簡単に説明する。2 節では、関連研究について比較をおこない、提案する手法の概要と特徴について述べる。そして、3 節では、部分的な弾性変形を用いて学習データを生成するための手法を提案する。提案手法の実装と実験結果の検討について 4 節で述べる。そして最後に、5 節で本稿のまとめと今後について述べる。

¹ 岩手大学
Iwate University, Ueda, Iwate 020-8551, Japan

2. 関連研究と提案手法の概要

2.1 学習データの重要性

機械学習においては、学習アルゴリズムと同様に、学習データも重要な役割を担う [2] .

機械学習のためのアルゴリズムでは、学習データを入力として、学習誤差が小さくなるように学習モデルのパラメータを推定することにより学習をおこなう。学習誤差の成分は、バイアス、バリエーションおよび削除不可能な誤差により構成される Geman 等 [5] . Mitchell[10], Geman 等 [5] が示すように、バイアスとバリエーションのトレードオフを考慮することにより、過学習に陥る危険性が小さくなるように学習をおこなうことが重要である。そのためには、十分な個数の学習データを用いて学習をおこなう必要がある。学習アルゴリズムの性能と学習データの個数の関係を調べた研究としては、Banko 等 [1] がある。ここでは、学習データの個数を変化させることにより学習アルゴリズムの認識性能が逆転する例を示し、十分な個数の学習データが必要であることを述べている。

また、Sculley 等 [13] が述べているように、機械学習を用いるシステムについては、一般的なシステムについての観点からだけでなく、機械学習に特有の観点から考慮するべき点がある。例えば、システムを構築する場合に用いた機械学習の学習データの性質が、システムの運用とともに変化する可能性があるのかどうかについての検討が必要である。その理由は、システムが取り扱うデータの性質が変化することにより、機械学習アルゴリズムの性能が低下する可能性があるからである。このような場合には、取り扱うデータの性質の変化にあわせて、新たな学習データを追加した学習データを用いて、機械学習のパラメータを再調整する必要がある。

2.2 形状データ augmentation

機械学習に用いるための学習データの収集には、多くの時間と労力を必要とする。例えば、Eitz 等 [3] では、形状が例示された場合に、その形状をどのようにスケッチするのかについて、機械学習を用いて分析をおこなっている。そこでの学習に用いたスケッチデータは、インターネットを利用することにより収集したものである。

一方、学習データを収集するための労力を削減することを目的として、学習データの augmentation がおこなわれる。学習データの augmentation(増補)とは、学習データの個数をアルゴリズムにより増加させることにより、学習データを補うことである。2.1 節で述べたように、過学習の可能性を減少させるためには、十分な個数の学習データを用いて学習をおこなう必要がある。そのため、過学習の可能性を減少させ、学習に用いていない入力データに対して頑健な学習をおこなうためには、データの augmentation

が有効である。

形状画像の学習データに augmentation をおこなっている例としては、Schmidhuber[12], Krizhevsky 等 [9] がある。ここでは、基準とする形状画像を基にして学習データの augmentation をおこない、形状の微小変化および照明の変化に対して頑健な学習をおこなっている。具体的な augmentation 手法としては、形状の微小変化に対する頑健性のためには基準とする形状画像に微小な移動変換を用い、そして、照明の変化に対する頑健性のためには色情報の変換を用いている。また、Fu 等 [4] は、少数の学習データを用いて手描きの線図形の画像を学習するために、学習データに augmentation をおこなっている。ここでは、Simard 等 [14] の提案による画像の弾性変形手法を用いて、スケッチ風の学習データを生成することにより、学習データの augmentation をおこなっている。

2.3 形状のディープラーニング

形状を機械学習するために、ディープラーニングを用いる研究が多数発表されている。しかし、それらの研究は、手描き数字の画像あるいは風景画像のパッチなどを対象とするものが多数であり、線図形をスケッチした形状を対象とするものは少数である。また、手描き数字の画像あるいは風景画像を対象する場合と比較して、線図形を対象とする場合には特有の工夫が必要になるのかどうかについてはほとんど研究がおこなわれていない。特に、スケッチした形状を学習する場合には、画像として表現したスケッチの形状の変化の度合いが大きいことに対応できる必要がある。

例えば、Fu 等 [4] では、スケッチした形状に augmentation をおこなった形状を訓練データとして機械学習をおこなっている。ここでは、学習手法としてディープラーニングを用いている。Hinton 等 [6] が示すように、ディープラーニングは、訓練データの特徴を抽出する性能に優れた手法である。Fu 等 [4] では、ディープラーニングの学習モデルのひとつである Deep Belief Network(DBN) [8] を用いている。DBN のパラメータの学習には、Restricted Boltzmann Machine(RBM) が用いられる。本稿の提案アルゴリズムでは、形状の特徴を捉えるために RBM を用いる。

2.4 提案手法の概要と適用分野

提案するアルゴリズムは、予め与えられた少数の形状を基にして、学習形状を生成するためのものである。スケッチした pictorial symbols の学習に用いることを目的として、2.2 節で述べた Simard 等 [14] の提案による画像の弾性変形手法に拡張をおこなった。その特徴を、以下に示す。

ラフ類似形状生成 形状の部分ごとに異なる弾性変形をおこなうことにより、粗く類似な形状を生成する。

学習形状の選択 生成したラフ類似形状のなかから、基準形状の学習に適した形状を選択する。そのために、形状の類似性の基準量として、RBMの再構築誤差を用いる手法を提案する。

提案手法を用いると、少数の形状データを基にして、機械学習のための学習データをアルゴリズムにより生成することが可能となる。それにより、認識しようとする手描き形状のカスタマイズが容易になることから、特定の適用分野に限定した図形形状の認識に用いることなどが考えられる。

3. 部分的弾性変形を用いた形状学習データ生成

3.1 アルゴリズムの各段階

提案するアルゴリズムでは、始めに、pictorial symbolsを表現する基準形状を基にしてスケッチ風の形状を生成する。そして、生成した形状から学習形状を選択する。その概要を、以下に示す。

Step1: 基準形状の生成 予め、pictorial symbolsの形状が、SVG形式の形状データとして与えられているとする。このSVG形式のデータから、形状を表現する画像を生成する。この形状画像は、学習形状を生成するための基準形状として用いられる。

Step2: 形状特徴の学習 基準形状に小さな変位の弾性変形をおこなうことにより、スケッチ風の類似形状を画像データとして生成する。そして、生成した画像の形状特徴を捉えるために、生成した画像をRestricted Boltzmann Machine(RBM)を用いて学習する。

Step3: ラフ類似形状の生成 基準形状に大きな変位の部分的な弾性変形をおこなうことにより、多様な類似性をもつ粗く類似な形状(ラフ類似形状)を生成する。

Step4: 学習形状の選択 生成したラフ類似形状のなかから、基準形状の学習に適した形状を選択する。ここでの選択には、Step2で学習したRBMを用いる。

これらの各段階について、これ以降の節において説明する。

3.2 基準形状の生成

予め、pictorial symbolsの形状が、SVG形式の形状データとして与えられているとする。このSVG形式の形状データから、学習形状を生成するために用いる基準の形状を生成する。

そのための手順は、2段階により構成される。始めに、SVG形式のデータの構文解析をおこなう。この構文解析の過程で、形状の部分グループごとに、形状を表現するBezier曲線を生成する。ここでの形状の部分グループとは、SVGの文法での形状グループのことである。SVG形式のデー

Algorithm 1 Base shape image generation

```
Read an SVG data into an SVG DOM doc.
Set currentNode to the root of the SVG doc.
Call function parseSVG( currentNode ).
Generate base shape images from parsedShapeGroups.
```

Algorithm 2 Function parseSVG(subRoot)

```
for each child node of the subRoot do
  if the node is an SVG group node then
    Parse the SVG transform attribute of the node.
    Push the parsed SVG transform parameters of the node
    into stackForTransform.
    Call function parseSVG( the node ).
    Pop the SVG transform parameters of the node out of
    stackForTransform.
  else if the node is an SVG path node then
    Parse the SVG path attribute of the node.
    Generate curves so as to represent the geometry of the
    parsed SVG graphical elements.
    Apply the all SVG transforms in stackForTransform,
    in order, to the generated curves.
    Add the transformed curves to parsedShapeGroups.
  end if
end for
```

タの構文解析をこのようにおこなうための手法を、アルゴリズム1, 2に示す。そして次に、生成したBezier曲線を形状の部分グループごとにラスタライズすることにより、形状の部分グループごとの形状画像を生成する。これらの形状画像を、学習形状を生成するための基準形状として用いる。

ここでは、SVGでの形状グループを単位として、基準形状の形状画像を生成する手法を述べた。同様の手順で、Bezier曲線の各セグメントを単位として、基準形状の形状画像を生成することが可能である。

3.3 形状特徴の学習

学習データを生成しようとするpictorial symbolsの形状の特徴を捉えるために、3.2節で生成した基準形状を用いて、以下の手順により特徴を学習する。

始めに、3.2節で生成した形状の部分グループごとの基準形状を1枚の画像に重ね合わせるにより、基準形状の全体の形状画像を生成する。次に、この形状画像に小さな弾性変形をおこなうことにより、基準形状に類似な形状画像を生成する。これらの類似形状の特徴を、Restricted Boltzmann Machine(RBM)を用いて学習する。その手順を、アルゴリズム3に示す。

弾性変形のアルゴリズムには、Simard等[14]でのアルゴリズムを用いる。このアルゴリズムは、Fu等[4]において、線画のディープラーニングを目的とする学習データの生成のために用いられている。一方、本研究では、弾性変

Algorithm 3 Shape feature learning

Set the total number of learning shapes to N .
Set the parameters of elastic deformation so as to generate small deformations:
 the kernel size and standard deviation of gaussian smoothing kernel, and the scaling value of the elastic deformation.
Overlay base shape images, generated using algorithm 1, so as to add up to a single image.
 $n \leftarrow 0$
while $n < N$ **do**
 Apply small elastic deformations to the overlaid shape image.
 $n \leftarrow n + 1$
end while
Learn the feature of the deformed images using RBM.

Algorithm 4 Roughly similar shape generation

Set the total number of generating roughly similar shapes to N .
Set the parameters of elastic deformation so as to generate large deformations:
 the kernel size and standard deviation of gaussian smoothing kernel, and the scaling value of the elastic deformation.
 $n \leftarrow 0$
while $n < N$ **do**
 for each base shape image generated using algorithm 1 **do**
 Apply large elastic deformations to the images.
 end for
 Overlay deformed images, generated from previous loop iterations, so as to add up to a single image.
 $n \leftarrow n + 1$
end while

形を2段階に分けておこなう。始めの小さな弾性変形では、基準形状の特徴を学習するための学習形状を生成する。そして、学習した特徴に基づいて、次の大きな弾性変形で生成した形状画像のなかから、スケッチ形状の学習データとして適当な形状画像を選択する。

3.4 ラフ類似形状の生成

多様な類似性を持つラフ類似形状を生成するために、3.2節で生成した基準形状に対して、以下の3種類の弾性変形をおこなう。

手法 1: 大きな変形 基準形状の全体の形状画像 (生成手法については3.3節を参照) に対して、大きな変位の弾性変形をおこない類似形状を生成する。

手法 2: 部分グループ単位の变形 3.2節で生成した形状の部分グループごとの基準形状の画像に大きな変位の弾性変形をおこない、部分グループごとの類似形状を生成する。ここでの弾性変形では、部分グループごとに異なる平滑化確率場を用いる。そして、それらの類似

Algorithm 5 Learning shape selection

Set the threshold of the reconstruction error of the shapes similar to training shapes to T_s .
Set the threshold of the reconstruction error of learning shapes to T_l .
Generate roughly similar shape images using algorithm 4.
for each image of generated roughly similar shape images **do**
 $e \leftarrow$ the RBM, trained using algorithm 3, reconstruction error of the image
 if $e < T_s$ **then**
 Add the image to **similarLearningImages**.
 else if $e < T_l$ **then**
 Add the image to **otherLearningImages**.
 else
 Add the image to **otherImages**.
 end if
end for
similarLearningImages and **otherLearningImages** are selected as learning shapes.

形状を、1枚の画像に重ね合わせるにより全体形状の類似形状を生成する。

手法 3: セグメント単位の变形 手法2と同様の操作を、3.2節で生成した形状の部分グループを構成する Bezier 曲線の各セグメントに対しておこなう。

それぞれの弾性変形には、Simard 等 [14] でのアルゴリズムを用いる。手法1により得られる変形形状は、Fu 等 [4] と同様の種類の変形形状である。一方、手法2,3により得られる形状は、1枚の全体形状の画像を生成するために、異なる複数の平滑化確率場を用いることから、Fu 等 [4] では得ることが不可能な変形形状を得ることが可能である。例えば、異なる形状グループに含まれる曲線どうしが接続する形状に対して手法2を用いた場合には、接続方法に変化を与えることが可能である。接続点での交差の程度に変化を与える、あるいは、接続を離すということが可能である。手法3については、異なる平滑化確率場を用いる単位が曲線セグメント単位であることにより、さらに変化の度合いが大きくなる。手法2を、アルゴリズム4に示す。手法3についても、同様である。

3.5 学習形状の選択

3.4節では、ラフ類似形状を生成するための手法について述べた。本節では、生成したラフ類似形状のなかから、基準形状をスケッチした形状の学習に適した形状を選択するための手法について述べる。そのアルゴリズムを、アルゴリズム5に示す。このアルゴリズムでは、形状を選択するための基準として、ラフ類似形状と基準形状との類似度を用いている。具体的には、(1)式に示す RBM の再構築誤差を類似度として用いている。なお、ここで用いる RBM は、3.3節で述べた手法を用いて基準形状の特徴を学習し

た RBM である。

$$e = \sqrt{\sum_i |v_i - \hat{v}_i|^2}. \quad (1)$$

ここで、ベクトル \mathbf{v} 、そして、 $\hat{\mathbf{v}}$ は、それぞれ、RBM の入力ベクトル、そして、その再構築ベクトルである。具体的には、入力ベクトルは、ラフ類似形状の画像データをベクトルに変換したものである。ここでの再構築ベクトルとは、RBM によりエンコードしたベクトルをデコードして得られるベクトルのことである。

(1) 式により得られる RBM による再構築誤差と予め与えた閾値とを比較することにより、ラフ類似形状と基準形状との類似度を判断する。

4. 実装と結果の検討

3 節で提案したアルゴリズムを実装し、その有効性について検討した。

4.1 ラフ類似形状の生成例

3.2 節で述べたアルゴリズム 1, 2 を用いてラフ類似形状を生成するための基準形状を生成した。図 1, 2, 3 の各図の第 1 行の左端の形状は同じ形状であり、これらが基準形状である。基準形状を生成するためにアルゴリズムの入力として用いた SVG 形式の形状定義では、3 個の部分グループ(コーヒーマグ、受け皿およびハンドル)により形状が表現されている。そのように SVG 形式により表現された形状を構文解析することにより、形状を表現する Bezier 曲線を形状の部分グループごとに生成した。この例では、Bezier 曲線の本数は、16 である。そして、その形状の部分グループごとにラスターサイズをおこない、基準形状の部分画像を生成した。それらの部分形状画像を、1 枚の画像に重ね合わせたものが各図の第 1 行の左端に示す基準形状である。

各図の基準形状以外の形状は、弾性変形を用いて生成した類似形状である。図 1 は、Simard 等 [14] での弾性変形手法を用いて生成した類似形状の例である。図 2 は、アルゴリズム 4 を用いて生成した、ラフ類似形状の例である。Simard 等 [14] での弾性変形手法を、形状の部分グループごとに適用している。図 3 は、アルゴリズム 4 と同様の変形を、形状を構成する各 Bezier セグメントごとに適用することにより生成したラフ類似形状である。

各類似形状を生成するための弾性変形では、平滑化確率場を用いている。各形状ごとに必要となる平滑化確率場の数は、図 1, 2, 3 では、それぞれ、1, 3 そして 16 個である。

4.2 学習形状の選択

生成したラフ類似形状のなかから、学習形状として適当なものを選択する例を図 4, 5 に示す。ここでは、アルゴリ

ズム 5 を用いた。なお、形状の画像サイズは 100×100 ピクセルである。

図 4 の第 1 行が、RBM の学習に用いた学習形状である。これらの形状は、図 1 に示す基準形状を基にして、アルゴリズム 3 を用いて生成した類似形状である。なお弾性変形の倍率として、40 を用いた。これらの形状画像に前処理をおこなったものを、RBM の入力として用いた。前処理として、始めに、画像の形状の周辺部分の余白を削除し、そして画像サイズを 100×100 ピクセルに拡大した。その後、拡大した画像を 2 値化した。前処理後の形状を、図 4 の第 2 行に示す。

基準形状の特徴を捉えるために、RBM を用いて形状の学習をおこなった。RBM の訓練に用いた画像の枚数は、基準形状の画像 1 枚とその類似形状の画像 1000 枚であり、合計 1001 枚である。RBM の訓練に用いたハイパーパラメータを、表 1 に示す。

次に、アルゴリズム 4 の中で述べた手法を用いて、ラフ類似形状を生成した。アルゴリズム 4 では、弾性変形の単位は、形状の部分グループであるが、それに加えて、Bezier 曲線の各セグメントを単位としてラフ類似形状を生成した。なお、弾性変形の倍率として、50, 80, および、200 を用いた。さらに、基準形状に近い類似形状を得るために、アルゴリズム 3 の中で述べた手法において弾性変形の倍率を 50 として、ラフ類似形状を生成した。

そして、アルゴリズム 5 を用いて、これらの生成したラフ類似形状のなかから、基準形状の学習形状として適当な形状を選択した。その結果を、図 5 に示す。図 5 の第 1, 2 行は、基準形状との類似度が大きい形状として選択された形状である。図 5 の第 3, 4 行は、基準形状との類似度が小さい形状であるが、学習データとして適当であるとして選択された形状である。図 5 の第 5, 6 行は、学習データとして適当でない形状であるとして選択された形状である。なお、 $T_s = 40, T_l = 45$ とした。

4.3 検討

図 1, 2, 3 から、基準形状に弾性変形をおこなうことにより、基準形状に類似なスケッチ風の形状を生成することが可能であることが分かる。図 1 と図 2, 3 とを比較すると、形状の各部分グループあるいは形状を表現する Bezier 曲線の各セグメントを単位とした部分的な弾性変形をおこなうことにより、より多様なラフ類似形状を生成可能であることが分かる。

図 4, 5 から、基準形状の特徴を学習した RBM によるラフ類似形状の再構築誤差を用いることにより、基準形状の学習形状として適した形状を選択することが可能であることが分かる。しかし、学習形状として適しないと判断された形状のなかにも、学習形状として用いることが可能な形状が含まれている。提案のアルゴリズムにより選択した形

表 1 RBM の訓練に用いたハイパーパラメータ
Table 1 Hyper-parameters for RBM training

learning rate	momentum	weight decay
0.0001	0.5	0.00001

状を用いて RBM を再学習することにより、基準形状の特徴を捉え直すなどの改良が考えられる。

形状の評価のための閾値の決定には、RBM の訓練での学習誤差を基準として用いている。RBM の訓練には contrastive divergence を用い、学習誤差の計算には RBM の入力ベクトルと negative phase での visible vector を用いている。閾値の選択方法については、今後の課題である。

5. おわりに

スケッチした pictorial symbols をディープラーニングにより学習することを目的として、予め与えた少数の基準形状を基にして学習データを生成するための手法を提案した。

特徴は、SVG 形式で表現された pictorial symbols を基準形状として、それに部分的な弾性変形をおこなうことにより、スケッチ風の多様な類似性を持つラフ類似形状を生成すること、そして、RBM を用いて基準形状の特徴を捉えることにより、ラフ類似形状のなかから学習形状として適した形状を選択することである。

提案手法を実装することにより、与えられた pictorial symbols を基にして、スケッチ風の多様な類似形状を生成することが可能であることを示した。また、ラフ類似形状から基準形状の学習に適した形状を選択することが可能であることを示した。

今後の課題には、複雑な形状への適用、そして、生成した学習形状を用いてのスケッチした pictorial symbols のディープラーニングなどに関する研究を挙げることができる。

参考文献

- [1] Banko, M. and Brill, E.: Mitigating the Paucity-of-data Problem: Exploring the Effect of Training Corpus Size on Classifier Performance for Natural Language Processing, *Proceedings of the First International Conference on Human Language Technology Research*, HLT '01, Stroudsburg, PA, USA, Association for Computational Linguistics, pp. 1–5 (online), DOI: 10.3115/1072133.1072204 (2001).
- [2] Edwards, C.: Growing Pains for Deep Learning, *Commun. ACM*, Vol. 58, No. 7, pp. 14–16 (online), DOI: 10.1145/2771283 (2015).
- [3] Eitz, M., Hays, J. and Alexa, M.: How do humans sketch objects?, *ACM Trans. Graph.*, Vol. 31, No. 4, pp. 44:1–44:10 (online), DOI: 10.1145/2185520.2185540 (2012).
- [4] Fu, L. and Kara, L. B.: Technical Section: Neural Network-based Symbol Recognition Using a Few Labeled Samples, *Comput. Graph.*, Vol. 35, No. 5, pp. 955–966 (online), DOI: 10.1016/j.cag.2011.07.001 (2011).
- [5] Geman, S., Bienenstock, E. and Doursat, R.: Neural Networks and the Bias/Variance Dilemma, *Neural Comput.*, Vol. 4, No. 1, pp. 1–58 (online), DOI: 10.1162/neco.1992.4.1.1 (1992).
- [6] Hinton, G. E. and Salakhutdinov, R. R.: Reducing the Dimensionality of Data with Neural Networks, *Science*, Vol. 313, No. 5786, pp. 504–507 (2006).
- [7] Hinton, G. E.: A Practical Guide to Training Restricted Boltzmann Machines, *Neural Networks: Tricks of the Trade - Second Edition*, Vol. 7700, Springer, pp. 599–619 (2012).
- [8] Hinton, G. E., Osindero, S. and Teh, Y.-W.: A Fast Learning Algorithm for Deep Belief Nets, *Neural Comput.*, Vol. 18, No. 7, pp. 1527–1554 (online), DOI: 10.1162/neco.2006.18.7.1527 (2006).
- [9] Krizhevsky, A., Sutskever, I. and Hinton, G. E.: ImageNet Classification with Deep Convolutional Neural Networks, *Advances in Neural Information Processing Systems 25* (Pereira, F., Burges, C., Bottou, L. and Weinberger, K., eds.), Curran Associates, Inc., pp. 1097–1105 (2012).
- [10] Mitchell, T. M.: The Need for Biases in Learning Generalizations, *Readings in Machine Learning* (Shavlik, J. W. and Dietterich, T. G., eds.), Morgan Kaufman, pp. 184–191 (1980).
- [11] Modley, R. and Myers, W.: *Handbook of Pictorial Symbols: 3,250 Examples from International Sources*, Dover pictorial archive series, Dover Publications (1976).
- [12] Schmidhuber, J.: Multi-column Deep Neural Networks for Image Classification, *Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, CVPR '12, Washington, DC, USA, IEEE Computer Society, pp. 3642–3649 (online), available from (<http://dl.acm.org/citation.cfm?id=2354409.2354694>) (2012).
- [13] Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., Chaudhary, V. and Young, M.: Machine Learning: The High Interest Credit Card of Techni-




図 1 弾性変形を用いた類似形状の生成 (左上:基準形状)

Fig. 1 Similar shape generation using elastic deformation method. Left of the first row: a given base shape, composed of 3 groups: coffee cup, saucer and grab. Others: generated shapes using elastic deformation method.




図 2 形状の部分グループごとに部分的な弾性変形をおこなったラフ類似形状の生成 (左上:基準形状)

Fig. 2 Roughly Similar shape generation by applying partial elastic deformation to each shape group. Left of the first row: a given base shape, composed of 3 groups: coffee cup, saucer and grab. Others: generated shapes using partial elastic deformation method.




図 3 形状の Bezier セグメントごとに部分的な弾性変形をおこなったラフ類似形状の生成 (左上:基準形状)

Fig. 3 Roughly similar shape generation by applying partial elastic deformation to each Bezier segment of the shapes. Left of the first row: a given base shape, composed of 3 groups: coffee cup, saucer and grab. Others: generated shapes using partial elastic deformation method.




図 4 RBM の訓練形状の例 (第 1 行:弾性変形後, 第 2 行:トリミング, 拡大そして 2 値化後)

Fig. 4 Examples of the shapes used in the training of RBM. First row: elastically deformed shapes. Second row: shapes generated by applying trimming, scaling and binarization to elastically deformed shapes.




図 5 RBM を用いたラフ類似形状からの学習形状の選択

Fig. 5 Selection of learning shapes from roughly similar shapes using RBM. First and second rows: shapes selected as learning shapes, similar to the RBM training shapes. The reconstruction errors e of the shapes are less than T_s . Third and fourth rows: shapes selected as the other learning shapes ($T_s \leq e < T_l$). Fifth and last rows: shapes selected as the other shapes than above shapes.

cal Debt, *SE4ML: Software Engineering for Machine Learning (NIPS 2014 Workshop)* (2014).

- [14] Simard, P. Y., Steinkraus, D. and Platt, J. C.: Best Practices for Convolutional Neural Networks Applied to Visual Document Analysis, *Proceedings of the Seventh*

International Conference on Document Analysis and Recognition - Volume 2, ICDAR '03, Washington, DC, USA, IEEE Computer Society, pp. 958-963 (2003).

- [15] W3C: *Scalable Vector Graphics (SVG) 1.1 Specification (Second Edition)*, <http://www.w3.org/> (2011).