

ドローイング学習支援システムにおけるストローク形状分類機能の性能向上のための形状分類モデルの開発に関する基礎的検討

A Basic Study on Developing a Stroke Shape Classification Model to Improve the Performance of Stroke Shape Assessment Functions in the Drawing Learning Support System

浅井 雄大^{*1}, 香山 瑞恵^{*2}, 館 伸幸^{*2}, 永井 孝^{*3}
Yudai ASAI^{*1}, Mizue KAYAMA^{*2}, Nobuyuki TACHI^{*2}, Takashi NAGAI^{*3}

^{*1} 信州大学大学院総合理工学研究科

^{*1} Graduate School of Science and Technology, Shinshu University

^{*2} 信州大学工学部

^{*2} Faculty of Engineering, Shinshu University

^{*3} ものづくり大学技能工芸学部

^{*3} Faculty of Technologists, Institute of Technologists

Email: 23w2004a@shinshu-u.ac.jp

あらまし：我々はこれまで、ドローイングのスキル獲得を支援するシステムを構築・運用してきた。本研究の目的は、同システムにおける、ドローイング作品に対する自動評価機能の性能向上である。本稿では、先行研究で構築されたストローク形状分類機能の精度評価を行う。また、精度改善のため、機械学習を用いた新たな分類手法を提案する。そして、提案手法と先行研究での分類手法の精度を比較し、形状分類機能の信頼性について考察する。

キーワード：ドローイング, 2 値分類

1. はじめに

ドローイングは、濃淡をもつ線(ストローク)を用いて、描画対象物(モチーフ)の形状や質感を描画することである。ドローイングは、美術教育における基礎的な技術として位置づけられ、美術入門者が最初に学ぶべき内容とされる^(1,2)。本研究では 2012 年度より、このドローイング学習を支援するシステムを運用している。美術専門学校でのデジタルドローイングクラスで用いられているこのシステムは、毎年約 20 名により入学時から隔週で 6 回のドローイングデータを蓄積している。対象モチーフは紙箱(前半 3 回)と紙袋(後半 3 回)である。

ドローイング学習では、「モチーフを単純な形状のストロークで描くこと」が指導される。崎本⁽³⁾はこの指導を支援するため、各ドローイングに含まれるストローク形状の種類や、その割合を提示するシステムを構築している。形状の分類には、美術指導者へのヒアリングにもとづくルールベースのモデルが用いられている。しかし、ストローク形状の分類性能について評価が不十分である。

本稿では、先行研究での形状分類モデルの評価と改善を目的とする。また、分類精度改善のため、機械学習を用いる。機械学習の手法やハイパーパラメータ、入力特徴量の最適な組合せを模索し、新たな分類手法を提案する。次のリサーチクエスチョン(RQ)を設ける。

RQ: 本稿で提案するストローク形状分類モデルと、モデルに入力する特徴量、特徴点の抽出方法と数の組合せのうち、最も F 値が大きくなる組合せはどれか。また、その F 値は先行研究と比べ、どの程度か。

2. 実験: 分類モデルの構築

本章では、形状分類モデルへの入力対象データと、前処理の方法、特徴量の抽出方法、分類に使用する機械学習手法について述べる。そして、構築したモデルを用いて分類精度を導出する手順を述べる。

2.1 入力対象データ

分類モデルへの入力対象として、スキルの習熟度が異なる 3 名の描画者 A, B, C と熟練者 1 名が描いた、合計 23 個のドローイングデータを使用する。対象モチーフは紙箱と紙袋とする。

ドローイングデータからランダムに抽出した各ストロークに対し、美術指導者 1 名が、好ましい直線と曲線、指導対象の複雑線という、3 種のラベルを付ける。その結果、正解ラベル付きのストロークデータ、合計 1035 個を得た。

2.2 ストローク座標の前処理

ストロークデータを分類モデルへの入力形式に適した形式にするため、変形処理を施す。本実験では、各ストロークを構成する 2 次元直交座標に対し、回転処理、平行移動、ストローク外包矩形の正規化、特徴点の抽出を行う。なお、特徴点の抽出には、形状を保つために線分ベクトル間のコサイン類似度が大きい箇所から座標を抽出する方法(抽出方法 1)と、一定間隔の長さで特徴点を抽出する方法(抽出方法 2)の 2 種類を採択した。

2.3 特徴量の抽出

本実験では、分類モデルに対し、特徴点ごとに特徴量を抽出する。抽出する特徴量は以下とする。

- 特徴点の 2 次元直交座標(特徴量 1)
- 隣接する特徴点間のベクトル(特徴量 2)
- 隣接する特徴点間のベクトルどうしのコサイン

表 1 交差検証での F 値が最も大きくなるパラメータの組合せとテスト精度

手法	特徴点の抽出方法	特徴点の数 [個]	入力特徴量	K-fold交差検証の精度 (K=5) [%]			テスト精度 [%]		
				再現率	適合率	F値	再現率	適合率	F値
ルールベース ³⁾	—	—	—	—	—	—	99.5	92.8	96.0
LGR	抽出方法2	12	特徴量3	98.2	96.1	97.2	97.9	94.0	95.9
k-NN	抽出方法1	7	特徴量4	98.7	96.2	97.4	98.4	96.9	97.7
SVM	抽出方法1	16	特徴量4	99.1	96.4	97.7	98.4	95.0	96.7
RF	抽出方法2	52	特徴量4	96.7	98.2	97.4	95.3	97.4	96.3

類似度(特徴量 3)

- 隣接する特徴点間のベクトルと、始点から終点までのベクトルとのコサイン類似度(特徴量 4)

2.4 分類手法の選択

本実験では、好ましい形状か否かの 2 値分類を行う。直線と曲線を好ましい形状とし、それ以外を好ましくない形状とする。分類手法には、ロジスティック回帰 (LGR:Logistic Regression), k 近傍法 (k-NN:k-Nearest Neighbor), サポートベクターマシン (SVM:Support Vector Machine), ランダムフォレスト (RF:Random Forest)を用いる。なお, SVM には Gaussian カーネルを採用した。また, 本実験では分類精度を測る指標として, 再現率, 適合率, F 値を使用し, 各手法の間でそれぞれの指標を比較する。

2.5 分類精度の導出手順

入力対象データを, 学習・検証用(725 個)とテスト用(310 個)に分割する。その際, 直線と曲線と複雑線が同じ割合になるよう層化抽出する。まず, 学習・検証データのみを用いて, 特徴点の抽出方法と数, 入力特徴量, ハイパーパラメータの組合せごとに K-fold 交差検証(K=5)を行う。その際, 各入力特徴量を 0~1 で正規化する。そして, 5 回分の F 値の平均値を求め, 分類手法ごとに, 各交差検証における F 値の平均値が最も高いモデルを選定する。最後に, テストデータを入力し, 再現率, 適合率, F 値を算出し, 汎化性能を確認する。

3. 結果と考察

3.1 分類精度の比較

各手法の分類精度を表 1 に示す。ルールベースについて, 再現率が適合率を 6.7[%]上回り, F 値は 96.0[%]となった。

RQ にもとづき提案手法を比較した結果, F 値がルールベースを最も大きく上回る手法は, 交差検証時では SVM(=97.7[%]), テストデータにおいては k-NN(=97.7[%])であった。また, 特徴量の抽出方法について, 両手法において元のストローク形状を保持するよう努める方法(抽出方法 1)が最適であった。そして, 抽出座標数は SVM で 16 個, k-NN で 7 個が最適であった。また, 最適な特徴量は, 隣接する特徴点間のベクトルと, 始点から終点までのベクトルとのコサイン類似度(特徴量 4)であった。

3.2 考察

ルールベースでは, 再現率が適合率を上回った。すなわち, 指導者から見て指導対象であるストロー

クも好ましいと分類してしまう傾向が強い。

最適な組合せでの SVM や k-NN をテストデータに適用した結果, ルールベースと比較し, 再現率は下回り, 適合率は上回る結果となった。よって, ルールベースでの分類の傾向は抑えられたといえる。また, 最適な組合せで構成したモデルとは別に, 再現率がルールベースを上回る組合せもあった。しかし, その場合, 最適な組合せでの適合率を下回った。再現率と適合率のトレードオフ⁴⁾により, 両指標ともにルールベースの精度を上回るのは難しいと考える。

4. おわりに

本研究の目的は, 先行研究での形状分類モデルの評価と改善である。本稿では, ストローク形状を分類するモデルの構築および, 先行研究との精度比較を行った。今後は, 以下の方針で研究を進める。

- 誤分類ストロークの傾向を解析し, 表 1 に示した組合せが最適であった理由を明らかにする。
- 各パラメータの組合せごとの精度を分布で比較し, 最適な組合せでの精度と有意な差があるか検証する。

謝辞

遠隔ドローイング学習支援システムを 2012 年より導入および, データの収集にご協力いただいている日本外国語専門学校留学科の関係者の皆様に感謝申し上げます。本研究の一部は科研費(23K17015)により支援されている。

参考文献

(1) 佐藤聖徳: “美術・デザイン系大学におけるデザイン指導の発展的試み”, 静岡文化芸術大学研究紀要, Vol.4, pp.153-162 (2004)

(2) 関根英二: “美術体系の試み”, 美術教育学会大学美術教科教育研究会報告, Vol.6, pp.89-100 (1984)

(3) 崎本貴之, 永井孝, 香山瑞恵, 橋本昌巳: “ドローイング学習支援システムにおけるドローイング自動評価機能の性能向上のための指導対象ハッチング同定アルゴリズムに関する検討”, 人工知能学会第二種研究会資料, Vol.2017, No.KST-30, pp.2-7 (2017)

(4) Aurélien Geron 著, 下田倫大監訳, 長尾高弘訳: “scikit-learn と TensorFlow による実践機械学習”, 株式会社オライリー・ジャパン, 東京 (2018)