

ドローイング学習支援システムにおけるストロークソート提示機能のための外形完成時刻推定に関する基礎的検討

A Basic Study on Estimating Outline Completion Time for a Stroke-Sorting Presentation Function in a Drawing Learning Support System

針谷美羽¹ 永井孝² 香山瑞恵³
Miu HARIYA¹ Takashi NAGAI² Mizue KAYAMA³

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 ものづくり大学

² Institute of Technologists

³ 信州大学工学部

³ Faculty of Engineering, Shinshu University

Abstract: This study investigates automatic estimation of outline completion time as a basis for a stroke-sorting presentation function in a drawing learning support system. Stroke time-series features are used to classify each moment as before or after outline completion, and three machine-learning models are compared under participant-wise cross-validation. The study also examines whether the estimated time can serve as a stage boundary for stroke sorting. The findings suggest that outline completion time should be treated as auxiliary information and combined with other drawing features.

1 はじめに

ドローイングは、美術教育における基礎的な技能であり、描画対象であるモチーフを観察し、その形状、明暗、質感を線によって表現する行為である。デザイン基礎教育においてもデッサン力の習得は重要であり、対象を十分に観察しながら描くことは、客観的な形態把握や表現力の形成に関わる [1]。また、美術表現は、対象を見ること、形を認識すること、手を動かして具体的な表現へ変換することが結びついた総合的な行為である [2]。

これらの観点から、ドローイング学習では完成作品だけでなく、描画者がどのような順序で対象を捉え、どの時点で構図や外形を決定し、その後どのように面、陰影、細部を描き進めたかを把握することが重要である。観察ドローイングにおける望ましい描画プロセスは、概略的には、アタリや外形の形成、面やトーンの描き込み、影の描写、ディテールの追加へと進む流れとして捉えられる。この流れは、最初にモチーフ全体の構図や比率を把握し、その後に明暗や質感を加えて完成度を高めるという制作上の手順に対応する。

しかし、初学者は必ずしもこの順序で描画を進めるとは限らない。たとえば、外形が十分に定まらない段階で局所的な陰影や細部を描き始めたり、画面全体の構図を確認する前に一部の形状を強く描き込んだりする場合がある。描画プロセスのずれは、完成作品だけを見ても把握しにくい。学習者に自身の描画プロセス上の特徴や改善点への気づきを促すためには、記録されたストローク列を指導上意味のある段階に整理し、学習者自身の描画プロセスと望ましい描画プロセスとの差異を比較可能にすることが有効であると考えられる。

本研究では、これらの処理をストロークソートと呼ぶ。ストロークソートとは、デジタルペンによって記録された時系列ストロークを、単に描画時刻順に再生するのではなく、描画プロセスに基づきストロークを再配置する処理である。ストロークソートが実現できれば、学習者が実際にどの順序で描いたかを、望ましい描画順序と比較しながら提示できるため、学習者自身の振り返りや指導者によるフィードバックを支援できる可能性がある。

ストロークソートを実現するためには、まず描画プロセス中の段階境界を推定する必要がある。特に、ア

タリ・外形の形成は、後続の面塗り、陰影、ディテール描写の基盤となるため、外形がどの時点で概ね完成したかを把握することは重要である。外形完成時刻が遅い場合、限られた制作時間の中で後続の描き込みに十分な時間を割けない可能性がある。また、外形が未確定のまま陰影や細部に移行している場合には、描画プロセス上の改善点として提示できる可能性がある。本研究では、外形完成時刻を、描画者がモチーフの外形形成を概ね終え、その後の面、陰影、細部の描き込みへ移行する基準時刻と定義する。

浅井らは、アウトライン描画段階を、構図や比率、モチーフの形状を決定する段階として扱い、同段階における定量的特徴の解析と終了時刻の同定アルゴリズムを検討している [5]。同研究では、美術専門家へのヒアリングに基づいてアウトライン描画段階終了時刻を定義し、各描画データに対して正解時刻を手動で付与している。その上で、手動で付与された正解時刻に対して、共通時刻による同定と、ハッチング的特徴の検出に基づくルールベースの同定アルゴリズムを比較している。

一方で、ルールベースの同定アルゴリズムでは、短く同方向の外形ストロークを連続して描く事例において、それらをハッチングとして誤検出し、終了時刻を実際より早く同定する可能性がある。そのため、外形完成時刻を推定するためには、ハッチング的特徴のみを直接的な手がかりとするのではなく、描画密度、累積ストローク数、描画領域の広がりなど、複数の時系列特徴量を統合して判断する必要がある。

そこで本研究では、ストロークソート実現に向けた基礎的検討として、ドローイングプロセスにおける外形完成時刻の自動推定を行う。本稿では、ストロークソートのアルゴリズム全体の実装や評価までは扱わず、その前段階として、アタリ・外形形成段階と後続の描き込み段階を分ける基準時刻の推定に焦点を当てる。具体的には、正解外形完成時刻ラベルを持つ 66 件のドローイングデータを用い、LightGBM, Random Forest, 線形 SVM の 3 モデルによる推定精度を比較する。さらに、時間誤差だけでなく、正解外形完成時刻までのストローク数に対する推定時刻までのストローク数の割合や具体的な推定事例を確認し、ストロークソートに用いる段階境界としての利用可能性を検討する。

本研究では、以下のリサーチクエスチョンを設定する。

RQ1 外形完成時刻推定において、どのような機械学習モデルが適しているか。

RQ2 最適な機械学習モデルによる外形完成時刻の推定精度は、ストロークソートに用いる段階境界として利用可能な範囲にあるか。

以上により、本研究は、ストロークソートに基づく

描画プロセスの整理と学習者への気づき支援に向けて、その基礎となる外形完成時刻の自動推定について検討する。

2 先行研究

2.1 ドローイング学習支援とストロークソート

永井らは、デジタルペンから描画時刻、座標、筆圧などのストローク情報を取得し、ドローイングプロセスモデルに基づいて描画過程を閲覧・比較できる学習支援ツールを検討している [3]。これにより、完成作品だけでは把握しにくい描画段階の推移や描画行動を、学習者と指導者が振り返ることが可能となる。また、ストローク数を意識させる支援機能により、学習者が自己や他者の描画過程を比較できる環境も構築されている [4]。

一方、描画量が増えても、構図、形状、トーン、ディテールが十分でない作品が確認されており、描画量だけでなく、どの段階で何を描いたかを把握する必要がある。特に、初学者の描画では、外形が十分に定まる前に部分的な面や影を描いたり、後続の描き込み後に再び外形を修正したりする場合があります。描画段階が時間順に明確に分離されるとは限らない。

本研究では、記録されたストロークをアタリ・外形、面・トーン、影・質感、ディテール・仕上げといった指導上意味のある段階に整理する処理をストロークソートと呼ぶ。ストロークソートにより、実際の描画順序と望ましい描画順序との差異を提示できれば、学習者自身の振り返りや指導者によるフィードバックに利用できる。本研究では、その第一段階として、アタリ・外形形成段階の終了時刻に相当する外形完成時刻を推定する。

2.2 アウトライン描画段階の同定

浅井らは、アウトライン描画段階の定量的特徴を解析し、美術専門家の判断に基づく正解時刻に対して、共通時刻およびハッチング検出に基づく同定手法を比較している [5]。同研究では、アウトライン描画段階の終了時刻を、後続のハッチング描画への移行に基づいて扱っている。

ハッチング検出は段階遷移を捉える手がかりとなる一方、短く同方向の外形ストロークをハッチングとして誤検出し、終了時刻を実際より早く同定する可能性がある。このため、単一の線種や局所的なストローク配置だけではなく、描画量や描画領域の変化を含む複数の情報から段階遷移を判断する必要がある。

本研究では、描画密度、累積ストローク数、単位領域あたりのストローク密度、凸包進行率など、複数のストローク時系列特徴量を機械学習モデルに入力し、特定の線種検出条件に依存せず外形完成前後を分類する。各時刻までの描画量、描画密度、描画領域の広がり、および直近の変化を統合して扱うことで、作品ごとに異なる外形完成時刻を推定することを目指す。

2.3 本研究の位置づけ

本研究は、ストロークソートにおける最初の段階境界として外形完成時刻に着目し、同一の時系列特徴量を用いて LightGBM, Random Forest, 線形 SVM を描画者単位の交差検証により比較する。また、単一の評価指標だけでモデルを選択するのではなく、平均的な誤差、典型的な誤差、誤差の広がり、正解時刻との対応、および結果の解釈可能性を総合して検討する。

さらに、秒単位の誤差に加えて、正解外形完成時刻までの累積ストローク数を基準としたストローク到達率と具体的な推定事例を確認する。これにより、推定時刻が単に時間的に近いだけでなく、描画段階として正解境界付近に位置しているかを検討する。

3 使用データと提案手法

3.1 対象データ

本研究では、ドロ잉学習支援システムにより取得されたストロークデータを用いる。対象データは、正解外形完成時刻ラベルを持つ 66 件のドロ잉データである。被験者数は 28 名であり、モチーフは紙箱と紙袋の 2 種類である。内訳は、紙箱を対象としたドロ잉が 38 件、紙袋を対象としたドロ잉が 28 件である。計測時間は 20 分、用紙は A3 判であり、筆記具にはアノト式デジタルペンを用いた。

各ドロ잉データは、デジタルペンにより取得された複数のストロークから構成される。各ストロークには、描画時刻、座標、筆圧、線種、ストローク長などの情報が含まれる。本研究では、これらの時系列情報を用いて、各時刻における描画状態を表す特徴量を算出する。

3.2 外形完成時刻ラベル

本研究では、外形を、モチーフの概形や構造を成立させる主要な輪郭線および構造線とする。また、外形完成時刻を、描画者がモチーフの外形形成を概ね終えたときと熟練者が判断した最初の時刻と定義する。正解外

形完成時刻は、各ドロ잉データに対して熟練者が手動で付与した時刻ラベルである。

本研究では、この正解外形完成時刻を基準として、各時刻が外形完成前であるか外形完成後であるかを表す 2 値ラベルを付与する。正解時刻以前を 0、正解時刻より後を 1 とし、各時刻までの描画状態から外形完成後である確率を推定する。

3.3 時系列特徴量の算出

描画開始から 1 秒間隔で時間窓を設定し、各時刻までに得られたストローク情報から時系列特徴量を算出する。主な特徴量は、描画密度、累積ストローク数、単位領域あたりのストローク密度、凸包進行率である。描画密度は、描画済み画素数をその時点の描画領域で正規化した値であり、描き込みの密度を表す。累積ストローク数は、その時刻までに描かれたストローク数であり、描画量の蓄積を表す。単位領域あたりのストローク密度は、描画領域に対するストローク数の多さを表す。凸包進行率は、最終的な描画領域に対して、その時点の描画領域がどの程度広がっているかを表す。

このほか、累積陰影比率、累積休止時間、平均ストローク長、累積平均筆圧、直近ストローク数、直近描画速度などを用いる。また、直近 15 秒間の描画密度増加量および凸包進行率増加量、ストローク数の減速比、直近 30 秒間の凸包停滞度など、時間変化を表す特徴量も算出する。

3.4 比較モデル

外形完成時刻推定に適した機械学習モデルを検討するため、LightGBM, Random Forest, 線形 SVM の 3 モデルを比較する。LightGBM は、前段階の誤差を補正するように決定木を逐次的に追加する勾配ブースティング手法である。Random Forest は、複数の決定木を独立に学習し、多数決または平均によって結果を統合する手法である。線形 SVM は、外形完成前後を分離するマージンが最大となる線形境界を学習する手法であり、特徴量を標準化した上で学習する。

3 モデルには同一のストローク時系列特徴量を入力する。各モデルは、各 1 秒窓に対して外形完成後である確率を出力し、共通の時刻決定処理によって推定外形完成時刻を算出する。これにより、入力特徴量と時刻決定条件を共通化し、分類モデルの違いによる推定精度を比較する。

3.5 推定外形完成時刻の決定

各モデルが1秒ごとに出力する外形完成後確率には、一時的な上昇や低下が含まれる可能性がある。そこで、出力確率に5秒の移動平均を適用して平滑化する。その後、45秒間の平滑化確率について、平均が0.6以上、かつ最小値が0.3以上となる条件を設定する。この条件を最初に満たした時刻を推定外形完成時刻とする。条件を満たす時刻が存在しない場合は、描画終了時刻を推定時刻とする。

この処理により、単一時点における確率上昇ではなく、外形完成後と判断される状態が一定時間継続した時点を推定する。平滑化および継続判定は3モデルに共通して適用する。

3.6 ストロークソートにおける位置づけ

本研究で推定する外形完成時刻は、ストロークソートにおける最初の段階境界の候補として利用することを想定している。外形完成前のストロークはアタリ・外形形成に関する候補となり、外形完成後のストロークは面、影、ディテールなどの候補となる。

ただし、推定時刻だけで段階境界を確定できるかは、推定誤差と描画状態の両面から検討する必要がある。そこで本研究では、秒単位の誤差指標に加えて、正解時刻までのストローク数を基準とした推定位置の進行度や具体的な推定事例を確認し、ストロークソートに利用可能な精度であるかを評価する。

4 評価実験

4.1 評価方法

同一被験者のデータが訓練データと評価データの双方に含まれることを避けるため、被験者をグループとしたLeave-One-Group-Out交差検証を行う。1名の被験者を評価対象として除外し、残りの被験者のデータでモデルを学習した後、除外した被験者のデータを評価する。これを28名分繰り返す。

描画速度、筆圧、ストローク長、描き込み量などには描画者ごとの傾向が含まれるため、同一描画者の作品を訓練データと評価データにランダムに分割すると、モデルが描画者固有の特徴を利用し、未知の描画者に対する性能を過大評価する可能性がある。そこで本研究では、作品単位ではなく描画者単位でデータを分離し、未学習の描画者に対する汎化性能を評価する。

評価単位は各ドロワーイングであり、各作品について1つの推定外形完成時刻を算出する。評価指標には、平均絶対誤差 (Mean Absolute Error: MAE)、絶対誤差

表 1: モデル別の外形完成時刻推定結果

手法	MAE [s]	中央値 [s]	R^2	P90 [s]
LightGBM	43.35	27.50	0.1451	107.50
Random Forest	43.44	25.00	0.0012	109.00
線形 SVM	49.65	22.00	-0.2626	136.00

の中央値、決定係数 R^2 、P90 絶対誤差を用いる。P90 絶対誤差は、全作品の90%がその値以下に収まる絶対誤差であり、大きな誤差がどの程度まで広がっているかを確認するために用いる。

さらに、ストロークソートにおける段階境界としての利用可能性を確認するため、式 (1) に示すストローク到達率を算出する。 N_{est} は推定外形完成時刻までに描かれた累積ストローク数、 N_{gt} は正解外形完成時刻までに描かれた累積ストローク数である。

$$\text{Attainment} = \frac{N_{\text{est}}}{N_{\text{gt}}} \times 100 \quad (1)$$

ストローク到達率が100%であれば、正解時刻と推定時刻における累積ストローク数が一致する。100%未満は正解より早い描画段階での推定、100%を超える場合は正解より後の描画段階での推定を示す。本研究では、推定位置の分布を確認するための参考範囲として80%以上120%以下に含まれる作品数も算出する。この範囲は実用上の許容基準を確定するものではなく、正解境界付近に推定が集中しているかを記述するために用いる。

4.2 モデル別の推定精度

表1に、3モデルによる外形完成時刻推定の結果を示す。LightGBMでは、MAEが43.35秒、中央値誤差が27.50秒、 R^2 が0.1451、P90絶対誤差が107.50秒であった。Random Forestでは、MAEが43.44秒、中央値誤差が25.00秒、 R^2 が0.0012、P90絶対誤差が109.00秒であった。線形SVMでは、MAEが49.65秒、中央値誤差が22.00秒、 R^2 が-0.2626、P90絶対誤差が136.00秒であった。

LightGBMとRandom ForestのMAEの差は0.09秒であり、平均誤差はほぼ同程度であった。一方、LightGBMは R^2 およびP90絶対誤差で最も良い値を示した。線形SVMは中央値誤差が最小であり、典型的な作品では誤差が小さい一方、MAEとP90絶対誤差が大きく、 R^2 も負となった。このことから、一部の作品における大きな誤差が全体性能に影響していると考えられる。

図1に、3モデルの絶対誤差分布を示す。線形SVMは中央値が小さい一方で、上側に大きな誤差を持つ作品が見られる。LightGBMとRandom Forestの分布




図 1: 3 モデルにおける絶対誤差の分布

は近いが、LightGBM は P90 絶対誤差がわずかに小さかった。

以上から、すべての評価指標で同一のモデルが最良となったわけではないが、MAE, R^2 , P90 絶対誤差と、決定木に基づく結果の解釈可能性を総合し、本研究で比較した 3 モデルの中では LightGBM が最も適していると判断する。以降では、LightGBM による推定結果を用いて、ストロークソートの段階境界としての利用可能性を検討する。

4.3 LightGBM による推定時刻の分布

図 2 に、LightGBM による正解外形完成時刻と推定外形完成時刻の関係を示す。横軸は正解外形完成時刻、縦軸は推定外形完成時刻を表し、破線は両者が一致する場合を示す。一致線の近くに分布する作品がある一方で、線から大きく離れる作品も存在する。特に、正解時刻が長い作品の一部では、推定時刻が正解時刻より早くなる事例が確認できる。 R^2 が 0.1451 であることから、作品ごとの正解時刻の違いを十分に説明できているとはいえない。

図 3 に、ストローク到達率の分布を示す。中央値は 109.2% であり、分布の中心は正解時点よりやや後に位置した。また、80%以上 120%以下の参考範囲に含まれた作品は 25 件であり、全 66 件の 37.9%であった。一方で、分布は 100%付近だけでなく、200%を超える範囲にも広がっていた。このことから、ストローク数を基準とした描画段階で見ても、すべての作品で正解境界付近を推定できているわけではない。

4.4 推定事例

図 4 に、紙箱および紙袋の推定例を示す。紙箱の例では、正解外形完成時刻が 45 秒、推定外形完成時刻が 66 秒であり、絶対誤差は 21 秒、ストローク到達率




図 2: LightGBM による正解外形完成時刻と推定外形完成時刻の関係




図 3: 正解外形完成時刻を基準としたストローク到達率の分布

は 140.7%であった。推定時刻では正解時刻よりもストロークが追加されているが、両時刻とも紙箱の主要な外形は概ね形成されている。

紙袋の例では、正解外形完成時刻が 78 秒、推定外形完成時刻が 71 秒であり、絶対誤差は 7 秒、ストローク到達率は 90.1%であった。推定時刻と正解時刻の描画状態は近く、両時刻とも紙袋の主要な輪郭が形成されている。これらの事例では、秒数や累積ストローク数に差がある場合でも、外形形成という描画段階としては比較的近い状態を推定できている。

4.5 誤差事例

図 5 に、LightGBM において絶対誤差が大きかった事例を示す。この作品では、正解外形完成時刻が 357 秒であったのに対し、推定外形完成時刻は 154 秒であり、203 秒早く推定された。ストローク到達率は 28.0%であり、推定時刻の描画状態と正解時刻の描画状態に




図 4: 紙箱および紙袋における正解時刻, 推定時刻, 完成作品の比較

は大きな差がある。

同図に示す外形完成後確率の時間変化を見ると, 推定時刻付近で確率が上昇し, その後, 45 秒間の継続判定条件を満たしている. このため, モデルは外形が十分に形成される前の段階を外形完成後と判断し, 154 秒を推定時刻として出力した. 本事例は, 外形完成後確率が早い段階で安定した場合, 現在の時刻決定処理では大きな早期推定が生じ得ることを示している.

5 考察

5.1 RQ1: 外形完成時刻推定に適したモデル

モデル比較では, LightGBM が MAE, R^2 , P90 絶対誤差で最も良い値を示し, 線形 SVM が中央値誤差で最も良い値を示した. Random Forest の MAE は LightGBM とほぼ同程度であり, 平均誤差だけから両者に明確な差があるとはいえない. 一方, Random Forest の R^2 は 0.0012 であり, 正解時刻の違いに対応した推定時刻の変化は小さかった.

線形 SVM は中央値誤差が 22.00 秒であり, 典型的な作品では比較的正確に推定できたが, P90 絶対誤差は 136.00 秒, R^2 は -0.2626 であり, 一部作品に対する大きな誤差が課題となった. 中央値だけを見ると線形 SVM が最良であるが, モデル選択では, 典型的な誤差だけでなく, 誤差の広がりや正解時刻との対応も考慮する必要がある.

これに対し LightGBM は, Random Forest と比較して MAE の差は小さいものの, R^2 と P90 絶対誤差が良好であり, 特徴量重要度などを通して判定傾向を確認

できる. また, 決定木の組合せにより, 描画特徴間の非線形な関係を扱える点も, 本研究の時系列特徴量に適している可能性がある. ただし, 本実験の結果だけから性能差の原因をモデル構造に限定して断定することはできない. 以上を踏まえ, 精度と解釈可能性を総合すると, 本研究で比較したモデルの中では LightGBM が最も適していると判断した. 以上が RQ1 に対する回答である.

5.2 RQ2: 段階境界としての利用可能性

LightGBM の中央値誤差は 27.50 秒であり, 紙箱および紙袋の例のように, 正解時刻に近い描画状態を推定できる作品も存在した. このことから, 外形完成付近を捉える情報として一定の有用性はあると考えられる.

一方, P90 絶対誤差は 107.50 秒であり, ストローク到達率が 80%以上 120%以下の参考範囲に含まれた作品は 37.9%にとどまった. 誤差事例では, 正解時刻より 203 秒早く, ストローク到達率 28.0%の時点が推定された. したがって, 現在の推定時刻は, 単独でストロークソートの段階境界を確定するために利用可能な精度には達していない. ただし, 他の描画情報と組み合わせて外形完成付近を判断する補助的指標として利用できる可能性がある.

また, 同じ時間誤差であっても, 描画速度やストローク数が作品ごとに異なるため, 描画段階としてのずれが同程度であるとは限らない. 紙箱の例では時間誤差が 21 秒であった一方, ストローク到達率は 140.7%であり, 正解時刻後に比較的多くのストロークが追加されていた. これに対し, 紙袋の例では時間誤差 7 秒, ス




図 5: LightGBM における誤差事例と外形完成後確率の推移

トロック到達率 90.1%であり、時間と描画段階の双方で正解境界に近かった。このことから、段階境界としての利用可能性を判断する際には、秒単位の誤差だけでなく、ストローク到達率や推定時刻における描画状態を併せて評価する必要がある。以上が RQ2 に対する回答である。

5.3 誤差事例と新たな指標との併用

誤差事例では、外形完成後確率が早い段階から高い状態となり、5 秒移動平均と 45 秒継続判定を満たした。現在の処理では、一時的な確率変動は抑制できる一方、誤った高確率状態が継続した場合にも、最初に条件を満たした時刻を推定時刻として確定する。実際に当該事例では、推定時刻におけるストローク到達率が 28.0%であり、正解時刻の描画状態との差も大きかった。したがって、確率が継続的に高いことだけでは、外形が十分に形成されていることを保証できない。このため、単一の時刻決定条件だけでは誤差を防げない場合がある。

新たな指標として、内部マスクの生成が考えられる。内部マスクとは、モチーフの内側に描画されるストロークと外側に描画されるストロークを分類するための外形に基づく内部領域である。内部マスク生成処理では、機械学習モデルが出力する外形完成後確率に基づき、確率の高い複数時刻を外形候補として抽出する。各候補時刻までのストロークから内部マスクを生成し、候補ごとのマスクを比較することで、より適切な外形候補

と内部マスクを選択する。この処理を外形完成時刻推定と併用すれば、最初に条件を満たした単一時刻だけに依存せず、候補時刻における描画状態も考慮できる可能性がある。たとえば、早い候補時刻の確率が高くても、その時点のストロークから生成されたマスクがモチーフ内部を十分に表していない場合には、後続の候補を選択することが考えられる。今後は、内部マスクの形状や線による支持状態などの評価結果を時刻決定に組み込み、誤差を抑制できるか検証する。

5.4 学習データ構成と汎化性能

本研究のデータには初学者から熟練者までが含まれるが、熟達度ごとの作品数には偏りがあり、初学者の作品数が多く、経験者および熟練者の作品数は相対的に少ない。このため、学習された判定傾向が初学者の描画プロセスを強く反映している可能性がある。

今後は、経験者および熟練者の作品データを追加し、熟達度ごとのデータ数の偏りを緩和する必要がある。目的は各群を機械的に完全に同数にするのではなく、各熟達度の特徴的な描画プロセスをモデルが十分に学習できる件数を確保することである。その上で、初学者、経験者、熟練者の各群に対する推定誤差を比較し、特定の熟達度に対して性能が偏っていないかを検証する。また、被験者数と作品数を増やすだけでなく、紙箱と紙袋以外のモチーフにも適用し、形状や描画方法が異なる場合の汎化性能を検証する必要がある。

5.5 ストロークソートへの接続

今後のストロークソートでは、推定外形完成時刻を段階境界の候補として扱う。外形完成前のストロークをアタリ・外形形成の候補とし、外形完成後のストロークを面、影、ディテールの候補として、さらに分類することを想定している。

ただし、本研究の結果から、推定時刻だけで段階を確定することは適切ではない。外形完成後確率、複数候補から生成した内部マスク、ストロークの位置や線種などを組み合わせ、段階を総合的に判断する必要がある。その後、外形完成後のストロークを面・トーン、影・質感、ディテール・仕上げへ分類し、実際の描画順序と望ましい描画順序を比較できる提示機能へ接続する。

この提示機能により、外形完成前に行われた過度な描き込み、外形形成に要した時間、および後続段階に使用できた時間を可視化できる可能性がある。これらを学習者自身の描画プロセスとともに提示し、学習者および指導者の振り返り支援を実現することを目指す。ただし、本稿ではストロークソート全体の実装および学習支援効果の評価までは扱っていない。

6 おわりに

本研究では、ストロークソート提示機能に向けた基礎的検討として、ドローイングプロセスにおける外形完成時刻を自動推定した。66件、28名の描画データを対象とし、描画者単位の Leave-One-Group-Out 交差検証により、LightGBM, Random Forest, 線形 SVM の 3 モデルを比較した。

LightGBM では、MAE が 43.35 秒、中央値誤差が 27.50 秒、 R^2 が 0.1451、P90 絶対誤差が 107.50 秒であった。線形 SVM は中央値誤差が 22.00 秒で最小であった一方、LightGBM は MAE, R^2 , P90 絶対誤差で最も良い値を示した。この結果と解釈可能性を総合し、RQ1 に対しては、本研究で比較したモデルの中では LightGBM が最も適していると判断した。

RQ2 については、ストローク到達率が 80%以上 120% 以下となった作品が 37.9%であり、大きな時間誤差と描画段階のずれも確認された。したがって、推定時刻だけで段階境界を確定する精度には達していないが、他の描画特徴と組み合わせて外形完成付近を判断する補助的指標として利用できる可能性がある。今後は、複数候補から生成した内部マスクとの併用、熟達度間のデータ数の偏りの緩和、対象データとモチーフの拡張、後続ストローク分類を進め、ストロークソート提示機能の実現を目指す。

7 謝辞

本研究で使用したドローイングプロセスデータは、遠隔ドローイング学習支援システムを通じて収集されたものである。同システムの 2012 年からの導入および継続的なデータ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海外芸術大学留学コースの教員、学生、ならびに関係者の皆様に深く感謝申し上げます。本研究は JSPS 科研費 JP23K17015 の助成を受けたものです。

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 (2003).
- [2] 関根英二: 美術体系の試み, 美術教育学: 美術科教育学会誌, Vol. 6, pp. 89–100 (1984).
- [3] 永井孝, 崎本貴之, 香山瑞恵: 美術入門者に対するドローイングプロセスモデルによる学習支援ツールの検討, 人工知能学会第二種研究会資料, 身体知研究会, SIG-SKL-23-10 (2017).
- [4] 永井孝, 香山瑞恵: ドローイング学習支援システムのストローク数変化への効果, 教育システム情報学会誌, Vol. 42, No. 2, pp. 175–184 (2025). DOI: 10.14926/jsise.42.175.
- [5] 浅井雄大, 香山瑞恵, 館伸幸, 永井孝: ドローイング学習支援システムへのアウトライン描画段階に対する自動評価機能実装のための定量的特徴の解析および同定アルゴリズムに関する基礎的検討, 人工知能学会第二種研究会資料, 身体知研究会 (2023).