

深層計量学習を用いた花押画像検索

仲居 優志[†] 宮崎 肇[‡] 井上 聡[‡] 大山 航[†]

埼玉工業大学[†] 東京大学史料編纂所[‡]

1. はじめに

花押は歴史学史料の一種である古文書において署名の機能を持つ記号である。花押は筆者固有のものであるが、同一人物の花押でも様々な要因により形状が変動する事象が認められている。花押の形状が変動する主な要因は、筆者の社会的地位の変化に伴う花押形状の意図的な変更、新しい花押のデザインを血縁者や親族の関係を反映させて作成、経年による筆跡の変化などである。このことから、古文書の解析において、花押は文書筆者を同定するだけでなく、身分、血縁関係、年代などの推定にも利用可能な重要な手がかりである。図1に花押の実例を示す。左と中央は足利義満の花押であり、時期によって形状が変化している。また、右は実父の足利義詮の花押であり、中央と形状が類似している。

膨大な花押資料の再利用を容易にするために、網羅的なデータベースの作成と拡充は歴史学における重要な研究課題の一つである。花押画像をクエリとしたデータベース検索が実現されれば、データベースの活用促進だけでなく、管理運用面でも大きな利点である。

深層学習により花押形状を解析し、画像検索に利用する試みが鬼塚らによって行われた[1, 2]。この手法では、畳み込み自己符号化器と計量学習を併用したニューラルネットワークにより花押の形状特徴を抽出し、画像検索を行う手法を提案したが、小規模なデータセットでの検証実験しか行われておらず、大規模なデータベース運用に利用可能かどうかの検証が課題であった。

本研究では、鬼塚らが提案した深層計量学習による花押画像検索手法の有効性を、2万画像を超える大規模なデータセットを用いて検証した。

2. 提案手法

本研究では、畳み込み自己符号化器（以下、CAEと呼ぶ）に計量学習による制約を加えたニューラルネットワークで、花押画像24881枚を含む大規模データセットを解析する。本報告では、主にニューラルネットワークの学習に用いるデータセットの規模により、検索性能が受ける影



図1 花押の実例：足利義満（左：1376年，中央：1382年），足利義詮（右）

響の程度を検証する。

2.1 データセットの準備

まず、花押画像データセットをクエリ画像（検索クエリとする画像）、データベース登録画像、CAE学習用画像に分割した。クエリ画像は花押が2枚以上存在する人物の花押から無作為に1枚を選んだ。CAE学習用画像は4種類の規模（画像数 $n=3300, 7000, 14000, 21000$ ）を準備した。

2.2 畳み込み自己符号化器

自己符号化器（AE）は、入力データに対する特徴抽出に用いられる手法である。通常、AEは同じサイズの入力層と出力層、それらよりサイズの小さい中間層を持つニューラルネットワークとして構成される。AEは前半部分、後半部分がそれぞれ符号化器、復号化器として機能する。入力層や出力層よりも小さい中間層を用いることで、符号化された情報は入力情報の潜在的構造を捉えることができる。符号化情報を復号した情報が、入力情報を十分に近似していれば、入力情報を表現するために必要な情報が符号化によって抽出されていると考えられる。

CAEは畳み込み層とプーリング層を交互に配置、その後畳み込み層とアップサンプリング層を交互に配置した畳み込みニューラルネットワークで構成される。CAEは入力が画像ならば内部の入出力も画像であり、内部情報を可視化できる。

2.4 計量学習

計量学習（ML）とは、データ間の関係性を考慮した特徴量空間を学習する手法である。原特徴空間において同じクラスの組は近く、異なるクラスは遠くなるように計量を学習し、データ

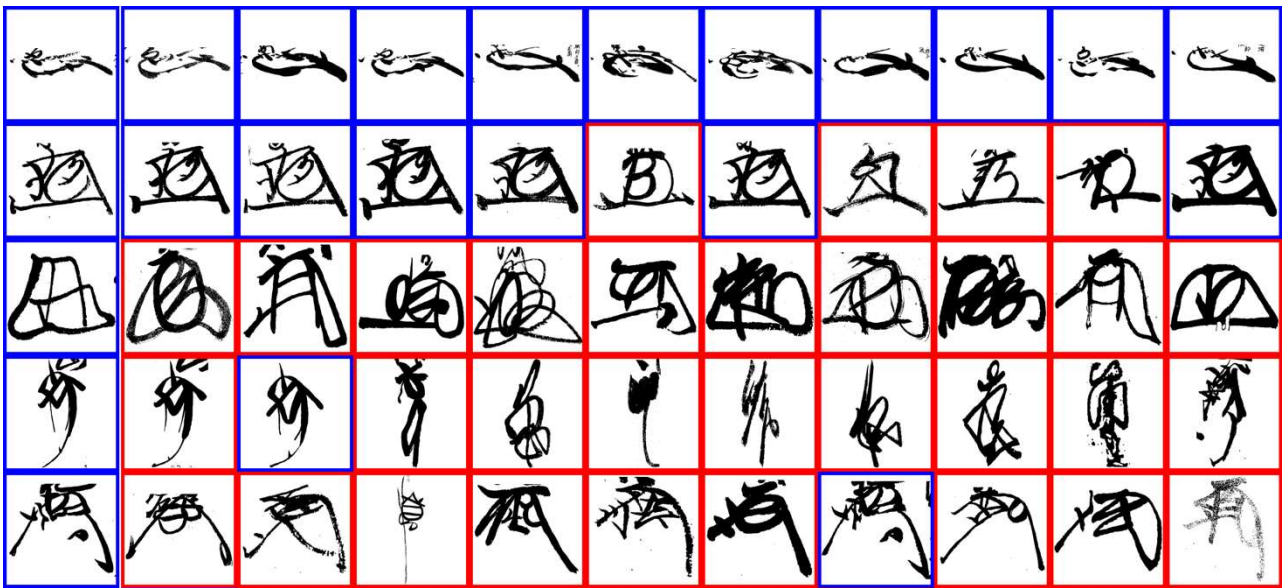


図 2 花押画像検索結果の一例

の類似度を反映させた特徴量空間へ変換する。

ML の特徴はクラス内の変動が抑制され、同時にクラス間の違いが拡大される距離空間への写像を学習することである。各クラスに十分な数のサンプルを含むデータセットがある場合、ML は適切な写像を学習し、空間上で重複していたクラスを適切に分離することが可能であるが、データ数が小さい場合、過学習が発生しやすい。

3. 評価実験および結果

まず、クエリ画像、登録画像それぞれに対して学習済 CAE で特徴抽出し検索処理を行なった。花押画像検索結果の例を図 2 に示す。各行の左の画像がクエリ画像である。それに対して右に検索された花押画像が、検索スコアが大きい順に 10 例並んでいる。検索結果において、青色、赤色の枠はそれぞれ、クエリ画像と同じ人物、異なる人物の花押画像であることを示す。

続いて、4 通りのサイズの学習用画像セットで CAE を学習し、それぞれの検索性能を比較した。図 3 にそれぞれのサイズの学習用画像セットを用いた場合の検索性能を示す。図は検索上位 R 位までの累積精度グラフである。4 種類の学習用画像セットにおいて、検索性能に明確な差は認められなかった。本研究で用いた手法では、小規模な学習用画像セットに対して過学習しないようにモデル自由度が低くなるように CAE が設計されている。そのため、規模の大きな学習用画像セットに含まれる画像変動の多様性を十分に捉えられていないことが示唆される。

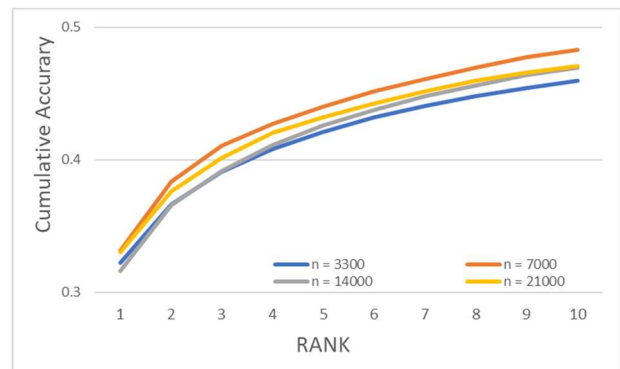


図 3 4 通りのサイズの学習用画像セットで学習した場合の検索性能の比較

4. おわりに

本研究では、深層計量学習を用いて花押画像の形状特徴を抽出し画像検索を行う手法の検索性能を、学習用データセットの規模を変化させて評価した。4 通りのサイズの学習用データセットにおいて、検索性能に明確な差は認められなかった。今後は、モデル自由度が高い CAE を構築し、同様の実験を行う予定である。

本研究は JSPS 科研費 18H05221, 20H00022 の助成を受けたものです。

参考文献

[1] 鬼塚洋輔 他：花押類似検索のための畳み込みオートエンコーダによる画像特徴抽出，じんもんこん 2018
 [2] Y. Onitsuka et al.: Training Convolutional Autoencoders with Metric Learning, ICDAR2019