

## 自動付与したウィーン分類コードと図形の形状に基づく 類似商標検索法

工藤 力\*, 岩田 基\*, 岩村 雅一\*, 黄瀬 浩一\*

(2019.1.28 受理)

### A Method of Trademark Search Based on the Automatically Assigned Codes of Vienna Classification and Figure Shapes

Riki KUDO\*, Motoi IWATA\*, Masakazu IWAMURA\*, and Koichi KISE\*

Demand for the search of similar trademarks is increasing. In the existing methods, the similarity is measured based on the similarity of appearance with the shape. However, to judge the similarity of appearance, trademark examiners also take into account the classification of graphical elements in trademarks. To realize this function, we focus on the Vienna Classification which is the classification of graphical elements in trademarks. If two trademarks have the same Vienna Classification code, they tend to have similar contents. However, the codes are currently assigned by experts, which prevent us from using the codes in search methods. We solve this problem by automatic assignment of Vienna Classification codes implemented using the Deep Learning. The proposed method takes into account both the automatically assigned codes and shape similarity for search. We have succeeded to improve a three percentage point accuracy as compared with the method without using the Vienna Classification.

**Keywords:** Trademark image retrieval, Large scale database, Similar image retrieval, Deep Learning, Vienna Classification

年々増加する商標の登録作業を効率化するため、類似商標検索が求められている。従来の検索手法は、外観の類似性を図形の形状の類似性からのみ評価するものが大半である。ところが、商標審査官の類似性判断では、形状の類似性だけでなく、商標に描かれている図形要素の分類も加味されることが多い。本研究では、この機能の実現のため、商標の図形分類指標であるウィーン分類に着目する。2枚の商標に同じウィーン分類コードが付いていれば、それらは同じ分類の図形を含むため、類似している可能性が高い。つまりウィーン分類コードの照合で、図形の分類を同じくする類似商標を検索できると言える。この場合、検索質問の商標へのウィーン分類コードの付与が必須である。現在ウィーン分類コードの付与は、専門家が知識と経験則をもって行っている。そのスキルを Deep Learning を用いて学習することで、我々は自動でウィーン分類コードを付与し、検索できる手法を提案する。本手法は、従来のウィーン分類を用いない手法と比べて3ポイント検索精度が向上した。

キーワード：商標画像検索、大規模データベース、類似画像検索、深層学習、ウィーン分類

### 1. 背 景

商標は事業者や企業が自己の提供する商品やサービスに付ける標識であり、ブランドイメージを示す重要な役割を担っている。商標を利用するためには、まず特許庁に申請し、商標審査

を受けて登録が認められ商標権を得る必要がある。商標審査とは、申請された商標に対して、外観、観念、称呼の観点から、既に登録された商標の中に類似したものがないかを確認する作業を指す。また、類似した商標が既に登録されていたとしても、商標を使用する商品やサービスが重複しない限りは、登録される。

我が国では、毎年約10万件以上の商標が申請され、登録商標も年々増加していることから、商標審査は審査官にとって労力がかかる作業となっている。一方、商標を申請する事業者や企業の視点から見ても、商標登録には約8か月かかることから

\* 大阪府立大学

〒599-8531 大阪府堺市中央区学園町 1-1

\* Osaka Prefecture University

1-1 Gakuen-cho, Naka, Sakai, Osaka 599-8531, Japan

商標審査の効率化は切望されるところである。また、そのように時間をかけても、もし登録商標の中に類似したものが見つければ、再査定の手続きを踏まねばならず、さらに時間がかかることになる。これはビジネスの機会損失につながると言える。そこでもし申請者が特許庁に商標申請をする前に、あらかじめ商標審査官が行うような類似商標を検索するシステムで調査出来れば、このようなロスは省けると考えられる。

ここで、商標審査官が行う商標審査のプロセスを考えてみる。現状では、大量にあるすべての登録商標に対して類似性を人手で評価することは非現実的であるため、特許庁では独自の商標検索システムを使って、登録商標を絞り込んでから、類似性を評価している。各類似性において、システムが絞り込む商標が違うため、ここでは、最も基本的で多数の事例を有する外観の類似を対象として説明を進める。まず、外観が類似した商標を絞り込むには、商標の図形要素を分類したウィーン分類<sup>1)</sup>とその商標が使用される商品やサービス名が用いられている。具体的には、申請商標に対して専門家が付与したウィーン分類コードと商品・サービス名をシステムに入力し、それらが同一の登録商標を出力する。つまりウィーン分類コードを用いることで、同じ分類の図形が描かれた商標を出力することができる。このようにして絞り込まれた商標に対して、商標審査官は1枚ずつ目視によって類似性を判別している。しかしこの商標検索システムによる絞り込みだけでは、なお多くの商標が検索されるため、目視による作業の負担は大きい。またウィーン分類コードの付与は、専門家が行っているとは言え、人の主観によって決定されるため個人差が出たり、付け漏れが生じたりする可能性もある。つまりウィーン分類コードに紐づいていない類似商標に対しては検索漏れが生じる。そこで誰でも簡単に使えて、より効率的な類似商標を検索する手法があれば、商標審査官の労力は軽減され、企業や事業者にとっても商標登録の時間削減につながると考えられる。そこで我々は、外観が類似した商標を自動的に検索する手法を提案する。

従来の商標検索の研究では外観類似を検索する様々な手法が提案されている。これらの手法は主に形状の類似性から類似商標を検索している。しかしこれらの手法を用いても、外観が類似した商標をすべて検索できるわけではない。なぜなら、商標審査官は、上記のウィーン分類という図形の分類も加味した検索を行っているためである。例えば、形状が異なっても、同じ分類の図形が描かれていれば、その商標を類似しているとみなすケースがある。つまり外観類似の商標を検索する手法は、図形の形状のみならず分類も考慮しなければならない。図形の分類も考慮した検索手法の構築には、図形の分類に基づいた類似性を評価する必要がある。

そこで、本研究では、ウィーン分類を加味した商標検索を提案する。この検索を行う上で必須となる条件は、データベース内の商標と検索質問に対してウィーン分類コードが付いていることである。前者に関しては、我が国を含む多くの国の登録商標はウィーン分類コードが付与されている。一方後者に対しては、申請商標は主に新規の商標であることから、新たにウィーン分類コードを付与する必要がある。しかし、商標にウィーン分類コードを付与するには、専門家が持つ知識や経験則が不可

欠であり、申請者である一般の企業や事業者には手間がかかり、また安定性にかける。そこで Deep Learning を用いて、既にウィーン分類コードが付与されている商標の傾向を学習することで、ウィーン分類コードを自動付与できる処理を導入する。これにより、ウィーン分類を加味した商標検索を行うことができる。

本論文では、外観が類似した商標を検索する手法として、図形の形状に基づく類似性に加えて図形の分類に基づく類似性を考慮した検索手法を提案し、その有効性を調査する。以降、2章で関連研究について述べ、3章でウィーン分類の説明を行い、4章で提案手法の解説をし、5章で実験内容、そして最後に6章で本論文をまとめる。なお、本文図表中の商品名、会社名およびそのロゴマークは、一般的に各社の商号、登録商標または商標である。

## 2. 関連研究

### 2.1 商標検索の従来法

近年、局所特徴を用いた類似商標検索手法<sup>2,3)</sup>が増えている。局所特徴を用いた手法は、大域的にも部分的にも類似した商標の検索を行うことができる。しかし、部分的に似ている商標が類似商標とは限らないため、この手法は同時に非類似商標の検索の原因にもなっている。

この問題を解決するために我々は局所特徴に基づく検索手法に対して、非類似商標の検索を抑制する処理<sup>4)</sup>と類似商標の検索を促進する処理<sup>5)</sup>を導入した。前者においては局所特徴の位置関係を考慮することで対応し、後者においては Pseudo relevance feedback を導入することで対応している。しかし、この手法を用いてもなおすべての類似商標を検索できているわけではない。その理由として、これらの手法は図形の形状の類似度のみで外観が類似した商標を評価しているためである。外観が類似した商標とは、図形の形状に基づく類似性のみを測るだけでなく、図形の分類に基づく類似性も考慮する必要がある。そこで、本手法では、図形の分類に基づく類似性も考慮した類似商標検索手法を提案する。

### 2.2 Deep Learning による分類付与

我々が知る限り、ウィーン分類コードを自動で付与する研究事例はない。その理由は、従来の画像分類の技術は、人手で作成した特徴を用いて分類を行っていたため、特徴の有効性に欠ける点があり、精度が十分なものではなかったためである。

この問題を解決できる可能性のある技術として Deep Learning がある。Deep Learning を用いた画像分類では、人手を介さずに分類する上で最適な特徴を抽出するため、分類精度が飛躍的に向上している。そこで Deep Learning を用いた画像分類についての関連研究を述べる。

Saito ら<sup>6)</sup>の研究に、イラストに分類を付与する Illustration2vec がある。この研究では、イラストに描かれている要素を 1,539 個の分類で表し、入力したイラストに対して自動で分類を複数付与するネットワークを作成している。例えば、青い目で金髪の 1 人の少女が描かれたイラストをこのネットワークに入力すると、「青い目」、「1 人」、「金髪」、「少女」といった分類を付与することができる。また、Pan ら<sup>7)</sup>は、食品が映

った画像を 41 種類の中から 1 種類に分類する DeepFood の研究を行っている。各食品に対して 100 画像あるデータセットを用いて、three-fold cross validation で評価したところ、約 85% 以上の精度で分類することができている。このように近年、Deep Learning を用いた画像分類の研究は目覚ましい成果を出している。また、He<sup>8)</sup>らは、自然画像に映っている物体を 1000 クラスの物体のなかから認識する ResNet の研究を行っている。ResNet は、Large Scale Visual Recognition Challenge 2015 という画像認識コンペティションにおいて第一位の精度を出しており、その認識エラー率が約 4% と非常に低いことから画像分類手法の中でも代表的な手法となっている。

### 3. ウィーン分類

ウィーン分類とは、1973 年にオーストリアのウィーンで作成された商標に含まれる図形要素を形状などの特徴によって分類した国際指標である。わが国では 2004 年度からウィーン分

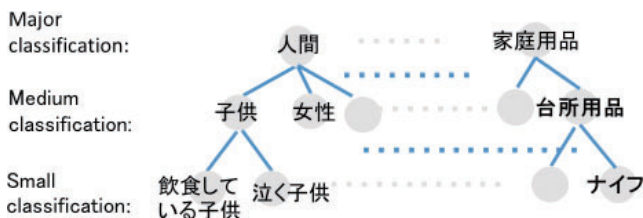


Fig. 1 Vienna Classification.

類を商標審査にて利用している。ウィーン分類は、Fig. 1 に示すとおり大分類、中分類、小分類の木構造をもち、それぞれ 29/144/1887 の分類から成りたっている。例えば、大分類は Table 1 に示すように、29 の区分に分けられているおり、大分類 1 (天体、自然現象、地図) のように物体や現象を表す分類や、大分類 26 (幾何学図形及び立体的幾何学図形) のように図形の形状を表す分類などがある。また大分類 1 (天体、自然現象、地図) に属する中分類に着目すると、中分類 1.1 (星、彗星)、中分類 1.3 (太陽)、中分類 1.5 (地球、地球儀、惑星)、中分類 1.7 (月) のように枝分かれし、中分類 1.1 (星、彗星) では、小分類 1.1.1 (星)、小分類 1.1.2 (一つの星)、小分類 1.1.3 (二つの星) の様に、さらに細かく分けられている。つまりウィーン分類では下層の分類ほど図形の複雑な要素を示すことができる。基本的にウィーン分類コードは、大分類、中分類、小分類の組み合わせで表現されるが、日本では独自に小分類をもう一段階細かく分類した細分類を設けている。

実際に、登録商標に付与されているウィーン分類コードを Fig. 2 から Fig. 4 に示す。各図には、左側に対象となる商標を示し、右側の表の各行が商標に付与されたウィーン分類コードを示している。また、右側の表の 1 列目に付与されたウィーン分類コードを示し、2 列目に大分類、3 列目に中分類、4 列目に小分類、5 列目に細分類を示している。

Fig. 2 で扱う商標は、「TAMIYA」と書かれた商標でありアルファベットの上部に正方形の中に星が描かれた図が 2 つ並んでいる。この商標の図形を表した部分は、正方形の中に星が描

Table 1 Types of the major classification.

Major categories	The name of categories	Major categories	The name of categories
1	天体、自然現象、地図	16	遠隔通信・録音及び再生・コンピュータ・写真・映画・光学機械器具
2	人間	17	計時機械器具、装身具、度量衡器
3	動物	18	輸送機械、動物用器具
4	超自然的・伝説・空想又は確認できない生き物	19	容器及び包装、種々雑多な製品
5	植物	20	製図又は絵画用具、事務用品、文房具及び書店の商品
6	風景	21	娯楽用具、玩具、スポーツ用品、回転木馬
7	建造物、広告用建造物、門又は柵	22	楽器及びその付属品、演奏補助品、鐘、絵画、彫刻
8	食料品	23	武器、弾薬、甲冑(「よろい」と「かぶと」)
9	織物、衣服、裁縫用品、帽子、履物	24	紋章、コイン、表象、象徴
10	タバコ、喫煙用具、マッチ、旅行用品、扇、化粧用具	25	装飾模様、装飾のある外見又は背景
11	家庭用品	26	幾何図形及び立体的幾何図形
12	家具、衛生施設	27	書体、数字
13	照明器具、電子管、暖房器具、調理又は冷蔵機器、洗濯機、乾燥機	28	種々の字体による文字
14	金具、工具、はしご	29	色
15	機械、モーター、エンジン		



Vienna classification code	Major classification	Medium classification	Small classification	Sub-classification
1.1.1	1.天体、自然現象、地図	1.星、彗星	1.星	
1.1.3	1.天体、自然現象、地図	1.星、彗星	2.二つの星	
1.1.10.1	1.天体、自然現象、地図	1.星、彗星	10.五つ以上の先端を有する星	1.五つの先端を有する星(五稜星)
26.4.1	26.幾何図形及び立体的幾何図形	4.四角形	1.正方形	
26.4.7	26.幾何図形及び立体的幾何図形	4.四角形	7.二つの四角形、一方が他方の中にある二つの四角形	
26.4.9	26.幾何図形及び立体的幾何図形	4.四角形	9.差置・結合又は交差する複数の四角形	
26.4.13	26.幾何図形及び立体的幾何図形	4.四角形	13.天体又は自然現象の表現を内包する四角形	

Fig. 2 The Vienna Classification code of a trademark with a graphic and a character.

Vienna classification code	Major classification	Medium classification	Small classification	Sub-classification
27.5.1.8	27.書体、数字	5.特殊な書体で表現された文字	1.特殊な書体で表現された文字	8.H, h
27.5.4	27.書体、数字	5.特殊な書体で表現された文字	4.線で強調又は装飾された文字	
27.5.21	27.書体、数字	5.特殊な書体で表現された文字	21.一文字	

Fig. 3 The Vienna Classification code of a trademark mainly composed of letters.

Vienna classification code	Major classification	Medium classification	Small classification	Sub-classification
4.5.3.1	4.超自然的・伝説・空想又は確認できない生き物	5.擬人化・擬動物化した植物・物又は幾何図形。面又は空想的あるいは確認できない生き物の頭部	3.擬人化した幾何図形又は立体。擬人化した幾何図形又は立体	1.擬人化した幾何図形又は立体
4.5.4	4.超自然的・伝説・空想又は確認できない生き物	5.擬人化・擬動物化した植物・物又は幾何図形。面又は空想的あるいは確認できない生き物の頭部	4.人間の容姿のロボット	
4.5.5	4.超自然的・伝説・空想又は確認できない生き物	5.擬人化・擬動物化した植物・物又は幾何図形。面又は空想的あるいは確認できない生き物の頭部	5.その他の確認できない物の擬人化。その他の人間の姿をした空想的物	
26.1.1	26.幾何図形及び立体的幾何図形	1.円、楕円	1.円	
26.1.1.1	26.幾何図形及び立体的幾何図形	1.円、楕円	1.円	1.突起・飛び出し線のある円
26.1.5	26.幾何図形及び立体的幾何図形	1.円、楕円	5.二つ以上の円又は楕円、三筆の円又は楕円あるいはらせん形	
26.1.6	26.幾何図形及び立体的幾何図形	1.円、楕円	6.差置・結合又は交差する複数の円あるいは楕円	

Fig. 4 The Vienna Classification code of a trademark with a mascot character.

かれた部分であるため、大分類1（天体、自然現象、地図）と大分類26（幾何学図形及び立体的幾何学図形）に属する7個のウィーン分類コードが付与されている。その中で、「星」を表現しているウィーン分類コードは、大分類1（天体、自然現象、地図）、中分類1（星、彗星）、小分類1（星）となり1.1.1と表される。またこの星に対して、1.1.1（星）と1.1.3（二つの星）と内容が重複されているウィーン分類コードが付与されている。このような内容が重複しているウィーン分類コードの付与は、基本的には検索漏れを防ぐために行われていると考えられるが、その判断は専門家の知識や経験則によるものである。

次に、Fig. 3に文字を図形のように変形した商標と付与されたウィーン分類コードを示す。この例では、「Hisamitsu」と書かれた「H」の部分に3本の横線が引かれており、特殊な書体となっている。以上のことから、ウィーン分類コード27.5.1.8

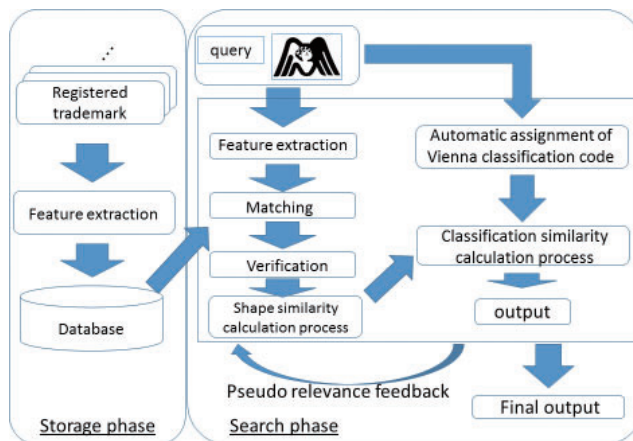


Fig. 5 Flow of trademark search processing.

(H, h) が付与されている。また、ウィーン分類コード27.5.21（一文字）が付与されているように、ウィーン分類コードが付与されている箇所は、「H」の部分だけであり、残りの「hisamitsu」にはウィーン分類コードが付与されていない。このように、どの文字が図形要素を表しているかを判断する基準も専門家の知識や経験則による。

最後にFig. 4にキャラクターを用いた商標と付与されたウィーン分類コードを示す。この登録商標には、円に手足の生えたキャラクターが描かれており、7個のウィーン分類コードが付与されている。ウィーン分類コード4.5.5に着目すると、「その他の確認できない物の擬人化、その他人間の姿をした空想的物」とある。ここで示す「その他」とは、中分類4.5の下層の他のウィーン分類コード（例えば4.5.1（擬人化した植物、擬人化した植物の組合せ）や、4.5.4（人間の容姿のロボット）など）で表現できないものを指す。このように「その他」を含むウィーン分類コードは、対象となる層の他のウィーン分類コードも考慮する必要があるため、専門家の知識が必要となる。

#### 4. 提案手法

全体の処理の流れは、Fig. 5に示すように、「登録処理」と「検索処理」に分けられる。「登録処理」は、データベースに商標画像を登録する処理である。登録する商標画像（以下、データベース画像とする。）から付与されたウィーン分類コードとその画像から抽出された局所特徴をデータベースに登録する。

「検索処理」では、図形の形状と分類に基づく類似性を測り、それらの類似性から外観が類似した商標を検索する。

はじめに図形の形状に基づく類似性を測るプロセスを説明する。まずクエリとなる商標画像（以下、クエリ画像とする。）から局所特徴を抽出する。次に、データベースに対して、クエリ画像から得た局所特徴を照合する。そして、照合された局所特徴が信頼性のある特徴かどうかを評価する検証処理を行う。最後に、信頼性のある局所特徴の照合数からデータベース画像の図形の形状に基づく類似度 $s$ （以下、形状類似度 $s$ とする。）を測る。詳細は工藤らの研究<sup>4)</sup>を参照されたい。

次に図形の分類に基づく類似性を測るプロセスを説明する。まず、クエリ画像のウィーン分類コードを自動付与する。次

に、クエリ画像のウィーン分類コードとデータベース画像のウィーン分類コードの一致した数から図形の形状に基づく類似度  $a$  (以下、分類類似度  $a$  とする。) を測る。このような処理を経て、得られた形状類似度  $s$  と分類類似度  $a$  から総合的な類似度が高い順に出力する画像を決定する。また本手法では、類似商標の検索精度を向上させるために Pseudo relevance feedback<sup>5)</sup>を採用している。以下、各処理の詳細について説明する。

#### 4.1 ウィーン分類自動付与

この処理では、Deep Learning を用いて、クエリ画像に用いた商標にウィーン分類コードの付与を行う。具体的には、学習処理と付与処理の2つの処理に分けられる。学習処理では、日本にすでに登録された商標を用いて、それらに付与されていた1644分類の小分類を学習する。本手法では日本独自の指標である細分類は学習の対象としない。すなわち、細分類を含んだウィーン分類コードは、細分類を除いた大分類・中分類・小分類までを学習に用いる。例えば、ウィーン分類コード2.9.1.2 (トランプのハート) は2.9.1 (心臓) として学習を行う。

学習時に用いる Deep Learning のネットワークは、画像認識で代表的なネットワークである ResNet とする。ResNet は、50 層、101 層、152 層の3種の層を用いたモデルが一般的だが、本手法では最もシンプルな ResNet50 を用いる。ResNet50 で扱う loss 関数は、通常シングルラベルを扱う softmax cross entropy が用いられるが、本手法ではマルチラベルを扱うため sigmoid cross entropy を用いる。これにより、対象となるそれぞれのウィーン分類コードが存在する、もしくは存在しないという二値のマルチラベル分類を行う。また sigmoid 関数を通すことで、出力されるベクトルの要素は  $[-\infty, \infty]$  から  $[0, 1]$  の値に正規化される。正規化された値が1に近いほど、対応したウィーン分類コードが商標に付与されている可能性が高いと考えられる。またウィーン分類コードの付与精度を向上させる手法として、学習に用いるデータの正規化や Data augmentation を用いる。

付与処理の流れを Fig. 6 に示す。まず、新規の商標を学習したモデルに入力する。次に、モデルから1644次元のベクトル

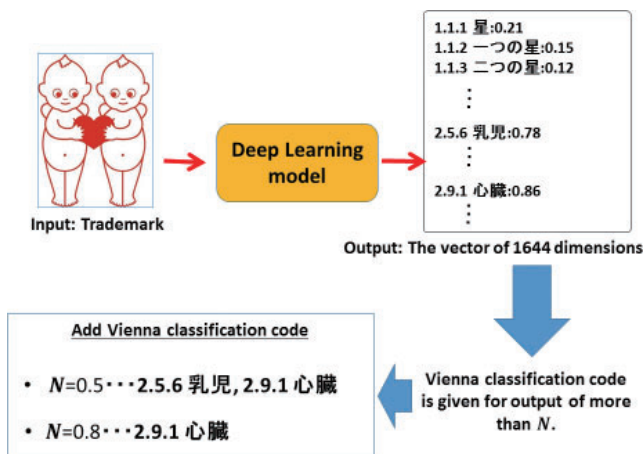


Fig. 6 How to add the Vienna Classification code.

ルが出力される。各ベクトルの要素は、ウィーン分類コードと対応しており、その要素が  $N$  以上の場合商標にウィーン分類コードが付与される。例えばウィーン分類コード2.5.6 (乳児) に対応するベクトルの要素が0.78のとき、 $N=0.5$  ならば付与されるが、 $N=0.8$  ならば付与されない。ここで用いるパラメータ  $N$  は、5章の実験により決定する。

#### 4.2 分類類似度算出処理

この処理では、ウィーン分類コードを用いてデータベース画像の分類類似度  $a$  を算出する。すなわちクエリ画像とデータベース画像に付与された同じウィーン分類コードの数から分類類似度  $a$  を算出する。この場合、該当するウィーン分類コードの数をそのまま分類類似度  $a$  と定義すると、データベース画像に付与されたウィーン分類コードの数が多いほど、分類類似度  $a$  が高くなる。よって、提案手法で用いる分類類似度  $a$  は、データベース画像に付与されたウィーン分類コード数の値で正規化する。

つまりクエリ画像の商標  $x$  に付与されたウィーン分類コードの集合が  $X$  であり、データベース画像  $y$  に付与されたウィーン分類コードの集合が  $Y$  であるとき、分類類似度  $a$  を、以下のように定義する。ただし、 $|Y|$  はデータベース画像  $y$  に付与されたウィーン分類コードの数を表す。

$$a = \frac{|X \cap Y|}{\sqrt{|Y|}} \quad (1)$$

なお、正規化をする際に、平方根をとったデータベース画像のウィーン分類コード数の値で除算することは、事前実験による知見から得たものである。

分類類似度  $a$  の算出例を Fig. 7 に示す。このクエリ画像にはウィーン分類コードが3個付与されており、データベース画像にはウィーン分類コードが5個付与されている。また同じウィーン分類コードが付与された数は2個ある。すなわち Fig. 7 の例では、データベース画像の分類類似度  $a$  は  $2/\sqrt{5}$  となる。

#### 4.3 出力処理

以上のプロセスを経て、クエリ画像と照合されたデータベース画像をすべて出力する。そこで、データベース画像の形状類似度  $s$  と分類類似度  $a$  をもとに総合類似度  $s'$  を算出し、その

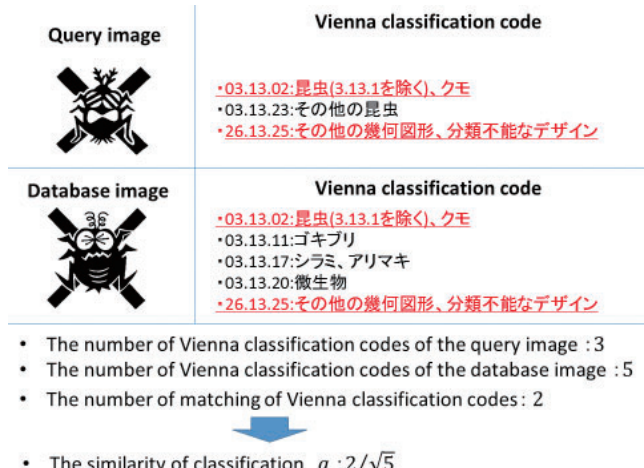


Fig. 7 How to calculate the similarity of classification.



値の高い順に出力を行う。算出には以下の式を用いる。

$$s' = (1 - m)s + ma \quad (2)$$

なお、データベース画像の形状類似度  $s$  と分類類似度  $a$  の重みを示す定数  $m$  は、5章の実験により決定する。

#### 4.4 Pseudo relevance feedback

Pseudo relevance feedback は、クエリを拡張するための検索方法である。まず、元のクエリ画像（以下、初期クエリ）を使用して、出力処理を行い、総合類似度  $s'$  の高い順に上位  $N$  個の画像を検索する。その後、上位  $N$  個の画像をクエリとして再度検索を行い、出力結果を更新し、最終出力結果を得る。この方法を用いることにより、最初の検索で欠落した類似商標を検索することができるので、性能を向上させることができる。以下式を用いて各商標の総合類似度  $s''$  を新たに更新する。

$$s'' = s'_0 + \sum_{k=1}^N s'_k \quad (3)$$

$s'_0$  は、初期クエリを用いたときの総合類似度  $s'$  を示す。 $s'_k$  は、検索結果  $k$  位の商標をクエリに用いたときの総合類似度  $s'$  を示す。

## 5. 実験

提案手法の性能を調査するために2種類の実験を行った。

第一の実験では、提案手法の検索に用いる適切なパラメータを調査する。商標検索の性質上、提案手法は類似商標の検索漏れを避けることが最も重要である。そこで検索パラメータを変化させてその傾向を調査し、提案手法の検索漏れが最も少なくなるときの検索パラメータ（以下、最適な検索パラメータとする。）を求めた。

第二の実験では、提案手法の有効性を示すために、形状類似度  $s$  のみで外観が類似した商標を検索する手法（以下、既存手法とする。）と提案手法の検索結果の比較を行った。また、ウィーン分類コードが正確に付与された際に、提案手法の検索精度がどの程度向上するかについても調べた。具体的な方法として、提案手法の「ウィーン分類自動付与」の処理を取り除き、専門家が手動付与したウィーン分類コードを用いて分類類似度  $a$  を算出した検索手法（以下、手動付与の検索手法とする。）と提案手法の検索結果の比較を行った。

### 5.1 実験で使用したデータセット

日本の登録商標には、使用する商品やサービスを考慮しなければ、外観が類似した商標が多く存在する。そこで本実験では、日本で登録された商標画像を対象として、外観類似の商標を検索するデータセットを作成した。具体的には、623,101枚をデータベース画像とし、4,222枚をクエリ画像とした。まず4,222枚中1,000枚のクエリ画像を用いて最適な検索パラメータを求め、その後残りの3,222枚でウィーン分類の自動付与が正確に行われているかと提案手法の有効性を確かめた。1,000枚のクエリ画像の正解画像数は14,226枚であり、残りの3,222枚のクエリ画像の正解画像数は45,422枚であった。この正解画像は、商標サーチャーと大学院28名の協力のもと、1枚ずつ目視で評価して定めた。この際、「クエリ画像に対して、解像度の違いや色の違いは考慮せず、画像の一部または全体に、人が見て明らかに同一の形状が存在していると判断できる画

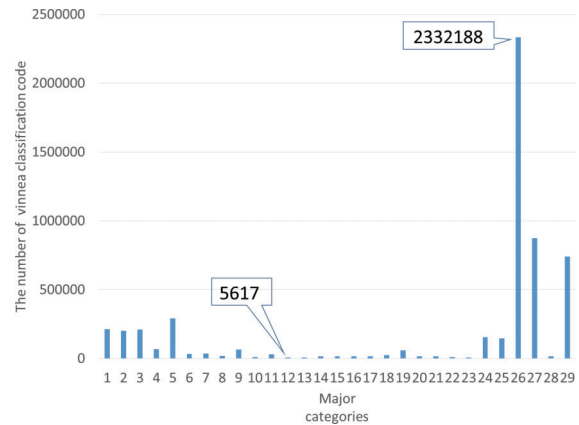


Fig. 8 The number of learning data for each major classification.

像」を選択させた。また、本実験で使用されるデータセットは、完全に同一な商標はなく、解像度や色などの差異が認められた商標を用いた。

### 5.2 実験条件

実験で使用した CPU は AMD Opteron (TM) Processor 6238 でメモリは 512 GB の計算機である。また GPU は NVIDIA Corporation GP102 を 9 枚使用した。また形状類似度  $s$  を求める際に、用いたパラメータは以下のものとする。各種パラメータの詳細は工藤らの研究<sup>4)</sup>を参考されたし。

- 形状類似度  $s$  の算出に用いたパラメータ
  - 距離の概算値により検索する局所特徴の数  $C=10000$
  - $k$  近傍探索におけるパラメータ  $k=10$

今回の実験で用いたパラメータは、工藤らの研究<sup>4)</sup>で使用したパラメータ  $k=50$  から  $k=10$  に変更している。その理由は、正解画像の追加やプログラムの実装の修正により、最も高速・高精度に検索できるパラメータに変更したためである。

ResNet50 の学習には、日本で登録された商標 694,428 枚を用いた。この学習に用いた商標の中には、データベースで使用した 623,101 枚の商標の内、ウィーン分類コードが付与されている商標 562,275 枚を用いた。また学習に用いた商標には、ウィーン分類コードが最大で 40 個、最小で 1 個付与されていた。さらにウィーン分類コードの付与されていた数の平均は 8.1 であり標準偏差は 5.75 であった。より詳細に学習データを分析するために、Fig. 8 に各大分類の学習に用いたデータ数を載せる。Fig. 8 は、横軸に大分類を示しており、縦軸に学習に用いたウィーン分類コードの数を示している。このグラフから、大分類 26（幾何学図形及び立体的幾何学図形）の学習データ数が 2,332,188 個と多く、最も学習データ数が少なかった大分類 12（家具、衛生施設）は 5,617 個であったことがわかる。つまり、登録された商標においてウィーン分類コードには偏りが生じており、不均衡なデータを学習することとなった。このことから、学習数の少ないウィーン分類コードは、付与精度が下がり、対象のコードを持つ商標が検索しにくくなるという問題が考えられる。この問題を解決する方法として、対象のコードの学習数を増やすことが考えられる。しかし、商標のウィーン分

類はマルチラベルであるため、対象のコードの学習数のみを増やすことは難しい。さらに学習する商標数を増やすことで過学習を起こす危険性がある。以上のことから今回は、学習する商標は1 epochにつき1回だけ学習するという最もベーシックな方法を採用した。しかし、このウィーン分類コードの偏りが本実験の検索結果に対して与える影響は小さいと考えられる。なぜならば、学習に用いた商標の多くは、データベースで使用している商標だからである。ウィーン分類コードの学習数が少ないものは、データベースで使用している商標に対しても付与数が少ないことから、対象のコードの有無による検索結果の変動は小さいと考えられる。

ResNet50 で用いた学習パラメータは以下のとおりである。

- ResNet50 の学習に用いたパラメータ
    - バッチサイズ：512
    - epoch数：100
    - optimizer: Adam (alpha=0.0001, beta1=0.9, beta2=0.999, eps=1.0×10<sup>-8</sup>, eta=1.0)
    - alphaの減少：60epoch および 90epoch にて alphaの値を1/10
    - データの正規化：学習に用いる画像のChannel毎に学習データセットの平均値を引き1/255でスケール
    - Data augmentation: Random Crop, Horizontal Flip
    - ResNet50のパラメータの初期化：Heらの研究<sup>9)</sup>に従う。
- 以上の条件で学習を行い、クエリ画像に対してウィーン分類コードを付与した。

### 5.3 最適な検索パラメータを求める実験

この実験では、1,000枚のクエリ画像を対象に、提案手法の最適な検索パラメータをグリッドサーチによって求めることで、各検索パラメータを変化させたときの傾向を調べた。

さらに、最適な検索パラメータ  $N$  を用いたときの自動付与のパフォーマンスを調べるために、専門家が付与したウィーン分類コードとの差を3,222枚のクエリに対して確認した。

#### 5.3.1 実験条件

最も検索漏れが少ない指標として、Recallが100%のときのPrecisionを使用した。またRecallとPrecisionの算出には、11点補完平均適合率<sup>10)</sup>を採用した。この実験で対象とする検索パラメータは以下の2点であり、加えて各検索パラメータの調査する値を以下に示す。

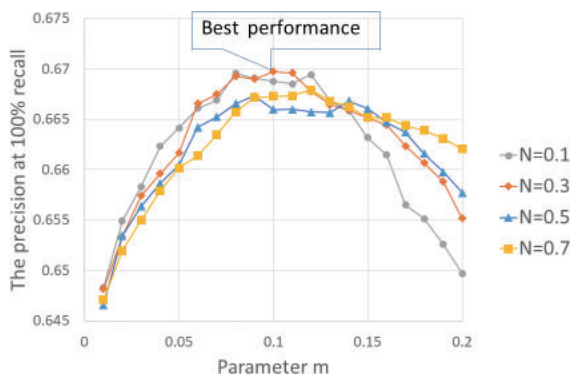


Fig. 9 Search accuracy when changing parameters  $N$  and  $m$ .

- 対象となる検索パラメータ
  - ウィーン分類コードの自動付与に関する閾値  $N$  (4.1節参照)
    - ◇ 調査する値：0.1 から 1.0 まで 0.1 間隔で設定
  - データベース画像の形状類似度  $s$  と分類類似度  $a$  の重み  $m$  (4.3節参照)
    - ◇ 調査する値：0.01 から 0.2 まで 0.01 間隔で設定

#### 5.3.2 実験結果・考察

まず、Recallが100%のときのPrecisionが最も高い検索パラメータ  $N$  と  $m$  を上記の値で調べた。Precisionが最も高い検索パラメータ  $N$  とその周辺の値を用いた結果を Fig. 9 に示す。この図では、縦軸はRecallが100%のときのPrecisionを、横軸は検索パラメータ  $m$  を示している。Precisionが最も高い検索パラメータ  $N$  と  $m$  はそれぞれ0.3と0.1であった。これらの検索パラメータを用いることで、提案手法は約67%のPrecisionを得ることができた。次に、各検索パラメータを変化させたときのPrecisionの傾向について調べる。まず、各検索パラメータ  $N$  の最もPrecisionが高いときを比較すると、差が0.2ポイント以内に収まっている。このことから、検索パラメータ  $N$  の変化による違いだけでは、たいした差異は見られなかった。一方、検索パラメータ  $m$  を大きくすると、どの検索パラメータ  $N$  対しても  $m=0.15$  付近でPrecisionが減少傾向になるが、その度合いは  $N$  の値が大きいくほうが緩やかである。つまり  $N$  の値が大きいくときは、検索パラメータ  $m$  の値を大きくすることの影響度は小さい。

次に、検索パラメータ  $N=0.3$  に定めたときにウィーン分類が正確に付与されているかを3,222枚のクエリに対して調べた。自動付与できた割合はRecallが50.2%のときでPrecisionが50.6%であった。このことから、ウィーン分類コードの自動付与は十分な精度が達成できているとはいえない。

次に自動付与された具体例を Fig. 10 から Fig. 12 示し、考察する。これらの例では、対象となるクエリ画像とそれに付与されたウィーン分類コードを示す。専門家が付与したウィーン分類コードを実線で囲み、自動付与したウィーン分類コードを破線で囲んだ。

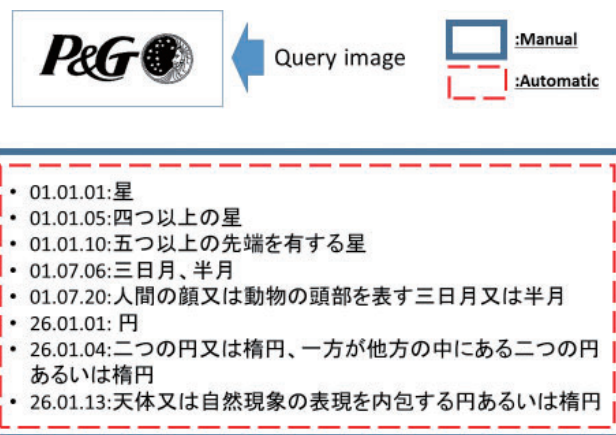


Fig. 10 The Vienna Classification code attached to the Query image of a moon.



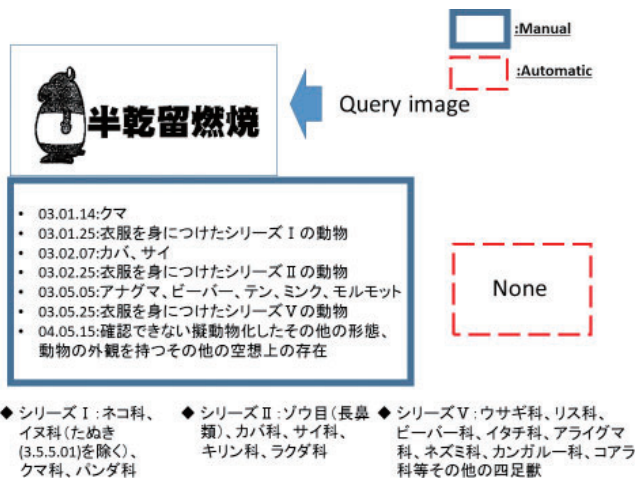


Fig. 11 The Vienna Classification code attached to the query image of a mascot character.

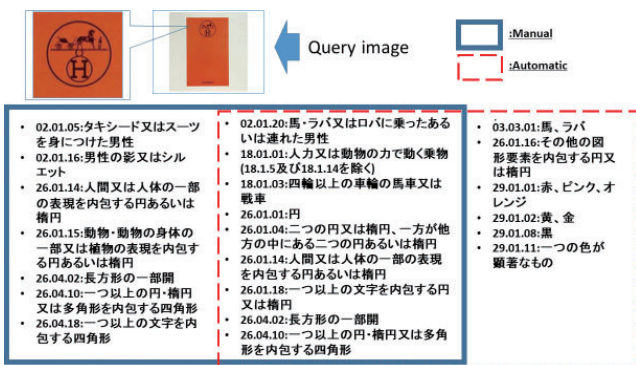


Fig. 12 The Vienna Classification code attached to the query image of a man with a horse drawn.

まず Fig. 10 は、専門家が付与したウィーン分類コードをすべて正確に自動付与できた例である。この例では、人間の顔を持つ三日月描かれており、専門家がつけた 8 個のウィーン分類コードをすべて正確に自動付与できている。このようにすべて正確に付与できた例は 519 枚あった。

また、Fig. 11 にてウィーン分類コードが自動付与されなかった例を示す。この例では、動物のキャラクターが描かれている。専門家がつけた 7 個のウィーン分類コードが、自動付与では 1 個も付与されなかった。このように、ウィーン分類コードが 1 個も自動付与されなかった例は 54 枚あった。

最後に、ウィーン分類コードのつけ漏れや過剰な自動付与があった例を Fig. 12 に示す。この例では、馬を引き連れた男が図に描かれている。専門家がつけた 16 個のウィーン分類コードのうち 9 個が自動付与できており、6 個のウィーン分類コードが過剰に自動付与されている。このように、1 個も自動付与されなかった例を除き付け漏れや過剰な付与がおこなわれた例は、2649 枚あった。次に、Fig. 12 の具体例を精査する。自動付与できなかったウィーン分類コードは 7 個あるが、03.03.01 (馬、ラバ) と 02.01.20 (馬・ラバ又はロバに乗ったあるいは連れた男性) のように共通に付与できたウィーン分類コードと

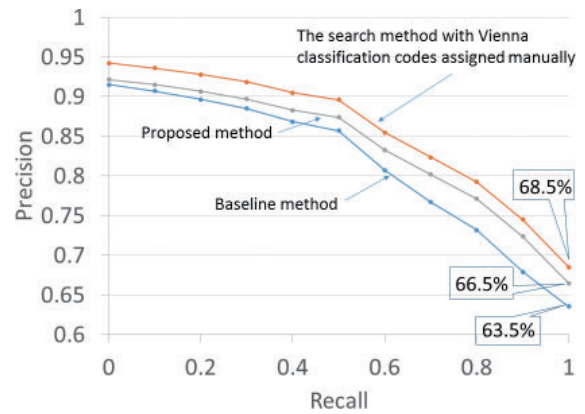


Fig. 13 11 point interpolated average precision.

重複した内容が多い。また過剰に自動付与したウィーン分類コードは、6 個中 4 個が大分類 29 (色) に関する内容であり 29.01.01 (赤、ピンク、オレンジ) のように商標を正しく表現できていると思えるものもあったが専門家は付与していなかった。以上の点から、専門家が重複したウィーン分類コードを付与する傾向と、色のウィーン分類コードの付与する傾向に関して、学習が十分でないと考えられる。また 26.01.16 (その他の図形要素を内包する円又は楕円) が自動付与されているが、「その他」を含んだ内容であり対象となる層の他のウィーン分類コードも考慮する必要があるため、正確に付与することが難しいと考えられる。参考までにウィーン分類コード 26.01.16 の専門家が付与した数は 288 枚で、自動付与した数は 260 枚であったが、正確に付与できたものは 1 枚もなかった。

#### 5.4 提案手法の有効性を示す実験

この実験では、最適な検索パラメータを用いた提案手法の有効性を示すために、3,222 枚のクエリ画像を用いて、既存手法との比較を行った。

##### 5.4.1 実験条件

この比較では、5.3 節同様、11 点補完平均適合率<sup>10)</sup>を採用した。加えて、提案手法と既存手法の検索に有意差があるかを調べるために検定法を用いた。具体的に、提案手法と既存手法で各クエリ画像の Average Precision を算出し、その数値から有意差があるかをウィルコクソンの符号順位検定<sup>11)</sup>を行うことで確認した。Average Precision はランキングの上位にどれだけ適合する画像が出現しているかを測る指標である。また、ウィルコクソンの符号順位検定は、2 つのデータ間に対応関係がある際に用いられ、そのデータの差分をもとに、有意差を認める手法である。

またウィーン分類コードが正確に付与されれば、どの程度検索精度を向上させることができるかを調べるために、手動付与の検索手法との比較も行った。手動付与の検索手法の最適な検索パラメータ  $m$  は、5.3 節同様にグリッドサーチによって調べた結果、0.13 であった。よって、手動付与の検索手法では、パラメータ  $m$  を 0.13 とする。最後に、具体的な検索例を示し、考察する。

##### 5.4.2 実験結果・考察

提案手法と手動付与の検索手法と既存手法の 11 点補完平均



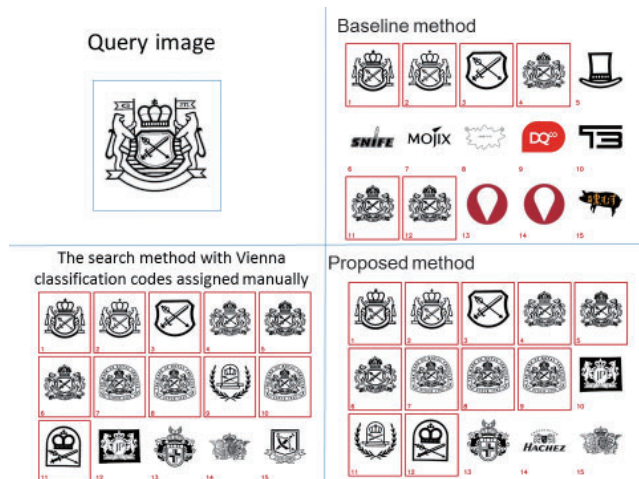


Fig. 14 An example of the searching trademarks with same classifications.

適合率の結果を Fig. 13 に示す。この結果から、手動付与の検索手法、提案手法、既存手法の順にすべての Recall 値において Precision が高くなっていることがわかる。また提案手法と既存手法を Recall が 100% のときの Precision を比較する。Recall が 100% のときに、提案手法は既存手法よりも Precision が 3.0 ポイント向上した。また既存手法と提案手法の Average Precision に対してウィルコクソンの符号順位検定を適用した結果、P 値は  $2.2 \times 10^{-16}$  となった。よって有意水準 1% を下回っているため、提案手法と既存手法の Average Precision は有意差があるといえる。以上により、Deep Learning により自動付与したウィーン分類コードを検索に用いることは有効であるといえる。さらに手動付与の検索手法と比較すると、Recall が 100% のときに手動付与の検索手法の Precision が 2.0 ポイント高かった。以上のことから、ウィーン分類コードの付与精度をより向上させることができれば、提案手法の Precision を手動付与の検索手法の Precision まで引き上げることができると考えられる。

次に、検索結果の具体例を Fig. 14 と Fig. 15 に示す。これらの例では、左上にクエリ画像を示し、右上に既存手法、右下に提案手法、左下に手動付与の検索手法の上位 15 位までの検索結果を示す。正解画像は赤枠で囲んでいる。

Fig. 14 は、既存手法に比べて提案手法が優れていた例である。Fig. 14 の既存手法では、検索順位 15 位までに正解画像が 6 枚検索されている。それに対して、手動付与の検索手法と提案手法では検索順位 15 位までにそれぞれ正解画像が 11 枚検索されている。クエリ画像に着目すると、描かれているのは上部に王冠、両側に獅子を携え中央に矢と剣を交差させた紋章である。一方、手動付与の検索手法と提案手法の検索できた正解画像には、剣と矢を交差させた紋章や王冠や盾などが描かれている。これらの正解画像が出力できた理由として、クエリ画像の商標に、手動と自動にて 24.1.19 (盾持ちを有する盾) や 24.9.5 (一つの王冠) などのウィーン分類コードが付与されていたことが挙げられる。

一方、Fig. 15 は提案手法に比べて既存手法が優れていた例

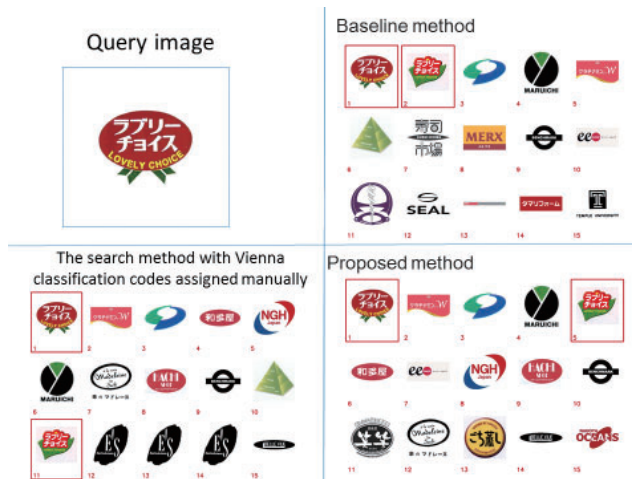


Fig. 15 An example of the decreased search accuracy.

Table 2 The number of the improved search accuracy and the number of the decreased search accuracy.

The number of examples with better accuracy with the proposed method	The number of examples with better accuracy with the baseline methods
885	278

である。ここでは、既存手法の検索精度が最も高かった例を示している。既存手法は正解画像が 1 位と 2 位に検索できており、提案手法と手動付与の検索手法では、2 枚目の正解画像がそれぞれ 5 位と 11 位に検索されている。このように提案手法と手動付与の検索手法では、2 枚目の正解画像の検索順位が下がった。その理由は、両手法において、クエリ画像に付与したウィーン分類コードと 2 枚目の正解画像のウィーン分類コードが 1 個も一致しなかったためである。このように既存手法の検索精度がよかったクエリ画像数と提案手法の検索精度がよかったクエリ画像数を Table 2 に示す。Table 2 から、自動付与したウィーン分類コードを検索に加えることによって、検索精度が改善されたクエリ画像が多くなったことがわかる。

## 6. おわりに

本論文では、外観が類似した商標を検索するために、図形の形状に基づく類似性に加えて図形の分類に基づく類似性も評価する検索手法を提案した。本手法の特徴は、図形の分類に基づく類似性を評価する際に、Deep Learning による自動付与したウィーン分類コードを用いることである。そこでまず、ウィーン分類コードを正確に自動付与できていたかを調べた。その結果、Recall が 50.2% のときに Precision が 50.4% であった。このことから、ウィーン分類コードの自動付与は十分高い精度が達成できているとはいえない。しかし、提案手法と既存手法の検索精度を比較した結果、提案手法は Recall が 100% のときに、Precision が 3.0 ポイント向上した。また、提案手法と既存手法の Average Precision に検定法を適用した結果、有意差

があった。以上のことから、図形の形状に基づく類似性に加えて図形の分類に基づく類似性も評価する検索手法の有効性が示された。

今後の方針として、より検索精度を上げるために、Deep Learning のウィーン分類コードの付与精度を向上させることが挙げられる。その方法として、ウィーン分類コードの学習データ数を揃えることや ResNet50 以外のモデルを使用するなど考えられる。さらに今回はウィーン分類コードの一致数のみから類似性を評価したが、ウィーン分類コードによって付与されやすさが違うことから、何らかの重みづけを与えて類似性を評価することが考えられる。

### 参 考 文 献

- 1) [https://www3.j-platpat.inpit.go.jp/TF/htmlj/term\\_v/indexj.html](https://www3.j-platpat.inpit.go.jp/TF/htmlj/term_v/indexj.html), (accessed 2018-12-03).
- 2) A. Joly and O. Buisson, "Logo retrieval with a contrario visual query expansion," Proceedings of the 17th ACM international conference on Multimedia. ACM (2009), pp. 581-584.
- 3) J. Fu, J. Wang, and H. Lu, "Effective logo retrieval with adaptive local feature selection," the 18th ACM international conference on Multimedia, ACM (2010), pp. 971-974.
- 4) R. Kudo, M. Iwata, M. Iwamura, and K. Koichi, "Proposal of Similar Image Retrieval System Using Large Scale Trademark Image Database," Journal of the Imaging Society of Japan, **57**, pp. 403-412 (2018) [in Japanese].
- 5) R. Kudo, M. Iwata, M. Iwamura, and K. Kise, "Improvement of Trademark Retrieval Using Pseudo Relevance Feedback," 11th Indian Conference on Vision, Graphics and Image Processing (2018), accepted.
- 6) M. Saito and M. Yusuke, "Illustration2vec: a semantic vector representation of illustrations." SIGGRAPH Asia 2015 Technical Briefs. ACM (2015), pp. 5: 1-5: 4.
- 7) C. Liu, Y. Cao, Y. Luo, G. Chen, V. Vokkarane, and Y. Ma, "Deepfood: Deep learning-based food image recognition for computer-aided dietary assessment," International Conference on Smart Homes and Health Telematics. Springer, Cham (2016), pp. 37-48.
- 8) K. He, X. Zhang, S. Ren, and J. Sun "Deep residual learning for image recognition," Proceedings of the IEEE conference on computer vision and pattern recognition (2016), pp. 770-778.
- 9) K. He, X. Zhang, S. Ren, and J. Sun "Delving Deep into Rectifiers: Surpassing Human-Level Performance on Image-Net Classification," arXiv preprint arXiv (2015).
- 10) Edited by K. Kita, K. Tuda, and M. Shishibori, "Jyouhoukensaku arugorizumu," Kyoritsu Shuppan (2002), pp. 20-21 [in Japanese].
- 11) Frank Wilcoxon, "Individual comparisons by ranking methods," Biometrics bulletin, **1**, pp. 80-83 (1945).



**工藤 力**

2015 年大阪府立大学大学院工学研究科電気・情報系専攻博士前期課程了。電子情報通信学会 学生員。



**岩田 基**

1999 年大阪府立大学大学院工学研究科電気・情報系専攻博士前期課程了。同年同大・工・情報助手。2007 年同大大学院工学研究科助教。2016 年同大大学院工学研究科准教授。現在に至る。博士 (工学)。情報検索、文書画像解析、電子透かし技術の研究に従事。電子情報通信学会、IEEE、映像情報メディア学会、各会員。



**岩村 雅一**

1998 年東北大・工・通信卒。2003 年同大大学院博士課程了。同年同大大学院工学研究科助手。2004 年阪府大大学院工学研究科助手。助教を経て、2011 年より同准教授。博士 (工学)。文字・物体認識、視覚障害者支援などの研究に従事。2006 年電子情報通信学会論文賞、2007 年 IAPR/ICDAR Best Paper Award、2010 年 IAPR Nakano Award、ICFHR Best Paper Award、2011 年 IAPR/ICDAR Young Investigator Award、2017 年 MVA Best Paper Award 各受賞。2016 年～2018 年 IAPR TC11 (Reading Systems) Vice Chair。電子情報通信学会、IEEE、情報処理学会 各会員。



**黄瀬 浩一**

1986 年阪大・工・通信卒。1988 年同大大学院博士前期課程了。同年同大大学院博士後期課程入学。1990 年阪府大・工・電気助手。現在、同大大学院工学研究科教授。博士 (工学)。2000 年～2001 年ドイツ人工知能研究センター客員教授。文書画像解析、情報検索、画像認識、行動認識などの研究に従事。2006 年度電子情報通信学会論文賞、2007 年、2013 年 IAPR/ICDAR Best Paper Award、2010 年 IAPR Nakano Award、ICFHR Best Paper Award、2011 年 ACPR Best Paper Award、2017 年 MVA Best Paper Award 各受賞。2016 年まで、IAPR TC11 (Reading Systems) Chair、現在、IAPR Conferences & Meetings Committee 委員、International Journal of Document Analysis and Recognition (IJ DAR) Editor-in-Chief。電子情報通信学会、情報処理学会、人工知能学会、電気学会、IEEE、ACM などの会員。