

デザインパターンの列挙に関する一考察

A Study of the Permutation of Design Pattern

渡辺 俊*¹
Shun Watanabe*¹

*1 筑波大学 システム情報系 教授 博士(工学)

Professor, Faculty of Engineering, Informaion and Systems, University of Tsukuba, Ph.D.

キーワード：デザイン科学、羽目板遊び、グラフ同型、機械学習

Keywords : Design Science, Panel Exercise, Graph Isomorphism, Machine Learning

1. はじめに

東京オリンピック 2020 のエンブレムは 3 種類のタイルによる平面充填によりデザインされている。デザインした野老朝雄氏はコンペへの応募にあたり百通り位くらいは描いて推考したと述べているが、堀山貴史氏によれば、真ん中に穴が開いたオリンピックのエンブレムには 539,968 通り、上に穴が開いたパラリンピックのエンブレムには 3,357,270 通りの組み合わせがあるとのことである¹⁾。

筆者も先の論文において、ル・コルビュジエが提示したモデュールによる羽目板遊びの探究を行い、デザインパターンの列挙が如何に組み合わせ爆発を起こすかを確認した²⁾。特に羽目板遊び2においては、深さ優先探索によるプログラムにより、b) 6 種類 12 枚のパネル構成では、1,449,912 通りの組み合わせがあることを明らかにした。一方で、これら全てを一覧するためには、1つの組み合わせを 22.6 mm (1/100) という小さな正方形で描いて隙間なく並べたとしても、36m × 20m 以上の空間が必要である。

今日、コンピュータの力を借りることで、膨大な数の組み合わせを全て描き出すことが物理的には可能ではある。しかし、デザインの過程において、具体的な制約条件や明確な評価関数などによる基準が示されない限り、それらの中から感性のみを頼りに望ましい組み合わせを探し出すのは容易ではない。

2. 研究目的

そこで、本稿では、機械学習の手法を援用することで、1,449,912 通りの組み合わせを似たようなパネル構成のグループに分類することを通じて、デザインの選考に役立つ方法について考察してみたい。

3. 特徴量を導出

機械学習によりデータを分類するためには、それらの特徴量を抽出する必要がある。

3-1 グラフの利用

建築計画では平面図を空間的な繋がり視点から評価する手法が広く普及している。そこで、パネル配置をグラフ構造に置き換えて、グラフから特徴量の抽出を試みた。

12 枚のパネル配置のベクトルデータを用いて、Python の GIS 用ジオメトリ操作ライブラリ Shapely の関数 intersection によりポリゴン同士に重複部分(線分)が存在するかでパネル同士の隣接関係を判定し、それぞれの組み合わせにおける隣接行列を生成した。なお、点で接しているパネル同士については隣接関係を設定していない(図1)。

次に、隣接行列を用いて、ネットワーク分析ライブラリ Networkx のオブジェクトを生成し、組み合わせ全体の構造についての指標として平均距離(average shortest path length)、クラスター係数(average clustering)、同類選択性係数(degree assortativity coefficient)を算出するとともに、個々のパネルについての指標として次数中心性(degree centrality)、近接中心性(closeness centrality)、媒介中心性(betweenness centrality)を算出し、それぞれの組み合わせの特徴量とした。

3-2 画像データの利用

先の研究では、Python の Decimal クラスを利用した高精度のベクトルデータによりパネル配置を計算させていたが、深さ優先探索における重複解の高速判定のために、226 pixel × 226 pixel の変換した画像データも活用していた。一方、画像認識では、SIFT (Scaled Invariant Feature Transform) や HOG (Histograms of Oriented Gradients) により画像の特徴量を得る手法が広く用いられている。そこで、Python の画像処理ライブラリ scikit-image の hog 関数を利用して、レイアウトの画像データから HOG 特徴量を取得することにした。変換した画像の例を同様に図1に示す。ただし、HOG 特徴量は画像データの輝度の勾配をヒストグラム化したものなので、パネル配置が持つ空間的な構造が反映されているとは言えない。




図1 特徴量の抽出

4. グラフ同型による分類

グラフ同型とは、2つのグラフが同じ個数の頂点を持ち、頂点と辺の繋がり方が同じ場合を指す、グラフ理論における概念の一つである。そこで、まずグラフ同型に基づくパターンの分類を試みた。

グラフ同型かどうかの判定には、Networkx に含まれる関数 is_isomorphic を利用し、全ての組み合わせについて一対比較を繰り返した結果、1,449,912 通りの組み合わせは 9945 グループに分類できることが確認された。ここで、配置した 12 枚に正方形のパネルは含まれておらず、任意のパネル配置には回転 (4 方向) と鏡像 (2 方向) による同じパターンが存在するので、それぞれのグループに属する組み合わせの数は基本的に 8 (4 × 2) の倍数となる。8 の倍数とならない場合、そのグループには線対称・点対称の配置が含まれていることになる。

グループに含まれる組み合わせの数 (C) とそのグループ数 (N) を表1に示す。最もグループ数が多い組み合わせの数は 16 通り (2 パターン) の場合で 1837 グループとなり、全体的には組み合わせの数が多くなるにつれてグループ数も指数関数的に減少する傾向が伺える。

最も組み合わせの数が少ないグループは、図2に示す 5 種類で、それぞれ線対称・点対称による 4 通り (1 パターン) の組み合わせのみである。グラフ同型の視点から見れば、これらのパネル配置はいずれも唯一無二のデザインと言えるが、人間の目には互いに似たようなパネル配置にも見えるであろう。

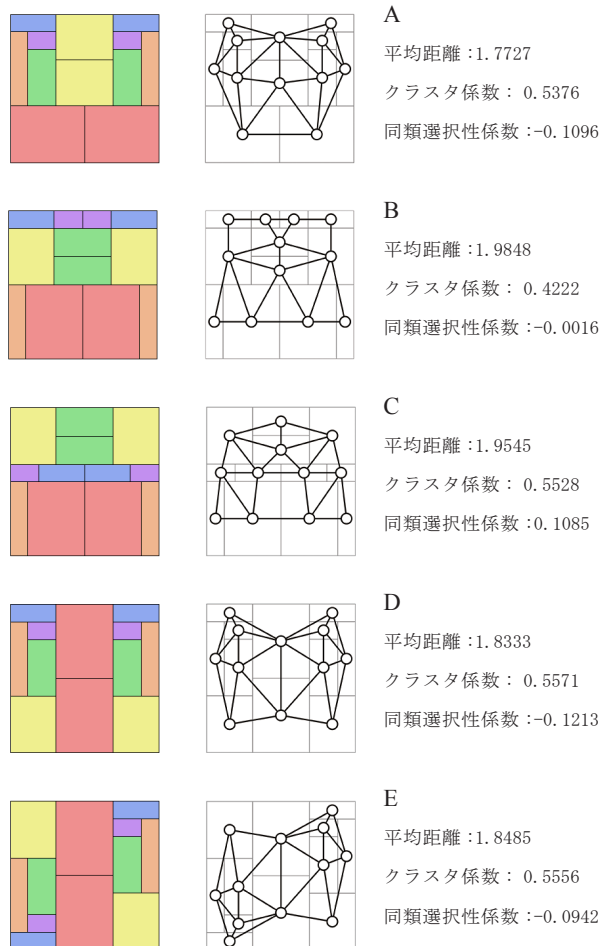


図2 唯一無二のグラフによるパターン

表1 グループに含まれる組み合わせの数 (C) とグループ数 (N)

C	N	C	N	C	N	C	N	C	N	C	N	C	N	C	N	C	N	C	N
4	5	160	166	312	15	496	21	680	4	848	3	1032	1	1264	1	1616	2	2368	1
8	1232	168	45	320	95	504	7	684	1	856	4	1040	2	1288	1	1624	1	2384	1
12	1	176	79	328	17	512	50	688	14	864	7	1048	1	1296	2	1648	2	2392	1
16	1837	180	2	336	42	520	10	696	5	872	5	1056	4	1304	1	1664	1	2456	1
24	351	184	38	344	24	528	18	704	15	880	6	1072	5	1312	1	1688	1	2496	1
32	1267	188	1	352	45	536	8	712	5	888	6	1080	2	1320	1	1712	1	2568	1
40	224	192	158	360	22	544	26	716	1	896	6	1088	3	1328	3	1720	1	2640	1
48	375	196	1	368	36	552	7	720	9	904	3	1096	1	1344	1	1736	1	2744	1
56	133	200	39	376	17	560	17	728	4	912	7	1104	2	1352	2	1752	2	3072	1
64	553	204	1	384	48	568	7	736	5	920	6	1112	1	1360	2	1776	1	3240	1
72	115	208	76	388	1	572	1	744	9	920	1	1128	1	1368	3	1792	2	3368	1
80	195	212	2	388	1	576	25	752	9	928	10	1136	2	1392	1	1824	1	3448	1
84	1	216	28	392	15	584	5	760	9	936	3	1144	3	1408	2	1832	1	3544	1
88	84	224	94	400	30	592	22	768	8	944	4	1152	1	1416	1	1856	2	3792	1
96	243	232	27	408	15	600	4	772	1	948	1	1160	2	1424	2	1912	2	4160	1
100	3	240	71	416	37	604	1	776	4	952	2	1168	1	1456	2	1928	1	4176	1
104	71	248	23	424	19	608	13	784	8	960	3	1176	4	1472	2	1952	1	4200	1
108	1	256	148	432	33	616	7	792	3	968	3	1184	4	1488	3	2020	1	4296	1
112	117	264	34	440	11	624	9	800	8	976	3	1200	1	1504	1	2040	1	6368	1
120	48	272	50	448	37	632	3	808	8	980	1	1208	4	1520	1	2048	1		
128	310	280	29	456	4	640	10	816	7	984	2	1212	1	1544	2	2096	1		
132	1	284	1	464	22	648	5	824	2	992	3	1216	2	1552	2	2144	1		
136	42	288	62	472	8	656	11	832	3	1000	2	1232	1	1576	1	2192	1		
144	104	296	28	480	30	664	5	840	3	1008	4	1240	3	1600	1	2248	1		
152	30	304	56	488	10	672	18	844	1	1024	6	1248	2	1608	2	2280	1		




図3 グラフ同型の組み合わせ

図3は400通り(50パターン)の組み合わせを含むグループから任意の一つを選び、各パターンを一つづつグラフの方向を揃えて並べてみたものである。グラフ同型の視点から見れば全て同一ということになるが、デザイン的にはさらに幾つかのサブグループに分割できそうに思われる。

最もパターン数が多いグループには6368通り(779パターン)もの組み合わせが含まれている。従って、同様にグループに含まれるパターンを並べて見ても、数が多すぎて人間の目では見通しがきかない。

5. ネットワーク指標による分類

次に、グラフから導かれた特徴量に基づいた分類を試みた。ただし、組み合わせがグラフ同型の場合、全体構造の特徴量である平均距離、クラスター係数、同類選択性係数は全て同じ値になる。そこで、グラフ同型に基づく9945のグループをネットワーク指標により再分類できるか確認することにした。図4は、機械学習ライブラリ scikit-learn の関数 PCA (主成分分析) で特徴量を集約して得られた第1成分と第2成分による散布図である。結果的には、一塊となっているので明確なクラスターは確認できないが、図2に示した5種類のパターンについて見てみると、一見似ているように見えるパターン同士は、確かに散布図上でもそれなりに近い位置にプロットされている。そもそも、これらの指標は主に複雑ネットワーク分析で言及されるものなので、ノード数が12の小さなグラフの類似度を判定する指標として有用かは、さらに詳細な検討が必要であろう。

一方で、グラフ同型や全体構造に関するネットワーク指標に基づく分類では、パネルの違いは全く考慮していなかった。そこで、各グループ内の組み合わせについて、其々の

パネルの3種類の中心性指標(計36特徴量)を用いて、scikit-learnの関数PCA(主成分分析)により分布の傾向を確認することにした。ただし、6種類の大きさの異なるパネルを2枚ずつ配置しているため、パネルの種類毎の特徴量は2枚の平均値とした。

図5に、先の50パターンについて、次数中心性、近接中心性、媒介中心性、およびそれら全てを特徴量としたPCAによる結果の散布図を示す。やはり、いずれの散布図からも明確なクラスターは確認できないが、とりあえず全ての特徴量で scikit-learn の関数 KMeans (K 平均法) による分類を試みた。なお、K 平均法では予めクラスター数を指定




図4 グラフ同型グループの再分類

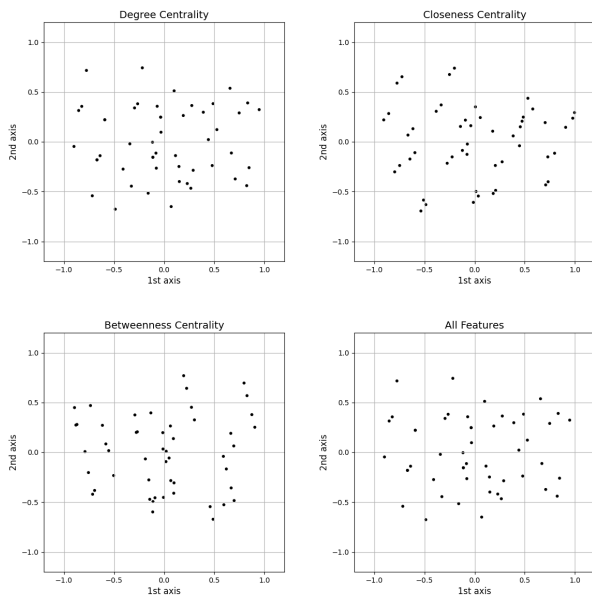


図5 PCA（主成分分析）の結果

する必要があるため、後の結果と比較をするためにクラスター数は5 (a, b, c, d, e) として計算した (表2)。

6. HOG 特徴量による分類

画像認識における物体検出の分野では、HOG 特徴量を SVM (Support Vector Machine) や CNN (Convolutional Neural Network) により分類する手法が広く行われている。しかし、ここでは教師データに相当する分類の基準が予め決められている訳ではない。また、HOG 特徴量による類似画像の分類では、線対称・点对称のパネル配置は別データ

表2 特徴量の違いによる機械学習の結果

パターン		1	2	3	4	5	6	7	8	9	10
中心性指標		a	b	b	a	c	a	c	a	b	b
HOG	Kmeans	α	β	β	β	γ	γ	γ	α	α	α
	DBSCAN	ζ	η	η	η	η	η	η	ζ	θ	θ
パターン		11	12	13	14	15	16	17	18	19	20
中心性指標		b	a	a	d	d	c	c	a	c	c
HOG	Kmeans	α	α	α	δ	δ	ϵ	ϵ	δ	δ	δ
	DBSCAN	ζ	ζ	ι	κ	κ	κ	κ	κ	κ	κ
パターン		21	22	23	24	25	26	27	28	29	30
中心性指標		c	a	c	c	c	c	d	c	a	c
HOG	Kmeans	δ	ϵ	ϵ	ϵ	ϵ	ϵ	δ	ϵ	δ	ϵ
	DBSCAN	κ	κ	κ	κ	κ	κ	κ	κ	κ	κ
パターン		31	32	33	34	35	36	37	38	39	40
中心性指標		d	a	a	c	d	c	d	e	e	e
HOG	Kmeans	δ	ϵ	δ	ϵ	δ	ϵ	δ	α	β	β
	DBSCAN	κ	κ	κ	κ	κ	κ	κ	ζ	η	η
パターン		41	42	43	44	45	46	47	48	49	50
中心性指標		e	e	e	e	e	b	b	b	e	a
HOG	Kmeans	β	γ	γ	γ	α	α	α	α	α	α
	DBSCAN	η	η	η	η	ζ	θ	θ	ζ	ζ	ι

と認識されると考えられることから、中心性指標の際と同様に先の 50 パターンについて、KMeans (K 平均法) によりクラスター数を5 ($\alpha, \beta, \gamma, \delta, \epsilon$) として再分類を試みた (表2)。

一方、K 平均法では予めクラスター数を指定する必要があるだけでなく、クラスター重心からの距離で分類しているため、クラスターの形状が複雑な場合にはうまく機能しないことも知られている。そこで、DBSCAN による再分類についても試してみることにした。scikit-learn の関数 DBSCAN では、クラスター数を指定する代わりに、クラスターの密度基準となるパラメータ (min_samples, eps) を指定する必要がある。パラメータの値が厳しすぎるとクラスターに分類されないノイズ (outlier) が多く発生し、甘すぎると1つのクラスターにしかならない。パラメータを段階的に変化させて DBSCAN を実行した結果、min_samples=3, eps=0.2 の時に outlier=0 となり、5つのクラスター ($\zeta, \eta, \theta, \iota, \kappa$) に分類することができた (表2)。

それぞれの結果を見比べてみると、配置画像に基づく HOG 特徴量による分類法は、見た目の印象通り、一番大きな赤いパネルが横並びの場合 (α, β, γ) (ζ, η, θ) と対角状の場合 (δ, ϵ) (κ) に分類しているのに対して、中心性指標による分類法はこれらを混同している。さらに細かく見ると、KMeans では対角状の配置の方を2分類しているのに対して、DBSCAN ではむしろ13、50 (ι) の赤いパネル配置に反応している。逆に、中心性指標による分類は見た目の印象とは大分異なるので、グループ内のパターン分類ではなく、グラフ同型パターンの枠組みを外して比較した方が、別の尺度から見た類似性の着眼が得られるかもしれない。

7. おわりに

本稿では、膨大な数のデザインパターンについて、機械学習の手法による分類を試みたが、現状では限られたグループに対する試行に留まっているために、全てのグループで同様の手続きを実施した場合、どのような結果になるのかは定かではない。また、人間による直感的な分類とどの程度一致するのかについての検証も必要であろう。

本研究は、科学研究費補助金 基盤研究 (B) 「創造性の論理的・技術的探求に基づくデザイン共創環境の構築と教育プログラムの開発」の支援を得て行われた。

[参考文献]

- 堀山貴史：列挙アルゴリズムとデザイン、第1回デザイン科学数理知能シンポジウム資料、日本建築学会、2018年6月
- 渡辺俊：ル・コルビュジェが提示したモデュロールによる羽目板遊びの探究、日本建築学会計画論文集、第84巻 第766号、2679-2686、2019年12月