

# ポスターデザイン評価における 短時間閲覧時の指導者着目点再現の検討

深澤 菜月<sup>1</sup> 間瀬 健二<sup>2</sup> 榎堀 優<sup>1</sup>

**概要：** 絵画や伝統工芸、ものづくりなどの様々な分野において、熟練者は初心者及び中級者とは異なる視覚行動の特徴がある。このような熟練者の着目点を機械学習で再現できれば、初学者の支援や作品レベルの自動判別など、様々な応用が可能となる。本研究では、研究発表ポスターのデザインを対象にこれを研究した。ポスター画像及び評価時の大学教員の視線データから作成した良点・改善点ヒートマップで、顕著性マップ生成ネットワークを用いて学習した。これにより、ポスター画像に対する良点・改善点ヒートマップの生成を試みた。機械学習によって指導者着目点を再現することで、新規ポスター画像に対して良い箇所と改善すべき箇所を抽出できるポスターデザインの技能習得支援システム作成の見通しを得た。

## A Study about Reproduction of Instructor's Interesting Areas during Short-Time Poster Design Evaluation

NATSUKI FUKASAWA<sup>1</sup> KENJI MASE<sup>2</sup> YU ENOKIBORI<sup>1</sup>

### 1. はじめに

絵画や伝統工芸、ものづくりなどの様々な分野において、熟練者は理論的・直感的に、作品などの注目点を判断している。例えば、竹浪ら [12] は伝統工芸品である樂焼抹茶碗鑑賞時の視線移動について、金藤ら [8] はプログラミングのコード読解時における視線の動きについて、それぞれ熟練者は初心者及び中級者とは異なる視覚行動の特徴があることを明らかにした。このような熟練者の着目点を機械学習で再現できれば、初学者の支援や作品レベルの自動判別など、様々な応用が可能となる。

本研究では、研究発表ポスターのデザインを対象にこれを研究した。ポスターは、同じ研究内容を伝える場合でも、デザインの違いによって受け取る印象は異なる。ポスター発表は、閲覧初期に、いかに効果的に論点などへ視線を誘導できるかが重要であり、そのデザイン技能の習得支援を目指した。

本研究では、ポスター画像および大学教員が良点や改善

点を指摘するときの視線データから作成した良点・改善点ヒートマップで学習し、ポスター画像に対する良点・改善点ヒートマップの生成を試みた。学習には、画像の中で人の視線が集まりやすい箇所を示す顕著性マップの生成手法である Pan ら [4] の SalGAN を使用した。以上から、機械学習によって指導者着目点を再現することで、新規ポスター画像に対して良い箇所と改善すべき箇所を抽出できるポスターデザインの技能習得支援システム作成の見通しを得た。

### 2. 関連研究

#### 2.1 発表コンテンツのデザイン評価や自動生成

ポスターデザインに関して、野本らは、既存の研究発表に用いられたポスターに対して、「視認性」「判読性」「可読性」という3つの評価項目を設け、人手で評価点をつけ、ポスターの特徴を説明変数としてロジスティック回帰分析を行った [1]。

ポスターとは異なるが、スライドも発表の際によく用いられる形式であり、大山らは、同じような内容を表現する場合でも表現方法によってスライドの印象が変化すること、一般的に「分かりやすいスライド」が存在することを

<sup>1</sup> 名古屋大学大学院 情報学研究科  
Graduate School of Informatics, Nagoya University

<sup>2</sup> 名古屋大学 数理・データ科学教育研究センター  
Mathematical and Data Science Center, Nagoya University

実験的に示した [3]。さらに、スライドの画像特徴、構造特徴、内容特徴を組み合わせて用いることで、スライドが分かりやすいか分かりにくいかの 2 クラス分類問題で 74 % の精度を達成した。

このように、発表コンテンツのデザインに関する研究はこれまでも行われてきた。しかし、これらはコンテンツ全体を対象として良し悪しを評価しており、部分ごとの良し悪しの評価は行っていない。一枚のポスターでも、その中に良いところがあれば改善すべきところもあると考えられる。従って、一概に良い悪いのみで分類することは相応しくない。本研究では、ポスターの中のどの部分が良いのか、どの部分が改善すべき所なのかなどを、詳細に評価する。

## 2.2 顕著性マップの自動生成

顕著性マップとは、人が画像を認識する際に注視しやすい部分をヒートマップで表現したものであり、本研究と同様に着目点を再現している。本研究ではこの顕著性マップ生成ネットワークを学習に使用した。

顕著性マップについて、1998 年に Itti ら [17] によって実用的な生成手法が提案されて以来、様々な手法が提案されてきた。そのほか、深層学習を用いた手法として、顕著性予測の初期のネットワークを代表とする Vig らの Ensemble of Deep Networks (eDN) [13]、Pan らの SalGAN[4]、Kümmerer らの DeepGaze II[6]、Liu らの DSCLRCN[7] などの様々な顕著性マップ生成ネットワークが提案されてきた。

本研究では、学習データをポスター画像と良点及び改善点を示すそれぞれのヒートマップとして、顕著性マップの生成ネットワークで新規ポスター画像に対する良点と改善点のヒートマップを出力させた。使用するネットワークは、シンプルな構造でありながら比較的高い精度である Pan らの SalGAN[4] を採用した。

## 3. 視線計測実験によるデータセット作成

本節では、視線データを取得し、ポスター画像に対する良点及び改善点を示すヒートマップを作成した手法について述べる。第 3.1 節で視線計測実験に関して、第 3.2 節で取得データから良点・改善点ヒートマップを作成した方法について述べる。

### 3.1 視線計測実験

ポスター画像に対する良点と改善点を示すヒートマップを作成するために、視線計測器を装着し研究発表に用いられたポスターを評価する実験を行った。本節では上記の実験に関する視線計測器、視線計測環境、被験者属性、実験手順について順に述べる。

### 3.1.1 視線計測器

視線計測器は Tobii Pro グラス 3 を使用した (図 1 参照)。Tobii Pro グラス 3 は眼鏡型の視線計測器であり、装着することで眼鏡の中央のカメラからの映像 (音声を含む) と、その映像内で視点の座標データが取得できる。データ取得には、専用アプリケーション Glasses 3 をノートパソコンにインストールして使用した。

実験の際、被験者の必要に応じて視力補正用の度付きレンズを視線計測器に取り付けた。Tobii Pro グラス 3 の度付きレンズは、+3 から-5 の範囲で 0.5 ディオプター間隔で用意されており、近視または遠視の視力補正が左右の目それぞれで可能である。



図 1 Tobii Pro グラス 3 (公式サイトより引用)

### 3.1.2 視線計測環境

実験環境を図 2 に示す。縦型に配置した 27 インチ型 4K モニター (リフレッシュレート: 60 Hz, 型番:S2722QC, Dell) に図のようにポスターを表示させた。机の端からの距離が 40cm となるようにモニターを設置した。モニターには別のノートパソコンを接続し、心理学実験環境構築用のアプリケーション PsychoPy[5] を使用して、モニターにポスター画像を表示させた。また、被験者の眼球からモニターまでの距離が凡そ 80cm となるように被験者用の椅子を設置した。

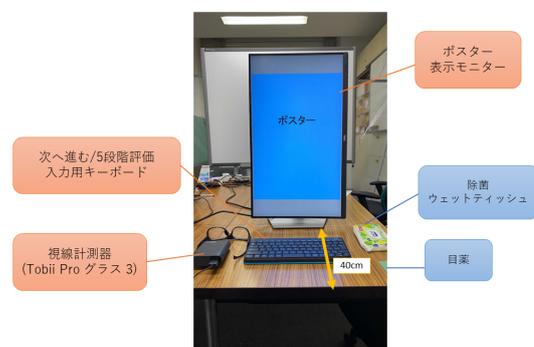


図 2 実験環境

### 3.1.3 被験者属性

日常的にポスター発表を評価している大学教員を被験者として、良点・改善点を指摘するときの視線データを収集した。被験者は名古屋大学情報学研究科の教員9名(男性9名, 年齢30歳~65歳)である。被験者9名のうち3名は乱視があった。被験者が視力補正を必要とする場合は、視線計測器に付属の視力補正用レンズを取り付けて実験を行った。視力補正レンズを取り付けて実験した被験者は2名であった。

### 3.1.4 実験手順

1枚のポスターに対して、以下の手順で視線を計測した。手順を図にしたものを図3に示す(①~④は図3の番号に対応する)。なお、視線計測時のポスターの表示は心理学実験環境構築用のアプリケーション PsychoPy[5]を使用した。

- ① ポスター全体を見て、その中で良点と改善点を見つける(視線計測は行わない)
- ② 理由について発言しながら、ポスターの良い点を注視
- ③ 理由について発言しながら、ポスターの改善点を注視
- ④ ポスター全体としてのデザインを5段階で評価(5: とてもよい, 4: よい, 3: どちらともいえない, 2: よくない, 1: とてもよくない)

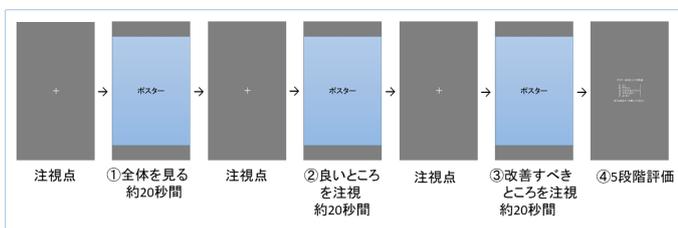


図3 ポスター呈示手順

①~③は20秒を目安としており、20秒経過時にブザー音がなるが自動的に終了せず、被験者がスペースキーを押すことで次の手順へと進む仕様とした。これは、被験者が見つけた良点・改善点の数に応じて、理由を発言する所要時間が異なるためである。実験は、複数のポスター画像それぞれに対して、以上の手順を実施して視線データを計測した。本研究では計77枚のポスターを評価し、9~10枚のポスターの評価を1セットとして、一人の被験者につき4セット計測した。セットごとに視線計測器をキャリブレーションした。以上より、1枚のポスターにつき、4~5名分の視線を計測した。なお、今回の実験では、ポスターの内容(文章など)は評価の対象とせず、デザインのみを評価するように指示した。この理由は、研究発表される内容は多種多様であるので、内容まで対象とすると十分なデータ量を収集できないためである。

### 3.2 良点・改善点ヒートマップの作成方法

本節では、前節で収集した視線データをもとに、ポスターに対しての良点及び改善点を示す視線ヒートマップを作成した方法を述べる。視線計測器から得られるのは、眼鏡中央部に配置されたフルHDカメラからの一人称視点映像と、その中で視線がどこにあるかという情報である。一人称視点映像中のポスター画像は傾いていたり、頭部が固定されていないためフレームごとに位置がずれたりする。よって、ヒートマップを作成するためには、一人称視点映像での視線座標がポスター画像の中のどの座標を指すのか変換する必要がある。本研究では、以下の手順で、ホモグラフィ変換により座標を変換した。

- (1) 一人称視点動画から視線停留時の動画を切り出し
- (2) 各フレームごとにホモグラフィ行列で視線座標を変換
  - (a) ポスター画像と一人称視点映像を白黒画像に変換
  - (b) 変換された白黒画像の特徴点を抽出
  - (c) 二つの画像間で特徴点をマッチング
  - (d) 特徴点の組からホモグラフィ行列を計算
  - (e) ホモグラフィ行列を用いて座標を変換
- (3) 出力ヒートマップサイズの二次元配列を用意
- (4) 視線座標および周りの中心視野範囲に対応する配列の値を加算
- (5) 最大値を255に調整して画像を出力

視線停留部分の検出には、Tobii Pro LabのTobii I-VT (Attention) フィルタを使用した。特徴点抽出、ホモグラフィ行列の計算には、OpenCVを使用した。特徴点抽出のアルゴリズムは、AKAZE (Accelerated-KAZE) [9]とした。特徴点マッチングの選択方法及び閾値に関しては、D.Loweの比率検定手法[14]およびOpenCVの特徴点マッチング[15]を参考にした。変換の様子を図4に示す。

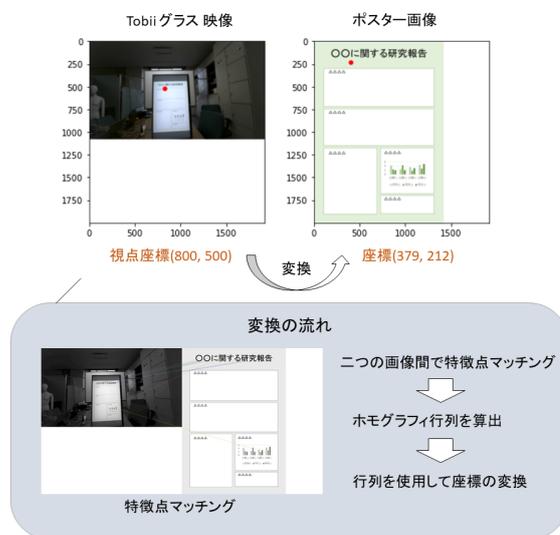


図4 ホモグラフィ行列を用いた座標変換例

出力ヒートマップの構築は、提示したポスター画像と同サイズの空の二次元配列を用意し、各被験者の各ポスター評価毎に、50 fps の視線データの各フレームについて、視野の座標及び中心視野の範囲内の値を 1 加算した。ポスターごとに全被験者の配列を足し合わせ、この最大値を 255 となるように正規化して、ヒートマップ画像とした。出力画像サイズ 1415 × 2000 ピクセルに対して中心視野の範囲を半径 120 ピクセルとした。この値の算出方法について、本実験では、中心視野角度を 2 度として配列で視線座標および周りの中心視野範囲に対応する値を加算することでヒートマップを作成した。中心視野角度を  $p$  度、ポスターまでの距離を 1 メートル、ディスプレイに表示されたポスターの縦の長さを  $q$  メートル、出力ヒートマップの縦の長さを  $u$  ピクセルとすると、ヒートマップでの中心視野の範囲は

$$\frac{ul}{q} \tan \frac{2p\pi}{360}$$

となる。本実験では、 $p = 2$ ,  $l = 0.8$ ,  $q = 0.465$ ,  $u = 2000$  で実験したため、中心視野の半径は 120 ピクセルとした。

以上の手順で視線計測により作成された良点・改善点視線ヒートマップの一部を例として図 5 に示す。こちらは 5 枚のポスター画像に対する視線ヒートマップであり、上段が良点を注視した際の視線ヒートマップ、下段が改善点を注視した際の視線ヒートマップである。

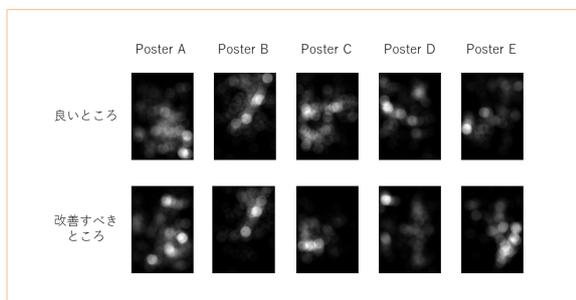


図 5 作成した良点・改善点視線ヒートマップ例

#### 4. SalGAN を用いた良点・改善点ヒートマップの再現

本章では、作成した良点・改善点ヒートマップを元に顕著性マップ生成ネットワーク SalGAN で学習し、ポスター画像に対する顕著性マップを生成した結果について述べる。

##### 4.1 ポスターの良点・改善点抽出のための学習

前節で作成した良点及び改善点の視線ヒートマップと、元のポスター画像を入力として学習し、新規ポスター画像に対しての良点と改善点を示すヒートマップの出力を試みた。学習には、Pan らのネットワーク SalGAN[4] を使用し

た。ネットワークの概要図を図 6 に示す ([4] より引用)。

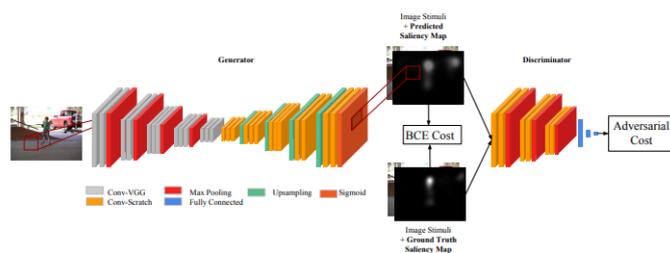


図 6 SalGAN([4] より引用)

SalGAN とは、GAN の構造を用いて顕著性マップを生成するネットワークであり、前半の生成部と後半の識別部からなる。生成部のネットワークを図 7、識別部のネットワークを図 8 に示す。図中に用いたブロック構造の詳細を表 1 に示す。ブロック名について、Conv は畳み込み層、2dPooling はプーリング層、UPsample はアップサンプリング層、FC は全結合層を表す。生成部はエンコーダデコーダモデルとなっており、エンコーダ部分は VGG16 から最後のプーリング層と全結合層を取り除いたものである (ImageNet で学習済みの VGG16 の重みを使用した)。

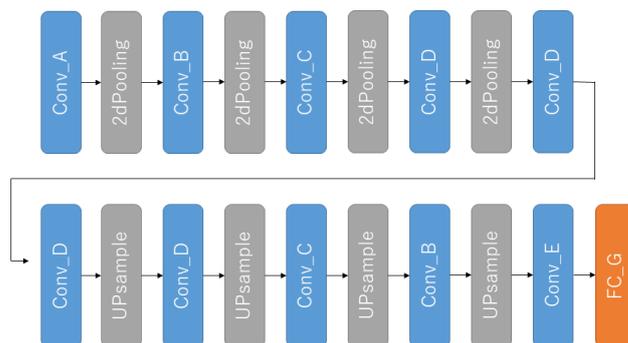


図 7 生成部のネットワーク構造

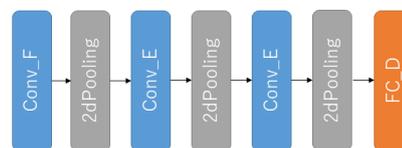


図 8 識別部のネットワーク構造

損失関数は以下の式で計算される。生成器の損失関数を  $L_g$ 、識別器の損失関数を  $L_d$  とすると、

$$L_g = \alpha \times L_b + L(D(I, \hat{S}), 1)$$

$$L_d = L(D(I, S), 1) + L(D(I, \hat{S}), 0)$$

となる。ここで、 $\alpha$  は定数 (重み) であり、 $L_b$  は生成器で

表 1 ネットワークのブロック構造

2dPooling					
layer	depth	kernel	stride	pad	activation
layer_1		2×2	2	0	-

UPsample					
layer	depth	kernel	stride	pad	activation
layer_1		2×2	2	0	-

Conv_A					
layer	depth	kernel	stride	pad	activation
layer_1	64	1×1	1	1	ReLU
layer_2	64	3×3	1	1	ReLU

Conv_B					
layer	depth	kernel	stride	pad	activation
layer_1	128	3×3	1	1	ReLU
layer_2	128	3×3	1	1	ReLU

Conv_C					
layer	depth	kernel	stride	pad	activation
layer_1	256	3×3	1	1	ReLU
layer_2	256	3×3	1	1	ReLU
layer_3	256	3×3	1	1	ReLU

Conv_D					
layer	depth	kernel	stride	pad	activation
layer_1	512	3×3	1	1	ReLU
layer_2	512	3×3	1	1	ReLU
layer_3	512	3×3	1	1	ReLU

Conv_E					
layer	depth	kernel	stride	pad	activation
layer_1	64	3×3	1	1	ReLU
layer_2	64	3×3	1	1	ReLU

Conv_F					
layer	depth	kernel	stride	pad	activation
layer_1	3	1×1	1	1	ReLU
layer_2	32	3×3	1	1	ReLU

FC_G					
layer	depth	kernel	stride	pad	activation
layer_1	1	1×1	1	0	sigmoid

FC_D					
layer	depth	kernel	stride	pad	activation
layer_1	100	3×3	-	-	tanh
layer_2	2	3×3	-	-	tanh
layer_3	1	2×2	-	-	sigmoid

生成されたヒートマップと正解ヒートマップ間のピクセルごとのバイナリクロスエントロピーの平均である。また、 $I$  は生成器により作られたヒートマップ、 $S$  は本物のヒートマップ、 $\hat{S}$  は偽物の (作られた) ヒートマップを示しており、 $D(I, S)$  は識別器によって計算される生成されたヒートマップが本物である確率、 $D(I, \hat{S})$  は偽物である確率を示す。 $L()$  は内部の 2 項間のバイナリクロスエントロピーを指し、ここで 0 は完全に偽物のヒートマップであること、1 は完全に本物のヒートマップであることを示す。すなわち、 $L_g$  の  $L(D(I, \hat{S}), 1)$  に関しては、生成器により生成されたヒートマップがより本物に近づくとき小さな値になる。本実験では、このネットワークにポスター画像と、良点及び改善点を注視した際のヒートマップを入力することで学習した。今回用いたデータセットは合計で 77 枚と機械学習用のデータとしては少ない枚数であったため、10 分割交差検証により評価指標値を算出した。つまり、77 枚のポスターを 10 分割し、そのうちの一つをテスト用データ、残りを学習用データとして評価指標値を算出することを 10 回し、その平均値を求めた。それぞれの分割において、バッチサイズを 8、エポック数を 100 として、損失関数の重み  $\alpha$  および学習率についてハイパーパラメータ自動探索ツール Optuna を用いて最適化した。損失関数の重み  $\alpha$  および学習率は 0~1 の間で探索し、候補値のサンプリングアルゴリズムは TPE アルゴリズム [18]、枝刈りアルゴリズムは HyperBand アルゴリズム [19] を使用した。試行数は 100 とし、学習用データから無作為に選出された 8 枚のハイパーパラメータ調整用データで評価指標値の AUC が最も小さくなるように最適化した。最適化後、探索したハイパーパラメータでエポック値を 300 として再学習し、テスト用データの評価指標値を算出した。

#### 4.1.1 良点・改善点再現の評価指標

学習後、SalGAN[4] で用いられた顕著性ヒートマップ再現の評価指標値を算出した。各値の概要及び算出方法は、下記のとおりである。説明及び算出方法は、[10] 及び [11] を参考にした。

#### AUC (borji) (Area under ROC Curve)

AUC は Area under ROC Curve の略であり、ROC 曲線より下の面積を指す。ROC 曲線は、横軸を偽陽性 (正解ヒートマップではハイライトされていないのに生成ヒートマップでハイライトされてしまう) 率、縦軸をそれに対する真陽性 (正解ヒートマップ及び生成ヒートマップの両方でハイライトされる) 率として描かれる。AUC 値は 0 から 1 までの値をとり、値が 1 に近いほど判別性能が高いことを示す。判別性能が無作為であるとき、AUC は 0.5 となる。

顕著性マップの AUC を計算する際には、顕著性マップは 0~255 の画素値で表される二次元配列であるため、閾値を定め陽性/陰性を区別する。顕著性マップの評価指標としての AUC は、主に偽陽性と真陽性の計測方法の異なる AUC (Judd) と AUC (borji)、センターバイアスを取り除くために生成ヒートマップを別の正解ヒートマップと比較する sAUC があるが、本研究では SalGAN[4] で用いられた AUC (borji) を算出した。AUC (borji) では、正解ヒートマップでの値が閾値以上である画素数をカウントし、生成されたヒートマップで同じ数の画素を無作為に一度のみ選出する。閾値を 0.1 から 0.9 まで 0.1 刻みで変化させることにより、様々な偽陽性率に対する真陽性率を計算することで、ROC 曲線が描かれ AUC (borji) が求められる。

## NSS (Normalized Scanpath Saliency)

生成ヒートマップと正解ヒートマップ間の対応付けの指標である。AUC と異なり、平均と分散を用いた標準化計算を使用して算出している。計算は以下の式によりされる。

$$NSS = \frac{1}{N} \times \sum_{p=1}^N NSS(p)$$

$$NSS(p) = \frac{SM(p) - \mu_{SM}}{\sigma_{SM}}$$

ここで、 $p$  は正解ヒートマップの値が閾値 (= 127.5) 以上である座標を表し、 $SM(p)$  は座標  $p$  での生成ヒートマップの値、 $\mu_{SM}$ 、 $\sigma_{SM}$  はそれぞれ生成ヒートマップの平均値、標準偏差値を示す。すなわち、 $NSS(p)$  では平均が 0、分散が 1 となるように標準化の計算がされており、 $NSS$  は正解ヒートマップの値が閾値以上の座標でこの値の平均をとったものである。NSS が高いほどモデルの性能が高いことを示す。

## CC (Pearson's Correlation Coefficient)

生成されたヒートマップと正解ヒートマップ間のピアソンの相関係数を指標としている。計算は以下の式によりされる。

$$CC = \frac{cov(SM, TM)}{\sigma_{SM} \times \sigma_{TM}}$$

ここで、 $SM$  は生成ヒートマップ、 $TM$  は正解ヒートマップであり、 $cov(SM, TM)$  はこれらの共分散を意味する。 $CC$  の出力範囲は -1 から 1 の間である。1 に近いほど強い正の相関関係、-1 に近いほど強い負の相関関係を示す。本実験では正解ヒートマップの値が高い場所では生成ヒートマップの値も高くなることが望ましいので、1 に近いほど優れたモデルであることを示している。

## 4.2 実験結果と考察

本節では実験結果について述べる。生成された良点・改善点ヒートマップの例を図 9 に示す。上段がポスター番号、中段が生成された良点及び改善点ヒートマップ、下段が視線計測器より取得したデータから作成した正解値を示すヒートマップである。例えば、ポスター 2 の良点ヒートマップでは上部や左側のハイライトが、ポスター 4 の改善点ヒートマップでは右側のハイライトが再現できていることが読み取れる。一方で、ポスター 2 では左下が誤ってハイライトされるなど、再現に失敗したポスターもあった。

また、10 分割交差検証により算出された評価指標値を表 2 に示す。

評価指標 AUC.borji, NSS, CC は、良点ヒートマップでそれぞれ  $0.735 \pm 0.046$ ,  $0.919 \pm 0.295$ ,  $0.188 \pm 0.052$ , 改善点ヒートマップでそれぞれ  $0.649 \pm 0.043$ ,  $0.557 \pm 0.178$ ,

ポスター	良点正解ヒートマップ	良点生成ヒートマップ	改善点正解ヒートマップ	改善点生成ヒートマップ
1				
2				
3				
4				

図 9 生成物及び正解ヒートマップ例

表 2 評価指標値

	AUC (borji)	NSS	CC
良点 (平均 ±SD)	$0.735 \pm 0.046$	$0.919 \pm 0.295$	$0.188 \pm 0.052$
改善点 (平均 ±SD)	$0.649 \pm 0.043$	$0.557 \pm 0.178$	$0.112 \pm 0.035$

$0.112 \pm 0.035$  となった。AUC の値は 1 に近いほど正解ヒートマップを忠実に再現できたことを示し、判別性能が無作為である場合では計算上 0.5 となる。AUC 値は良点ヒートマップで 0.735、改善点ヒートマップでは 0.649 といずれも 0.5 を上回っているため、本システムは着目点の再現に寄与できたと考えられる。一方で、最高値が 1 である CC 値は良点ヒートマップで 0.188、改善点ヒートマップでは 0.112 と絶対値としては低く、着目点の概形の再現はできているが概形内の重要度付けはまだ不十分であり改善の余地がある。また、NSS は CC の離散近似の一種であり [10]、CC についても同様のことが言える。

AUC, NSS, CC は全ての値で良点ヒートマップのほうが改善点ヒートマップより高いスコアとなった。この結果より、本実験の学習では改善点よりも良点の再現の方が良く出来たと捉えられる。改善点ヒートマップの再現度が低くなってしまった原因に関して、本実験では、ポスターの内容 (文字) は評価の対象とせず、デザインのみを評価するように指示して実験したが、例えば「考察の項目がポスターの右上にあるのは改善すべきだ」として右上の箇所を注視した場合があった。本研究の手法では画像を入力しているため、ポスターの文字の内容まで考慮して学習は困難である。このような内容が考慮されて視線が計測された例は改善点を注視する場合に多く見られ、改善点ヒートマップの再現度が良点と比べて低くなってしまった一因であると考えられる。

また、被験者から背景の色やレイアウトのバランスの改善点を指摘する際にどこを注視してよいかわからなかったという声があり、こちらも改善点再現の精度を低めた要因であると予測できる。音声データ等をもとに、注視して

いる箇所が全体的な評価であるのか部分的な評価であるのかをラベル付けて別々に学習する等すれば、より精度が向上する可能性が考えられる。

## 5. おわりに

本研究では、ポスターデザインを対象として、機械学習による熟練者の着目点の再現を試みた。日常的にポスター発表を評価している大学教員を被験者として、視線計測器からポスターの良点・改善点ヒートマップを作成し、良点・改善点それぞれで学習することで、別のポスター画像の入力に対する良点・改善点ヒートマップを出力させた。本研究により、機械学習によって指導者着目点を再現することで、新規ポスター画像に対して良い箇所と改善すべき箇所を抽出できるポスターデザインの技能習得支援システム作成の見通しを得た。本研究の応用により、ほかの様々な分野における指導についても、指導者着目点の再現により技能習得支援ができることが期待される。

## 参考文献

- [1] 野本聡史, 竹島亮, 長尾確. 機械学習に基づくポスターの自動評価とそれを用いたポスター制作支援システム. 情報処理学会全国大会講演論文集. Vol.17, No.1, pp.479-480, 2017.
- [2] Yuting Qiang, Yanwei Fu, Yanwen Guo, Zhi-Hua Zhou, and Leonid Sigal. Learning to generate posters of scientific papers. Thirtieth AAAI Conference on Artificial Intelligence, Vol.30, No.1, pp.51-57. 2016.
- [3] 大山真司, 山崎俊彦, 相澤清晴. プレゼンテーションスライドの客観評価と印象予測. 情報科学技術フォーラム. Vol.16, No.3, pp.45-52. 2017.
- [4] J. Pan, E. Sayrol, X. G.-i. Nieto, C. C. Ferrer, J. Torres, K. McGuinness, and N. E. OConnor. Salgan: Visual saliency prediction with adversarial networks. CVPR Scene Understanding Workshop (SUNw). 2017.
- [5] Jonathan Peirce. PsychoPy v3.0. 入手先 <<https://psycho.org/index.html>> (参照 2021-12-22).
- [6] Kümmerer, M., Wallis, T.S., Gatys, L.A., Bethge, M. Understanding low-and high-level contributions to fixation prediction. IEEE International Conference on Computer Vision. pp.4799-4808. 2017.
- [7] Liu, N., Han, J. A deep spatial contextual long-term recurrent convolutional network for saliency detection. IEEE Transactions on Image Processing 27, pp.3264-3274. 2018.
- [8] 金藤 光平, 石原 真紀夫. プログラミングの熟練者と初心者のコード読解時における視線情報に関する一考察. 電気・情報関係学会九州支部連合大会. 10-2A-04. 2019.
- [9] Pablo F, Alcantarilla, Jesús Nuevo, Adrien Bartoli, Fast Explicit Diffusion for Accelerated Features in Nonlinear Scale Spaces, BMVC, pp.13.1-13.11. 2013.
- [10] Z. Bylinskii, T. Judd, A. Oliva, A. Torralba and F. Durand. What Do Different Evaluation Metrics Tell Us About Saliency Models?. IEEE Transactions on Pattern Analysis and Machine Intelligence. vol. 41, no. 3, pp. 740-757. 2019.
- [11] N. Riche, M. Duvinage, M. Mancas, B. Gosselin and T. Dutoit. Saliency and Human Fixations: State-of-the-Art and Study of Comparison Metrics. IEEE International Conference on Computer Vision. pp. 1153-1160. 2013.
- [12] 竹浪祐介, 廣澤覚, 岩崎健太. 伝統工芸品鑑賞のコツの科学 ~感性工学を活用した製品評価手法の研究~ 京都市産業技術研究所研究報告, No.6 p.66-70. 2016.
- [13] Vig, E., Dorr, M., Cox, D. Large-scale optimization of hierarchical features for saliency prediction in natural images, IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2014.
- [14] Lowe, D.G. Distinctive Image Features from Scale-Invariant Keypoints. International Journal of Computer Vision 60, pp.91-110. 2004
- [15] OpenCV:Feature Matching. 入手先 <[https://docs.opencv.org/4.x/dc/dc3/tutorial\\_py\\_matcher.html](https://docs.opencv.org/4.x/dc/dc3/tutorial_py_matcher.html)> (参照 2022-02-10).
- [16] 吉田辰夫. 図形知覚における中心視と周辺視の役割. 人間工学, Vol.18, No.3, pp.155 - 164. 1982
- [17] L. Itti, C.Koch, and E.Niebur. A model of saliency-based visual attention for rapid scene analysis. IEEE Trans.on PAMI, Vol. 20, No. 11, pp. 1254 - 1259. 1998.
- [18] James Bergstra, R. Bardenet, Yoshua Bengio, Balázs Kégl. 25th Annual Conference on Neural Information Processing Systems. 2011.
- [19] L Li, K Jamieson, G DeSalvo, A Rostamizadeh, A Talwalkar. Hyperband: A novel bandit-based approach to hyperparameter optimization. The Journal of Machine Learning Research 18 (1), 6765-6816. 2017