

敵対的生成ネットワークを利用したバナー広告の自動生成手法

石山 航平[†] 牛尼 剛聡[‡]

[†]九州大学芸術工学部 〒815-8540 福岡県福岡市南区塩原 4-9-1

[‡]九州大学芸術工学研究院 〒815-8540 福岡県福岡市南区塩原 4-9-1

[†] E-mail:ishiyama.kouhei.842@s.kyushu-u.ac.jp, [‡] ushiama@design.kyushu-u.ac.jp

あらまし 代表的なインターネット広告の一つにバナー広告があり、バナー広告を自動生成できれば、安価にユーザに適した広告を提供できるようになる。本研究では、バナー広告画像を自動生成する手法を提案する。提案手法では、代表的な画像生成手法の一つである敵対的生成ネットワーク (GAN) を利用する。一般的に、GAN を利用した画像生成では、学習済みの生成器に対してノイズを入力とした出力として画像を生成する。しかし、バナー広告のように複雑な条件や要求が存在する対象に関して同様なアプローチで画像を生成することは困難である。この問題を解決するために、本研究では、大量のバナー広告画像を用いて複数のデザイン的な観点から GAN を学習させることで得られる学習済みの識別器を利用して、与えられた商品画像や広告文等の入力素材を利用して自動的にデザインされた画像を評価することにより、バナー広告を自動生成する手法を提案する。さらに、被験者による主観評価による評価実験によって提案手法の有効性を示す。

キーワード 敵対的生成ネットワーク (GAN)、バナー広告、生成モデル、画像生成、深層学習

1. はじめに

近年、様々な SNS や Web アプリケーションの普及に伴い、インターネット上で広告が利用される機会が増加している。例えば、インターネット広告費は 2019 年の時点で 6 年連続増加しており、媒体別に見ても総広告費の 30.3% を占める 2 兆 1048 億円を記録しており、飛躍的に市場規模が増大していることがわかる[1]。

インターネットにおける広告の固有の特徴として、SNS や Web アプリケーションのアクセス履歴や検索履歴といった情報を利用でき、個人の嗜好を反映した広告配信が可能である。一般的に、インターネット広告では、ユーザの特性や嗜好を反映した商品が選ばれ、その商品に関する広告が提示される。ユーザの特徴や嗜好を反映した商品が選ばれるだけでなく、広告媒体そのものもユーザの特性や嗜好を考慮して個別化できれば、より効果的な広告活動の実現が期待できる。

また、一般的に、代表的なインターネット広告の一つであるバナー広告の制作は、専門性を有するグラフィックデザイナーによって 1 つ 1 つ人手によって製作されることが多く、製作に時間がかかり、製作コストが高いことが課題となっている。これらバナー広告の制作にかかるコストの課題の解決や個人にマッチした広告配信を実現するために、大量のバナー広告を効率的にデザインする自動生成技術が期待されている。

近年、広告に限らず、コンテンツの自動生成に関する手法の開発に関する研究が活発に行われている。コンテンツの自動生成に利用される代表的な手法の一つとして、敵対的生成ネットワーク (Generative



図1 提案システムの概要

Adversarial Network: GAN)[2]がある。GAN は生成器と識別器と呼ばれる 2 種類のニューラルネットワークから構成される。生成器はノイズからコンテンツを生成するニューラルネットワークであり、識別器は入力データが教師データであるか、生成器で生成されたデータであるかを見分けるニューラルネットワークであり、その両者が敵対的に学習を行うことによって生成器が教師データに近いデータを生成できるようになる。

一般的な GAN を利用した画像生成では、学習済みの生成器に対してノイズを入力とした出力として画像を生成する。しかし、バナー広告のように複雑な条件や要求が存在する対象に関して同様なアプローチで画像を生成することは困難である。そこで、本論文では GAN の機構を応用し複雑な条件や要求があるバナー広告を自動生成するシステムを提案する。

本論文で提案するシステムの概要を図 1 に示す。本システムは、商品画像やイメージ画像といった素材画像と広告文を入力として、それらの素材の特徴に応じて、広告文の配置や大きさや色等を自動的にデザインし、バナー広告として適切な広告画像を生成する。

本システムでは、GAN を利用した学習によって得られた機械学習モデルを利用するが、汎用性を高めるために、教師データとして与えるバナー画像データは、そこに含まれる各素材要素について配置や色などのデザインパラメータに関する情報が得られることを前提とせず、結果として与えられる画像データのみを用いる。これにより、既存の大量の広告画像データをそのまま教師データとして利用できるため、様々な分野の様々な目的のグラフィック生成に拡張可能となる利点がある。

一般的に、グラフィックデザインに関しては、それを構成する複数の要素が複雑に関係し合っただesignの全体的な良し悪しが決定される。そのため各要素の大きさや配置情報を用いず、実際のパナー広告の画像データのみを用いて、統計的にグラフィックデザインを生成するのは困難である。そこで、本研究ではGAN で学習した識別器を用いて、「バナー広告らしさ」という観点から、生成された画像の評価を行うことで、与えられた素材や条件に基づいて適切なバナー画像を生成する。

2. 関連研究

これまで、グラフィックデザインを対象として、レイアウトの自動生成や背景画像に対するテキストの配置決定に関する研究が活発に行われてきた。本章では、それらの研究について述べる。

2.1 レイアウトの自動生成に関する研究

Sreekanth [3]らは遺伝的アルゴリズムを用いて、バナー広告のレイアウトを生成する手法を提案している。この手法では、各要素が重複していないか、距離が近すぎないかといった様々な評価値を与え、それらが遺伝的アルゴリズムによって最適化されることによって、バナー広告のレイアウトの自動生成を行う。また、Jianan[4]らは GAN を利用して、様々なグラフィックデザインのレイアウトの生成を行う手法を提案している。この手法では、各要素の配置に関するパラメータを生成する生成器と配置に関するパラメータ群からピクセルレベルの画像を生成するワイヤーフレームレンダリング機構を取り入れ、その画像を CNN[5]によって本物か偽物かを判別する識別器の機構を導入している。Xinru[6]らは入力に応じた最適な雑誌のレイアウトの自動生成手法を提案している。この手法では、入力素材の特徴を VGG16[7]や Word2vec[8]によってエンコードし、それらを生成器と識別器に組み込み、生成器のノイズを入力に応じた条件付き分布からサンプリングする。

上記の手法は全て、教師データとするグラフィック

を構成する画像やテキストの要素に関して、それぞれの位置、サイズ等のレイアウト情報が取得できることを前提としている。しかし、インターネット上に存在する広告画像に関しては、構成要素のレイアウト情報をデータとして利用できない場合が多い。もし、レイアウト情報がわからない結果としてのグラフィックイメージを教師データとして広告を生成することができれば、より汎用性が高い広告生成手法となる。本論文では、各要素のレイアウト情報が不明な完成画像を教師とした手法を提案する。

2.2 テキストの配置決定に関する研究

Yang[9]らは、テキスト要素が背景画像の被写体部分に重複しないという条件の下で、テキストを適切な位置に配置するために画像中の注意をひきやすい視覚的特性を持った領域を表す顕著性マップ[10]を用いて、最適化を行う手法を提案している。また大峠[11]らは背景画像にニューラルネットワークの物体検出手法におけるネットワークの出力である物体マップを利用した手法を提案している。しかし、これらの手法は入力画像のみの特徴を用いており、「バナー広告らしさ」という観点から生成した画像を評価できない。

3. 提案システム

3.1 全体像

本論文で提案するバナー画像生成システムの全体像を下記の図 2 に示す。本システムでは、ユーザがバナー広告の構成要素を明示的に入力として与える。ここでの構成要素とは、具体的には、素材画像、ロゴ画像、広告文の内容文、ボタン画像の内容文である。入力に対してデザイン機構によって、構成要素のパラメータを設定してバナー広告画像を生成する。生成されたバナー画像は、複数の評価器に入力される。それぞれの評価機は異なる観点から入力されたバナー画像の妥当性を評価し、結果を出力する。それぞれの評価器が出力した値を総合的に判断し、評価値が高いものを広告としてふさわしいバナー画像候補としてユーザに提示する。

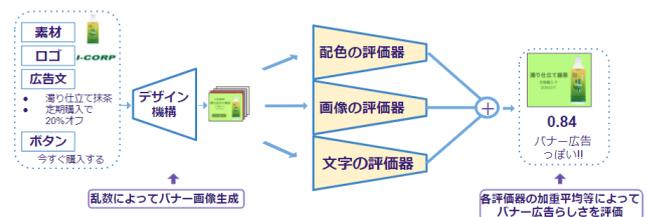


図 2 提案システムの概要

3.2 デザイン機構

ユーザが入力したバナー広告の構成要素はそれぞれ、バナー画像上での位置、サイズ、背景色、前景色等がパラメータ化されているものとする。このとき、バナー広告をデザインするという処理は、それぞれの構成要素に対して適切なパラメータを設定することになる。本研究では、乱数によってそれぞれの要素のパラメータを決定して広告画像を生成する。詳細には表1に示すように、入力として与えられる素材画像とロゴ画像の位置と大きさ、ボタンの位置、広告文のフォントサイズと位置と色を乱数によって決定し、また、背景の色も乱数によって決定する。

表1 デザイン機構によって乱数によって決定されるパラメータ群

乱数によって決定されるパラメータ	
背景	色 (R, G, B)
広告文	文字色 (R, G, B) フォントサイズ 座標 (x, y)
素材画像	拡大倍率 座標 (x, y)
ロゴ	拡大倍率 座標 (x, y)
ボタン	色 (R, G, B) 座標 (x, y)

3.3 評価器

本手法では、評価器の評価基準は「バナー広告らしさ」とする。与えられた画像の「バナー広告らしさ」を算出するためにGANの機構を利用して学習済みの識別器を用いる。つまり、大量のバナー広告を学習データとして、GANによって学習が行われた識別器の出力は、入力データが本物のバナー広告である確率である。そのため、識別器と生成器の学習を繰り返すことによって、学習済みの識別器は入力画像に対して、潜在的な「バナー広告らしさ」を評価可能となる(図3)。

本手法では、この学習済みの識別器を生成された画像がバナー画像として適切かどうかを判定する評価器として利用する。GANの機構を用いることによって、生成されたバナー広告画像のみから、「バナー広告らしさ」を評価する機械学習モデルを学習させることが可能になる。

また、本手法では、GANによって評価器を構築するが、バナー広告画像をそのままピクセルレベルで画像生成を行うような一般的なGANでは、評価器は各要素の位置や大きさなどといったレイアウト情報を把握できない。そのため、学習データに前処理を加えることによって、「配色」、「素材レイアウト」、「文字レイアウト」という3つのデザインの観点から評価を行う評価器を構築する。最終的にそれぞれの評価器の出力に対して加重平均等により統合し最終的な評価値を計算する。

ト」という3つのデザインの観点から評価を行う評価器を構築する。最終的にそれぞれの評価器の出力に対して加重平均等により統合し最終的な評価値を計算する。



図3 GANの学習と識別器

4. 評価器の構成

本章では「配色」、「素材レイアウト」、「文字レイアウト」という3つのデザインの観点から評価を行う評価器の構成手法を述べる。

4.1 配色評価器

配色評価器は、入力として与えられる画像に対して、全体の配色に関してバナー広告らしさという点で評価を行う。この評価器を作成するためにGANの学習を行う。ここでは、既存のバナー画像を16×16画素の低解像度にダウンサンプリングした画像を学習データとする。ダウンサンプリングには求めたい画素値を元画像の周辺4×4画素の輝度値を用いて計算を行うバイキュービック補間を用いる。ダウンサンプリングするのはフォントの種類やエッジ情報といった、配色に関する情報以外の複雑な情報を落とすためである。生成器は同じく低解像度のバナー広告画像を生成するよう学習させることによって、そこで得られる識別器は全体の配色に関して広告らしさという点でできるようになる。この識別器を配色の評価器として用いる。ここで利用するGANの概念図を図4に示す。

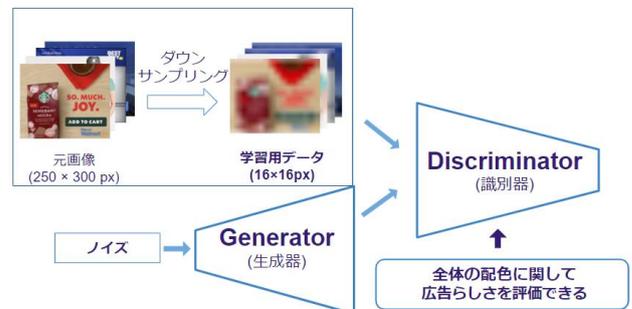


図4 配色を学習するGAN

4.2 素材レイアウト評価器

素材レイアウト評価器は、入力として与えられる素材画像の大きさと配置に関してバナー広告らしさという点で評価を行う。この評価器を学習させるため、入力として与えられる画像を前述した Yang らの手法のように顕著性マップ(saliency map)に変換する。顕著性マップとは与えられた画像に対して、人間がその画像を見た際に注視が集まりやすい場所で表した画像であり、顕著性マップの各画素は視線の集中する確率が輝度値で表される。バナー画像の顕著性マップへの変換の例を図5に示す。



図5 顕著性マップへの変換

一般的に、バナー広告は広告の対象となる商品やイメージを表す素材画像やその商品の特徴を表す広告文に注意が向くように作成される。そのため、素材画像と重複する領域において、顕著性マップの画素値は高くなると考えられる。この性質を利用し、実際のバナー画像を変換した顕著性マップを学習データとして利用する。素材レイアウト評価器の学習のための顕著性マップへの変換の計算には OpenCV の Spectral Residual[12] モデルを利用する。このモデルは入力画像の周波数の対数スペクトルと複数画像の周波数の対数スペクトルの平均との差分を利用して、顕著性マップを作成する。

バナー広告画像の顕著性マップを生成するように GAN を学習することで、得られる識別器は各素材のレイアウトに関して広告らしさという点で評価できるようになる。実際の GAN の機構を以下の図6に示す。

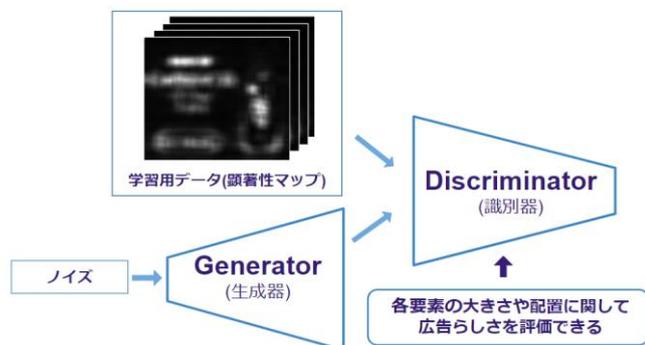


図6 各要素の大きさと配置を学習する GAN

4.3 文字レイアウト評価器

文字レイアウト評価器は、入力として与えられる画像の広告文やボタン画像の内容文といった文字の大き

さと配置に関してバナー広告らしさという点で評価を行う。評価器作成のため、入力として与えられる画像から文字領域を表すマスク画像に変換する。マスク画像への変換の概要を以下の図7に示す。



図7 マスク画像への変換

本研究では、文字領域の矩形検出のために Google Cloud Vision API の fullTextAnnotation の Paragraph のモデルを利用する。文字領域として認識された部分を 1、それ以外の領域を 0 とすることで 2 階調のマスク画像を生成する。作成された実際のバナー広告画像の文字領域を表すマスク画像を学習データとして、生成器がバナー広告画像の文字領域であるマスク画像を生成するように GAN を学習させる。そこで得られる識別器は文字レイアウトに関して広告らしさという点で評価できるようになる。ここで利用する GAN の機構を図8に示す。

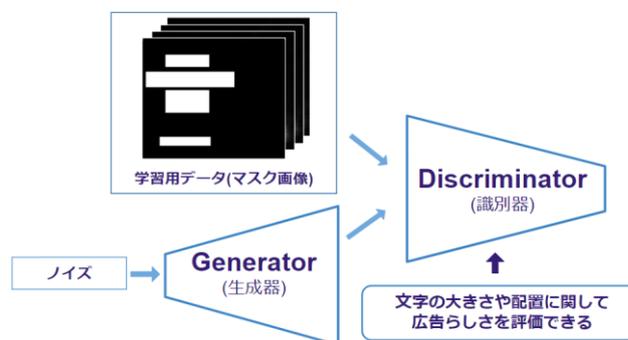


図8 文字領域の大きさと配置を評価する GAN

5. 評価器のための機械学習モデル

本手法ではバナー画像を対象とした GAN によって学習した識別器を評価器として利用する。画像を対象とする GAN は様々な手法が提案されている。本研究では、すべての評価器の学習において、GAN のモデルとして DCGAN[13]を利用する。DCGAN とは識別器にネットワークを全結合層のみではなく、畳み込み処理を加え、生成器のネットワークには畳み込みの逆の処理である、転置畳み込みを加えた GAN のモデルである。教師データの画像について、配色の評価器の学習

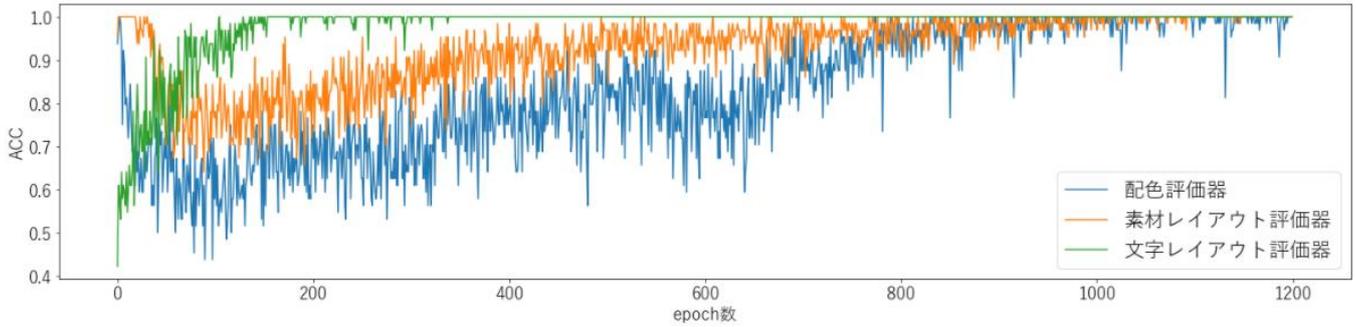


図9 各評価器の出力値の上位, 下位4つの画像に対する主観評価の結果

では 16×16 画素の 3 チャンネルのカラー画像のデータ用い, 素材レイアウトの評価器と文字レイアウトの評価器では 64×64 画素の 1 チャンネルのモノクロ画像のデータを用いた. 配色の評価器の学習のための DCGAN の生成器と識別器のネットワークの詳細については以下の図 10, 11 に示す.

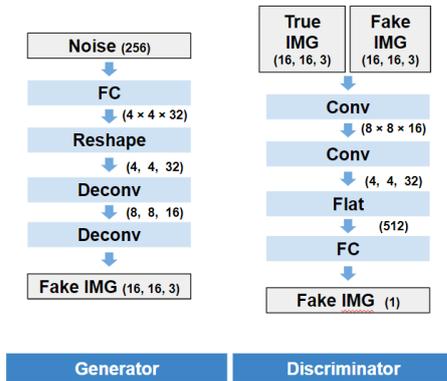


図 10 配色評価器の学習のための DCGAN の生成器と識別器

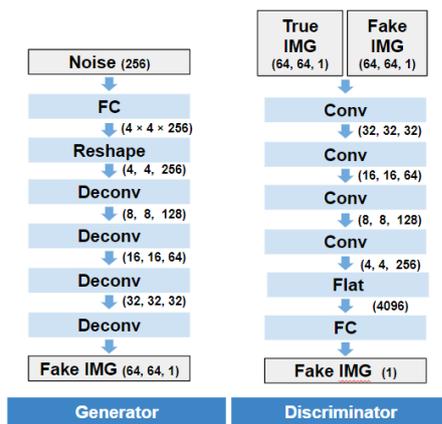


図 11 素材レイアウトの評価器と文字レイアウトの評価器の学習のための DCGAN の生成器と識別器

また, すべてのモデルにおいて, 識別器損失関数 L は式(1)に示す 2 値クロスエントロピー誤差を用いる. ここで, y は識別機での出力を表し, t は教師画像の場合

は 1 であり, 生成機で生成された画像の場合は 0 となる.

$$L = -t \log y - (1-t) \log(1-y) \quad (1)$$

学習の際の最適化関数は Adam[14]を用い, バッチサイズは 32 とする.

6. 評価実験

6.1 バナー生成手法

提案手法の有効性を評価するために評価実験を行った. 学習用のデータセットは Web 上に存在する解像度 300×250 画素のバナー画像 3,000 枚である. バナー画像の収集には Moat を利用した. また使用したマシンのスペックは以下の通りである.

OS : Ubuntu18.04LTS 64bit
 CPU : Intel(R) Xeon(R) Silver 4110
 GPU : NVIDIA Geforce RTX 2080 Ti
 Memory : 94GB

また, 実装には python のフレームワークである Keras を用いた.

6.2 バナー生成結果

5.1 で述べた DCGAN を学習データのバッチサイズでそれぞれの学習を行った. それぞれの学習段階での識別器における出力に対する精度 (Accuracy) の推移は以下の図 19 に示す. 図の横軸が学習の試行回数 (エポック数) を表し, 縦軸が精度を表す. また, 学習過程において, 生成器で出力された画像の例を図 12, 図 13, 図 14 に示す.



図 12 配色の評価器の学習のための DCGAN の 700 エポックにおける生成器の出力画像例

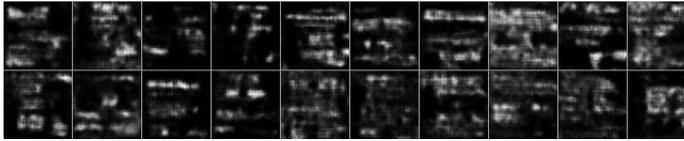


図 13 素材レイアウトの学習のための DCGAN の 300 エポックにおける生成器の出力画像例

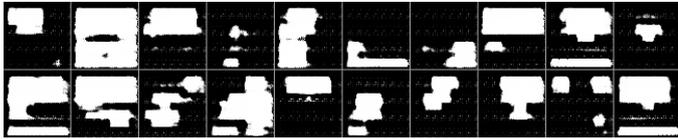


図 14 文字レイアウトの学習のための DCGAN の 300 エポックにおける生成器の出力画像例

さらに、提案手法におけるデザイン機構に以下の表 2 に示す素材を入力として、素材画像の位置と大きさ、ロゴ画像の位置と大きさ、広告文のフォントサイズと位置と色、ボタンの位置と大きささと色、と背景を乱数によって決定してバナー画像を 10,000 枚生成した。

表 2 デザイン機構に入力した素材群

素材画像	
ロゴ画像	I-CORP
広告文	濁り仕立て緑茶
ボタン内容文	ボタン内容文

上記で得られた識別器をバナー広告画像の評価器として、それを 16×16 画素にリサイズしたものを配色の評価器の入力、前述の顕著性マップに変換したものを素材レイアウトの評価器の入力、文字領域を表すマスク画像に変換したものを文字レイアウトの評価器の入力として、評価を行った。それぞれの評価器において評価値が高かった画像上位 5 件、及び評価値が低かった画像の下部 5 件を図 15 から図 22 に示す。



図 15 配色評価器における評価上位 5 件



図 16 配色評価器における評価下部 5 件

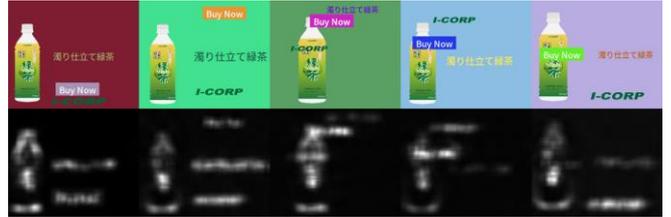


図 17 素材レイアウト評価器における評価上位 5 件



図 18 素材レイアウト評価器における評価下部 5 件



図 19 文字レイアウト評価器における評価上位 5 件



図 20 文字レイアウト評価器における評価下部 5 件

また以下の図 21、図 22 はそれぞれの評価器の出力の合計値が高かったものと低かったものを左から上位 5 つを示す。



図 21 総合的な評価による評価値上位 5 件



図 22 総合的な評価による評価値下部 5 件

6.3 被験者実験

提案手法で生成したバナー画像に対する印象を評価するために、被験者を利用した主観評価実験を行った。対象とするバナー画像は、提案手法におけるデザイン機構を利用して生成した 10,000 枚のバナー画像のうち、3 種類の評価器の出力値およびそれらを合計した

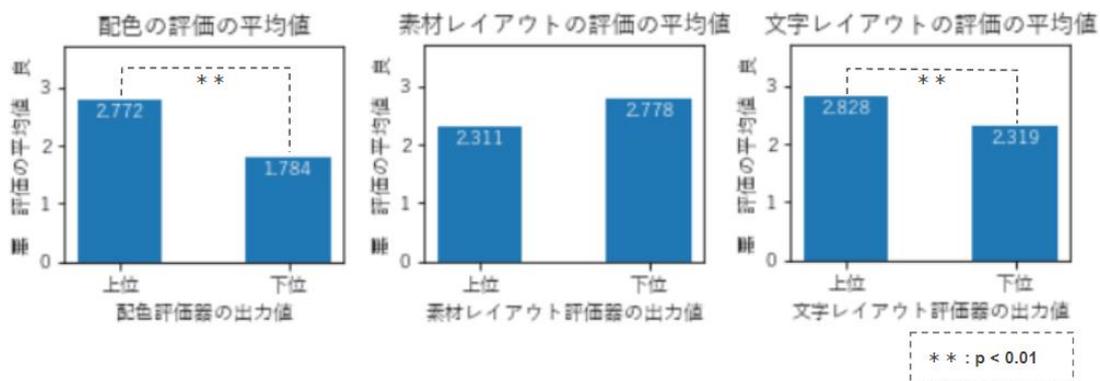


図 23 各評価器の出力値の上位、下位 4 つの画像に対する主観評価の結果

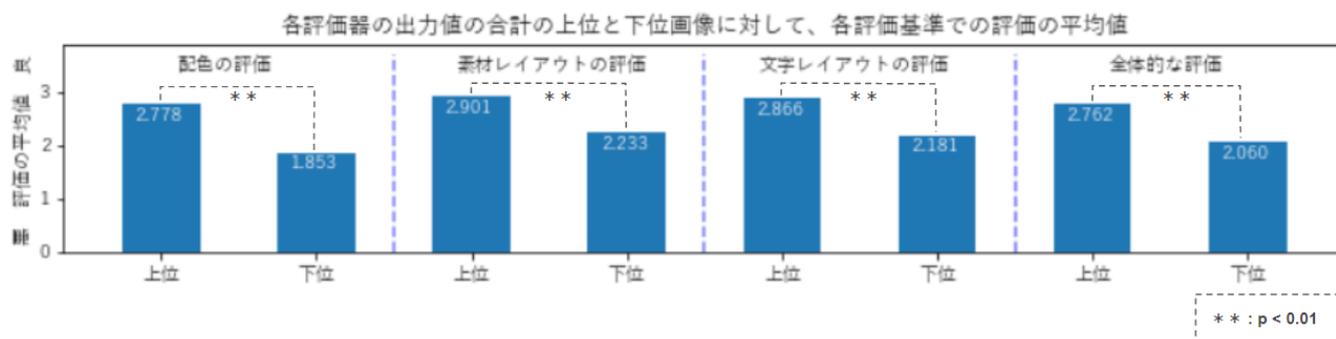


図 24 各評価器の出力値の合計の上位、下位 4 つの画像に対する各評価基準での主観評価の結果

総合評価値の上位と下位それぞれ 4 件ずつ選択した合計 32 件である。

上記のバナー画像を対象に、被験者に対してアンケートによる主観評価を行った。具体的には、ランダムに並べ替えられたバナー画像に対して、以下の質問にそれぞれ 5 段階評価で回答をしてもらった。ここでは、数字が大きいほど良いものとした。被験者の人数は 29 名である。

- (1) 全体の配色は適切だと思いますか？
- (2) 広告を構成する要素（商品名テキスト、商品画像、ボタン、ボタンテキスト）のレイアウトは適切だと思いますか？
- (3) テキスト要素のレイアウト（素材画像は無視）は適切だと思いますか？
- (4) 全体的にバナー広告のデザインとして適切だと思いますか？

6.4 被験者実験の結果

被験者実験によるそれぞれの評価器ごとの結果を図 23 に示す。図 23 には 3 種類の結果が含まれており、左から以下の内容を表している。

1. 配色評価器での出力値の上位、または下位のそれぞれ 4 件の画像に対して「全体の配色は適切だと思いますか？」という質問に対する返答の集計結果の平均をとったもの

2. 素材レイアウト評価器での出力値の上位、または下位のそれぞれ 4 件の画像に対して「全体の配色は適切だと思いますか？」という質問に対する返答の集計結果の平均をとったもの
3. 文字レイアウト評価器での出力値の上位、または下位のそれぞれ 4 件の画像に対して「全体の配色は適切だと思いますか？」という質問に対する返答の集計結果の平均をとったもの

配色評価器および文字レイアウト評価器に関しては、評価器の出力と被験者による主観評価には相関がみられた。これらについて、t 検定によって評価器の出力が高い画像群と低い画像群に対する主観評価の平均値の差について検証した。両者において p 値は $p < 0.001$ となり、優位水準 0.01 を下回り、有意差が示された。

しかし、素材レイアウト評価器においては、評価器の出力と被験者による主観評価では逆の相関がみられ、期待した結果は得られなかった。

次に、各評価器の出力値を合計した総合的な評価値の上位 4 件、下位 4 件の画像に対して、「配色」、「素材レイアウト」、「文字レイアウト」、「全体的な評価」という評価基準に対する主観評価の平均値を図 24 に示す。すべての評価基準において、総合評価上位の画像を被験者は高く評価しており、総合評価値の上位の画像群と下位の画像群に対して、各評価基準における集計結果の平均値の差について t 検定で有意差を調べた

結果, すべての評価基準において p 値は $p < 0.001$ となり, 優位水準 0.01 を下回り, 有意差が示された.

7. まとめと今後の予定

本研究では, バナー広告を自動生成する手法を開発し, 評価実験によって評価を行った. 本手法は, 「バナー広告らしさ」という観点からデザインの評価を行う仕組みを提案し, 「色」, 「素材レイアウト」, 「文字レイアウト」という3点を評価する個別の評価器を GAN で学習した識別器を用いて実現する. 提案手法に関する評価実験を行い, 「配色」と「文字レイアウト」に関しては一定の効果が見られたが, 「素材レイアウト」に関してはあまり有効性を見出すことができなかった. また, それらの合計値をとることによって, 「配色」, 「素材レイアウト」, 「文字レイアウト」すべてにおいて, また, 「画像全体的」にもバナー広告のデザインとして適切なものを抽出することができた.

今後の予定については, 「素材レイアウト」の評価器作成には実際のバナー広告の顕著性マップを教師データとして学習を行っているが, 「文字レイアウト」の評価器の学習時に用いたテキストの位置を示すマスク画像も利用することによって評価器がテキストと素材画像がバランスのとれたレイアウトをしているのか判断できるのではないかと考え, 実証実験を行いたいと考えている. また, バナーを生成するデザイン機構では乱数によって生成を行っているため, 学習済みの評価器を利用して, あらかじめ生成のパラメータの分布を絞ることができるのではないかと検討している.

謝辞

本研究は JSPS 科研費 19H04219 の助成を受けたものです.

文献

- [1] 電通, “2019 年 日本の広告費 | 媒体別広告費”, ナレッジ & データ, https://www.dentsu.co.jp/knowledge/ad_cost/2019/media.html, (参照 2020-12-19)
- [2] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. WardeFarley, S. Ozair, A. Courville, and Y. Bengio, “Generative adversarial nets,” in Neural Information Processing Systems, pp. 2672–2680, 2014.
- [3] Sreekanth Vempati, Korah T Malayil, Sruthi V, Sandeep R, “Enabling Hyper-Personalisation: Automated Ad Creative Generation and Ranking for Fashion e-Commerce”, Workshop on Recommender Systems in Fashion, arXiv preprint arXiv:1511.06434, 2019
- [4] Jianan Li, Jimei Yang, Aaron Hertzmann, Jianming Zhang, Tingfa Xu, “LayoutGAN: Generating Graphic Layouts with Wireframe Discriminators”, ICLR 2019
- [5] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition”, Proc. of the IEEE, 86(11), pp.2278-2324, 1998
- [6] Xinru Zheng, Xiaotian Qiao, Ying Cao, Rynson W.H. Lau “Content-aware Generative Modeling of Graphic Design Layouts”, SIGGRAPH2019, 2019
- [7] Karen Simonyan and Andrew Zisserman, “Very deep convolutional networks for large-scale image recognition”, ICLR, 2015
- [8] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S corrado, and Jeff Dean, “Distributed Representations of Words and Phrases and their Compositionality. in proc”, Neural Information Processing System 2013, 3111-3119
- [9] XUYONG YANG, TAO MEI, YING-QING XU, YONG RUI, SHIPENG LI, “Automatic Generation of Visual-Textual Presentation Layout”, ACM Transactions on Multimedia Computing, Communications, and Applications, 2016
- [10] Itti, Laurent, Christof Koch, and Ernst Niebur. ”A model of saliency-based visual attention for rapid scene analysis . ”IEEE Transactions on pattern analysis and machine intelligence 20. 11, pp. 1254-1259, 1998
- [11] 大峠 和基, 大谷 まゆ, “バナー制作のための背景を考慮した自動テキスト配置”, 人工知能学会 第34回全国大会(2020)
- [12] Hou, Xiaodi, and Liqing Zhang. "Saliency detection: A spectral residual approach." 2007 IEEE Conference on computer vision and pattern recognition. Ieee, 2007
- [13] A. Radford, L. Metz, and S. Chintala. Unsupervised representation learning with deep convolutional generative adversarial networks. arXiv preprint arXiv:1511. 06434, 2015. 2, 3
- [14] Kingma, Diederik P and Ba, Jimmy Lei. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412. 6980, 2014.