

深層学習したテクスチャ潜在空間の探索のための 類似度に基づく探索方向の選択

佐藤 信¹

概要：本稿では、深層生成モデルにより学習したテクスチャの潜在空間の探索のために、探索方向の選択手法を提案する。提案手法では、始めに、対話的に選択されたテクスチャに類似なテクスチャを学習モデルから生成する。そして、それらの中から目的のテクスチャを選択することにより探索方向を決定する。類似度が近いという条件のもとで多様なテクスチャを選択の候補とするために、潜在空間において乱数により n -sphere 上に点を生成し、それらの点から生成されるテクスチャのクラスタリングをおこなう。提案手法は、学習モデルの対話的な分析に用いることが可能である。また、既提案の補間テクスチャ列の生成手法において微調節をおこなう場合に提案手法は有効である。微調節により洗練化した繊細なテクスチャは、落ち着いた雰囲気のを表現するコンテンツを制作するための素材として適しているといえる。

Searching Direction Selection Based on Similarity for Searching Deep Learned Texture Latent Spaces

MAKOTO SATOH¹

Abstract: This paper presents a searching direction selection method for searching the latent space learned with a deep generative model. In the method, first, the textures similar to an interactively selected one are generated from the learned model. Then, the searching direction is decided by selecting an intended texture. To be available for diverse candidate textures on the condition that they are similar to each other, latent space points are generated randomly on the surface of an n -sphere, then the textures generated from the points are clustered. The method can be used for interactively analyzing learned models. Additionally, it can be used effectively for adjustment in the proposed method for generating interpolating textures. The nuanced textures refined with adjustments are suitable for creating artistic contents representing relaxing japanese traditional ambiente.

1. はじめに

本稿では、深層生成モデルを用いて学習した潜在空間の探索において探索方向を選択するための手法を提案する。特徴は、次のとおりである。

- 直感的な理解が容易な手法により、高次元の潜在空間上での探索方向の選択の対象領域を指定可能である。
- 対象領域から生成されるテクスチャの代表例を示し、その中から選択されたテクスチャに基づき探索方向を決定する。

提案手法は、学習モデルの対話的な分析に有効である。また、潜在空間を探索することにより補間テクスチャ列を生成するための既提案手法 [7] において、提案手法を補間テクスチャ列の微調節に用いることが可能である。微調節により洗練化した繊細なテクスチャは、落ち着いた雰囲気のを表現するコンテンツを制作するための素材として適しているといえる [8], [9]。

これ以降の構成について、簡単に説明する。2 節では、関連研究との比較をおこなう。そして 3 節において、潜在空間上での探索方向の選択手法を提案する。4 節では実装を用いた実験結果を示し検討をおこなう。そして最後に、5 節で本稿のまとめと今後について述べる。

¹ 岩手大学
Iwate University, Ueda, Iwate 020-8551, Japan

2. 関連研究との比較

2.1 学習モデルの分析

深層学習 (deep learning) [3], [6] は, データの特徴を捉える性能にすぐれた学習手法である. そのことから盛んに研究がおこなわれ, 学習手法の改良などの基礎研究および多くの分野への応用研究が発表され続けている.

深層学習の学習メカニズムについては, ネットワークを構成する各素子単位については学習の原理が明確であるといえる. しかし, あるデータ集合を用いて学習をおこなった場合に, 各素子がデータのどのような特徴を学習することによりネットワーク全体として機能するのかについては, 完全には解明されていない部分が少なくないといえる.

そのような状況を改善するために, 深層モデルを用いた学習についての理解を容易にするための研究がおこなわれている [1]. それらには, 理解が容易な学習方式に関する研究, および, 学習モデルの状態を分析するための研究がある. 前者には, 深層モデルの各層が明確な機能をもつように学習モデルを改良する研究などがあり, 後者には, 学習した各層のパラメータと出力の関連を分析するための研究などがある. そして, 学習モデルの分析に基づき学習モデルを改良することも可能である [4].

本稿の提案手法は後者であり, 学習モデルの潜在空間上での探索を用いた分析などにおいて, 直感的に理解が容易な手法により探索方向の選択を容易にするためのものである.

2.2 深層生成モデルによるテクスチャの生成

深層生成モデル (deep generative model) によりデータの学習をおこなうと, 学習した潜在空間から学習データに類似なデータを高品質に生成することが可能である. そのため, 深層生成モデルは多くの研究者の注目を集め, 多くの関連モデルおよび応用例が発表され続けている. それらには, VAE (Variational Auto-Encoder) [5] を基にしたものと, GAN (Generative Adversarial Network) [2] を基にしたものなどがある.

本稿では, GAN の関連モデルである DCGAN (Deep Convolutional Generative Adversarial Network) [10] を用いて学習した, 和紙のテクスチャの学習モデルを用いる. その学習モデルの潜在空間において, 提案手法により探索方向の選択をおこなう. そして, 選択した探索方向上に存在する点を補間の一方の端点として用いることにより, 補間テクスチャ列を生成する. テクスチャ列の生成には, 潜在空間を探索することにより補間テクスチャ列を生成するための既提案手法 [7] を用いる. 潜在空間から生成されるテクスチャの視覚的な類似度に基づき潜在空間上での探索方向を選択することにより, 補間テクスチャ列の微調整による洗練化が可能であることを示す.

Algorithm 1 Searching Direction Selection

Step 1

Prepare a Washi texture model trained with DCGAN.
Set the parameters of the n-sphere in the latent space:
center $\mathbf{c}$ and radius r .
Set the parameters of a von Mises-Fisher (vMF) distribution:
mean direction $\mathbf{d} \in \mathbb{R}^n$ and concentration κ .

Step 2

Generate random vectors $\mathbf{v}_i \in \mathbb{R}^n$ from the vMF distr.
Sample points $\mathbf{p}_i$ from the surface of the n-sphere:
 $\mathbf{p}_i = r \mathbf{v}_i + \mathbf{c}$.

Step 3

Generate textures from $\mathbf{p}_i$, and cluster those textures.
Provide the representative textures $\mathcal{T}$ of each cluster.
Find interactively a suitable texture from $\mathcal{T}$ that will be generated from the next latent space searching point.

if a suitable texture $\mathbf{S}$ has been found,

 go to Step 4,

else

 set new values to $\mathbf{c}$, r , $\mathbf{d}$ and/or κ if needed,

 go to Step 2.

Step 4

Compute a searching direction vector: $r \mathbf{v}_s = \mathbf{p}_s - \mathbf{c}$.
 $\mathbf{p}_s$ is the latent point that $\mathbf{S}$ has been generated from.

3. 探索方向の選択

3.1 提案手法

アルゴリズム 1 に提案手法を示す. **Step 1** では始めに, 深層生成モデルを用いて学習した和紙テクスチャの学習モデルを準備する. そして, 和紙テクスチャの潜在空間上の n-sphere の中心 $\mathbf{c}$ と半径 r , および, von Mises-Fisher (vMF) 分布の平均方向 (mean direction, $\mathbf{d} \in \mathbb{R}^n$) と集中度 (concentration, κ) を設定する. $\mathbf{c}$ は, 潜在空間上での現在の探索位置である. **Step 2** では, vMF 分布の複数の乱数 $\mathbf{v}_i \in \mathbb{R}^n$ を生成する. そして式 1 により, n-sphere 上に複数の点 $\mathbf{p}_i$ をサンプリングする.

$$\mathbf{p}_i = r \mathbf{v}_i + \mathbf{c} \quad (1)$$

Step 3 では, 和紙テクスチャの潜在空間上の点 $\mathbf{p}_i$ からテクスチャを生成し, それらをクラスタリングする. そして, 各クラスターに含まれるテクスチャの特徴を代表するテクスチャ $\mathcal{T}$ を提示する. $\mathcal{T}$ の中に, 現在の探索位置 $\mathbf{c}$ から移動した場合の次の探索位置から生成したテクスチャとしてふさわしいテクスチャ $\mathbf{S}$ が含まれているかどうかを確認する. そのようなテクスチャが含まれている場合には, **Step 4** に進む. そうでない場合には, 必要に応じてパラメータを再設定してから, **Step 2** に戻る. **Step 4** では,




図 1 DCGAN の訓練に用いた和紙のテクスチャ画像（上半分），および，学習した潜在空間から生成したテクスチャ画像（下半分）の例

Fig. 1 Examples of Washi texture images used to train DCGAN (upper half), and texture images generated from the learned latent space (lower half).

現在の探索位置 $\mathbf{c}$ からの探索方向 $r\mathbf{v}_s$ を式 2 により計算する． $\mathbf{p}_s$ は， $\mathbf{s}$ を生成した潜在空間上の点である．

$$r\mathbf{v}_s = \mathbf{p}_s - \mathbf{c} \quad (2)$$

3.2 SSIM ベクトルによるクラスタリング

アルゴリズム 1 の **Step 3** では，和紙テクスチャの潜在空間から生成したテクスチャについて，類似度を基準として用いたクラスタリングをおこなう．

テクスチャの類似度を評価するためには，多くの基準 [11] が提案されている．[7] ではテクスチャの類似度の基準として，SSIM (Structural Similarity, [12], [13], [14]) の平均値である MSSIM (Mean Structural Similarity, [13]) を用いた．MSSIM は，輝度 (luminance)，コントラスト (contrast) および構造 (structure) に基づく画像の品質の評価基準であり，静止画像および動画画像の類似度の評価基準としても用いられる．

SSIM を用いたテクスチャの評価では，評価しようとする画像と参照画像との類似度により評価がおこなわれる．そのため，複数のテクスチャをクラスタリングする場合の基準として SSIM を用いる場合には，複数の参照テクスチャを用いることにより多角的な評価をおこなう必要がある場合がある．

本稿では，クラスタリングに用いる特徴量として，式 3 のように MSSIM 値を各成分とする SSIM ベクトル (SSIM Vector, SSIMV) を用いる．

$$\mathbf{s} = (s_1, s_2, \dots, s_n) \quad (3)$$

ここで， s_i ($1 \leq i \leq n$) は，それぞれ参照テクスチャ T_i ($1 \leq i \leq n$) とある同一のテクスチャとの類似度を示す MSSIM 値である．

4. 実験と結果の検討

4.1 和紙テクスチャの学習モデル

実験では，[7] での和紙テクスチャの学習モデルを用いた．そこでの学習に用いた和紙のテクスチャ画像の例を，図 1(上半分) に示す．なお，深層生成モデルとして DCGAN を用いた．

学習モデルの生成器を用いてテクスチャ画像を生成することにより，学習モデルの確認をおこなった．図 1(下半分) は，von Mises Fisher (vMF) 分布から取り出した乱数により選択した和紙テクスチャの潜在空間上の点から生成したテクスチャ画像である．vMF 分布の集中度は 10 である．

4.2 von Mises Fisher 分布の集中度

アルゴリズム 1 では，von Mises Fisher (vMF) 分布から取り出した乱数により和紙のテクスチャモデルの潜在空間上の点をサンプリングする．vMF 分布の集中度 (concentration) と生成される乱数の分布の関係，および，vMF 分布の集中度を変化させた場合のサンプリング点から生成されるテクスチャの例を，図 2 に示す．

図 2(a) は，3 次元空間上の vMF 分布により生成した点の分布である (青色)．オレンジ色の球形の中心が，vMF 分布の中心である．vMF 分布の集中度は左から 0, 10, 100 である．図 2(b) は，100 次元空間上の vMF 分布からのサンプリング点について，vMF 分布の平均方向 (mean direction) の周辺での分布を確認した例である．多次元空間上の点の分布を可視化する場合には次元圧縮などがおこなわれるが，その場合には次元圧縮の手法がどの程度忠実に分布を近似しているかなどの検討が必要である．ここでは，100 次元空間上でのサンプリング点の分布を正確な尺度により表現するために，vMF 分布からのサンプリング点は n-sphere の表面上に存在することを利用して，角度により点の分布を表現した．具体的には，vMF 分布の平均方向ベクトルを




図 2 von Mises Fisher(vMF) 分布からのサンプリング. (a) 3 次元空間上の vMF 分布からのサンプリング点 (blue), 左から 集中度 0, 10, 100. (b) 100 次元空間上の vMF 分布の平均方向ベクトルと vMF 分布の中心点からサンプリング点へのベクトルとのなす角 (集中度: 0, 50, 200, 1000). (c) サンプリング点から生成したテクスチャ (上半分: 集中度 100, 下半分: 集中度 1000)

Fig. 2 Sampling points(blue) drawn from a von Mises Fisher (vMF) distribution. (a) sampled points drawn from a vMF distribution on three dimensional space, from left to right concentration 0, 10, 100. (b) the angle between the mean direction vector of a vMF distribution on 100 dimensional space and the vector from the center of the vMF distribution to sampled points, (concentration: 0, 50, 200, 1000). (c) generated textures from sampled points (upper half: concentration 100, lower half: concentration 1000)

基準として用いて, vMF 分布の中心とサンプリング点とを結ぶベクトルのなす角度の分布を確認した. 図 2(b) の vMF 分布の集中度は, 0, 50, 200, 1000 である. 角度の単位はラジアンである. 図 2(c) は, 和紙テクスチャの潜在空間上で vMF 分布を用いてサンプリングした点から生成したテクスチャの例である. 集中度は上半分では 100 であり, 下半分では 1000 である. 集中度の影響を明確にする

ために, 乱数のシードを含めて, 集中度以外のパラメータには同じ値を用いた.

4.3 探索方向の選択

提案手法 (アルゴリズム 1) により和紙テクスチャの潜在空間の探索をおこなった結果を, 図 3 に示す. (a) は, 式 1 によりサンプリングした潜在空間上の点から生成し



図 3 探索方向の選択

Fig. 3 Searching direction selection using Algorithm 1: (a) randomly generated textures from a learned texture latent space, interactively selected textures are edged in orange; (b) generated textures similar to the selected one (iteration 1), (c) clustered textures contained in each cluster (iteration 1), representative textures are edged in blue, interactively selected representative texture is edged in orange; (d) generated textures similar to the selected one (iteration 2), (e) clustered textures contained in each cluster (iteration 2).

たテクスチャである．式 1 の計算では，集中度 0, 平均方向 $\mathbf{d} = (0.0, 1.0, 0.0, \dots, 0.0)$ の 100 次元の von Mises Fisher(vMF) 分布から取り出した乱数 $\mathbf{v}_i$ を用いた．また， $r = 7$ および $\mathbf{c} = (0.0, \dots, 0.0)$ とした．オレンジ色の枠で囲んだテクスチャを対話的に選択した．(b) では，(a) で選択したテクスチャに類似なテクスチャを生成した．潜在空間上の点をサンプリングするための vMF 分布の集中度を 100 に変更した．それ以外は，(a) と同様である．(c) は，生成したテクスチャのクラスタリングの結果，および，各クラスタを代表するテクスチャを選択した結果である．青色またはオレンジ色の枠で囲んだテクスチャが，代表となるテクスチャである．クラスタリングでは始めに，各テク

スチャについて SSIM ベクトル (SSIMV) を生成した．次に，SSIMV に次元圧縮をおこないクラスタリングをおこなった．そして，クラスタリングに用いた k-means 法のセントロイドとの距離を用いて各クラスタを代表するテクスチャを決定した．各クラスタの代表となるテクスチャのなかからテクスチャを対話的に選択することにより，これから移動する潜在空間上の点を選択した．オレンジ色の枠で囲んだテクスチャが対話的に選択されたテクスチャである．潜在空間上の点の座標を直接的に指定するのではなく，選択されたテクスチャを生成した潜在空間上の点を次に移動する位置とした．これから移動する点への方向ベクトルは，式 2 により計算した．

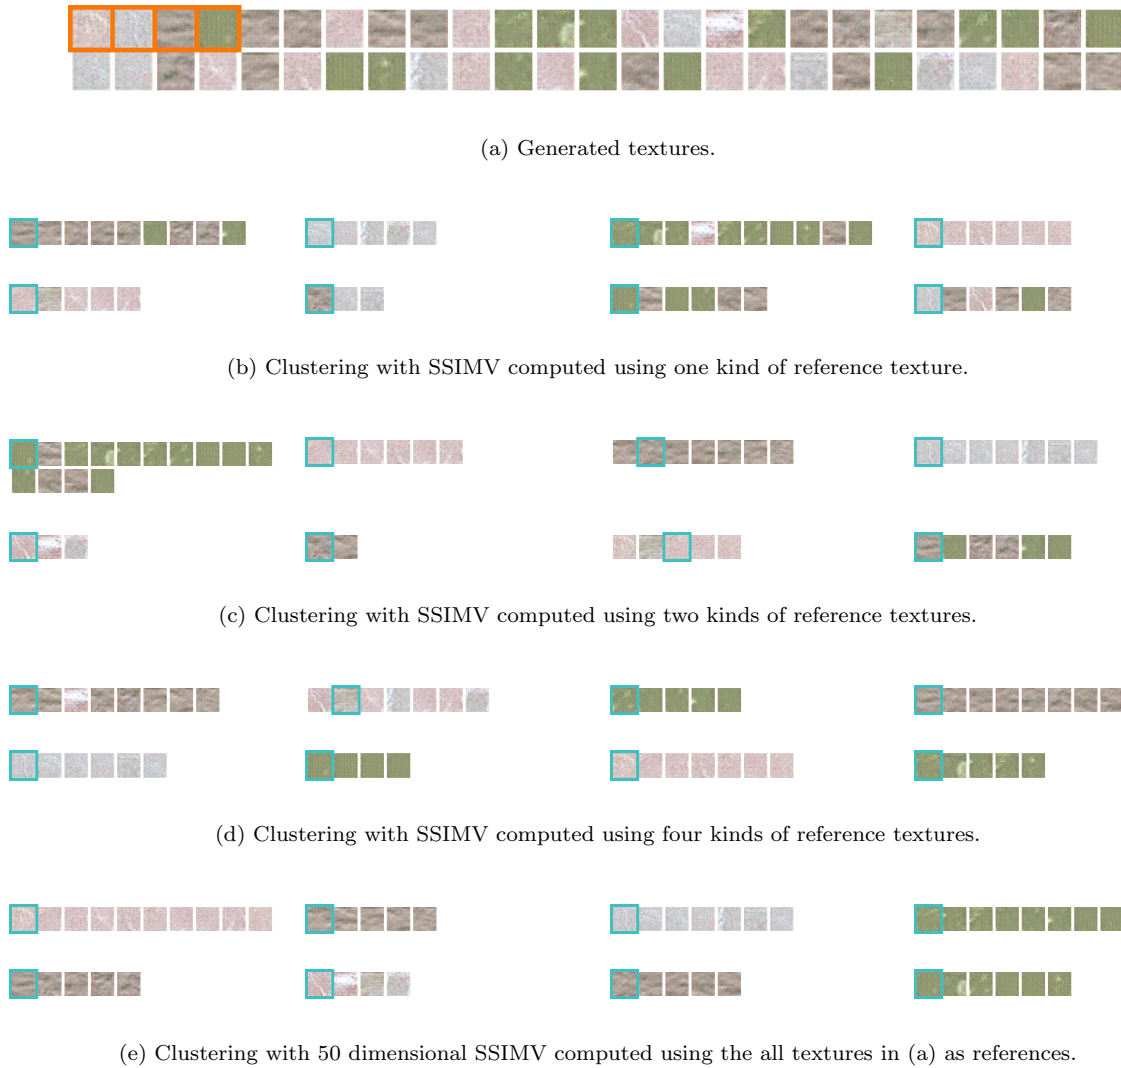


図 4 SSIM ベクトルの効果

Fig. 4 Effects of SSIM vectors (SSIMV): (a) textures generated from a learned latent space; (b,c and d) clustered textures with 4 dimensional SSIMV using a variety of reference textures, (b) the leftmost orange edged one, (c) the leftmost two orange edged ones, (d) the four orange edged ones; (e) clustered textures with 50 dimensional SSIMV, using the all textures in (a) as references. The representative texture of each cluster is blue edged.

(d,e) は, (c) で求めた潜在空間上の点に移動してからおこなった 2 回目の繰り返しの結果である. (d) は, 移動した点の周辺でサンプリングした点から生成したテクスチャである. vMF 分布のパラメータは, 集中度を 1 にした. それ以外は, (a) と同様である. 式 1 の計算では, $r = 1.0$ とした. (e) については, (c) と同様である.

4.4 SSIM ベクトルの効果

提案手法でのクラスタリングにおいて SSIM ベクトル (SSIMV) の次元を変化させた場合について比較をおこなうことにより, SSIMV の効果の確認をおこなった. (a) は, von Mises Fisher(vMF) 分布の乱数を用いてサンプリ

ングした潜在空間上の点から生成したテクスチャである. (b,...,e) は, クラスタリングの結果である. (b,c,d) では, 4 次元の SSIMV を用いた. (b) では (a) の左上のテクスチャを参照テクスチャとした MSSIM 値を SSIMV の各成分に格納した. (c) では, (a) の左上とその隣のテクスチャを参照テクスチャとした MSSIM 値のそれぞれを SSIMV の 2 つの成分に格納した. (d) では, (a) の左上の 4 テクスチャを参照テクスチャとした MSSIM 値を SSIM の成分に格納した. (e) では, (a) の全てのテクスチャを参照テクスチャとした 50 次元の SSIMV を用いた. 青色の枠で囲まれたテクスチャは, 各クラスに含まれるテクスチャの特徴を代表するテクスチャである.




図 5 潜在空間の探索による補間テクスチャの生成

Fig. 5 Generating interpolating textures with the latent space search method described in [7]. The first row shows the MSSIMs of the interpolated and interpolating textures (circles), and the locations of the latent space points from which the textures was generated (triangles). The locations are normalized with respect to the distance between the latent space points from which interpolated textures was generated. The second row shows the similarity searching intervals (MSSIM intervals) used in latent space search (blue scale), and the similarity (MSSIMs) of the generated textures (green arrows).

4.5 潜在空間の探索

図 5 は、提案手法により探索した潜在空間上の点を用いて補間テクスチャ列を生成した例である。始めに、補間テクスチャ列の端点となるテクスチャを生成するための潜在空間上の点を、提案手法を用いて探索した。そして、[7] の手法を用いてテクスチャの類似度を基準として潜在空間上を探索することにより、類似度が滑らかに変化する補間テクスチャ列を生成した。

第 1 行のグラフの丸印は、参照テクスチャと補間テクスチャ列の各テクスチャとの類似度 (MSSIM 値) である。比較される 2 つのテクスチャが全く同じである場合には、MSSIM 値が 1.0 となる。テクスチャの類似度が小さくなるほど、MSSIM 値は小さくなる。グラフの三角印は、各テクスチャの生成に用いた潜在空間上の点の位置である。ここでは潜在空間上での位置を、潜在空間上での補間の端点を結ぶ線分上での一方の端点からの正規化距離として示している。なお、潜在空間上での補間の端点とは、補間されるテクスチャに対応する潜在空間上の 2 点のことである。潜在空間上での補間の端点のそれぞれの点から、補間テクスチャ列の両端のテクスチャが生成される。

第 2 行のグラフの青色の目盛りは、探索において用いた類似度探索区間 ([7] を参照) である。[7] の探索手法では、類似度探索区間に設定された類似度の変化の条件を満たすような補間テクスチャ列を生成するための潜在空間上の補間点列を探索する。グラフの緑色の矢印は、補間テクスチャ画像列に含まれる各テクスチャ画像の類似度とその画像を生成した類似度探索区間上での位置を対応付けている。

4.6 検討

図 1 からは、深層生成モデルの訓練に用いた和紙のテクスチャ画像と訓練した生成器から生成したテクスチャ画像とを比較することにより、深層生成モデルである DCGAN を用いて訓練した生成器から、和紙の繊細な特徴を捉えたテクスチャを生成可能であることが分かる。

図 2(a) からは、von Mises Fisher (vMF) 分布の集中度が大きいほど、球面の局所的な領域から点がサンプリングされていることが分かる。図 2(b) は、100 次元の vMF 分布からサンプリングした例である。集中度が大きいほど、vMF 分布の平均方向ベクトルに対して vMF 分布の中心とサンプリング点を結ぶベクトルのなす角が小さくなること分かる。サンプリング点は、n-sphere 上に存在することから、集中度が大きくなるとより狭い範囲からサンプリングされることが分かる。図 2(c) は、テクスチャの潜在空間上の n-sphere の表面上にサンプリングした点からテクスチャを生成した例である。vMF 分布の集中度が大きくなるほど、より類似なテクスチャが生成されることが分かる。

図 3 では、アルゴリズム 1 によりテクスチャの潜在空間の探索をおこなっている。式 1 による潜在空間上での対象領域の選択は、潜在空間上での現在位置 $\mathbf{c}$ の周囲にライトを照らしての探索として捉えると直感的に分かりやすいといえる。vMF 分布の平均方向ベクトルがライトの方向であり、集中度がライトを照らす範囲である。式 1 の r がどの程度遠方にライトを照らすかである。そして、対象領域上にサンプリングした点から生成したテクスチャを用いて探索方向を決定する手法は、グラフィックス・コンテンツの制作のために意図に合ったテクスチャを探索するような

場合に有効であるといえる。

図4では、SSIM ベクトル (SSIMV) の次元を増加させることにより、よりよいクラスタリング結果が得られることが分かる。SSIM は参照テクスチャを基準とした類似度であることから、SSIMV の次元を増加させることにより多くの種類の基準を用いた類似度の表現が可能になり、よりよいクラスタリングの結果が得られると考えられる。一方では、クラスタリングのための計算量が増加することになる。SSIMV の次元数などについては、検討が必要である。

図5では、提案手法により探索したテクスチャを補間の端点として深層生成モデルの潜在空間の探索手法 [7] を用いることにより、類似度が滑らかに変化する和紙の補間テクスチャ列を生成可能であることが分かる。MSSIM 値 (丸印) の変化からは、補間テクスチャ列を構成するテクスチャの類似度が滑らかに変化していることを数値的に確認できる。また、類似度探索区間上での探索位置 (矢印)、および、潜在空間上での探索位置 (三角印) からは、実験に用いた和紙テクスチャの学習モデルでは、滑らかに変化する潜在空間を学習できていることが分かる。

5. おわりに

深層生成モデルにより学習した潜在空間の探索において探索方向を選択するための手法を提案した。手法の特徴は、直感的な理解が容易な手法により高次元の潜在空間上での探索方向を選択可能である点である。それを実現するために、vMF 分布およびテクスチャの類似度を用いた。そして、提案手法の実装をおこない、実験により動作の確認をおこなった。提案手法は、学習モデルの対話的な分析、グラフィックス・コンテンツの制作のためのテクスチャの微調節などに用いることが可能である。

今後の課題としては、多くの種類のテクスチャの学習モデルへの提案手法の適用、潜在空間の探索のための対話的インタフェースの改良、および、クラスタリングの性能の改善などがある。

参考文献

- [1] Du, M., Liu, N. and Hu, X.: Techniques for Interpretable Machine Learning, *Commun. ACM*, Vol. 63, No. 1, p. 68-77 (online), DOI: 10.1145/3359786 (2019).
- [2] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y.: Generative Adversarial Nets, *Advances in Neural Information Processing Systems 27* (Ghahramani, Z., Welling, M., Cortes, C., Lawrence, N. D. and Weinberger, K. Q., eds.), Curran Associates, Inc., pp. 2672-2680 (online), available from <http://papers.nips.cc/paper/5423-generative-adversarial-nets.pdf> (2014).
- [3] Hinton, G. E. and Salakhutdinov, R. R.: Reducing the Dimensionality of Data with Neural Networks, *Science*, Vol. 313, No. 5786, pp. 504-507 (2006).

- [4] Jiang, L., Liu, S. and Chen, C.: Recent Research Advances on Interactive Machine Learning, *J. Vis.*, Vol. 22, No. 2, pp. 401-417 (online), DOI: 10.1007/s12650-018-0531-1 (2019).
- [5] Kingma, D. P. and Welling, M.: Auto-Encoding Variational Bayes, *ArXiv e-prints* (2013).
- [6] LeCun, Y., Bengio, Y. and Hinton, G.: Deep learning, *Nature*, Vol. 521, No. 7553, pp. 436-444 (2015).
- [7] 佐藤 信: 深層生成モデルにより学習した潜在空間を用いた和紙テクスチャの補間, 情報処理学会研究報告, Vol. 2018-CG-169, No. 2, pp. 1-6 (2018).
- [8] 佐藤 信: 動的な Small Multiple Textures の生成のための和紙テクスチャの潜在空間への風鈴音の写像, 情報処理学会研究報告, Vol. 2018-AVM-102, No. 1, pp. 1-6 (2018).
- [9] 佐藤 信: 風鈴音にあわせた動的な和紙テクスチャの生成のための潜在空間の探索区間のガンマ補正, 情報処理学会研究報告, Vol. 2019-CG-173, No. 8, pp. 1-8 (2019).
- [10] Radford, A., Metz, L. and Chintala, S.: Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks, *CoRR*, Vol. abs1511.06434 (online), available from <http://arxiv.org/abs/1511.06434> (2015).
- [11] Thung, K. H. and Raveendran, P.: A survey of image quality measures, *2009 International Conference for Technical Postgraduates (TECHPOS)*, pp. 1-4 (online), DOI: 10.1109/TECHPOS.2009.5412098 (2009).
- [12] Wang, Z. and Bovik, A. C.: A universal image quality index, *IEEE Signal Processing Letters*, Vol. 9, No. 3, pp. 81-84 (online), DOI: 10.1109/97.995823 (2002).
- [13] Wang, Z., Bovik, A. C., Sheikh, H. R. and Simoncelli, E. P.: Image Quality Assessment: From Error Visibility to Structural Similarity, *Trans. Img. Proc.*, Vol. 13, No. 4, pp. 600-612 (online), DOI: 10.1109/TIP.2003.819861 (2004).
- [14] Wang, Z., C. Bovik, A. and Simoncelli, E.: *Structural Approaches to Image Quality Assessment*, pp. 961-974 (2005).