

# 深層学習した和紙テクスチャの潜在空間の探索手法を用いた 繊細な動的 Small Multiple Textures の洗練化\*

○佐藤 信 (岩手大学理工学部)




Figure 1: Refining nuanced Small Multiple Textures (SMTs): from left to right, a pixel pattern generated with a fluid simulation method, its quantified pixel pattern, SMTs generated using the quantified pixel pattern and a texture sequence, and refined SMTs which was generated using another texture sequence.

## 概要

本稿では、繊細な和紙の動的 Small Multiple Textures の洗練化が可能であることを示す。テクスチャの生成には、深層学習したテクスチャの潜在空間を用いることにより繊細な動的テクスチャを生成するための既提案手法 [1] を用いる。コンテンツの制作過程では、調節を繰り返しながら意図にあうようにコンテンツを洗練化することが重要であることから、既提案手法では、生成される動的テクスチャの微調節が可能ないように手法の設計がおこなわれている。ここでは、既提案手法の内部でおこなわれる潜在空間の探索において、類似度探索区間を微調節することにより動的テクスチャの洗練化が可能であることを示す。既提案手法は、落ち着いた雰囲気のを表現するコンテンツの制作に適した手法であるといえる。

## 1 はじめに

本稿では、深層生成モデルにより学習した和紙テクスチャの潜在空間を用いて動的 Small Multiple Textures を生成するための既提案手法 [1] において、繊細な動的テクスチャの洗練化が可能であることを示す。[1] の提案手法の特徴は、次のとおりである。

- 学習したテクスチャの潜在空間を探索することにより、滑らかに類似度が変化する補間テクスチャ列を生成する。テクスチャの類似度の基準として、MSSIM(Mean Structural Similarity) [2] を用いる。
- 生成した補間テクスチャ列に含まれるテクスチャを、動的に変化するパターンに写像する。動的パターンの生成には、コンピュータ・グラフィックスにおいてよく用いられる、流体の動きを視覚的にシミュレーションするための手法を用いる。
- テクスチャの類似度に基づいて、動的テクスチャを意図にあわせて直感的に洗練化することが可能である。それを実現するために、学習したテクスチャの潜在空間の探索手法、および、動的パターンの量子化を用いた写像手法を有効に用いている。

この手法の目的は、コンテンツを制作するための素材の選択での自由度を大きくすることである。落ち着いた雰囲気の和を表現するコンテンツの制作に適した手法であるといえる。

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、繊細な動的 Small Multiple Textures を生成するための既提案手法について、3 節において説明する。4 節では、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。

\*Refining Nuanced Dynamic Small Multiple Textures Using Search Method for Deep Learned Washi Texture Latent Spaces

## 2 関連研究

### 2.1 テクスチャ生成

コンピュータ工学においてテクスチャは重要な役割を担うことから、様々な応用を目的としてテクスチャに関する研究がおこなわれている。

例えば、コンピュータ・グラフィックス分野においては、コンテンツの制作に用いるためのテクスチャの生成手法が多数提案されている。また、機械学習の分野では各種の応用を目的として、学習によりテクスチャを生成するための研究が盛んにおこなわれている。

コンピュータ・グラフィックス分野でのテクスチャの生成に関連する研究には、[3]がある。その手法では、予め定義した数学的な変換を用いて乱数を変換することにより、手続き的にテクスチャを生成している。大理石のようなテクスチャの生成には、よく用いられる手法である。しかし、テクスチャを生成するために定義した変換とそれにより生成されるテクスチャとの関係が直接的でないことから、新しいテクスチャを生成するための変換を考える場合などには生成されるテクスチャを予測するのが困難な場合が多いといえる。

一方、予め用意したテクスチャを基準として、それに類似なテクスチャを生成しようとする手法が多数発表されている。それらの手法には、テクスチャの合成によるものと、テクスチャの学習によるものがある。

合成によるテクスチャ生成では、テクスチャ・パッチの特徴を基準としてパッチを合成する（組み合わせる）ことにより、類似なテクスチャを生成する[4]。合成するテクスチャ・パッチの選択および配置などが必要となり、組み合わせ問題を解くための計算コスト（時間およびメモリ量）が大きい手法である。また、十分な個数のパッチを用意しない場合には、パッチの継ぎ目が不自然になる可能性がある。

テクスチャ生成に学習を用いる手法には、合成によるテクスチャ生成において学習によりテクスチャ・パッチの選択をおこなう手法も含まれるが、多様な類似度をもつテクスチャを高品質に生成することが可能になったのは、パッチの合成とは全く別の発想に基づく手法である深層生成モデルを用いたテクスチャ生成手法が発表されてからである。深層生成モデルを用いると、テクスチャ・データから特徴を表現する潜在空間を直接的に学習することが可能であり、学習した潜在空間から学習に用いたテクスチャに類似の特徴をもつ多様なテクスチャを生成することが可能である。深層生成モデルを用いたテクスチャの学習には、大量の計算資源を必要とするが、学習したモデルの潜在空間からテクスチャを生成するための計算コストは比較的小さいといえる。

本稿では、深層生成モデルにより学習した潜在空間を探索するための既提案手法[5]での和紙テクスチャの学習モデルを用いる。和紙テクスチャの学習には、深層生成モデルであるDCGAN (Deep Convolutional Generative Adversarial Network) [6]を用いた。

### 2.2 深層生成モデル

本稿では、深層学習 (deep learning) [7] の学習モデルのひとつであるDCGANにより学習した和紙テクスチャの学習モデルを用いて、動的テクスチャを生成し洗練化をおこなう。

DCGANは、深層学習モデルのなかの深層生成モデル (deep generative model) に含まれる学習モデルである。機械学習における生成モデルとは、学習データに類似のデータを生成することが可能な学習モデルであり、深層学習が発表される以前から存在した。しかし、それらにより生成されるデータの品質は十分とはいえなかった。深層学習が発表されると、それまでの生成モデルに深層学習を適用する手法が発表されたが、それらにより生成される画像はそれまでのものと比較すると格段に高品質であるが、コンテンツの制作に用いるためには十分とはいえなかった。

そして、VAE (Variational Auto-Encoder) [8] およびGAN (Generative Adversarial Network) [9] などの、深層生成モデルが発表され、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ことが示された。そのことから、これらの学習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。

## 3 繊細な動的テクスチャの洗練化

### 3.1 動的テクスチャの生成

アルゴリズム1に、[1]での既提案手法を示す。**Step 1**では、深層生成モデルにより和紙のテクスチャを学習した学習モデル  $M$  の生成器を用いて、和紙に類似なテクスチャ画像  $T$  を生成する。そして、 $T$  の中から意図にあわせてテクスチャ画像を選択し、[10]での手法により、それらを補間するテクスチャ画像列  $I$  を生成する。 $I$  は、テクスチャの類似度が滑らかに変化する画像列である。**Step 2**では、流体の視覚的なシミュレーション手法[11]により、滑らかに変化するピクセル・パターン  $P$  を生成する。**Step 3**では、学習によりピクセル・パターン  $P$  を量子化し、学習したカラーパレットのインデックスにより構成されるピクセル・パターン・インデックス  $Q$  を

**Algorithm 1** Generating Nuanced Textures\***Step 1**

Prepare a Washi texture model  $\mathcal{M}$  trained with DCGAN.  
Generate texture images  $\mathcal{T}$  using the generator of  $\mathcal{M}$ .  
Generate a interpolating texture images  $\mathcal{I}$  from  $\mathcal{T}$ .

**Step 2**

Create a pixel pattern  $\mathcal{P}$  with a fluid simulation method.

**Step 3**

Generate quantified pixel pattern indexes  $\mathcal{Q}$  from  $\mathcal{P}$ .

**Step 4**

Generate nuanced textures by means of mapping  $\mathcal{I}$  to  $\mathcal{Q}$ .

生成する (量子化については, [1] を参照). **Step 4** では, ピクセル・パターン・インデックス  $\mathcal{Q}$  と補間テクスチャ画像列  $\mathcal{I}$  に含まれるテクスチャ画像のインデックスとを対応付けることにより, 動的な Small Multiple Textures を生成する.

### 3.2 潜在空間の探索による洗練化

本稿で用いる [1] での手法は, コンテンツの制作に用いる素材を生成するための手法であり, [5], [10], [12] に関連する研究である.

それらの研究では, 和紙テクスチャの学習モデルにより生成した多様な類似度をもつ和紙テクスチャを用いる. [5] は, 類似度が滑らかに変化する補間テクスチャ列の生成手法であり, 2種類の探索区間を基準として用いて区間木探索をおこなう. それらの探索区間は, 潜在空間から生成する補間テクスチャ列に含まれるテクスチャの類似度の変化を制約するための類似度探索区間, および, 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端点とする探索区間である. 一般的な区間木探索との相違点は, 2種類の区間上の探索点の更新をおこないながら探索をおこなうこと, および, 連続な実数値の区間を対象に探索をおこなう点である. これらの探索区間を調節することにより, 生成される補間テクスチャ列を意図にあうように調節することが可能である. 繊細な和紙の質感を表現するコンテンツを制作するための手法を構築するために重要な役割を担う手法である.

コンテンツを制作する場合には, 意図にあうように微調節を繰り返すことにより洗練化をおこなうことが重要であるといえる. そのために [1] では, 生成される動的テクスチャの微調節が可能であるように設計をおこなった. 具体的には, アルゴリズム 1 の **Step 1** において生成する補間テクスチャ列, および, **Step 3** でおこなう

ピクセル・パターンの量子化のレベルの調節により, 生成される動的テクスチャの微調節が可能である.

本稿では, アルゴリズム 1 の **Step 1** での補間テクスチャ列の生成において, 潜在空間の探索の基準として用いる探索区間を調節することにより, 生成される動的な和紙テクスチャを微調節することにより洗練化をおこなう.

## 4 実験結果と検討

### 4.1 和紙テクスチャの学習

アルゴリズム 1 の **Step 1** での和紙テクスチャの生成および補間テクスチャ列の生成には, [5] での和紙テクスチャの学習モデルを用いた. そこでは, 深層生成モデルのひとつである DCGAN (Deep Convolutional Generative Adversarial Network) [6] を用いることにより, 和紙のテクスチャの学習をおこなった. 訓練に用いた和紙のテクスチャ画像の例を, 図 2 に示す.

図 3 は, 和紙のテクスチャを学習した DCGAN の生成器 (generator) の入力に乱数を与えることにより生成したテクスチャである.

図 4 は, 特徴が滑らかに変化するよう生成した補間テクスチャ列の例である. 始めに, 図 3 と同様にして, 乱数により和紙に類似の複数のテクスチャを生成した. その中から, 補間テクスチャ列の補間の端点として用いるためのテクスチャを対話的に選択し (グラフの両端のテクスチャ), 選択したテクスチャの特徴を補間するようにテクスチャ列を生成した (グラフの両端のテクスチャの間のテクスチャ). 補間テクスチャ列の生成では, テクスチャの類似度基準として MSSIM を用いた.

図 4 の上部のグラフは, 生成した補間テクスチャ列に含まれる各テクスチャについて, MSSIM の値を示したものである (丸印). MSSIM の計算に用いる参照テクスチャには, 補間テクスチャ列の左端のテクスチャを用いた. 参照テクスチャと比較したテクスチャとの類似度が大きい場合には, MSSIM の値が大きくなる. 同一のテクスチャを比較した場合には, MSSIM の値は 1 である. また, 補間テクスチャ列に含まれる各テクスチャを生成した潜在空間上の点について, それらの相対的な位置をグラフに示した (三角印). 潜在空間上の位置の表現には, 補間テクスチャ列の一方の端点のテクスチャに対応する潜在空間上の点からの正規化距離を用いた. 正規化には, 補間テクスチャ列の端点となるテクスチャを生成した潜在空間上の 2 点間の距離を用いた.

図 4 の下部のグラフは, 生成した補間テクスチャ列に含まれる各テクスチャの MSSIM の値と, 探索において

\*from [1]



Figure 2: Examples of Washi texture images used to train DCGAN.



Figure 3: Generated Washi textures using randomly sampled latent space vectors.

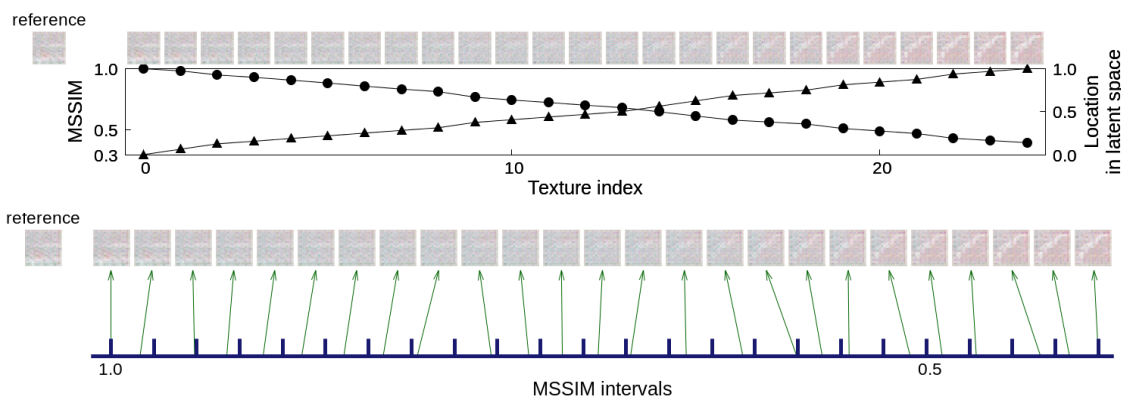


Figure 4: Washi texture interpolation using learned latent space.




Figure 5: Refining nuanced Small Multiple Textures (SMTs) by adjusting the level of quantification: (a) a pixel pattern generated with a fluid simulation method, (b) its quantified pixel pattern with quantification level 10, (c) with quantification level 25, (d) SMTs generated using (b), and (e) SMTs generated using (c).

基準として用いた類似度探索区間 (MSSIM intervals) との関係を示したものである (矢印).

#### 4.2 量子化レベルの調節による洗練化

図5は、アルゴリズム1のStep2からStep4により、動的 Small Multiple Textures を生成した例である。ここでは、Step2でおこなう量子化のレベルを調節す

ることにより、生成されるテクスチャの調節をおこなった。なお、量子化には、自己組織化マップ [13] を用いた学習手法 [14] を用いた (詳細は、[1] を参照)。

図5(a)は、アルゴリズム1のStep2において流体計算により生成したピクセル・パターンである。(b)および(c)は、Step3において生成した量子化したピクセル・パターンである。そして、(d)および(e)は、Step4において生成した動的 Small Multiple Textures のなかの

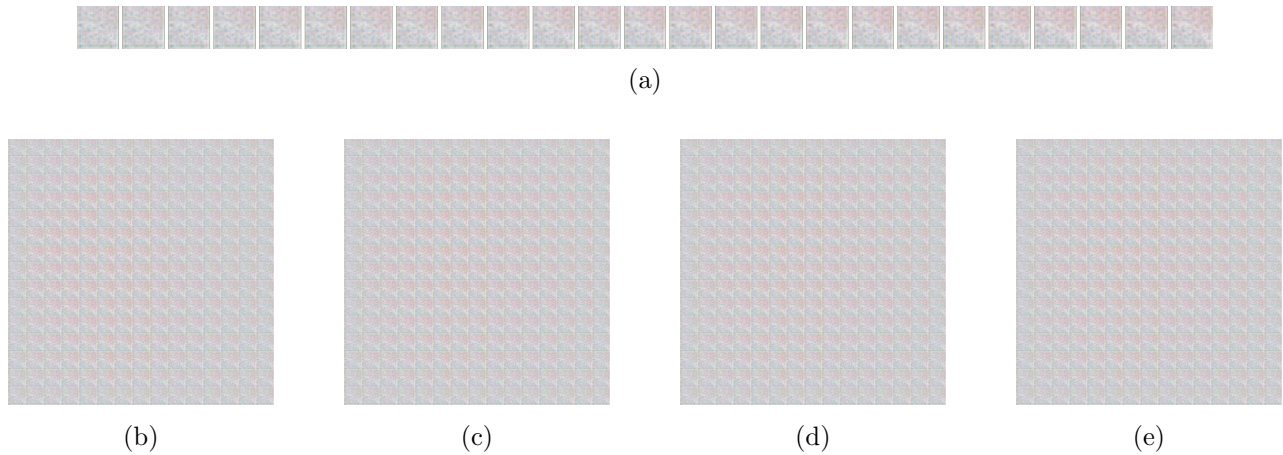


Figure 6: Generating dynamic Washi Small Multiple Textures (SMTs): (a) A generated interpolating texture sequence using a latent space search method, and (b), $\dots$ , (e) a dynamic SMTs sequence generated with (a).

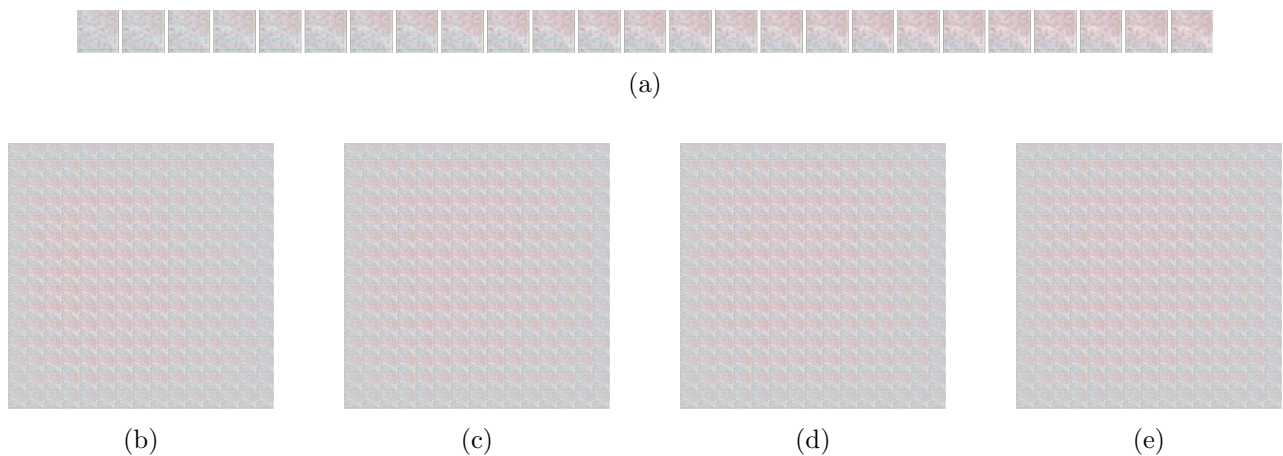


Figure 7: Refining dynamic Washi Small Multiple Textures (SMTs) in Figure 6: (a) a generated texture sequence for refinement, and (b), $\dots$ , (e) a dynamic SMTs sequence refined with (a).

あるフレームである。なお、(b) および (d) は量子化レベル 10 であり、(c) および (e) は量子化レベル 25 である。量子化レベルは、自己組織化マップのニューロンの個数に対応する。

### 4.3 潜在空間の探索区間の調節による洗練化

図 6, 7 は、アルゴリズム 1 を用いて動的 Small Multiple Textures を生成した例である。ここでは、アルゴリズム 1 の **Step 1** で生成する補間テクスチャ列を調節することにより動的テクスチャの洗練化をおこなった。図 6(a) は、生成した補間テクスチャ列である。補間テクスチャ列の生成では、始めに、両端のテクスチャを対話的に選択した。そして、[5] での潜在空間の探索手法を用いて、選択したテクスチャを補間の端点とする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。探索において

類似度の変化を制約するための類似度探索区間 (MSSIM intervals) は、両端のテクスチャの類似度の差の値を均等に分割するように設定した (図 4 と同様)。各区間について類似度の条件を満たすテクスチャを 1 つずつ探索することにより補間テクスチャ列を生成した。MSSIM による類似度の計算では、補間テクスチャ列の左端のテクスチャを参照テクスチャとして用いた。(b), $\dots$ , (e) は、(a) を用いて生成した動的 Small Multiple Textures のなかの連続するフレームである。

図 7 では、図 6 で生成した動的テクスチャを微調節することにより、テクスチャのパターンが僅かに強調されるように洗練化をおこなった。図 7(a) は、洗練化に用いた補間テクスチャ列である。(b), $\dots$ , (e) は、(a) を用いて洗練化した動的 Small Multiple Textures である。これらは、図 6(b), $\dots$ , (e) とそれぞれ、同一のフレームで

あり、同一のピクセル・パターンおよび量子化ピクセル・パターン（アルゴリズム 1, 図 1, 5 を参照）を用いて生成した。

図 8 は、図 7(a) の補間テクスチャを用いて生成した動的 Small Multiple Textures である。テクスチャ列は、左上のテクスチャから開始し、右下のテクスチャで終了する。これらのテクスチャのみを用いて、滑らかに変化する動画を作成可能であることを確認できた。

#### 4.4 検討

図 2, 3 および 4 では、アルゴリズム 1 の **Step 1** で用いた和紙のテクスチャを学習したモデルの状態を確認している。DCGAN の訓練に用いた和紙のテクスチャ（図 2）と訓練した DCGAN の生成器の入力に乱数を与え生成したテクスチャ（図 3）とを比較すると、訓練に用いた和紙のテクスチャに特徴が類似なテクスチャを生成可能であることが分かる。図 4 では、アルゴリズム 1 の **Step 1** で生成した補間テクスチャ列を確認している。対話的に選択したテクスチャを補間の端点として、特徴が滑らかに変化する補間テクスチャ列を生成可能であることが分かる。図 4 の上部のグラフからは、特徴が滑らかに変化していることを、視覚的に確認できるばかりではなく、MSSIM の値からも確認できる。また、各テクスチャの類似度にあわせて、テクスチャを生成した潜在空間上の点の相対的な位置が変化していることが分かる。図 4 の下部のグラフからは、潜在空間の探索に用いた類似度探索区間の各区間から 1 つのテクスチャが選択され、類似度探索区間に設定したように滑らかに類似度が変化する補間テクスチャ列を生成可能であることが分かる。

図 5 は、量子化レベルの調節により動的 Small Multiple Textures を洗練化した例である。図 5(a) と (b) および (c) を比較すると、流体計算により生成したピクセル・パターンにあわせてピクセル・パターンの量子化が可能であり、量子化レベルの調節により量子化ピクセル・パターンを調節可能であることが分かる。これらと (d) および (e) から、量子化レベルの調節により、流体計算により得られるパターンにあわせた動的テクスチャの洗練化が可能であることが分かる。

図 6 および 7 では、アルゴリズム 1 の **Step 1** で生成する補間テクスチャ列の調節により動的 Small Multiple Textures の洗練化をおこなっている。動的テクスチャの生成に用いる補間テクスチャ列を図 6(a) から図 7(a) のように微調節することにより、同一のピクセル・パターンおよび量子化ピクセル・パターンを用いて生成される動的テクスチャを図 6(b), …, (e) から図 7(b), …, (e) のように微調節することが可能であることが分かる。各図の

(a) の補間テクスチャ列は、[5] での手法を用いることにより、補間の端点となるテクスチャのみを指定することによりアルゴリズムを用いて生成可能であり、[12] のように、生成した補間テクスチャ列について対話的に洗練化を繰り返すことも可能である。このように、対話的に微調節しながらアルゴリズムにより補間テクスチャ列を生成可能であるので、アルゴリズム 1 を用いると動的テクスチャの洗練化の繰り返しが容易である。

図 8 は、図 7(a) の補間テクスチャ列を用いて、アルゴリズム 1 により生成した動的テクスチャである。流体内で粒子の密度が拡散するように、繊細なテクスチャを用いて生成したパターンが変化する動的テクスチャを生成可能であることが分かる。

## 5 おわりに

本稿では、動的 Small Multiple Textures を生成するための既提案手法 [1] において、繊細な動的テクスチャの洗練化が可能であることを示した。既提案手法の特徴は、深層生成モデルにより学習した和紙テクスチャの潜在空間の探索などを用いて、テクスチャの類似度に基づき動的テクスチャを生成する点である。本稿では、潜在空間の探索により得られる補間テクスチャ列を微調節することにより、意図にあわせて動的テクスチャを洗練化することが可能であることを示した。既提案手法の目的は、コンテンツを制作するための素材の選択での自由度を大きくすることであり、落ち着いた雰囲気のを表現するコンテンツの制作に適した手法であるといえる。今後の課題としては、多くの種類のテクスチャによる動的テクスチャの生成、意図にあわせたピクセル・パターンの生成手法に関する研究がある。また、各種の繊細なテクスチャの学習を必要とする分野へ、既提案手法でのテクスチャの学習の知見を応用することも重要な課題である。

## 参考文献

- [1] 佐藤信：深層学習した和紙テクスチャの潜在空間を用いた繊細な動的 Small Multiple Textures の生成, 情報処理学会研究報告, 第 2019-AVM-107 巻, pp. 1-6 (2019).
- [2] 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 (2004).

- [3] Perlin, K.: An Image Synthesizer, *SIGGRAPH Comput. Graph.*, Vol. 19, No. 3, pp. 287–296 (1985).
- [4] Akl, A., Yaacoub, C., Donias, M., Costa, J.-P. D. and Germain, C.: A survey of exemplar-based texture synthesis methods, *Computer Vision and Image Understanding*, Vol. 172, pp. 12 – 24 (2018).
- [5] 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, 第 2018-CG-169 巻, pp. 1–6 (2018).
- [6] Radford, A., Metz, L. and Chintala, S.: Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks, *CoRR*, Vol. abs1511.06434, (2015).
- [7] LeCun, Y., Bengio, Y. and Hinton, G.: Deep learning, *Nature*, Vol. 521, No. 7553, pp. 436–444 (2015).
- [8] Kingma, D. P. and Welling, M.: Auto-Encoding Variational Bayes, *ArXiv e-prints* (2013).
- [9] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y.: Generative Adversarial Nets, in Ghahramani, Z., Welling, M., Cortes, C., Lawrence, N. D. and Weinberger, K. Q. eds., *Advances in Neural Information Processing Systems 27*, pp. 2672–2680, Curran Associates, Inc. (2014).
- [10] 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, 第 2019-CG-173 巻, pp. 1–8 (2019).
- [11] Stam, J.: Stable Fluids, in *Proceedings of the 26th Annual Conference on Computer Graphics and Interactive Techniques*, SIGGRAPH '99, pp. 121–128, New York, NY, USA (1999), ACM Press/Addison-Wesley Publishing Co.
- [12] 佐藤信：視覚的な類似性に基づく和紙テクスチャの対話的生成, 情報処理学会研究報告, 第 2018-HCI-177 巻, pp. 1–8 (2018).
- [13] T. コホネン：自己組織化マップ, 丸善出版 (2016).
- [14] Dekker, A. H.: Kohonen neural networks for optimal colour quantization, *Network: Computation in Neural Systems*, Vol. 5, No. 3, pp. 351–367 (1994).



Figure 8: Generated dynamic Washi Small Multiple Textures (SMTs): the texture sequence of the SMTs starts at top left and ends at bottom right.