

BO as Assistant: ベイズ最適化を活用した非同期的なデザイン案生成のためのフレームワーク

小山 裕己^{1,a)} 後藤 真孝^{1,b)}

概要: 本稿では、デザイナーが複数のパラメタ調整用スライダを試行錯誤しながら操作して望ましいデザインを得る過程（パラメトリックデザインにおける探索）を支援するために、ベイズ最適化（Bayesian optimization; BO）を活用したデザイン案生成フレームワーク **BO as Assistant** を提案する。ベイズ最適化は、観測データに基づき効率的なサンプリングを逐次的に行う最適化手法であり、これまでに、designer-in-the-loop なデザイン最適化のフレームワークで効果的に用いられてきた。しかし従来は、システムがサンプリングしたデザイン案をデザイナーが評価させられる（明示的な loop を強制される）ワークフローになっていたために、デザイナーは主導権を握って自由な探索を行うことができず、行為主体感が失われる問題があった。それに対して我々の BO as Assistant では、デザイナーが自由にスライダを操作してデザインを探索している様子（パラメタ値の組み合わせの探索を行っている様子）をシステムが観測することにより、明示的にデザイナーに inputs を求めることなく、ベイズ最適化のサンプリング戦略によって効果的なデザイン案を生成できる点が優れている。本稿では提案フレームワークの一般性を示すために、写真の色調補正、プロシージャルモデリング、プロシージャルマテリアル生成の異なるドメインに適用し、デザイナーが自由に探索を行うことを阻害することなく合理的なデザイン案が非同期的に生成できる様子を示す。

1. はじめに

写真の色調補正、プロシージャルデザイン、機械学習によるコンテンツ生成などの、多くのデザインプロセスはパラメタ調整というタスクを伴う [12], [17]。パラメタ調整では、望ましいデザインを実現するための複数のパラメタ値の組合せが事前にわかっていることは稀で、通常はデザイナーが、それらのパラメタを変更するための複数のスライダを何度も前後に操作して試行錯誤することで、適切なパラメタ値の組合せを発見しなければならない。このようなタスクは、デザイナーにとっての望ましいデザインの主観的評価を目的関数とした多次元最適化問題とみなすことができる [10]。本研究は、このような最適化問題をデザイナーが手動で解く支援をすることを目的とする。

こうした最適化問題に対して、多くの研究者がこれまでに **human-in-the-loop 最適化** (人が評価者として振る舞う最適化) のフレームワークの研究に取り組んできた。特に、数理的観点で合理的なサンプリング戦略によって、少ないサンプル数でも最適化問題を解くことができる性質を持つ **ベイズ最適化 (Bayesian optimization; BO)** [21] は、このよ

うな目的において有望な技術である [6], [14], [15], [28], [29]。BO は、探索 (exploration; 未探索領域を優先的にサンプリングする性質) と活用 (exploitation; 有望な領域を優先的にサンプリングする性質) の両方を考慮して、各ステップで最も効果的な点をサンプリングすることによって、効率的に解 (望ましいパラメタ値の組合せ) を探索できる。

しかし、既存の designer-in-the-loop 最適化 (デザイナーが評価者として振る舞う最適化) のフレームワークでは、あくまでシステム側がデザインプロセスの主体であり、デザイナーはサンプリングされたデザイン案の評価のみを実施する仕組みのため、デザイナーがドメイン知識や直感に基づいて自由にパラメタ空間を探索するための柔軟性に欠けていた。つまり、デザイナーがどのようにデザインプロセスを進めるかの主導権を持っていなかった。このことは、デザイナーの行為主体感や創造性の低下を招く懸念がある [4]。

本研究では、新しいデザインのフレームワーク **BO as Assistant** を提案する。このフレームワークは、人間のデザイナーがデザインプロセスの完全な主導権を維持しつつ、ベイズ最適化の合理的なサンプリング戦略の恩恵も受けることができる特長を持つ。図 1 にそのコンセプトを示す。デザイナーは通常のデザインプロセスと同様に複数のパラメタ調整用スライダを自由に操作することができる。その一方で、システムはスライダの操作を常に監視し、その場で

¹ 産業技術総合研究所

^{a)} koyama.y@aist.go.jp

^{b)} m.goto@aist.go.jp

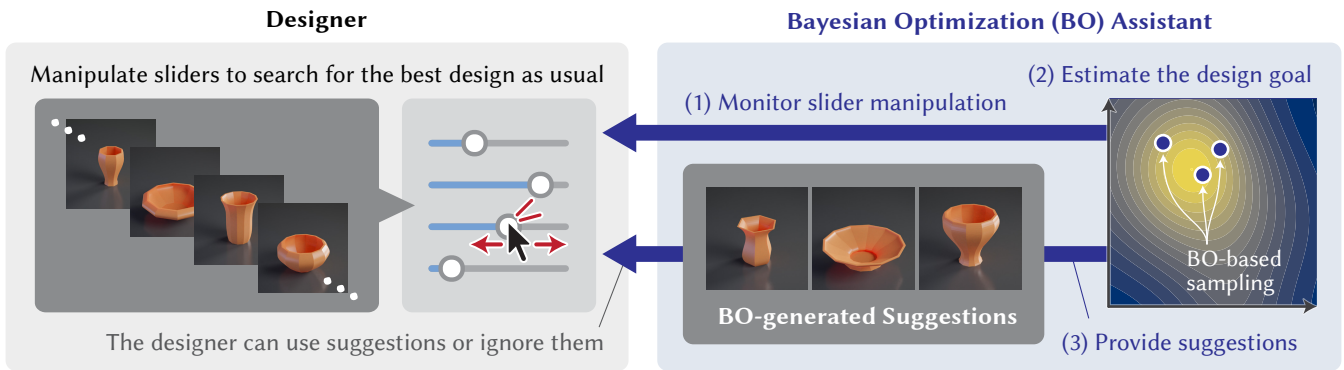


図 1 デザイナーが複数のパラメタ調整用スライダを操作して望ましいデザインを探索する過程をベイズ最適化 (BO) によって支援するフレームワーク **BO as Assistant** の概要. システムは (1) デザイナーによるスライダの操作を監視し, (2) 自動的にデザイナーのデザイン目標を推定し, (3) ベイズ最適化のサンプリング戦略を用いてデザイン案を生成して非同期に提示する. デザイナーはデザイン案を利用することも無視することもできる.

自動的にデザイナーの好み, すなわちデザイン目標を推定し, ベイズ最適化のサンプリング戦略を用いて未探索かつ有望なデザイン案を生成し, 非同期にデザイナーに対して提案する. デザイナーは提示された提案を利用することも無視することもできる. つまり, 従来の designer-in-the-loop 最適化のフレームワークとは異なり, デザイン案を生成するためにシステムはデザイナーに対して明示的な入力を求めることはない点が優れている. 我々が実装したインタフェースの例を図 2 に示す. なお, このような最適化計算の仕組みを助手 (assistant) として利用するアプローチは, 既存研究にも存在する [18], [25] が, デザイナーの挙動だけからデザイン目標を動的に推定することでデザイン案を生成する点に本研究の新規性がある.

このようなフレームワークを実現するため, ベイズ最適化を実行する上で必要な情報を複数のスライダ操作の挙動だけから (デザイナーに追加の入力を要求することなく) 暗黙的に抽出する技術を我々は提案する. 通常のベイズ最適化 [21] を実行するためには, 各データ点における目的関数の値 (対応するデザインに対する好ましさの具体的な点数) を観測する必要がある. しかしながら, そのような値はスライダ操作から観測することはできない. そこで本研究では**選好ベイズ最適化 (preferential Bayesian optimization; PBO)** [3], [14], [15] に着目する. PBO は, 絶対的な評価値ではなく, 相対的な好ましさの情報 (複数のデザイン間における好ましさの序列関係) を用いて最適化を実行することができるベイズ最適化の派生手法である. 我々は, システムがスライダ操作を観察し続けることによって相対的な好ましさの情報を抽出する新たな技術を提案する. 抽出した情報を用いて PBO を実行することで, 合理的なデザイン案 (パラメタ値の組み合わせ) をサンプリングしてデザイナーへ提示できる.

提案フレームワークは, あるドメインに特化した定式化

はしていないので様々なドメインに適用できる. この一般性を実証するため, 本稿ではコンピュータグラフィクスに関連する複数のデザインドメインに提案フレームワークを適用した様子を示す. 具体的には, 写真の色調補正, プロシージャルモデリング, プロシージャルマテリアル生成において, 提案フレームワークによってデザイナーによる自由な探索を阻害することなく合理的なデザイン案が非同期的に生成できる様子を示す. 本稿は, 我々の ACM UIST 2022 論文 (CC BY 4.0) [11] を和訳・要約したものである.

2. 関連研究

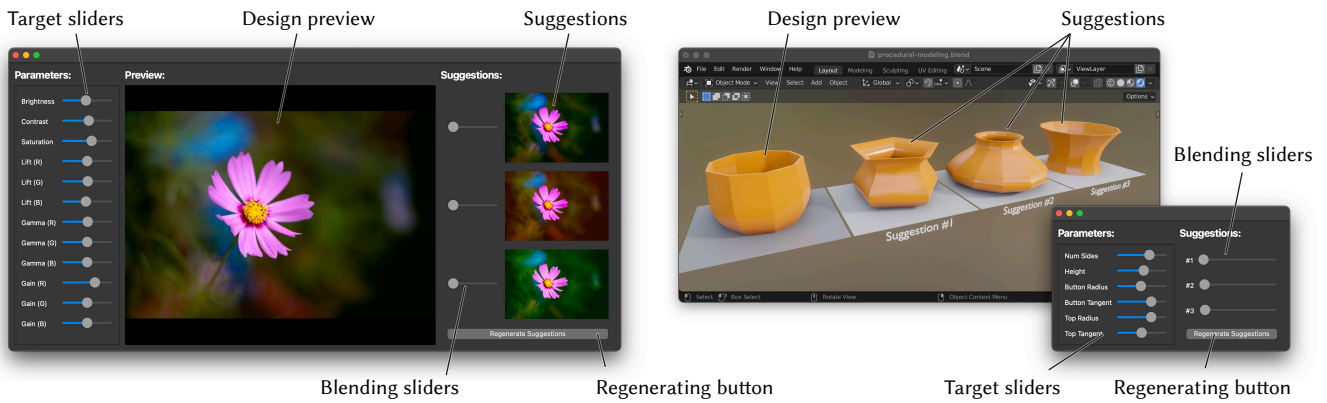
2.1 デザインのためのパラメタ調整インタフェース

デザインにおけるパラメタ調整タスクを支援するために, デザイン候補の一覧表示に基づくインタフェース [14], [17] など, 様々なインタフェースが提案されてきた. 本研究では, デザイン探索のための主たるインタフェースとして, 様々なドメインでよく用いられているスライダを想定する.

スライダインタフェースを拡張する研究は多数存在する. 特に, 評価者に対して明示的に入力を求めることでデザイン目標を推定する研究 [7], [12], [22] や, 多数のデザインセッションを観察することでデザイン目標を推定する研究 [13] は, 本研究と関連深い. しかし, スライダの操作自体を観察してそこからデザイン目標を推定するという我々のアプローチは新規性がある.

2.2 最適化を助手 (Assistant) とするデザインツール

最適化計算の仕組みをデザインにおける助手とする研究には, DesignScope [18] や Sketchplore [25] がある. これらは最適化計算によってレイアウトデザイン案を生成して提示するものであり, インタラクションの観点では本研究の提案フレームワークと似ている. しかし, レイアウトデザインなど特定のドメインでのみ有効な知識 (できるだ



(a) 写真の色調補正システム (スタンドアロンシステムとして実装) (b) プロシージャルモデリングシステム (Blender の addon として実装)

図 2 コンセプト実証システムのインターフェース。デザイナーは主に、デザインのプレビュー表示を見ながらスライダを操作する。すると複数 (図の例では三つ) のデザイン案が非同期に提示される。良いデザイン案があればそのブレンド用スライダを操作して、現在のスライダ値とブレンド (補間) できる。さらに提示中のデザイン案すべてを再生成 (変更) するボタンを押して多様な案を見ることもできる。

け線を揃える方が好ましいなど) に頼って事前に定義されたデザイン目標を用いるのではなく、代わりにベイズ的手法によってその場で動的にデザイン目標を推定していく点で異なる。さらに、ベイズ最適化の性質によって、デザインが有望かどうかだけでなく未探索かどうかも考慮した上でデザイン案を生成できる点で異なる。

2.3 Human-in-the-Loop ベイズ最適化

Human-in-the-loop 最適化は、評価に人間の関与が必要な最適化問題を扱うアプローチである。人間の関与方式として、タスク実施時のパフォーマンスの計測 [8], [9] や主観的評価 [5], [14], [15] などがある。いずれの場合も、システムは評価者である人間に対してタスクや質問を与えてそのフィードバックを得ること (データサンプリング) を反復することで、最適なパラメタ値の組合せを発見する。

BO はサンプル効率性 (少ないデータサンプル数で良い解を発見する性質) の良さを特徴とするブラックボックス最適化手法である [21]。これは、探索と活用を用いた合理的なサンプリング戦略によって実現される。そのサンプル効率性の良さから、BO は深層学習のハイパーパラメタ調整 [1] などで活用されている。人間による評価回数を少なくするため、human-in-the-loop 最適化でもベイズ最適化が活用されている [6], [8], [9], [14], [15], [29]。

デザイン目標が好みなどの主観的評価に依る場合、フィードバックデータの質を安定させるために、単一のデザインに対する絶対評価ではなく複数のデザインに対する相対比較によるフィードバックを用いることが推奨されている [2], [26]。相対比較データを用いて BO を実行する手法は PBO と呼ばれ [10], Brochu ら [3] によって提案され、様々な拡張がなされてきた [6], [14], [15]。汎用技術であるため適用可能範囲が広く、アニメーション [2], 深層学習に

よる画像生成 [6], メロディ生成 [29], 写真撮影時の照明設計 [28] などに適用した研究事例が報告されている。

提案フレームワークは、human-in-the-loop 最適化のフレームワークとはインタラクション設計で異なる。提案フレームワークでは明示的な loop は存在せず、代わりにデザイナーの自由な探索の様子をシステムが観察して暗黙的にデザイン目標を推定し、さらに非同期的にデザイン案を生成してデザイナーを支援できる。本研究は、このように明示的な loop を持たないインタラクションにおいて BO をサジェスト生成に活用する最初の研究である。

3. 提案フレームワークとインタラクション

3.1 フレームワークの概要

提案フレームワークである BO as Assistant では、デザイン案を生成する助手として BO を位置付ける。パラメタ調整タスクを行う主体はデザイナーであり、システムはデザイナーに対して追加の入力を要求することなくデザイン案を生成することでデザイナーのタスク遂行を支援する。デザイナーはデザイン案の生成を待つ必要はないし、それを利用しても無視してもよい。図 1 にコンセプトを、図 2 に我々のコンセプト実証システムのインターフェースを示す。

3.1.1 デザイン案の生成に BO を用いる利点

BO では、多次元のパラメタ空間から探索 (exploration) と活用 (exploitation) の両側面を同時に考慮しながらデザイン案をサンプリングできる利点がある。仮にデザイナーがある程度好ましいデザイン (パラメタ値の組み合わせ) を発見できたとして、実はそこから複数のスライダを大幅に動かした別のデザインの方がより良い可能性があっても、デザイナーがそれに気付くのが難しいことがある。局所解に試行錯誤がとどまり、遠くにある大局解を考慮できなくなるそうした状況を防ぐためには、未探索領域を優先的にサ

ンプリングする「探索の側面」が有益である。一方、有望な領域を優先的に探索する「活用の側面」は、デザイナーのデザイン目標（好みや意図）を考慮するので、そもそも見込みの低いデザインを生成することが防げて有益である。このように両側面を考慮したデザイン案を提示できれば、従来のデザイナーによるスライダ操作のみで自力でデザインを発見するインタラクションに対して、有益な追加情報を与えて支援できる。しかも、仮に提示したデザイン案がデザイン目標の観点で直接有益でなくても、どのようなデザインの可能性があるかというデザイン空間そのものに対するデザイナーの理解を深める上では有益で、それによってデザイナーが自身のスライダ操作によって得たデザインに対してより自信を持つことができる可能性がある。

3.1.2 技術的な要素

提案フレームワークは、以下のステップをバックグラウンドで実行し続ける。

スライダ操作の観察 (6章) システムは、デザイナーがスライダを操作する様子を観察し、その内容から BO を実行するために必要な情報を抽出する。これは、デザイナーが最終的に選んだスライダ値だけではなく、それに至るまでにスライダ値を行ったり来たりさせた際の軌跡も含む。

デザイン目標の推定 (5章) 抽出された情報を用いて、システムはデザイン目標（パラメタ空間中のどの領域がより好ましいか）を推定する。より具体的には、パラメタ値に対してそれに対応するデザインがどの程度好ましいかを予測するモデルを構築する。

デザイン案の生成と提示 (5章) 推定されたデザイン目標のモデルを用いて、システムは最も効果的なデザイン案を生成し、ユーザに対して提示する。

3.2 タスクに対する仮定

提案フレームワークでは対象とするデザインのタスクに対し、以下の仮定を置いている。

パラメタの種類 各パラメタはスライダにマッピングして操作できるように、有限の連続値 (e.g., $[0, 1]$) をとると仮定する。有限の整数値をとるパラメタも、量子化でスライダにマッピングできるので対象となる。

デザイン目標 デザイン目標は、デザイナーが見た目から主観的に評価でき、デザイン探索の途中で時間変化しないことを仮定する。

パラメタの数 同時に扱うパラメタの数は 2 個以上、20 個 (BO が効果的に働く上限の目安として知られている [27]) 以下だと仮定する。

リアルタイムでの表示 スライダ操作に応じて、デザインがリアルタイムに更新表示されることを仮定する。

連続的な変化 パラメタ値が連続的に変化するとき、デザイン自体も連続的に変化すると仮定する。

3.3 デザイン案とのインタラクション

3.3.1 デザイン案のブレンド

システムが提示したデザイン案をデザイナーが選択して利用する際に、そのパラメタ値をそのまま、現在のスライダ値に上書きしてしまう方法が最も単純である。それに対して我々は、対象のデザイン案に対応するパラメタ値と現在のスライダ値とを任意の割合で線形ブレンド（補間）できるアプローチを採用する。これは既存研究 [15] から着想を得たアプローチで、直接上書きする [3] よりも効率的に最適なデザインを発見できることが期待できる。具体的には、各デザイン案に対して一つずつブレンド用のスライダが提供 (図 2) され、デザイナーが対話的にこのブレンド用スライダの値を調整すると、それに追従してデザインの表示とスライダ値がリアルタイムに更新される。好みのデザインになったところで調整をやめれば、そのブレンドの割合で決定され、そこからまたデザイナーは自分でパラメタ調整用スライダで操作できる。

3.3.2 デザイン案の再生成

追加のインタラクションとして、提示中の全デザイン案の再生成をデザイナーがシステムに対して明示的に指示する操作を提供する。スライダ操作をしても他のデザイン案は非同期に生成されるが、デザイナーがこの操作をすれば、迅速に多様なデザイン案を検討できる利点がある。さらに、現在のデザインよりも再生成される前のデザイン案が好ましくない（だからこそ再生成の明示的な指示がきた）とシステムが解釈して観測データに加えることで、よりの確にデザイン目標の推定しやすくなる副次的な利点もある。

4. 問題設定

対象とするデザインパラメタの数を N として、それぞれを $x_i \in [0, 1]$ ($i = 1, \dots, N$) と表記する。また、これらをまとめて $\mathbf{x} = [x_1 \ \dots \ x_N]^T \in \mathcal{X}$ (ただし $\mathcal{X} = [0, 1]^N$) と表記する。このパラメタ調整タスクの目的は、最適なパラメタ値

$$\mathbf{x}^* = \arg \max_{\mathbf{x} \in \mathcal{X}} g(\mathbf{x}) \quad (1)$$

を決定することである。この目的関数 $g: \mathcal{X} \rightarrow \mathbb{R}$ は **goodness 関数** [14] と呼ばれ、デザイナーの主観的な好みの程度 (デザイン目標) を表す。

Goodness 関数の値は、直接観測できない。代わりに、システムはデザイナーのスライダ操作の様子を観察することで、goodness 関数を推定する。基本的な考え方として、デザイナーは goodness 関数の値が大きくなるようにスライダを操作していると想定する。

本研究では、デザイナーに K 個 (我々のコンセプト実証システムの実装では単純化のために $K = 3$ で固定するが、デザインドメインに応じて任意の個数を設定できる) のデザイン案 $\mathbf{x}_1^{\text{suggest}}, \dots, \mathbf{x}_K^{\text{suggest}}$ を提示し、またデザイナーのスラ

イダ操作に応じて随時これらを更新していくことを技術的な目的とする。そして、BO のサンプリング戦略を用いてこれらのデザイン案を非同期に随時生成することで、探索と活用の両方の観点で合理的な支援をすることを目指す。

5. 選好ベイズ最適化 (PBO)

スライダ操作の情報に基づいて PBO を実行する上で必要な情報を抽出する提案技術について述べる前に、この節では前提となる PBO について簡単に説明する。なお、PBO の詳細は [10] を参照されたい。

5.1 選好データのモデリング

PBO では、観測データは絶対評価の関数値 (e.g., $g(\mathbf{x}_A) = 0.1, g(\mathbf{x}_B) = 0.2$) ではなく、相対比較 (e.g., $g(\mathbf{x}_A) < g(\mathbf{x}_B)$) の情報を扱う。より具体的には「 L 個の選択肢 $\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(L)}$ ($L \geq 2$) のうち、第 i 番目の選択肢 $\mathbf{x}^{(i)}$ ($1 \leq i \leq L$) が好まれた」という形式の観測データを扱う。このような観測データを

$$d = [\mathbf{x}^{(i)} \succ \{\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(i-1)}, \mathbf{x}^{(i+1)}, \dots, \mathbf{x}^{(L)}\}] \quad (2)$$

と表記する。また、それぞれの (直接観測できない) goodness 値を $g^{(i)} = g(\mathbf{x}^{(i)})$ ($i = 1, \dots, L$) とし、まとめて $\mathbf{g} = [g^{(1)} \dots g^{(L)}]^\top$ と表記する。先述の選好データの尤度は Bradley–Terry–Luce モデル [26] を用いると

$$p(d | \mathbf{g}) = \frac{\exp(g^{(i)})}{\sum_{j=1}^L \exp(g^{(j)})} \quad (3)$$

とモデル化することができる。選好データが複数ある場合、 $\mathcal{D} = \{d_1, d_2, \dots\}$ と表記すると、その尤度は $p(\mathcal{D} | \mathbf{g}) = \prod_i p(d_i | \mathbf{g})$ となる。従来の human-in-the-loop なフレームワークでは、このような選好データの情報は明示的に評価者に質問をすることで得ることができる。我々は、このような情報をスライダ操作を観察することで抽出することを目指す (6 章)。

5.2 Goodness 値の推定

我々は goodness 関数がガウス過程 (Gaussian process; GP) [19] に従うと仮定する。ここで、これまでに $\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(M)} \in \mathcal{X}$ の M 個の点に関する選好データ \mathcal{D} を観測したとする。これらの点における goodness 値を推定するために、我々は maximum a posteriori (MAP) 推定を用いる [15]。具体的には、

$$\mathbf{g}^{\text{MAP}} = \arg \max_{\mathbf{g} \in \mathbb{R}^M} p(\mathbf{g} | \mathcal{D}) = \arg \max_{\mathbf{g} \in \mathbb{R}^M} p(\mathcal{D} | \mathbf{g}) p(\mathbf{g}) \quad (4)$$

を計算する。ただし、 $p(\mathbf{g})$ は goodness 値の事前分布で、GP の仮定より単純なガウス分布となる。この goodness 関数の推定値を用いることで、まだ観測されていない任意の点 \mathbf{x} における goodness 値の予測分布を

$$g(\mathbf{x}) \sim \mathcal{N}(\mu(\mathbf{x}), \sigma^2(\mathbf{x})) \quad (5)$$

によって計算することができる。平均 μ と分散 σ^2 の具体的な計算方法は PBO [10] または GP [19] を参照されたい。

5.3 サンプリング

BO や PBO では獲得関数と呼ばれる関数を用いて次に観測すべき点 (本研究の場合はデザイン案として提示する点) を決定する。予測分布 (式 (5)) を用いることで、獲得関数 $a: \mathcal{X} \rightarrow \mathbb{R}$ は、任意の点 \mathbf{x} に対してその点が次に観測されたときの“効果”の大きさ (探索と活用の両方を考慮した値として定義される) を計算する。BO や PBO では獲得関数 a の値が大きい点 (例えば最大となる点) をサンプリングして評価者への次の質問に利用することでサンプル効率性が実現される。なお、Schonlau ら [20] の手法などを利用することで、同時に多数の互いに異なる点をサンプリングすることができる。本研究では K 個の多様なデザイン案をサンプリングするために Schonlau らの手法を用いる。獲得関数の詳細については [21] が詳しい。

6. 選好データの抽出手法

6.1 スライダ操作からの抽出技術

6.1.1 スライダ操作セッション

スライダインタフェースでは、同時に 1 つのスライダしか操作することはできない。ここでは、あるスライダのノブをマウスで押し、ドラッグすることでノブを行ったり来たりさせ、ある位置でマウスをリリースする一連の流れをセッションと呼ぶことにする。提案技術では、1 つのセッションから 1 つの選好データを抽出する。なお、複数のセッションにまたがって解析して選好データを抽出することは、ここでは扱わずに将来課題とする。

キーとなるアイデアは、デザイナーはスライダを操作する際に、その 1 次元の探索空間の中でより goodness 値の高い点を探してそこでマウスをリリースするであろう、という発想である。図 3 にこのアイデアを示す。このアイデアに基づいて選好データを抽出する方法はいくつか考案することが可能であるが、ここでは我々のコンセプト実証システムの実装で採用した 1 つだけを紹介する。他の方法については [11] を参照されたい。

6.1.2 戦略

ここで、 N 個のスライダのうち第 i 番目のものをデザイナーが操作するセッションについて考える。システムはスライダ値の時系列変化を全て記録する。記録されたスライダ値のリストを $s = (\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(n_s)})$ と表記する (ただし $n_s = |s|$)。

選好データを抽出する上で、マウスがリリースされた最後の点 $\mathbf{x}^{(n_s)}$ が、 s の中で最も好ましい点であると仮定することは自然である。そこで以下では、比較対象となる点

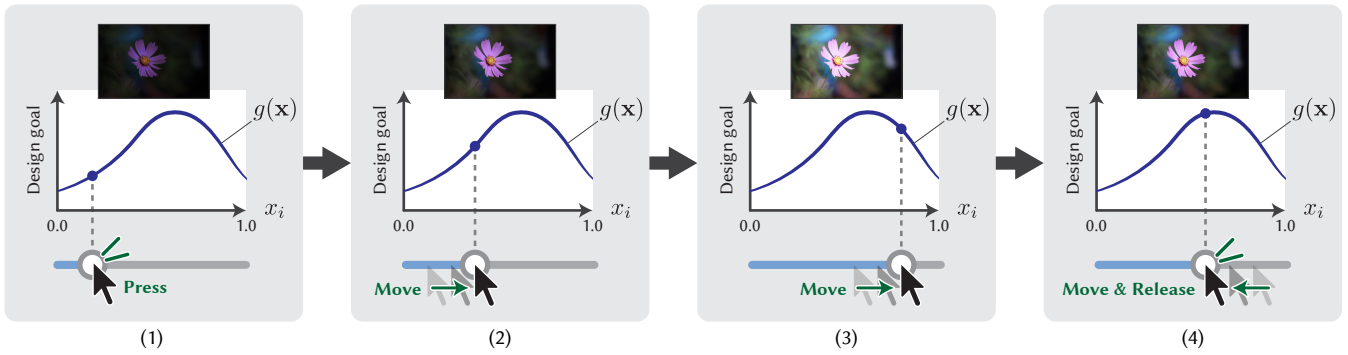


図 3 スライダー操作セッションの様子. この例では画像の明るさを調整するためにデザイナーがスライダーを試行錯誤しながら左右に動かしている. (1) パラメタ値を増やすため, デザイナーがスライダーのノブを押して右に動かす. (2) ノブを動かしながら, デザインのプレビュー表示が変化の様子を見ていくと, 画像はより良くなってきている (goodness 値が大きくなってきている). (3) 画像が悪くなり始めてきた (goodness 値が小さくなり始めた) とき, デザイナーはスライダーを右に動かすすぎた (パラメタ値を大きくしすぎた) ことが原因だとわかる. (4) デザイナーはスライダーを左に戻して適切な値になったらノブを離す. このノブの最終的な位置は, この 1 次元の探索空間においては, goodness 関数 g の最大値の周辺であると仮定できる.

の抽出について考える. まずナイーブな発想として, 最初の点 $\mathbf{x}^{(1)}$ のみを比較対象 (最後の点よりも相対的に好ましくない点) とすることが考えられるが, これでは得られる情報が少なく, 効果的でない. 次に, 最後の点を除く全ての点を比較対象とすることがあり得るが, これは計算量の観点から現実的でないなどの問題がある.

そこで本研究では“折り返し”の点を抽出する方法を採用する. 例えば, 図 3 のように, スライダーを右に動かしていた後に左に動き始めたならば, その点が折り返し点である. この方法の着想を以下に述べる. スライダー操作によりパラメタ値を増加させている最中は, デザイナーは「より大きな値の方が好ましいデザインになるはずだ」という信念で動かしており, その後折り返して値を減少させ始めるということは, 折り返し点において「値を大きくしすぎてしまい, 好ましいデザインではなくなってきた」ということを考えたため, そのような折り返しを行ったと考えることができる. したがって, 折り返し点はデザイナーが明確な意図を持って「好ましくない」と判断したと解釈できる. 以上の発想に基づき, 1 つのスライダー操作セッションから

$$d = [\mathbf{x}^{(n_s)} \succ \{\mathbf{x}^{(1)}\} \cup \{s \text{ 中の折り返し点の集合}\}] \quad (6)$$

という選好データを抽出する. なおセッション s の中の j 番目の点 ($j = 2, \dots, n_s - 1$) が折り返し点であるかどうかは

$$(x_i^{(j+1)} - x_i^{(j)})(x_i^{(j)} - x_i^{(j-1)}) < 0 \quad (7)$$

の真偽値で判定することができる.

6.1.3 動作例

提案フレームワークの挙動を示すため, 図 4 に例示したスライダー操作履歴データに対して, PBO がどのような推

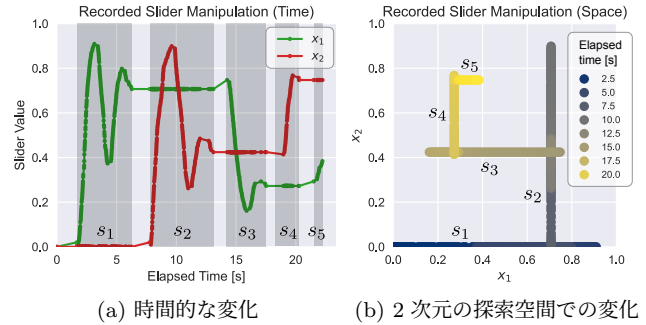


図 4 2 次元の探索空間でのスライダー操作履歴データの例. 2 個のスライダー (x_1 と x_2 にそれぞれ対応) が交互に操作されていて, 5 個のスライダー操作セッション (s_1, \dots, s_5) が行われている.

定を行い, どのようなデザイン案 (パラメタ値の組み合わせ) が生成されたかを可視化する. このデータは 2 個のスライダーを対象として, 合計で 5 個のスライダー操作セッションを行ったことを表している.

図 5 に可視化結果を示す. オレンジの点は選好データに關与するデータ点 (つまりスライダー操作前後の点と折り返し点) を表し, ブルーの点はそこまでの観測データに基づいて生成されたデザイン案の 3 個の点 ($K = 3$) を表す. デザイン案は獲得関数 a の値が大きい領域からサンプリングされている. 大まかに, 獲得関数 a は予測分布の平均 μ と標準偏差 σ (平均が「活用」(exploitation), 標準偏差が「探索」(exploration) に対応する) が共に大きい領域で大きい値をとる性質があり, 図 5 でもその性質を観察することができる.

6.2 ブレンド操作からの抽出

ブレンド操作により, デザイナーは現在のパラメタ値とデ

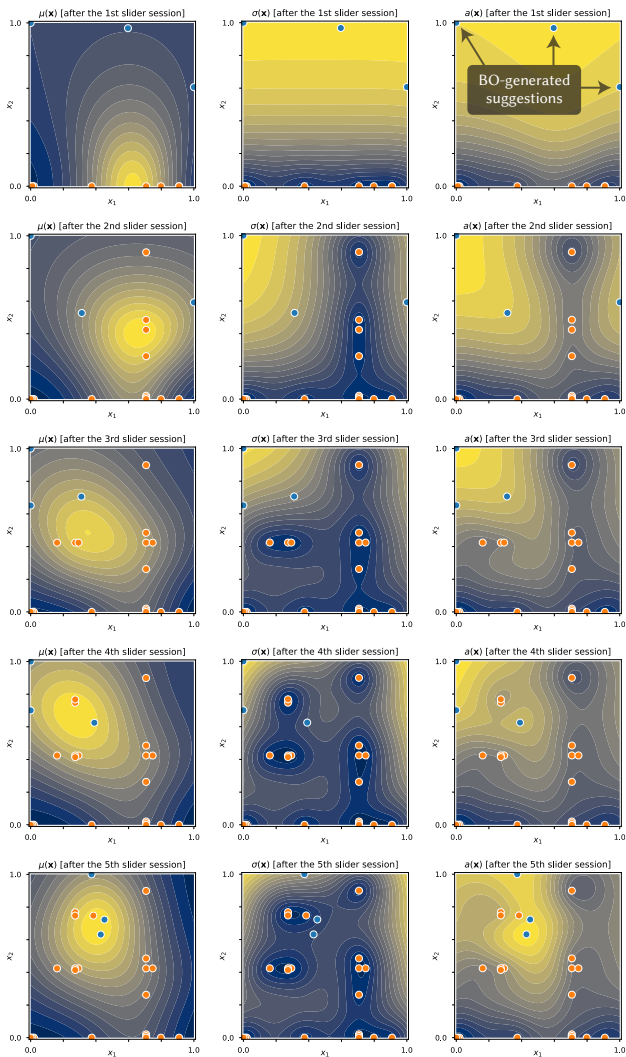


図5 図4のスライダー操作データから折り返しの点を抽出する方法で得られたBOの内部モデル (i.e., $\mu(\mathbf{x})$, $\sigma(\mathbf{x})$, and $a(\mathbf{x})$) の可視化結果。オレンジの点はBOで使われたデータ点を表す。ブルーの点はBOによって生成されたデザイン案を表す。(左) 予測分布の平均 $\mu(\mathbf{x})$ 。推定されたデザイン目標 (有望な度合い) を表す。(中央) 予測分布の標準偏差 $\sigma(\mathbf{x})$ 。未探索で不確実な度合いを表す。(右) 獲得関数 $a(\mathbf{x})$ 。デザイン案のサンプリングに用いられる。

デザイン案のパラメタ値とを任意の重みで線形ブレンドすることができる。ブレンド結果は最も好ましいはずであり、ブレンド前のデザインや選ばれなかったデザイン案が相対的に好ましくないはずであるという発想から、選好データを抽出できる。ここで、第 i 番目のデザイン案がブレンド対象となった場合について考える。ブレンド結果のパラメタ値を $\mathbf{x}^{\text{blend}}$ とすると、ここから選好データ

$$d = [\mathbf{x}^{\text{blend}} \succ \{\mathbf{x}^{\text{current}}, \mathbf{x}_1^{\text{suggest}}, \dots, \mathbf{x}_K^{\text{suggest}}\}] \quad (8)$$

を抽出し、デザイン目標の推定に利用することができる。

6.3 デザイン案再生成からの抽出

デザイナーが全デザイン案の再生成を明示的に指示すると

き、生成前のデザイン案はいずれも現在のデザインよりも好ましくなく、採用に至らなかったということを暗示していると解釈できる。このことから、

$$d = [\mathbf{x}^{\text{current}} \succ \{\mathbf{x}_1^{\text{suggest}}, \dots, \mathbf{x}_K^{\text{suggest}}\}] \quad (9)$$

という選好データを抽出できる。この選好データを考慮してPBOのサンプリングを行うことで、再生成前とは異なるデザイン案を生成することが可能である。

7. 一般性の実証

提案フレームワークの一般性を実証するため、コンピュータグラフィックスに関連する3種類の異なるドメインのパラメトリックデザインに適用した結果を示す。

7.1 写真の色調補正

写真の色調補正では、明るさやコントラストなど多数のパラメタを調整することで写真の見た目を好ましくするという作業が行われる。ここでは、既存研究 [14] で用いられた12個のパラメタを用いた写真の色調補正アプリケーションをスタンドアロンシステムとして実装した。図6に、二つの異なる写真に対して提案フレームワークを用いて色調補正を実施した様子を示す。写真が異なればデザイン目標も異なるため、異なる色調のデザイン案が提示されている。

7.2 プロシージャルモデリング

プロシージャルモデリングとは多数の手続きを組み合わせることで形状をデザインする3Dモデリング手法の一種 [24] で、映像制作、メカニカル設計、建築、デジタルファブリケーションなど様々なドメインで活用されている。ここではBlenderのaddonとして提案フレームワークを実装し、デジタルファブリケーションを想定した6次元のプロシージャル形状モデルに対して適用した。プロシージャルシステムおよびデザインのリアルタイム表示はBlenderの標準機能を用いており、デザイン案は現在のデザインの右側に表示するように実装した。図7に三つの異なるデザイン目標を想定してパラメタ調整を行った様子を示す。なお、同じプロシージャル形状モデルであっても、スライダー操作の観察からデザイン目標をその場で推定し、適応的にデザイン案を提示できていることが分かる。

7.3 プロシージャルマテリアル生成

プロシージャルマテリアル生成とは、3Dコンピュータグラフィックスにおけるマテリアルの反射特性の空間分布を、多数の手続きを組み合わせることでデザインする手法であり、映像制作やゲーム制作などで広く用いられている。ここでは、Blenderのaddonとして提案フレームワークを実装し、所望のマテリアル (ここではペンキが剥げかかっている錆びた金属) を生成するために8つのパラメタを調整

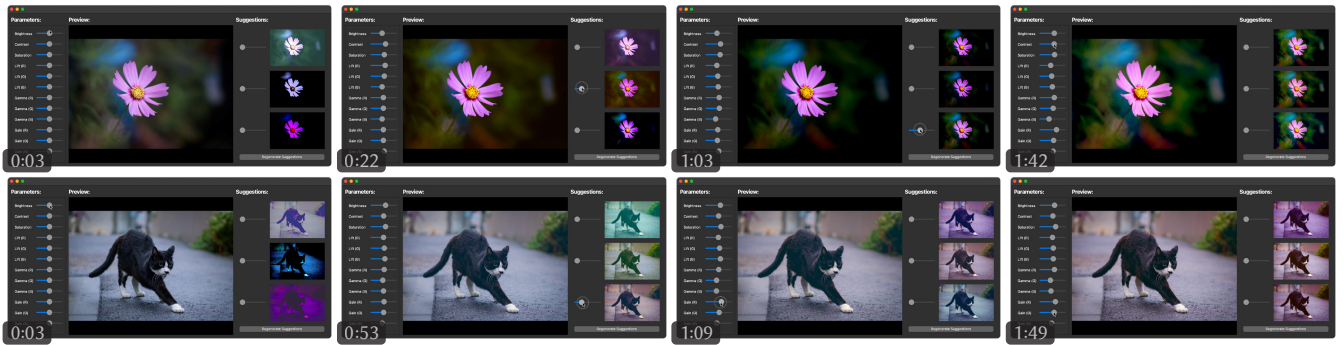


図 6 写真の色調補正（12パラメータ）での二つのデザイン事例（上段と下段）のスクリーンショット例。デザイナーが望ましいと思うパラメータ調整の仕方は写真ごとに異なっているが、デザイナーのスライダ操作のみからデザイン目標を推定して、三つのデザイン案を適応的に提示できている。各スクリーンショットは、参考資料のデモビデオからの抜粋で、左下に各事例内の経過時間を示してある。

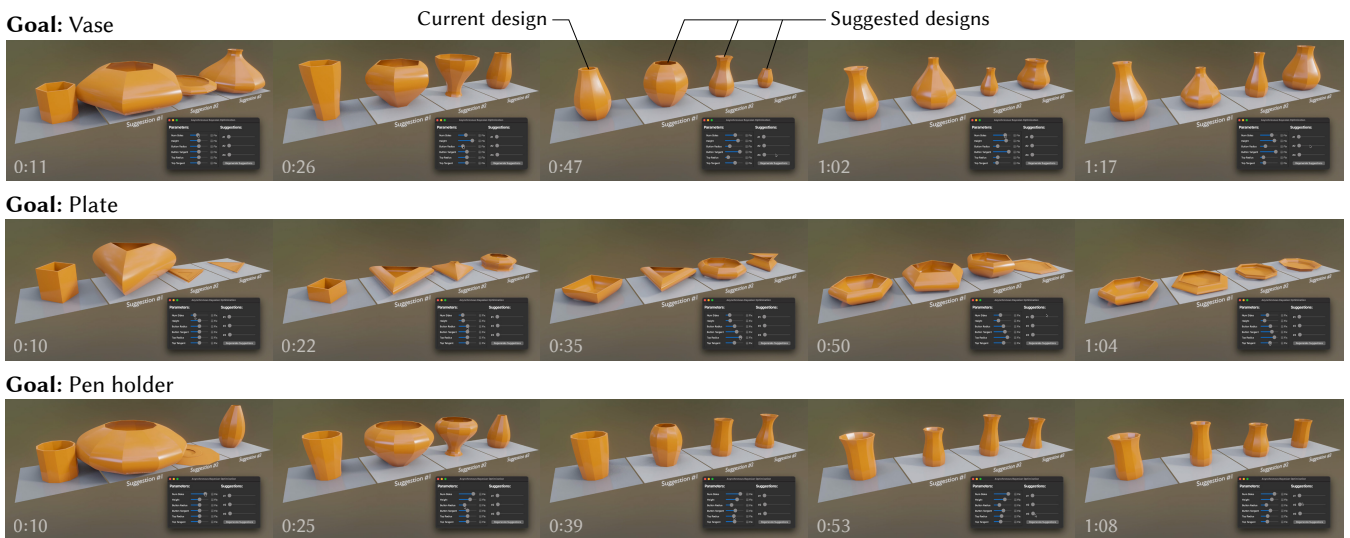


図 7 プロシージャルモデリング（6パラメータ）での三つのデザイン事例（上段、中段、下段）のスクリーンショット例。全事例で同じプロシージャルモデルが使われているが、事例毎に、花瓶、平皿、ペン立てをデザインするという異なるデザイン目標が与えられている。デザイナーのスライダ操作のみからデザイン目標を推定して、三つのデザイン案を適応的に提示できている。各スクリーンショットは、参考資料のデモビデオからの抜粋で、左下に各事例内の経過時間を示してある。

するタスクに対して適用した。プロシージャルシステムおよびデザインのリアルタイム表示はBlenderの標準機能を用いており、デザイン案は現在のデザインの右側に表示するように実装した。図8にパラメータ調整の過程を示す。デザイン目標の推定が進んだ後半にはより目標の主旨に沿ったデザイン案が提示されている。

8. 議論と将来展望

8.1 スライダ操作に関する仮定

我々が提案したスライダ操作履歴から選好データを抽出する技術は、各スライダ操作セッションでデザイナーが常により好ましいデザインを発見することを仮定している。7章で示した通り、この仮定はある程度は妥当であると考え

られるが、この仮定の妥当性の検証を実際のデータを用いて行っていないことは本研究のリミテーションである。この仮定が成立しない挙動（例えばあるスライダ操作セッションで行った変更を、次のスライダ操作セッションで取り消した場合など）をデザイナーがした場合、矛盾する選好データが蓄積されることからデザイン目標の推定精度が下がり、デザイン案生成における活用（有望な領域を優先的にサンプリングする性質）が期待通りの効果を発揮しない可能性がある。なおこの場合であっても、探索（未探索領域を優先的にサンプリングする性質）は影響を受けず、またデザイン案が役に立たないときは単にデザイン案をデザイナーが無視すればよいため、従来のスライダのみのタスク遂行に比べて大きな悪影響はないと考えられる。



図 8 プロシージャルマテリアル生成 (8 パラメータ) でのデザイン事例のスクリーンショット例。ペンキが剥げかかっている錆びた金属のデザインにするというデザイン目標が与えられている。各スクリーンショットは、参考資料のデモビデオからの抜粋で、左下に経過時間を示してある。 Bastien Genbrugge 氏によって CC BY 4.0 のライセンスの元で提供された 3D モデル (<https://skfb.ly/6pNQ6>) を使用した。

8.2 好みに関する仮定

本研究ではデザイナーは時間変化しない好みを持っていることを仮定するが、実際にはデザインを探索する中で好みが変わることがありえる。このような変化に対応するには、変化を検出してそれ以前のデータを破棄する処理を考案するなど、更なる技術的な検討が必要である。なお、この好みに関する仮定は、初めから最終的なデザインについて具体的なイメージがあることを要求するものではない点に注意されたい。デザイナーは最終的なイメージを持っている必要はないが、探索中に目にしたデザインについて相対的により好ましいデザインを選択できることが要求される。

8.3 行為主体感の評価

従来の designer-in-the-loop 最適化の枠組みに比べて、提案フレームワークはデザイナーに対してより強い行為主体感を与えることが期待される [4] が、その程度や性質についてユーザ実験などを通して理解を深めることは、将来取り組むべき重要な研究課題である。その理解が深まれば、将来の human-AI collaboration システムの設計指針にも寄与できる可能性がある。

8.4 ユーザビリティおよび有用性の評価

本研究の焦点は新しいコンピューショナルインタラクションの汎用コンセプトを技術的に実現することにあり、

その結果得られるユーザ体験の評価は本稿の範囲を超える。とはいえ、提案フレームワークのユーザビリティ、実際のタスク遂行における寄与度合い、想定ユーザにとっての提示されたデザイン案の有用性などを評価することは、提案するコンセプトをより理解する上で重要であり、議論が不足する点は本研究のリミテーションである。そのような評価は、将来研究において、特定のドメインに特化してツールを作り込み、ドメイン知識や実験参加者の持つ専門性を考慮して実験設計を行うことが望ましい。

8.5 創造性支援

我々は、本研究が創造性支援ツール [23] の研究者も触発できればと願っている。創造的なアイデアは独創性と有用性に関連していることが既存研究等で議論されてきた [16] が、BO における探索と活用もそれぞれ独創性と有用性に関連するコンセプトであり、創造性との関連性を議論できる可能性がある。その際、「BO で生成された提案は創造的か?」「BO は創造性を支援できるのか?」という問いは興味深く、それに答えるためにはさらなる研究が必要である。

9. おわりに

本稿では、システムから提示されたデザイン案をデザイナーが明示的に評価しなくても、パラメータ調整用スライダを操作してデザインを探索しているだけで支援を受けられる

フレームワーク BO as Assistant を提案した。主な貢献として、(1) 「提案する助手」という役割を BO がする新たなフレームワークの提案、(2) スライド操作から選好データを抽出して BO を実行する新たな手法の提案、(3) 3種類の異なるデザインドメインでのフレームワークの一般性の実証の3点が挙げられる。我々はこれが BO の未知の可能性を引き出し、より多様な状況下でベイズ手法を人間中心に活用していくための重要な一歩になると信じている。

謝辞 本研究の一部は JST CREST JPMJCR20D4 の支援を受けた。図 8 で用いた 3D モデルは Bastien Genbrugge 氏によって CC BY 4.0 のライセンスの元で提供されたものであり、我々は提案フレームワークの実証のためにそのマテリアルを変更した。

参考文献

- [1] Akiba, T., Sano, S., Yanase, T., Ohta, T. and Koyama, M.: Optuna: A Next-Generation Hyperparameter Optimization Framework, *Proc. KDD '19*, pp. 2623–2631 (2019).
- [2] Brochu, E., Brochu, T. and de Freitas, N.: A Bayesian Interactive Optimization Approach to Procedural Animation Design, *Proc. SCA '10*, pp. 103–112 (2010).
- [3] Brochu, E., de Freitas, N. and Ghosh, A.: Active Preference Learning with Discrete Choice Data, *Proc. NIPS '07*, pp. 409–416 (2007).
- [4] Chan, L., Liao, Y.-C., Mo, G. B., Dudley, J. J., Cheng, C.-L., Kristensson, P. O. and Oulasvirta, A.: Investigating Positive and Negative Qualities of Human-in-the-Loop Optimization for Designing Interaction Techniques, *Proc. CHI '22*, pp. 112:1–112:14 (2022).
- [5] Chiu, C.-H., Koyama, Y., Lai, Y.-C., Igarashi, T. and Yue, Y.: Human-in-the-Loop Differential Subspace Search in High-Dimensional Latent Space, *ACM Trans. Graph.*, Vol. 39, No. 4, pp. 85:1–85:15 (2020).
- [6] Chong, T., Shen, I.-C., Sato, I. and Igarashi, T.: Interactive Optimization of Generative Image Modelling using Sequential Subspace Search and Content-based Guidance, *Comput. Graph. Forum*, Vol. 40, No. 1, pp. 279–292 (2021).
- [7] Desai, R., Anderson, F., Matejka, J., Coros, S., McCann, J., Fitzmaurice, G. and Grossman, T.: Geppetto: Enabling Semantic Design of Expressive Robot Behaviors, *Proc. CHI '19*, pp. 369:1–369:14 (2019).
- [8] Dudley, J. J., Jacques, J. T. and Kristensson, P. O.: Crowdsourcing Interface Feature Design with Bayesian Optimization, *Proc. CHI '19*, pp. 252:1–252:12 (2019).
- [9] Khajah, M. M., Roads, B. D., Lindsey, R. V., Liu, Y.-E. and Mozer, M. C.: Designing Engaging Games Using Bayesian Optimization, *Proc. CHI '16*, pp. 5571–5582 (2016).
- [10] Koyama, Y., Cheng, T. and Igarashi, T.: Preferential Bayesian Optimisation for Visual Design, *Bayesian Methods for Interaction and Design* (Williamson, J. H., Oulasvirta, A., Kristensson, P. O. and Banovic, N., eds.), Cambridge University Press, chapter 8, pp. 239–258 (2022).
- [11] Koyama, Y. and Goto, M.: BO as Assistant: Using Bayesian Optimization for Asynchronously Generating Design Suggestions, *Proc. UIST '22* (2022).
- [12] Koyama, Y., Sakamoto, D. and Igarashi, T.: Crowd-Powered Parameter Analysis for Visual Design Exploration, *Proc. UIST '14*, pp. 65–74 (2014).
- [13] Koyama, Y., Sakamoto, D. and Igarashi, T.: SelPh: Progressive Learning and Support of Manual Photo Color Enhancement, *Proc. CHI '16*, pp. 2520–2532 (2016).
- [14] Koyama, Y., Sato, I. and Goto, M.: Sequential Gallery for Interactive Visual Design Optimization, *ACM Trans. Graph.*, Vol. 39, No. 4, pp. 88:1–88:12 (2020).
- [15] Koyama, Y., Sato, I., Sakamoto, D. and Igarashi, T.: Sequential Line Search for Efficient Visual Design Optimization by Crowds, *ACM Trans. Graph.*, Vol. 36, No. 4, pp. 48:1–48:11 (2017).
- [16] Kozbelt, A., Beghetto, R. A. and Runco, M. A.: Theories of Creativity, *The Cambridge Handbook of Creativity* (Kaufman, J. C. and Sternberg, R. J., eds.), Cambridge University Press, chapter 2, pp. 20–47 (2010).
- [17] Marks, J., Andalman, B., Beardsley, P. A., Freeman, W. T., Gibson, S. F., Hodgins, J. K., Kang, T., Mirtich, B., Pfister, H., Ruml, W., Ryall, K., Seims, J. E. and Shieber, S. M.: Design Galleries: A General Approach to Setting Parameters for Computer Graphics and Animation, *Proc. SIGGRAPH '97*, pp. 389–400 (1997).
- [18] O'Donovan, P., Agarwala, A. and Hertzmann, A.: DesignScape: Design with Interactive Layout Suggestions, *Proc. CHI '15*, pp. 1221–1224 (2015).
- [19] Rasmussen, C. E. and Williams, C. K. I.: *Gaussian Processes for Machine Learning*, The MIT Press (2005).
- [20] Schonlau, M., Welch, W. J. and Jones, D. R.: Global versus local search in constrained optimization of computer models, *IMS Lecture Notes—Monograph Series*, Vol. 34, No. 1, pp. 11–25 (1998).
- [21] Shahriari, B., Swersky, K., Wang, Z., Adams, R. P. and de Freitas, N.: Taking the Human Out of the Loop: A Review of Bayesian Optimization, *Proc. IEEE*, Vol. 104, No. 1, pp. 148–175 (2016).
- [22] Shimizu, E., Fisher, M., Paris, S., McCann, J. and Fatahalian, K.: Design Adjectives: A Framework for Interactive Model-Guided Exploration of Parameterized Design Spaces, *Proc. UIST '20*, pp. 261–278 (2020).
- [23] Shneiderman, B.: Creativity Support Tools: Accelerating Discovery and Innovation, *Commun. ACM*, Vol. 50, No. 12, pp. 20–32 (2007).
- [24] Smelik, R. M., Tutenel, T., Bidarra, R. and Benes, B.: A Survey on Procedural Modelling for Virtual Worlds, *Comput. Graph. Forum*, Vol. 33, No. 6, pp. 31–50 (2014).
- [25] Todi, K., Weir, D. and Oulasvirta, A.: Sketchplore: Sketch and Explore with a Layout Optimiser, *Proc. DIS '16*, pp. 543–555 (2016).
- [26] Tsukida, K. and Gupta, M. R.: How to Analyze Paired Comparison Data, Technical Report UWEETR-2011-0004, University of Washington, Department of Electrical Engineering (2011).
- [27] Wang, Z., Zoghi, M., Hutter, F., Matheson, D. and de Freitas, N.: Bayesian Optimization in a Billion Dimensions via Random Embeddings, *J. Artif. Intell. Res.*, Vol. 55, pp. 361–387 (2016).
- [28] Yamamoto, K., Koyama, Y. and Ochiai, Y.: Photographic Lighting Design with Photographer-in-the-Loop Bayesian Optimization, *Proc. UIST '22* (2022).
- [29] Zhou, Y., Koyama, Y., Goto, M. and Igarashi, T.: Generative Melody Composition with Human-in-the-Loop Bayesian Optimization, *Proc. CSMC-MuMe '20*, pp. 21:1–21:10 (2020).