

令和6年度

静岡大学大学院 総合科学技術研究科

工学専攻 数理システム工学コース

修士論文

実測データの学習に基づく
油絵の具の混色支援システム

指導教員

岡部誠 准教授

提出者

51335014 土井遼太郎

提出日

2025年2月3日

目次

第1章 序論.....	4
第2章 関連研究	9
2.1 クリエイティビティサポートツール.....	9
2.2 デジタルでの絵の具に関連した研究.....	10
2.3 現実世界での絵の具の混色に関連した研究	11
第3章 第一の提案手法.....	14
3.1 学習のベースモデル	15
3.2 データセットの作成.....	16
3.3 ファインチューニング.....	17
3.3.1 実際の絵の具の混合データの取得.....	17
3.3.2 照明環境による色変化の撮影.....	18
3.3.3 フレームごとのデータ作成.....	19
3.4 モデルの学習	20
3.4.1 ベースモデルの学習.....	20
3.4.2 モデルのファインチューニング.....	20
3.5 ユーザーインターフェース.....	22
3.5.1 最初の混色.....	22

3.5.2 段階的な調整.....	23
第4章 第一の提案手法における結果と考察	24
4.1 筆者自身による色再現実験①	24
4.2 ユーザテスト①	25
4.2.1 ユーザテスト①のやり方	25
4.2.2 ユーザテスト①の結果	26
4.2.2 考察	27
第5章 第二の提案手法.....	29
5.1 学習モデル	29
5.1.1 ベースモデルの学習とデータセットの作成	29
5.1.2 ファインチューニング	29
5.1.3 モデルの学習.....	30
5.1.4 ファインチューニングの効果の検証例	31
5.2 ユーザインターフェース.....	33
5.2.1 自動的な色取得とリアルタイムな予測表示	33
5.2.2 照明環境による影響を低減させるための工夫....	35
第6章 第二の提案手法における結果と考察	37
6.1 筆者自身による色再現実験②	37

6.2 ユーザテスト②	39
6.2.1 ユーザテスト②のやり方	39
6.2.2 ユーザテスト②の結果	43
6.3 考察.....	47
6.3.1 筆者自身の結果とユーザテストの結果の乖離....	47
6.3.2 アンケートから見るシステム導入のメリット.....	48
第7章 まとめと今後の展望.....	51
謝辞	52
参考文献.....	53
付録 A 実際にユーザに配布したマニュアル	55

第1章 序論

「絵を描く」という行為は人間の芸術的な自己表現の代表例であり、現在でも根強い人気を誇り続ける趣味の一つである。パソコンやタブレットなどのデジタルツールを用いたデジタルアートが急速に普及している一方、筆と絵の具を使って紙やキャンバスに絵を描くアナログアートの人気も依然として高く、国内だけでもそれに携わる人の数は数百万人に上るとされている([1, 2])。実際に、絵の具を使って絵を描くという技法は、絵画制作における代表的かつ歴史的な技法であり、多くの人が学校の授業などで一度は絵の具や筆を使って何かしらの絵を描いたことがあるのではないだろうか。

アナログアートにおいては、基本的に紙・筆・絵の具さえあれば制作を始められるが、一般的には手元にある絵の具の色数は限られている。そのため、描きたい物の色を忠実に再現したい場合や、身の回りに存在する色を真似して使いたい場合、頭の中にイメージした色を実際に使いたい場合などに、持っている絵の具同士を混ぜ合わせることによって使いたい色を新たに作る「混色」が必要となる。

混色はアナログアートにおける基本的かつ重要な作業であり、作品の表現力を高める上でも欠かせない。絵の具を混ぜ合わせることによって、単色では表現しきれないような独自の色を作り出すことができるようになるのである。例えば、図 1 に示すように「赤色」と一口に言っても、その色調には大きな幅が存在する。このように色には微妙な違いがあり、それらを忠実に表現するためには混色が欠かせない。混色を用いることで、単純な色の再現にとどまらず、自然物や独自のイメージに近い色を作り出し、作品にさらなる奥行きと魅力を加えることが可能となる。



図 1. 赤色系の色の多様性. CARMINE や WATERMELON など、色調ごとに異なるニュアンスを持つ多様な赤色が存在する. [26]

しかし、自分で絵の具同士を混ぜて使いたい色を作る際に、どの色の絵の具をどのくらいずつ混ぜ合わせる必要があるかを正しく判断することは多くの人にとって非常に困難であり、欲しい色を即座に思い通りに作れる人は少ない。例えば、図 2(a)はゴッホの代表的な作品「ひまわり」であるが、このひまわりの花びらの色を自分の絵で使ってみてみたいと思ったとしよう。ところが、実際に手元にある絵の具は図 2(b)のような 12 色のみであり、これらの色をそれぞれどれくらいずつ混ぜれば、この色になるかを瞬時に分かる人はいない。混色とは感覚的・経験的な作業であるため、プロのアーティストや熟練者などの色作りが得意な一部の人間であれば、ある程度時間をかければこの色と全く同じ色を再現することができるかもしれないが、たとえプロの画家であっても試行錯誤を繰り返す必要があり、即座に作れるわけではない。

実際に、図 2(c)に示すように、ひまわりの花びらの色に近い色紙の色を手元の絵の具で再現しようとした際の結果からも、必要な色の組み合わせや比率を正しく見極めることがいかに困難であるかがうかがえる。そこで我々は、絵の具を使って絵を描く際に、誰でも簡単かつ正確に使いたい色を作れるように絵の具の混色を支援するシステムの開発を目的としている。




図 2. (a) ゴッホの代表的な作品の一つである“ひまわり”[27]. (b) 一般的な 12 色セットの絵の具(クサカベ習作用油絵具[3]). (c) 色紙と同じ色を絵の具で再現することを試みた結果の一例. 何度かチャレンジしたが、色紙と同じ黄色を作りことはできなかった。

絵の具の混色をサポートする従来の手法としては、混色比率が示された色見本を参考にして色を混ぜる方法が一般的に知られている。しかし、その色見本を完全に再現するためには、人間が正確に比率を量らなければならず、手間や経験を要する。さらに、自分が使いたい色が色見本に掲載されているとは限らないなどの制約もある。また、図 3 は本研究で使用する絵の具セットに付属している混色ガイドの例である。このガイドでは、セット内の絵の具を 2~3 色組み合わせることで得られる色を例示しており、初心者にとってはある程度の指標となる点が利点である。しかし、ガイドにない色を作りたい場合の応用が難しく、結局は試行錯誤に頼らざるを得ないという問題がある。その他の方法として、物体の色を認識してその色を絵の具で自動生成してくれる装置[4]などが存在する。しかし、これは専用のデバイスが必要となるため、誰もが利用できる方法ではない。また、絵の具の混色に関するツールとしては、デジタルペイントソフト上で実際の絵の具が混ざったように色を表現できる Mix Box というツール[5]が存在する。しかし、このツールはあくまでデジタルペイントソフト上の話であり、現実の絵の具の混色をサポートするツールではない。

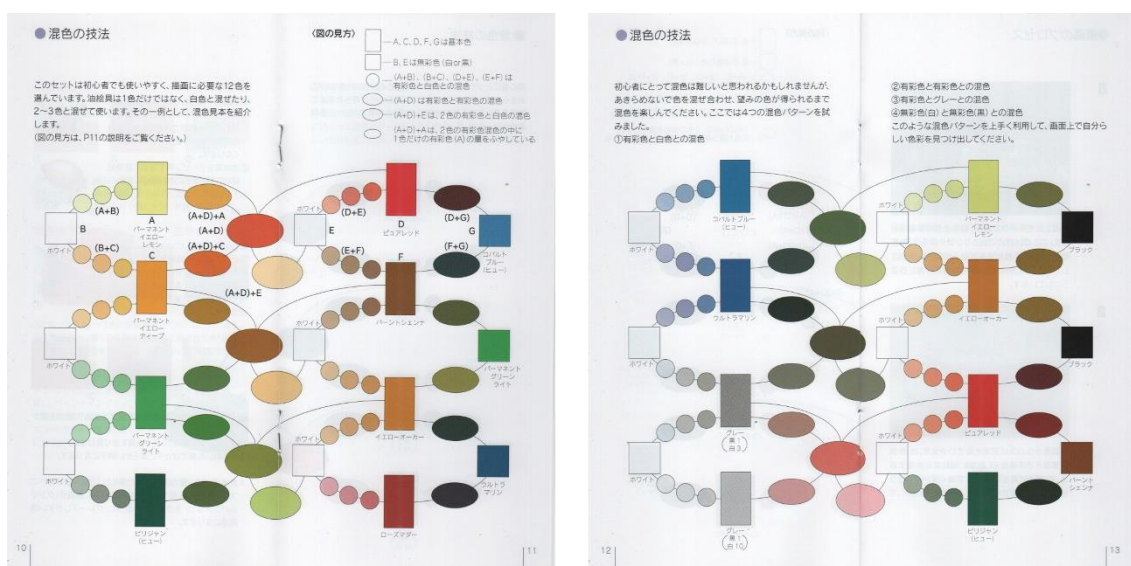


図 3. 提案手法で使用する絵の具セット(図 2(b))に付属されている絵の具の混色ガイド。

そこで本研究では、油絵の具を対象としながら、従来の色見本や専用装置に頼ることなく、誰でも素早く正確に混色を行えるシステムの構築を目指す。具体的には、混色のベースとなる色(混ぜている途中の色)に対して、あらかじめ用意された絵の具セットの中から「どの色の絵の具をどの程度混ぜればターゲットとなる色に近づくか」を推測する学習モデルを構築し、これを活用した油絵の具の混色支援 Web アプリケーションを開発する。まず、絵の具の混色結果を RGB 値でシミュレート可能な Mix Box を用いて大規模な仮想データセットを作成し、そのデータをもとにニューラルネットワークに混色の基本的な傾向を学習させる。さらに、本研究で使用する絵の具セットを実際に混ぜ合わせたサンプリングデータを加えてファインチューニングを行うことで、絵の具個々の特性などの現実的な要素をモデルに反映させたモデルを構築した。

学習モデルを組み込んだ最初の Web アプリケーション(第一の提案手法)では、作りたい色とベースとなる色をカメラでそれぞれ撮影し、事前に用意された絵の具セット(図 2(b))の中のどの色をどれくらいの比率でベースの色と混合すれば良いかの予測結果を提示する。ユーザはこの予測結果を参考にして実際に混色を行い、もし一度の混色で作りたい色を再現しきれない場合でも、ユーザが混ぜた色を再度ベースの色として撮影し予測を実行する。これにより、ユーザは段階的に混色を重ねながらターゲットとなる色に近づくことができ、一定の色の再現には成功した。しかし、このアプリケーションを使ったユーザテストの結果、ターゲットとなる色の再現速度や精度が期待を下回ったほか、カメラ撮影作業が煩雑な点や混色比率の提示が直感的ではない点、さらに照明環境を考慮したファインチューニングが十分に機能しない点などの様々な課題が明らかとなった。

そこで、これらの問題を踏まえて学習モデルやワークフロー、ユーザインターフェースを改良した新たな Web アプリケーション(第二の提案手法)では、リアルタイムに予測結果を提示する仕組みを採用しつつ、「実際に使用する絵の具の混ざり方」のみを考慮したファインチューニングを行い、照明環境による影響に関しては、システムの使用方法における工夫で低減する設計へと変更した。具体的には、アプリ

ケーションの画面内でカメラ映像を常時表示し、指定した領域でユーザが混色を行うと、ベースの色に対して最も追加すべき絵の具とその大まかな配合量がリアルタイムに画面に提示される(図 4)。また、ターゲットの色とベースの色が受ける環境光の差を可能な限り抑えるために、絵の具を混ぜるエリアからスマートフォンを適度に離して撮影するワークフローを採用している。これにより、二つの色に当たる照明角度や光量の極端な差を軽減できるように工夫している。

以上の提案手法を筆者自身が使用した結果、最小限の手間で作りたい色を正確かつ素早く再現することが可能となった(図 5)。また、既存の手法(ユーザの試行錯誤のみによる混色)と提案システムを利用した混色を比較して、ターゲットとなる色の再現精度と速度がどの程度向上するかを評価するユーザテストも行った。ユーザテストの結果、ターゲット色とユーザが作った色の精度を比べるとシステム利用時の方がわずかに精度が高い結果となったが、作業時間を比較すると大きな差はみられなかった。しかしながら、実際にシステムを利用したユーザへのアンケートの結果からは、「何色を追加するか悩む時間が減った」といった意見や「自分が予想もしていなかった色の追加を推奨され、それに従ったことによって目的の色に近づいた」といった意見があった。これらの意見や、システム利用時の方が僅かながらに精度が上がったことから、システムが実際の混色の場面で支援ツールとして役に立つことを確認した。

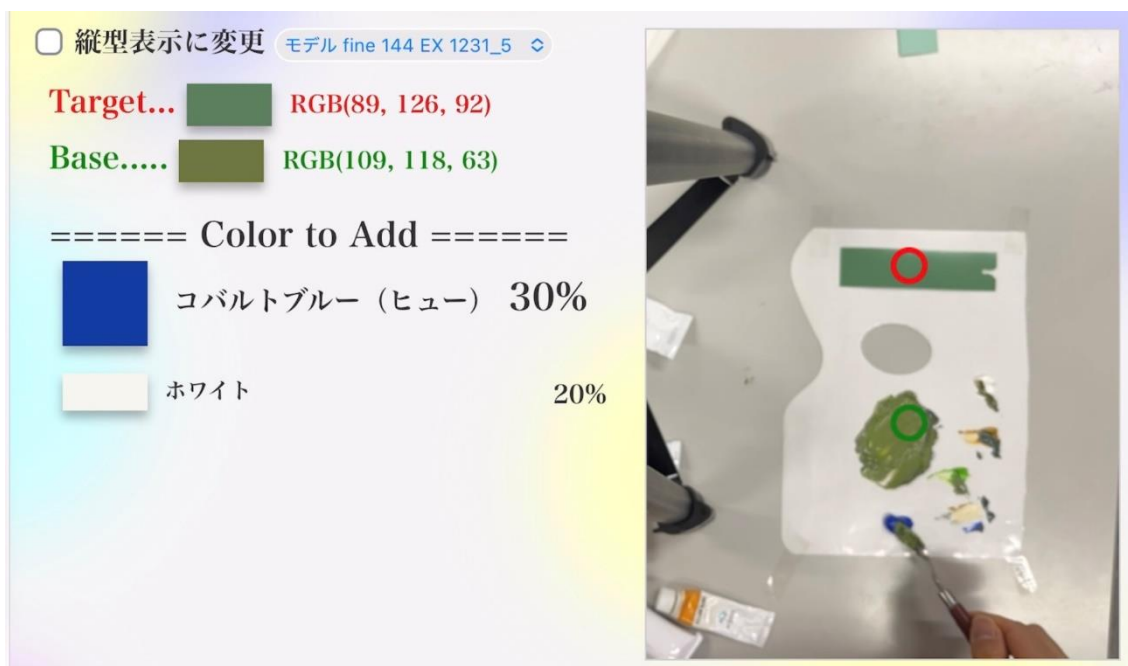



図4. 第二の提案手法のユーザインターフェースの概要。ユーザはカメラ映像上部の赤い丸の中にターゲットとなる色を配置することで、カメラ映像下部の緑色の丸の中に配置したベースの色(混ぜている途中の色)に対して、あらかじめ用意された絵の具セットの中のどの色をどの程度混ぜるべきかを確認することができる。




1分05秒




2分30秒




1分12秒



2分40秒



3分03秒



3分40秒

図 5. 第二の提案手法で筆者による実験の成功例. ターゲットとなる色の紙に, 作成した色を直接塗布している. ターゲットとなる色に近い色が再現できていることが確認できる.

第2章 関連研究

2.1 クリエイティビティサポートツール

近年、コンピュータを活用した創作活動や芸術制作を支援するクリエイティビティサポートツール (Creativity Support Tools, CST) が数多く提案されている。これらのツールは、初心者が高い表現力を身に付けるまでのハードルを下げると同時に、熟練者がさらに自由な発想を展開できるよう促すという点で大きな意義を持つ。「人間の創造性や発想をどうやってテクノロジーによって支援・促進できるか」をテーマとした Shneiderman らの研究[6]以降、CST は「ユーザが創造的プロセスをより豊かかつ効率的に進めるための支援機能」と定義され、学術・産業の両面で活発に研究が進められている。

CST の一例として、Haoran らによる Magical Brush[7]が挙げられる。Magical Brush では、中国画特有の筆致や墨のにじみを忠実に再現する代わりに、あらかじめ用意されたシンボルを自由に組み合わせる設計を採用し、初心者でも短時間でそれなりの中国画を制作できるようにしている。象徴的インタラクションによってユーザの負担を軽減しながら創造性を広げるというアプローチは、本研究が目指す「システムを通じて、初心者でも簡単かつ正確に目的の色を作れる世界を提供する」点と通じる点がある。一方で、Magical Brush は主にデジタルペイント環境に特化しており、物理的な絵の具の混色プロセスを直接支援するものではない。

色彩設計に焦点を当てた研究としては、Xinyu らによる De-Stijl[8]がある。De-Stijl は、ユーザが意図するスタイルや雰囲気に応じた最適なカラーパレットを自動提案し、視覚的に統一感のあるデザインを容易に作成できるよう支援するシステムである。本研究でも、ユーザが混色したい色と実際の手元の絵の具とを結びつけ、より直感的な混色とに自由な色の選択を支援するアプローチを目指している点で、De-Stijl の「カラーリコメンデーションの活用」は重要な先行知見といえる。ただし、De-Stijl はデジタル上での色パレット提案に主眼が置かれており、油絵の具のような物理素材の混色を扱うわけではない。

また、Jingyi らによる研究[9]では、クリエイティビティサポートツールがユーザに与える社会的・文化的影響にも注目している。具体的には「ユーザの能力をどのように強化するのか」「設計者やツールそのものがユーザに対して権力関係を形成していないか」など、利便性や技術的実装だけでは捉えきれない観点を提示している。本研究の対象は油絵の具の混色支援であり、その主目的はアナログアート制作における色再現の負担を軽減することである。しかし、同時に“色作り”という創作過程をツールが肩代わりすることが、ユーザの学習機会や表現の自由度にどのような影響を及ぼすのかは慎重に検討する必要がある。我々の提案手法では、この懸念に対応するために「最も追加すべき色」だけでなく、「ターゲット色に近づく可能性がある複数の候補色」も同時に提示する仕組みを採用している(図4)。これは、ユーザが最終的な混色プロセスを“ただシステムの指示通りに従う”のではなく、複数の選択肢から自分の発想に合った色を選んで試してみる余地を残すという設計上の意図によるものである。ユーザは提示された候補色から自身の直感に合うものを選択し、さらにそこから微調整を続けることが可能となる。こうした機能によってユーザが「どの色をどのタイミングで追加するか」を自ら判断・コントロールできるため、本来の“色作り”の楽しみや自発的な試行錯誤のプロセスを損なわずにサポートできると考えている。こ

のように、ユーザに選択の余地を残す設計は、クリエイティビティサポートツールがもつ権力関係やユーザの学習機会の喪失といった問題への対策の一つともいえる。道具が便利になればなるほどユーザが受動的になりがちだが、本研究ではツールの利便性とユーザの主体性・創造性とのバランスを重視している。

以上のように、クリエイティビティサポートツールに関する先行研究では、初心者を含む幅広い利用者の表現活動を支援するアプローチが試みられている。本研究も同じく「表現のハードルを下げ、創造性を促す」ことを目的としているが、特に油絵の具という物理素材の混色プロセスを対象とし、色再現を機械学習でサポートする点に大きな特徴がある。

2.2 デジタル環境での絵の具に関連した研究

本研究では、油絵の具の混色を支援するシステムを構築するうえで、物理的な絵の具や顔料の振る舞いをどのように捉え、モデル化するかが重要な課題となる。近年、絵の具や色材に関してはデジタル・アナログ問わず多様なアプローチが提案されている。

ニューラルネットワークを活用した絵の具の混合に関連する研究の一つとして、ディープラーニングによって絵画に使われている絵の具の混合を予測し、専用のインクを 3D プリンタで印刷することによって絵画の複製を行うという Liang らによる研究[10]が存在する。この研究は、与えられた色のスペクトル値と、その色を再現するためにモデルが予測したインクの積層によってできる色のスペクトル値を測定し、それらのスペクトル値の誤差が小さくなるように学習を繰り返すことでニューラルネットワークを構築している。この手法によって絵画の色を忠実に再現することができるものの、絵画のスペクトル値を測定するデバイスや 3D プリンタ、専用のインクなどの様々なものが必要となってしまう。そのため、絵の具を使って絵を描く場合における絵の具の混合を予測するためにこのシステムを応用することは困難であると考えられる。

一方、絵画作品の色合いをデジタル上で再解釈する研究として、Tan らによる PColorizer[11]が存在する。これは、中国の古典絵画を詩の内容に合わせて再着色するシステムで、作品の情感や歴史的コンテキストを考慮した色彩表現を実現している。しかし、PColorizer はあくまで完成した画像の色再配置を主眼としているため、物理的な絵の具の“混合比率”にまでは踏み込んでいない。本研究も「絵に使う色をユーザの意図に合わせて自在に得る」点は共通するが、PColorizer のような完成画像の再着色ではなく、「ユーザが実際に絵の具を混ぜる」行為を補助する点に相違がある。

また、油絵の具特有の厚みや混ぜり方の表現をデジタル空間でリアルに再現しようとする試みとして、Thomas らによる Vermillio[12]や Adobe・NVIDIA が開発した Project WetBrush[13]などのシステムが挙げられる。これらは VR や 3D 上で油絵の具の筆致や混色表現を視覚的・触覚的にシミュレートし、ユーザが現実さながらに描画できる環境を提供している。しかし、いずれも最終的に扱うのはデジタル環境での色混合であり、筆圧やストロークのシミュレーションなどは注力されているものの、実際に物理素材を使用して混色比率を求めるわけではない。本研究は VR や CG 技術によるリアリティ向上とは異なるアプローチであり、現実世界の油絵の具を対象とする点で大きく異なる。

同様に, Rundong らによる研究[14]でも, GAN(Generative Adversarial Network)を用いた物理ベースシミュレーションにより, 絵筆の筆致や顔料の流動を高精度に生成している. これも主な対象はデジタル描画であり, 物理的な筆やキャンバスを用いた制作プロセスそのものを支援する手法ではない. したがって, 本研究と共通する「絵の具の物理的な混ざり方」という論点も部分的に取り扱われるが, 最終的にはバーチャル描画を前提にしたものである.

色の混ざり方に関連するその他の研究として, デジタルペイントソフト上で実際の絵の具が混ざったような色の変化をシミュレートする Šarka らによる Mix Box[5]が挙げられる. 従来のデジタルペイントソフトでは, RGB 値を用いた加法混色(光の三原色である赤, 緑, 青を混ぜることで色を表現する方法)に基づく演算のみを行っているため, 光の性質に基づく鮮やかな色表現は可能だが, 実際の絵の具における減法混色(絵の具のように物質が光を吸収し, その残りの光を反射することで色を表現する方法)に近い複雑な混色計算を再現することが難しかった(図 6). そこで Šarka らは, 混合する各顔料の吸収係数と散乱係数から混合物の色を計算する Kubelka-Munk モデル[16]を応用し, RGB 値を入力として「物理的な絵の具が混ざった場合に生じる色」をあらためて RGB 値で出力する演算手法を構築した. この仕組みをライブラリ化した Mix Box を組み込むことで, さまざまなデジタルペイントソフトやプログラム上で, 「実際の絵の具らしい」色の混合を表現できるようになる. しかし, Mix Box はあくまでデジタル環境での色混合を目標として設計されているため, 「実際に持っている複数の油絵の具をどの程度混ぜれば目標色を作れるか」を直接予測するような機能は提供していない. また, 絵の具自体のブランドや顔料組成の違い, 混色における各色の強度を完全に再現することは難しい(図 7). 実際に物理的な絵の具を対象とし, 「作りたい色」を正確に出すための混合比率を推定するには, Mix Box だけでは不十分であると考えられる. そこで本研究では, Mix Box をデータセット作成のためのベースツールとして活用し, 学習モデルに基本的な色の混ざり方を学習させる一方, 油絵の具を実際に混合して得られる実測データを追加することで, モデルを現実的な色再現へと近づけるアプローチを採用している.

2.3 現実世界の絵の具の混色に関連した研究

現実世界の絵の具の混色に関連した研究としては, 水彩絵の具を対象とした Mei-Yun らによる研究[15]が挙げられる. この研究では, 水彩絵の具の半透明性や透過率・反射率を考慮したデータセットを構築し, 深層学習を用いて水彩絵の具同士の混色結果の反射率スペクトルを予測する SWPM 予測モデルを提案している. 加えて, ユーザが指定した色を得るための顔料の組み合わせと量を提供する Smart Palette システムを併せて開発しており, ユーザが目標とする色に近い色を作成するための混色比率を効率よく検索できる点に特徴がある. 具体的には, SWPM 予測モデルを用いてあらかじめ大量の水彩絵の具の混合結果を反射率スペクトルとして算出し, それを look-up table (LUT) 形式で保存している. ユーザが Smart Palette で特定の色を指定すると, その色に最も近い混合結果を LUT から検索し, 対応する色の組み合わせと混合量をユーザへ提示するという仕組みだ. つまり, ターゲット色に対して直接混色比率を推定するわけではなく, 事前計算された候補色の中から最も近似的な結果を探し出す方式である. また, ユーザが実際に絵の具を混合する際には, シリンジなどを使って顔料を正確に計

量することが前提となっている。このように、目的の色を再現するために必要な色の組み合わせや量を提供するという点では本研究と近い部分がある。一方で、本研究では「段階的に混色を繰り返しながらターゲット色を目指す」というアプローチを採用しており、正確な計量器具を前提としないままユーザが微調整を行いつつ、学習モデルがその都度混色比率を予測する点が大きく異なる。さらに、油絵の具と水彩絵の具の間には隠蔽力や粘性、光学特性などの面で大きな差異があるため、モデルの構築や実験手法には別種の考慮が必要となる。提案手法ではこうした差異を踏まえうえて、油絵の具特有の混色挙動を学習モデルに反映させることを目指している。

2.2 章及び 2.3 章の研究から、物理的な絵の具の振る舞いを精密に捉えようとするアプローチは増えつつあるものの、多くはデジタル上でのシミュレーションや印刷技術への応用に留まり、実際に油絵の具を混ぜ合わせて制作するプロセスの支援に焦点を当てたものは少ない。特に、ユーザが直観的かつ段階的に混色を行いながら色を近づける過程をサポートする研究は限定的である。そこで本研究では、既存の水彩絵の具やデジタル上のモデルにおける知見、Kubelka-Munk 理論をはじめとする光学モデルを参考にしつつ、仮想混色データと油絵の具の実測データを活用したニューラルネットワークによる混色支援システムを提案する。



図 6. 実際の絵の具・デジタルペイントソフト・Mix Box における青色と黄色の混ざり方の比較。Practical Pigment Mixing for Digital Painting[1]の Fig 1 より引用。一番左が実際の絵の具の混ざり方で、青色と黄色を混ぜると緑色になっていることが分かる。しかし、中央の 6 つのデジタルペイントソフト上で青色と黄色を混ぜた結果を見ると暗い灰色になってしまっており、現実の絵の具と混ざり方が異なることが分かる。一番右側が Mix Box による結果で、実際の絵の具のようにきちんと緑色になっていることが分かる。

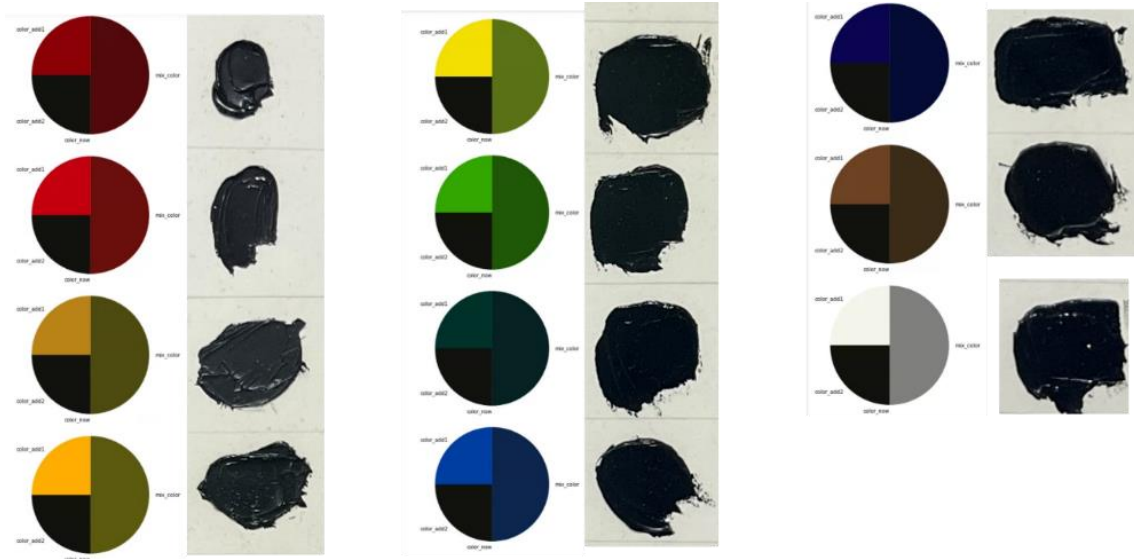


図7. MixBox での混合結果(各列左側)と実際の絵の具の混ざり方(各列右側)の比較. 黒以外の11色を, 黒とそれぞれ1:1で混合した結果を比較している. MixBox によるシミュレーション結果と比較して, 実際に使用する絵の具では黒の影響が非常に強いことが分かる. このことから, MixBox による混色シミュレーションだけでは, 実際の絵の具の混色を完全に再現することは難しいことが考えられる.

第3章 第一の提案手法

第一の提案手法では、混色のベースとなる色(混ぜている途中の色)に対して「どの絵の具をどのくらい混ぜれば目標の色になるか」を学習モデルで推測し、その混合比率をユーザに提供する。図8に、第一の提案システムを利用する際のワークフローを示す。ユーザはスマートフォンのカメラアプリやインターネット上の画像などから取得した作りたい色と、スマートフォンのカメラで撮影した画像から現在のベース色を選択することで、あらかじめ用意された絵の具(図2(b))の中から「どの色をどのくらいの比率で混ぜればよいか」をシステムから得られる。さらに、一度の混色で思い通りの色にならなかった場合は、その混色結果を新たなベース色として再度撮影して入力し、ターゲット色との誤差が小さくなるよう段階的に色を近づけることが可能である。




図8. 第一の提案システムを利用する際の流れ。作りたい色と混色のベースとなる色の2つの色のRGB値を入力することで、どの色をどのくらい混ぜるべきかを合計が1となるような0.1刻みの数値で出力してユーザの絵の具の混色を支援する。

3.1 学習のベースモデル

本研究の混色支援モデルは, Keras の Functional API[17]を用いて実装したニューラルネットワークによって構築する. 図9に示すように, 入力として「作りたい色 C_{target} 」と「ベースとなる色 C_{base} 」のそれぞれの RGB 値を与え, 出力として「どの色の絵の具をどれだけ混ぜればよいか」の混合比率を確率分布として得る仕組みである.

モデルの入力は作りたい色 C_{target} と, ベースとなる色 C_{base} である. C_{target} と C_{base} は 3 次元ベクトル (RGB 値) で, 入力は合計 6 チャンネルとなる.

出力はあらかじめ設定された 12 色の絵の具の色とベースとなる色の各予測混合比率に対応した値 r_i であり, i は $1 \sim N+1$ である. N は使える絵の具の数であり, 提案手法では図2(b)の12色の絵の具セットを用いるため $N=12$ となる. $N+1$ 番目の出力はベースとなる色 C_{base} であり, 出力の合計は 13 チャンネルとなる. $r_1 \sim r_N$ は 12 色セットの絵の具のそれぞれの色の混合比率, r_{N+1} はベースの色の混合比率であり, $\sum r_i = 1$ である.

中間層は 4 つの全結合層からなっており, 各層の活性化関数として ReLU 関数を適用する. また, 各層に Batch Normalization を一層ずつ適用し, 出力層の前に Dropout(20%)を一層適用することで, ニューラルネットワークの精度向上を図る[18]. なお, Batch Normalization は, 各ミニバッチ内での平均と分散を用いてデータを正規化し, 学習の安定性と速度を向上させる手法である. また, Dropout は, トレーニング中にランダムに 20%のニューロンを無効化することで過学習を防ぐテクニックである.

出力層では活性化関数に Softmax 関数を適用することによって, $\sum r_i = 1$ となる $0 \sim 1$ の確率値に変更して混合比率の予測結果を出力する. r_i が大きい色ほど混ぜる比率が大きくなることを意味する.




図 9. 本研究で使用するニューラルネットワークモデルの構造の概要図. この図の例では, 黄色 (混色のベースとなる色) の RGB 値と, 緑色 (作りたい色) の RGB 値が入力となる. この図における出力の例では, 青色と白色, そして混色のベースとなる色の数値が他と比べて高いことから, これら 3 つの色を混ぜると良いということの意味している.

3.2 データセットの作成

ニューラルネットワークモデルを適切に学習させるには、多様な色と比率の絵の具混合パターンを含む大規模なデータセットが必要となる。しかし、実際に油絵の具を大量に混ぜて測定する方法では、膨大な時間と労力がかかってしまう。また、デジタルペイントツールでデータを用意する方法も考えられるが、一般的なデジタルペイントソフトで作成したデータは、加法混色をベースとする RGB 値の演算が中心であり、実物の絵の具とは異なる色の混ざり方を示す(図 6 参照)。そこで本研究では、2.2 章でも述べたように、実際の絵の具の色の混ざり方に近い結果を再現できる MixBox を活用し、学習用のデータセットを効率的に作成する。

データセットの作成工程の概略を図 10 に示す。ニューラルネットワークの学習に用いる一つのデータサンプルは、作りたい色 C_{target} 、ベースの色 C_{base} 、比率集合 $\{r_i\}$ の 3 要素から成る。まず、ベースの色 C_{base} については、ランダムな 3 次元ベクトル (RGB 値) を生成して決定する。

次に、比率集合 $\{r_i\}$ についてもランダムに決定するが、あらかじめ用意された N 色の絵の具 (本研究では $N=12$) について、 $r_1 \sim r_N$ のうち 1~2 個のみが正の値を持ち、他の $N-2$ 個については $r_i = 0$ とする。また、ベースの色の比率 r_{N+1} の値もランダムに決める。ただし、正の値をもつ r_i は 0.1~0.9 までの 0.1 刻みの数値であり、 $\sum r_i = 1$ である。あらかじめ用意された N 色の絵の具の中で i に対応する色 (最大二色) が、 r_i の比率でそれぞれ C_{base} に加えられた結果を MixBox で算出することによって、作りたい色 C_{target} を求める。

このとき、MixBox での混合演算にはあらかじめ用意された N 色の絵の具の RGB 値が必要となる。本研究では、Nix Mini 3[19]によって 12 色の絵の具の RGB 値を測定した。ただし、バーントシェンナ (茶色) のみ RGB 値を手動で設定した。すべての絵の具の RGB 値を測定値のまま使用した場合、MixBox の演算結果により茶色が「暗い赤色」として扱われ、システムの学習結果に偏りが生じた。特に、暗めのピンクや紫系の色を再現しようとした際、不適切に茶色を提示するケースが頻発した。他の色ではこのような問題は見られず、茶色特有の課題であると判断した。ファインチューニングによる調整も考えられるが、初期データセットの偏りがシステム全体に影響を及ぼしている可能性があるため、バーントシェンナに関しては RGB 値を手動で (110, 65, 35) に設定することで問題を修正した。この変更により、暗い紫やピンク系の色再現時に見られた不適切な挙動が改善された。

このようにして、 $(C_{base}, \{r_i\}, C_{target})$ の対応関係が整合するデータセットを大量に生成できる。第一の提案手法では Python を利用して 700 万個のデータセットを用意した。

本研究では、ベース色に対して追加する絵の具の数を 2 色に限定している。これは、もし 3 色以上の絵の具を同時に混ぜるようにすると、実際の作業工程が煩雑になり、ユーザが比率を再現しにくい可能性が高まるためである。特に、段階的に色を調整するプロセスで 3 色以上を扱うと、ユーザビリティが著しく低下すると考えられる。このため、2 色までに絞ることで、ユーザが実際に混色を行いやすくしながら、十分な色再現性を確保する設計としている。

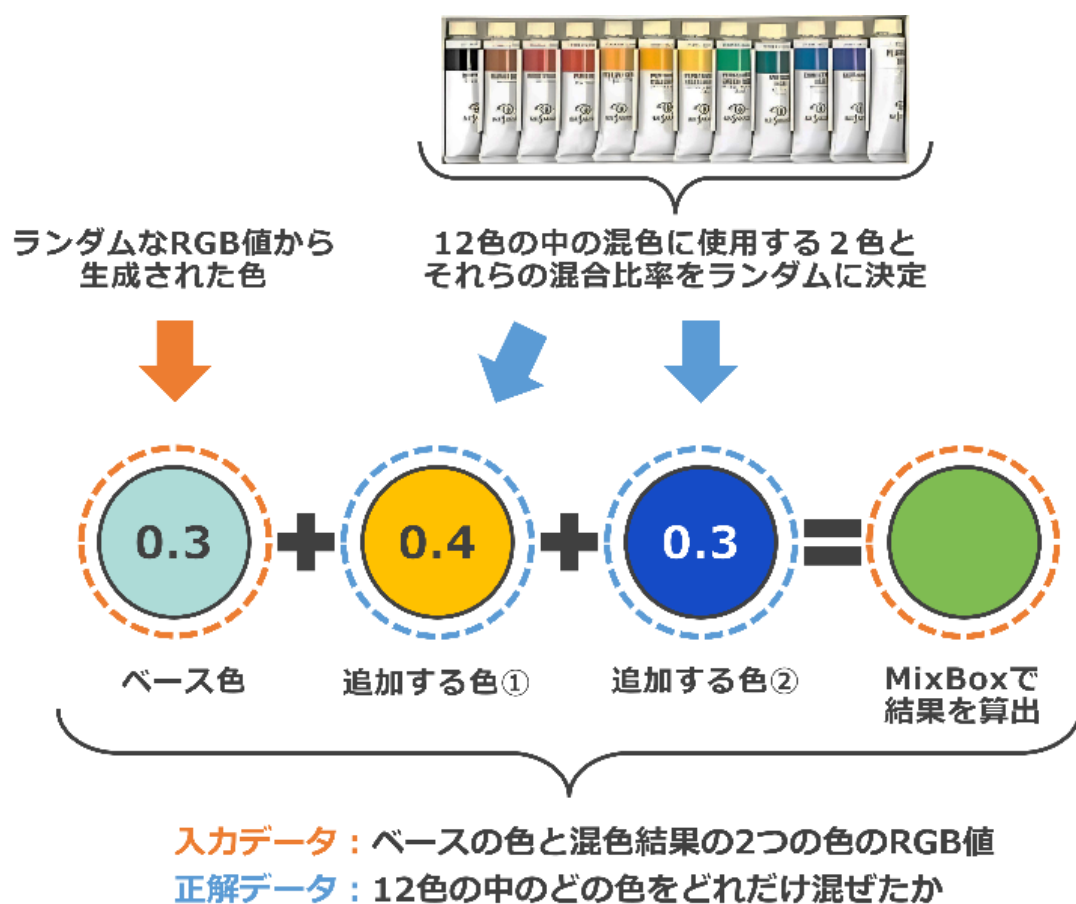


図 10. データセットの作成手順の概略図.

3.3 ファインチューニング

提案モデルでは、大規模な仮想データセットを活用して基本的な色混合の傾向を学習させた上で、実際に使用する油絵の具の混ざり方や照明環境による色変化も考慮したファインチューニングを行うことで、より現実的な色再現性を向上させる。

3.3.1 実際の絵の具の混合データの取得

まず、実際に使用する 12 色の絵の具同士を 1:1 の比率で混合し、それぞれの混色結果をサンプリングする。12 色の全組み合わせに対して混合を行うため、 $12 \times 12 = 144$ 通りの混色結果が得られる。混合比率はそれぞれ 1:1 とし、1 色同士の混合(同色×同色)もデータとして扱う。この混色結果を撮影用に一枚の大きな紙(図11)に塗り分ける。



図 11. 本研究で使用する 12 色の油絵の具を 1:1 の比率で混合した結果の一覧. 使用している絵の具セットに含まれる 12 色を, 縦と横の見出しにそれぞれ配置し, それらが交わるマス(セル)において「2 色を 1:1 の比率で混合したときに得られる色」を塗布している. 最上段(横方向)の行と左端(縦方向)の列の各色は, 今回用いる絵の具セットに含まれる 12 色を表しており, たとえば左端に並んでいる色と最上段に並んでいる色の交わったマスでは, それら 2 色を同量ずつ混合した結果を示している. ただし, 同じ組み合わせ(例:A+BとB+A)のマスは重複を避けるため省略している関係で, 理論上の 144 マスよりも数が少なくなっている. 実際には A+B と B+A は同じ混合結果を与えるため, 本研究におけるデータ収集において支障はない.

3.3.2 照明環境による色変化の撮影

3.3.1 章で作成した混色結果が塗布された大きな紙を用いて, 照明環境による色変化の情報も収集する. 具体的には, 図12のような環境で, 紙に向けてさまざまな角度から照明を当てながらビデオ撮影を行うことで, 環境光の変化に応じて各色の見え方(RGB 値)がどのように変化するかを, 動画撮影によって連続的に記録する. ここでカメラを固定しつつ, 光源の角度や明るさを変化させることで, 多様な照明条件下での色変化をとらえることができる. 本研究では iPhone13 の通常カメラアプリで動画を撮影した. 実際の撮影では, 混色結果が塗布された大きな紙に対して, 図 12(a)の二つの照明と 12(b)の手持ちライトを動かしながら様々な角度・強さで光を当てる.



(a)



(b)

図 12. (a)実際の撮影環境の様子. (b)撮影の際に利用した手持ち型のライト.

3.3.3 フレームごとのデータ作成

撮影したビデオを解析し、フレームごとに異なる照明条件下での色の変化を抽出する。このとき、単色領域・混合領域ともに、「どの色を混ぜた領域か」「実際にどの程度の混合比率か」を既に把握しているため、“光の当たり方によってターゲット色がこう変化するとき、ベースの色や追加する絵の具はこう変化する”といった対応関係を導くことができる。結果として、ベースの色・ターゲットの色・混合比率の各種データを、多様な光学条件(照明の当たり方)別に大量に用意できる。

本研究では 30fps で 50 秒ほどの動画を撮影しており、1 フレーム当たり 144 色分のパターンがあるため、約 230000 個のデータを作成した。このデータを用いてモデルに対して追加学習(ファインチューニング)を行うことで、「実際の絵の具の混ざり方」と「照明環境による色の変化」の双方をモデルに取り入れることを目指す。すなわち、「実際の油絵の具が持つ固有の反射・吸収特性(顔料組成, 隠蔽力など)」と、「異なる照明条件や観察角度による色変化」の 2 点をデータとして反映させることで、単にデジタル上のシミュレーションだけでは得られないリアルな色再現性能の実現を目指す。ファインチューニング後のモデルは、ユーザがどのような照明環境で撮影したベース色・ターゲット色であっても、より正確に「どの色をどれくらい混ぜればよいか」を予測できるように調整されることを目指している。

3.4 モデルの学習

モデルの学習に使用した計算機の動作スペックは、CPU が Intel Core i7-7700 3.60GHz, メモリが 64GB, GPU が GeForce GTX 1080 Ti である。

3.4.1 ベースモデルの学習

MixBox による大規模な仮想データセットを活用して、ベースモデルに色混合の基礎的な傾向を学習させる。データセットには 700 万件の色混合パターンが含まれており、ベースモデルはこれを通じて「どの絵の具をどの比率で混ぜるべきか」を学習した。第一の提案手法では、図 9 の出力層に対して新たな出力層を追加し、モデルの出力層を 2 段構成とすることで、ベース学習後の重みを大きく書き換えすぎずに調整(ファインチューニング)を施せるよう工夫している。具体的には、ネットワークの最終段階で一度 Softmax 出力を得た後、もう一層 Softmax を重ねる設計である。これにより、ベース学習で獲得した混色の特性を適度に保持しながら、微細な誤差を補正する仕組みとなる。学習設定としては、オプティマイザに Adam[30], 損失関数を平均二乗誤差(MSE), メトリクスを平均絶対誤差(MAE), バッチサイズを 128, エポック数 50 で、検証データ分割比率は 20%である。さらにモデルの収束を促進し、安定した結果を得るため、複数回の学習試行(Fit)を繰り返している。図 13 は、5 回の試行におけるトレーニングデータ(Train)およびバリデーションデータ(Test)のロス(MSE)および MAE の変化を示す。各試行において、トレーニングデータのロスはエポック数に応じて減少し、バリデーションロスも類似の傾向を示していることから、モデルが過学習に陥らず収束していることが確認できる。

3.4.2 モデルのファインチューニング

3.3 章で述べたように、実際に使用する油絵の具や照明環境による色変化に対応するためのファインチューニングを行った。ファインチューニングの設定として、再学習可能な層をベースモデルの最終 3 層とし、オプティマイザには学習率を低くした Adam(学習率は 0.00001), エポック数を最大 500, バッチサイズを 144 であり、検証データ分割比率は 20%である。この設定により、既に学習されたベースモデルの重みを大きく変更することなく、実際の油絵の具特有の特性や照明条件の変化をモデルに反映させることを目指した。図 14 にファインチューニング時のトレーニングデータおよびバリデーションデータにおける MAE(左図)とロス(右図)の変化を示す。両図から、ファインチューニングのエポック数が進むにつれ、トレーニングおよびバリデーションデータにおける誤差が減少し、過学習が発生せずにモデルが安定的に収束していることが確認できる。

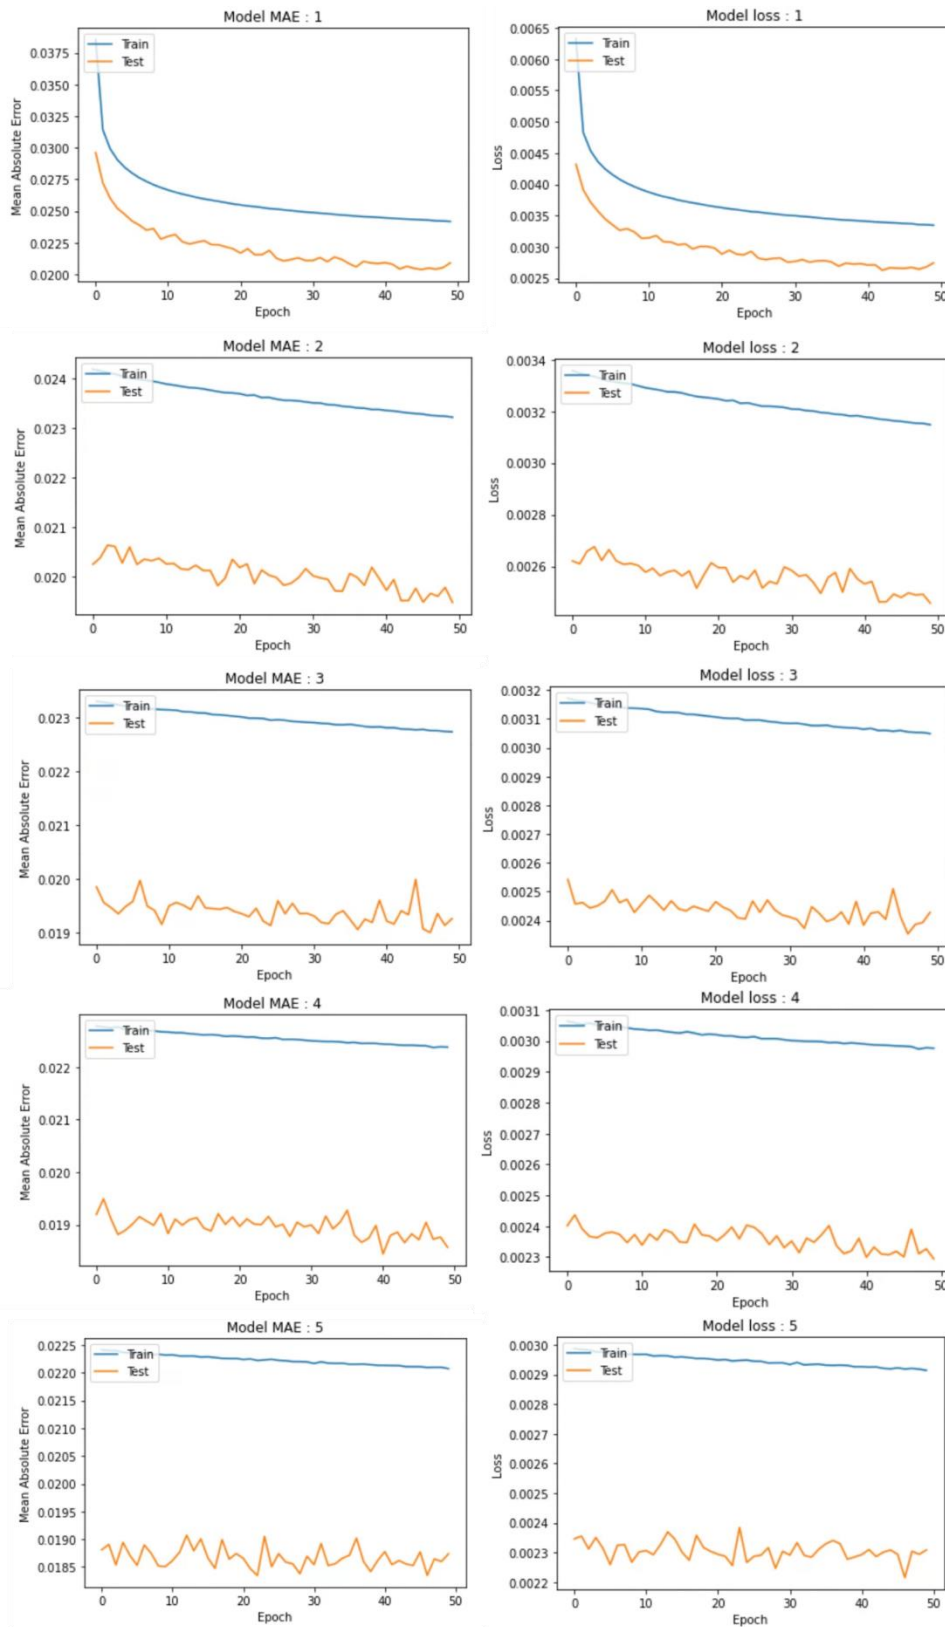


図 13. 第一の提案手法におけるベースモデルの学習における MAE と MSE の変化. 青色の線がトレーニングデータ, オレンジ色の線がバリデーションデータである.

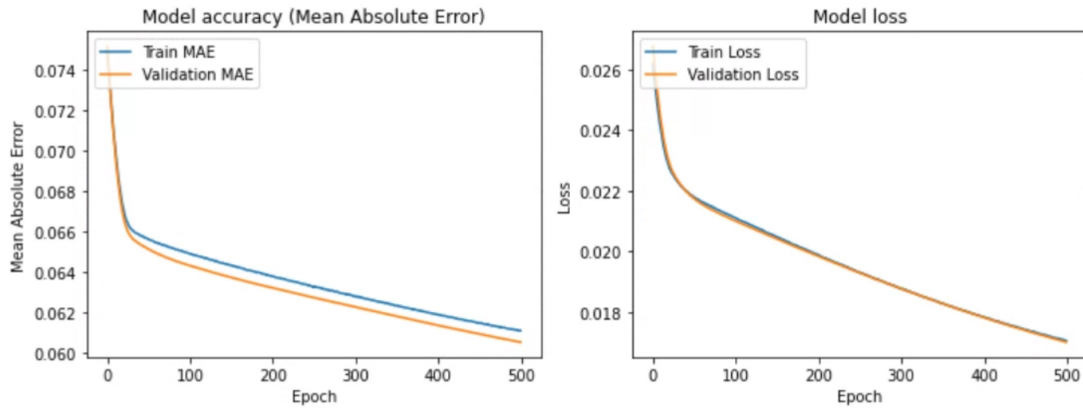


図 14. 第一の提案手法におけるファインチューニング時の MAE と MSE の変化. 青色の線がトレーニングデータ, オレンジ色の線がバリデーションデータである.

3.5 ユーザインターフェース

学習済みモデルを活用した混色支援機能を Web アプリケーションとして実装した「第一の提案システム」のユーザインターフェースについて述べる. ユーザはスマートフォンの Web ブラウザからアクセス可能であり, カメラ撮影機能やカラー選択ツールを用いて「作りたい色」と「ベースとなる色」を直感的に入力できる. 開発した Web アプリケーションは, HTML/CSS/JavaScript を用いたシングルページアプリケーション (SPA) として構築している. 内部では TensorFlow.js[20]を利用し, 事前に学習・ファインチューニング済みのモデルファイル (model.json および対応する重みファイル) をブラウザに読み込むことで, クライアントサイドのみで推論を行えるように設計している. これにより, ユーザは特別なソフトウェアをインストールせずに, Web ブラウザ上で「作りたい色」「ベース色」の RGB 値を入力するだけで, 学習モデルによる混色比率の提案が得られる.

3.5.1 最初の混色

第一の提案手法におけるユーザの操作フローは, 図 15(a)~(d)に示すように, 「最初の混色」と「段階的な調整」という 2 ステップ構成を想定している. はじめに, ユーザは「作りたい色 (C_{target})」をカメラ撮影や画像ファイルのアップロード, あるいはカラーサークル (Pickr [21]) を用いて指定する (図 15(a)). 具体的には, 画面上に撮影画像を表示し, タップしたピクセルから RGB 値を取得する方法 (図 15(b)) や, カラーピッカー UI を操作して数値的に色を選択する方法 (図 15(c)) などが用意されている.

次に, ユーザは「ファーストミックス」ボタン (図 15(a)(b)) を押し, システムに対して混色比率の推定をリクエストする. この段階では, まだ「現在のベース色 (C_{base})」が指定されていないため, システムは背後で 12 色の中から最も近い初期ベース色を探索し, 学習モデルによる混合比率予測を自動的に実行する. 具体的には, 12 色それぞれをベースとみなした場合の予測混合比率を計算し, その比率どおりに混色した結果 (MixBox を利用) とターゲット色との誤差を比較することで, 最も近くなる配合を選択して提示する仕組みである. 推定結果は合計 1 となるよう 0.1 刻みで表され (図 15(d)), 色タイルをバーチャー

トのように表示する(図 15(d)のタイルの数を混合比率に応じた数分表示することによって「どの色を多く混ぜるべきか」を視覚的に把握しやすい設計としている. また, ホワイトやブラックなど強弱が極端な顔料が提示された際には, 注意メッセージを表示して実際の混色作業を促す(具体的にはホワイトは多めに, ブラックは少なめに混ぜるように促す).

3.5.2 段階的な調整

最初の混色結果をもとに, ユーザは実際の絵の具を混ぜてみるが, 一度の混色で完全に思い通りの色が得られるとは限らない. そこで, ユーザは「混色後の色」をベース色(C_{base})としてカメラ撮影・ピクセル選択で取り込み, 作りたい色(C_{target})の時と同様にシステムに入力する(図 15(e)). すると, 学習モデルは「混色後の色(新たなベース色(C_{base}))に対して, 事前に用意された 12 色の中のどの色をどれくらい追加して混ぜれば, 作りたい色(C_{target})に近づくか」を再度推定し, 0.1 刻みの比率で提示する(図 15(f)). ユーザはこの結果を参考にして, 再び絵の具の混色を行う.

この「混色結果を新たなベース色として再撮影 → 再度推論 → 結果を参考にしながら混色」という流れを繰り返すことで, 段階的にターゲット色へ近づけることが可能である. こうした繰り返し利用可能なインタラクション設計により, ユーザは比較的少ない試行回数で正確な色づくりを行うことができ, 従来の“経験と勘”に頼った混色よりも短時間で目標色の再現が期待できる.

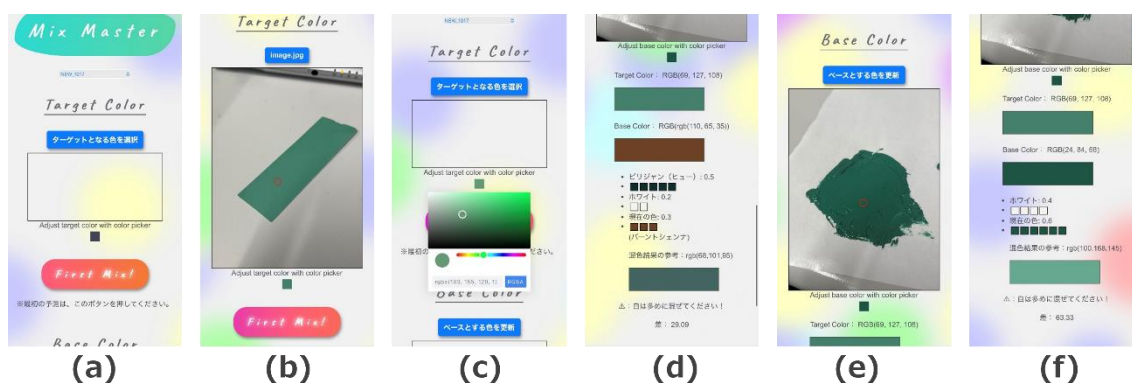


図 15. 第一の提案システムにおけるユーザインターフェースの例. (a) 作りたい色(ターゲット色)の入力画面. (b) 写真をアップロードし, キャンバス上でピクセルをタップして色を取得する様子. (c) カラーピッカーUI を用いたターゲット色の指定例. (d) ファーストミックス後の推定結果. バーチャートで混色比率を提示し, ホワイトやブラックといった強弱が極端な顔料に関しては警告を表示. (e) 混色後の実際の色を撮影し, 新たなベース色として取り込む画面. (f) ベース色とターゲット色を入力し直してモデル推論を実行. 予測結果を反映して再度混色を行う.

第4章 第一の提案手法における結果と考察

本章では、前章までに示した第一の提案手法を用いた混色実験の結果と、その考察をまとめる。まず筆者自身が複数の色の再現を試みた際の事例を示し(4.1章)、その後、提案システムの有効性を客観的に評価するために実施したユーザテスト(4.2章)の方法・結果・考察を述べる。

4.1 筆者自身による色再現実験①

第一の提案手法の基礎的な有用性を確認するため、事前に用意した複数の色をターゲットとして、実際に油絵の具を混ぜながら色再現を試みる実験を行った。ターゲット色としては、本研究で使用している絵の具セット(図2(b))で再現が可能な色を数種類選択した(図17(a)の色見本から選択)。各ターゲット色に対して3.5章で述べたような手順で混色を行い、最終的にターゲット色と十分近いと筆者が判断した段階で作業を終了した。

筆者自身が行った混色結果の成功例を図16に示す。いずれのターゲット色に対しても、ファーストミックス後に数回程度の調整を行うことで、肉眼的にかなり近い色を再現できた。

これらの結果から、自分自身がシステムを熟知している状況では、比較的スムーズに混色作業を完了できることがわかった。ただし、「狙ったターゲット色を事前にある程度見極め、作りやすい色を選定している」というバイアスがあることを考慮する必要がある。また、筆者自身がシステムの使用方法や混色のコツを理解している点も影響していると考えられる。



図16. 筆者自身が第一の提案手法を用いて行った混色結果の成功例。


4.2 ユーザテスト①

第一の提案手法の客観的な有効性を評価するため、油絵の具の混色経験が少ない一般ユーザ 3 名を被験者としてユーザテストを実施した。各被験者には 4 色ずつターゲット色を割り当て、自力での混色と本システムを利用した混色を交互に行ってもらい、所要時間や最終的な色再現精度などを比較した。

4.2.1 ユーザテスト①のやり方

ターゲット色の選定は図 17(a)に示す色見本からランダムに 12 色を抽出し、被験者ごとに 4 色ずつ分配した。被験者には紙パレットと 12 色絵の具セット(図 2(b)), パレットナイフ(図 17(b))が与えられ、システムは各被験者のスマートフォンに Web アプリケーションの URL が送られる。

実験は、①システムの使い方や混色のやり方を練習するチュートリアル ②自力での混色(1 回目, 最大 15 分) ③システムを利用した混色(1 回目, 最大 15 分) ④自力での混色(2 回目, 最大 15 分) ⑤システムを利用した混色(2 回目, 最大 15 分) といった手順で行われた。自力での混色では、ユーザは自身の勘や経験のみを頼りに、用意された 12 色セットの絵の具(図 2(b))を自由に混合してターゲット色の再現を目指す。システムを利用した混色では、ユーザは提案システムを 3.5 章で述べたような手順で利用し、システムの予測結果に従って混色を行う。各被験者は、割り当てられた 4 色に対して上記の順序で混色作業を行い、ターゲット色を再現できるかを検証し、その際にかかった時間を測定する。混色の制限時間は最大 15 分とし、被験者は自分が作っている色がターゲット色と十分近いと判断した段階で作業を終了する。被験者から監督者に対する質問は、実験手順やシステムの操作方法、道具の使い方等についてのみ許可し、実際の混色工程は被験者自身が試行錯誤する形式をとる。



(a)



(b)

図 17. (a)実験に使用した色見本[22]. (b)実験に使用したパレットナイフ.

4.2.2 ユーザテスト①の結果

ユーザテストの結果と混色にかかった時間をまとめたものを図 18 に示す。まず、ターゲット色を再現するのにかかった時間を比較すると、システムを利用した場合よりも自力での混色の方が、全体的に所要時間が短いことが分かる。実際に自力での混色の際の作業時間の平均は6分40秒であるのに対し、システムを利用した際の作業時間の平均は12分38秒であった。次に、実際に完成した色を比較すると、自力の混色でもある程度再現ができていていることが分かる。それどころか、システムを利用した場合では、図 18(d)のように、時間がかかった割にターゲット色から遠い結果になってしまった場合もある。




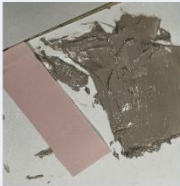








混色のやり方	ユーザA	ユーザB	ユーザC
自力での混色①	 (a) 4分32秒	 (b) 7分55秒	 (c) 8分30秒
システム利用①	 (d) 12分40秒	 (e) 13分17秒	 (f) 7分23秒
自力での混色②	 (g) 5分37秒	 (h) 10分20秒	 (i) 3分08秒
システム利用②	 (j) 12分50秒	 (k) 14分40秒	 (l) 15分

図 18. 第一の提案手法を使ったユーザテストにおける、混色の結果とかかった時間のまとめ。

4.2.3 考察

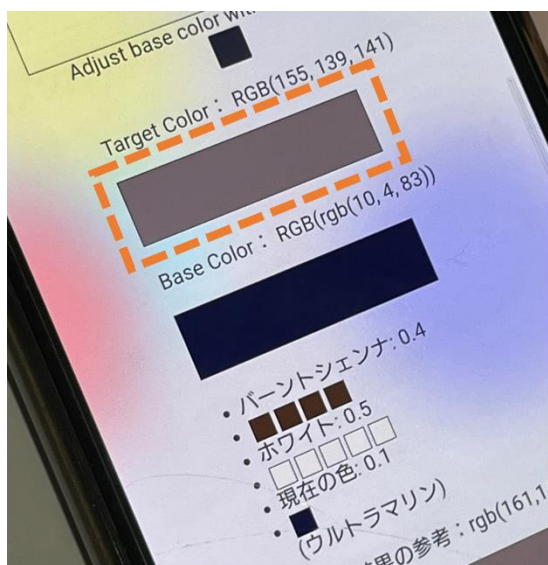
図 18 に示すユーザテストの結果から、自力で混色を行った方が所要時間は短く、色の再現精度もシステム利用と同等またはそれ以上であるケースが多く見られた。本研究ではシステム利用によってユーザの混色作業を効率化することを目指していたが、その目的が十分に達成されていない。この原因としてはいくつかの要因が考えられる。

まず、システム操作の煩わしさと比率による予測結果の分かりにくさが挙げられる。ユーザはターゲット色やベース色を撮影するたびにカメラを起動し、画像内のピクセルを選択する操作を繰り返す必要がある。この過程について、被験者からは、「混色のたびに写真を撮影することが大変」といった声が寄せられた。また、混色比率が 0.1 刻みで表示される仕組みについても、バーチャートで結果を可視化したものの、「混色比率を表示されても、実際にどれくらいずつ絵の具を混ぜれば良いかがイメージしづらい」という意見もあった。従来の経験や勘に頼る方法に慣れたユーザにとって、数値的な提示はかえって混乱を招く要因となった可能性がある。


次に、照明環境や撮影環境の影響が挙げられる。ファインチューニングによって照明環境を部分的に考慮しているものの、撮影時の影やスマートフォン側の自動色補正の影響でアプリ上のターゲット色が実際の色と微妙にずれることがあった。例えば、図 19(a)のようにターゲット色が実際の色より暗めに取得されると、システムはそのずれた色に基づいて予測を行い、結果として本来のターゲット色とは異なる方向に混色が誘導される(図 19(b))。また、ベース色とターゲット色を撮影するタイミングや照明条件が異なる場合、それぞれが別々の照明環境として認識されるという問題もある。

さらに、システムの予測精度についても十分とは言えず、ユーザの期待通りに機能しないケースも見受けられた。学習データやファインチューニングデータの特性、あるいはモデル設計に起因する可能性があり、更なる改良が必要であると考えられる。また、ユーザはシステムの予測を参考にしつつも最終的には自身の裁量で混色比率の調整を行う場合が多く、この点がシステムの役割を曖昧にしまった可能性がある。実際に、「比率よりも、とにかくどの色を混ぜれば良いかが知りたい」といった意見もあった。

最後に、自力での混色でも一定の再現性を示した背景には、被験者自身の経験が影響していると考えられる。被験者全員が過去に学校の授業などで混色を一度は経験したことがあるため、ターゲット色に完全に一致しなくても「この色にはどの絵の具を混ぜたら良さそう」という推測が働いた可能性がある。さらに、混色初心者にとってはシステムの操作よりも「直感を頼りにとりあえず混ぜてみる」という作業の方が取り組みやすく、結果的に操作コストがかからない自力混色の方がスピーディだったと考えられる。



(a)



(b)

図 19. (a)ユーザー A がシステムを利用した一回目の混色時における実際のアプリの混色予測画面. (b)ユーザー A が実際に混色をした結果.

第 5 章 第二の提案手法

第一の提案手法において、第 4 章で述べたユーザテストの結果から、操作の煩雑さや撮影環境による誤差、システム予測の分かりにくさなどが要因となり、システムが期待通りの成果を十分に発揮できていないことが明らかになった。この結果を踏まえ、学習モデルやワークフローを見直し、ユーザインターフェースを大幅に改良した Web アプリケーション(第二の提案手法)を開発した。

5.1 学習モデル

5.1.1 ベースモデルの学習とデータセットの作成

第二の提案手法におけるベースモデルは、第 3 章で述べた第一の提案手法におけるモデルと基本的には同様の構造である。ただし、第一の提案手法におけるファインチューニング用に追加した出力層は削除している。学習データセットの作成方法も同様であり、12 色の絵の具を混ぜ合わせた際の混色結果をもとに、混色比率を予測するタスクをベースモデルに学習させる。ただし、データセットの規模については、700 万個から 500 万個に削減した。これは、後述するファインチューニングの影響を相対的に強めるためであり、モデルが現実の混色データにより適応することを狙ったものである。

この調整により、ベースモデルは依然として混色の基本的な傾向を正確に学習する一方、ファインチューニングの効果がモデル全体の予測精度に与える影響を強化できる設計となっている。これにより、現実的な利用条件での性能向上が期待される。

5.1.2 ファインチューニング

第一の提案手法では「実際の絵の具の混ざり方」と「照明環境による色の変化」を同時に考慮するファインチューニングを行っていたが、ユーザテストの結果から、照明環境の補正が十分な効果を発揮できていない可能性が示唆された。このため、第二の提案手法では「実際の絵の具の混ざり方」にのみ焦点を当て、より現実的な混色結果を再現できるようにファインチューニングの方針を見直した。

ファインチューニングでは、第一の提案手法(3.3.1 章)と同様に、12 色セットの絵の具を 1:1 で混合した際の RGB 値(Nix Mini 3[19]による測定値)を基にしたデータを使用している。ただし、実際のシステム利用時の計測環境では、ノイズや微小な色ブレが避けられないため、データ拡張として RGB 値にランダムなばらつきを加える処理を導入した。このばらつきは、現実世界で測定された RGB 値の R,G,B の各値に ± 5 の範囲でランダムな整数を加え、各値が 0~255 の範囲を超えないようクリップすることで実現している。例えば、「ピリジャン」と「ホワイト」を 1:1 で混合した場合、理想的な条件下(Nix Mini 3[19]による測定値)では RGB 値が(0, 158, 138)であるが、実際には計測環境やカメラの特性により、RGB 値がわずかに変動する可能性がある。このような変動をデータセット内で再現するため、ターゲット色とベース色の両方にランダムなばらつきを加えたデータを生成し、144 セットのデータを 500 倍に拡張した。

これにより、モデルが「多少のズレがあっても正しい混色比率を導き出す」能力を習得する可能性が高まると考えられる。また、データ拡張により、モデルが現実の計測環境における不確実性のある程度

吸収し、より安定した予測を行えるようになることが期待される。このアプローチは、理想的なデータだけに依存せず、実際の計測誤差や環境変動を織り込むことで、モデルをより現実的な条件に適応させることを目指したものである。

これらの工夫によって、第二の提案手法におけるファインチューニングは、現実環境の特性に柔軟に対応しつつ、混色支援システムとしての実用性が高まることが期待される。

5.1.3 モデルの学習

モデルの学習には、第一の提案手法と同様に、CPU が Intel Core i7-7700 3.60GHz、メモリ 64GB、GPU が GeForce GTX 1080 Ti という計算機環境を使用した。

ベースモデルの学習における基本設定は第一の提案手法の際と基本的には同様であり、オプティマイザに Adam、損失関数に平均二乗誤差 (MSE)、メトリクスに平均絶対誤差 (MAE) を採用し、バッチサイズを 128、エポック数を 50、検証データ分割比率を 20% とした。ただし、第二の提案手法では学習手法にいくつかの変更を加えた。一つ目は、学習試行 (Fit) の回数を一度に減らしたことである。第一の提案手法では、複数回の試行を通じてモデルの収束を促進し、より安定した結果を得ることを目指していたが、今回はその手法を簡略化した。これには、データセットの規模を 700 万個から 500 万個に削減したことも関係しており、データ量を減らすことで計算負荷を軽減しつつ、ファインチューニングの影響を相対的に強める設計となっている。さらに、第一の提案手法では、ベース学習後の重みの安定性を考慮してモデルの出力層を二段構成 (Softmax 層を二重) としていたが、第二の提案手法ではこの追加層を削除し、出力層を単一の Softmax 層に簡素化している。この変更は、過度な出力層の複雑さを排除し、よりシンプルな設計でモデルの効率性を高める意図がある。図 20 に示す学習結果からは、トレーニングデータのロス (MSE) はエポック数に応じて順調に減少しており、バリデーションロスも同様の傾向を示している。これにより、モデルが過学習に陥ることなく収束していることが確認できる。また、学習試行の回数を減らしたにもかかわらず、最終的なロスや MAE は第一の提案手法で得られた結果 (図 13) とほぼ同等であり、MAE に関しては若干小さい値を示した。

この結果は、出力層の簡素化がモデルの収束を妨げるどころか、むしろ効率的な学習を実現した可能性を示唆している。これらの結果から、第二の提案手法では、モデルの学習効率が向上しつつも、第一の提案手法と同等、もしくはそれ以上の性能を維持することができたとと言える。この変更により、より実用的で効率的なモデル構築が可能となったと考えられる。

ファインチューニングに関しては、再学習可能な層をモデルの最後の 1 層に変更し、オプティマイザには学習率を 0.001 とした Adam、エポック数を最大 50、バッチサイズを 32 とし、検証データ分割比率は 20% とする変更を行った。

この設計により、ベースモデルがすでに学習している「混色の基本傾向」を活かしつつ、実測データを基にした予測精度の更なる向上が目指されている。図 21 にファインチューニング時のトレーニングデータおよびバリデーションデータにおける MAE (左図) とロス (右図) の変化を示す。両図から、ファインチューニングのエポック数が進むにつれ、トレーニングおよびバリデーションデータにおける誤差が減少し、過学習が発生せずにモデルが安定的に収束していることが確認できる。




図 20. 第二の提案手法におけるベースモデルの学習における MAE と MSE の変化. 青色の線がトレーニングデータ, オレンジ色の線がバリデーションデータである.

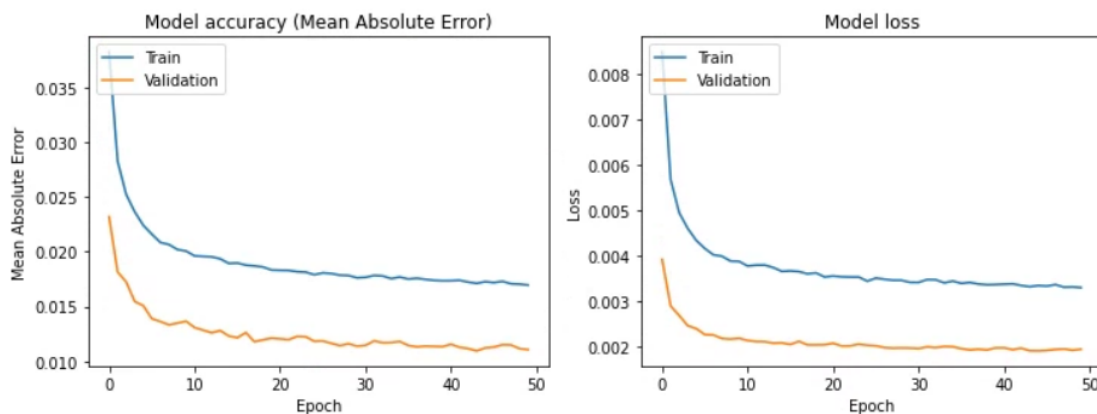


図 21. 第二の提案手法におけるファインチューニング時の MAE と MSE の変化. 青色の線がトレーニングデータ, オレンジ色の線がバリデーションデータである.

5.1.4 ファインチューニングの効果の検証例

図 22 は, ファインチューニングを行ったモデルと行っていないモデルによる予測結果を比較した例である. この比較では, ターゲットカラーとして図 17(a)の色見本から選択した色を配置し, ベースの色(紙パレットの薄いグレー)に対して追加するべき色の予測結果を提示している.

ファインチューニングを行ったモデルの予測は, 行っていないモデルに比べて実際の絵の具の混ざり方をより正確に反映していることが分かる. 具体的には, 黒を追加する割合が抑制されるなど, 混色における絵の具特有の特性を考慮した予測が可能になっている. この変化は, MixBox のシミュレーション結果が必ずしも実際の絵の具の挙動を完全に再現できない点を補完するものである. 例えば, 黒色の絵の具は MixBox のシミュレーションではその影響が過小評価される傾向があるが, 実際の絵の具では黒の隠蔽力が強く, 少量でも他の色を大きく変えてしまうことが知られている(図 7 参照). このため, ファインチューニングによりモデルが「黒を安易に追加すると色が大きく変わる」という実際の絵の具の特性を学習し, 黒の使用を適切に抑制する予測を行えるようになったと考えられる.

このように, ファインチューニングは, MixBox によるシミュレーションで得られた基礎的な知識を基に,

実際の絵の具の特性に適応させる重要なプロセスであることが示された。本手法により、ユーザが期待通りの色を再現するための支援精度が向上したといえる。

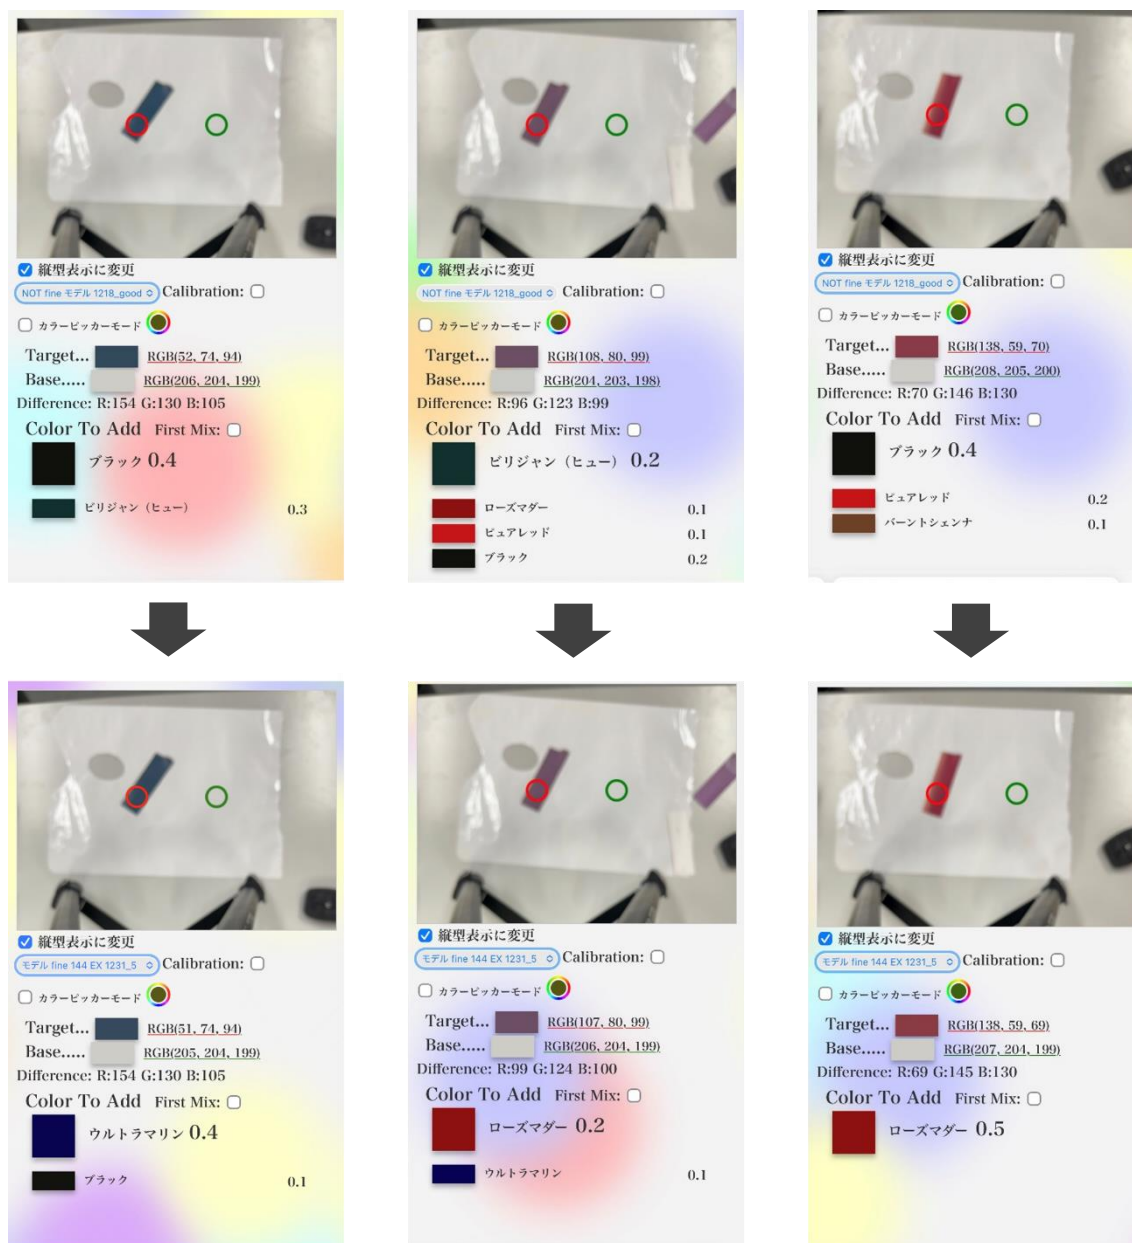


図 22. ファインチューニングを行ったモデルと行っていないモデルによるターゲットカラーへの混色予測結果の比較例。ターゲットカラーに図 17(a)の色見本から選択した色を配置し、ベースの色(薄いグレー)に対してどの色をどの程度追加すべきかを予測した結果(Color to Add)を示している。ファインチューニングを行っていないモデル(上段)と比較して、ファインチューニングを行ったモデル(下段)では、特に黒色の過剰な使用を抑制している点が特徴的である。

5.2 ユーザインターフェース

第一の提案手法の際と同様に、学習済みモデルを活用した混色支援機能を、新たなWebアプリケーションとして実装した「第二の提案システム」のユーザインターフェースについて述べる。開発したWebアプリケーションは第一の提案手法の際と同様に、HTML/CSS/JavaScriptを用いたシングルページアプリケーション(SPA)として構築している。内部ではTensorFlow.js[20]を利用し、新たな学習・ファインチューニング済みのモデルファイル(model.json および対応する重みファイル)をブラウザに読み込むことで、クライアントサイドのみで推論を行えるように設計している。以前と同様に、ユーザは特別なソフトウェアをインストールせずに、Webブラウザ上の学習モデルによる混色比率の提案が得られる。

しかし、先述の通り、第一の提案手法におけるユーザテストの結果やフィードバックを基に、システムのワークフローやユーザインターフェースを大幅に改良している。

5.2.1 自動的な色取得とリアルタイムな予測表示

第二の提案システムにおける大きな改良点の一つとして、スマートフォンカメラの映像を画面上にリアルタイム表示し、その映像から自動的にターゲット色・ベース色を取得する仕組みと、その取得情報を用いて学習モデルの予測結果をリアルタイムに表示する仕組みが挙げられる。以前のシステムでは、ユーザが混色のたびに「ベース色」や「ターゲット色」をカメラ撮影して取り込む必要があり、そのたびに生じるアプリケーションの操作が煩雑になるという課題があった。特に繰り返し予測を実行し、段階的な調整を行いながらターゲット色の再現を目指すというシステムの性質上、ベース色の更新と撮影頻度が高く、ユーザビリティ上の大きな問題となっていた。

これを解決するため、第二の提案システムでは、図 23 のように getUserMediaAPI[28](Web ブラウザ上からデバイスのカメラやマイクなどへアクセスし、リアルタイムの映像・音声ストリームを取得できる API)を利用してカメラ映像を常時画面に表示し、アプリケーション画面上で定義された赤い丸(図 23(a))や緑の丸(図 23(b))の領域から得られるピクセルの平均 RGB 値を、それぞれターゲット色(C_{target})およびベース色(C_{base})として自動的に取得(図 23(c))する設計に変更した。この設計により、ユーザが混色のたびに撮影操作を行う必要がなくなり、映像上の色がリアルタイムで学習モデルに渡され、予測結果が随時更新されるようになった。これによって、ユーザは混色作業を進めながら次に追加すべき色やその量を即座に確認できるようになり、操作負荷が大幅に軽減された。

さらに、予測結果の表示方法に関しては、ベース色に対して「最も追加すべき色」を 1 つ明示し(図 23(d))、その他の色を「候補色」として複数提示する(図 23(e))。ここでは、第一の提案手法におけるユーザテストで「全体の細かい混色比率が提示されても、実際にどの程度混ぜればよいかイメージしづらい」という意見があったことを踏まえ、全体の混色比率ではなくベース色に対して 10%~90%というパーセンテージで量を示すよう改良も行っている。パーセンテージが高いほど多めに混ぜることを推奨するという単純な指標を提示し、ユーザが詳細な比率を気にせずとも「まずはどの色を加えればよいか」を把握しやすくしている。また、「最も追加すべき色」以外にその他の色を「候補色」として複数提示する仕組みは、ユーザが「提示された色をただ機械的に混ぜる」のではなく、複数の選択肢から自身の直感や意

図に合うものを選んで試行できる余地を残すことで、創造的な試行錯誤の楽しみを損なわずにシステムを活用できるようにする狙いがある。実際に混色を進めていく中で、ユーザは最も推奨度の高い色と候補色の両方を試しつつ、さらに微調整していくことが可能となる。

また、この設計には第一の提案手法でのユーザテストから得られた「自力でもある程度近い色を再現できる可能性」に関する考察も反映されている。ユーザの多くは過去に学校の授業などで混色を経験したことがあり、その経験から「この色にはどの絵の具を混ぜたら良さそう」という推測が働く可能性が高い。それに加えて、混色初心者にとってはシステムの操作よりも「直感を頼りに混ぜてみる」という作業の方が取り組みやすいとも考えられる。この背景を考慮し、第二の提案システムではユーザに自由な試行錯誤の余地を与えつつ、システムの予測を補助的なツールとして利用する設計が採用されている。

このように、第二の提案手法ではカメラの起動を一度行うだけで、ユーザは画面上に映る絵の具やキャンバスの色を逐次ベース色として取り込みながら、ターゲット色へ近づく方法をリアルタイムに得ることができる。第一の提案システムと比較して、撮影と予測のステップを行き来する操作が大幅に削減され、操作フローが簡略化されると同時に、ユーザの経験や直感も活かせるような自由な色づくりを尊重する設計へと改良を図った。

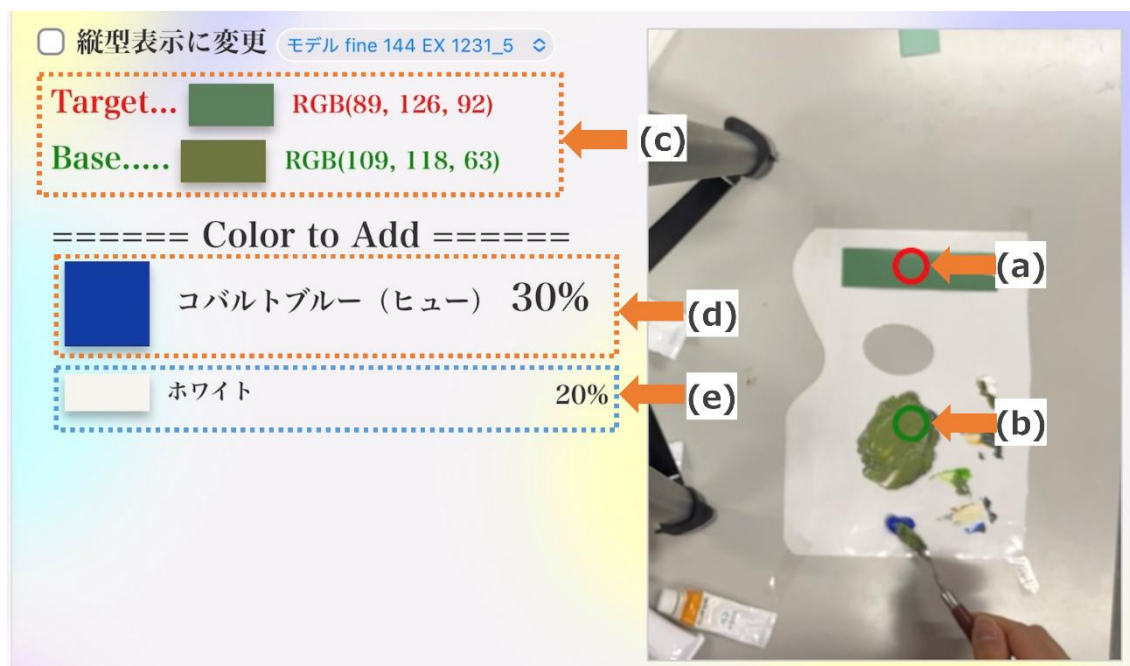


図 23. 第二の提案手法のユーザインターフェースの詳細。(a)ターゲットの色の取得領域。(b)ベースの色の取得領域。(c)実際に取得されたターゲットの色のRGB値とベースの色のRGB値を表示する領域。(d)ベースの色に対して最も追加するべき色とその量の目安。(e)追加するべき色のその他の候補。

5.2.2 照明環境による影響を低減させるための工夫

第一の提案手法における実験や、第二の提案手法における自動的な色取得とリアルタイムな予測表示の実現にあたって、照明環境が色取得の精度に影響を及ぼす課題が明らかとなった。具体的には、ターゲット色とベース色を同じカメラ映像内で同時に撮影されていたとしても、スマートフォンをターゲット色やベース色(混色中の絵の具)に近づけすぎた場合、光量や照明角度の不均一性が原因で、正確な色取得が困難になるケースが多発した。特に、混色中の絵の具に照明が反射してしまい、実際の色とは異なるデータがシステムに入力される問題が観察された(図 24)。

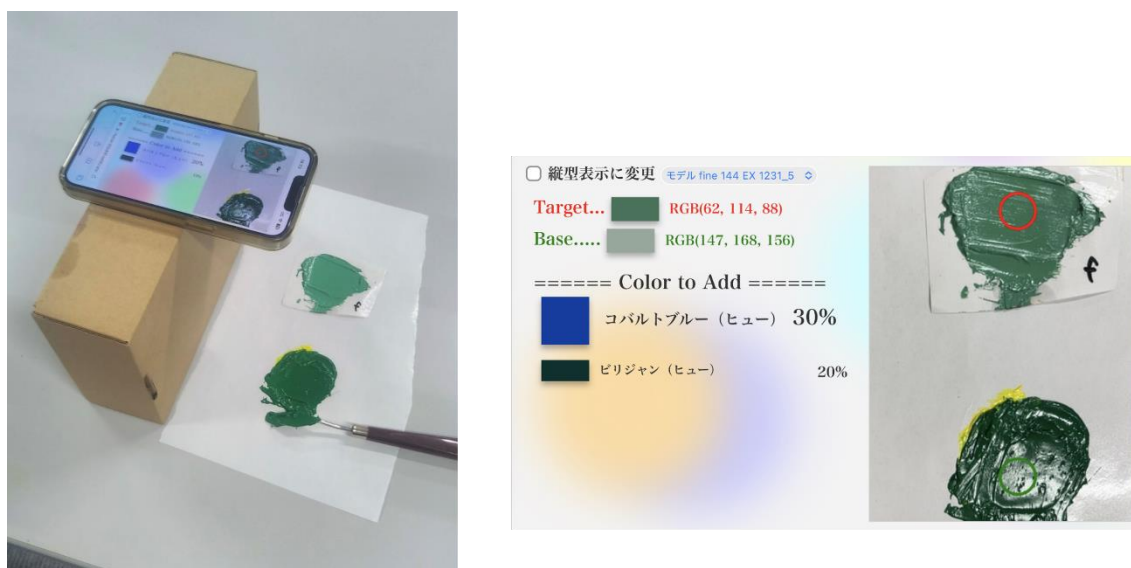


図 24. 絵の具の混色エリアとスマートフォンが近い状態で撮影するワークフローの例. 絵の具に照明の光が反射してしまい、色が適切に取得されていないことが分かる。

この問題を解決するため、本研究では、ターゲット色とベース色が受ける光環境を均等化する新たなワークフローを設計した。具体的には、ユーザが絵の具を混ぜるエリアからスマートフォンを適度に離して撮影することを推奨する手法を導入した。この方法により、ターゲット色とベース色がカメラ映像内で相対的に近接し、両者に当たる光の角度や光量の差を最小限に抑えることが可能となった(図 25)。

照明環境の影響を低減させるためのその他の手法として、実際に使用する絵の具を活用したカラーキャリブレーション機能も一度実装した。しかし、距離を調整することで影や光の影響をある程度緩和できることが確認できた上に、カラーキャリブレーションを導入するとシステムのユーザビリティが低下する可能性が高い。そのため、最終的にはカラーキャリブレーション機能の採用を見送りとした。

以上のように、絵の具を混ぜるエリアからスマートフォンを適度に離して撮影するワークフローは、ユーザの操作負担を軽減しつつ、混色プロセスの精度を向上させることを目的としている。ターゲット色とベース色の照明条件を近づけることで、システムはより正確な色取得を行い、結果として、ユーザが目標とする色を効率的に再現するための指標を適切に提示できるようになる。この工夫により、従来の方

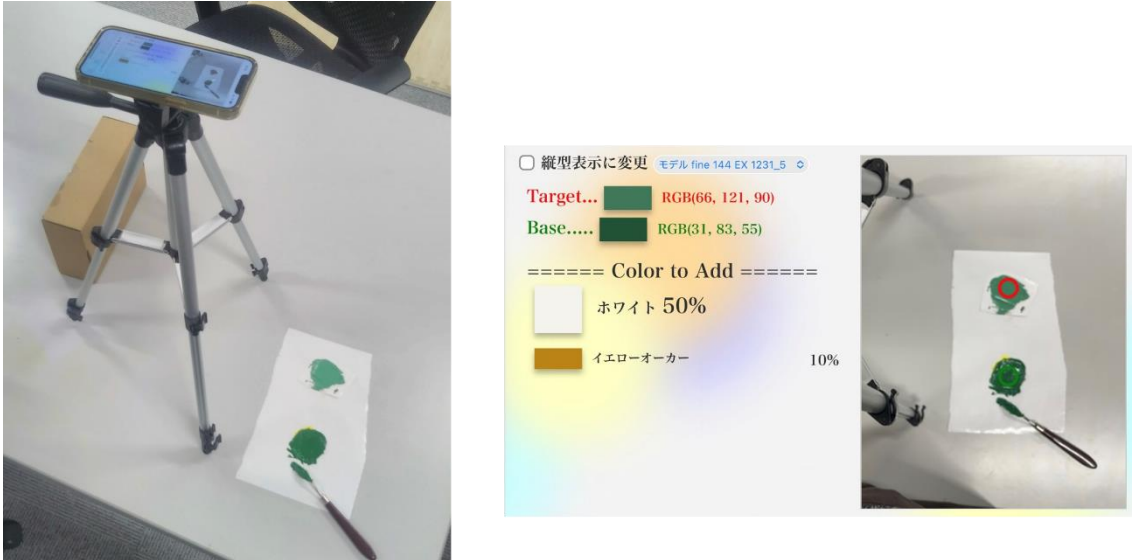


図 25. 絵の具の混色エリアからスマートフォンを適度に離して撮影するワークフローの例. 三脚などを用いてターゲット色とベース色がより均一な照明下に入るように配置する(この図における三脚の高さは 51 センチほどである). 光の反射などの影響が低減され, 図 24 のときと比べると色の取得がより適切に行われていることが分かる.

第6章 第二の提案手法における結果と考察

本章では、前章までに示した第二の提案手法を用いた混色実験の結果と、その考察をまとめる。まず筆者自身が複数の色の再現を試みた際の事例を示し、その後、提案システムの有効性を客観的に評価するために実施したユーザテストの方法・結果・考察を述べる。

6.1 筆者自身による色再現実験②

第二の提案手法の基礎的な有用性を確かめるため、あらかじめ用意した複数の色をターゲットに設定し、実際に油絵の具を混ぜて色を再現する実験を行った。ターゲット色としては、本研究で使用している絵の具セット(図 2(b))で再現が可能そうな色を、図 17(a)の色見本から数種類選択している。各ターゲット色に対しては、前章で述べた手順を用いながらシステムの予測結果に従って混色を進め、最終的にターゲット色と肉眼で見て十分近いと判断した時点で作業を終了した。あわせて、混色を開始してから作業を終えるまでの所要時間も計測し、システムの利便性を客観的に評価できるようにしている。

ただし、この実験では後述するユーザテストとは異なり、混色開始時点でパレット上に絵の具を出しておらず、チューブから絵の具を出す時間も計測に含めた。また、絵の具をパレットナイフで混ぜる際は、新たに絵の具を追加する場合でもナイフを拭かずにそのまま使用している。さらに、追加する色はシステムが提示したもののみに限定し、推奨する色の精度やアプリケーションの実用度を直接確認できるようにした。

図 26 には、筆者自身が行った混色の成功例を示している。どのターゲット色に対しても、短い作業時間で肉眼的にかなり近い色を再現できている様子がわかる。図中の各色の下に記載した数値は、完成までに要した所要時間であり、最長でも数分程度で十分に近い色を作れたケースが多かった。作業時間の短縮に大きく寄与した要因としては、リアルタイムで予測結果を参照できる仕組みにより、「どの色をどのくらい足せばよいか」を都度判断する手間や試行錯誤の回数が減った点が挙げられる。第一の提案手法と比べて作業の中断や煩雑な操作が少なく、スムーズに作業を進められることが今回のシステムの大きな利点であると考えられる。

さらに、図 27 にはターゲット色と実際に作成した色の RGB 値を Nix Mini 3 [19] で測定した結果を示した。表示されている各 RGB 値や画面上での色の見た目からも、作成された色がターゲット色に非常に近い数値を示しており、システムによる推奨が正確に機能していることが確認できる。

こうした結果から、第一の提案手法のときと同様に、筆者自身がシステムを熟知している状況下では、比較的スムーズにターゲット色を再現できることがわかった。一方で、「事前に作りやすい色を選んで」「筆者自身がシステムや混色のコツを理解している」などのバイアスはあるため、これらを除いた条件下でも同様の効果が得られるかを検証するには、より多様なユーザを対象にした評価が必要となる。しかし、今回の実験結果は、適切にターゲット色を設定したうえで、ターゲット色やベース色の取得が適切に行われれば、提案システムが絵の具の混色の場面において効果的に働く可能性を示唆している。




図 26. 第二の提案手法で筆者による実験の成功例と、各色の再現に要した時間. ターゲットとなる色の紙に、作成した色を直接塗布している(図 5 の再掲).




図 27. (上段)ターゲットの色の RGB 値の測定値. (下段)実際に作った色の RGB 値の測定値.

6.2 ユーザテスト②

第二の提案手法の有用性を確認するため、油絵の具の混色経験が少ない一般ユーザ 10 名を被験者として、事前に用意した複数の色をターゲットとして実際に油絵の具を混ぜながら色再現を試みる実験を行った。各被験者には 6 色ずつターゲット色を割り当て、自力での混色と本システムを利用した混色を交互に行ってもらい、作業にかかった時間や最終的な色再現の精度などを比較した。

6.2.1 ユーザテスト②のやり方

20 代の絵画経験のない 10 人のユーザを対象に、ユーザテストを実施する。この評価は、従来の方法（自力での混色）と比較して、油絵の具の混色効率化の有効性における提案システムの効果を調べることを目的とする。

ユーザを 2 つのグループ（グループ①、グループ②）に分け、グループ①のユーザにはタスク A・B の 2 つの混色タスクを実施、グループ②のユーザにはタスク C・D の 2 つの混色タスクを実施する。各タスクの目標は同じであり、12 種類の提供された絵の具から色を選んで混色し、ターゲットとなる色に近い色（理想としては完全に一致する色）を素早く作成することである。

ターゲットの色は合計 6 色設定されており、それらは図 28 のように 6 つの色カード（色カード a～f）に分けられている。各色カードにはターゲットの色が 1 色塗布されており、各色が自力での混色・提案システムを利用した混色で均等に利用されるように、以下のようにタスクを設定する。

タスク A: ユーザの直感に基づいて混色を行い、色カード a・c・e の色を再現する。（グループ①）

タスク B: 提案システムを利用しながら混色を行い、色カード b・d・f の色を再現する。（グループ①）

タスク C: ユーザの直感に基づいて混色を行い、色カード b・d・f の色を再現する。（グループ②）

タスク D: 提案システムを利用しながら混色を行い、色カード a・c・e の色を再現する。（グループ②）

ユーザは自力での混色（タスク A・C）とシステムを利用した混色（タスク B・D）を交互に 3 回ずつ行い、色カード a～f に割り当てられた 6 色を a・b・c・d・e・f の順番で作成する。

色カード a～f に割り当てられる色（ターゲットとなる色）は、実際に実験で利用する 12 色セットの絵の具の色をいくつか混色した結果の色である。ユーザテストに参加しない 3 人の人間に 3 色ずつ、12 色セット絵の具を 3～5 色ずつ混ぜた色を作ってもらい、その色をターゲットの色として色カード a～f に割り当てる。ターゲットの色を作る際、一人が作る色は、12 色セットの絵の具を 3 色混ぜた色を 1 つ、4 色混ぜた色を 1 つ、5 色混ぜた色を 1 つの 3 色であり、合計 9 色を用意した。その 9 色の中から、3 色混ぜた色を 2 つ、4 色混ぜた色を 2 つ、5 色混ぜた色を 2 つの合計 6 色を、作った人の数が均等になるように選び、色カード a～f にターゲットの色として割り当てる。

各タスクにおいて、ユーザは混色作業開始前に 12 種類の提供された絵の具を全て、使い捨ての専用の紙パレット（図 29）の所定の場所に出しておき、パレットナイフ（図 17 (b)）を用いて混色を行う。ただし、パレットナイフで絵の具を取るときは、パレットナイフに付着した絵の具をティッシュペーパーで拭い

てから色を取るものとする。そして、最初に出した絵の具が足りなくなった場合は、絵の具をチューブから紙パレットに追加しながら混色を行うものとする。また、使い捨ての混色用の紙パレット(システム用)(図 29 参照)には目印を付けておき、ユーザはその目印の場所にシステムの画面を合わせて、目印の場所で混色を行う。なお、混色用の紙パレットは、自力用・システム用の両方において混色作業開始前にセロハンテープで固定して、混色中に動かないように設置する。

ユーザは監督者のタイム計測スタートの合図で混色を始める。ターゲットの色に十分近い色を再現できたとユーザ自身が満足した時点で混色をやめてタイム計測を停止する。ただし、作業開始から 10 分経過した場合は作業を中断する。(なお、10 分という制限時間は、第一のシステムのユーザテストの際の自力での混色における作業時間の平均が 6 分 40 秒であったことや、筆者自身がシステムを利用した際には数分程度でターゲット色の再現に成功したことを考慮して決定した。)

自力での混色(タスクA・C)においては、ユーザは混ぜる色や比率を、自らの勘や経験のみを頼りに決めながら混色を行う。

提案システムを利用した混色では、ユーザは混ぜる色や比率を、基本的にはシステムの予測を参考にして決めながら混色を行う。ただし、必ずしもシステムの予測通りに混ぜる必要はなく、必要に応じてユーザが自ら好きな色を選んで混ぜることも可能とする。例えば、システムが青色か白色を追加するという予測を提示している場合でも、ユーザ自身の感覚で緑色を混ぜるべきだと判断した場合は、システムの予測を無視して緑色を混ぜても良い。(これは、システムの予測の入力として取得される RGB 値が、照明環境やデバイス側の色補正機能などの影響によって、実際に目に見えている色とは異なって取得されてしまう場合や、モデルの予測が完全ではない場合があるためである。)提案システムは Web アプリケーションとして URL がユーザに送付され、URL からユーザ自身のスマートフォンで Web アプリケーションを起動して利用される。

また、実際のユーザテストを行う前に、参加者は混色手順やシステムの利用に慣れるための練習を実施する。この練習には、絵の具をパレット上に出す作業や、パレット上の絵の具同士をパレットナイフを使って実際に混色する作業、システムの予測を参考にしながら混色をする作業などが含まれる。また、監督者に対する質問は、システムや道具の使い方・実験の進め方に関する質問に限定した。

さらに、ユーザテスト後のユーザに対して、提案システムがどの程度役に立ったか、混色のどの段階でシステムが最も役に立ったかといった内容を確認するアンケートを実施した。

実際のユーザテストでは、ユーザテストのマニュアル(付録 A)を配布し、マニュアルを用いながら練習の前に説明を行った。また、実際の作業環境の全体の様子を図 30 に示し、自力での混色の場合の様子を図 31(a)に、システムを利用した混色の場合の様子を図 31(b)に示す。




図 28. ユーザテスト②で利用した 6 つの色カード. ユーザは監督者に指定されたカードをターゲットの色として混色を行う.




図 29. 絵の具を出すための専用の紙パレット. ユーザは混色作業前にパレットの指定の位置に絵の具を出して混色を行う(図 31). 画像には, 混色用の紙パレット(システム利用時)が上に置かれている.





図 30.ユーザテストの作業環境. 絵の具を出す専用の紙パレットの上に, 自力混色用の紙パレット(画像奥側)とシステム利用混色用の紙パレット(画像手前側)が置かれている. また, パレットナイフふき取り用のティッシュや混色用紙パレットを固定するためのセロハンテープも近くにおいてある.



(a)



(b)

図 31. (a)自力での混色作業を行う際の作業環境. (b)システムを利用した混色をする際の作業環境.

6.2.2 ユーザテスト②の結果

6.2.1 章で述べたユーザテストの結果について述べる。本研究では、ターゲットの色と被験者が作成した色の違いを定量的に評価するために、色差 ΔE を用いた。 ΔE は国際照明委員会(CIE)の XYZ 表色系や Lab 表色系をもとに二つの色の差異を数値化した指標であり、以下のように定義される。

$$\Delta E_{ab} = \sqrt{(L_1^* - L_2^*)^2 + (a_1^* - a_2^*)^2 + (b_1^* - b_2^*)^2}$$

一般に、 ΔE の値が大きいほど、「二つの色が異なる」ことを意味する。図 32 は ΔE の値による色の差を比べた画像であり、値が小さいほど二つの色の差が小さく、値が大きいほど二つの色の差が大きいことが分かる。




図 32. ΔE の値による色の差の比較(プリントビズ株式会社のウェブサイトより引用[29]).

表 1 に示す箱ひげ図は、ユーザテストで得られた自力混色(青)とシステム利用混色(オレンジ)における ΔE の分布(各 30 サンプル: 6 色×5 人)をまとめたものである。自力混色における平均値は 8.2、システム利用混色における平均値は 7.3 と、システム利用によって全体的に ΔE が若干低下していることが分かる。このように、システム利用時の方が僅かではあるが色再現の精度が高い結果が得られた。

一方、最小値はいずれも 2 前後であり、極めて近い色再現に成功した被験者が存在することが分かる。また、最大値については、外れ値(一部の被験者が極端に大きな ΔE を示したケース)の影響により、両手法とも 20 を超えるケースが観測される。ただし、外れ値を除けば自力混色における最大値は 14.5、システム利用混色における最大値は 9.7 と、システム利用時の方が低い傾向がある。このことから、混色が苦手な被験者の場合でも、システムの提案を参考にすることで「大きく色を外してしまうリスク」を軽減できる可能性がうかがえる。

しかしながら、箱ひげ図の全体的なばらつきが大きい点も特徴的である。これは、各被験者の混色スキルや作業方針が結果に強く影響しているためであり、システムを使えば必ずしも低い ΔE に到達できるわけではないことを示す。それでも、平均値や最大値周辺の分布からは、システム利用のほうが多少なりとも精度向上につながる傾向が見られ、本システムが初心者や色作りに苦手意識をもつユーザをサポートする一定の効果を持つことが示唆される。




表 1. 自力混色とシステム利用混色における ΔE の分布。

さらに、表 2 に示す箱ひげ図は、自力混色(青)とシステム利用混色(オレンジ)における、ターゲット色 a~f の 6 種類ごとに分けたときの ΔE の分布(自力混色・システム利用混色ともに各色 5 サンプルずつ)をまとめたものである。これを見ると、たとえばターゲット色 f ではシステム利用混色が安定して低い ΔE を示す一方、自力混色の場合は全体的に ΔE が大きい。このことから、自力では再現が難しい色でも、システムを利用することによって再現精度が向上するケースが確認できる。一方、ターゲット色 a では自力混色の方が全体的にやや低い ΔE を示していることから、色相領域や明度・彩度によって、システムを利用しても再現が難しいケースの存在も推察される。また、ターゲット色 b では両者の結果が大きくばらついており、システム利用混色では特に予測結果をどのように活用するかによって結果が大きく左右されたと推察される。このように、ターゲット色の特性や被験者の慣れ・得手不得手、さらにシステムの予測結果をどのように実際の混色に反映させるかなどが相互に影響し合い、システムの恩恵が得られやすい色とそうでない色が混在している様子がうかがえる。




表 2. 自力混色とシステム利用混色における色ごとの ΔE の分布.

次に、混色に要した作業時間を比較する。表 3 に示す箱ひげ図は、ユーザテストで得られた自力混色(青)とシステム利用混色(オレンジ)における、ターゲット色の再現にかかった作業時間(各 30 サンプル: 6 色×5 人)をまとめたものである。自力混色における平均作業時間は約 472.8 秒(7 分 53 秒)、システム利用混色における平均作業時間は 約 465.2 秒(7 分 45 秒)と、全体として顕著な差は見られず、統計的にも大きく異なるとはいえない。ただし、最小値を比較すると、自力混色が 285 秒(4 分 45 秒)に対し、システム利用混色は 143 秒(2 分 23 秒)というケースもあり、特定の被験者や特定の条件では大幅に作業時間を短縮できる可能性も示唆された。一方で、最大値は両者とも 600 秒(制限時間の 10 分)に達する被験者が存在し、作業時間のばらつきが非常に大きい点も確認できる。

ユーザテスト後に行われたユーザアンケートからは、「システムの提案を頼りにすることで初期段階の色作りをスムーズに進められた」というようなポジティブな意見がある一方、「提案が目まぐるしく変わること戸惑った」という声もあった。このような結果から、作業時間の短縮効果はシステムの予測結果をどの程度活用できるか、予測の変動にどう対処するかによって大きく左右されると考えられる。

さらに、表 4 に示す箱ひげ図は、自力混色(青)とシステム利用混色(オレンジ)における、ターゲット色 a~f の 6 種類ごとに分けたときの、作業時間の分布(自力混色・システム利用混色ともに各色 5 サンプルずつ)をまとめたものである。これをみると、色 a・b・c ではシステム利用混色の方が下限値が小さくなる傾向があり、色 b に関しては平均値もかなり小さくなっていることが分かる。このように、一部の被験者においてシステムが大幅な時間短縮に寄与していることがうかがえる。一方、色 d・e・f などでは、自力混色とシステム利用混色の差が小さいか、むしろ自力混色が短い時間で終わった被験者も多く見られるなど、ターゲット色や個人によるばらつきが大きい点も特徴的である。このように、システム利用による

時間短縮効果はターゲット色の特性や被験者の利用方針によって大きく変動することを示唆している。

以上の結果から、 ΔE (色再現精度)に関してはシステム利用の方がやや優位であり、特定のターゲット色においては顕著に精度を高められる例がみられた。一方、作業時間の平均値は大きく改善されなかったものの、最小値の比較ではシステムによって大きく時間を短縮した被験者も存在する。総じて、システムをうまく活用した被験者ほど所要時間や色差が改善する傾向がみられるが、ターゲット色や個人の混色スキル、システム提案の活用の仕方によって結果にばらつきが生じることが明らかとなった。

また、第一の提案手法で得られた「自力で混色を行った方が作業時間も短く、色の再現精度も高い」という結果と比較すると、第二の提案手法は全体的に改善が見られた。特に、第一の提案手法ではカメラ撮影による手間が作業の負担となっていたが、第二の提案手法ではリアルタイムに予測を提示する仕組みを採用したことで、操作の煩雑さが解消された。さらに、システムの提案を参考にすることで「大きく色を外してしまうリスク」を低減できたことは大きな進歩である。これらのことから、第二の提案手法におけるシステムの活用が一定の効果を持ち、混色支援ツールとしての有用性が高まったことを確認できる。

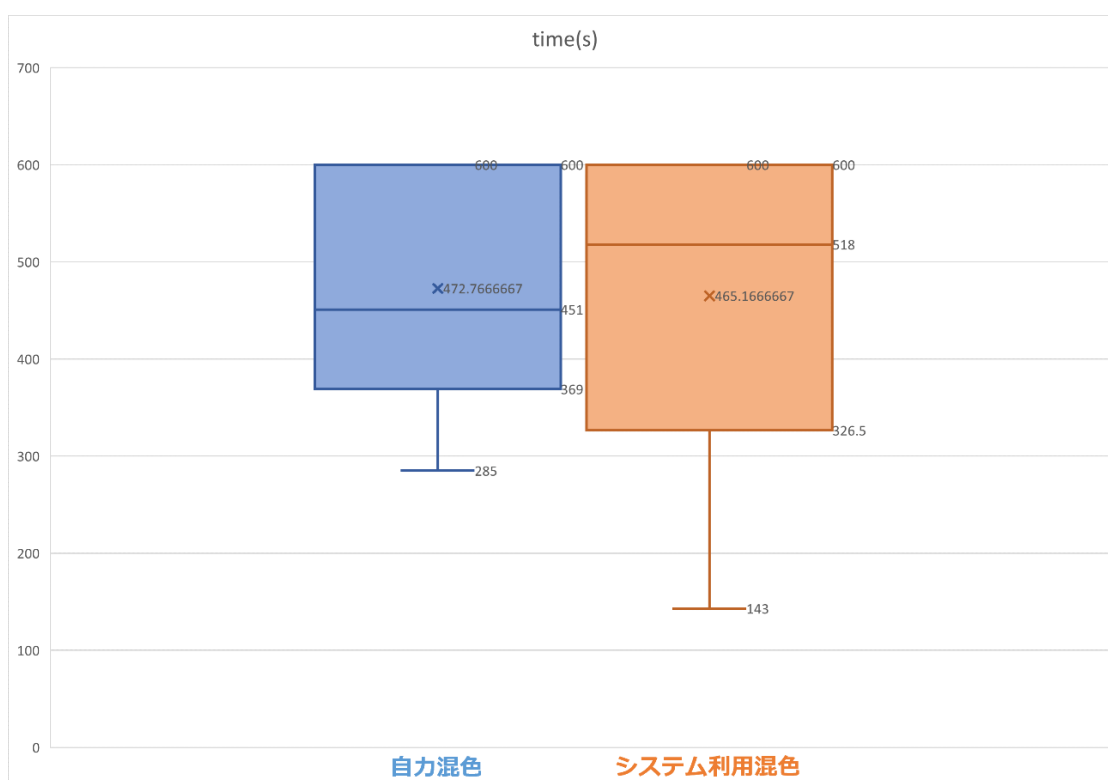


表 3. 自力混色とシステム利用混色における作業時間の分布。




表 4. 自力混色とシステム利用混色における色ごとの作業時間の分布.

6.3 考察

第二の提案システムでは、筆者がシステムを利用した場合に短時間かつ高精度でターゲット色を再現できることが確認された。一方、一般ユーザ 10 名を対象としたユーザテストでは、所要時間や色差 (ΔE) の定量評価において、自力での混色と比較して大幅な改善とはならなかったものの、特定のターゲット色や被験者においては、システムの活用による精度向上や作業効率の改善が見られた。特に、色差に関しては平均的には改善傾向が見られ、作業時間についても一部の被験者では大幅な短縮が確認された。また、ユーザアンケートではシステムの有用性を評価するポジティブな意見が多く寄せられ、特に「どの色を混ぜればよいか分からない」という課題の解決に役立ったとする回答が多かった。これらの結果から、提案システムは混色における精度向上や意思決定を支援するツールとして一定の効果を持つことが示唆された。以下では、これまでの結果を総合的に検討し、システムの有用性や改善の方向性について考察する。

6.3.1 筆者自身の結果とユーザテストの結果の乖離

提案システムの有用性を最も顕著に示したのは、筆者自身が行った混色実験である。筆者の場合は複数の色を短時間で高精度に再現できた。一方で、ユーザテストでは色再現精度にはある程度の優位性がみられたものの、作業時間の大幅な短縮効果は得られなかった。ここには、少なくとも次のような複数の要因が存在していると考えられる。

まず、筆者は本研究を進める過程で、油絵の具の混色やパレットナイフの操作に長時間慣れ親しんできた。その一方で、ユーザテストの被験者は「絵の具経験がほとんどない」状態であるため、単純に混色作業そのもののスピードや精度に差がある。また、色を混ぜる際にどの色を追加するとどのように変化

するか直感的理解や、ターゲット色との微妙な差異を肉眼で素早く見極める判断力も筆者の方が高いと推測される。その結果、筆者にとってはシステムのリアルタイム予測が最終的な調整の補助として自然に噛み合い、短時間で目標色にたどり着きやすかったと考えられる。

また、提案システムはカメラ映像からリアルタイムにターゲット色・ベース色の情報を取得して予測を更新しているため、光の当たり方やユーザの動きによる影、端末のカメラによる自動色補正など、カメラ映像のわずかな変化により「最も追加すべき色」の順位が入れ替わったり、候補色の変動したりする現象が発生する。この問題についても、筆者は研究を通じてこの挙動にある程度慣れているため、システムの予測結果が変動した場合でも、どの瞬間の予測を採用すべきか・どの色を追加すべきかを素早く判断できた。一方で、ユーザテストに参加した被験者の中には、たびたび変化するシステムの指示に困惑し、結果として「システムの判断をどこまで信頼していいかわからない」という戸惑いによる思考停止や心理的負担が作業速度を落とす一因となった可能性がある。

以上を踏まえると、「システム自体の性能」だけでなく、「ユーザの混色スキル」や「システム挙動への理解度」が総合的に影響し合っていることがわかる。本来ならばシステムをより長く利用しながら練習を重ねることで、予測結果との向き合い方が分かり、筆者が示したような短時間での高精度混色が多くのユーザにも実現可能になると期待される。しかし、今回の評価は初心者が短時間で数色の混色に取り組む形式であったため、システムの持つ本来の時短効果や精度向上効果が十分に発揮されにくかったと考えられる。それでも、6.2.2章でも述べたように、システムの利用によって混色経験の浅い被験者でも色の再現精度がわずかに向上したことや、「大きく色を外すリスク」を軽減する効果が確認された点は、初心者をサポートするツールとしての有用性を裏付ける重要な結果と言える。

6.3.2 アンケートから見るシステム導入のメリット

ユーザテストにおいては作業時間や色差の改善が限定的だった一方で、図 33 に示す被験者に対して実施したアンケートからは、システムが混色のサポートツールとして大きく貢献したことが確認された。特に、「提案システムを利用しながら混色をすることで、ターゲット色の再現が容易になったと感じましたか？」という質問(図 33 左列上段)に対する回答を見ると、被験者の 50%が「非常にそう思う」、40%が「そう思う」と評価しており、システムが被験者の混色作業を支援し、混色の負担軽減に大きく寄与していることが分かる。

さらに、「提案システムの良かった点があれば教えてください。」という自由記述形式の質問に対する回答からも、図 34 に示すような好意的な意見が多数寄せられ、システムの有用性が確認できる。特に「自力でやるとき何色を混ぜればいいのか分からず、止まってしまうことがあるが、提案システムは自分では考えがつかない色を指示してくれるため、止まることのない点。」といった意見や、「自分の予想もしていなかった色をシステムが示してくれたことで、目的の色により近づいた点。」といった意見からは、どの色を混ぜれば良いか分からず悩んでしまう停滞状態をシステムが解消し、色作りに大きく貢献していることがわかる。さらに、「初期の段階でどの色をベースの色に選ぶべきかが参考になった。」といった意見や「初めの数回の大まかな混色で役にたちました」といった意見、図 33 左列中段の回答からは、提案システムが混色の序盤で特に役に立ち、どのような色から混ぜていけば良いかという方針を確認するツ

ルとして大きな効果を発揮していることが分かる。

これらのようなアンケート結果からも、混色経験が浅いユーザにとっては、特に「まずはどのような色から混ぜるべきか」「次に何を混ぜていけばよいか」という悩みに対して、提案システムが大きく貢献することが分かる。これにより、システムが色作りにおける停滞状態を解消し、混色の序盤や何を混ぜるべきか分からない状態であっても、悩むことなく作業を進めることが可能となる。

一方で、システムが提案する色が頻繁に変動することに対する混乱や、不適切な予測が続く場合の戸惑いが課題として挙げられた。実際に図 33 右列上段の「システムを使用した混色と自力での混色を比較して、どちらの方が効率的だと感じましたか?」という質問に対する回答を見ると、自力での混色の方が効率的と回答する被験者も見受けられる。初心者には混色序盤の支援効果が大きい一方で、システムの挙動に慣れるまでの期間が必要となる点が課題であり、予測の安定性向上や UI・ワークフローの改良が必要だと考えられる。

以上を総合すると、本システムは「短時間である程度近い色まで導くサポート」としては十分効果的であり、システム利用の手軽さとアナログ制作の自由度のバランスを重視した支援システムとしても十分効果的であると言える。特に混色初心者にとっては、“何色を混ぜるべきか分からない”状態へのサポート価値が非常に高いことが示唆され、混色をサポートするツールとしての有用性が示されたと言える。



図 33. ユーザテスト被験者に実施したアンケート結果のまとめ (Google Forms にて集計)。

提案システムの良かった点があれば教えてください。

10件の回答

UIが比較的分かりやすく良かったです。

自力でやるとき何色を混ぜればいいのか分からず、止まってしまうことがあるが、提案システムは自分では考えがつかない色を指示してくれるため、止まることがない点。

初期の段階でどの色をベースの色に選ぶべきかが参考になった。

アプリが見やすく、使いやすい。複数の提案をしてくれるのでより好みの色に近づけやすくなる

初めの数回の大まかな混色で役に立ちました

ベースの色と混色中の色のRGB値が出るので、そこも混ぜる際の参考になった

リアルタイムで遅延なく動くので快適だった。
一人でシステムなしに混色するときには、次に何を混ぜればいいのか考え込む時間があったが、システムを使えばそのような時間がないのが良かった。
また、スマホを固定しておくだけで手軽に使えるので、混色の際に常に添えておいて分からなくなったり不安になったりしたら確認するという方法でも使えそうだと感じた。

自分の予想もしていなかった色をシステムが示してくれたことで、目的の色により近づいた点。また、RGB値をリアルタイムで出力しているのも参考になったため、良かった。

足りない色の要素の方針を決めやすい

どの色を加えるべきか分からない時に非常に便利だと感じた

図 34. 提案システムの良かった点に対するユーザ回答のまとめ (Google Forms にて集計).

第7章 まとめと今後の展望

本研究では、油絵の具の混色を支援する Web アプリケーションを開発し、混色作業の効率化と精度向上を目指した。Mix Box を用いて仮想データセットを構築し、これをもとに混色予測モデルを学習させるとともに、実際の絵の具の混色結果を用いたファインチューニングを実施した。これにより、学習モデルは現実の絵の具の特性を反映し、「ターゲット色へ近づけるために、ベースの色に対して絵の具セットのどの色を追加すべきか」という問題をより高精度に予測することが可能となった。また、システムのユーザインターフェースやワークフローを改善することによって、ユーザがシステムをより手軽に、より直感的に使用できるような工夫や、照明環境による影響を低減するような工夫を施した。筆者によるシステムを利用した実験では、いくつかの色の再現を高精度かつ高速に行うことに成功した。一方、ユーザテストの結果では、システムを利用することによって目的の色の再現精度は若干向上したが、作業時間に大きな変化はみられなかった。しかしながら、ユーザの意見からは好印象を得ており、特に「混色の序盤」や「何色を混ぜれば分からないといった状況」などでシステムが大いに役立つことが分かり、混色を支援するツールとしての有用性が確認された。

その一方で、本研究にはいくつかの課題が残されている。例えば、カメラの機種や環境光の影響を完全に除去することが難しく、これらの要素が予測結果に影響を与える場面が見受けられた。今後、カメラ制御や環境光の制御方法の改善が求められる。また、色再現精度をさらに高めるためには、混色予測モデルの精度向上とその汎用性を高める必要があり、特定の色に予測が偏る問題などに対してはモデルの再構築と改良を重ねていくことが求められる。さらに、これらの改良はシステムの予測の変動が頻発する問題への解決にもつながると考えられる。システム利用初心者にはこの予測の変動が作業の妨げとなる場合があるため、予測の安定化も重要な課題である。

また、本研究で採用した 12 色セットでは表現できない色も存在するため、色の拡張も今後の重要な課題として挙げられる。例えば、鮮やかな紫色を作成する際、現在のセットでは最も彩度・明度が高い赤と青を 1:1 で混ぜても期待する鮮やかな紫にはならない。このような特定の色を再現するために、12 色セットに紫色を追加することや、他にも必要に応じて色の追加を検討する必要がある。これにより、ユーザはより幅広い色彩表現が可能となり、アート制作の自由度が向上することが期待される。

今後の方向性としては、上記の課題に取り組みながら、より多くの絵の具セットやブランドへの対応を拡大し、さらに多様なユーザ層に向けたシステムの構築を目指す。また、教育分野への応用を視野に入れ、混色原理や色彩理論を学ぶための教材として活用する可能性についても検討する。これにより、混色やアート制作の支援だけでなく、色彩に関する教育や研究にも貢献できると期待している。

謝辞

最後に、本研究及び論文の作成にあたり、多くのご指導及びご助言を頂きました静岡大学工学部の岡部誠准教授に深く御礼申し上げます。また、ご助力頂いた岡部研究室の修士課程学生及び学部生の皆様方、審査をしてくださる石原進先生、甲斐充彦先生にも深く感謝申し上げます。

参考文献

- [1] 文化庁, “文化芸術関連データ集, 37. 我が国の「芸術家」人口①(職業別, 年齢別).”
- [2] 総務省統計局, “令和3年社会生活基本調査, 生活行動に関する結果, 趣味・娯楽,” 男女, ふだんの健康状態, 頻度, 年齢, 趣味・娯楽の種類別行動者数(10歳以上) - 全国.
- [3] 株式会社クサカベ, “習作用油絵の具セット,” Available: https://www.kusakabe-enogu.co.jp/product/cat_series_product?sid=101017#597. (accessed January 28, 2025).
- [4] livedoorNEWS, “見たままの色を絵の具で再現できるリアル「スポイトツウ」が登場,” Available: <https://news.livedoor.com/article/detail/14175853/>. (accessed January 28, 2025).
- [5] Š. Sochorová and O. Jamriška, “Practical pigment mixing for digital painting,” *ACM Transactions on Graphics*, vol. 40, no. 6, 2021.
- [6] B. Shneiderman, “Creativity support tools: Accelerating discovery and innovation,” *Communications of the ACM*, vol. 50, no. 12, pp. 20-32, 2007.
- [7] H. Xu, S. Chen, and Y. Zhang, “Magical Brush: A Symbol-Based Modern Chinese Painting System for Novices,” in *Proc. of the 2023 CHI Conference on Human Factors in Computing Systems*, pp. 1-14.
- [8] X. Shi, Z. Zhou, J. W. Zhang, and A. Neshati, “De-Stijl: Facilitating Graphics Design with Interactive 2D Color Palette Recommendation,” in *Proc. of the 2023 CHI Conference on Human Factors in Computing Systems*, pp. 1-19.
- [9] J. Li, E. Rawn, J. Ritchie, J. Tran O’Leary, and S. Follmer, “Beyond the Artifact: Power as a Lens for Creativity Support Tools,” in *Proc. of the 36th Annual ACM Symposium on User Interface Software and Technology*, pp. 1-15.
- [10] L. Shi, V. Babaei, C. Kim, and M. Foshey, “Deep multispectral painting reproduction via multi-layer, custom-ink printing,” *ACM Transactions on Graphics*, vol. 37, no. 6, pp. 1-15.
- [11] T. Tang, Y. Wu, P. Xia, W. Wu, X. Wang, and Y. Wu, “PColorizer: Re-coloring Ancient Chinese Paintings with Ideorealm-congruent Poems,” in *Proc. of the 36th Annual ACM Symposium on User Interface Software and Technology*, pp. 1-15.
- [12] T. van den Berge, “Vermillion: Oil Painting Simulation In Virtual Reality,” in *Proc. of ACM SIGGRAPH 2021 Immersive Pavilion*, pp. 1-2.
- [13] Adobe Research and NVIDIA, “World’s First Real-Time 3D Oil Painting Simulator,” Available: <https://developer.nvidia.com/blog/worlds-first-real-time-3d-oil-painting-simulator/>. (accessed January 28, 2025).
- [14] R. Wu, Z. Chen, Z. Wang, J. Yang, and S. Marschner, “Brush stroke synthesis with a generative adversarial network driven by physically based simulation,” in *Proc. of Expressive ’18: Joint Symposium on Computational Aesthetics and Sketch-Based Interfaces and Modeling and Non-Photorealistic Animation and Rendering*, pp. 1-10.
- [15] M.-Y. Chen, Y.-B. Huang, S.-P. Chang, and M. Ouhyoung, “Prediction Model for Semitransparent Watercolor Pigment Mixtures Using Deep Learning with a Dataset of Transmittance and Reflectance,” *arXiv preprint arXiv:1904.00275*, 2019. Available: <https://arxiv.org/abs/1904.00275>. (accessed January 28, 2025).
- [16] S. Noboru, “Kubelka-Munk Theory and Its Application,” *色材協会誌*, vol. 42, no. 10, pp. 470-476, 1969.
- [17] fchollet, “The Functional API,” Available: https://keras.io/guides/functional_api/. (accessed January 28, 2025).
- [18] X. Li, S. Chen, X. Hu, and J. Yang, “Understanding the Disharmony between Dropout and Batch Normalization by Variance Shift,” in *Proc. of IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019.
- [19] Nix Sensor Ltd., “Nix Mini 3 Color Sensor,” Available: <https://www.nixsensor.com/mini-3-color-sensor/>. (accessed January 28, 2025).
- [20] TensorFlow.js: A WebGL accelerated, browser-based JavaScript library for training and deploying machine learning models. Available: <https://www.tensorflow.org/js>. (accessed January 28, 2025).
- [21] Simonwep, “Pickr: Flat, simple, hackable color-picker library,” *GitHub Repository*. Available: <https://github.com/Simonwep/pickr>. (accessed January 28, 2025).
- [22] 日本色研事業株式会社, “新配色カード 199a,” Available: <https://sikiken.co.jp/products/50533.html>. (accessed January 28, 2025).
- [23] Mozilla Developer Network, “MediaDevices.getUserMedia,” Available:

- <https://developer.mozilla.org/en-US/docs/Web/API/MediaDevices/getUserMedia>. (accessed January 28, 2025).
- [24] P. Sloisel, "numeric.js," Available: <https://github.com/sloisel/numeric>. (accessed January 28, 2025).
- [25] Mozilla Developer Network, "WebGL API," Available: https://developer.mozilla.org/en-US/docs/Web/API/WebGL_API. (accessed January 28, 2025).
- [26] Artpictures.club, "Autumn 2023," Available: <https://artpictures.club/autumn-2023.html>. (accessed January 28, 2025).
- [27] Vincent van Gogh, "Sunflowers (1889)," Van Gogh Museum. Available: <https://www.vangoghmuseum.nl/en/collection/s0031V1962>. (accessed January 28, 2025).
- [28] World Wide Web Consortium, "Media Capture and Streams," W3C Recommendation, Jan. 22, 2016. Available: <https://www.w3.org/TR/mediacapture-streams/>. (accessed January 28, 2025).
- [29] プリントビズ株式会社, "高品質を提供するプリントビズの解答," Available: https://printbiz.jp/guide/information/news/high_quality.html. (accessed January 28, 2025).
- [30] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," arXiv preprint arXiv:1412.6980, 2014.

付録 A 実際にユーザに配布したマニュアル

混色を支援するシステムのユーザテストのマニュアル

油絵の具を混色してターゲットの色を再現する作業を、自力で行う場合とシステムを使う場合で比較する。

テストの流れ

① 練習

- 絵の具の出し方、パレットナイフの使い方、システムの利用方法を覚えるための短い練習を行います。自力での混色とシステムを使った混色を一度ずつ行います。
- 練習中は、システムや道具の使い方、テスト実施の進め方についての質問ができます。

② 本番テスト

- 色カードに塗布されたターゲット色（合計 6 色）を、「自力の混色」で 3 回、「システムを使った混色」で 3 回、それぞれ再現していただきます。
- グループ①のユーザは、色カード a・c・e の 3 色を「自力の混色」で再現し、色カード b・d・f の 3 色を「システムを使った混色」で再現してください。
- グループ②のユーザは、色カード b・d・f の 3 色を「自力の混色」で再現し、色カード a・c・e の 3 色を「システムを使った混色」で再現してください。
- グループ①②ともに、a・b・c・d・e・f の順番で色を再現してください。

③ アンケート

- テスト後、実際の混色作業の中でシステムがどの程度役に立ったか、どの段階で役立ったと感じたか、その他のシステム利用感想などに関するアンケートに回答していただきます。

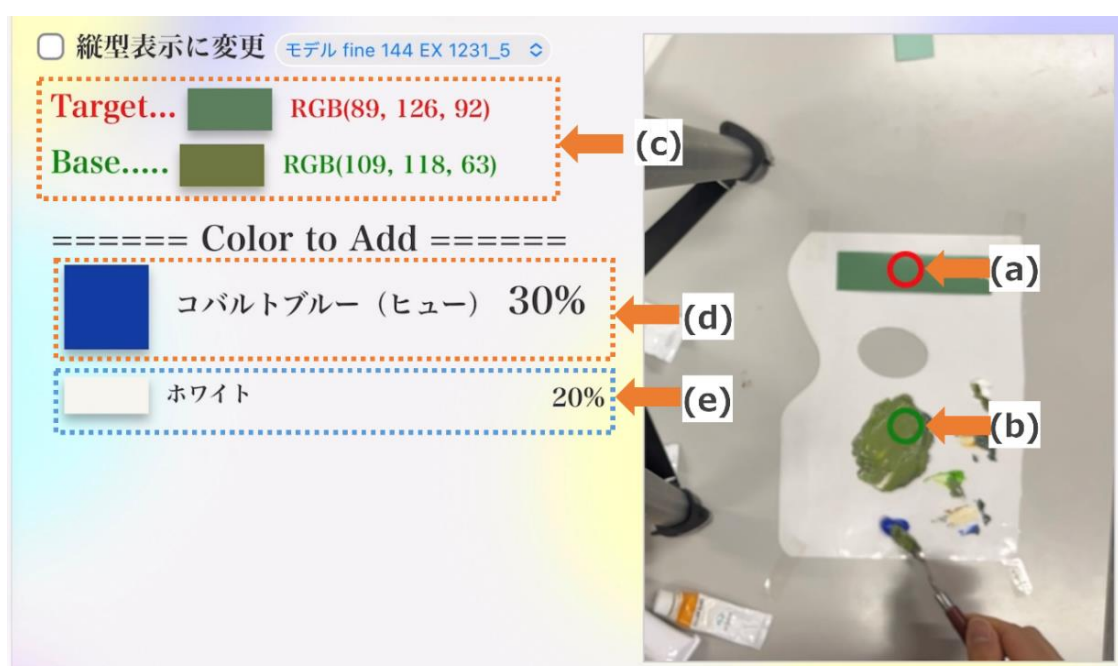
実際の混色作業の流れ

- ① 12 色の絵の具をすべて、専用の紙パレットの端の指定の場所に出してください。このとき、紙パレット上にあるマークが隠れるよう、十分な量を出してください。
- ② 監督者から混色用の紙パレットを受け取ってください。
- ③ 紙パレットが動かないように、セロハンテープで机の上に固定してください。
- ④ 「システムを使った混色」の場合は、紙パレット上の混色領域の目印とシステム画面上の混色領域の目印を合わせてください。
- ⑤ 監督者から色カード（ターゲットの色）を受け取ってください。
- ⑥ 色カードを混色用のパレット上に設置してください。
「システムを使った混色」の場合は、システム画面上の目印に合うように設置してください。
- ⑦ 監督者の実験開始の合図で混色を開始する。紙パレット上の所定のマークの位置に、色カードと同じ色を再現してください。
「自力の混色」の場合は、③で出した 12 色の色を自由にとって、自分の勘だけを頼りに色を作ってください。
「システムを使った混色」の場合は、システムの予測を参考にしながら③で出した 12 色の色を取って色を作ってください。ただし、必ずしもシステムの予測通りでなくても OK です。システムの予測を無視して、好きな色を混ぜることも可能です。
- ⑧ 十分に色カードに近い色ができた、と感じたら、監督者に「できました」と教えてください。監督者がタイムを記録したら、あなたの作業は終了です。
- ⑨ 混色の制限時間は 10 分です。10 分経過した場合はその時点で作業を中断してください。

混色作業について

- システム利用時は紙パレット上の所定のマークが完全に隠れるように、色カードの指定された色と同じ色を再現してください。
- もし紙パレット上の絵の具が足りなくなった場合は、チューブから追加してください。
- パレットナイフで絵の具を取るとき、パレットナイフに絵の具が付着している場合は、一度パレットナイフをティッシュペーパーできれいになるように拭いてください。
- できるだけ色カードに近い色が出るように努力してください。全く同じ色ができるのが理想です。
- できるだけ早く、色カードと同じ色を作り終えてください。

システムの画面の見方



- (a) ターゲットの色の取得領域 (赤い丸)
 - (b) ベースの色 (混色途中の色) の取得領域 (緑の丸)
 - (c) 実際に取得されたターゲットの色の RGB 値とベースの色の RGB 値
 - (d) ベースの色に対して最も追加すべき色とその量の目安
 - (e) 追加すべき色のその他の候補
- システムが最も追加すべきと予測する色は(d)に表示されます。
 - システムの予測結果を参考にする場合、(d)の最も追加すべき色や、(e)のその他の追加色の候補の中から、好きな色を参考として追加していただけます。
 - 追加すべき色のその他の候補は、1つも表示されない場合や、2つ以上表示される場合があります。
 - (d)(e)のパーセント表示は、ベースの色に対して混ぜるべき量の割合の目安です。

その他の注意点・質問について

- 混色中の「色の作り方」についてのアドバイスはできません。
- システムや道具の使い方、テストの進め方に関する質問は常時受け付けます。