

# 深層学習を用いた衣服形状の細部まで再現可能な縫製パターン自動生成

○鈴木 ひかる（中央大学），Alessandro Moro（RITECS），  
Sarthak Pathak（芝浦工業大学），梅田 和昇（中央大学）

## Automatic Sewing Pattern Generation Capable of Reproducing Detailed Garment Shapes Using Deep Learning

○ Hikaru SUZUKI (Chuo University), Alessandro MORO (RITECS),  
Sarthak PATHAK (Shibaura Institute of Technology) and Kazunori UMEDA (Chuo University)

**Abstract:** In this study, we propose a method for automatically generating sewing patterns from a single garment image using deep learning. Sewing patterns serve as the design blueprints of clothing. In garment production, predicting and designing sewing patterns from fashion sketches requires extensive expertise and is considered highly challenging. Automating this process is expected to improve both the efficiency and accuracy of garment manufacturing. Most existing studies focus on predicting and generating sewing patterns for entire garments. However, this approach tends to reduce shape fidelity for smaller and more diverse parts, such as collars and sleeves. To address this issue, our method divides a garment image into three major components—bodice, sleeve, and collar—and inputs each part into a dedicated sewing pattern generation model. This enables faithful reproduction of garment shapes, even for parts with complex structures.

### 1. 緒言

近年、ファッション業界では個性や多様性を重視したデザインが求められており、多くのデザイナーが独創的な作品を発表している。しかし、ファッションのトレンドは短い周期で変化するため、限られた時間で新作を市場に投入することが不可欠となっている。このような状況では、デザイナーの独創性を十分に發揮しつつ高品質な衣服を製作することが難しいという課題がある。

衣服製作は一般に、デザイン画の作成から始まり、それを基に縫製パターンを製作する。その後、その縫製パターンに沿って布を裁断、縫製を行って、衣服の完成となる。縫製パターンとは、衣服の設計図を指し、衣服の製作では無くてはならないものである。特に縫製パターンの設計には高度な服飾の専門知識や経験が求められ、製作者の技能に大きく依存する。また、製作者の技量不足によって縫製パターンが作成出来ないということで、作りたい衣服のデザインが制限される場合もある。

この背景を受け、衣服製作において最も難しい工程だとされる縫製パターンの製作に焦点を当て、衣服の画像やデザイン画から縫製パターンを自動的に生成する技術が実現可能となれば、衣服製作のプロセスが効率化され、更に服飾業界の労働環境の改善に繋がると予測される。

我々はこれまでに、深層学習モデルを用いて衣服画像から縫製パターンを生成する手法の検討を行ってきた[1]。従来は、衣服の縫製パターンを一枚の画像にまとめ、全てのパーツをまとめて学習させる方式をとり、縫製パターンの自動生成を目指した。その結果、スカートなど形状が明確で面積の大きいパーツについては、衣服画像に対応した縫製パターンを比較的正確に生成できた。しかし、衿や袖など面積が小さく形状変化が複雑なパーツでは、対応する縫製パターンを正確に生成することが難しく、特に衿についてはパターンの生成自体が不可能であった。この原因は、縫製パ

ターン全体を一括で扱ったことで学習対象となる特徴量が多くなり、モデルが面積の大きいパーツや形状が分かりやすい部分の特徴を優先的に学習してしまった点にあると考えられ、その結果、面積が小さく、形状が複雑なパーツの生成が困難であったと予想される。

加えて、学習データの不足も本研究の重要な課題である。これまでに衣服の画像解析など深層学習を用いたファッションの研究では、DeepFashion [2] や Fashion-MNIST [3] などが広く利用されてきた。しかし、これらのファッションデータセットには衣服の縫製パターンの画像は入っておらず、これらを用いての縫製パターン生成モデルの構築は難しい。

Korosteleva [4] らは、3D モデルを活用し 20,000 種類以上の衣服の縫製パターンを含んだデータセットを構築した。しかし、このデータセット内の縫製パターンは実際に衣服製作に使われる縫製パターンとは形式が異なるもので、これを用いて縫製パターン生成モデルを構築したとしても、出力された縫製パターンの実用性が低いことが課題として挙げられる。

そこで、本研究では、実際の縫製パターンを用いたデータセットを自作し、衣服画像を「身頃」「袖」「衿」の 3 つのパーツに分割して、それぞれに特化した深層学習ベースの縫製パターン生成モデルを構築する。これにより、衣服画像 1 枚から細部の形状まで忠実に反映された、より正確かつ実用的な縫製パターンの予測・生成を可能にすることを目的とする。

### 2. 提案手法

#### 2.1 概要

本研究では、衣服画像 1 枚から衣服の設計図である縫製パターンを生成することを目指す。その際に衣服を「身頃」「袖」「衿」の 3 つの主要パーツに分割し、それぞれのパーツに特化した縫製パターン生成モデルを構築する。衣服の各パーツの縫製パターンを一括で生成すると、袖や衿などの面積が小さく形状が複雑なパーツでは形状の再現が困難であった。この課題を解決する為、パーツごとに独立したモデルを学習させる



(a) Clothing image



(b) Part mask image

**Fig. 1** Image used for segmenting clothing

ことで、それぞれの形状的特徴をより的確に捉え、細部まで忠実に反映された縫製パターンを生成する。

## 2.2 衣服画像の分割と前処理

提案手法では、衣服画像をそのまま画像生成モデルに入力するのではなく、まず Segment Anything Model 2 (SAM2) [5] を用いて「身頃」「袖」「衿」の 3 つのパートに分割する。この節では、入力された衣服画像を各パートに分割し、縫製パターン生成モデルに入力するまでの画像処理の流れを説明する。

衣服分割モデルに画像を入力する前に、入力衣服画像にソーベルフィルタを適用し、輪郭や形状の境界線、しわや縫い目の位置といった縫製パターン生成に必要な情報を強調する。色情報は縫製パターン生成には不要であるため、この段階で形状情報のみを抽出し、不要な情報を除去する。

SAM2 は、Meta AI が開発した汎用物体分割モデルであり、ユーザが与えるプロンプトに基づいて画像中の任意の領域を高精度に抽出できる。学習済みの膨大な画像データを基盤としており、未知の物体カテゴリや複雑な形状にも対応できるため、事前にクラス情報を与えなくても柔軟に分割可能である。提案手法では、seed point を設定し、衣服を 3 つのパートに分割する。

しかし、本研究の対象となる衣服では、衿・袖・身頃の色が同一である場合が多く、領域境界が不明瞭になる。そのため、単純に seed point を設定しただけでは、正確にパートを切り出すことが困難であった。この課題を解決するため、本研究では、分割対象の衣服画像とともに、各領域（衿・袖・身頃）を異なる色で塗り分けた補助画像を用意した。入力画像と補助画像を Fig. 1 に示す。

この補助画像を基に seed point を設定し、SAM2 で領域を抽出する。抽出後は、補助画像の抽出されたパートを参照して元の衣服画像から該当パートを切り出す。

切り出しの際は、まず服全体、衿、右袖、左袖、顔と首の領域に seed point を設定する。そして、seed point の情報を基に衣服を 3 つのパートに分割する。まず、衿と両袖を個別に切り出し、身頃は服全体の領域から衿・両袖・顔と首の領域を除外することで抽出する。この方法により、衿や袖を誤って含む身頃領域や、顔部分が切り取られてしまうといった誤分割を防止する。

その後、得られたパート画像を  $256 \times 256$  pixel の黒背景画像の中央に配置し、入力画像のサイズと位置を統一する。この分割および前処理工程により、異なる衣服画像から得られたパートであっても、次節で説明する縫製パターン生成モデルに適した統一的な入力形式が確保される。

## 2.3 縫製パターン生成モデル

本研究では、各パート画像から対応する縫製パターンを生成するために、条件付き敵対的生成ネットワーク (Conditional GAN, CGAN) [6] をベースとした Pix2Pix [7] を採用する。Pix2Pix は画像から画像への変換タスクに特化しており、入力画像と出力画像のペアを用いて学習できる点が特徴である。本研究のように衣服パート画像（入力）から対応する縫製パターン画像（出力）を直接生成するタスクに適しており、エッジ情報や形状特徴を効果的に活用できる。また、入力と出力の局所的対応関係を保持しながら変換を行うため、細部の形状再現性向上にも寄与する。

入力画像には前処理済みのパート画像を、出力画像には対応する縫製パターン画像を用い、「身頃」「袖」「衿」の各パートごとに独立した Pix2Pix モデルを構築、学習させた。これにより、パートごとの形状的特徴を個別に学習し、形状の忠実な再現を可能にする。

損失関数には、生成結果のリアリティ向上を目的とした敵対的損失と正解パターンとの画素レベル一致度を高める L1 損失の和を採用する。

衣服の各パートは、いずれも形状バリエーションが多く、形状の違いによって縫製パターンの構造も大きく変化する。そのため、複数の形状を同一モデルで一括して学習させると、学習データ中で頻度の高い形状や特徴的な形状が優先的に学習され、その他の形状の生成精度が低下する傾向が見られた。特に衿は種類間の形状差が顕著であり、全種類を一度に学習させた場合、特定形状に引き寄せられた出力となり、各種類に固有の形状を正確に再現することが困難であった。

そこで本研究では、この問題を軽減しタスクを単純化するため、まず各パートごとに形状分類を行い、その後に分類ごとの生成モデルで学習を行う方式を採用する。各パートの縫製パターン生成モデルの手法を以下に示す。

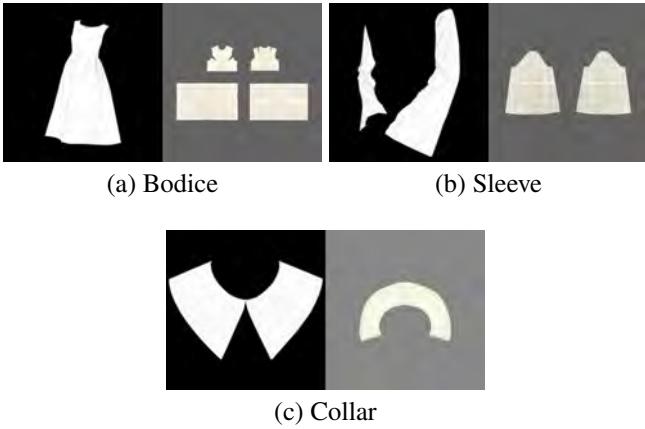
- 身頃：ウエスト切替の有無で分類し、それぞれの専用生成モデルに入力する。
- 袖：半袖か長袖かを分類し、それぞれの専用生成モデルに入力する。
- 衿：入力画像を 5 種類の衿形状のいずれかに分類し、対応する衿専用生成モデルに入力する。

この方式により、各モデルは限定された形状特徴（例：角の丸み、長さ、幅など）を重点的に学習でき、形状的特徴を忠実に反映した縫製パターン生成が可能となる。

## 2.4 データセットの構築

本研究では、縫製パターン生成モデルの学習に用いるため、入力画像（衣服画像）と出力画像（縫製パターン画像）のペアから成るデータセットを自作した。まず、インターネット上から身頃、袖、衿のパートごとに多様な形状を持つ衣服画像を収集した。衣服は、着用する人の体型やポーズによって形状を大きく変える。今回は衣服の形状多様性に対応するため、同じ形状の衣服であっても違う人が着用する画像や着用者が様々な向きやポーズを取っている画像をデータの中に含めた。

次に、2.2 節と同様に収集画像にソーベルフィルタを適用し、衣服の形状などの縫製パターン生成に有用な



**Fig. 2** An example of a dataset

**Table 1** Type of bodice and number of images

Bodice Type	Total Images
A-line	66
Panel Line	62
Box Line	68
Waist Seam (Gathered Skirt)	70
Waist Seam (Straight Skirt)	65
Waist Seam (Trapezoid Skirt)	61
<b>Total Images</b>	<b>392</b>

情報を強調した。

その後、labelme[8]を用いて各パーツ領域をポリゴンで囲み、アノテーションを行った。取得した座標情報に基づき各パーツを切り出し、2.2節と同様に黒背景の $256 \times 256$ pixelの正方形画像の中央に配置して学習用の入力画像とした。さらに、切り出した全パーツ画像に対して水平方向の反転処理を行い、データ拡張を実施した。

出力画像については、まず入力画像に対応する縫製パターンを設計した。特に衿については、同一の衿種であっても形状の異なる複数のバリエーション(2~4種類)を用意し、形状的多様性を確保した。そして、製作した縫製パターンをスキャン、編集を行い、グレー背景の $256 \times 256$ [px]の正方形画像の中央に配置して学習用の出力画像とした。背景をグレーに設定したのは、Pix2Pixが画像変換タスクであるため、入力画像との差異を視覚的に明瞭化し、学習効率を向上させることを期待したためである。

最終的なデータセットは、各パーツについて入力画像と出力画像のペアから構成する。Fig. 2に各パーツの縫製パターン生成モデルに学習させたデータセットの一例を、Table 1~Table 3に各データセットの形状のバリエーションと枚数を示す。

### 3. 実験

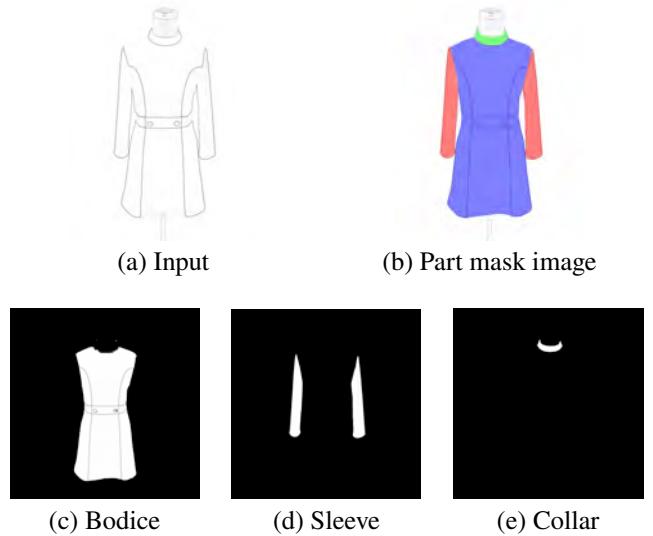
#### 3.1 実験環境と実験条件

実験は、NVIDIA GeForce RTX 4080 (24 GB VRAM)を1基搭載したPC環境で実施した。実装にはPython 3.12を使用し、深層学習フレームワークとしてPyTorch 2.2を採用した。

使用するデータセットは本研究で自作したもので、対象をワンピースに限定し、「身頃」「袖」「衿」の3

**Table 2** Type of sleeves and number of images

Sleeve Type	Total Images
Long Sleeve – Straight	60
Long Sleeve – Tight	60
Long Sleeve – Puff	60
Long Sleeve – Flare	60
Short Sleeve – Straight	60
Short Sleeve – Puff	60
Short Sleeve – Flare	60
<b>Total Images</b>	<b>420</b>



**Fig. 3** Segmentation results

パーツに分割した。それぞれのパーツに対し、入力画像（衣服画像）と対応する出力画像（縫製パターン画像）のペアを構築した。データは学習用、検証用、テスト用に8:1:1の比率で分割し、パーツごとに独立して学習を行った。

学習条件としては、全てのモデルでバッチサイズを1、学習率を0.0001、総学習回数を1000と設定し、100epごとにモデルを保存した。学習中は損失関数の推移を記録し、保存したモデルの中から、損失値が小さく、かつ衣服製作経験者2名による評価において生成画像が入力衣服の形状を最も忠実に反映していると判断されたエポックのモデルを最終モデルとして採用した。

#### 3.2 衣服画像分割の結果

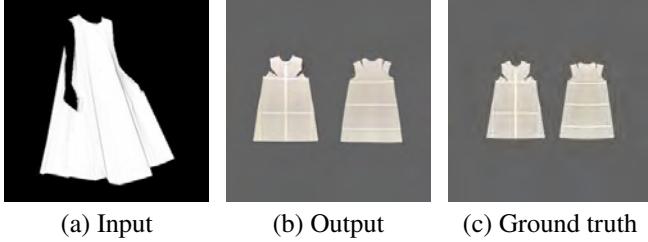
本節では、縫製パターン生成の前処理としてSAM2を用いた衣服画像のパーツ分割の結果を示し、提案手法の有効性を確認する。Fig. 3に、入力した衣服画像とそれを提案手法を使用し分割した各パーツを示す。Fig. 3より、身頃、袖、衿の各パーツにおいて、適切に切り出しが行われていることが確認できる。

#### 3.3 縫製パターン生成結果

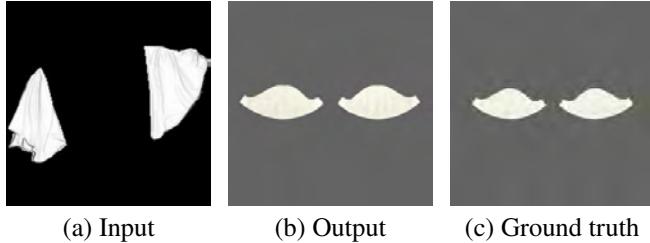
本節では、各パーツ（身頃・袖・衿）の縫製パターン生成モデルによる画像生成結果を示し、示した画像を基に各縫製パターン生成モデルの定性的評価を行う。Fig. 4に身頃の縫製パターン生成モデルが生成した縫

**Table 3** Type of collars, number of shape variations, and number of images

Collar Type	Number of Shape Variations	Total Images
Shirt Collar	4	100
Stand Collar	3	80
Sailor Collar	4	93
Flat Collar	4	91
Shirt Collar with Band	2	98
<b>Total Images</b>		<b>462</b>



**Fig. 4** Bodice pattern generation results



**Fig. 5** Sleeve pattern generation results

製パターン画像, Fig. 5 に袖の縫製パターン生成モデルが生成した縫製パターン画像, Fig. 6, Fig. 7 に衿の縫製パターン生成モデルが生成した縫製パターン画像を示す。

Fig. 4~Fig. 7 を見ると, 衿と袖は入力画像の形状を反映した縫製パターンが概ね生成出来ていた。一方, 身頃については形状が少し崩れてしまい, 形状を正確に反映した縫製パターンを生成することが他のパートと比べて困難であったことが分かる。

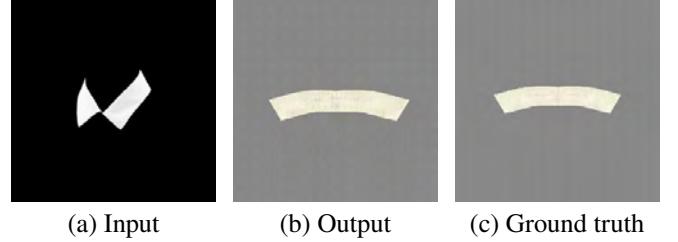
### 3.4 生成画像の評価

生成した縫製パターンが入力衣服の形状をどれだけ正確に反映しているかを評価するため, Intersection over Union (IoU) [9] を採用した。IoU は本来, 物体検出やセグメンテーションの分野において領域一致度を評価するために広く用いられる指標である [10]。しかし, 形状一致度の定量評価にも有効である事が報告されている [11]。このように IoU は, 本研究における生成結果の形状的正確性を評価する指標として適切であると判断した。IoU は次式で定義される。

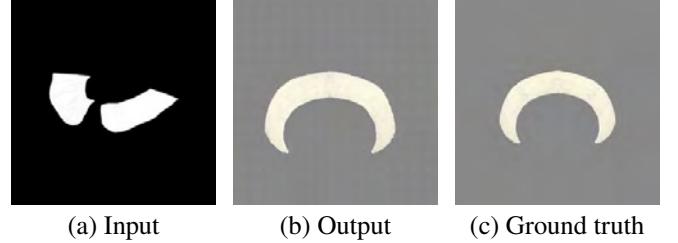
$$\text{IoU} = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

各衣服パートごとに, テストデータ全体で IoU 値を算出し, その平均値を求めた。結果を Table 4~Table 6 に示す。各パートにおけるテストデータの枚数は 衿が 51 枚, 袖が 42 枚, 身頃が 42 枚である。

今回の IoU 計測結果では, 衿が最も高い平均 IoU



**Fig. 6** Collar pattern generation results 1 (shirt collar)



**Fig. 7** Collar pattern generation results 2 (flat collar)

(0.760) を示し, 次いで袖 (0.678), 身頃 (0.552) の順となった。衿と袖は形状や領域が限定されているため, 入力衣服の形状を反映した縫製パターンが生成しやすかったと考えられる。一方, 身頃は形状の多様性や装飾要素の影響が大きいため, 形状再現精度が低下したと考えられる。これらの傾向や原因については, 次節でより詳細に考察する。

### 3.5 考察

#### 3.5.1 衣服の分割モデル

提案手法では, 縫製パターン生成モデルへの入力として十分な精度で, 衣服画像を「身頃」, 「袖」, 「衿」の 3 パーツに分割することに成功した。しかし, パーツ分割の際には補助画像の作成や seed point の設定が必要であり, 前処理に一定の手間を要するという課題が残った。今後は, 精度を維持しつつも, より自動化された簡便なパート切り出し手法を検討する必要がある。

#### 3.5.2 縫製パターン生成モデル

IoU の評価結果によれば, 衿および袖は比較的高い形状一致度を示したのに対し, 身頃は他の 2 パーツに比べて低い値を示した。

衿と袖の生成の再現性が高かった要因としては, これらのパートは領域が限定されており, 着用者の姿勢変化による形状の変動も小さいため, 生成モデルがエッジや輪郭の特徴を学習し易かったことが挙げられる。特に衿については, 事前に 5 種類の形状に細分類し, 各形状に特化したモデルを学習させたことが, 形状再現性の向上に寄与したと考えられる。

一方, 身頃の IoU が低かった要因として考えられる

**Table 4** IoU Results For Bodice Types

Bodice Type	Mean IoU
Bodice Skirt	0.649
Bodice Dress	0.455
Average	<b>0.552</b>

**Table 5** IoU Results For Sleeve Types

Sleeve Type	Mean IoU
Short Sleeve	0.660
Long Sleeve	0.697
Average	<b>0.678</b>

のは2つある。1つは身頃の形状のバリエーションの多さである。身頃は着用者の体型や姿勢の影響を大きく受けるため、他のパーツと比べて形状の多様性が高く、モデルによる特徴学習が困難であった可能性がある。もう1つの要因は身頃の領域の広さと情報量の多さである。身頃は衣服の中で最も面積が広く、模様や装飾などの不要な情報を多く含む場合が多いため、形状特徴の抽出が難しく、生成精度が低下したと考えられる。改善策としては、パーツ領域内部の模様や装飾を除去し、隠れている部分を補完する画像処理を導入することが有効である。また、衣服が本来3次元構造を持つことを踏まえ、入力画像から一旦3D形状を復元した上で縫製パターンを生成する手法も有望である。このような処理により、形状や構造の明瞭化が進み、より高精度かつ実用的な縫製パターン生成が可能になると考えられる。

## 4. 結言

本研究では、衣服画像から「身頃」「袖」「衿」の各パーツに対応する縫製パターンを自動生成する手法を提案した。まず、SAM2と補助画像を用いたパーツ分割および前処理により、縫製パターン生成に適した入力データを作成した。次に、各パーツごとに縫製パターン生成モデルを構築することで、従来の衣服の縫製パターンを一括で学習を行う手法では再現が困難であった小さいパーツにおいても、形状をより忠実に反映した縫製パターンを生成できることを示した。

実験の結果、提案手法は形状が一定である衿および袖において高いIoUを達成した一方、着用者の姿勢や体形による形状の多様性やオクルージョンの影響が大きい身頃では生成精度が低下する傾向が確認された。

今後は、全てのパーツでの形状再現性を向上させるため、パーツ領域内部の模様を除去しオクルージョンを補完する画像処理の導入や、衣服の持つ3次元構造を1度復元した上で縫製パターンを予測する手法の検討が有効であると考えられる。

## 参考文献

- [1] H. Suzuki, K. Miura, A. Moro, S. Pathak, and K. Umeda, “Realistic sewing pattern generation and dataset construction for GAN-based fashion synthesis,” in Proc. SICE FES 2025, 2025.
- [2] Z. Liu, P. Luo, S. Qiu, X. Wang, and X. Tang, “Deep-Fashion: Powering Robust Clothes Recognition and Retrieval with Rich Annotations,” in 2016 IEEE Conference on Computer Vision and Pattern Recognition

**Table 6** IoU results For Collar Types

Collar Type	Mean IoU
Sailor Collar	0.818
Shirt Collar	0.738
Shirt Collar with Collar Back	0.824
Stand-up Collar	0.630
Flat Collar	0.789
Average	<b>0.760</b>

(CVPR).pp. 1096–1104.

- [3] H. Xiao, K. Rasul, and R. Vollgraf, “Fashion-MNIST: a Novel Image Dataset for Benchmarking Machine Learning Algorithms,” Sept. 15, 2017, arXiv: arXiv:1708.07747.
- [4] M. Korosteleva and S.-H. Lee, “Generating Datasets of 3D Garments with Sewing Patterns,” Sept. 12, 2021, arXiv: arXiv:2109.05633.
- [5] N. Ravi, V. Gabeur, Y.-T. Hu, R. Hu, C. Ryali, T. Ma, H. Khedr, R. Rädle, C. Rolland, L. Gustafson, E. Mintun, J. Pan, K. V. Alwala, N. Carion, C.-Y. Wu, R. Girshick, P. Dollár, and C. Feichtenhofer, “SAM 2: Segment Anything in Images and Videos,” Oct. 28, 2024, arXiv:2408.00714.
- [6] M. Mirza and S. Osindero, “Conditional Generative Adversarial Nets,” Nov. 06, 2014, arXiv: arXiv:1411.1784.
- [7] P. Isola, J.-Y. Zhu, T. Zhou, and A. A. Efros, “Image-to-Image Translation with Conditional Adversarial Networks,” in 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).pp. 5967–5976.
- [8] K. Wada, “labelme: Image Polygonal Annotation with Python,” Zenodo, 2021.  
Available: <https://github.com/wkentaro/labelme>
- [9] H. Rezatofighi, N. Tsai, J. Gwak, A. Sadeghian, I. Reid, and S. Savarese, “Generalized Intersection over Union: A Metric and A Loss for Bounding Box Regression,” Apr. 15, 2019, arXiv: arXiv:1902.09630.
- [10] D. Zhou, X. Wang, P. Krähenbühl, and F. Li, “IoU Loss for 2D/3D Object Detection,” Aug. 11, 2019, arXiv:1908.03851.
- [11] P. Zeng, J. Yin, Y. Gao, J. Li, Z. Jin, and S. Lu, “Comprehensive and Dedicated Metrics for Evaluating AI-Generated Residential Floor Plans,” Buildings, vol. 15, no. 10, p. 1674, May 2025.