

画像生成学習が視覚理解能力へ与える影響の分析

神林 励旺¹ 稲葉 達郎² Benjamin Heinzerling^{3,1}
 坂口 慶祐^{1,3} 乾 健太郎^{2,1,3} 磯沼 大^{1,4,3}
¹ 東北大学 ² MBZUAI ³ 理化学研究所 ⁴ NII LLMC
 kambayashi.reo.t6@dc.tohoku.ac.jp

概要

視覚理解と画像生成を単一モデルで扱う Unified VLM が提案されている一方、理解・生成の混合学習による相乗効果や干渉については十分に解明されていない。本研究では、混合学習が視覚理解のどの能力に有効であるかを検証するために合成データを設計し、視覚理解を四つの能力に細分化して分析を行った。理解データのみでの学習と、理解・生成データの混合学習を比較した結果、混合学習では、同一更新ステップにおいて学習初期から性能の向上が見られ、より高い正解率が得られる傾向を確認した。また、図形の属性認識は理解タスクのみでも高精度に達する一方、位置関係の把握には混合学習が特に有効であることが示唆された。

1 はじめに

大規模言語モデルを基盤とし、視覚エンコーダやモダリティ接続部を組み合わせることで、画像と言語を同一モデルで扱う Vision-Language Models (VLMs) が発展している。従来は、画像入力に基づく視覚理解 (VQA) タスクやキャプションなどを目的とする系統と、画像生成を目的とする系統が独立に発展してきたが、近年では理解と生成を単一の枠組みで統合する Unified VLM が提案され、両タスクを混合学習することで相互に性能が向上することが期待されている [1]。先行研究では、理解データの増加が生成品質を、生成データの増加が理解性能をそれぞれ改善することが確認されている [2]。統合モデルにおける性能の相互改善の要因として、画像入力と画像出力の表現空間の整合や、生成で獲得された知識が理解へ転移する可能性が議論されている [3]。しかし、相互改善がどのような表現形成によって生じるのかという機序は依然として十分に解明されておらず、その効果が視覚理解のどの能力の向上として現れるのかについても体系的な分析は

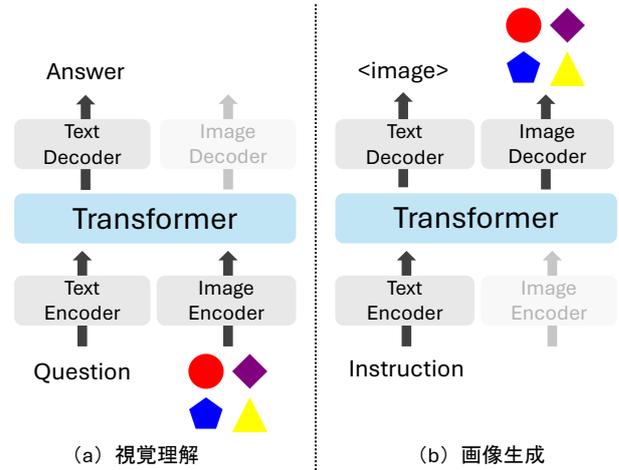


図 1: Unified VLM のアーキテクチャ。(a) 視覚理解と (b) 画像生成の両方のタスクにおいて、単一の Transformer が使用される。

限られている。

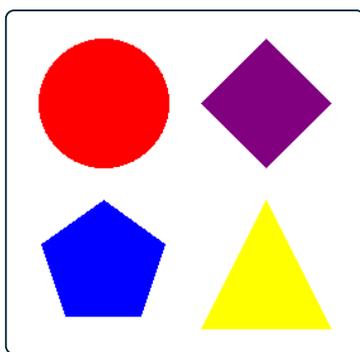
そこで本研究では、メカニズム解明に向けた第一歩として、視覚的属性と図形配置を制御可能な合成データを設計し、これを用いて視覚理解と画像生成の学習・評価実験を行った。その際、視覚理解を Localization / Relation / Attribute / Counting の四タスクに細分化し、混合学習がどの能力に寄与するかを検証した。

実験では、視覚理解データのみでの学習と、画像生成との混合学習を比較し、画像生成学習の追加が視覚理解にどのように寄与するかを分析した。結果として、混合学習は同一更新ステップでの比較で学習初期から性能を向上させ、特に位置関係の把握を要するタスクにおいて改善が見られた。

2 関連研究

2.1 Unified VLMs

VLM の視覚表現には主に二つの手法がある。一つは、画像を離散的な視覚トークン列へ符号化し、



Object Localization

Q: Where is the red circle located? A: Top-Left

Relation

Q: What is the spatial relationship of the red circle relative to the yellow triangle?
A: Diagonal

Attribute

Q: What is the shape of the object at Top-Right? A: diamond

Counting

Q: How many triangles are there? A: 1

画像生成

Top-Left: red circle. Top-Right: purple diamond. Bottom-Left: blue pentagon. Bo...

図 2: 2×2 グリッド合成画像におけるタスク例. 左は入力画像 (各セルに 1 つの図形オブジェクト) を示し, 右は視覚理解 (VQA) の四タスク (Localization/Relation/Attribute/Counting) および, 四セルの属性列挙に基づく画像生成タスクの例を示す.

テキストトークン列と連結した系列を自己回帰モデルに入力することで, 次トークン予測に基づき理解と生成を統一した枠組みで扱う手法である. LWM [4] や Chameleon [5] は, VQ [6, 7] 等の画像トークナイザで得た視覚トークン列を用いて, 視覚とテキストを同一の系列としてエンコード・デコードする. もう一つは, 画像を視覚エンコーダで連続的な特徴へ変換し, それを LLM の入力表現へ射影して理解を行うとともに, 生成では連続表現の回帰として視覚表現を学習する手法である. Emu [8] や MetaMorph [2] は, CLIP [9] や SigLIP [10] 等の視覚エンコーダを用い, 生成時には得られた視覚表現を条件として拡散モデルにより画像をデコードする. 加えて, 理解と生成で要求される視覚表現の粒度が異なる点に着目し, 符号化経路を分離する設計も提案されている. Janus [11] は, 理解では SigLIP による意味特徴を用い, 生成では VQ tokenizer [12] により画像を離散的なトークン列へ符号化することで, 理解・生成の視覚表現を分離しつつ単一の Transformer で処理する枠組みを採用している.

2.2 画像生成と視覚理解の学習の相関

MetaMorph [2] は理解と生成の相互影響を系統的に分析し, 生成データのみでの学習ではサンプル効率が悪い一方, 理解データを含む場合は少量の生成データでも生成能力を効率的に獲得できることを示した. さらに, 理解タスク別の相関分析では, 視覚能力中心の VQA は生成と強く相関する一方, 知識依存の VQA は相関が弱いと結論づけている. また, 生成タスクで獲得された知識が理解タスクへ転移すること, そしてその転移が基盤となる LLM 内部で

起きていることが示唆されており, マルチモーダルな入出力の表現空間の統合が汎化性能の向上に寄与すると指摘されている [3]. 一方, Janus [11] は, 理解と生成で要求される視覚表現の粒度が異なるため, 単一のエンコーダでの学習が性能低下につながり得ることを指摘している. これらの研究では, 画像内の要素と要求される能力が複合的に作用するため, 性能変化の要因を個別に切り分けて特定することが難しい. そこで本研究では, 視覚能力の構成要素を統制可能な合成画像を用い, 混合学習における要因を検証する.

3 タスク設定

画像生成の学習が視覚理解のどの能力に寄与するかを検証するため, Localization / Relation / Attribute / Counting の四能力に着目し, それぞれを個別に評価できる合成データを設計する.

3.1 画像仕様

Localization と Relation では, オブジェクトの位置特定および相対位置関係の判定を行うため, 配置を離散的に制御可能なグリッド構造が必要である. また Attribute の分析のために「色」と「形状」を属性として導入し, Counting の分析のために画像内に複数オブジェクトを配置して条件を満たす個数を問う設定を可能にする. 画像は 2×2 のグリッドから構成され, 各セルには必ず一つの図形オブジェクトを配置する (図 2). 各オブジェクトは「色」と「形状」の組で表す. 色は{red, blue, green, yellow, purple, orange}, 形状は{circle, triangle, square, diamond, pentagon, hexagon} から選択する.

3.2 視覚理解 (VQA) タスク

視覚推論を扱う代表的な合成 VQA データセットである CLEVR [13] では、質問を基本的な推論操作の組み合わせとして表現し、詳細な性能の分析を可能にしている。本研究でもこの考え方を踏まえ、より明確に視覚理解を能力ごとに切り分けて評価するため、以下の四タスクを定義する。

Localization (Loc.) 条件に合うオブジェクトを画像の中から特定する、絶対的な位置把握能力を評価する。質問で指定された色と形状を持つオブジェクトの位置を推定し、存在しない場合は Not Present を回答する。

Relation (Rel.) 複数のオブジェクトの位置を特定した上で、相対的な位置関係を把握する能力を評価する。質問で指定された2つのオブジェクト間の相対的な位置関係を5分類 (To the Left / To the Right / Above / Below / Diagonal) で回答する。

Attribute (Att.) オブジェクトの属性を特定する能力を評価する。質問で指定された位置に存在するオブジェクトの色、または形状を回答する。

Counting (Cnt.) 条件に合うオブジェクトを画像の中から特定し、その数を集計する能力を評価する。質問の中で色または形状のいずれか一方で条件付けし、該当オブジェクト数 (0-4) を回答する。

質問の曖昧性を避けるため、Localization および Relation において対象となる色、形状の組は画像内で一意に定まるように、同一の色と形状の組が複数セルに出現する画像を除外する。

3.3 画像生成タスク

テキストで各セルの属性を列挙し、その配置に一致する画像を生成する。入力プロンプトは Top-Left / Top-Right / Bottom-Left / Bottom-Right の順に、各セルの図形を <position>: <color> <shape>. の形式で指定する。この入力に対し、モデルはまず <image> を出力し、続いて画像を表す視覚トークン列を生成する。

4 実験

4.1 実験設定

図 1 の構成に従い、事前学習済みの画像エンコーダ (VQ-VAE [6], SigLIP [10]) を用いて画像を Transformer 層に入力する。画像生成のデコーダに

は、エンコーダの種類によらず VQ-VAE [6] を使用する。VQ-VAE [6] については、vq_ds16_t2i [12] を使用し、解像度は 256×256 とした。SigLIP については、SigLIP-base-patch16-224 [10] を使用し、解像度は 224×224 とした。基盤となる LLM には Vicuna-7B-v1.5 [14] を採用し、視覚アダプタ、画像生成ヘッド、および LLM を同時に更新する。この際、基盤 LLM に対して、LoRA [15] をすべての線形層に適用し、ファインチューニングを行った。

4.2 学習条件

画像生成の学習による視覚理解の学習への影響を評価するため、以下の条件で学習を比較する。

- und-only: 理解データのみで学習
- joint: 理解データと生成データを混合学習

学習データ規模は理解データ、生成データいずれも 12,800 件で、テストデータは VQA データをタスクごと 600 件、合計 2,400 件とした。両実行条件の更新ステップ数を揃えるため、バッチサイズは und-only を 64, joint を 128 とした。

最適化設定は、基本的に LLaVA-v1.5 [16] の LoRA による指示微調整で公開されている設定に準拠した。und-only と joint の差は学習データの混合条件とバッチサイズのみで、その他の設定は共通とした。詳細は付録 A 表 2 に示す。

4.3 実験結果

図 3 に、視覚エンコーダ (VQ-VAE / SigLIP) および学習条件 (joint / und-only) 別の VQA 平均正解率の学習曲線を示した。VQ-VAE は 2 エポック、SigLIP は 1 エポック学習した結果である。

学習の収束速度 画像生成を同時に学習する joint 設定は、理解タスクのみを学習する und-only 設定と比較して、全てのタスクにおいて高い正解率を達成した。さらに、学習の収束速度を比較すると、joint は und-only よりも同一ステップ数での比較で早くから性能が向上しており、生成タスクによる正則化、もしくは有用な視覚表現の学習が、視覚理解タスクの学習に早い段階から寄与していることがわかる (図 3)。

タスク別の比較 Attribute タスクは、画像内の特定オブジェクトに注目し、色や形状などの局所の特徴を抽出できれば回答可能である。Counting タスクも同様に、個々のオブジェクトを独立して認識し、

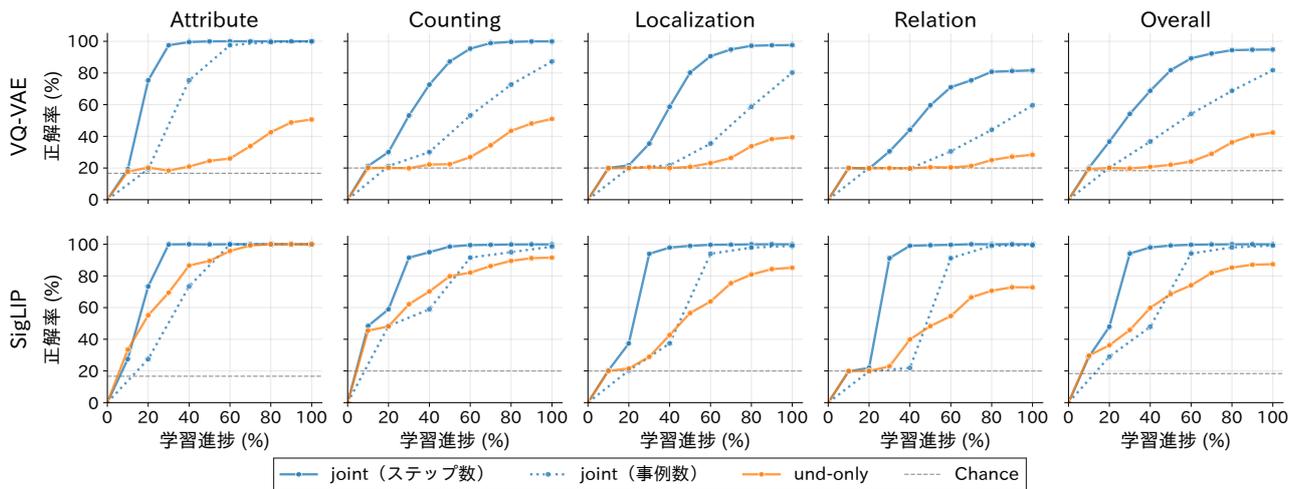


図 3: 学習進捗に伴う VQA タスクの 5 seed 平均正解率の推移. 上段は視覚エンコーダに VQ-VAE, 下段は SigLIP を用いたものである. 青色の実線は更新ステップ数を und-only と揃えた joint (ステップ数準拠) である. 青色の点線は, 同一の joint 学習曲線を事例数基準に換算してプロットしたものであり, バッチサイズ差を補正した比較を目的とする.

表 1: 最終ステップでの VQA 正解率 (5 seed 平均正解率 (%) \pm 標準偏差).

Task	VQ-VAE		SigLIP	
	joint	und-only	joint	und-only
Loc.	97.60 \pm 1.46	39.40 \pm 6.84	99.97 \pm 0.07	85.17 \pm 17.08
Rel.	81.63 \pm 9.20	28.37 \pm 9.86	100.00 \pm 0.00	72.73 \pm 25.93
Att.	100.00 \pm 0.00	50.63 \pm 9.96	100.00 \pm 0.00	100.00 \pm 0.00
Cnt.	99.93 \pm 0.13	51.00 \pm 13.97	99.90 \pm 0.08	91.53 \pm 11.61
All	94.79 \pm 2.62	42.35 \pm 8.46	99.97 \pm 0.02	87.36 \pm 13.31

数え上げればよい. これらは視覚理解タスクの学習のみで十分に獲得可能な能力である (図 3). 一方, Localization 及び Relation タスクでは, joint と und-only の差が相対的に大きかった (図 3). 前者は指定オブジェクトの絶対位置, 後者は二つのオブジェクト間の相対位置を問うタスクであり, この結果は画像生成タスクの学習が位置関係の理解に寄与する可能性を示唆する. この傾向は, 本実験で用いた二つの視覚エンコーダに共通して見られた.

学習の安定性 表 1 は, 各条件を複数回実行した最終ステップの正解率を平均 \pm 標準偏差で示している. まず VQ-VAE では, und-only での全タスクの正解率平均が 42.35 \pm 8.46 と低く, Localization / Relation タスクの両方で改善が限定的であった. 一方, joint は全タスクの正解率平均が 94.79 \pm 2.62 まで改善し, Relation タスクでは性能にばらつきが残るものの, 高い正解率へ収束しやすくする効果が観測された. 次に SigLIP では, und-only では Attribute

タスクは完璧に解けているが, Localization タスクや Relation タスクといった, 位置関係の学習では高い性能に収束するかどうかを実行ごとに不安定であることが確認された. 一方 joint では, シードに依存せず全タスクでほぼ完璧な性能を達成した.

5 おわりに

本研究では, Unified VLM において画像生成との混合学習が視覚理解能力へ与える影響を, 構成要因を厳密に制御できる 2 \times 2 合成データで分析した. Localization / Relation / Attribute / Counting からなる VQA と属性列挙に基づく画像生成タスクを定義し, 理解のみで学習する und-only と理解・生成を同時に学習する joint を, VQ-VAE 及び SigLIP の二種の視覚エンコーダで比較した. 実験の結果, joint は同一更新ステップでの比較で学習初期から正解率の向上が見られ, 最終的にも高い性能へ到達しやすい傾向を示した. 特に, 局所的属性の認識を扱う Attribute / Counting タスクは und-only でも高精度に達する一方, 空間構造の把握を要する Localization / Relation タスクでは joint の改善が相対的に大きく, 実行間のばらつきも抑制された. 今後は, 混合学習による性能向上の要因を正則化効果と共有表現学習の観点から検証する. さらに, 理解・生成の同時学習における学習過程の相互作用も分析することで, 混合学習が視覚理解を改善するメカニズムの解明を行ってきたい.

謝辞

本研究は JSPS 科研費 JP24K03236, JP25K03175 及び JST BOOST JPMJBY24A6, JPMJBY24F9 の助成を受けたものです。

参考文献

- [1] Xinjie Zhang, Jintao Guo, Shanshan Zhao, Minghao Fu, Lunhao Duan, Jiakui Hu, Yong Xien Chng, Guo-Hua Wang, Qing-Guo Chen, Zhao Xu, Weihua Luo, and Kaifu Zhang. Unified multimodal understanding and generation models: Advances, challenges, and opportunities. **arXiv preprint arXiv:2505.02567**, 2025. v5.
- [2] Shengbang Tong, David Fan, Jiachen Li, Yunyang Xiong, Xinlei Chen, Koustuv Sinha, Michael Rabbat, Yann LeCun, Saining Xie, and Zhuang Liu. Metamorph: Multimodal understanding and generation via instruction tuning. In **Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)**, pp. 17001–17012, October 2025.
- [3] Jihai Zhang, Tianle Li, Linjie Li, Zhengyuan Yang, and Yu Cheng. Are unified vision-language models necessary: Generalization across understanding and generation. **arXiv preprint arXiv:2505.23043**, 2025.
- [4] Hao Liu, Wilson Yan, Matei Zaharia, and Pieter Abbeel. World model on million-length video and language with blockwise RingAttention. In **International Conference on Learning Representations (ICLR)**, 2025.
- [5] Chameleon Team. Chameleon: Mixed-modal early-fusion foundation models. **arXiv preprint arXiv:2405.09818**, 2024.
- [6] Aaron van den Oord, Oriol Vinyals, and Koray Kavukcuoglu. Neural discrete representation learning. In I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, and R. Garnett, editors, **Advances in Neural Information Processing Systems**, Vol. 30, pp. 6306–6315, 2017.
- [7] Patrick Esser, Robin Rombach, and Björn Ommer. Taming transformers for high-resolution image synthesis. In **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)**, pp. 12873–12883, June 2021.
- [8] Quan Sun, Qiyang Yu, Yufeng Cui, Fan Zhang, Xiaosong Zhang, Yueze Wang, Hongcheng Gao, Jingjing Liu, Tiejun Huang, and Xinlong Wang. Emu: Generative pretraining in multimodality. In **International Conference on Learning Representations (ICLR)**, 2024.
- [9] Alec Radford, Jong Wook Kim, Chris Hallacy, Aditya Ramesh, Gabriel Goh, Sandhini Agarwal, Girish Sastry, Amanda Askell, Pamela Mishkin, Jack Clark, Gretchen Krueger, and Ilya Sutskever. Learning transferable visual models from natural language supervision. In Marina Meila and Tong Zhang, editors, **Proceedings of the 38th International Conference on Machine Learning**, Vol. 139 of **Proceedings of Machine Learning Research**, pp. 8748–8763. PMLR, 18–24 Jul 2021.
- [10] Xiaohua Zhai, Basil Mustafa, Alexander Kolesnikov, and Lucas Beyer. Sigmoid loss for language image pre-training. In **Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)**, pp. 11975–11986, October 2023.
- [11] Chengyue Wu, Xiaokang Chen, Zhiyu Wu, Yiyang Ma, Xingchao Liu, Zizheng Pan, Wen Liu, Zhenda Xie, Xingkai Yu, Chong Ruan, and Ping Luo. Janus: Decoupling visual encoding for unified multimodal understanding and generation. In **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)**, pp. 12966–12977, June 2025.
- [12] Peize Sun, Yi Jiang, Shoufa Chen, Shilong Zhang, Bingyue Peng, Ping Luo, and Zehuan Yuan. Autoregressive model beats diffusion: Llama for scalable image generation. **arXiv preprint arXiv:2406.06525**, 2024.
- [13] Justin Johnson, Bharath Hariharan, Laurens van der Maaten, Li Fei-Fei, C. Lawrence Zitnick, and Ross Girshick. CLEVR: A diagnostic dataset for compositional language and elementary visual reasoning. In **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**, pp. 2901–2910, July 2017.
- [14] Baolin Peng, Chunyuan Li, Pengcheng He, Michel Galley, and Jianfeng Gao. Instruction tuning with GPT-4. **arXiv preprint arXiv:2304.03277**, 2023.
- [15] Edward J. Hu, Yelong Shen, Phillip Wallis, Zeyuan Allen-Zhu, Yuanzhi Li, Shean Wang, Lu Wang, and Weizhu Chen. LoRA: Low-rank adaptation of large language models. In **International Conference on Learning Representations (ICLR)**, 2022.
- [16] Haotian Liu, Chunyuan Li, Yuheng Li, and Yong Jae Lee. Improved baselines with visual instruction tuning. In **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)**, pp. 26296–26306, June 2024.

A 参考情報

表 2: 実験におけるハイパーパラメータ. U は Understanding, G は Generation を表す.

Parameter	VQ Model	SigLIP Model
<i>Model Architecture</i>		
Base LLM	Vicuna-7B v1.5	Vicuna-7B v1.5
Vision Tower (U / G)	VQ-VAE / VQ-VAE	SigLIP-224 / VQ-VAE
Projector (U / G)	Linear / Linear	MLP / Linear
Input Resolution (U / G)	256 × 256 / 256 × 256	224 × 224 / 256 × 256
<i>Training Settings</i>		
LoRA (rank / alpha)	128 / 256	128 / 256
Optimizer	AdamW	AdamW
Learning Rate	2×10^{-4}	2×10^{-4}
Projector Learning Rate	1×10^{-4}	1×10^{-4}
LR Scheduler	Cosine Decay	Cosine Decay
Warmup Ratio	0.03	0.03
Effective Batch Size (und-only / joint)	64 / 128	64 / 128
Training Epochs	2	1

表 3: 学習進捗における正解率 (平均 (%) ± 標準偏差).

VQ-VAE (Joint)						VQ-VAE (Und-only)					
進捗 (%)	Loc.	Rel.	Att.	Cnt.	All	進捗 (%)	Loc.	Rel.	Att.	Cnt.	All
10	20.00 ± 0.00	20.10 ± 0.20	19.23 ± 1.66	21.27 ± 1.58	20.15 ± 0.34	10	19.90 ± 0.20	20.00 ± 0.00	17.70 ± 1.60	20.00 ± 0.00	19.40 ± 0.42
20	21.70 ± 1.85	19.63 ± 1.87	75.37 ± 15.14	30.07 ± 3.06	36.69 ± 4.31	20	19.97 ± 0.07	19.77 ± 0.48	20.27 ± 3.05	20.07 ± 0.23	20.02 ± 0.70
30	35.40 ± 12.43	30.53 ± 9.09	97.53 ± 2.01	53.13 ± 9.32	54.15 ± 6.26	30	20.53 ± 0.69	20.00 ± 0.00	18.37 ± 2.30	19.90 ± 0.20	19.70 ± 0.74
40	58.67 ± 13.18	44.10 ± 10.00	99.53 ± 0.46	72.63 ± 11.40	68.73 ± 8.31	40	19.93 ± 0.08	19.73 ± 0.53	20.90 ± 2.52	22.20 ± 2.86	20.69 ± 0.98
50	80.23 ± 11.14	59.63 ± 7.68	99.97 ± 0.07	87.27 ± 4.06	81.77 ± 5.44	50	20.77 ± 1.39	20.53 ± 0.84	24.50 ± 3.70	22.40 ± 2.24	22.05 ± 1.34
60	90.60 ± 7.52	71.03 ± 6.60	100.00 ± 0.00	95.37 ± 1.68	89.25 ± 3.71	60	23.10 ± 4.31	20.40 ± 0.89	26.00 ± 4.65	26.87 ± 3.81	24.09 ± 2.92
70	94.83 ± 3.87	75.37 ± 2.54	100.00 ± 0.00	98.87 ± 0.68	92.27 ± 1.69	70	26.37 ± 2.87	21.30 ± 0.97	33.83 ± 8.14	34.33 ± 7.44	28.96 ± 4.23
80	97.17 ± 1.91	80.77 ± 9.21	100.00 ± 0.00	99.63 ± 0.31	94.39 ± 2.66	80	33.77 ± 3.32	25.03 ± 5.98	42.57 ± 8.14	43.47 ± 11.60	36.21 ± 5.35
90	97.50 ± 1.67	81.23 ± 8.89	100.00 ± 0.00	99.93 ± 0.13	94.67 ± 2.56	90	38.30 ± 6.79	27.13 ± 9.14	48.80 ± 10.59	48.10 ± 12.73	40.58 ± 8.04
100	97.60 ± 1.46	81.63 ± 9.20	100.00 ± 0.00	99.93 ± 0.13	94.79 ± 2.62	100	39.40 ± 6.84	28.37 ± 9.86	50.63 ± 9.96	51.00 ± 13.97	42.35 ± 8.46

SigLIP (Joint)						SigLIP (Und-only)					
進捗 (%)	Loc.	Rel.	Att.	Cnt.	All	進捗 (%)	Loc.	Rel.	Att.	Cnt.	All
10	20.30 ± 0.27	19.77 ± 0.47	27.50 ± 3.55	48.40 ± 2.00	28.99 ± 1.36	10	20.00 ± 0.00	19.97 ± 0.27	33.50 ± 13.02	45.43 ± 6.05	29.72 ± 4.39
20	37.37 ± 19.84	21.90 ± 3.06	73.37 ± 15.53	58.93 ± 8.02	47.89 ± 9.52	20	21.60 ± 1.61	19.97 ± 0.24	55.17 ± 21.34	48.13 ± 4.81	36.22 ± 5.92
30	93.97 ± 2.67	91.20 ± 10.04	99.90 ± 0.13	91.53 ± 1.32	94.15 ± 3.41	30	28.90 ± 7.14	22.93 ± 5.99	69.43 ± 22.96	62.10 ± 12.74	45.84 ± 10.74
40	97.87 ± 0.55	99.03 ± 0.68	100.00 ± 0.00	94.97 ± 2.30	97.97 ± 0.60	40	42.70 ± 13.74	39.90 ± 12.41	86.53 ± 26.19	70.17 ± 12.08	59.82 ± 14.63
50	98.97 ± 1.24	99.37 ± 0.95	99.87 ± 0.27	98.50 ± 0.87	99.18 ± 0.80	50	56.57 ± 23.61	48.30 ± 18.15	89.47 ± 20.57	79.80 ± 13.08	68.53 ± 17.82
60	99.63 ± 0.29	99.63 ± 0.40	100.00 ± 0.00	99.43 ± 0.29	99.68 ± 0.15	60	63.83 ± 24.45	54.63 ± 24.11	95.73 ± 8.37	82.07 ± 13.37	74.07 ± 16.75
70	99.73 ± 0.29	100.00 ± 0.00	100.00 ± 0.00	99.63 ± 0.29	99.84 ± 0.09	70	75.40 ± 23.39	66.47 ± 26.18	99.20 ± 1.52	86.20 ± 14.04	81.82 ± 15.73
80	99.93 ± 0.08	99.97 ± 0.07	100.00 ± 0.00	99.83 ± 0.18	99.93 ± 0.06	80	80.87 ± 21.88	70.63 ± 28.39	99.97 ± 0.07	89.50 ± 12.53	85.24 ± 15.42
90	99.97 ± 0.07	100.00 ± 0.00	100.00 ± 0.00	99.90 ± 0.08	99.97 ± 0.02	90	84.30 ± 18.32	72.83 ± 26.38	100.00 ± 0.00	91.20 ± 11.69	87.08 ± 13.81
100	99.97 ± 0.07	100.00 ± 0.00	100.00 ± 0.00	99.90 ± 0.08	99.97 ± 0.02	100	85.17 ± 17.08	72.73 ± 25.93	100.00 ± 0.00	91.53 ± 11.61	87.36 ± 13.31