



Comparative Analysis of Backbone Architectures for Instance Segmentation of Objects in Aerial Imagery Using Mask R-CNN

Igor Victorovich **Vinokurov**¹, Daria Aleksandrovna **Frolova**²,
Andrey Ivanovich **Ilyin**³, Ivan Romanovich **Kuznetsov**⁴

¹⁻⁴ Financial University under the Government of the Russian Federation, Moscow, Russia

¹igvvinokurov@fa.ru

Abstract. This paper compares Mask R-CNN models with various pretrained backbone architectures for implementing instance segmentation of real estate objects in aerial images. The models were fine-tuned on a specialized dataset provided by the PLC « Roskadastr».

Analysis of the accuracy of detecting bounding boxes and object segmentation masks revealed the preferred architectures: Swin transformers (Swin-S and Swin-T) and the ConvNeXt-T convolutional network. The high accuracy of these models is explained by their ability to account for global contextual dependencies of the image.

The results of the study allow us to formulate the following recommendations for choosing a backbone architecture: for real-time monitoring systems where performance is critical, lightweight models (EfficientNet-B3, ConvNeXt-T, Swin-T) are advisable; for offline tasks requiring maximum accuracy (such as real estate mapping), the large-scale Swin-S model is recommended. (*Linked article texts in English and in Russian*).

Key words and phrases: instance segmentation, backbone, Mask R-CNN, ResNet, DenseNet, EfficientNet, ConvNeXt, Swin

2020 *Mathematics Subject Classification:* 68T20; 68T07, 68T45

For citation: Igor V. Vinokurov, Daria A. Frolova, Andrey I. Ilyin, Ivan R. Kuznetsov. *Comparative Analysis of Backbone Architectures for Instance Segmentation of Objects in Aerial Imagery Using Mask R-CNN*. Program Systems: Theory and Applications, 2025, **16**:4(67), pp. 173–216. (*In English, in Russian*). https://psta.psiras.ru/read/psta2025_4_173-216.pdf

Introduction

The automation of aerial imagery analysis is one of the key tasks in modern geoinformatics, urban studies, environmental monitoring, and land management. Among the multitude of tasks in this field, instance segmentation, which involves detecting and precisely segmenting each object in an image at the pixel level (*pixel-wise*), holds a central place. Its solution enables the automatic identification and mapping of objects such as buildings, elements of road infrastructure, agricultural facilities, etc., on aerial photographs obtained using aircraft.

The relevance of this work is driven by the growing volume of aerial photography data and the acute need for its operational analysis. However, the development of automatic methods faces a number of challenges inherent to aerial imagery – high dynamic range, significant variability in scales and shooting angles, complex weather conditions, optical distortions, as well as often limited volumes of expertly annotated data for training machine learning models. These factors impose special requirements on the reliability and generalization ability of segmentation models.

In recent years, the **Mask R-CNN** model [1] has established itself as a de facto standard for solving instance segmentation tasks, consistently demonstrating high results in simultaneous object detection and the construction of their precise binary masks. Its architecture, which extends Faster R-CNN [2] by adding a parallel branch for mask prediction, provides an effective combination of localization accuracy and semantic segmentation quality. This feature makes Mask R-CNN particularly valuable in applications requiring not only detection but also precise contour description of complex-shaped objects.

The final effectiveness of this model is largely determined by the choice of feature extractor architecture or backbone – a deep convolutional or transformer network responsible for extracting hierarchical features from the image. For a considerable time, backbone architectures from the ResNet family [3] dominated.

However, the emergence of more modern and efficient CNNs such as DenseNet [4], EfficientNet [5], and ConvNeXt [6], as well as the revolutionary breakthrough of transformer-based architectures, particularly Swin [7], has radically changed the landscape and expanded researchers' choices. In this context, conducting a systematic comparative analysis of these architectures for the specific and significant task of segmentation on aerial imagery is of considerable practical and scientific interest.

The scope of this study does not include some modern and promising architectures, such as Vision Transformer [8] in its basic configuration, as well as the latest efficient models like MobileOne [9], EdgeNeXt [10], or recurrent network structures focused on sequential feature processing.

Furthermore, hybrid approaches combining convolutional layers with attention mechanisms within a single block, for example, models from the CoAtNet family [11], were also beyond the scope of this work. This is due to the focus on widely adopted and practically proven architectures, as well as the need to ensure the representativeness and comparability of results. These directions represent potential avenues for future research in the context of optimizing accuracy and computational efficiency for aerial imagery analysis tasks.

The research conducted in this work continues and develops the approaches formulated in [12] and [13], offering an alternative solution to the problem considered in [13]. In [12], the target object classes for identification on aerial photography materials were systematized, and a comprehensive methodology for forming a representative dataset with detailed semantic annotation was developed.

The work [13] implemented an approach to improve the accuracy of object mask generation based on Generative Adversarial Networks (GANs), focusing on the task of post-processing segmentation results and subpixel refinement of object contour characteristics. In contrast to this approach, the present work proposes an alternative methodology based on a comparative analysis of different backbone architectures for the Mask R-CNN model, aimed at improving segmentation accuracy at the primary prediction stage, rather than through subsequent post-processing of the results.

The aim of this study is to conduct a comparative analysis of the accuracy and efficiency of seven different pre-trained backbone architectures (ResNet-50, ResNet-101, DenseNet-121, EfficientNet-B3, ConvNeXt-T, Swin-T, Swin-S) within the Mask R-CNN framework for the task of instance segmentation of objects in aerial imagery.

The selection of these backbone architectures for comparative analysis is motivated by the need to cover a representative spectrum of modern approaches to designing deep neural networks, ensuring the comparability of results and testing key research hypotheses.

ResNet-50 and *ResNet-101* [3] implement the residual learning framework that addresses the vanishing gradient problem by introduction skip-connections. They ensure stable gradient flow during training and allow for effective scaling of network depth. They are included as the widely accepted baseline standard in computer vision for assessing the impact of network depth on segmentation quality.

DenseNet-121 [4] utilizes a dense-connection paradigm, in which each layer directly accesses the feature maps of all preceding layers. This approach promotes intensive feature reuse, parameter reduction, and improved gradient flow throughout the network.

EfficientNet-B3 [5] employs a compound scaling strategy that optimizes the depth, width, and resolution of the input data, achieving an optimal balance between prediction accuracy and computational complexity under given resource constraints.

ConvNeXt-T [6] is a modern interpretation of the classical convolutional architecture that incorporates the most successful solutions from the transformer domain. The architecture utilizes an increased convolution kernel size, improved normalization, and activation methods, which together provide competitive performance. The architecture utilizes an increased convolution kernel size, improved normalization, and activation methods, which together provide competitive performance.

Swin-T and *Swin-S* [7] are hierarchical transformers that utilize self-attention within local windows with subsequent window shifting. This approach allows for efficient modeling of global context dependencies while maintaining linear computational complexity relative to image size, which is particularly important for processing high-resolution aerial photography data.

This selection ensures coverage of both classical and modern paradigms, allowing for a systematic assessment of the impact of architectural innovations on the accuracy and effectiveness of instance segmentation in aerial photography conditions.

1. Definition of Research Aims and Objectives

Analysis of recent publications reveals a variety of approaches to using these architectures within the Mask R-CNN model. The work [14]

demonstrates the advantage of transformer-based backbones for precise segmentation tasks, reflecting a trend towards attention-based architectures capable of effectively modeling global contextual dependencies [15, 16]. Conversely, [17] shows the effectiveness of modern CNNs for solving many practical problems; this finding is supported by works dedicated to optimizing lightweight architectures for real-time tasks [18].

A comparative analysis in [19] reveals a trade-off between accuracy and computational complexity among different architectures, aligning with the methodology of comprehensive evaluation of modern models that considers not only accuracy metrics but also inference speed, memory consumption, and computational complexity [20]. However, assessing the effectiveness of different backbones for aerial imagery analysis tasks, characterized by high scale variability and the need for small object segmentation, remains insufficiently explored.

The main objectives of this work are:

- (1) To adapt the Mask R-CNN model for use with various backbone architectures.
- (2) To implement fine-tuning of each model configuration on a custom dataset of aerial imagery.
- (3) To compute standard metrics ($loss_bbox$, $loss_mask$, $bbox_mAP$, and $segm_mAP$) for each model.
- (4) To analyze the obtained results, identifying patterns between the architecture type and detection accuracy.

2. Experiment Methodology

The computational experiment for conducting a comparative analysis of the performance of different backbone architectures in the Mask R-CNN model was organized using the **MMDetection** framework – an open-source toolbox for object detection and instance segmentation based on PyTorch.

The dataset compiled for model training and validation consisted of 435 aerial images obtained by quadcopter. The dataset includes an equal number of JSON files in LabelMe format, containing arrays of polygon contour point coordinates and object names (labels) of 5 types: summer

house (label '*building*', 12.470 instances), greenhouse (label '*greenhouse*', 6.450 instances), outbuilding (label '*outbuilding*', 2.150 instances), vehicle (label '*vehicle*', 1.516 instances), and swimming pool (label '*swimming*', 490 instances) [12]. The dataset was partitioned into training and validation subsets with a 75% and 25% split, respectively. The training procedure was carried out on a single NVIDIA A100 80GB GPU.

Base configuration files for each backbone were taken from the official MMDetection (v3.3.0) repository. In all configuration files, the *data_root* and *metainfo* parameters were overridden (configured). The former specified the root folder name of the dataset, while the latter contained information about the 5 target classes. The *num_classes* parameters in *bbox_head* and *mask_head* were set to 5, corresponding to the number of target classes.

For correct transfer learning, models were initialized with pre-trained weights from the COCO dataset. The weights were loaded from the MMDetection repository (version 2 or 3). The fine-tuning strategy consisted of two stages: during the first five epochs, the backbone layers were frozen, and only the model's head were trained ($lr = 1e-3$). This allowed the classification layers to adapt to the target classes. This was followed by full fine-tuning of all layers with a reduced learning rate ($lr = 1e-4$) for up to 100 epochs. The stopping criterion was the absence of improvement in the *bbox_mAP* metric on the validation set for 15 consecutive epochs.

For optimization, AdamW was used with *weight_decay* = 0.05 (the default value in MMDetection) and gradient clipping with a threshold of 1.0 to stabilize training. Validation was performed after each epoch, and the best model was saved automatically upon improvement of the *bbox_mAP* metric on the validation set. All experiments were conducted on identical hardware configuration with a fixed *random seed* = 42.

Performance evaluation was carried out on the dedicated validation set using COCO metrics *bbox_mAP* and *segm_mAP* for IoU thresholds from 0.5 to 0.95 with a step of 0.05. The values of these metrics were calculated for large (*mAP_l*), medium (*mAP_m*), and small (*mAP_s*) objects. The area of small objects is less than 32^2 pixels ($< 1024 \text{ px}^2$), medium objects range from 32^2 to 96^2 pixels ($1024 - 9216 \text{ px}^2$), and large objects exceed 96^2 pixels ($> 9216 \text{ px}^2$); *mAP* represents the average value of the metrics for detected objects of all sizes.




FIGURE 1. ROI classification accuracy on the validation dataset for classical CNN architectures

3. Experiment Results

3.1. ROI Classification Accuracy Analysis

A Region of Interest (ROI) is a selected region on the feature maps generated by the model's backbone. In object detection and segmentation pipelines, these regions are further processed for object classification (predicting segmentation masks) and bounding box regression. The conducted analysis of experimental data reveals a pronounced trend towards improved ROI classification accuracy when transitioning to modern transformer architectures (Swin-T, Swin-S) and advanced CNN architectures (ConvNeXt-T), as clearly demonstrated by their training dynamics plots on Figure 1 and Figure 2.





FIGURE 2. ROI classification accuracy on the validation dataset for transformer and advanced CNN architectures

3.2. Analysis of Bounding Box and Mask Detection Losses

The loss functions for bounding box regression ($loss_bbox$) and mask detection ($loss_mask$) are critically important components of the composite optimization function in instance segmentation tasks. $loss_bbox$ ensures precise object positioning by minimizing the discrepancy between predicted and ground truth bounding box coordinates. In turn, $loss_mask$ is responsible for the accuracy of pixel-wise classification within each ROI, guaranteeing that the predicted mask matches the object's contour.

Figure 3 shows that modern architectures, particularly Swin-T and Swin-S transformers, demonstrate high efficiency in optimizing loss functions. The Swin-S architecture achieves the minimum values for both metrics, indicating its clear advantage due to its ability to effectively model



(g) Swin-S

FIGURE 3. Bounding box regression and object mask detection losses for various CNN architectures

TABLE 1. Loss function values on the validation dataset for different backbone architectures

<i>Backbone</i>	<i>loss_bbox</i>	<i>loss_mask</i>
ResNet-50	0.2185	0.2891
ResNet-101	0.2137	0.3211
DenseNet-121	0.1854	0.2244
EfficientNet-B3	0.2136	0.2666
ConvNeXt-T	0.1793	0.2603
Swin-T	0.1813	0.2148
Swin-S	0.1020	0.1141

global contextual dependencies and extract hierarchical features with high discriminative power, thereby enabling more accurate bounding box positioning and detailed segmentation masks.

The superior performance of Swin-S confirms the promise of transformer-based approaches for instance segmentation tasks, where both localization accuracy and pixel-level classification quality are critically important.

Meanwhile, Table 1 show comparable to DenseNet-121 efficiency of Swin-T and ConvNeXt-T models, ranking among the most balanced solutions for optimizing both metrics.

3.3. Bounding Box Detection Accuracy Analysis

Below, in Figure 4 and Figure 5, the graphs of bounding box detection accuracy metrics $bbbox_mAP$ obtained from experimental studies for objects of different sizes – mAP_s , mAP_m , and mAP_l (see Section 2) are presented.

Analysis of the experimental data reveals a consistent improvement in the mAP metric across the studied architectures, as shown in Table 2. The last column indicates the epoch at which the backbone architecture with the best weights for bounding box detection is formed.

ResNet-50 demonstrates the baseline accuracy level ($mAP \sim 0.3236$), while DenseNet-121, thanks to its dense connection mechanism, shows a noticeable improvement ($mAP \sim 0.3800$). ResNet-101, despite its increased depth, shows only moderate improvement ($mAP \sim 0.4080$) compared to DenseNet-121, highlighting the limitations of simply increasing network depth.




FIGURE 4. Bounding box detection accuracy on the validation dataset for classical CNN architectures

TABLE 2. Bounding box detection accuracy metrics for different backbone architectures

<i>Backbone</i>	<i>mAP</i>	<i>mAP_s</i>	<i>mAP_m</i>	<i>mAP_l</i>	<i>Epoch</i>
ResNet-50	0.3236	0.1500	0.3200	0.4500	51
ResNet-101	0.4080	0.2000	0.3900	0.5000	66
DenseNet-121	0.3800	0.1800	0.3600	0.4800	71
EfficientNet-B3	0.4340	0.2200	0.4100	0.5300	64
ConvNeXt-T	0.4300	0.2300	0.4200	0.5400	76
Swin-T	0.4702	0.2400	0.4300	0.5500	77
Swin-S	0.5606	0.2800	0.5200	0.6500	81

The significant performance jump with EfficientNet-B3 ($mAP \sim 0.4340$) demonstrates the effectiveness of the compound scaling strategy. The increased accuracy of the ConvNeXt-T architecture ($mAP \sim 0.4300$)




FIGURE 5. Bounding box detection accuracy on the validation dataset for transformer and advanced CNN architectures

indicates the potential of convolutional networks with an enhanced ability to model complex spatial-contextual dependencies.

Further improvement is shown by Swin-T ($mAP \sim 0.4702$), which uses a window attention mechanism to efficiently model global contextual interactions while maintaining linear computational complexity. The best result is demonstrated by Swin-S ($mAP \sim 0.5606$), clearly illustrating the advantages of transformer architectures and their exceptional effectiveness in accurately localizing objects of all size categories, especially small objects, where the most significant performance gain is observed.

3.4. Segmentation Mask Detection Accuracy Analysis

Figure 6 and Figure 7 present graphs of segmentation mask detection accuracy metrics $segm_mAP$ for objects of different sizes, see Section 2.

The initial level of detection accuracy is demonstrated by ResNet-50 ($mAP \sim 0.3000$). DenseNet-121 achieves some improvement in metrics




FIGURE 6. Segmentation mask detection accuracy on the validation dataset for classical CNN architectures

($mAP \sim 0.3121$) through efficient feature reuse via dense connections. Increasing network depth, as implemented in ResNet-101, provides only a slight improvement in segmentation quality ($mAP \sim 0.3561$), indicating the limitations of this approach. The application of compound scaling in EfficientNet-B3 stabilizes the metrics at the level of $mAP \sim 0.3795$, but a true qualitative leap is observed when transitioning to modern architectural solutions.

The advanced CNN architecture ConvNeXt-T demonstrates significant improvement ($mAP \sim 0.3948$), surpassing traditional approaches by optimizing the spatial feature extraction process. The transformer architecture Swin-T with its window attention mechanism shows further improvement ($mAP \sim 0.4332$), effectively combining local and global contextual dependencies.

The highest effectiveness in the instance segmentation task is achieved by the transformer architecture Swin-S ($mAP \sim 0.5030$), setting a new




FIGURE 7. Segmentation mask detection accuracy on the validation dataset for transformer and advanced CNN architectures

standard of accuracy for objects of all size categories. Particularly significant results are observed for small object segmentation, where this approach demonstrates the most substantial advantage over other architectures, see Table 3. The last column indicates the epoch at which the backbone architecture with the best weights for segmentation mask detection is formed.

3.5. Analysis of mAP Metrics for Different Architectures

The results of the comparative analysis of detection accuracy metrics for bounding boxes and instance segmentation masks on aerial imagery reveal significant performance differences among the models, as shown in Figure 8. Classical convolutional networks (ResNet-50, ResNet-101, DenseNet-121) demonstrate the lowest metric values, while modern architectures (ConvNeXt-T, Swin-T) provide a substantial gain in accuracy. The Swin-S architecture outperforms all considered models on both metrics.

TABLE 3. Segmentation mask detection accuracy metrics for different backbone architectures

<i>Backbone</i>	<i>mAP</i>	<i>mAP_s</i>	<i>mAP_m</i>	<i>mAP_l</i>	<i>Epoch</i>
ResNet-50	0.3000	0.1200	0.2800	0.4200	52
ResNet-101	0.3561	0.1900	0.3600	0.5100	67
DenseNet-121	0.3121	0.1600	0.3300	0.4800	73
EfficientNet-B3	0.3795	0.2000	0.3700	0.5200	65
ConvNeXt-T	0.3948	0.2300	0.4000	0.5500	75
Swin-T	0.4332	0.2400	0.4100	0.5600	78
Swin-S	0.5030	0.2800	0.4700	0.6300	82




FIGURE 8. Comparison of $bbox_mAP$ and $segm_mAP$ metrics for different backbone architectures of the Mask R-CNN model

All architectures exhibit a consistent pattern where the $bbox_mAP$ value exceeds the $segm_mAP$ value, which aligns with theoretical expectations – the task of precise pixel-wise object delineation is more challenging compared to bounding box detection.

The magnitude of the gap between metrics varies depending on the architecture. The smallest relative deviation is observed for Swin-S (~ 0.0576), indicating its balanced effectiveness in solving both tasks. Conversely, the largest gap is characteristic of ResNet-50 (0.0236) and

FIGURE 9. ResNet-50 (contour detection error $\sim 15\%$)FIGURE 10. ResNet-101 (contour detection error $\sim 10\text{--}11\%$)

DenseNet-121 (0.0679), suggesting their suboptimal adaptation to the instance segmentation task.

Thus, the obtained data confirms the promise of using transformer-based and modern convolutional architectures for processing aerial imagery that requires simultaneous achievement of high accuracy in both object detection and segmentation.


3.6. Comparative Visualization of Object Segmentation Mask Contours

Figure 9–15 present object detection results on a fragment of an aerial image using the Mask R-CNN model with different backbones. The practical significance of effectively solving this task is described in [13].

Analysis of segmentation mask contour detection error revealed a direct dependence between the backbone architecture and segmentation accuracy. Classical CNN architectures demonstrate the highest error: ResNet-50 ($\sim 15\%$), ResNet-101 ($\sim 10\text{--}11\%$) and DenseNet-121 ($\sim 12\%$).

FIGURE 11. DenseNet-121 (contour detection error $\sim 12\%$)FIGURE 12. EfficientNet-B3 (contour detection error $\sim 10\text{--}11\%$)FIGURE 13. ConvNeXt-T (contour detection error $\sim 7\%$)

EfficientNet-B3 shows a result ($\sim 10\text{--}11\%$) comparable to ResNet-101 and DenseNet-121, which may indicate a performance plateau for this class of traditional convolutional architectures. Lower error values were obtained for modern architectures ConvNeXt-T ($\sim 7\%$) and Swin-T ($\sim 3\text{--}5\%$). The

FIGURE 14. Swin-T (contour detection error $\sim 3\text{--}5\%$)FIGURE 15. Swin-S (contour detection error $\sim 1\text{--}2\%$)

lowest segmentation mask contour detection error was recorded for the transformer architecture Swin-S ($\sim 1\text{--}2\%$), Figure 15.

The obtained results indicate that using modern architectures, particularly transformers, significantly improves the accuracy of object boundary positioning compared to classical CNN approaches. This is especially important for solving applied tasks requiring high segmentation accuracy, such as mapping or cadastral registration [12, 13]. The improved accuracy opens up opportunities for automating aerial image processing with minimal human involvement.

3.7. Model Training and Inference Time Evaluation

Experimental studies of Mask R-CNN models with different backbone architecture types were conducted using an NVIDIA A100 80GB GPU. The model training times and their inference times for images with an average size of 1010×750 px are presented in Table 4.

TABLE 4. Model Training and Inference Times

<i>Backbone</i>	<i>Training Time</i>	<i>Inference Time</i>
ResNet-50	12–18 min.	0.05–0.1 sec.
DenseNet-121	20–30 min.	0.08–0.15 sec.
ResNet-101	18–25 min.	0.07–0.12 sec.
EfficientNet-B3	22–35 min.	0.09–0.16 sec.
ConvNeXt-T	15–22 min.	0.06–0.1 sec.
Swin-T	30–45 min.	0.1–0.2 sec.
Swin-S	1.5–2 hours	0.2–0.4 sec.

Conclusion

This work presents a comparative analysis of the effectiveness of seven backbone architectures within the Mask R-CNN model for the task of instance segmentation of objects in aerial imagery. The experimental results demonstrate the advantage of attention-based architectures (Swin-T and Swin-S) and the advanced CNN (ConvNeXt-T) over classical convolutional networks.

It has been established that the model's ability to capture global contextual dependencies is a significant factor for achieving high segmentation accuracy under aerial photography conditions. The Swin-S architecture showed the highest values of the metrics *bbox_mAP* (0.5606) and *segm_mAP* (0.5030), especially for segmenting small-sized objects. However, achieving maximum accuracy is associated with significant computational costs, which limits the use of Swin-S to off-line processing tasks. For real-time scenarios, the use of Swin-T and ConvNeXt-T models is more appropriate, providing an acceptable compromise between accuracy and performance.

The research provides empirical data for selecting a backbone architecture depending on the requirements of a specific application. The research results are currently being used in the mapping information system of the PLC «Roscadastr». A promising direction for future work is the development of methods for optimizing the accuracy-performance trade-off, including the creation of hybrid architectures.

References

- [1] K. He, G. Gkioxari, P. Dollár, R. B. Girshick. “Mask R-CNN”, *2017 IEEE International Conference on Computer Vision (ICCV)* (Venice, Italy, 22–29 October 2017), IEEE, 2017, ISBN 9781538610336, pp. 2980–2988.   [arXiv:1703.06870](https://arxiv.org/abs/1703.06870)  174
- [2] S. Ren, K. He, R. Girshick, J. Sun. “Faster R-CNN: towards real-time object detection with region proposal networks”, *Advances in Neural Information Processing Systems 28*. V. 1, NIPS 2015 (Montreal, Canada, 7–12 December 2015), MIT Press, Cambridge, 2015, ISBN 9781510825024, pp. 91–99.   [arXiv:1512.03385](https://arxiv.org/abs/1512.03385)  174
- [3] K. He, X. Zhang, S. Ren, J. Sun. “Deep residual learning for image recognition”, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (Las Vegas, NV, USA, 27–30 June 2016), IEEE, 2016, ISBN 9781467388528, pp. 770–778.   [arXiv:1512.03385](https://arxiv.org/abs/1512.03385)  174, 176
- [4] G. Huang, Z. Liu, L. van der Maaten, K. Q. Weinberger. “Densely connected convolutional networks”, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (Honolulu, HI, USA, 21–26 July 2017), 2017, ISBN 9781538604588, pp. 2261–2269.   [arXiv:1608.06993](https://arxiv.org/abs/1608.06993)  174, 176
- [5] M. Tan, Q. V. Le. “EfficientNet: rethinking model scaling for convolutional neural networks”, International Conference on Machine Learning (Long Beach, California, USA, 9–15 June 2019), Proceedings of Machine Learning Research, vol. **97**, 2019, ISBN 9781510886988, pp. 6105–6114.    [arXiv:1905.11946](https://arxiv.org/abs/1905.11946)  174, 176
- [6] Z. Liu, H. Mao, C.-Y. Wu, C. Feichtenhofer, T. Darrell, S. Xie. “A ConvNet for the 2020s”, *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (New Orleans, LA, USA, 18–24 June 2022), IEEE, 2022, ISBN 9781665469470, pp. 11976–11986.  [arXiv:2201.03545](https://arxiv.org/abs/2201.03545)   174, 176
- [7] Z. Liu, Y. Lin, Y. Cao, H. Hu, Y. Wei, Z. Zhang, S. Lin, B. Guo. “Swin Transformer: hierarchical vision transformer using shifted windows”, *2021 IEEE/CVF International Conference on Computer Vision (ICCV)* (Montreal, QC, Canada, 10–17 October 2021), 2021, ISBN 978-1-6654-2812-5, pp. 9992–10002.   [arXiv:2103.14030](https://arxiv.org/abs/2103.14030)  174, 176
- [8] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, T. Unterthiner, M. Dehghani, M. Minderer, G. Heigold, S. Gelly, J. Uszkoreit, N. Houlsby. “An image is worth 16x16 words: transformers for image recognition at scale”, *International Conference on Learning Representations (ICLR)* (Vienna, Austria, 4 May 2021), 2021, ISBN 9798331321949, 21 pp.   [arXiv:2010.11929](https://arxiv.org/abs/2010.11929)  175
- [9] P. K. A. Vasu, J. Gabriel, J. Zhu, O. Tuzel, A. Ranjan. “MobileOne: an improved one millisecond mobile backbone”, *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (Vancouver, BC, Canada, 18–22 June 2023), IEEE, 2023, ISBN 9798350301304, pp. 7907–7917.   [arXiv:2206.04040](https://arxiv.org/abs/2206.04040)  175
- [10] M. Maaz, A. Shaker, H. Cholakkal, S. Khan, S. W. Zamir, R. M. Anwer, F. S. Khan. “EdgeNeXt: efficiently amalgamated CNN-transformer architecture for mobile vision applications”, *Computer Vision – ECCV 2022 Workshops (ECCV 2022)* (Tel Aviv, Israel, 23–27 October 2022), Lecture Notes in

- Computer Science, vol. **13807**, Springer, Cham, 2022, ISBN 978-3-031-25082-8, pp. 3–20.   2206.10589  175
- [11] Z. Dai, H. Liu, Q. V. Le, M. Tan. “CoAtNet: marrying convolution and attention for all data sizes”, *NIPS’21: Proceedings of the 35th International Conference on Neural Information Processing Systems* (6–14 December 2021), Curran Associates Inc., Red Hook, 2021, ISBN 978-1-7138-4539-3, pp. 3965–3977, id. 303.   2106.04803  175
- [12] I. V. Vinokurov. “Using the Mask R-CNN model for segmentation of real estate objects in aerial photographs”, *Program systems: theory and applications*, **16**:1(64) (2025), pp. 3–44 (in Engl. In Russ.).    175, 178, 190
- [13] I. V. Vinokurov. “Improving the accuracy of segmentation masks using a generative-adversarial network model”, *Program systems: theory and applications*, **16**:2(65) (2025), pp. 111–152 (in Engl. In Russ.).    175, 188, 190
- [14] E. Xie, W. Wang, Z. Yu, A. Anandkumar, J. M. Alvarez, P. Luo. “SegFormer: simple and efficient design for semantic segmentation with transformers”, *NIPS’21: Proceedings of the 35th International Conference on Neural Information Processing Systems* (6–14 December 2021), Curran Associates Inc., Red Hook, 2021, ISBN 978-1-7138-4539-3, pp. 12077–12090.   2105.15203  176
- [15] B. Cheng, I. Misra, A. G. Schwing, A. Kirillov, R. Girdhar. “Masked-attention mask transformer for universal image segmentation”, *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (New Orleans, LA, USA, 18–24 June 2022), IEEE, 2022, ISBN 9781665469470, pp. 1290–1299.   2112.01527  177
- [16] N. Carion, F. Massa, G. Synnaeve, N. Usunier, A. Kirillov, S. Zagoruyko. “End-to-end object detection with transformers”, *Computer Vision - ECCV 2020 (ECCV 2020)*, Lecture Notes in Computer Science, vol. **12346**, Springer, Cham, 2020, ISBN 978-3-030-58452-8, pp. 213–229.   2005.12872  177
- [17] M. Tan, R. Pang, Q. V. Le. “EfficientDet: scalable and efficient object detection”, *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (Seattle, WA, USA, 14–19 June 2020), IEEE, 2020, ISBN 9781728171692, pp. 10778–10787.   1911.09070  177
- [18] J. Peng, Y. Liu, S. Tang, Y. Hao, L. Chu, G. Chen, Z. Wu, Z. Chen, B. Lai. *PP-LiteSeg: a superior real-time semantic segmentation model*, 2022, 8 pp.   2204.02681  177
- [19] A. M. Hafiz, G. M. Bhat. “A survey on instance segmentation: state of the art”, *International Journal of Multimedia Information Retrieval*, **9** (2020), pp. 171–189.   177
- [20] A. Canziani, A. Paszke, E. Culurciello. *An Analysis of Deep Neural Network models for practical applications*, 2016.   1605.07678  177

Received
approved after reviewing
accepted for publication
published online

22.09.2025;
27.09.2025;
12.10.2025;
19.10.2025.

Recommended by

PhD. E. P. Kurshev

Information about the authors:



Igor Victorovich Vinokurov

Candidate of Technical Sciences (PhD), Associate Professor at the Financial University under the Government of the Russian Federation. Research interests: information systems, information technologies, data processing technologies



0000-0001-8697-1032

e-mail: igvvinokurov@fa.ru



Daria Aleksandrovna Frolova

Third-year undergraduate student at the Financial University under the Government of the Russian Federation. Research interests: information technology, business process automation, data analysis



0009-0009-7830-1165

e-mail: dari15frolova@gmail.com



Andrey Ivanovich Ilyin

Third-year undergraduate student at the Financial University under the Government of the Russian Federation. Research interests: information technology, programming, data analysis



0009-0002-0651-8102

e-mail: andrey08937@yandex.ru



Ivan Romanovich Kuznetsov

Third-year undergraduate student at the Financial University under the Government of the Russian Federation. Research interests: information and data processing technologies, programming



0009-0000-3135-4424

e-mail: ivan.kuznetsov0709@mail.ru

Authors contribution: *Igor V. Vinokurov* — 70% (development of experimental methodology, formation of configuration files, implementation of training and research of models, integration of results into control and data processing systems of the PLC «Roscadastr»); *Daria A. Frolova* — 10% (images annotation, dataset compilation); *Andrey I. Ilyin* — 10% (models accuracy metrics optimization); *Ivan R. Kuznetsov* — 10% (models inference visualization).

The authors declare no conflicts of interests.

УДК 004.932.75'1, 004.89

 10.25209/2079-3316-2025-16-4-173-216



Сравнительный анализ архитектур backbone для инстанс-сегментации объектов на аэрофотоснимках с использованием Mask R-CNN

Игорь Викторович **Винокуров**^{1✉}, Дарья Александровна **Фролова**²,
Андрей Иванович **Ильин**³, Иван Романович **Кузнецов**⁴

¹⁻⁴ Финансовый Университет при Правительстве Российской Федерации, Москва, Россия

[✉]igvvinokurov@fa.ru

Аннотация. В работе проведено сравнительное исследование моделей Mask R-CNN с различными предобученными backbone-архитектурами для реализации инстанс-сегментации объектов недвижимости на аэрофотоснимках. Модели дообучались на специализированном наборе данных ППК «Роскадастр».

Анализ точности детектирования ограничивающих рамок и масок сегментации объектов выявил предпочтительные архитектуры – трансформеры Swin (Swin-S и Swin-T) и свёрточная сеть ConvNeXt-T. Высокая точность этих моделей объясняется их способностью учитывать глобальные контекстные зависимости между элементами изображения.

Результаты исследования позволяют сформулировать следующие рекомендации по выбору архитектуры backbone: для систем мониторинга в реальном времени, где критична скорость работы, целесообразно применение легковесных моделей (EfficientNet-B3, ConvNeXt-T, Swin-T), для offline задач, требующих максимальной точности (таких как картирование объектов недвижимости), рекомендована крупномасштабная модель Swin-S.

(Связанные тексты статьи на английском и на русском языках)

Ключевые слова и фразы: инстанс-сегментация, backbone, Mask R-CNN, ResNet, DenseNet, EfficientNet, ConvNeXt, Swin

Для цитирования: Винокуров И. В., Фролова Д. А., Ильин А. И., Кузнецов И. Р. Сравнительный анализ архитектур backbone для инстанс-сегментации объектов на аэрофотоснимках с использованием Mask R-CNN // Программные системы: теория и приложения. 2025. Т. 16. № 4(67). С. 173–216. (Англ.+русс.) https://psta.psisras.ru/read/psta2025_4_173-216.pdf

Введение

Автоматизация анализа аэрофотоснимков является одной из ключевых задач современной геоинформатики, урбанистики, экологического мониторинга и управления территориями. Среди множества задач в этой области, задача инстанс-сегментации, заключающаяся в обнаружении и точном попиксельном (*pixel-wise*) выделении каждого объекта на изображении, занимает центральное место. Её решение позволяет автоматически идентифицировать и картировать на аэрофотоснимках, полученных с помощью летательных аппаратов, такие объекты, как здания, элементы дорожной инфраструктуры, сельскохозяйственные объекты и т.п.

Актуальность данной работы обусловлена растущим объёмом данных аэрофотосъемки и острой потребностью в их оперативном анализе. Однако разработка автоматических методов сталкивается с рядом сложностей, присущих именно аэрофотоснимкам – высокий динамический диапазон, значительная вариативность масштабов и ракурсов съемки, сложные погодные условия, оптические искажения, а также часто ограниченный объём экспертно размеченных данных для обучения моделей машинного обучения. Эти факторы предъявляют особые требования к надёжности и обобщающей способности моделей сегментации.

В последние годы модель Mask R-CNN [1] зарекомендовала себя в качестве фактического стандарта для решения задач инстанс-сегментации, демонстрируя стабильно высокие результаты в одновременном детектировании объектов и построении их точных бинарных масок. Её архитектура, расширяющая Faster R-CNN [2] за счёт добавления параллельной ветви для предсказания масок, обеспечивает эффективное сочетание точности локализации и качества семантической сегментации. Эта особенность делает Mask R-CNN особенно востребованной в приложениях, требующих не только обнаружения, но и точного контурного описания объектов сложной формы.

Итоговая эффективность этой модели в значительной степени определяется выбором архитектуры экстрактора признаков или backbone – глубокой свёрточной или трансформерной сети, ответственной за извлечение иерархических признаков из изображения. Относительно долгое время доминировали backbone-архитектуры семейства ResNet [3].

Однако появление более современных и эффективных CNN, таких как DenseNet [4], EfficientNet [5] и ConvNeXt [6], а также революционный прорыв архитектур на основе трансформеров, в частности Swin [7], кардинально изменили положение дел и расширили выбор исследователей. В связи с этим проведение систематического сравнительного анализа этих архитектур в контексте специфической и значимой задачи сегментации на аэрофотоснимках представляет значительный практический и научный интерес.

В рамках настоящего исследования не рассматривались некоторые современные и перспективные архитектуры, такие как Vision Transformer [8] в её базовой конфигурации, а также новейшие эффективные модели типа MobileOne [9], EdgeNeXt [10] или рекуррентные сетевые структуры, ориентированные на последовательную обработку признаков.

Кроме того, остались за рамками работы гибридные подходы, сочетающие свёрточные слои с механизмами внимания в рамках одного блока, например, модели семейства CoAtNet [11]. Это связано с акцентом исследований на широко распространенных и практически апробированных архитектурах, а также с необходимостью обеспечения репрезентативности и сопоставимости результатов. Указанные направления представляют интерес для будущих исследований в контексте оптимизации точности и вычислительной эффективности для задач анализа аэрофотоснимков.

Исследования, проведённые в этой работе, продолжают и развивают подходы, сформулированные в [12] и [13], предлагая альтернативное решение задачи, рассмотренной в [13]. В [12] были систематизированы целевые классы объектов, подлежащих идентификации на материалах аэрофотосъёмки, а также разработана комплексная методика формирования репрезентативного набора данных с детализированной семантической разметкой.

В работе [13] был реализован подход к повышению точности генерации масок объектов на основе генеративно-состязательных сетей (GAN), с фокусом на задаче постобработки результатов сегментации и субпиксельного уточнения контурных характеристик объектов. В отличие от данного подхода, в настоящей работе предлагается альтернативная методология, основанная на сравнительном анализе различных backbone-архитектур для модели Mask R-CNN, направленная на повышение точности сегментации на этапе первичного прогнозирования, а не последующей постобработки результатов.

Целью настоящего исследования является проведение сравнительного анализа точности и эффективности семи различных предобученных backbone-архитектур (ResNet-50, ResNet-101, DenseNet-121, EfficientNet-B3, ConvNeXt-T, Swin-T, Swin-S) в рамках модели Mask R-CNN для задачи инстанс-сегментации объектов на аэрофотоснимках.

Выбор этих архитектур backbone для сравнительного анализа обусловлен необходимостью охватить репрезентативный спектр современных подходов к проектированию глубоких нейронных сетей, обеспечив сопоставимость результатов и проверку ключевых исследовательских гипотез:

ResNet-50 и *ResNet-101* [3] реализуют концепцию остаточного обучения, которая решает проблему исчезающих градиентов посредством введения skip-connections, обеспечивающих стабильный поток градиентов в процессе обучения и позволяющих эффективно масштабировать глубину сети. Они включены как общепринятый базовый стандарт в компьютерном зрении, позволяющий оценить влияние глубины сети на качество сегментации.

DenseNet-121 [4] использует парадигму плотных соединений, в рамках которой каждый слой получает прямой доступ к картам признаков всех предшествующих слоёв. Она интересна как архитектура с плотными соединениями для интенсивного повторного использования признаков, снижения количества параметров и улучшения градиентного потока.

EfficientNet-B3 [5] применяет стратегию составного масштабирования (compound scaling), оптимизирующую глубину, ширину и разрешение входных данных и позволяющую достичь оптимального баланса между точностью предсказания и вычислительной сложностью модели при заданных ресурсных ограничениях.

ConvNeXt-T [6] представляет собой современную интерпретацию классической свёрточной архитектуры, объединяющую наиболее успешные решения из области трансформеров. Архитектура предполагает использование увеличенного размера ядра свёртки, усовершенствованных методов нормализации и активации, что в совокупности обеспечивает конкурентоспособную производительность.

Swin-T и *Swin-S* [7] относятся к классу иерархических трансформеров, использующих механизм самовнимания в рамках локальных окон с последующим их сдвигом. Такой подход позволяет эффективно моделировать глобальные контекстные зависимости при сохранении линейной вычислительной сложности относительно размера изображения, что особенно значимо для обработки данных аэрофотосъёмки высокого разрешения.

Такой отбор обеспечивает покрытие как классических, так и современных парадигм, позволяя системно оценить влияние архитектурных инноваций на точность и эффективность инстанс-сегментации в условиях аэрофотосъёмки.

1. Определение цели и задач исследований

Анализ современных публикаций выявил существование различных подходов к использованию данных архитектур в составе модели Mask R-CNN. В работе [14] демонстрируется преимущество трансформерных backbones для задач точной сегментации, что отражает тенденцию

перехода к архитектурам на основе механизма внимания, способным эффективно моделировать глобальные контекстные зависимости [15, 16].

В [17], наоборот, показывается эффективность современных CNN для решения многих практических задач; такой подход находит подтверждение в работах, посвященных оптимизации lightweight-архитектур для задач реального времени [18].

Сравнительный анализ в [19] выявляет компромисс между точностью и вычислительной сложностью различных архитектур, что соответствует методологии всесторонней оценки современных моделей, учитывающей не только метрики точности, но и скорость инференса, потребление памяти и вычислительную сложность [20].

При всём этом оценка эффективности использования различных backbone для задач анализа аэрофотоснимков, характеризующихся высокой вариативностью масштабов и необходимостью сегментации малых объектов, остаётся исследованной недостаточно.

Основные задачи работы:

- (1) Адаптировать модель Mask R-CNN для работы с использованием различных backbone-архитектур.
- (2) Реализовать дообучение (fine tuning) каждой из конфигураций модели на собственном наборе данных из аэрофотоснимков.
- (3) Вычислить для каждой модели стандартные метрики `loss_bbox`, `loss_mask`, `bbox_mAP` и `segm_mAP`.
- (4) Проанализировать полученные результаты, выявив закономерности между типом архитектуры и точностью детектирования.

2. Методология проведения эксперимента

Вычислительный эксперимент для проведения сравнительного анализа производительности различных архитектур backbone в модели Mask R-CNN был организован с использованием фреймворка **MMDetection** – открытой инструментальной библиотеки для детекции и сегментации объектов на основе PyTorch.

Сформированный для обучения и валидации моделей набор данных представлял собой совокупность из 435 полученных с помощью квадрокоптера аэрофотоснимков. В набор данных входит и такое же количество JSON-файлов в формате ПО LabelMe, содержащих массивы координат точек полигональной контуризации и имена (метки) объектов пяти типов – дачный домик (метка «building», 12470 экземпляров) экземпляров, теплица (метка «greenhouse», 6450 экземпляров), хозяйстройка (метка «outbuilding», 2150 экземпляров), транспортное средство (метка «vehicle»,

1516 экземпляров), бассейн (метка «swimming», 490 экземпляров) [12]. Для обучения использовалось 75% элементов набора данных, для валидации оставшиеся 25%.

Обучение проходило на GPU A100 80GB.

Базовые конфигурационные файлы для каждого backbone были взяты из официального репозитория MMDetection (v3.3.0). Во всех конфигурационных файлах переопределялись (формировались) параметры `data_root` и `metainfo`. В первом из них переопределялось имя корневой папки набора данных, во втором формировалась информация о пяти целевых классах. Параметры `num_classes` в `bbox_head` и `mask_head` устанавливались по количеству целевых классов в 5.

Для корректного трансферного обучения модели инициализировались предобученными весами для набора данных COCO. Веса загружались из репозитория MMDetection (версии 2 или 3). Стратегия дообучения включала два этапа – на первых пяти эпохах производилась заморозка слоёв backbone с обучением только головных частей модели ($lr = 1e-3$). Это позволило адаптировать классификационные слои к целевым классам.

После этого следовала полная настройка всех слоёв с пониженной скоростью обучения ($lr = 1e-4$) в течение 100 эпох. Критерием остановки служило отсутствие улучшения метрики `bbox_mAP` на валидационной выборке на протяжении 15 эпох.

Для оптимизации использовался AdamW с `weight_decay = 0.05` (значение по умолчанию в MMDetection) и градиентным клиппингом с порогом 1.0 для стабилизации обучения. Валидация проводилась после каждой эпохи, лучшая модель сохранялась автоматически при улучшении метрики `bbox_mAP` на валидационном наборе. Все эксперименты проводились на единой аппаратной конфигурации с фиксированным `random_seed = 42`.

Оценка производительности осуществлялась на выделенном валидационном наборе с использованием метрик COCO `bbox_mAP`, `segm_mAP` для порогов IoU от 0.5 до 0.95 с шагом 0.05. Значения этих метрик рассчитывались для объектов больших (`mAP_l`), средних (`mAP_m`) и малых (`mAP_s`) размеров.

Площадь малых объектов составляет менее 32^2 пикселей ($<1024 \text{ px}^2$), средних – от 32^2 до 96^2 пикселей, ($1024\text{--}9216 \text{ px}^2$), больших – более 96^2 пикселей ($>9216 \text{ px}^2$); `mAP` – среднее значение метрик для объектов детектирования всех размеров.

3. Результаты эксперимента

3.1. Анализ точности классификации ROI

Область интереса (Region of Interest, ROI) представляет собой выделенный регион на карте признаков (feature maps), которую генерирует backbone модели. В конвейерах детекции и сегментации объектов эти области в дальнейшем обрабатываются для классификации объектов (предсказания масок сегментации) и регрессии ограничивающих рамок.

Проведенный анализ экспериментальных данных выявляет выраженную тенденцию к улучшению точности классификации ROI при переходе к современным трансформерным архитектурам (Swin-T, Swin-S) и усовершенствованным архитектурам CNN (ConvNeXt-T), что наглядно демонстрируется графиками динамики их обучения на рисунках 1 и 2.




РИСУНОК 1. Точность классификации ROI для классических CNN архитектур




РИСУНОК 2. Точность классификации ROI для трансформерных и усовершенствованной CNN архитектуры

3.2. Анализ потерь при детектировании ограничивающих рамок и масок

Функции потерь для регрессии ограничивающих рамок (`loss_bbox`) и для детектирования масок (`loss_mask`) являются критически важными компонентами составной функции оптимизации в задачах инстанс-сегментации. `Loss_bbox` обеспечивает точное позиционирование объектов путём минимизации расхождения между предсказанными и эталонными координатами ограничивающих рамок. В свою очередь, `loss_mask` отвечает за точность попиксельной классификации внутри каждой ROI, гарантируя соответствие предсказанной маски контуру объекта.

Из графиков рисунка 3 видно, что современные архитектуры, в частности трансформеры Swin-T и Swin-S, демонстрируют высокую эффективность в оптимизации функций потерь. Архитектура Swin-S достигает минимальных значений по обоим метрикам, что свидетельствует об её явном преимуществе благодаря способности эффективно моделировать




Рисунок 3. Потери регрессии рамок и детектирования масок объектов для различных CNN архитектур

глобальные контекстные зависимости и извлекать иерархические признаки с высокой дискриминативной способностью, реализуя тем самым более точное позиционирование рамок и детализацию масок сегментации.

Наилучшие показатели Swin-S подтверждают перспективность использования трансформерных подходов для задач инстанс-сегментации, где критически важны как точность локализации, так и качество пиксельной классификации.

При этом таблица 1 показывает сопоставимую с DenseNet-121 эффективность моделей Swin-T и ConvNeXt-T, входящих в число наиболее сбалансированных решений по оптимизации обеих метрик.

Таблица 1. Значения функций потерь на валидационном наборе данных для различных архитектур backbone

Backbone	loss_bbox	loss_mask
ResNet-50	0.2185	0.2891
ResNet-101	0.2137	0.3211
DenseNet-121	0.1854	0.2244
EfficientNet-B3	0.2136	0.2666
ConvNeXt-T	0.1793	0.2603
Swin-T	0.1813	0.2148
Swin-S	0.1020	0.1141

3.3. Анализ точности детектирования ограничивающих рамок

На рисунках 4 и 5 представлены графики значений метрик точности детектирования ограничивающих рамок `bbox_mAP`, полученные в результате экспериментальных исследований для объектов различных размеров – `mAP_s`, `mAP_m` и `mAP_l`, см. раздел 2.

Анализ экспериментальных данных выявляет последовательное улучшение метрики `mAP` в исследуемых архитектурах, показанное на таблице 2. В последнем столбце указана эпоха, на которой формируется архитектура backbone с наилучшими весами для детектирования ограничивающих рамок.

ResNet-50 демонстрирует базовый уровень точности ($mAP \approx 0.3236$), в то время как DenseNet-121, благодаря механизму плотных соединений, показывает заметный прирост ($mAP \approx 0.3800$). ResNet-101, несмотря на увеличенную глубину, демонстрирует лишь умеренное улучшение ($mAP \approx 0.4080$) по сравнению с DenseNet-121, что подчеркивает ограничения парадигмы простого наращивания глубины.





РИСУНОК 4. Точность детектирования ограничивающих рамок на валидационном наборе данных для классических CNN архитектур


ТАБЛИЦА 2. Метрики точности детектирования ограничивающих рамок для различных архитектур backbone

Backbone	mAP	mAP _s	mAP _m	mAP _l	Эпоха
ResNet-50	0.3236	0.1500	0.3200	0.4500	51
ResNet-101	0.4080	0.2000	0.3900	0.5000	66
DenseNet-121	0.3800	0.1800	0.3600	0.4800	71
EfficientNet-B3	0.4340	0.2200	0.4100	0.5300	64
ConvNeXt-T	0.4300	0.2300	0.4200	0.5400	76
Swin-T	0.4702	0.2400	0.4300	0.5500	77
Swin-S	0.5606	0.2800	0.5200	0.6500	81


Заметный скачок производительности у EfficientNet-B3 ($\text{mAP} \approx 0.4340$) демонстрирует эффективность стратегии составного масштабирования. Увеличение точности у архитектуры ConvNeXt-T ($\text{mAP} \approx 0.4407$) свидетель-



(а) ConvNeXt-T



(б) Swin-T



(в) Swin-S

Рисунок 5. Точность детектирования ограничивающих рамок на валидационном наборе данных для трансформерных и усовершенствованной CNN архитектур


ствует о потенциале конволюционных сетей с улучшенной способностью к моделированию сложных пространственно-контекстных зависимостей.

Дальнейшее улучшение показывает Swin-T ($mAP \approx 0.4702$), использующий механизм оконного внимания для эффективного моделирования глобальных контекстных взаимодействий при сохранении линейной вычислительной сложности. Наилучший результат демонстрирует Swin-S ($mAP \approx 0.5606$), что наглядно иллюстрирует преимущества трансформерных архитектур и их исключительную эффективность в точной локализации объектов всех размерных категорий, особенно малых объектов, где наблюдается наиболее значимый прирост производительности.


3.4. Анализ точности детектирования масок сегментации

На рисунках 6 и 7, представлены графики значений метрик точности детектирования масок сегментации $segm_mAP$ для объектов различных размеров, см. раздел 2.


Начальный уровень точности детектирования демонстрирует ResNet-50 ($mAP \approx 0.3000$), DenseNet-121 позволяет достичь определённого улучшения




(a) ResNet-50



(б) ResNet-101



(в) DenseNet-121




(г) EfficientNet-B3

РИСУНОК 6. Точность детектирования масок сегментации на валидационном наборе данных для классических CNN архитектур


показателей ($mAP \approx 0.3121$) за счёт эффективного переиспользования признаков через плотные соединения. Увеличение глубины сети, реализованное в ResNet-101, обеспечивает лишь незначительный прирост качества сегментации ($mAP \approx 0.3561$), что свидетельствует об ограничении данного подхода. Применение составного масштабирования в EfficientNet-B3 позволяет стабилизировать показатели на уровне $mAP \approx 0.3795$, однако настоящий качественный скачок наблюдается при переходе к современным архитектурным решениям.

Усовершенствованная CNN архитектура ConvNeXt-T демонстрирует существенное улучшение ($mAP \approx 0.3948$), превосходя традиционные подходы за счёт оптимизации процесса извлечения пространственных признаков. Трансформерная архитектура Swin-T с механизмом оконного внимания показывает дальнейшее улучшение ($mAP \approx 0.4332$), эффективно комбинируя локальные и глобальные контекстные зависимости.


Наивысшую эффективность в задаче инстанс-сегментации реализует трансформерная архитектура Swin-S ($mAP \approx 0.5030$), устанавливающая



(a) ConvNeXt-T



(б) Swin-T



(е) Swin-S

Рисунок 7. Точность детектирования масок сегментации на валидационном наборе данных для трансформерных и усовершенствованной CNN архитектуры

новый стандарт точности для объектов всех размерных категорий. Существенно значимые результаты наблюдаются для сегментации малых объектов, где данный подход демонстрирует наиболее значительное преимущество над другими архитектурами, см. таблицу 3. В последнем столбце указана эпоха, на которой формируется архитектура backbone с наилучшими весами для детектирования масок сегментации.

3.5. Анализ метрик mAP для различных архитектур

Результаты сравнительного анализа метрик точности детектирования ограничивающих рамок и масок сегментации объектов на аэрофотоснимках выявляют значимые различия производительности моделей, рисунок 8. Классические свёрточные сети (ResNet-50, ResNet-101, DenseNet-121) демонстрируют наименьшие значения метрик, в то время как современные архитектуры (ConvNeXt-T, Swin-T) обеспечивают существенный прирост точности. Архитектура Swin-S превосходит все рассмотренные модели по обоим показателям.

Таблица 3. Метрики точности детектирования масок сегментации для различных архитектур backbone

Backbone	mAP	mAP_s	mAP_m	mAP_l	Эпоха
ResNet-50	0.3000	0.1200	0.2800	0.4200	52
ResNet-101	0.3561	0.1900	0.3600	0.5100	67
DenseNet-121	0.3121	0.1600	0.3300	0.4800	73
EfficientNet-B3	0.3795	0.2000	0.3700	0.5200	65
ConvNeXt-T	0.3948	0.2300	0.4000	0.5500	75
Swin-T	0.4332	0.2400	0.4100	0.5600	78
Swin-S	0.5030	0.2800	0.4700	0.6300	82




Рисунок 8. Сравнение метрик bbox_mAP и segm_mAP для различных архитектур backbone модели Mask R-CNN

Для всех архитектур характерно устойчивое превышение значения bbox_mAP над segm_mAP, что согласуется с теоретическими ожиданиями – задача точного пиксельного выделения объектов является более сложной по сравнению с детектированием ограничивающих рамок.

Величина разрыва между метриками варьируется в зависимости от архитектуры. Наименьшее относительное отклонение наблюдается у Swin-S (≈ 0.0576), что свидетельствует о её сбалансированной эффективности при решении обеих задач. Напротив, наибольший разрыв характерен для ResNet-50 (0.0236) и DenseNet-121 (0.0679), что указывает на их менее оптимальную адаптацию к задаче инстанс-сегментации.

Таким образом, полученные данные подтверждают перспективность

использования трансформерных и современных сверточных архитектур для обработки аэрофотоснимков, где требуется одновременное достижение высокой точности детектирования и сегментации объектов.

3.6. Сравнительная визуализация контуров масок сегментации объектов

На рисунках 9–15 и приведены результаты детектирования объектов на фрагменте изображения аэрофотоснимка с использованием модели Mask R-CNN, имеющей разные backbone. Практическая значимость



Рисунок 9. ResNet-50, погрешность контуров масок $\approx 15\%$



Рисунок 10. ResNet-101, погрешность контуров масок $\approx 10\text{--}11\%$

эффективного решения этой задачи описана в [13].

Анализ погрешности детектирования контуров масок сегментации показали прямую зависимость между архитектурой backbone и точностью сегментации. Классические архитектуры CNN демонстрируют наибольшую погрешность: ResNet-50 ($\approx 15\%$), ResNet-101 ($\approx 10\text{--}11\%$) и DenseNet-121 ($\approx 12\%$). EfficientNet-B3 показывает результат ($\approx 10\text{--}11\%$), сопоставимый с ResNet-101 и DenseNet-121, что, возможно, свидетельствует о достижении




Рисунок 11. DenseNet-121, погрешность контуров масок $\approx 12\%$




Рисунок 12. EfficientNet-B3, погрешность контуров масок $\approx 10\text{--}11\%$




Рисунок 13. ConvNeXt-T, погрешность контуров масок $\approx 7\%$

предела эффективности традиционных свёрточных архитектур. Более низкие значения погрешности получены для современных архитектур ConvNeXt-T ($\approx 7\%$) и Swin-T ($\approx 3\text{--}5\%$). Наименьшая погрешность определения контуров масок сегментации зафиксирована у трансформерной

Рисунок 14. Swin-T, погрешность контуров масок $\approx 3\text{--}5\%$ Рисунок 15. Swin-S (погрешность контуров масок $\approx 1\text{--}2\%$)

архитектуры Swin-S ($\approx 1\text{--}2\%$), рисунок 15.

Полученные результаты свидетельствуют, что использование современных архитектур, в частности трансформеров, позволяет существенно повысить точность позиционирования границ объектов по сравнению с классическими CNN-подходами. Это особенно значимо для решения прикладных задач, требующих высокой точности сегментации, таких как картографирование или кадастровый учёт [12, 13]. Повышение точности открывает возможности для автоматизации процессов обработки аэрофотоснимков с минимальным участием человека.

3.7. Оценка времени обучения и инференса моделей

Экспериментальные исследования моделей Mask R-CNN с различными типами архитектур backbone осуществлялись с использованием GPU A100 80GB. Время обучения моделей и время их инференса для изображений, средний размер которых составляет 1010×750 px, приведено в таблице 4.

ТАБЛИЦА 4. Время обучения и инференса моделей

Backbone	Время обучения	Время инференса
ResNet-50	12–18 мин.	0.05–0.1 сек.
DenseNet-121	20–30 мин.	0.08–0.15 сек.
ResNet-101	18–25 мин.	0.07–0.12 сек.
EfficientNet-B3	22–35 мин.	0.09–0.16 сек.
ConvNeXt-T	15–22 мин.	0.06–0.1 сек.
Swin-T	30–45 мин.	0.1–0.2 сек.
Swin-S	1.5–2 час.	0.2–0.4 сек.

Заключение

В работе проведён сравнительный анализ эффективности семи архитектур backbone в составе модели Mask R-CNN для задачи инстанс-сегментации объектов на аэрофотоснимках. Результаты эксперимента демонстрируют преимущество архитектур на основе механизма внимания (Swin-T и Swin-S) и усовершенствованной CNN (ConvNeXt-T) над классическими свёрточными сетями.

Установлено, что способность модели к захвату глобальных контекстных зависимостей является значимым фактором для достижения высокой точности сегментации в условиях аэрофотосъёмки. Архитектура Swin-S показала наивысшие значения метрик *bbox_mAP* ($= 0.5606$) и *segm_mAP* ($= 0.5030$), особенно для сегментации объектов малого размера. При этом достижение максимальной точности сопряжено со значительными вычислительными затратами, что ограничивает применение Swin-S задачами offline обработки. Для сценариев реального времени более целесообразно использование моделей Swin-T и ConvNeXt-T, обеспечивающих приемлемый компромисс между точностью и производительностью.

Исследование предоставляет эмпирические данные для выбора архитектуры backbone в зависимости от требований конкретного приложения. Результаты исследований в настоящее время используются в информационной системе картографирования ППК «Роскадастр». Перспективным направлением дальнейших работ является разработка методов оптимизации соотношения точности и производительности, включая создание гибридных архитектур.

Список использованных источников

- [1] He K., Gkioxari G., P. Dollár, Girshick R. B. *Mask R-CNN* // *2017 IEEE International Conference on Computer Vision (ICCV)* (Venice, Italy, 22–29 October 2017).– IEEE.– 2017.– ISBN 9781538610336.– Pp. 2980–2988.   1703.06870  ¹⁹⁶
- [2] Ren S., He K., Girshick R., Sun J. *Faster R-CNN: towards real-time object detection with region proposal networks* // *Advances in Neural Information Processing Systems 28*.– V. 1, NIPS 2015 (Montreal, Canada, 7–12 December 2015), Cambridge: MIT Press.– 2015.– ISBN 9781510825024.– Pp. 91–99.    ¹⁹⁶
- [3] He K., Zhang X., Ren S., Sun J. *Deep residual learning for image recognition* // *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (Las Vegas, NV, USA, 27–30 June 2016).– IEEE.– 2016.– ISBN 9781467388528.– Pp. 770–778.   1512.03385  ^{196, 198}
- [4] Huang G., Liu Z., van der Maaten L., Weinberger K. Q. *Densely connected convolutional networks* // *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (Honolulu, HI, USA, 21–26 July 2017).– 2017.– ISBN 9781538604588.– Pp. 2261–2269.   1608.06993  ^{196, 198}
- [5] Tan M., Le Q. V. *EfficientNet: rethinking model scaling for convolutional neural networks*, International Conference on Machine Learning (Long Beach, California, USA, 9–15 June 2019), Proceedings of Machine Learning Research.– vol. **97**.– 2019.– ISBN 9781510886988.– Pp. 6105–6114.    1905.11946  ^{196, 198}
- [6] Liu Z., Mao H., Wu C. -Y., Feichtenhofer C., Darrell T., Xie S. *A ConvNet for the 2020s* // *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (New Orleans, LA, USA, 18–24 June 2022).– IEEE.– 2022.– ISBN 9781665469470.– Pp. 11976–11986.  2201.03545   ^{196, 198}
- [7] Liu Z., Lin Y., Cao Y., Hu H., Wei Y., Zhang Z., Lin S., Guo B. *Swin Transformer: hierarchical vision transformer using shifted windows* // *2021 IEEE/CVF International Conference on Computer Vision (ICCV)* (Montreal, QC, Canada, 10–17 October 2021).– 2021.– ISBN 978-1-6654-2812-5.– Pp. 9992–10002.   2103.14030  ^{196, 198}
- [8] Dosovitskiy A., Beyer L., Kolesnikov A., Weissenborn D., Zhai X., Unterthiner T., Dehghani M., Minderer M., Heigold G., Gelly S., Uszkoreit J., Houlsby N. *An image is worth 16x16 words: transformers for image recognition at scale* // *International Conference on Learning Representations (ICLR)* (Vienna, Austria, 4 May 2021).– 2021.– ISBN 9798331321949.– 21 pp.   2010.11929  ¹⁹⁷
- [9] Vasu P. K. A., Gabriel J., Zhu J., Tuzel O., Ranjan A. *MobileOne: an improved one millisecond mobile backbone* // *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (Vancouver, BC, Canada, 18–22 June 2023).– IEEE.– 2023.– ISBN 9798350301304.– Pp. 7907–7917.   2206.04040  ¹⁹⁷
- [10] Maaz M., Shaker A., Cholakkal H., Khan S., Zamir S. W., Anwer R. M., Khan F. S. *EdgeNeXt: efficiently amalgamated CNN-transformer architecture for mobile vision applications*, Computer Vision – ECCV 2022 Workshops (ECCV 2022) (Tel Aviv, Israel, 23–27 October 2022), Lecture Notes in Computer Science.– vol. **13807**, Cham: Springer.– 2022.– ISBN 978-3-031-25082-8.– Pp. 3–20.   2206.10589  ¹⁹⁷

- [11] Dai Z., Liu H., Le Q. V., Tan M. *CoAtNet: marrying convolution and attention for all data sizes* // *NIPS'21: Proceedings of the 35th International Conference on Neural Information Processing Systems* (6–14 December 2021), Red Hook: Curran Associates Inc.– 2021.– ISBN 978-1-7138-4539-3.– Pp. 3965–3977.– id. 303. 2106.04803 197
- [12] Винокуров И. В. *Использование модели Mask R-CNN для сегментации объектов недвижимости на аэрофотоснимках* // Программные системы: теория и приложения.– 2025.– Т. 16.– № 1(64).– С. 3–44 (Англ., Рус.). 197, 200, 212
- [13] Винокуров И. В. *Повышение точности сегментирования объектов с использованием генеративно-состязательной сети* // Программные системы: теория и приложения.– 2025.– Т. 16.– № 2(65).– С. 111–152 (Англ., Рус.). 197, 210, 212
- [14] Xie E., Wang W., Yu Z., Anandkumar A., Alvarez J. M., Luo P. *SegFormer: simple and efficient design for semantic segmentation with transformers* // *NIPS'21: Proceedings of the 35th International Conference on Neural Information Processing Systems* (6–14 December 2021), Red Hook: Curran Associates Inc.– 2021.– ISBN 978-1-7138-4539-3.– Pp. 12077–12090. 2105.15203 198
- [15] Cheng B., Misra I., Schwing A. G., Kirillov A., Girdhar R. *Masked-attention mask transformer for universal image segmentation* // *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (New Orleans, LA, USA, 18–24 June 2022).– IEEE.– 2022.– ISBN 9781665469470.– Pp. 1290–1299. 2112.01527 199
- [16] Carion N., Massa F., Synnaeve G., Usunier N., Kirillov A., Zagoruyko S. *End-to-end object detection with transformers*, Computer Vision - ECCV 2020 (ECCV 2020), Lecture Notes in Computer Science.– vol. 12346, Cham: Springer.– 2020.– ISBN 978-3-030-58452-8.– Pp. 213–229. 2005.12872 199
- [17] Tan M., Pang R., Le Q. V. *EfficientDet: scalable and efficient object detection* // *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (Seattle, WA, USA, 14–19 June 2020).– IEEE.– 2020.– ISBN 9781728171692.– Pp. 10778–10787. 1911.09070 199
- [18] Peng J., Liu Y., Tang S., Hao Y., Chu L., Chen G., Wu Z., Chen Z., Lai B. *PP-LiteSeg: a superior real-time semantic segmentation model*.– 2022.– 8 pp. 2204.02681 199
- [19] Hafiz A. M., Bhat G. M. *A survey on instance segmentation: state of the art* // *International Journal of Multimedia Information Retrieval*.– 2020.– Vol. 9.– Pp. 171–189. 199
- [20] Canziani A., Paszke A., Culurciello E. *An Analysis of Deep Neural Network models for practical applications*.– 2016. 1605.07678 199

Поступила в редакцию	22.09.2025;
одобрена после рецензирования	27.09.2025;
принята к публикации	12.10.2025;
опубликована онлайн	19.10.2025.

Рекомендовал к публикации

к.т.н. Е. П. Куршев

Информация об авторах:



Игорь Викторович Винокуров

Кандидат технических наук (PhD), ассоциированный профессор в Финансовом Университете при Правительстве Российской Федерации. Область научных интересов: информационные системы, информационные технологии, технологии обработки данных



0000-0001-8697-1032

e-mail: igvvinokurov@fa.ru



Дарья Александровна Фролова

Студент третьего курса бакалавриата Финансового Университета при Правительстве Российской Федерации. Область научных интересов: информационные технологии, автоматизация процессов, анализ данных



0009-0009-7830-1165

e-mail: dari15frolowa@gmail.com



Андрей Иванович Ильин

Студент третьего курса бакалавриата Финансового Университета при Правительстве Российской Федерации. Область научных интересов: информационные технологии, программирование, анализ данных



0009-0002-0651-8102

e-mail: andrey08937@yandex.ru



Иван Романович Кузнецов

Студент третьего курса бакалавриата Финансового Университета при Правительстве Российской Федерации. Область научных интересов: информационные технологии и технологии обработки данных, программирование



0009-0000-3135-4424

e-mail: ivan.kuznetsov0709@mail.ru

Вклад авторов: *И. В. Винокуров* – 70% (разработка методики проведения экспериментов, формирование конфигурационных файлов, реализация обучения и исследования моделей, интеграция результатов в информационные системы ППК «Роскадастр»); *Д. А. Фролова* – 10% (аннотирование изображений, формирование набора данных); *А. И. Ильин* – 10% (оптимизация метрик точности моделей); *И. Р. Кузнецов* – 10% (визуализация инференса моделей).

Декларация об отсутствии личной заинтересованности: *благополучие авторов не зависит от результатов исследования.*