



## Применение нейросетей для оценки разводимости при проектировании СБИС с учетом начальных параметров топологии

<sup>1,2</sup> М.Х. Сайбодалов, ORCID: 0009-0003-0473-2161 <maratsaibodalov@gmail.com>

<sup>1,3</sup> М.В. Дашиев, ORCID: 0009-0004-0309-7175 <dashiev@niisi.ras.ru>

<sup>1,2</sup> Я.М. Карандашев, ORCID: 0000-0001-8483-072X <karandashev@niisi.ras.ru>

<sup>1</sup> Н.В. Желудков, ORCID: 0009-0009-0501-5686 <nvgel@cs.niisi.ras.ru>

<sup>1</sup> Е.С. Кочева, ORCID: 0009-0002-9587-0115 <kocheva@cs.niisi.ras.ru>

<sup>1</sup> НИЦ «Курчатовский институт», НИИСИ,

Россия, 117218, г. Москва, Нахимовский просп., 36, к.1.

<sup>2</sup> Российский Университет Дружбы Народов им. Патриса Лумумбы,

Россия, 117198, г. Москва, ул. Миклухо-Маклая, 6.

<sup>3</sup> Московский физико-технический институт,

Россия, 141701, г. Долгопрудный, Институтский пер., 9.

**Аннотация.** В статье рассматривается задача оценки карты разводимости при проектировании интегральных схем на этапе размещения цифровых блоков с использованием нейросетевых моделей. Раннее прогнозирование разводимости позволит инженеру-проектировщику схем изменить план размещения, расположение макросов и портов ввода-вывода, чтобы предотвратить проблемы с маршрутизацией межсоединений на более поздних этапах, тем самым сократив количество запусков инструментов автоматизации электронного проектирования и общее время разработки схемы. В работе предлагается использовать начальные параметры топологии, которые не учитывались в предыдущих работах и позволяют моделям делать более точные прогнозы карты разводимости.

**Ключевые слова:** сверхбольшие интегральные схемы СБИС; карта разводимости; нейронные сети.

**Для цитирования:** Сайбодалов М.Х., Дашиев М.В., Карандашев Я.М., Желудков Н.В., Кочева Е.С. Применение нейросетей для оценки разводимости при проектировании СБИС с учетом начальных параметров топологии. Труды ИСП РАН, том 37, вып. 3, 2025 г., стр. 9–18. DOI: 10.15514/ISPRAS-2025-37(3)-1.

**Благодарности:** Работа выполнена в рамках государственного задания НИЦ «Курчатовский институт» – НИИСИ по теме № FNEF-2024-0001 "Создание и реализация доверенных систем искусственного интеллекта, основанных на новых математических и алгоритмических методах, моделях быстрых вычислений, реализуемых на отечественных вычислительных системах" (1023032100070-3-1.2.1).

# Application of Neural Networks for Routing Congestion Prediction in VLSI Design Using Initial Layout Parameters

<sup>1,2</sup> M.K. Saibodalov, ORCID: 0009-0003-0473-2161 <maratsaibodalov@gmail.com>

<sup>1,3</sup> M.V. Dashiev, ORCID: 0009-0004-0309-7175 <dashiev@niisi.ras.ru>

<sup>1,2</sup> I.M. Karandashev, ORCID: 0000-0001-8483-072X <karandashev@niisi.ras.ru>

<sup>1</sup> N.V. Zheludkov, ORCID: 0009-0009-0501-5686 <nvigel@cs.niisi.ras.ru>

<sup>1</sup> E.S. Kocheva, ORCID: 0009-0002-9587-0115 <kocheva@cs.niisi.ras.ru>

<sup>1</sup> NRC «Kurchatov Institute» – SRISA,

bld. 1, 36, Nakhimovskiy pr., Moscow, 117218, Russia.

<sup>2</sup> The Patrice Lumumba Peoples' Friendship University of Russia,

6, Miklukho-Maklaya st., Moscow, 117198, Russia.

<sup>3</sup> Moscow Institute of Physics and Technology,

9, Institutskiy per, Dolgoprudniy, 141701, Russia.

**Abstract.** This paper considers the problem of congestion map prediction at the pre-routing stage of VLSI layout design of digital blocks by applying neural network models. Early prediction of congestion will allow the VLSI design engineer to modify floorplan, macro placement and input-output port placement to prevent interconnect routing issues at later stages, thereby reducing the number of EDA tool runs and the overall circuit design runtime. In this work we propose the use of the initial layout parameters, which were not considered in previous works and allow for a more accurate congestion prediction.

**Keywords:** VLSI; congestion map; neural networks.

**For citation:** Saibodalov M.K., Dashiev M.V., Karandashev I.M., Zheludkov N.V., Kocheva E.S. Application of Neural Networks for Routing Congestion Prediction in VLSI Design Using Initial Layout Parameters. *Trudy ISP RAN/Proc. ISP RAS*, vol. 37, issue 3, 2025. pp. 9-18 (in Russian). DOI: 10.15514/ISPRAS-2025-37(3)-1.

**Acknowledgements.** The work was carried out within the framework of the state task of the NRC «Kurchatov Institute» – SRISA on the topic FNEF-2024-0001 «Development and deployment of trusted AI systems based on new mathematical and algorithmic approaches and fast computing models compatible with domestic computer hardware» (1023032100070-3-1.2.1).

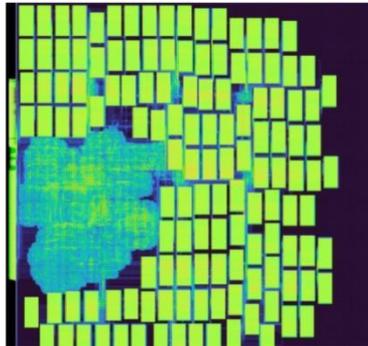
## 1. Введение

В рамках топологического проектирования цифровых блоков СБИС (сверхбольших интегральных схем) важными критериями является быстрое достижение результата, соответствующего правилам проектирования DRC (Design Rule Check). Одним из ключевых этапов проектирования является детальная маршрутизация межсоединений в схеме. Это один из финальных и наиболее трудоемкие этапов, в результате которого могут возникать DRC-нарушения.

В зависимости от используемого технологического процесса может отличаться количество доступных для трассировки слоев металлизации и набор правил, согласно которым реализуется детальная маршрутизация. Для каждого слоя металлизации существует некая сетка, сформированная из вертикальных и горизонтальных треков, по которым должна осуществляться маршрутизация. Как правило, в процессе топологического проектирования, качество маршрутизации оценивается дважды: после глобальной маршрутизации, которая производится без жесткой привязки к конкретным трекам (после этапа размещения стандартных элементов), и после финальной детальной маршрутизации. Для данной оценки схема делится на некоторую сетку, высота ячейки которой кратна высоте стандартных ячеек. Для каждой ячейки оценивается отношение требуемых для разводки треков к имеющемуся при данном размещении количеству элементов. Соответственно, во избежание нарушений, количество требуемых треков не должно превышать доступное.

На ранних этапах проектирования существует целый ряд настроек, оказывающих непосредственное влияние на итоговую карту разводимости. На первом этапе – плане размещения, определяются: площадь схемы, от которой будет зависеть плотность расположения элементов (при слишком больших значениях плотности маршрутизация может оказаться вовсе невыполнимой); то, насколько близко расположены друг к другу макроблоки (при слишком плотном размещении могут возникать локальные зоны превышения допустимой разводимости); с какими настройками выполнено построение сетки земли/питания, в зависимости от чего определяется остаточное количество трексов, доступных для маршрутизации. Таким образом, в случае появления большого количества областей с превышением допустимой разводимости, необходимо варьирование параметров, определяемых в самом начале маршрута проектирования, что требует повторного прохождения всего цикла топологического проектирования, приводя к большим затратам по времени и вычислительным ресурсам.

В рамках данной работы мы хотим продемонстрировать применение машинного обучения для прогнозирования карты разводимости на основе начальных параметров топологии, минуя этап маршрутизации. Это позволит существенно сократить временные затраты и получить точную оценку карты разводимости для заданного нетлиста, который представляет собой список логических элементов и их межсоединений, описывающих работу определенной схемы на языке verilog. Мы использовали EDA-инструмент (Electronic design automation) с открытым исходным кодом OpenROAD [1], с помощью которого было произведено размещение ячеек, глобальная маршрутизация и извлечение фактической карты разводимости. На рис. 1 показано изображение карты разводимости, полученное с помощью OpenROAD. Более темные участки соответствуют областям с более низкими значениями разводимости.



*Рис. 1. Карта разводимости, полученная в OpenROAD.*

*Fig. 1. Congestion map in the OpenROAD EDA tool.*

## 1.1. Смежные работы

Большинство работ по предсказанию разводимости связаны с графовыми нейронными сетями. Использование таких архитектур обусловлено тем, что нетлист содержит информацию о логических соединениях между ячейками. В более ранних работах [2] и [3] каждая ячейка представлялась как узел в графе, ее размер и количество соединений являлись признаками узла, а каждый net представлялся как ребро. Затем эти данные передавались в модели GAT (Graph Attention Network) [4] и GraphSAGE (sample and aggregate) [5] для получения предсказаний. В данных работах не использовалась информация о размещении ячеек, модели пытались предсказать значение разводимости на самом раннем из возможных этапов. В более современных работах [6] и [7] уже использовалась информация о размещении, так как она дает более подробную информацию о схеме, а также способствует улучшению конечного результата. В нашей более ранней работе [8] тоже использовались

графовые нейронные сети, но было предложено также использовать оценку RUDY (Rectangular Uniform Wire Density) [9] в качестве входной информации для модели. В данной работе мы предлагаем использовать алгоритмы компьютерного зрения для предсказания карты разводимости. Мы также будем использовать оценку, полученную с помощью алгоритма RUDY, но уже в формате изображения.

## 2. Данные

В качестве исходных данных мы используем 25 открытых блоков из набора данных openABC-D [10], которые представлены в виде RTL (Resistor-transistor level). Все эти схемы были запущены с различными параметрами и, таким образом, было получено 6700 образцов данных. Затем для каждого из этих образцов мы вычисляем оценку RUDY и карту плотности ячеек. На рис. 2 показаны примеры карты, полученной с помощью RUDY, а также карта плотности ячеек. Полученный набор данных делится на обучающую и валидационную выборку таким образом, чтобы 20 схем были в обучающей выборке и 5 в валидационной.

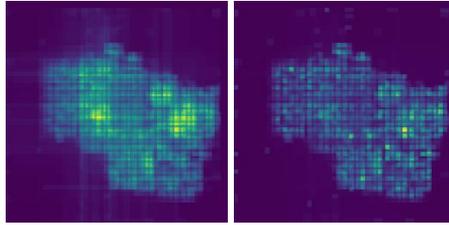


Рис. 2. Пример карты RUDY (слева) и карты плотности ячеек (справа)  
Fig. 2. An example of RUDY map (on the l.h.s.) and cell density map (on the r.h.s.)

Основным нововведением данной работы является использование начальных параметров топологии, которые не учитывались в предыдущих работах по данной тематике. Параметры выбираются до стадий размещения ячеек и маршрутизации, и они имеют сильное влияние на итоговую карту разводимости. В данной работе мы используем 4 параметра:

- Начальная плотность заполнения (core utilization, CU) – считается как отношение площади ячеек в нетлисте к площади блока. Предполагается, что чем меньше значение CU, тем больше места для разводки и лучше разводимость. На рис. 3 показано влияние начальной плотности заполнения на итоговую карту разводимости.

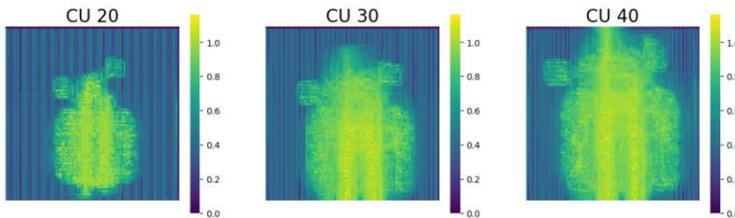


Рис. 3. Влияние начальной плотности заполнения на карту разводимости (реальный размер у изображений разный, но поскольку работа идет со сверточными нейронными сетями, все изображения были уменьшены до одного размера).  
Fig. 3. Core utilization influence on the final congestion map (in fact the size of the images differs, but since the convolutional neural networks are used, all the images were reduced to one size).

- Вид сетки земли-питания (power grid type) – варианты отличаются только разными расстояниями между шинами металлов. Вариант "0" предполагает самое маленькое расстояние, "4" - самое большое. Чем больше расстояние между шинами сетки, тем больше места остается под сигнальную разводку, тем лучше разводимость. То есть

для варианта "4" мы ожидаем увидеть лучшее значение. На рис. 4 показано влияние разных вариантов сетки земли-питания на итоговую карту разводимости.

- Верхний металл – доступный верхний металл для сигнальной разводки. Чем выше значение, тем лучше должна быть разводимость.
- Layer adjustment – параметр, запрещающий определенный процент трексов для разводки. Чем выше значения, тем больший процент трексов запрещен, однако, в некоторых ситуациях более высокие значения этого параметра помогают снизить пиковые значения разводимости.

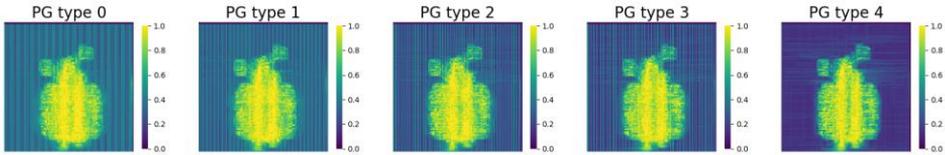


Рис. 4. Влияние вида сетки земли-питания на итоговую карту разводимости.  
Fig. 4. Influence of power grid type on the final congestion map.

### 3. Предлагаемый подход

Основной архитектурой для данной задачи является U-Net [11]. На рис. 5 показана архитектура данной модели. Это одна из самых популярных архитектур сверточных нейронных сетей, изначально созданная для сегментации биомедицинских изображений. Несмотря на то, что этой архитектуре уже почти 10 лет, она по-прежнему показывает хорошие результаты во многих задачах компьютерного зрения и часто используется в качестве компонента более сложных архитектур. Популярность этой архитектуры заключается в ее простоте и эффективности. Эта сеть часто используется для различных задач "image-to-image", наша задача также относится к классу "image-to-image", поскольку мы хотим получить изображение карты разводимости, используя многоканальные изображения RUDY и плотности ячеек. В процессе разработки мы опробовали три разные модели: vanilla U-Net, Attention U-Net [12] и Pix2pix [13]. Pix2pix отличается от двух других моделей тем, что это генеративная состязательная сеть (GAN), которая состоит из генератора и дискриминатора. Как и в оригинальной статье, для генератора мы используем U-Net, а для дискриминатора - PatchGAN. Обученная модель использует только генератор.

Все модели принимают карту RUDY, карту плотности ячеек и начальные параметры топологии в качестве входных данных. Для RUDY и плотности ячеек мы используем функцию, которая представляет собой разделение всех значений карты RUDY и плотности ячеек на процентилях (0-50%, 50-75%, 75-90% и 90-100%) на 4 части (в нашем случае). Идея разделения заключается в том, чтобы помочь нашей модели, выделив области с более высокими и более низкими значениями RUDY и плотности ячеек, которые коррелируют с разводимостью. Количество частей, на которые мы делим исходное изображение, и процентиля, на который происходит разделение, являются гиперпараметрами. На рис. 6 показан пример разделения RUDY.

Поскольку архитектура модели U-Net предназначена для работы с изображениями и принимает двумерные матрицы в качестве входных данных, мы решили передать каждый параметр топологии в отдельном канале в виде двумерной матрицы, в которой каждая позиция заполнена одним и тем же значением (например, при использовании параметра начальной плотности заполнения (Core utilization) = 0,4 мы передаем матрицу ((0,4 0,4 ... 0,4), ..., (0,4 0,4 ... 0,4))). После разбиения на процентиля мы получаем 4 канала RUDY и 4 канала плотности ячеек, затем объединяем RUDY, плотность ячеек и параметры и передаем их на вход нашей модели. Финальный алгоритм показан на рис. 7.

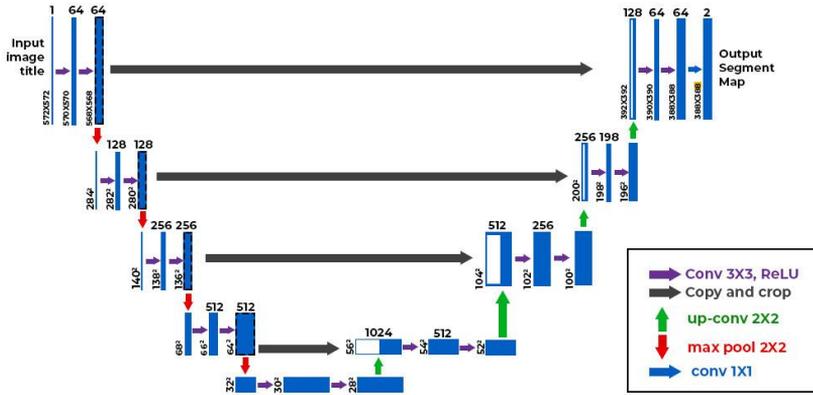


Рис. 5. Архитектура U-Net из оригинальной статьи [11].  
 Fig. 5. U-Net architecture from the original paper [11].

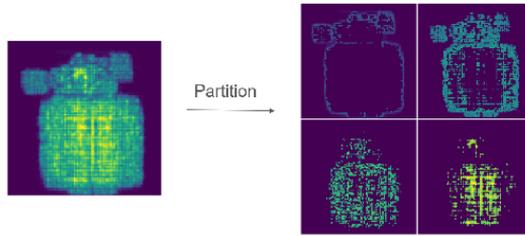


Рис. 6. Разделение RUDY – синий цвет означает меньшие значения, желтый – большие. Канал RUDY делится на 4 части по перцентильям 0-50%, 50-75%, 75-90% и 90-100%.  
 Fig. 6. Partition of RUDY - blue means lower value, yellow means bigger. RUDY channel is divided into 4 parts by percentiles of 0-50%, 50-75%, 75-90% and 90-100%.

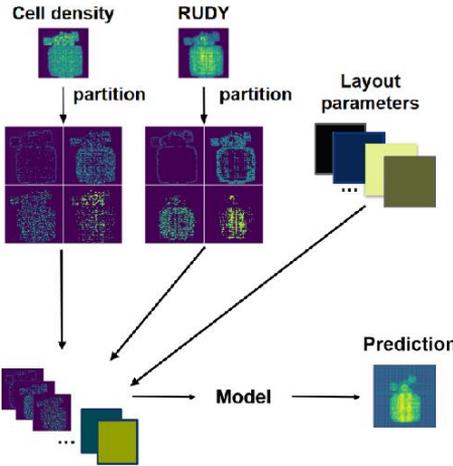


Рис. 7. Основные этапы нашего подхода.  
 Fig. 7. Main stages of our pipeline.

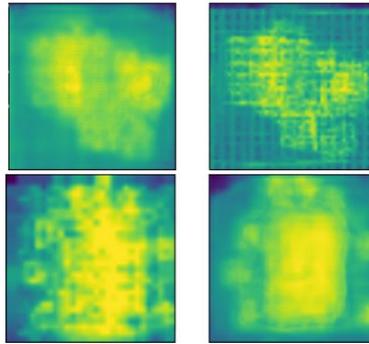
Так как мы работаем с изображениями, мы попытались использовать аугментацию данных, чтобы “расширить” набор данных. В задаче прогнозирования разводимости важно сохранить информацию обо всей структуре схемы, поэтому мы не можем использовать, например, добавление шума, поэтому были использованы повороты и зеркальное отражение, но это привело к ухудшению результатов. Мы связываем это с небольшим разнообразием схем, что

приводит к недостаточной обобщающей способности модели. Из-за этого аугментация данных только запутала модель.

Все модели обучались в течение 100 эпох, при этом карты RUDY и плотности ячеек были разделены с помощью разбиения на четыре части на основе перцентилей: 50, 75 и 90 процентов. Предложенные алгоритмы обычно сходятся за 30 эпох, используется скорость обучения  $2 \times 10^{-4}$  и оптимизатор Adam с гиперпараметрами по умолчанию. Весь этот процесс был выполнен на графическом процессоре NVIDIA RTX 2070 Super.

### 3. Результаты

Наши результаты показаны на рис. 8. Как видно, модель правильно определяет многие участки с высокой разводимостью. Кроме того, наш подход не требует глобальной и детальной маршрутизации для прогнозирования разводимости по сравнению со стандартными подходами.



*Рис. 8. Результаты модели Pix2pix. Слева предсказание модели, справа целевое изображение. Корреляции Пирсона и Кендалла для верхней пары 0.879 и 0.69, для нижней 0.875 и 0.673 соответственно.*

*Fig. 8. Pix2pix results, on the l.h.s is the generated image, on the r.h.s is target. Correlations on the top are 0.879 and 0.69, on the bottom 0.875 and 0.673 for Pearson and Kendall respectively.*

Мы представляем новый подход к прогнозированию карты разводимости на основе начальных параметров топологии, которые сильно влияют на итоговую карту разводимости. Наш подход позволяет исключить трудоемкие этапы глобальной и детальной маршрутизации для прогнозирования разводимости. Хотя этот метод не предполагает полного отказа от инструментов EDA, поскольку используется информация о размещении, данный подход представляет собой переход к более эффективной методологии, основанной на данных. Эффективность моделей на различных схемах существенно различается и подчеркивает необходимость дальнейших исследований для повышения точности методов, основанных на нейронных сетях.

В целях подтверждения актуальности нашего подхода, мы проводим исследования по удалению компонентов модели. Основная цель этой статьи - продемонстрировать важность начальных параметров топологии в моделях прогнозирования разводимости. В табл. 1 можно увидеть результаты удаления различных компонентов из наших моделей. Значения корреляции Кендалла в таблице были рассчитаны путем усреднения по 5 различным итерациям обучения, а также представлены данные о стандартных отклонениях. Как вы можете видеть, начальные параметры топологии оказывают значительное влияние на результирующую корреляцию, их использование мы считаем очень важным нововведением. Кроме того, можно видеть, что использование разделения и карты плотности ячеек также улучшает результаты работы модели. В нашем случае использование разделения карт на 4 части приводит к лучшей корреляции, чем использование карты плотности ячеек, что

означает, что этот метод действительно помогает модели лучше прогнозировать разводимость. Все результаты, представленные в таблице, были получены без использования аугментации, поскольку обучение с аугментацией приводило к худшим результатам.

Основной проблемой является недостаток схем. Некоторые образцы значительно отличаются по значениям разводимости и количеству ячеек, что может отрицательно сказаться на результатах работы моделей. Несмотря на то, что наш набор данных содержит 6700 экземпляров данных, кажется, что 25 различных схем недостаточно для обучения модели с достаточными обобщающими способностями. Основным способом улучшения результатов является увеличение разнообразия схем. Это позволит использовать более глубокие модели, которые могут обеспечить лучшие результаты и обобщающую способность.

Табл. 1. Корреляции Пирсона и Кендалла.

Table 1. Kendall and Pearson correlations.

	UNet		Attention Unet		Pix2pix	
	Kendall	Pearson	Kendall	Pearson	Kendall	Pearson
w/o parameters	0.488 ± 0.015	0.708 ± 0.058	0.484 ± 0.016	0.652 ± 0.027	0.469 ± 0.024	0.643 ± 0.020
w/o partition	0.559 ± 0.046	0.815 ± 0.001	0.553 ± 0.007	0.809 ± 0.006	0.520 ± 0.056	0.713 ± 0.009
w/o density	0.575 ± 0.012	0.780 ± 0.014	0.572 ± 0.019	0.777 ± 0.013	0.572 ± 0.009	0.765 ± 0.025
ours	0.603 ± 0.010	0.810 ± 0.019	0.602 ± 0.008	0.812 ± 0.006	0.616 ± 0.007	0.834 ± 0.006

## Список литературы / References

- [1]. Ajayi et. al. OpenROAD: Toward a Self-Driving, Open-Source Digital Layout Implementation Tool Chain. Proc. GOMACTECH, 2019, pp. 1105–1110.
- [2]. R. Kirby, S. Godil, R. Roy, and B. Catanzaro. CongestionNet: routing congestion prediction using deep graph neural networks. IFIP/IEEE 27th International Conference on Very Large Scale Integration (VLSI-SoC), Cuzco, Peru, 2019, pp. 217–222.
- [3]. A. Ghose, V. Zhang, Y. Zhang, D. Liu, W. Liu, and V. Coates. Generalizable cross-graph embedding for GNN-based congestion prediction. IEEE/ACM International Conference on Computer Aided Design (ICCAD), 2021.
- [4]. P. Velickovic, G. Cucurull, A. Casanova, A. Romero, P. Lió, and Y. Bengio. Graph attention networks. arXiv (Cornell University), 2018.
- [5]. W. L. Hamilton, R. Ying, and J. Leskovec. Versatile multi-stage graph neural network for circuit representation. arXiv (Cornell University), 2017.
- [6]. S. Yang, Z. Yang, D. Li, Y. Zhang, Z. Zhang, G. Song, and J. Hao. Inductive representation learning on large graphs. In Advances in Neural Information Processing Systems, 2022, vol. 35.
- [7]. B. Wang, G. Shen, D. Liu, J. Hao, W. Liu, Y. Huang, H. Wu, Y. Lin, G. Chen, and P. Heng. LHNN: Lattice hypergraph neural network for VLSI congestion prediction. arXiv (Cornell University), 2022.
- [8]. M. Saibodalov, I. Karandashev, Z. Sokhova, E. Kocheva, and N. Zheludkov. Routing Congestion Prediction in VLSI Design Using Graph Neural Networks. DSPA 2024 26th International Conference on Digital Signal Processing and its Applications, Moscow, Russian Federation, 2024, pp. 1-4.
- [9]. P. Spindler and F. M. Johannes. Fast and accurate routing demand estimation for efficient routability-driven placement. EDA Consortium Proceedings of the Conference on Design, Automation and Test in Europe, San Jose, CA, USA, 2007, pp. 1226–1231.
- [10]. A. B. Chowdhury, B. Tan, R. Karri, and S. Garg. OpenABC-D: a large-scale dataset for machine learning guided integrated circuit synthesis. arXiv (Cornell University), 2021.

- [11]. Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-Net: Convolutional Networks for Biomedical Image Segmentation. arXiv (Cornell University), 2015.
- [12]. Ozan Oktay et al. Attention U-Net: Learning Where to Look for the Pancreas. arXiv (Cornell University), 2018.
- [13]. Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, and Alexei A. Efros. Image-to-Image Translation with Conditional Adversarial Networks. arXiv (Cornell University), 2016.

### **Информация об авторах / Information about authors**

Марат Халитович САЙБОДАЛОВ – аспирант РУДН, младший научный сотрудник НИЦ Курчатовский Институт – НИИСИ. Сфера научных интересов: графовые нейронные сети, автоматизация проектирования высокопроизводительных СБИС.

Marat Khalitovich SAIBODALOV – postgraduate student at RUDN University, junior researcher at SRISA. Research interests: graph neural networks, VLSI design automation.

Максим Вадимович ДАШИЕВ – инженер НИЦ Курчатовский Институт – НИИСИ, студент магистратуры МФТИ. Сфера научных интересов: разработка и применение методов машинного обучения и нейронных сетей для решения прикладных задач в различных областях.

Maxim Vadimovich DASHIEV – engineer at SRISA, master degree student at MIPT. Research interests: development of machine learning methods and neural networks to solve applied problems in various fields.

Яков Михайлович КАРАНДАШЕВ – кандидат физико-математических наук, ведущий научный сотрудник НИЦ Курчатовский Институт – НИИСИ, сфера научных интересов: компьютерное зрение, сегментация изображений.

Iakov Mikhailovich KARANDASHEV – Cand. Sci. (Phys.-Math.), leading researcher at SRISA. Research interests: computer vision, image segmentation.

Никита Владимирович ЖЕЛУДКОВ – младший научный сотрудник НИЦ Курчатовский Институт – НИИСИ, сфера научных интересов: автоматизация проектирования высокопроизводительных СБИС, применение методов машинного обучения для решения задач проектирования топологии интегральных схем, повышение сбоеустойчивости цифровых блоков СБИС.

Nikita Vladimirovich ZHELUDKOV – junior researcher at SRISA. Research interests: VLSI design automation, application of machine learning methods to solve integrated circuit topology design problems, increasing the stability of VLSI digital blocks.

Елизавета Сергеевна КОЧЕВА – инженер НИЦ Курчатовский Институт – НИИСИ, сфера научных интересов: топологическое проектирование СБИС, применение машинного обучения при проектировании цифровых блоков СБИС.

Elizaveta Sergeevna KOCHEVA – engineer at SRISA. Research interests: VLSI topological design, application of machine learning methods to solve integrated circuit topology design problems.

