

Исследование эффективности применения различных архитектур нейросетей в расчете маски в задаче инверсной фотолитографии

Я.М. Карандашев^{1,4}, Г.С. Теплов^{2,3}, В.В. Керемет⁵, А.А. Карманов³,
А.В. Кузовков², М.Ю. Мальсагов¹

¹ФГУ ФНЦ НИИСИ РАН, Москва, Россия, karandashev@niisi.ras.ru;

²АО «НИИМЭ», Зеленоград, Россия, gteplov@niime.ru;

³Московский физико-технический институт, Долгопрудный, Россия;

⁴Российский университет дружбы народов, Москва, Россия;

⁵Московский государственный университет им. М.В.Ломоносова, Москва, Россия

Аннотация. В данной работе нами решается обратная задача вычислительной фотолитографии. Расчет топологии маски производился глубокими нейронными сетями. Исследование было направлено на сравнение эффективности нейросетевых архитектур U-Net, Erf-Net и Deep Lab v3, а также встроенных алгоритмов Calibre Workbench в решении задачи инверсной фотолитографии. Обучение искусственных нейронных сетей было выполнено на специально сгенерированном и размеченном наборе данных. Случайные фигуры генерировались с помощью САПР Calibre Workbench для маски затворов транзисторов технологии 90 нм. Сравнение производилось по параметрам точности и скорости. В качестве метрик в работе были использованы edge placement error (EPE) и intersection over union (IOU). Применение нейронных сетей позволило в 100 раз ускорить расчет маски при сохранении точности в 92% на метрике IOU.

Ключевые слова: вычислительная фотолитография, инверсная литография, сверточные нейронные сети, коррекция оптической близости, U-Net, Erf-Net, Deep Lab v3, перевод картинки в картинку, автоматизация электронного проектирования, искусственный интеллект, EPE, IOU

1. Введение

Современные процессы производства микросхем включают технологические операции фотолитографии. Тип операций и используемые методы фотолитографии зависят от минимального линейного размера применяемого в микросхеме и объемов производства. На уровне технологии 180 нм и менее (90 нм, 65 нм, 45 нм, 32 нм) в процессе экспонирования топологии микросхем волновая природа источника излучения с длиной волны 193 нм вызывает эффекты оптической близости [1]. Данный класс эффектов может приводить к искажениям и ошибкам в топологии микросхемы, что в итоге снижает количество выхода годных изделий [2]. К негативным эффектам относятся: укорачивание линий на концах, скругление углов, возникновение перемычек между областями, уширение линий, сужение линий располагающихся в группе и многие другие [3]. Современные фотолитографические технологии включают набор методов повышения разрешающей способности, которые позволяют скорректировать эффекты оптической близости [4]. В число этих методов входят методы преднамеренного изменения маски для компенсирова-

ния нежелательных эффектов оптической природы света. Корректировка эффектов оптической близости при топологических нормах 90 нм и 180 нм может осуществляться двумя технологиями. Первая технология - Optical Proximity Correction (OPC), основана на правилах [5] или оптической модели [6]. Вторая технология - Inverse Lithography Technology (ILT), основана на оптимизации параметров окна процесса фотолитографии [7]. Расчет с применением ИЛТ требует значительного времени и вычислительных ресурсов. Проблема усугубляется увеличением вычислительной сложности выполнения расчета для комплекта фотошаблонов одного изделия, что становится особенно критично при снижении минимальной топологической нормы [8]. Смена нормы приводит к увеличению количества фотошаблонов в комплекте изделия и увеличению времени расчета одного слоя [9].

Возможным решением проблемы для OPC и для ИЛТ может служить применение технологий искусственного интеллекта на основе машинного обучения [10] и нейронных сетей [11]. Ряд коллективов ведет исследования по объединению ML-OPC подхода с техническими решениями EDA для ускорения подготовки комплекта

фотошаблонов [12]. Основные направления применения машинного обучения и нейронных сетей в вычислительной фотолитографии рассматривались в работе [13]. Ранее в своей работе мы исследовали эффективность применения различных алгоритмов ML для выполнения OPC [14]. В данной работе фокусом нашего исследования является применение искусственных нейронных сетей для расчета топологии фотошаблона сопоставимого с фотошаблоном рассчитанным ИЛТ.

Одним из вариантов технического решения является применение GAN для расчета фотошаблона. Указанный подход может применяться как отдельно [15], так и в сочетании с последующим классическим решением [16], которое ускоряет обучение или точность вычислений. Другой подход базируется на применении модифицированных архитектур сверточных нейронных сетей [17, 18]. Последний подход использует специально разработанные для решения данной задачи архитектуры [19] или их модификацию [20].

В своей работе мы рассматриваем технологический процесс 90 нм. Имеющиеся в нашем распоряжении OPC-рецепты учитывают в своем расчете параметры фотолитографического оборудования и свойства применяемого резиста, что ограничивает применение сторонних моделей машинного обучения и нейронных сетей. Поэтому нами были сгенерированы оригинальные наборы данных с применением Calibre Workbench. Цель нашего исследования заключалась в определении эффективности существующих архитектур сверточных нейронных сетей по параметрам точности и скорости расчета. В сравнении использовались архитектуры U-Net [21], Erfnet [22] и DeepLabv3+[23].

2. Описание наборов данных, аппаратных ресурсов и программных средств

Исследование было выполнено на двух сгенерированных наборах данных. Генерация наборов данных для обучения сетей была выполнена в CAD Calibre Workbench. Обучающий пример состоит из изображения топологии (рис. 1а) до расчета маски технологией ИЛТ для этой топологии и рассчитанных фотошаблонов (рис. 1б и рис. 1с). В генерации случайных фигур топологии использовались OPC-рецепты для технологии 90 нм. Фотошаблон соответствует наиболее сложному для вычислений этапу – уровню формирования затворов транзисторов. В обоих случаях во время предобработки и разметки данных из изображения целевого вектора удалялись sub resolution assisted figures (SRAF). Изображения

приведены к бинарному формату через объединение каналов RGB. Черный цвет соответствует фигуре, а белый цвет является фоном. Разрешение изображений 768x768 пикселя, где каждому пикселю соответствует размер топологии 5x5 нм. Линейные размеры сгенерированных фигур находятся в диапазоне от 0.5 до 4 мкм. Выборка состояла из 1536 пар изображений в формате png. Выборка разделена на следующие 3 части: 70% – данные для обучения, 10% – валидационные данные для определения переобучения, 20% тестовые данные для оценки модели.

Первый набор данных включал исходную топологию рис. 1а и результат ее моделирования без применения опции соответствия MRC(mask rule check), рис. 1б. Первый набор данных применялся на стадии оценки эффективности CNN в качестве алгоритма расчета ИЛТ без опции MRC. Архитектура применяемая в проверке гипотезы – U-Net.

Во втором наборе данных целевой вектор является результатом расчета по технологии ИЛТ с опцией соответствия MRC, рис. 1с. Процесс изготовления фотошаблонов имеет свои технологические ограничения, что приводит к необходимости применения опции соответствия MRC при расчете методом ИЛТ. Второй набор данных использовался для тестирования эффективности архитектур U-Net, ErfNet и DeepLabV3+ по параметрам скорости и точности вычислений.




Рис. 1. Рисунки целевых векторов. а) исходный вектор, б) целевой вектор без MRC, в) целевой вектор с MRC.

Расчет фотошаблона в CAD Calibre Workbench с опцией MRC произведен на CPU Intel Gold 6254. Общее время расчета составило 30 минут, что приблизительно соответствует 1 секунде на изображение. Для первичного анализа эффективности применения CNN для решения задачи вычислительной фотолитографии использовался ресурс Google Colaboratory [24] со следующими характеристиками: 12.69 Gb оперативной памяти, 1 видеокарта Nvidia Tesla K80 с 12 Gb видеопамати. Обучение нейронных сетей U-Net, ErfNet и DeepLabV3+ для решения обратной задачи на датасете с MRC выполнено на GPU Nvidia RTX 3080 laptop version. В обоих




Рис. 2. Архитектура нейронной сети Unet.

случаях использовался фреймворк PyTorch [25].

2.1. Архитектуры нейросетевых моделей

Unet. В качестве первой применяемой для решения задачи архитектуры искусственной нейронной сети была выбрана UNet [26], которая хорошо зарекомендовала себя в задачах сегментации и перевода картинки в картинку [27]. Наша сеть имеет сходную с Unet архитектуру, приведенную на рис. 2. Она состоит из сужающегося пути слева (encoder) и расширяющегося пути справа (decoder).

Сужающийся путь Encoder — типичная архитектура сверточной нейронной сети, — представляет собой повторное применения сверток (4×4), с Striding (2, 2), padding (1, 1) за которыми следуют BatchNorm и функция активации ReLU. В отличие от оригинальной UNET модели, мы отказались от maxpooling слоев, заменив их на понижающих размер Striding. Также, в отличие от оригинальной статьи, мы используем padding, для того чтобы выход нашей сети не отличался размером от выхода, и мы не теряли информацию при обрезке. Также мы используем BatchNorm, которого не было в оригинальной работе.

Decoder состоит из повторяющихся операций повышающих дискретизации карты свойств, после чего объединяется с соответствующим образом карты свойств из стягивающегося пути, после каждой операции следуют BatchNorm и функция активации ReLU, кроме последней, по-

сле последней операции следует функция активации sigmoid, чтобы выход сети был в интервале от 0 до 1.

Как уже упоминалось ранее, наш набор данных представляет из себя пару изображений размера 768×768 . Мы специально привели картинки к такому размеру, чтобы длина и ширина делилась на степень двойки, в данном случае на 2^8 , что необходимо для применения 6 последовательных операций свертки 4×4 с шагом 2. Отсюда следует предложенная архитектура нейросети (рис. 2). Общий размер сети составил 1 829 025 параметров.

ERFNet. Вторая использованная нами нейронная сеть — это ERFNet. Архитектура сети полностью соответствует предложенной в работе [22]. Основным преимуществом применяемой архитектуры является применение особого блока последовательных сверток — non-bottleneck-1D, который позволяет уменьшить количество параметров в Encoder не сокращая число сверточных слоев. Применяемый в архитектуре Decoder с малым количеством развертывающих слоев также позволяет уменьшить общее количество параметров сети. В качестве основного преимущества сети традиционно указывают соотношение точности и скорости обработки изображений в сравнении с другими применяемыми архитектурами. Общий размер сети составлял 2 063 130 параметров.




Рис. 3. Характерный результат обучения архитектур. Слева направо: входной вектор, целевой вектор, выход нейронной сети.

DeepLabv3+. Третьей архитектурой для решения задачи была выбрана *DeepLabv3+*. Архитектура может реализовываться различными вариантами модулей. Сравнительный анализ эффективности модулей проводился ранее в работе [23]. В качестве преимуществ указывается, что разреженные сверточные слои позволяют сильно увеличить перцептивную область нейрона, а сшивка представлений, полученных с различной областью восприятия нейрона, позволяет нейросети обучаться как локальным зависимостям, так и располагающимся в обширной области изображения. Различные варианты архитектуры сети включают следующие основные блоки: backbone, assp, decoder и несколько дополнительных. В исследовании была использована архитектура нейронной сети, которая состояла из трех модулей: модуля backbone, модуля ASPP, и модуля decoder. В нашем исследовании в модуле backbone использовалась предобученная нейронная сеть ResNet 101. Общий размер сети *DeepLabv3+* составлял 59 332 642 параметров.

3. Результаты

3.1. Результаты обучения для набора данных ИЛТ без опции MRC

В качестве архитектуры использовалась архитектура Unet, показанная на рис. 2. В качестве функции потерь для обучения использовалась бинарная кросс энтропия, которая вычисляется в каждой точке и определяется:

$$BCE(p, t) = \sum_j -t_j \ln p_j - (1 - t_j) \ln(1 - p_j) \quad (1)$$

где t - реальное бинарное значение пикселя, p - число от 0 до 1, предсказанное нейросетью.

Для оценки качества получаемых изображений использовалась метрика IoU:

$$IoU(A, B) = |A \cap B| / |A \cup B| \quad (2)$$

Метрика IoU (Intersection over Union, формула (3)), известная также как Jaccard index, —

число от 0 до 1, показывающее, насколько у двух объектов совпадает внутренний “объем”. Метрика IoU рассчитывалась между данными с выхода нейронной сети и вектором рис. 1с, в зависимости от используемого набора данных для обучения. В ходе проведения 10 различных запусков процесса обучения были получены следующие усредненные результаты представленные в Таблице 1.

В таблице показано, что все архитектуры сетей продемонстрировали одинаковые показатели качества с точностью до второго знака. Учитывая множественность запусков можно заключить, что точность рассматриваемых моделей совпадает. Стоит отметить, что архитектура UNet обладает самым малым временем расчета, которое вдвое меньше времени расчета ErfNet и в четыре раза меньше времени расчета *DeepLabv3+*. Таким образом, можно заключить что наибольшей производительностью среди рассмотренных моделей обладает архитектура UNet. Стоит отметить, что расчет одного элемента классическими методами на процессоре Intel Xeon Gold 6254 составил порядка 1000 мс.

К основным недостаткам рассчитанных ответов можно отнести скругление краевых линий в областях углов, заметное невооруженным глазом, рис. 3. На рисунке фигуры обозначены белым цветом, и можно видеть как у выходного изображения нейронной сети наблюдается размытие краев. Данная картина была характерна для всех трех архитектур.

Таблица 1. Усредненные результаты по 10 запускам обучения

Параметры/ Архитектуры	U-Net	ErfNet	DeepLab V3+
IOU	0,921	0,923	0,924
Время расчета одного эле- мента, мс	7	13	27

Поскольку полученные результаты совпадают с результатами расчетов классическими методами с разницей в чуть более 1%, была проведена оценка качества полученного решения с применением метрики EPE.

EPE — значение ошибки размещения ребра фрагмента в контрольной точке [28] (см. рис. 4 “Смещение”, ошибка выделена черным). Распределение величины EPE (Edge Placement Error) характеризует ошибку размещения ребер фрагментов в смоделированном контуре, которая вычисляется в контрольных точках. На Рисунке 4 можно видеть абстрактную схему выпол-




Рис. 4. Процедура получения фигуры смещения смоделированного контура для расчёта распределения величины EPE (Edge Placement Error) [28]. EPE выделена черным на стадии “Смещение”.

3.2. Результаты обучения для набора данных ИЛТ с MRC

Обучение на первом наборе данных производилось с использованием функции потерь по-пиксельной бинарной кросс энтропии. В качестве метрики применялась IoU и MSE (mean square error). Таблица с процессом обучения представлена в Таблице 2. Модель обучалась за 30 эпох, время прохождения каждой эпохи в среднем 2 минуты. Метрика IoU показала точность в 0.989.

Таблица 2. Обучение нейронной сети по эпохам.

№ Эпохи	Train loss BCE	Val loss BCE	IoU	MSE
1	0.22669	0.15972	0.89204	0.00262
10	0.02240	0.02286	0.98000	0.00047
20	0.01661	0.01806	0.98460	0.00037
30	0.01089	0.01290	0.98935	0.00027

нения ИЛТ. “Топология” соответствует входному вектору для нашей нейронной сети и аналогична рис. 1а. “Коррекция” соответствует выходному вектору и аналогична рис. 1б. Коррекция представляет собой целевой вектор (рис. 1б и рис. 1с). Для расчета EPE данные с выхода нейронной сети преобразовывались в GDSII, после чего осуществлялось моделирование в САПР “Calibre OPCpro”. Расчет включал в себя 300 смоделированных с помощью нашей нейросетевой модели фигур. Расчет EPE выполнялся только для анализа первого набора данных (без MRC) из-за высокой трудоемкости процесса.

Оценка качества нашей модели с помощью метрики EPE, рассчитанной в САПР показана на рис. 5. Качество представлено гистограммой ошибок EPE нейронной сети и EPE оригинальной модели ИЛТ.

Из рис. 5 видно, что распределение ошибок нейронной сети ближе к нулю, т.е. нейросетевая модель дала даже лучший результат, чем оригинальный алгоритм инверсной фотолитографии. Кроме того, время расчета одного изображения с помощью данного пакета САПР занимало секунду, в то время как работа нейронной сети порядка 17 мс, т.е. достигаемое ускорение в вычислении – на два порядка.




Рис. 5. Гистограммы ошибки EPE Unet и EPE оригинального алгоритма ILT.

4. Заключение

Задачи инверсной фотолитографии, как и другие обратные задачи физики и математики, представляют особый класс задач, в которых применение нейронных сетей кажется наиболее естественным. Действительно, решение, предоставляемое нейронной сетью может быть с легкостью проверено прямым численным моделированием, которое не занимает столь много времени, как итерационный процесс решения обратных задач.

Решение задачи ILT без опции MRC при работе с первым датасетом продемонстрировало результаты превосходящие в скорости и точно-

сти применяемые классические алгоритмы, которые являются стандартом в промышленности. Полученная в работе нейросетевая модель UNet на валидационной выборке из 300 пар изображений показала лучший результат, чем оригинальная модель инверсной фотолитографии, при этом время расчета одной структуры уменьшилось на два порядка. Можно заключить, что данная задача решена на приемлемом уровне.

Решение задачи ILT с опцией MRC при работе со вторым датасетом продемонстрировало недостаточную точность работы сетей, которая составила порядка 92% (по метрике IOU). Основным недостатком в результатах рассмотренных моделей является наличие размытия краев у фигур, что особенно заметно вблизи углов фигур. Полученное решение задачи требует дополнительного исследования для устранения этого недостатка.

Поскольку экстенсивный путь увеличения количества слоев модели (применение ErfNet) и общего количества параметров и слоев (применение DeepLabv3+), не возымел эффекта – изменение подхода к обучению сети и применение других сверточных слоев видится нам следующим логичным шагом в достижении результата.

Работа выполнена при поддержке гранта РФФИ No 19-29-03030 «Поиск физических, технологических и схемотехнических нейросетевых решений на основе мемристорных кроссбаров»

Application of Various Neural Networks Architectures for Mask Calculation in Problem of Inverse Photolithography

Ya.M. Karandashev, G.S. Teplov, V.V. Keremet, A.A. Karmanov,
A.V. Kuzovkov, M.Yu. Malsagov

Abstract. In this work, we solve the inverse problem of computational photolithography. The mask topology was calculated using deep neural networks. The study was aimed at comparing the effectiveness of the neural network architectures U-Net, Erf-Net and Deep Lab v3, as well as the built-in Calibre Workbench algorithms in solving the problem of inverse photolithography. Training of artificial neural networks was performed on a specially generated and labeled data set. Random shapes were generated using the Calibre Workbench CAD mask for the 90nm transistor gate mask. The comparison was made in terms of accuracy and speed. Edge placement error (EPE) and intersection over union (IOU) were used as metrics in the work. The use of neural networks made it possible to speed up the calculation of the mask by 100 times while maintaining an accuracy of 92% on the IOU metric.

Keywords: computational photolithography, inverse lithography technology, convolutional neural networks, ML-OPC, U-Net, Erf-Net, Deep Lab v3, image-to-image, electronic design automation, artificial intelligence, edge placement error, intersection over union

Литература

1. Chien P., Chen M. Proximity effects in submicron optical lithography //Optical microlithography VI. – International Society for Optics and Photonics, 1987. – T. 772. – С. 35-41.

2. Balasinski A. et al. A novel approach to simulate the effect of optical proximity on MOSFET parametric yield //International Electron Devices Meeting 1999. Technical Digest (Cat. No. 99CH36318). – IEEE, 1999. – С. 913-916.
3. Wong A. K. K. Resolution enhancement techniques in optical lithography. – SPIE press, 2001. – Т. 47.
4. Балан Н. Н. и др. Основные подходы к моделированию формирования фоторезистивной маски в вычислительной литографии //Известия высших учебных заведений. Материалы электронной техники. – 2020. – Т. 22. – №. 4. – С. 279-289.
5. Otto Oberdan W, Garofalo Joseph G, Low KK et al. Automated optical proximity correction: a rules-based approach // Optical/Laser Microlithography VII / International Society for Optics and Photonics. — Vol. 2197. — 1994. — P. 278–293.
6. Li J. et al. Model-based optical proximity correction including effects of photoresist processes //Optical Microlithography X. – International Society for Optics and Photonics, 1997. – Т. 3051. – С. 643-651.
7. Hung C. Y. et al. First 65nm tape-out using inverse lithography technology (ILT) //25th Annual BA-CUS Symposium on Photomask Technology. – International Society for Optics and Photonics, 2005. – Т. 5992. – С. 59921U.
8. Красников Г. Я., Синюков Д. В. Проблемы и перспективы развития методов коррекции оптической близости для современных уровней технологии //Труды научного совета РАН" Фундаментальные проблемы элементной базы информационно-вычислительных и управляющих систем и материалов для ее создания". – 2019. – Т. 1. – №. 3. – С. 17.
9. Spence C., Goad S. Computational requirements for OPC //Design for Manufacturability through Design-Process Integration III. – International Society for Optics and Photonics, 2009. – Т. 7275. – С. 72750U.
10. Choi S., Shim S., Shin Y. Machine learning (ML)-guided OPC using basis functions of polar Fourier transform //Optical Microlithography XXIX. – International Society for Optics and Photonics, 2016. – Т. 9780. – С. 97800H.
11. Choi S., Shim S., Shin Y. Neural network classifier-based OPC with imbalanced training data //IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems. – 2018. – Т. 38. – №. 5. – С. 938-948.
12. Shi B. et al. Fast OPC repair flow based on machine learning //Design-Process-Technology Co-optimization for Manufacturability XIV. – International Society for Optics and Photonics, 2020. – Т. 11328. – С. 113281B.
13. Shin Y. Computational Lithography Using Machine Learning Models //IPSJ Transactions on System LSI Design Methodology. – 2021. – Т. 14. – С. 2-10.
14. Tryasoguzov, P.E., Kuzovkov, A.V., Karandashev, I.M. et al. Using Machine Learning Methods to Predict the Magnitude and the Direction of Mask Fragments Displacement in Optical Proximity Correction (OPC). Opt. Mem. Neural Networks 30, 291–297 (2021). <https://doi.org/10.3103/S1060992X21040056>
15. Ye W. et al. LithoGAN: End-to-end lithography modeling with generative adversarial networks //2019 56th ACM/IEEE Design Automation Conference (DAC). – IEEE, 2019. – С. 1-6.
16. Yang H. et al. GAN-OPC: Mask optimization with lithography-guided generative adversarial nets //IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems. – 2019. – Т. 39. – №. 10. – С. 2822-2834.
17. Sun X. et al. U-Net convolutional neural network-based modification method for precise fabrication of three-dimensional microstructures using laser direct writing lithography //Optics Express. – 2021. – Т. 29. – №. 4. – С. 6236-6247.
18. Shao H. C. et al. From IC Layout to Die Photograph: A CNN-Based Data-Driven Approach //IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems. – 2020. – Т. 40. – №. 5. – С. 957-970.
19. Ma X. et al. Model-driven convolution neural network for inverse lithography //Optics express. – 2018. – Т. 26. – №. 25. – С. 32565-32584.
20. Ma X., Zheng X., Arce G. R. Fast inverse lithography based on dual-channel model-driven deep learning //Optics Express. – 2020. – Т. 28. – №. 14. – С. 20404-20421.
21. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation //International Conference on Medical image computing and computer-assisted intervention. – Springer, Cham, 2015. – С. 234-241.
22. Romera E. et al. Erfnet: Efficient residual factorized convnet for real-time semantic segmentation //IEEE Transactions on Intelligent Transportation Systems. – 2017. – Т. 19. – №. 1. – С. 263-272.

23. Chen L. C. et al. Encoder-decoder with atrous separable convolution for semantic image segmentation //Proceedings of the European conference on computer vision (ECCV). – 2018. – C. 801-818.
24. Google Colab, <https://colab.research.google.com>
25. Pytorch Documentation, <https://pytorch.org/docs/stable/index.html>
26. Ronneberger, Olaf, Philipp Fischer, and Thomas Brox. "U-net: Convolutional networks for biomedical image segmentation." In International Conference on Medical image computing and computer-assisted intervention, pp. 234-241. Springer, Cham, 2015.
27. Jun-Yan Zhu, Taesung Park, Phillip Isola, and Alexei A. Efros. "Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks", in IEEE International Conference on Computer Vision (ICCV), 2017
28. "Algorithm and methodology for increasing the OPC-recipe efficiency" Medvedev Konstantin A., Kuzovkov Alexey V., Ivanov Vladimir V. 10.22184/NanoRus.2019.12.89.368.372