

Применение нейронных сетей в современной рентгенографии: автоматизированный анализ данных рефлектометрии с использованием машинного обучения

Р.Д. Голя

*Российский новый университет, Москва
ООО «Рентген-комплект», Москва*

Аннотация: В данной статье рассматривается пакет "mlreflect". Современные технологии анализа данных находят широкое применение в различных областях науки. В частности, язык Python стал ключевым инструментом для создания и обучения искусственных нейронных сетей. Эта мощная платформа предназначена для обработки информации, полученной при зеркальном отражении рентгеновских лучей и нейтронов. Разработанная архитектура на Python представляет собой усовершенствованный конвейер, который автоматизирует анализ данных рефлектометрии. В этом процессе активно используются методы машинного обучения, что значительно повышает точность и скорость обработки информации. Пакет объединяет несколько алгоритмов обучения и обработки данных, что позволяет получить точные и надёжные прогнозы, которые могут служить отправной точкой для последующей подгонки данных с использованием метода наименьших средних квадратов. Для обширного набора информации, который содержит 250 разнообразных кривых отражательной способности тончайших плёнок на кремниевых подложках, было доказано, что поток данных, оптимизированный с целью повышения качества и скорости аналитических вводов, способен с высокой точностью идентифицировать минимум плёнки. Этот минимум оказывается близким к значению, установленному исследователем, опирающимся на свои глубокие физические знания и тщательно подобранные граничные условия. Таким образом, разработанная методология является неотъемлемой частью исследования, обеспечивая надёжные результаты и открывая новые горизонты для дальнейших экспериментов. В заключение, использование оптимизированного потока данных в сочетании с глубоким пониманием физических процессов позволяет значительно продвинуться в области исследований тонких плёнок.

Ключевые слова: нейронная сеть, рентгенография, тонкие пленки, конвейер данных, машинное обучение.

Введение

Современные рентгеновские шаблоны представляют собой сложные многослойные структуры, включающие в себя металлические покрытия, которые способны поглощать рентгеновское излучение, с изображением, нанесенным на них, и тонкую мембрану, которая может пропускать рентгеновские лучи.

Для формирования изображения на фоточувствительном материале толщина поглощающего слоя зависит от длины волны рентгеновского излучения, коэффициента поглощения материала и требуемого контраста.

В настоящее время широко используемым материалом для поглощения рентгеновских лучей является золото, благодаря его высокой эффективности.

Рисунок на рентгеновском шаблоне формируется с применением технологии электронно-лучевой литографии в сочетании с методами сухого травления, что позволяет достичь высокого разрешения и точного контроля размеров элементов изображения, включая наличие вертикальных стенок окон [1].

Для обеспечения эффективного использования шаблона в технологическом процессе необходима мембрана, обладающая высокой прозрачностью для рентгеновских лучей. Этот материал должен быть стабильным по размерам и достаточно прочным для многократного использования. Важно также, чтобы мембрана была прозрачной для видимого света при применении оптического совмещения.

Для создания мембран могут использоваться разнообразные материалы, включая полиимид, кремний (Si), карбид кремния (SiC), нитрид кремния (Si₃N₄), оксид алюминия (Al₂O₃), а также многослойные структуры, такие как Si₃N₄/SiO₂/Si₃N₄. Благодаря этому разнообразию вариантов можно подобрать оптимальный материал для конкретных целей и условий производства.

Несмотря на свою хрупкость, мембраны, состоящие из неорганических компонентов, действительно сложны в процессе производства. Тем не менее, они демонстрируют значительно большую стабильность в размерах, когда происходят изменения температуры, уровня влажности, механических воздействий и многих других факторов. Это делает их предпочтительными в некоторых технологических приложениях, где стабильность критически важна.

На рис.1 можно увидеть структуру рентгеновского шаблона. Этот шаблон находит широкое применение в производстве интегральных схем (ИС). Что касается его конструкции, то он представляет собой многослойную систему, которая включает нитрид бора и полиимид. Важным элементом является тонкая плёнка золота толщиной всего 0,6 мкм. Эта золотая плёнка играет ключевую роль, так как она эффективно поглощает рентгеновское излучение, создавая тем самым детализированный топологический рисунок схемы.




Рис. 1. – Структура рентгеновского шаблона

Использование таких мембран и рентгеновских шаблонов открывает новые горизонты в области микроэлектроники. Улучшение технологии их производства и применения может привести к значительному прогрессу в создании более эффективных и надежных интегральных схем.

При создании данного шаблона, который используется для выделения, применяется специфическое излучение PdLa с длиной волны 0,437 нм. Это излучение, которое очень полезно для данного процесса, обладает уникальными свойствами и способно эффективно воздействовать на объекты. Исследования показывают, что именно это характеристическое излучение позволяет достичь оптимальных результатов в данном контексте.

Успех в области субмикронной рентгеновской литографии зависит от эффективности технологии изготовления рентгеновского шаблона.

Необходимо уделить внимание решению следующих задач, чтобы обеспечить оптимальную стабильность и четкость шаблона.

Структура рентгеновского шаблона, изображенная на рис.1, является ключевым элементом в процессе литографии. Совершенствование процесса изготовления шаблона играет важную роль в достижении высокой разрешающей способности.

Эффективное решение указанных задач способствует снижению плотности дефектов шаблона, что в свою очередь способствует улучшению производительности и качества литографии. Развитие субмикронной рентгеновской литографии возможно при условии решения данных проблем.

Рентгеновская литография является оптимальным инструментом для достижения субмикронного разрешения и обработки пластин. Важно сосредоточить усилия на совершенствовании технологии изготовления шаблона для достижения желаемых результатов в данной области.

Возможно, в будущем с помощью коллимированного рентгеновского излучения синхротрона будет осуществлено экспонирование резистов методом мультиплицирования. Это позволит значительно увеличить эффективность процесса и снизить время экспозиции пластин, достигая разрешения менее 0,5 мкм за одну минуту. При использовании существующих резистов и рентгеновских источников этот метод может стать революционным в области микро- и нанотехнологий [2, 3].

Нейронные сети имеют потенциал для использования в производственных процессах [4, 5].

Задача исследования: Обучить нейронные сети для различных настроек профиля плотности длины рассеяния (ПДР) на тонкой плёнке.

Методы исследования

Здесь будет разработан аналитический конвейер *mlreflect*, который полностью написан на языке Python. Исходный код проекта *mlreflect* доступен

для свободного использования на платформе GitHub по адресу github.com/schreiber-lab/mlreflect. Нейронная сеть, реализованная в рамках проекта, основана на TensorFlow.

Подробные инструкции по установке, полная документация и учебное пособие предоставляются на веб-сайте: mlreflect.readthedocs.io/en/latest/. Для доступа к исходному коду проекта можно воспользоваться ссылкой на GitHub - github.com/schreiber-lab/mlreflect. Пакет Python можно загрузить с индекса по адресу: pypi.org/project/mlreflect/. Помимо этого, дополнительным материалом служит пошаговое руководство в формате исполняемых записных книжек Jupyter и в виде PDF-файла [6]. Для моделирования данных об отражательной способности применяется матричный формализм, который уже реализован в пакете *refl1d* [7].

Концептуально рабочий процесс пакета можно разделить на три этапа:

1. Предварительная обработка;
2. Прогнозирование;
3. Последующая обработка.

На рис.2 схематично показана взаимосвязь этих этапов. Подробно каждый из них будет разобран ниже.

Он состоит из трех основных этапов [8, 9]:

1. На этапе предварительной обработки данных осуществляются геометрические и иные корректировки, связанные с проведением эксперимента. В этот период данные подвергаются нормализации, преобразованию в qz-пространство, интерполяции и стандартизации.

2. Прогнозирование параметров с использованием нейронной сети: предварительно обработанные данные передаются в обученную, полностью подключённую нейронную сеть, которая формирует первичное предположение о параметрах тонкой плёнки.

3. Последующая обработка: первичное предположение используется в качестве исходных параметров для быстрой подгонки с помощью метода Левенберга-Марквардта, что позволяет определить ближайший минимум функции наименьших средних квадратов (НСК) [10].

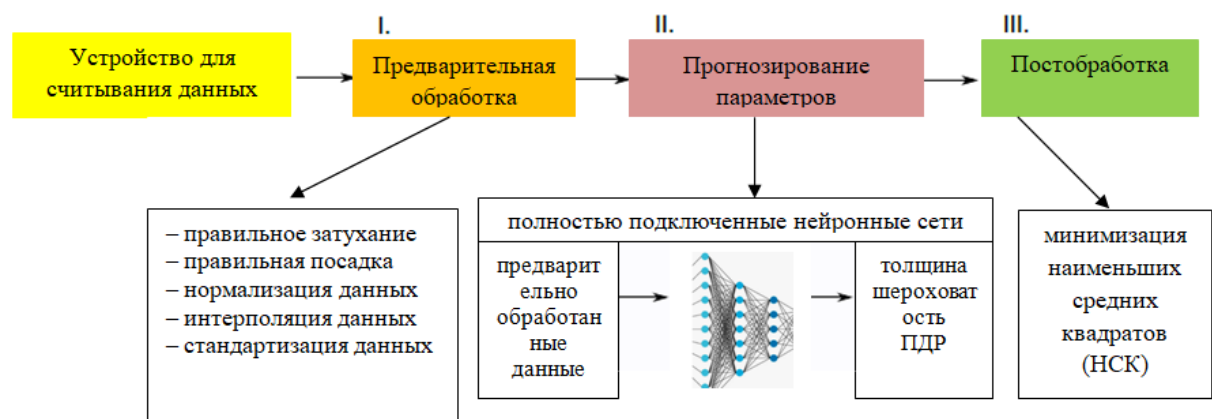


Рис. 2. – Схематическое описание аналитического конвейера.

Модель включает три скрытых слоя, каждый из которых содержит 512 нейронов. Потери при обучении рассчитываются как среднеквадратичная ошибка между нормализованными прогнозируемыми и базовыми параметрами.

Обучающие данные были получены при условии, что структура образца представляла собой тонкую плёнку, нанесённую на кремниевую подложку, покрытую оксидным слоем. Окружающей средой служил воздух, а рентгеновские лучи использовались в качестве датчика. Параметры тонкой плёнки в обучающих данных охватывали широкий диапазон: от 20 до 1000 Å для толщины, от 0 до 100 Å для шероховатости и от $1 - 14 \times 10^{-6} \text{Å}^{-2}$ для ПДР [6, 7].

Новые исследования показывают, что шероховатость, ограничиваемая соответствующими значениями, не превосходит половину толщины, из-за того, что эти критерии не соответствуют теоретической модели, используемой для описания. Помимо этого, стоит отметить, что подобный подход может быть легко распространен на нейтроны или другие структуры образцов,

просто переобучив нейронную сеть с использованием других обучающих данных.

Ожидается, что этот подход будет эффективен и для большего количества слоёв, пока обученное пространство параметров не приведёт к слишком большому количеству неоднозначных решений. То есть количество и диапазон подходящих параметров должны оставаться прежними.

Обсуждение результатов

Эффективность аналитического конвейера была проверена на 250 экспериментальных рентгеновских кривых. В ходе экспериментов, проведённых в условиях «*in situ*» и «*ex situ*», были получены данные для девяти органических тонких плёнок, нанесённых на поверхность кремния и диоксида кремния. При этом для каждого образца было получено от одной до семидесяти девяти кривых при различной толщине плёнок. Распределение толщины, шероховатости и ПДР пленки в этом тестовом наборе представлено на рис.3.

Для получения эталона каждая кривая отражательной способности была предварительно подобрана по логарифмической шкале с использованием алгоритма дифференциальной эволюции. Начальные значения и границы для каждого параметра были заданы вручную.

В нашем аналитическом исследовании мы будем рассматривать параметры, подобранные вручную, как отправную точку для оценки эффективности нашего конвейера. Следует отметить, что модель, используемая для подбора этих параметров, аналогична той, что использовалась при обучении нейронной сети. Таким образом, мы определим абсолютную погрешность по сравнению с исходными данными как меру качества нашего процесса. Далее мы проведем сопоставление между исходными данными и полученными результатами для более детального анализа, полученными с помощью нейронной сети, а также с результатами

автоматизированной последующей подгонки НСК, которая была выполнена на основе этих прогнозов.

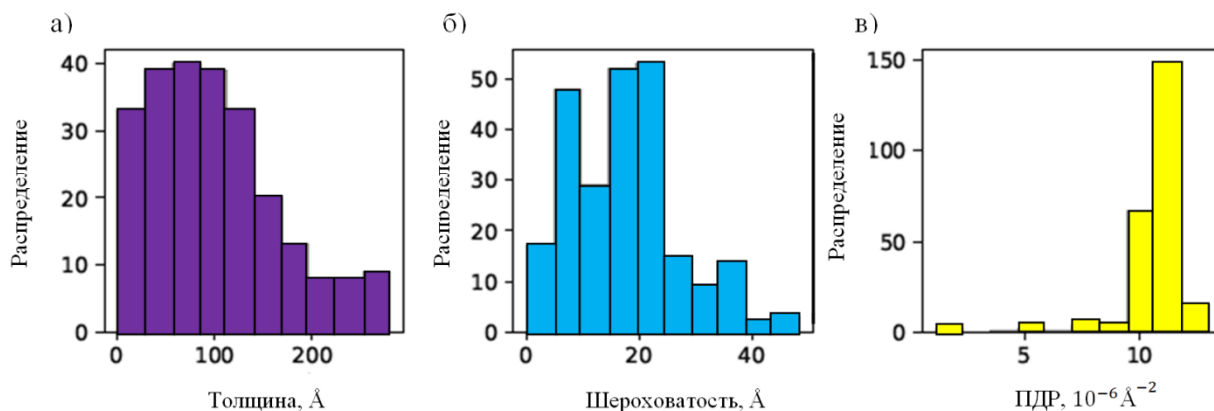


Рис. 3. – Распределение трех параметров образца: толщины (а), шероховатости (б) и ПДР (в)

Для всех 250 кривых, прогнозы нейронной сети показали среднюю абсолютную ошибку (и средний процент ошибки), которые составили 6,0 Å (7,1%) для толщины пленки, 2,0 Å (12,4%) для шероховатости поверхности раздела и $0,72 \times 10^{-6} \text{Å}^{-2}$ (6,8%) для ПДР.

Таким образом, наша сеть демонстрирует более широкую область обобщения по сравнению с ранее опубликованными результатами. Отметим, что все наши данные были получены из органических тонких пленок, и ПДР в тестовом наборе в основном находятся в диапазоне от $10\text{-}13 \times 10^{-6} \text{Å}^{-2}$. Однако будем считать, что наши результаты не зависят от этого диапазона, так как сеть была обучена на данных с ПДР в диапазоне от $1\text{-}14 \times 10^{-6} \text{Å}^{-2}$.

Следующий этап разработки — это дальнейшее уточнение полученных результатов. В ходе исследования была разработана НСК-аппроксимация, в которой в качестве исходных данных используются прогнозы нейронной сети.

Поскольку прогнозы нейронной сети являются достоверными и близки к истинным значениям, нет необходимости использовать сложные и

медленные алгоритмы минимизации, такие как генетические алгоритмы и дифференциальная эволюция, играют важную роль в нахождении глобального минимума. Эти подходы позволяют эффективно исследовать многомерные пространства, обеспечивая точность и надежность результатов. В результате, процесс поиска минимума для каждой кривой занимает всего несколько секунд. Более того, данная процедура может быть полностью автоматизирована, что значительно ускоряет обработку данных.

После выполнения этой процедуры уточнения, средняя абсолютная погрешность (или средняя процентная погрешность) становится ещё более близкой к исходным значениям. Например, для толщины данный показатель достигает 2,3%, для шероховатости — 1%, а для ПДР (показатель деформации поверхности) — 0,47%. Эти достижения свидетельствуют о высокой эффективности применяемых алгоритмов.

Важно отметить, что сравнение распределений ошибок до и после уточнения наглядно представлено на рис.4, что позволяет визуально оценить улучшения. Такие результаты подчеркивают значимость использования данных алгоритмов в различных областях, где требуется высокая точность и надежность. Развитие технологий в области алгоритмов минимизации открывает новые горизонты для исследования и оптимизации, что приносит пользу множеству научных и практических приложений.

На рис.4: а) Исследование отражательной способности включало анализ 24×2 различных измерений. Абсолютные погрешности были рассчитаны для каждой из кривых, соответствующих трём прогнозируемым параметрам. График представляет собой прямоугольные формы, внутри которых отмечены верхние и нижние границы, соответствующие первому и третьему квартилям. Медиана обозначена горизонтальной линией внутри каждого прямоугольника.

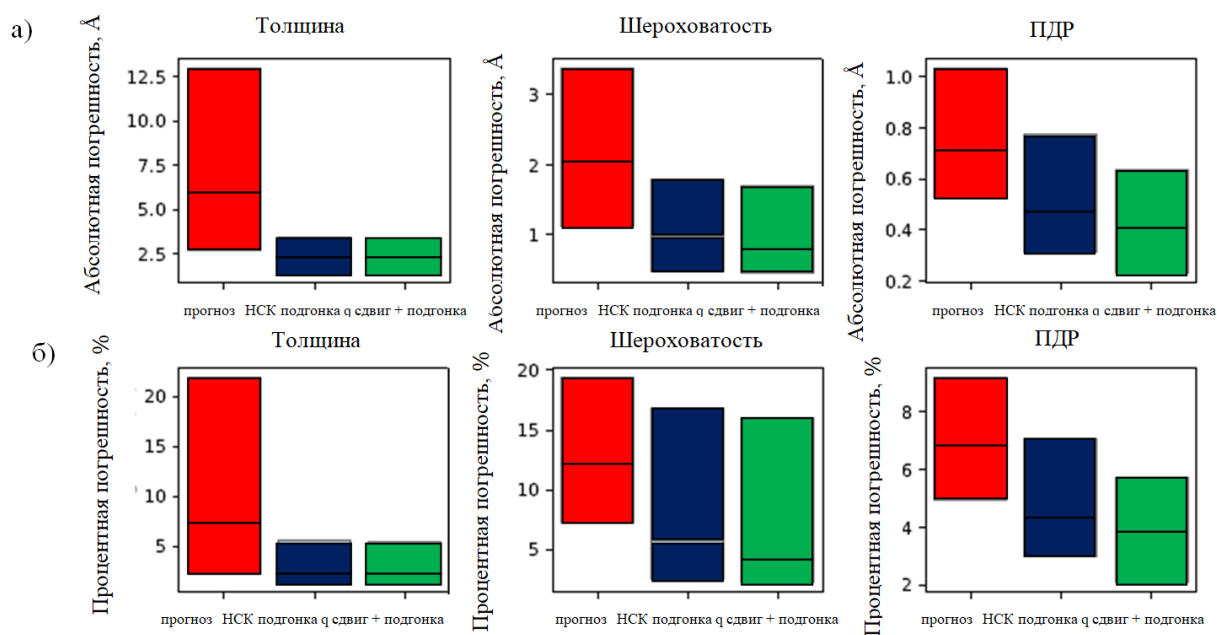


Рис. 4. – Сравнение распределений ошибок до и после уточнения

Синие прямоугольники отображают ошибку по сравнению с прогнозами, полученными с помощью нейронной сети. Красные прямоугольники представляют собой ошибку после применения простой процедуры минимизации НСК с использованием прогнозов нейронной сети в качестве начальных параметров. На графике представлены зелёные прямоугольники, которые являются индикатором ошибки, возникающей в результате некорректного выполнения процедуры оптимизации сдвига qz перед процедурой подгонки НСК.

Также на графике представлены прямоугольные диаграммы средней ошибки (б), выраженные в процентном соотношении к базовой достоверности.

Все результаты были получены при уровне тренировочного шума, равном $n = 0,3$.

Остаточная ошибка может быть объяснена тем, что соответствие не является абсолютно точным, и базовая достоверность содержит некоторую погрешность. Мы оцениваем эту погрешность как минимум в $\pm 10\%$ для каждого параметра, что сопоставимо с отчётом об ошибке нейронной сети.

Эти результаты свидетельствуют о том, что описанный алгоритм анализа в большинстве случаев функционирует аналогично тому, как это делает исследователь-человек. Важно отметить, что результаты были получены значительно быстрее, чем при ручной подгонке.

В большинстве случаев моделирование подвергается дополнительной модификации, которая включает введение определённых артефактов, таких как шум, с целью более точного воспроизведения условий эксперимента. Однако оценить необходимость такого подхода достаточно сложно, поскольку обычно единственным доступным критерием является производительность на других моделируемых данных, которая, как ожидается, будет снижаться с увеличением возмущений.

Исследование воздействия равномерного шума на производительность нейронной сети проводилось в рамках данного эксперимента, где использовался обширный набор данных, включающий 250 различных кривых. Результаты исследования показали, что шум оказывает значительное воздействие на работу нейронной сети, что необходимо учитывать при разработке алгоритмов и моделей машинного обучения.

Кроме того, для оценки влияния шума на производительность сети было обучено 11 копий одной и той же нейронной модели с применением различных уровней шума. Каждая точка данных на кривой шума была выбрана случайным образом в пределах значений $R_i(1-n)$ и $R_i(1+n)$, где n отражает максимальное относительное изменение для каждой точки данных R_i на моделируемой кривой. Это позволило более детально изучить, как шум влияет на точность и стабильность работы нейронной сети в различных условиях.

Важно отметить, что подобные исследования способствуют лучшему пониманию процессов, происходящих в нейронных сетях при воздействии шума, и могут помочь оптимизировать алгоритмы обучения и повысить общую эффективность использования нейронных сетей в различных областях.

В процессе обучения каждой модели значение параметра n изменялось в диапазоне от 0 до 0,5 с незначительным шагом в 0,05. Важно отметить, что равномерный шум, который применяется в этой методике, не предназначен для точного воспроизведения специфических типов физического шума. Например, пуассоновский шум часто используется в статистических расчётах и имеет свои уникальные характеристики. Таким образом, следует помнить, что наш подход к использованию равномерного шума может не отражать реальных условий, с которыми сталкиваются в практических приложениях. В конечном итоге, использование равномерного шума в таких моделях открывает новые перспективы для анализа, но требует осторожного подхода и понимания ограничений. В качестве независимого и всеохватывающего источника шума был выбран однородный шум, воздействующий на всю кривую одинаковым образом. Это делает нейронную сеть устойчивой к ошибкам во всём диапазоне значений параметра q .

Сравнение потерь, представленное на рис.5, демонстрирует различия в результатах, полученных с использованием имитационного и экспериментального тестовых наборов для каждой из моделей. Эти потери, выраженные в виде среднеквадратичной ошибки всех трех параметров выборки, служат важным показателем точности модели. Таким образом, анализ сравнительных данных позволяет увидеть, как точно каждая модель отражает реальные условия.

При $n = 0$, смоделированный тестовый набор демонстрирует невероятно низкие потери, близкие к нулю (примерно 10^{-7}), что указывает на высокую точность модели в условиях искусственного тестирования. Однако, когда рассматриваются потери, основанные на реальных экспериментальных данных, видно, что они значительно превышают значения, полученные в имитационных условиях, на пять порядков.

Такое различие в потерях между имитационными и экспериментальными данными говорит о важности корректного моделирования реальных ситуаций для достижения точности и надежности результатов.

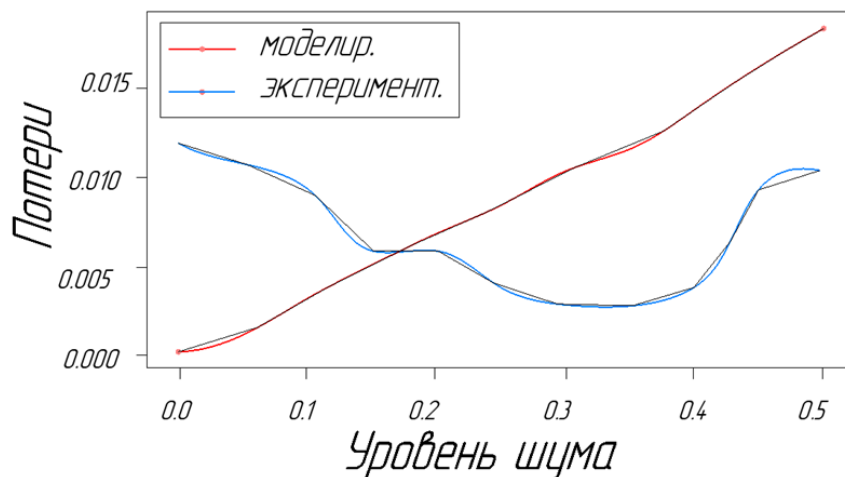


Рис. 5. – Сравнение потерь

Недавние исследования подтверждают, что нейронная сеть, работая без каких-либо помех, демонстрирует впечатляющие результаты, которые превосходят традиционные методы моделирования. Однако, как уже было отмечено, на моделируемых данных наблюдается постоянное увеличение потерь по мере роста уровня шума. Интересно, что, когда уровень шума достигает диапазона 0,3–0,35, наблюдается заметное улучшение производительности обработки реальных данных.

Это открытие подчеркивает сложную природу взаимодействия между шумом и эффективностью работы сети. Примечательно, что даже более высокие уровни шума, похоже, негативно сказываются на производительности, что делает очевидным существование оптимального порога. На этом уровне добавленный шум, по всей видимости, оказывает положительное влияние на результаты, что может быть связано с тем, что он помогает модели лучше обобщать данные.

Таким образом, дальнейшие эксперименты в этой области могут привести к новым инсайтам о том, как оптимально настраивать нейронные сети для работы с шумными данными. Важно отметить, что понимание этого баланса между шумом и производительностью может значительно улучшить практические применения нейронных сетей в реальных условиях. В заключение, дальнейшее изучение оптимальных уровней шума откроет новые горизонты в обработке данных и машинном обучении, как эффективный метод регуляризации, предотвращая переобучение. Однако, если уровень шума слишком высок, то, как следствие, недостаток информации может негативно сказаться на обучении. Таким образом, определено, что $n = 0,3$ является идеальным уровнем шума для данных, аналогичных нашему тестовому набору, который, в частности, содержит данные из разных источников рентгеновского излучения. Оптимальный уровень шума при обучении остаётся относительно постоянным для подмножеств с различными уровнями шума (от 0,1 до 0,5) в рамках нашего экспериментального набора тестов. В связи с этим установлено значение уровня шума по умолчанию в нашем конвейере анализа равным 0,3 [3].

Конечно, наборы данных, которые существенно отличаются от нашего тестового набора с точки зрения экспериментальных артефактов, могут дать несколько иные результаты, хотя ожидается, что общая тенденция останется прежней. Это подчёркивает важность наличия большого экспериментального набора тестов с репрезентативными экспериментальными артефактами, поскольку показателей, основанных только на смоделированных данных, явно недостаточно для оценки прогресса обучения.

Для правильной оценки обученных моделей машинного обучения необходим значительный объём экспериментальных данных. Большинство исследований на данный момент сосредоточены на том, как модель работает на смоделированных данных, и лишь небольшая часть включает

экспериментальные тестовые данные, если они доступны. Однако такой подход может привести к неверному пониманию, поскольку наши результаты ясно демонстрируют, что результаты моделирования не всегда можно легко перенести на экспериментальные условия.

Выводы

В данной статье представлен оптимизированный аналитический конвейер *mlreflect*, созданный на основе машинного обучения для автоматизированного анализа данных об отражательной способности. Конвейер протестирован на обширном наборе данных, состоящем из 250 XRR-кривых, которые включают результаты измерений «*in situ*» (моделирование) и «*ex situ*» (эксперимент) органических тонких пленок на подложках Si/SiO_x. Для большинства данных, наш конвейер продемонстрировал производительность, сравнимую с результатами, полученными с помощью метода наименьших среднеквадратичных значений.

Таким образом, с уверенностью можно утверждать, что *mlreflect* представляет собой полезный инструмент для автоматизированной предварительной проверки или даже анализа данных об отражательной способности в режиме реального времени.

Литература

1. Kovarik M.L., Jacobson S.C. Fabrication of three-dimensional micro-and nanoscale features with single-exposure photolithography // Analytical chemistry. 2006. V. 78. №14. pp. 5214-5217.

2. Артюков И.А. Оптическая и рентгеновская микролитография на рубеже веков // Квантовая электроника. 2022. Т. 52. №12. С. 1094-1101.

3. Loaiza J.M.C., Raza Z. Towards reflectivity profile inversion through artificial neural networks // Machine Learning: Science and Technology. 2021. V. 2. №2. p. 025034.

4. Гладченко-Джевелекис Я.Н., Кулаев К.Д., Поносова Е.Е., Бабаянц А.С., Ермакова А.М., Сухарина Г.Б., Прядченко В.В., Авакян Л.А. Графовые нейронные сети и XANES спектроскопия для исследования структуры центров меди в Cu-MOR // Инженерный вестник Дона, 2023, №12 URL: ivdon.ru/ru/magazine/archive/n12y2023/8892.

5. Звягинцев Н.В., Гордеев Р.Н., Бурилин А.В. Разработка универсальной базы данных структуры и свойств химических соединений для построения моделей «структура-свойство» на основе эвристических алгоритмов MOR // Инженерный вестник Дона, 2013, №4 URL: ivdon.ru/ru/magazine/archive/n4y2013/1967.

6. Mironov D., Durant J.H., Mackenzie R., Cooper J.F.K. Towards automated analysis for neutron reflectivity // Machine Learning: Science and Technology. 2021. V. 2. №3. URL: doi.org/10.1088/2632-2153/abe7b5.

7. Greco A. Starostin V., Hinderhofer A., Gerlach A., Skoda M.W.A., Kowarik S., Schreiber F. Neural network analysis of neutron and x-ray reflectivity data: pathological cases, performance and perspectives //Machine Learning: Science and Technology. 2021. V. 2. №4. URL: doi.org/10.1088/2632-2153/abf9b1.

8. Arzamasov K. Vasilev Yu., Vladzimirsky A., Omelyanskaya O., Shulkin I., Kozikhina D., Goncharova I., Gelezhe P., Kirpichev Yu., Bobrovskaya T., Andreychenko A. An International Non-Inferiority Study for the Benchmarking of AI for Routine Radiology Cases: Chest X-ray, Fluorography and Mammography //Healthcare. MDPI, 2023. V. 11. №12. URL: doi.org/10.3390/healthcare11121684.

9. Солодкий В.А., Каприн А.Д., Нуднов Н.В., Харченко Н.В., Ходорович О.С., Запиров Г.М., Шерстенва Т.В., Дибирова Ш.М., Канахина Л.Б. Современные системы поддержки принятия врачебных решений на базе искусственного интеллекта для анализа цифровых маммографических изображений //Вестник рентгенологии и радиологии. 2023. Т. 104. №2. С. 151-162.

10. Нуризадех Х., Фармани А. Количественное соотношение структура потенциал полуволны для замещенных бензоидных соединений: моделирование на основе искусственной нейронной сети Левенберга-Марквардта // Электрохимия. 2015. Т. 51. №3. С. 293-293.

References

1. Kovarik M.L., Jacobson S.C. Analytical chemistry. 2006. V. 78. №14. pp. 5214-5217.
2. Artyukov I.A. Kvantovaya elektronika. 2022. V. 52. №12. pp. 1094-1101.
3. Loaiza J.M.C., Raza Z. Machine Learning: Science and Technology. 2021. V. 2. №2. pp. 025034.
4. Gladchenko-Dzhevelekis Ya.N., Kulaev K.D., Ponosova E.E., Babayants A.S., Ermakova A.M., Sukharina G.B., Pryadchenko V.V., Avakyan L.A. Inzhenernyj vestnik Dona, 2023, №12. URL: ivdon.ru/ru/magazine/archive/n12y2023/8892.
5. Zvyagintsev N.V., Gordeev R.N., Buriлин A.V. Inzhenernyj vestnik Dona, 2013, №4. URL: ivdon.ru/ru/magazine/archive/n4y2013/1967.
6. Mironov D., Durant J.H., Mackenzie R., Cooper J.F.K. Machine Learning: Science and Technology. 2021. V. 2. №3. URL: doi.org/10.1088/2632-2153/abe7b5.
7. Greco A. Starostin V., Hinderhofer A., Gerlach A., Skoda M.W.A., Kowarik S., Schreiber F. Machine Learning: Science and Technology. 2021. V. 2. №4. URL: doi.org/10.1088/2632-2153/abf9b1.
8. Arzamasov K. Vasilev Yu., Vladzimirsky A., Omelyanskaya O., Shulkin I., Kozikhina D., Goncharova I., Gelezhe P., Kirpichev Yu., Bobrovskaya T., Andreychenko A. Healthcare. MDPI, 2023. V. 11. №12. URL: doi.org/10.3390/healthcare11121684.



9. Solodkiy V.A., Kaprin A.D., Nudnov N.V., Kharchenko N.V., Khodorovich O.S., Zapirov G.M., Sherstenva T.V., Dibirova Sh.M., Kanakhina L.B. Vestnik rentgenologii i radiologii. 2023. V. 104. №2. pp. 151-162.

10. Nurizadekh Kh., Farmani A. Elektrokimiya. 2015. V. 51. №3. pp. 293-293.

Дата поступления: 30.12.2024

Дата публикации: 25.02.2025