

**УДК 004.942**

**Шарапов Евгений Николаевич**, магистрант, Московский технический университет связи и информатики, г. Москва

**ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ  
МОДЕЛИРОВАНИЯ ЭЛЕКТРИЧЕСКИХ ПАРАМЕТРОВ  
ЭЛЕКТРОННЫХ УСТРОЙСТВ**

**Аннотация**

В работе рассматриваются современные методы моделирования электрических параметров электронных модулей с применением нейросетевых и гибридных архитектур. Особое внимание уделяется предсказанию S-параметров, малосигнальных характеристик и паразитных элементов. Проведён обзор подходов на основе полносвязных нейросетей, свёрточных и рекуррентных архитектур, а также ансамблевых и гибридных моделей, включая методы с физическими ограничениями. Описаны преимущества и ограничения популярных решений, такие как искусственные нейронные сети (ANN), опорные векторы (SVR), гауссовские процессы (GPR) и случайные леса. Представлены примеры применения ИИ к моделированию СВЧ-транзисторов, FinFET-структур, печатных плат и силовых преобразователей. В заключение выделены перспективы развития, включая mini-ML-модели, интерпретируемость, физически обоснованные модели и автоматизацию параметрической идентификации. Результаты обобщены на основе анализа 18 научных публикаций, отражающих текущее состояние области.

**Abstract**

This paper explores modern approaches to modeling the electrical parameters of electronic modules using neural network and hybrid architectures. Particular attention is given to the prediction of S-parameters, small-signal characteristics, and parasitic effects. The study reviews methods based on fully connected neural networks, convolutional and recurrent architectures, as well as ensemble and hybrid models, including physics-informed techniques. The strengths and limitations of commonly used methods—such as artificial neural networks (ANN), support vector regression (SVR), Gaussian process regression (GPR), and random forests—are analyzed. Practical applications are presented, covering microwave transistors, FinFET structures, printed circuit boards, and power converters. The paper concludes with perspectives on future development, including miniaturized ML models, model interpretability, physics-based constraints, and automated parameter identification. The findings are synthesized from 18 scientific publications that reflect the current state of research in the field.

**Ключевые слова:** нейросетевое моделирование, электрические параметры, S-параметры, малосигнальная модель, паразитные элементы, электронные модули, искусственные нейронные сети, гибридные модели, машинное обучение, физически обоснованные модели.

**Keywords:** neural network modeling, electrical parameters, S-parameters, small-signal model, parasitic elements, electronic modules, artificial neural networks, hybrid models, machine learning, physics-informed models.

## Введение

Моделирование электрических параметров электронных модулей – таких как S-параметры, малосигнальные характеристики транзисторов, паразитные ёмкости и индуктивности – является ключевым для проектирования и оптимизации современной радиоэлектронной аппаратуры. Традиционные подходы основываются на физических эквивалентных схемах и ручной параметрической подгонке, что требует значительных временных и трудовых затрат. Кроме того, классические модели могут не полностью

учитывать сложные эффекты (например, температурную зависимость или нелинейности новых материалов), вследствие чего точность страдает [1][2]. В этой связи наблюдается возрастающий интерес к использованию методов машинного обучения, в частности нейронных сетей, для создания так называемых суррогатных-моделей электронных компонентов. Такие модели обучаются по экспериментальным или симуляционным данным и способны напрямую предсказывать электрические параметры по условиям работы устройства, минуя трудоёмкие вычисления по физическим уравнениям при помощи специализированного ПО.

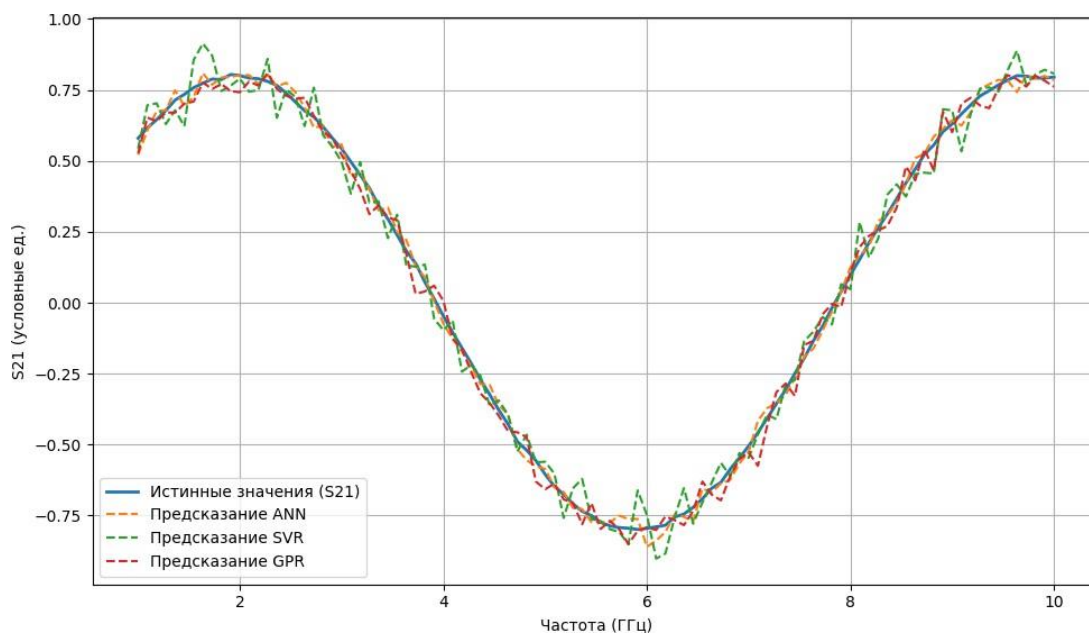


Рисунок 1. – Предсказание S21 параметров различными типами моделей машинного обучения

Нейросетевые методы уже успешно применяются в смежных задачах электроники – например, для автоматизированного контроля качества печатных плат, где алгоритмы глубокого обучения достигают точности выявления дефектов свыше 95% [3]. Это демонстрирует потенциал нейронных сетей в анализе сложных электронных объектов. Напрямую для моделирования параметров устройств искусственные нейронные сети (ИНС) показали способность воспроизводить нелинейные характеристики без явного задания физических закономерностей [4][5]. Уже имеются примеры, когда

ИНС с высокой точностью аппроксимируют S-параметры транзисторных каскадов на широком диапазоне частот [6], предсказывают вольт-амперные (I–V) и емкостные (C–V) характеристики наноразмерных транзисторов [5], либо вычисляют паразитные RLC-параметры сложных межсоединений [7].

Такие модели работают значительно быстрее традиционных схемотехнических симуляторов и облегчают многовариантные оптимизации в проектировании устройств [8][9]. В данной статье представлен обзор современных подходов к моделированию электрических параметров электронных модулей с помощью машинного обучения, анализируются используемые архитектуры нейросетей (от классических многослойных перцептронов до ансамблей и трансформеров) и обсуждаются методологические аспекты их применения. Также приводятся практические примеры из литературы, демонстрирующие достигнутую точность и эффективность таких моделей.

### **Обзор существующих подходов**

**Искусственные нейронные сети.** Наиболее распространенный подход – применение искусственных нейронных сетей для аппроксимации зависимостей между входными воздействиями (напряжения смещения, частота, геометрия конструкции и пр.) и искомыми выходными параметрами (коэффициент усиления, S-параметры, сопротивления и емкости и т.д.). Многослойные перцептроны (MLP) благодаря своей универсальной аппроксимирующей способности широко используются для моделирования приборов. Так, в работе [13] предложена ML-модель FinFET-транзистора: нейросеть, принимающая на вход напряжение затвора и 9 технологических параметров, успешно предсказывает его выходные I–V и C–V характеристики с высокой точностью. В других исследованиях ANN-модели строились для малосигнального эквивалента GaN-HEMT транзисторов [1] [4] [15], для параметров схем на печатных платах и др. Основное достоинство ANN – способность выучивать сложные нелинейные зависимости, фактически

моделируя поведение прибора без явного знания физики процесса [16] [18]. Однако нейросети чувствительны к настройке: процесс обучения может застревать в локальных минимумах ошибки, а результат зависит от выбора архитектуры и гиперпараметров [13]. Для повышения надежности часто прибегают к гибридным решениям – например, совмещают ANN с генетическими алгоритмами для оптимизации начальных весов или структуры сети [4][15]. Примером служит гибрид GA-ANN, который оказался наиболее точным среди многих моделей для малосигнального моделирования GaN-транзисторов [4]. Также применяется техника разбиения задачи: в работе [13] двухэтапная модель на основе ANN сначала предсказывала ряд опорных точек кривых  $I-V/C-V$ , а затем достраивала непрерывные характеристики – такой подход улучшает согласование модели с физическими особенностями прибора.

**Методы опорных векторов.** Наряду с нейросетями для задачи регрессии широко применяются методы на основе опорных векторов, в частности метод опорных векторов для регрессии (SVR). SVR ищет решение через построение оптимальной регрессионной гиперплоскости в пространстве признаков и обладает способностью находить глобальный оптимум задачи оптимизации, что выгодно отличает его от обучения ANN, подверженного влиянию начальной инициализации [1]. В работах по ВЧ-моделированию SVR зарекомендовал себя как надежный инструмент: например, в задаче прогнозирования параметров схем упаковки микросхем модель на базе наименьших квадратов SVR с оптимизацией параметров генетическим алгоритмом превзошла по точности нейросеть и ансамблевые алгоритмы, снизив среднюю ошибку примерно на 14–15% [16]. SVR также применялся для малосигнального моделирования транзисторов наряду с ANN – хотя обучение SVR зачастую уступает по точности хорошо настроенной нейросети, он менее чувствителен к локальным экстремумам и обеспечивает единственность решения [1]. В работе [14], где сравнивались ANN, SVR, гауссовский процесс и гребневая регрессия при оценке параметров диодов Шоттки, именно SVR

показал наибольшее соответствие экспериментальным данным, предсказав электрические параметры (токи утечки, барьерную высоту и др.) ближе всех к реальным значениям. Таким образом, метод опорных векторов остается востребованным, особенно в случаях, когда требуется гарантированная сходимость и устойчивость модели.

**Гауссовские процессы.** GPR (Gaussian Process Regression) – еще один подход, применяемый для моделирования электронных устройств, примечательный тем, что он не только выдает прогнозные значения, но и оценивает доверительный интервал (неопределенность) своего предсказания [5][14]. Это ценно для задач, требующих учета статистической вариативности компонентов и оценки надежности прогнозов (например, для анализа разброса параметров в схемах). В работе [5] предложен вероятностный ML-метод на основе GPR для квантирования неопределенности в электронных схемах – модель строит надстройку над традиционным макро моделированием, предоставляя доверительные границы для прогнозируемых выходных характеристик с учетом неопределенности входных параметров. Хотя GPR-модели обладают высоким качеством аппроксимации, они имеют ограничения по масштабированию: вычисления ковариационной матрицы требуют большого объема памяти и времени, поэтому на больших массивах данных такие модели оказываются наименее эффективными. Действительно, сравнительный анализ в [5] показывает, что по вычислительной эффективности GPR значительно уступает более простым алгоритмам (например, методам на основе случайных выборок или деревьев решений). Тем не менее в узких задачах с ограниченным объемом данных GPR дает мощный инструмент для получения не только прогноза, но и доверительной оценки, что находит отклик в задачах схемотехнического анализа и оптимизации с учетом статистических допусков.

**Современные архитектуры (Transformer, CNN и др.).** В последние годы в области обработки сигналов и языков появилось множество новых

архитектур глубокого обучения – сверточные нейронные сети (CNN), рекуррентные сети (RNN/LSTM) и трансформеры – которые начинают находить применение и в радиотехнических задачах. Сверточные сети особенно эффективны для анализа изображений и двумерных распределений; они с успехом применялись для обработки радиочастотных сигналов в форме спектрограмм или “изображений” распределения полей. Хотя непосредственно для моделирования S-параметров и ВАХ CNN используются реже, их потенциал демонстрируется на задачах дефектоскопии: например, в исследовании по поиску дефектов на рентгеновских снимках плат модель на основе CNN достигла 85–95% точности выявления дефектов печатных проводников [17][18]. Transformers – архитектуры, изначально разработанные для обработки последовательностей (NLP), – начали проникать в радиоэлектронику в задачах классификации сигналов и многозадачного обучения. Так, в работе [12] предложен подход к распознаванию и параметрической характеристике радиолокационных сигналов на основе многоцелевого обучения: единая модель (IQ Signal Transformer) одновременно классифицирует тип модуляции и оценивает численные параметры радиосигнала. Использование трансформерной архитектуры позволило эффективно учесть временную структуру IQ-данных и достигнуть высокой точности определения параметров импульсов.

**Ансамблевые методы и деревья решений.** Еще один класс подходов – методы ансамблевого обучения, объединяющие предсказания нескольких базовых моделей (деревьев решений, нейронных сетей и др.). Их популярность в задачах моделирования растет благодаря способности улучшать обобщающую способность за счет усреднения ошибок различных алгоритмов. В свежих исследованиях по малосигнальному моделированию GaN НЕМТ отмечено, что ансамбли решающих деревьев (включая методы бэггинга и бустинга, такие как Random Forest, XGBoost и др.) демонстрируют превосходную точность, сопоставимую с лучшими нейросетевыми моделями [4]. Например, в работе [15] шесть регрессоров (DT – решающее дерево, EL –

ансамбль, SVR, KAR – ядровая регрессия, GPR и NN) обучались на нескольких наборах GaN-транзисторов. Лучшие результаты по ошибке предсказания S-параметров показала ансамблевая модель (обозначенная как EL) – средняя относительная ошибка порядка 2,8–3,8%, тогда как у одиночных нейросетей она была несколько выше (до ~7%), а у SVR и других – доходила до ~9–10%. Это указывает, что ансамбли (особенно градиентный бустинг и случайный лес) эффективно улавливают нелинейности в данных и менее склонны к переобучению. Достоинство деревьев решений и ансамблей – малая потребность в подборе гиперпараметров по сравнению с глубокой нейросетью: они автоматически выполняют отсев незначимых признаков и зачастую даже с минимальной настройкой дают приемлемую точность.




Рисунок 2. – Сравнение точности моделей машинного обучения при предсказании параметров электронных устройств

### Методологические аспекты применения нейросетей

Подготовка данных и генерация выборки. Ключевым фактором успеха моделей ML является наличие качественных данных, покрывающих рабочий диапазон параметров устройства. В электронике сбор больших массивов измерений затруднён, поэтому часто прибегают к генерации обучающих

данных путем численного моделирования (TCAD, полноволновые EM-симуляторы и т.п.). Многие работы строят датасеты на основе виртуальных экспериментов: к примеру, для обучения модели GaN транзистора использовались результаты параметрического EM-симулирования его S-параметров на разных частотах, при различных напряжениях смещения и геометрических размерах [4][15]. Для создания модели FinFET в [13] авторы сгенерировали выборку с помощью TCAD, варьируя 9 технологических параметров – это позволило охватить пространство изменений, труднодоступное в реальных измерениях. Аналогично, в работе [2] ANN-модель “обучалась” на данных TCAD по семействам новых нано-транзисторов (nanosheet FET и negative-capacitance FET), и достигнутая точность (менее 1% ошибок) относительно результатов TCAD подтверждает корректность такого подхода. Тем не менее, используя синтетические данные, важно внимательно относиться к реализму симуляций – модель обучится только тем закономерностям, которые присутствуют в данных, поэтому необходимо закладывать в симулятор достоверные физические эффекты (например, саморазогрев, паразитные параметры среды и т.п.).

### **Обобщающая способность и предотвращение переобучения**

Важная задача – добиться, чтобы модель правильно работала на новых данных, а не просто запомнила обучающую выборку. Для этого используют ряд методик. Во-первых, необходим раздел данных на обучающую и тестовую (а часто и валидную) выборки, с перекрестной проверкой результатов. Такой подход позволяет количественно оценить степень обобщения модели и избежать избыточной подгонки. Во-вторых, применяют регуляризацию и оптимизацию гиперпараметров. В ряде работ отмечается эффективность случайного поиска гиперпараметров в сочетании со скользящим контролем: например, в исследовании [15] гиперпараметры различных моделей (включая глубину деревьев, параметры ядра SVR и т.д.) подбирались методом Random Search с 5-кратной кросс-проверкой, что устранило случайные дисперсии

качества. В более продвинутых подходах прибегают к автонастройке архитектуры нейросети. Так, авторы работы [2] разработали методологию FARM (Fully Adaptive Regression Model), в которой структура ANN и функции активации автоматически подбираются с помощью алгоритма Tree Parzen Estimator. Такая автоML-схема позволила устранить проблему субъективного выбора архитектуры, избежав недообучения либо переобучения модели: итоговый оптимизированный глубокий перцептрон оказался точнее других методов и устойчиво воспроизвел характеристики нескольких типов транзисторов.

### **Интеграция знаний о физике и интерпретируемость**

Поскольку нейросетевые модели являются “черным ящиком”, встает вопрос доверия к их предсказаниям и обеспечения физической согласованности результатов. Одно из направлений – physics-informed ML, когда в целевую функцию обучения или структуру сети явно заложены известные физические соотношения. Например, в работе [6] реализована физически обоснованная нейросеть для оценки параметров силового DC–DC преобразователя: динамическая модель преобразователя (система уравнений состояний) объединена с обучаемой нейросетью, которая оценивает скрытые параметры по доступным сигналам. Этот гибрид способен соблюсти законы схемотехники (баланс энергии, уравнения Кирхгофа) и тем самым преодолеть ограничение “черного ящика”. Авторы отмечают, что такой PIML-подход преодолевает проблемы чисто данных методов – требование больших наборов данных, плохую экстраполяцию за пределы обучающей выборки и отсутствие гарантий физической правдоподобности результатов. В случае анализа временных сигналов, как указано в работе [17], использование глобального усреднения по каналам в CNN-модели позволило построить карту активации (CAM), подсвечивающую участок временного сигнала, наиболее важный для классификации – это дало возможность связать решение сети с физически значимым фрагментом осциллограммы (начальная переходная область в

сигнале оказалась критичной для диагностики дефекта). Таким образом, хотя нейросеть сама по себе не раскрывает внутренней “физики” процесса, инструменты интерпретации и интеграция физических знаний помогают повысить доверие к моделям и сделать их применение более осмысленным для инженера.

### **Совместимость с инструментами проектирования и производительность**

Для практического внедрения ML-моделей в инженерный цикл важно, чтобы они легко встраивались в существующие САД-инструменты (такие как SPICE, ADS, COMSOL и др.). В ряде работ продемонстрировано, что обученные модели можно перенести в формат, пригодный для схемных симуляторов. Например, в исследовании [15] все разработанные автором модели (ANN, SVR, деревья, ансамбли) были экспортированы в среду Keysight ADS в виде поведенческих блоков, что позволило напрямую использовать их при схемотехническом моделировании ВЧ-усилителей. В другом случае разработчики ANN-модели компактного транзистора создали на ее основе Verilog-A модуль, полностью совместимый с SPICE-моделированием [3]. При этом отмечено, что такая ML-модель обеспечивает корректный расчет как в режиме постоянного тока, так и в АС-анализе и транзитном анализе, с ошибкой всего несколько процентов относительно штатной модели SPICE. Важна и вычислительная эффективность: нейросетевые модели, как правило, работают очень быстро на этапе применения (инференса). После обучения на GPU или кластере, развернутая модель может моментально выдавать результаты на обычном ПК. Отмечены случаи, когда прогноз S-параметров и других характеристик выполняется за миллисекунды или считанные секунды, тогда как аналогичный расчет методом full-wave EM или схемотехнической итерации занял бы минуты и часы [5]. Таким образом правильный выбор и настройка модели обеспечат баланс между точностью и эффективностью, необходимый для практического применения нейросетевых методов в электронике.

## Заключение

Нейросетевые методы зарекомендовали себя как мощный инструмент для моделирования электрических характеристик электронных модулей. Обобщая опыт последних лет, можно констатировать, что правильно обученные модели на основе ANN, SVR, GPR и ансамблей способны с высокой точностью предсказывать S-параметры, передаточные характеристики, паразитные компоненты и другие ключевые параметры, важные для инженеров-разработчиков. В ряде случаев (например, для ВЧ транзисторов GaN, современных FinFET и др.) такие модели достигли точности, сопоставимой с трудоемкими физическими симуляциями, при существенно меньших затратах времени. Применение машинного обучения (ML) уже сейчас позволяет автоматизировать и ускорить этапы проектирования: вместо ручного подбора параметров модель может за миллисекунды оценить характеристики при тысячах вариантов условий, что практически нереализуемо средствами традиционного моделирования. В то же время, накопленный опыт выявил и границы применимости подобных методов. Для надежной работы модели требуется репрезентативный набор данных; без достаточной и разнообразной обучающей выборки нейросеть может потерять обобщающую способность и дать неверный прогноз при экстраполяции. Поэтому важным направлением остается синтез данных и привлечение результатов физического моделирования для обогащения обучающих выборок. Таким образом, нейросетевые методы заняли прочное место в арсенале средств моделирования электронных модулей. Они дополняют и расширяют возможности традиционных подходов, позволяя инженерам быстрее и точнее оценивать характеристики устройств. Дальнейшее развитие этого направления – в интеграции знаний предметной области, повышении устойчивости и интерпретируемости моделей – будет способствовать еще более широкому внедрению искусственного интеллекта в электронном приборостроении, автоматизации проектирования и цифровой трансформации отрасли.

## Список литературы

1. Ahmed S., Elsayed M., Abdelaty A., et al. A probabilistic machine learning approach for the uncertainty quantification of electronic circuits based on Gaussian process regression // *Microelectronics Reliability*. – 2022. – Vol. 132. – P. 114367.
2. Bahgat M.M., Ragab M., Zekry A., Allam M. Optimized machine learning-augmented hybrid empirical models for AlGaN/GaN HEMTs: A comprehensive analysis // *IEEE Access*. – 2022. – Vol. 10. – P. 73139–73153.
3. Nguyen V., Choi W.Y. Fast and expandable ANN-based compact model and parameter extraction for emerging transistors // *IEEE Transactions on Electron Devices*. – 2022. – Vol. 69, No. 3. – P. 1444–1450.
4. Ko G., Lee J., Jang S., et al. Deep-learning-based precise characterization of microwave transistors using fully-automated regression surrogates // *IEEE Transactions on Microwave Theory and Techniques*. – 2021. – Vol. 69, No. 1. – P. 287–299.
5. Liu X., Lu J., Yang Y., et al. A machine learning approach for predicting electrical features of Schottky structures with graphene and ZnTiO<sub>3</sub> nanostructures doped in PVP interfacial layer // *IEEE Transactions on Electron Devices*. – 2022. – Vol. 69, No. 11. – P. 6530–6537.
6. Bakar A.A., Jusoh J., Ahmad N.A., et al. Parameter estimation of power electronic converters with physics-informed machine learning // *Energies*. – 2022. – Vol. 15, No. 21. – P. 7987.
7. Zhang H., Wang S., Xu J., et al. RLC circuit forecast in analog IC packaging and testing by machine learning techniques // *IEEE Transactions on Components, Packaging and Manufacturing Technology*. – 2021. – Vol. 11, No. 2. – P. 341–351.
8. Zhang C., Liang X., Zhang Y., et al. Large scale radio frequency wideband signal detection and recognition // *IEEE Access*. – 2020. – Vol. 8. – P. 203089–203103.

9. Hossain A., Islam M., Liu P., et al. Front-end adaptive electronic modeling with neural networks for radioastronomy // *IEEE Access*. – 2022. – Vol. 10. – P. 90177–90187.
10. Mao Y., Liu S., Chen R., et al. Machine learning based device modeling and performance optimization for FinFETs // *IEEE Transactions on Electron Devices*. – 2021. – Vol. 68, No. 3. – P. 1251–1257.
11. Farooq M., Jin Y., Shafique M. Multilayer perceptron–random forest based hybrid machine learning–neural network model for GaN high electron mobility transistor’s parameter estimations // *Microelectronics Reliability*. – 2022. – Vol. 139. – P. 114750.
12. Rehman M.U., Ahmad I., Zhang S., et al. On temperature-dependent small-signal modelling of GaN HEMTs using artificial neural networks and support vector regression // *Int. J. Circuit Theory Appl.* – 2022. – Vol. 50, No. 10. – P. 3703–3721.
13. Mao Y., Chen R., Liu S., et al. Machine learning approach for FinFET compact modeling with process variations // *IEEE Trans. Electron Devices*. – 2020. – Vol. 67, No. 5. – P. 1953–1959.
14. Rehman M.U., Ahmad I., Zhang S., et al. Comprehensive investigation and comparative analysis of machine learning-based small-signal modelling techniques for GaN HEMTs // *Microelectronics Reliability*. – 2022. – Vol. 138. – P. 114520.
15. Yadav R., Purohit G., Kalla A., et al. An ensemble learning-based predictive parameterization approach for permanent magnet synchronous machines // *IEEE Access*. – 2021. – Vol. 9. – P. 71914–71925.
16. Rehman M.U., Zhang S., Ahmad I., et al. Deep ensemble learning for small-signal parameter prediction of GaN HEMTs // *IEEE Trans. Microwave Theory Techn.* – 2023. – Vol. 71, No. 2. – P. 1142–1152.

17. Zhao Y., Zhang Y., Duan Y., et al. Parametric circuit fault diagnosis through oscillation-based testing in analogue circuits: Statistical and deep learning approaches // *Microelectronics Reliability*. – 2021. – Vol. 119. – P. 114030.
18. Chen H., Wang J., Wang J., et al. Physics-Informed Machine Learning for Power Grid Frequency Modeling // *IEEE Access*. – 2023. – Vol. 11. – P. 10666–10677.

### **References**

1. Ahmed S., Elsayed M., Abdelaty A., et al. A probabilistic machine learning approach for the uncertainty quantification of electronic circuits based on Gaussian process regression // *Microelectronics Reliability*. – 2022. – Vol. 132. – P. 114367.
2. Bahgat M.M., Ragab M., Zekry A., Allam M. Optimized machine learning-augmented hybrid empirical models for AlGaN/GaN HEMTs: A comprehensive analysis // *IEEE Access*. – 2022. – Vol. 10. – P. 73139–73153.
3. Nguyen V., Choi W.Y. Fast and expandable ANN-based compact model and parameter extraction for emerging transistors // *IEEE Transactions on Electron Devices*. – 2022. – Vol. 69, No. 3. – P. 1444–1450.
4. Ko G., Lee J., Jang S., et al. Deep-learning-based precise characterization of microwave transistors using fully-automated regression surrogates // *IEEE Transactions on Microwave Theory and Techniques*. – 2021. – Vol. 69, No. 1. – P. 287–299.
5. Liu X., Lu J., Yang Y., et al. A machine learning approach for predicting electrical features of Schottky structures with graphene and ZnTiO<sub>3</sub> nanostructures doped in PVP interfacial layer // *IEEE Transactions on Electron Devices*. – 2022. – Vol. 69, No. 11. – P. 6530–6537.
6. Bakar A.A., Jusoh J., Ahmad N.A., et al. Parameter estimation of power electronic converters with physics-informed machine learning // *Energies*. – 2022. – Vol. 15, No. 21. – P. 7987.

7. Zhang H., Wang S., Xu J., et al. RLC circuit forecast in analog IC packaging and testing by machine learning techniques // *IEEE Transactions on Components, Packaging and Manufacturing Technology*. – 2021. – Vol. 11, No. 2. – P. 341–351.
8. Zhang C., Liang X., Zhang Y., et al. Large scale radio frequency wideband signal detection and recognition // *IEEE Access*. – 2020. – Vol. 8. – P. 203089–203103.
9. Hossain A., Islam M., Liu P., et al. Front-end adaptive electronic modeling with neural networks for radioastronomy // *IEEE Access*. – 2022. – Vol. 10. – P. 90177–90187.
10. Mao Y., Liu S., Chen R., et al. Machine learning based device modeling and performance optimization for FinFETs // *IEEE Transactions on Electron Devices*. – 2021. – Vol. 68, No. 3. – P. 1251–1257.
11. Farooq M., Jin Y., Shafique M. Multilayer perceptron–random forest based hybrid machine learning–neural network model for GaN high electron mobility transistor’s parameter estimations // *Microelectronics Reliability*. – 2022. – Vol. 139. – P. 114750.
12. Rehman M.U., Ahmad I., Zhang S., et al. On temperature-dependent small-signal modelling of GaN HEMTs using artificial neural networks and support vector regression // *Int. J. Circuit Theory Appl.* – 2022. – Vol. 50, No. 10. – P. 3703–3721.
13. Mao Y., Chen R., Liu S., et al. Machine learning approach for FinFET compact modeling with process variations // *IEEE Trans. Electron Devices*. – 2020. – Vol. 67, No. 5. – P. 1953–1959.
14. Rehman M.U., Ahmad I., Zhang S., et al. Comprehensive investigation and comparative analysis of machine learning-based small-signal modelling techniques for GaN HEMTs // *Microelectronics Reliability*. – 2022. – Vol. 138. – P. 114520.
15. Yadav R., Purohit G., Kalla A., et al. An ensemble learning-based predictive parameterization approach for permanent magnet synchronous machines // *IEEE Access*. – 2021. – Vol. 9. – P. 71914–71925.

16. Rehman M.U., Zhang S., Ahmad I., et al. Deep ensemble learning for small-signal parameter prediction of GaN HEMTs // IEEE Trans. Microwave Theory Techn. – 2023. – Vol. 71, No. 2. – P. 1142–1152.
17. Zhao Y., Zhang Y., Duan Y., et al. Parametric circuit fault diagnosis through oscillation-based testing in analogue circuits: Statistical and deep learning approaches // Microelectronics Reliability. – 2021. – Vol. 119. – P. 114030.
18. Chen H., Wang J., Wang J., et al. Physics-Informed Machine Learning for Power Grid Frequency Modeling // IEEE Access. – 2023. – Vol. 11. – P. 10666–10677.