

Интеллектуальный программный комплекс прогнозирования теплового сопротивления полупроводников

А.Д. Кудряшов, А. И. Сурайкин

*Национальный исследовательский Мордовский государственный университет им.
Н. П. Огарева, Саранск*

Аннотация: В статье представлена архитектура и реализация интеллектуального программного комплекса (ИПК) для прогноза теплового сопротивления полупроводниковых приборов, в частности, полевых транзисторов с изолированным затвором, на этапе проектирования. Разработанная система сочетает физико-математическое моделирование многослойных теплопроводящих структур с методами машинного обучения, что позволяет осуществлять точный прогноз тепловых параметров на основе инженерных характеристик и конструкции корпуса. В ИПК реализован механизм автоматического дополнения неполных данных с использованием базы знаний о типовых параметрах отечественных и зарубежных приборов. Обучение моделей проведено на синтетически расширенной выборке, сформированной с учётом теплопроводностей конструктивных материалов и геометрии слоёв. Применённые алгоритмы: ансамбли случайных лесов и градиентного бустинга, а также нейросетевые модели. Проведён анализ важности признаков, выявлены ключевые параметры, определяющие тепловое сопротивление, и продемонстрирована возможность применения ИПК для ранней оценки тепловых режимов в автоматизированной системе проектирования и создания технических чертежей CAD и системах автоматического анализа проекта.

Ключевые слова: тепловое сопротивление, машинное обучение, интеллектуальный программный комплекс, многослойная структура, предсказательная модель, CAD, теплопроводность.

Металлооксидно-полупроводниковые полевые транзисторы (МОП-транзисторы) являются одними из основных компонентов современной электроники. МОП-транзисторы играют важнейшую роль в промышленности: они применяются в высокоскоростных импульсных источниках питания для компьютеров, драйверах двигателей для электромобилей, а также в сложных системах управления промышленного оборудования. Эффективность и производительность МОП-транзисторов напрямую влияют на надежность и функциональность устройств силовой электроники [1].

В современных условиях проектирование силовой электроники в соответствии с требованиями по эффективности и надежности невозможно без точного учета теплового режима работы дискретных МОП-транзисторов. Стремление к миниатюризации устройств и низкопрофильные корпуса микросхем создают серьезные проблемы для отвода тепла, особенно при отсутствии полноценного радиатора или активного охлаждения [2]. Это обуславливает необходимость разработки оперативных и точных методов расчета теплового сопротивления $R_{\theta JA}$ всей системы с учетом конструкции корпуса и условий теплоотвода.

Традиционный подход — использование паспортных данных или МКЭ-моделей (метод конечных элементов) — часто ограничен неполнотой документации или высокой вычислительной затратностью. Сравнительный анализ показал, что традиционные подходы к оценке тепловых режимов, применяемые в расчётах импульсных каскадов [3], не обеспечивают должной гибкости при работе с неполными данными. Поэтому, все больше находят применение методы машинного обучения для оценки тепловых характеристик корпусов интегральных схем и силовых транзисторов.

Цель исследования: разработка интеллектуального программного комплекса (ИПК), предназначенного для прогнозирования возможного теплового сопротивления $R_{\theta JA}$ для дискретных n- и p-канальных МОП-транзисторов от российских производителей с точностью $\leq \pm 10\%$, используя неполные исходные данные (геометрия, корпус, мощность, температура, эффективность охлаждения).

В силовых полупроводниковых приборах (таких как МОП-транзисторы) тепловое сопротивление характеризует способность устройства отводить тепло от активной области (обычно — полупроводникового кристалла) к окружающей среде. Поскольку значительное количество электрической энергии преобразуется в тепловую в процессе переключения и

проводимости прибора, эффективное управление температурным режимом является критически важным условием обеспечения его надёжности, долговечности и отказоустойчивости.

Потери мощности в МОП-транзисторах обусловлены тремя основными механизмами, приведенными ниже.

Потери мощности при изменении проводимости канала возникают при протекании тока через открытый канал транзистора и определяются соотношением: $P_c = I_{DRMS}^2 \times R_{DSon}$, где I_{DRMS} — среднеквадратичный ток стока. Важной особенностью является температурная зависимость сопротивления открытого канала R_{DSon} , создающая положительную обратную связь (рост температуры увеличивает сопротивление, что приводит к дополнительному тепловыделению).

Потери при переключении происходят в переходные моменты включения и выключения, когда напряжение сток-исток U_{DS} и ток в канале I_D одновременно не равны нулю. Эти потери пропорциональны частоте переключения и времени переходных процессов. В современной силовой электронике тенденция к увеличению частот коммутации для уменьшения габаритов устройств значительно повышает долю коммутационных потерь.

Потери управления затвором связаны с зарядкой и разрядкой емкости затвора при каждом переключении.

Суммарные потери мощности этих механизмов приводят к выделению тепла в кристалле транзистора. Для анализа теплового режима работы вводится понятие теплового сопротивления, которое связывает выделяемую мощность с температурным перепадом в конструкции.

Тепловое сопротивление определяется аналогично электрическому и количественно выражается как отношение температурного перепада к выделяемой тепловой мощности:

$$R_{\theta} = \frac{\Delta T}{P}$$

где: R_{θ} — тепловое сопротивление, [°C/Вт], $\Delta T = T_j - T_{ref}$ — разность температур между кристаллом и опорной точкой (например, корпусом или радиатором), P — мощность тепловыделения, [Вт].

Для практических расчётов используют различные виды теплового сопротивления:

$R_{\theta JC}$ — от перехода (кристалл) к корпусу;

$R_{\theta CS}$ — от корпуса к радиатору;

$R_{\theta SA}$ — от радиатора к окружающей среде;

$R_{\theta JA} = R_{\theta JC} + R_{\theta CS} + R_{\theta SA}$ — полное тепловое сопротивление от перехода к окружающей среде.

Значение теплового сопротивления формируется под воздействием комплекса параметров, как конструктивных, так и технологических. К числу основных факторов, оказывающих влияние, относятся:

Геометрия кристалла: площадь и толщина кристалла определяют длину и сечение теплового пути. С увеличением площади уменьшается тепловое сопротивление, согласно закону Фурье.

Материалы конструкции: теплопроводность (λ) подложки, соединительных слоёв, термоинтерфейсных материалов (ТИМ), корпуса. Например, медь и алюминий обладают высокой теплопроводностью, а пластмассы и керамика — существенно меньшей.

Конструкция и способ отвода тепла: наличие и эффективность радиатора, тепловых интерфейсных материалов, активного охлаждения, термотрубок и др.

Тип корпуса: корпуса с металлическими элементами отвода (ТО-220, DPAK) демонстрируют более низкое тепловое сопротивление, чем пластиковые корпуса без контакта с радиатором (SOIC, DIP).

Плотность тепловых потоков: при высокой мощности и малых габаритах устройства возникает локальный перегрев, что требует точного моделирования температурных градиентов.

Модели теплопередачи в полупроводниковых структурах

Для анализа тепловых характеристик применяются различные модели, зависящие от уровня абстракции и точности:

Наиболее простая модель, используемая для первичных инженерных оценок – это одномерная теплопроводность (1D модель). Согласно закону Фурье:

$$q = -\lambda \cdot \frac{dT}{dx} \Rightarrow R_{\theta} = \frac{L}{\lambda \cdot A}$$

где: L — длина теплового пути, λ — коэффициент теплопроводности, A — поперечная площадь теплопередачи.

Применяется в случае теплопередачи вдоль одной координатной оси и однородной структуры.

Метод конечных разностей подходит для двумерного или трёхмерного анализа температурных полей. Рабочее тело разбивается на ячейки, для которых формулируются дискретные уравнения теплового баланса. Метод широко используется в инженерных САПР-платформах и в ручных расчетах при наличии регулярной сетки.

Метод конечных элементов – это наиболее универсальный и точный способ численного моделирования. Позволяет учитывать сложную геометрию, анизотропию материалов, нелинейные зависимости теплопроводности от температуры. Позволяет получать пространственно распределённые температурные поля и оценивать перегрев в критических узлах конструкции.

Таким образом, тепловое сопротивление представляет собой интегральную характеристику способности устройства отводить тепло,

которая зависит от конструктивных, технологических и эксплуатационных параметров. Выбор модели для анализа должен соответствовать стадии проектирования: от приближённых инженерных формул до полной многомерной FEM-модели. (Finite Element Method) — это численный метод, который разделяет сложную структуру на более простые части (конечные элементы).

Разработка интеллектуального программного комплекса требует формализации этих зависимостей и интеграции алгоритмов оценки теплового сопротивления на основе известных геометрических и физических параметров полупроводникового прибора.

Применение машинного обучения в тепловом анализе электроники

Последние годы ознаменовались стремительным развитием применения методов машинного обучения в области теплового анализа электронных компонентов, что обусловлено растущими требованиями к миниатюризации при увеличении производительности [4].

В области теплового анализа полупроводников наибольшее распространение получили нейронные сети, ансамблевые методы и физически обоснованные подходы. В работе [5] разработан подход символьной регрессии на основе генетического программирования для поиска аналитических моделей теплопроводности, которые превосходят классическую формулу Слэка [6].

Для прогнозирования деградации сопротивления МОП-транзисторов применяются нейронные сети прямого распространения, которые изучают тренды деградации одного устройства и предсказывают остаточный срок службы для остальных устройств с аналогичными трендами деградации [7]. Исследования показывают, что точность предсказания остаточного срока службы увеличивается до определенного количества нейронов, а затем снова уменьшается.

Для силовых полупроводниковых модулей применяются методы машинного обучения в сочетании с теоретико-игровым подходом. База данных из 2592 точек (стационарный режим) и 1200 точек (переходный режим) была создана для обучения алгоритмов случайного леса, опорных векторов и нейронных сетей при анализе коммерческого SiC полумоста (1,2 кВ/444 А). При этом была получена точность прогнозирования со значениями $R^2 > 99,5\%$. [8].

Современные интегрированные системы используют сверточные нейронные сети для управления термоэлектрическими охладителями в реальном времени. При этом время вычислений составляет около 42 мс, что представляет ускорение более чем на три порядка по сравнению с традиционными методами конечных элементов [9].

Физически обоснованные нейронные сети — это метод, который сочетает традиционные уравнения физики (например, уравнения теплопроводности) с обучением нейронных сетей, что позволяет решать сложные дифференциальные уравнения даже при неполных или зашумленных данных [10].

Машинное обучение является эффективным методом для решения высокоразмерных задач предсказания теплового сопротивления. Интеграция таких методов непосредственно в процесс проектирования позволит значительно ускорить разработку новых конструктивных решений.

Архитектура интеллектуального программного комплекса для прогноза теплового сопротивления

Разрабатываемый интеллектуальный программный комплекс (ИПК) предназначен для оперативного и высокоточного прогноза теплового сопротивления R_θ полупроводниковых устройств на ранних этапах проектирования, используя исходные инженерные параметры и данные

САПР. ИПК построен по модульному принципу, архитектура комплекса представлена на рис.1




Рис. 1. Архитектура ИПК

Рассмотрим основные функциональные модули:

1. *Модуль ввода и валидации данных.* На этом этапе исходные параметры транзистора (электрические пределы, тип корпуса и др.) вводятся пользователем и проверяются на полноту и корректность. Реализована автоматическая проверка обязательных полей и оценка процентной заполненности данных; при неполных входных сведениях система формирует предупреждение, но допускает прогноз при заполнении $\geq 30\%$ параметров.

2. *База знаний и дополнение данных.* ИПК включает встроенную базу знаний об отечественных полевых транзисторах с изолированным

затвором, содержащую информацию о производителях и типовых конструктивных особенностях корпусов. На основе этой базы модуль автоматического дополнения данных заполняет недостающие сведения: например, для известных серий транзисторов подставляются стандартные значения предельных напряжений U_{GS} (например, для N-канальных транзисторов 20 В), а для корпусов — типичные толщины и теплопроводности конструктивных слоёв. Это обеспечивает устойчивость работы комплекса при неполных исходных данных за счёт заполнения пропусков из БД.

3. Модуль предобработки и формирования признаков

На данном этапе загруженные и дополненные данные подвергаются очистке и нормализации. Реализовано масштабирование числовых признаков и кодирование категориальных параметров. Кроме того, автоматически вычисляется ряд производных признаков, отражающих тепловые характеристики прибора: плотность мощности рассеяния, тепловая эффективность, отношение P_d/R_θ , плотность тока, оценочная площадь кристалла, тепловая постоянная времени и показатель эффективности теплоотвода. Эти характеристики добавляются в набор признаков модели для улучшения точности прогноза теплового сопротивления. Если в данных остаются пропуски, они восполняются методом k-ближайших соседей, что позволяет корректно обработать даже существенно неполные записи.

4. III-модуль

Предсказание R_θ осуществляется с помощью ансамбля из трёх алгоритмов машинного обучения, дополняющих друг друга:

1. Случайный лес, обеспечивающий устойчивость прогнозов.
2. Градиентный бустинг, демонстрирующий высокую точность за счет последовательной минимизации ошибки.

3. Искусственная многослойная нейронная сеть прямого распространения (MLP ANN - Multi-layer Perceptron artificial neural network model), которая обучается методом обратного распространения ошибки. Используется два скрытых слоя (с архитектурой 50 и 25 нейронов соответственно), что позволяет эффективно выявлять сложные зависимости между признаками и целевой переменной.

Каждый алгоритм обучается по подготовленным признакам на основе имеющейся выборки транзисторов. Обучение этих моделей проводится на массиве данных, сформированном путем численного моделирования (многослойная модель, аналогичная FEM-анализу) и дополненном экспериментальными измерениями тепловых характеристик полевых транзисторов с изолированным затвором. Обучение реализовано в среде Python с использованием библиотеки scikit-learn (классы RandomForestRegressor, GradientBoostingRegressor, MLPRegressor); для обработки табличных данных применяются pandas, а для визуализации результатов – matplotlib.

Разработанный программный код отличается модульностью и легко расширяем: при необходимости добавления новых типов корпусов или конструктивных параметров достаточно дополнить соответствующие словари базы знаний и переобучить модели.

5. Модуль вывода

Результаты обработки передаются в модуль вывода, который выполняет: прогноз теплового сопротивления R_{θ} , анализ вклада признаков в итоговое значение. Выходными данными комплекса являются прогнозное значение теплового сопротивления данного прибора и сопутствующая аналитическая информация. Для повышения надежности результатов вычисляется среднее ансамбля моделей (усреднение трех предсказаний), которое принимается в качестве итогового прогноза R_{θ} . Одновременно

оценивается разброс между индивидуальными моделями: на этой основе рассчитывается стандартное отклонение и формируется доверительный интервал (по умолчанию 90%) для предсказанного значения. Система выводит итоговый прогноз с указанием доверительного интервала, а также выдает пояснение – вклад каждой модели (отдельно приводятся результаты Random Forest, Gradient Boosting и MLP, что позволяет оценить сходимость предсказаний). Кроме того, после обучения формируется рейтинг важности входных признаков, облегчающий интерпретацию модели (рис. 2).




Рис. 2. Рейтинг важности входных признаков

ИПК реализован на языке Python; расчёты проводились в среде Jupyter Notebook. В программном коде использованы библиотеки: pandas для обработки таблиц параметров транзисторов, scikit-learn для методов машинного обучения, а также matplotlib/seaborn для построения графиков. Обучающая выборка формируется на основе данных производителей и экспертных оценок: разработан генератор, комбинирующий базовые технические характеристики транзисторов различных производителей с

разновидностями корпусов, с расчётом оценочного R_θ по упрощённой тепловой модели. Перед обучением выполняется разделение на обучающую и тестовую подвыборки (80/20%). Для контроля качества модели вычисляются метрики на тестовых данных: средняя абсолютная ошибка, корень средней квадратичной ошибки, коэффициент детерминации (R^2), средняя процентная ошибка, а также доля предсказаний с ошибкой не более $\pm 10\%$ (Accuracy within 10%). Обученные алгоритмы проходят валидацию на отложенной выборке; результаты по основным метрикам для всех трёх моделей приведены в табл. 1.

Таблица 1

Метрики точности моделей прогнозирования (тестовые данные)

Модель	Средняя абсолютная ошибка (К/Вт)	Корень средней квадратичной ошибки (К/Вт)	Коэффициент детерминации, R^2	Доля предсказаний с ошибкой не более $\pm 10\%$, $\Delta \leq 10\%$ (%)	Средняя процентная ошибка (%)
Случайный лес	~0.86	~1.05	0.97	70.0	8.3
Градиентный бустинг	~0.69	~0.95	0.98	80.0	6.4
Искусственная многослойная нейронная сеть прямого распространения	~3.92	~5.26	0.32	20.0	34.6

Как видно из табл. 1, наилучшую точность демонстрирует модель градиентного бустинга: она обеспечивает минимальную ошибку (MAE порядка 0,7 К/Вт) и наибольшую объяснённую дисперсию ($R^2 \approx 0,98$). Около 80% её предсказаний имеют погрешность в пределах $\pm 10\%$ от фактического R_θ , а средняя процентная ошибка не превышает 6–7%. Случайный лес показал несколько меньшую точность ($R^2 \approx 0,97$, доля точных предсказаний ~70%). Наихудший результат у нейросетевой модели MLP – её ошибка

значительно выше (~ 3.9 К/Вт), и лишь 20% прогнозов лежат в допустимом $\pm 10\%$ -интервале. Данный разброс результатов обусловлен ограниченностью обучающей выборки и возможным недостаточным подбором гиперпараметров для нейронной сети; тем не менее, даже при таких настройках ансамблевый подход позволяет сгладить неточность одного из алгоритмов. В целом, учитывая приведённые показатели, в дальнейшей работе за основу берётся модель градиентного бустинга как обеспечивающая наибольшую точность прогноза.

Демонстрация работы на примерах. Для наглядной иллюстрации возможностей ИПК проведено тестирование на двух примерах транзисторов, сведения о которых были заведомо неполны. Первый пример – устройство, условно обозначенное Тест_1 (N-канальный транзистор серии КП901А в корпусе КТ-26), для которого отсутствовали данные о сопротивлении $R_{DS(on)}$, максимальной рассеиваемой мощности P_d и конструктивных слоях корпуса. Полнота исходных данных составила всего $\sim 66\%$, однако благодаря заполнению типовыми значениями (для корпуса КТ-26 автоматически подставлены характерные толщины и теплопроводности слоёв, а отсутствующие электрические параметры заменены усреднёнными) модель успешно сформировала прогноз. Комплекс оценил тепловое сопротивление данного прибора приблизительно в 130 К/Вт, при этом разброс между алгоритмами дал неопределённость порядка ± 30 К/Вт. Итоговый результат представлен в формате: $R_\theta = 130$ К/Вт (доверительный интервал 90%: 100–160 К/Вт), что свидетельствует о работоспособности системы даже при неполном наборе характеристик. Для сравнения также приведены индивидуальные предсказания моделей ансамбля: Случайный лес и градиентный бустинг дали несколько завышенные оценки (~ 150 К/Вт), тогда как нейросеть – заниженную (~ 80 К/Вт); усреднение этих значений

позволило компенсировать их отклонения, предоставив более надежный усреднённый прогноз.

Второй пример – транзистор Тест_2 (N-канальный транзистор, серия 2П903А, корпус ТО-220). Для него изначально неизвестен максимальный ток $I_{D\ max}$ и сопротивление $R_{DS(on)}$. Несмотря на наличие пропуска этих полей, модуль дополнения данных присвоил этому транзистору типичные значения (для $I_{D\ max}$ взято ~ 5 А исходя из аналогов, $R_{DS(on)} \sim 0,1$ Ом по средней тенденции для данной серии). В результате система выдала прогноз $R_{\theta} \approx 70$ К/Вт. Доверительный интервал (90%) составил приблизительно 60–80 К/Вт, т.е. неопределённость не превысила ± 10 К/Вт – значительно меньше, чем в первом случае, благодаря тому, что корпус ТО-220 сам по себе имеет низкое базовое сопротивление (≈ 65 К/Вт) и модель менее чувствительна к пропущенному току I_D . Таким образом, даже при отсутствии одного из обязательных эксплуатационных параметров комплекс за счёт знаний о корпусе и базовых уравнениях смог выдать достаточно точный результат.

Эти демонстрационные примеры подтверждают, что разработанный ИПК устойчив к пропускам данных и способен предоставлять пользователю не только численное значение прогноза, но и информативную оценку достоверности (интервалы, расхождения моделей), что крайне важно для практического применения в инженерных задачах.

В процессе обучения был проведён анализ вклада входных параметров в точность прогноза (рис. 2). Наиболее значимым признаком оказалась тепловая постоянная времени, что согласуется с физикой процесса: данный показатель характеризует способность устройства накапливать и рассеивать тепло и напрямую связан с тепловым сопротивлением R_{θ} . Существенную роль также играют признаки, отражающие геометрию устройства и эффективность теплоотвода. Таким образом, модель не только даёт точный прогноз, но и помогает выявить ключевые конструктивные параметры,

оптимизация которых позволит снизить тепловое сопротивление проектируемых устройств.

Литература

1. Керенцев А., Ланин В. Конструктивно-технологические особенности MOSFET-транзисторов // Силовая электроника. 2008. № 1. С. 44–48.
2. Боднарь Д. Основные тенденции применения микроэлектронных корпусов в мире и в России // Russian Electronics. 2023. URL: russianelectronics.ru/korpusa/ (дата обращения: 18.07.2025).
3. Колпаков А. Расчёт тепловых режимов MOSFET-транзисторов с помощью программы HEXRISE // Компоненты и технологии. 2002. № 5. С. 72–76.
4. Luo Y., Li M., Yuan H. Predicting lattice thermal conductivity via machine learning: a mini review // npj Comput Mater. 2023. Volume 9. No. 4. DOI: 10.1038/s41524-023-00964-2
5. Loftis C., Yuan K., Zhao Y., Hu M., Hu J. Lattice thermal conductivity prediction using symbolic regression and machine learning // arXiv:2008.03670 [cond-mat.mtrl-sci]. 2020. URL: <https://arxiv.org/abs/2008.03670>
6. Slack G.A. CRC Handbook of Thermoelectrics / Ed. D. M. Rowe // Chemical Rubber. 1995. P. 407.
7. Pugalenth K., Park H., Raghavan N. Prognosis of power MOSFET resistance degradation trend using artificial neural network approach // Microelectronics Reliability. 2019. Volume. 100–101. P. 113467. DOI: 10.1016/j.microrel.2019.113467.
8. Acharya P., Lokanathan M., Ouroua A., Hebner R., Strank Sh., Bahadur V. Machine Learning-Based Predictions of Benefits of High Thermal Conductivity Encapsulation Materials for Power Electronics Packaging // Journal of Electronic Packaging. 2021. P. 143. 10.1115/1.4052814.

9. Luo J., Lee J. Machine learning-assisted thermoelectric cooling for on-demand multi-hotspot thermal management // Journal of Applied Physics. 2024. Volume 135, Issue 24. DOI: 10.1063/5.0206287.

10. Cai Sh., Wang Zh., Wang S., Perdikaris P., Karniadakis G. Physics-Informed Neural Networks (PINNs) for Heat Transfer Problems // Journal of Heat Transfer. 2021. P. 143. 10.1115/1.4050542.

References

1. Kerencev A., Lanin V. Silovaya elektronika. 2008. № 1. pp. 44–48.
2. Bodnar' D. Russian Electronics. 2023. URL: russianelectronics.ru/korpusa/ (data obrashcheniya: 18.07.2025).
3. Kolpakov A. Komponenty i tekhnologii. 2002. № 5. P. 72–76.
4. Luo Y., Li M., Yuan H. npj Comput Mater. 2023. Volume 9. № 4. DOI: 10.1038/s41524-023-00964-2
5. Loftis C., Yuan K., Zhao Y., Hu M., Hu J. arXiv: 2008.03670 [cond-mat.mtrl-sci]. 2020. URL: arxiv.org/abs/2008.03670
6. Slack G.A. Chemical Rubber. 1995. P. 407.
7. Pugalenthil K., Park H., Raghavan N. Microelectronics Reliability. 2019. Volume. 100–101. P. 113467. DOI: 10.1016/j.microrel.2019.113467.
8. Acharya P., Lokanathan M., Ouroua A., Hebner R., Strank Sh., Bahadur V. Journal of Electronic Packaging. 2021. P. 143. 10.1115/1.4052814.
9. Luo J., Lee J. Journal of Applied Physics. 2024. Volume 135, Issue 24. DOI: 10.1063/5.0206287.
10. Cai Sh., Wang Zh., Wang S., Perdikaris P., Karniadakis G. Journal of Heat Transfer. 2021. P. 143. 10.1115/1.4050542.

Дата поступления: 11.08.2025

Дата публикации: 26.11.2025