

УДК 621.372.049.77: 004.032.26

АЛГОРИТМ СОЗДАНИЯ НЕЙРОСЕТЕВОЙ МОДЕЛИ НА ПРИМЕРЕ ПОЛОСКОВОГО МЭМС-ПЕРЕКЛЮЧАТЕЛЯ

Д. Х. Нгуен, аспирант РГРТУ, Рязань, Россия;
orcid.org/0000-0002-2456-5220, e-mail: danghoprzn@mail.ru

Е. П. Васильев, д.т.н., профессор кафедры КТ РГРТУ, Рязань, Россия;
orcid.org/0000-0003-2747-7012, e-mail: evasiliev48@mail.ru

Предложен алгоритм моделирования ёмкостных МЭМС-переключателей шунтирующего типа на основе использования искусственных нейронных сетей. Рассмотрены современные методы анализа полосковых устройств, включая электродинамическое моделирование, эквивалентные схемные модели и модели на основе машинного обучения. **Целью работы** является разработка алгоритма создания нейросетевой модели для прогнозирования S -параметров, обеспечивающего баланс между точностью и временными затратами на вычислительный процесс. Предложенный алгоритм включает этапы синтеза конструкции, формирования обучающей выборки методом латинского гиперкуба ($N = 1000$ – число вычислительных экспериментов), электродинамического моделирования в среде High frequency structure simulator (HFSS) через интерфейс библиотеки Python PyAEDT, нормализации данных и обучения многослойной нейронной сети архитектуры $16 \times 16 \times 16$. Разработанная модель обеспечивает высокую точность аппроксимации ($R^2 = 0,9085$ – коэффициент детерминации, MAPE = 1,15 % – средняя абсолютная процентная ошибка) при сокращении времени расчета более чем в 10^4 раз по сравнению с полноволновым электродинамическим моделированием. Верификация на независимой тестовой выборке подтверждает точность предсказания резонансных частот (средняя погрешность 1,3 – 1,4 %) и развязки (средняя погрешность 2.2 %). Универсальность алгоритма подтверждена дополнительным исследованием на PIN-диодном переключателе, для которого при $N = 975$ достигнута точность $R^2 = 0,9684$, MAPE = 2,98 %. Предложенный подход аппроксимации частотно-зависимых выходных S -параметров применим к широкому классу полосковых переключателей.

Ключевые слова: схемотехническое и электродинамическое моделирование, полосковый МЭМС-переключатель, аппроксимация, S -параметры, искусственная нейронная сеть, нейросетевая модель, PIN-диодный переключатель.

DOI: 10.21667/1995-4565-2026-95-27-40

Введение

Современные радиотехнические устройства и системы предъявляют высокие требования к характеристикам полосковых устройств – переключателей, коммутаторов, фильтров, антенн, усилителей, линий передачи. Полосковые переключатели стали основными функциональными устройствами для создания реконфигурируемых антенн для телекоммуникации, спутниковых систем связи и приемопередающих модулей сложных радиотехнических систем [1].

Проектирование таких устройств требует точного анализа электромагнитных полей с учетом сложной трехмерной геометрии и неоднородных материалов [1-3].

Традиционное моделирование полосковых устройств выполняется методами полноволнового электромагнитного анализа в программных комплексах HFSS, CST Microwave Studio, Microwave office AWR (AWR) и других. При этом время электродинамического анализа одной конфигурации полоскового переключателя, фильтра, делителя/сумматора мощности составляет от нескольких минут до нескольких часов на компьютере средней мощности в зависимости от сложности структуры. Это делает задачи анализа и многовариантной оптимизации крайне трудоемкими [3, 4].

В представленной статье решается *актуальная задача* создания алгоритма нейросетевой модели полоскового переключателя для существенного сокращения временных затрат на вычислительный процесс при высокой точности совпадения результатов нейросетевой аппроксимации и электродинамического моделирования методом конечных элементов (FEM) в среде HFSS.

Методы моделирования полосковых переключателей

Существующие подходы к моделированию полосковых переключателей можно разделить на несколько категорий:

1. Полноволновое электромагнитное моделирование – наиболее точный подход, использующий метод FEM (показал на многочисленных примерах высокую точность совпадения теоретических и экспериментальных результатов [19]) или метод моментов (MoM) для решения уравнений Максвелла в трехмерной постановке. Обеспечивает погрешность $< 1\%$, но требует значительных вычислительных ресурсов.

2. Эквивалентные схемные модели – быстрые аналитические модели, основанные на упрощенном представлении структуры через сосредоточенные RLC-элементы и отрезки линий передачи. Обладают высокой скоростью расчета (секунды и миллисекунды), но имеют погрешность $10 - 20\%$ вследствие пренебрежения высшими типами волн и распределенными электромагнитными эффектами.

3. Модели на основе машинного обучения – современный подход, обеспечивающий баланс между точностью и вычислительной эффективностью [4-7]. Используют результаты полноволнового моделирования для обучения нейросетевых моделей, которые затем применяются для быстрого анализа и оптимизации новых конструктивных конфигураций.

Zhang и Gupta [2] систематизировали применение нейронных сетей для проектирования микроволновых устройств. Rayas-Sanchez [4] показал, что нейросетевые модели обеспечивают точность предсказания в пределах $2 - 5\%$ при сокращении времени анализа от часов до миллисекунд. Cao [5] применили многомодульные нейронные сети для моделирования резонаторных фильтров, достигнув высокой точности при высокой размерности пространства параметров. Feng [6] разработал метод адаптивной оптимизации микрополосковых фильтров на основе нейросетевых моделей.

Таким образом, полноволновое электромагнитное моделирование обеспечивает наивысшую точность, но требует значительных вычислительных ресурсов – от нескольких минут до нескольких часов на одну конфигурацию, что делает его непригодным для сложных конфигураций и многовариантной оптимизации. Эквивалентные схемные модели обладают высокой скоростью расчёта, однако их точность ограничена, особенно в высокочастотном диапазоне (погрешность $10 - 20\%$). Нейросетевые модели, предложенные в работах [4-7], продемонстрировали возможность достижения высокой точности при минимальных вычислительных затратах, однако каждая из них разработана для конкретного типа устройства и не предлагает универсального алгоритма, применимого к различным типам переключателей.

В отличие от указанных работ, предлагаемый в данной статье подход реализует единый автоматизированный алгоритм, включающий все этапы – от генерации обучающей выборки до верификации модели, и демонстрирует его применимость к переключателям различных типов, в частности к МЭМС-переключателю и PIN-диодному переключателю.

Теоретические исследования

Микроэлектромеханические системы (МЭМС) представляют собой перспективное направление развития коммутационных полосковых устройств. МЭМС-переключатели обладают существенными преимуществами по сравнению с традиционными полупроводниковыми аналогами, обеспечивая низкие вносимые потери (менее $0,1$ дБ), высокую развязку (до 60 дБ), линейность и практически нулевое энергопотребление в статическом режиме [1, 8, 9].

Конструкция ёмкостного МЭМС-переключателя шунтирующего типа (рисунок 1) включает следующие основные элементы: подвижную металлическую мембрану (балку) длиной

L , шириной w и толщиной t , расположенную над центральным полосковым проводником шириной W . Между мембраной и центральным проводником размещён тонкий диэлектрический слой толщиной t_d , который предотвращает короткое замыкание при контакте, что ограничивает максимальное значение ёмкости и повышает срок службы.




Рисунок 1 – Конструкция ёмкостного МЭМС-переключателя шунтирующего типа
 Figure 1 – Structure of shunt-type capacitive RF MEMS switch

Принцип действия основан на электростатическом управлении: в выключенном состоянии воздушный зазор g_0 обеспечивает минимальную ёмкость C_0 и низкие вносимые потери; при подаче управляющего напряжения мембрана замыкается на диэлектрический слой, ёмкость C_n резко возрастает ($C_n \gg C_0$) и сигнал отражается, обеспечивая высокую развязку.

Основные геометрические параметры рассматриваемой конструкции представлены в таблице 1.

Таблица 1 – Геометрические параметры ёмкостного МЭМС-переключателя шунтирующего типа

Table 1 – Geometrical parameters of shunt-type capacitive RF MEMS switch

Параметр	Обозначение	Значение (мкм)
Длина мембраны	L	500
Ширина мембраны	w	66
Толщина мембраны	t	1
Ширина центрального проводника	W	115
Толщина диэлектрика	t_d	0.18
Диаметр отверстий	d_r	10
Площадь перекрытия управляющего электрода	$A = W \times w$	115×66
Высота воздушного зазора	g_0	2

Эквивалентная схема ёмкостного МЭМС-переключателя

Для моделирования МЭМС-переключателя построена эквивалентная электрическая схема (рисунок 2), включающая две линии передачи и сосредоточенную RLC-структуру мембраны.




Рисунок 2 – Эквивалентная схема замещения шунтирующего МЭМС-переключателя
 Figure 2 – Equivalent circuit of shunt-type RF MEMS switch

Электрический импеданс переключателя определяется выражением:

$$Z_s = R_s + j\omega L + \frac{1}{j\omega C},$$

где C принимает значения C_g и C_n в зависимости от положения мембраны [1]:

$$C_g = \frac{\varepsilon_0 A}{g_0 + t_d / \varepsilon_r}, \quad C_n = \frac{\varepsilon_0 \varepsilon_r A}{t_d}.$$

где ε_0 – электрическая постоянная.

Алгоритм создания нейросетевой модели на примере МЭМС-переключателя

В рамках задач многовариантного моделирования и оптимизации не всегда требуется восстановление полной частотной зависимости коэффициента отражения $S_{11}(f)$ и развязки $S_{21}(f)$. На практике достаточно предсказывать информативные признаки отклика – экстремальные значения S-параметров и соответствующие им частоты (S_{11_max} , $f_{S_{11_max}}$, S_{21_min} , $f_{S_{21_min}}$), поскольку именно они напрямую связаны с критериями согласования и развязки в рабочем диапазоне.

Попытка аппроксимации S-параметров во всём частотном диапазоне приводит к многомерному выходу (десятки–сотни частотных точек), это существенно увеличивает число параметров модели и усложняет задачу обучения, что, как правило, требует заметно большего объёма обучающей выборки по сравнению с $N = 1000$. Поэтому в данной работе эмпирически выбран подход аппроксимации признаков отклика, обеспечивающий требуемую точность менее 3 % при умеренном объёме данных $N = 1000$ и минимальных вычислительных затратах – единицы секунд.

Далее рассмотрим алгоритм создания нейросетевой модели на примере ёмкостного МЭМС-переключателя шунтирующего типа. Разработанный алгоритм применим к широкому классу полосковых коммутационных устройств радиотехнических систем, характеристики которых описываются S-параметрами.

Общая схема алгоритма

Предлагаемый алгоритм создания нейросетевой модели МЭМС-переключателя для прогнозирования экстремальных характеристик S-параметров состоит из двенадцати основных этапов (рисунок 3). Алгоритм включает три основных блока: подготовительный этап проектирования и верификации конструкции (этапы 1 – 5), формирование обучающей выборки методом автоматизированного электродинамического моделирования (этапы 6 – 9) и создание нейросетевой модели с последующей верификацией точности (этапы 10 – 12).

Этапы 1 – 5. Подготовительный этап включает формулирование технического задания (рабочая полоса частот, требуемая развязка, вносимые потери), синтез конструкции переключателя по методу [1], формирование базы входных данных и верификацию конструкции комбинированными методами электродинамического моделирования в среде HFSS и схемотехнического расчёта в среде AWR [19]. При соответствии результатов техническому заданию осуществляется переход к формированию обучающей выборки.

Этап 6. Выбор архитектуры искусственной нейронной сети (ИНС) и определение объёма выборки N . Определяется архитектура ИНС прямого распространения на основе анализа размерности задачи (3 входных параметра, 4 выходных параметра) и требуемой точности аппроксимации. Устанавливается объём обучающей выборки $N = 1000$ образцов. Выбор данного объёма обоснован балансом между точностью аппроксимации и вычислительными затратами: каждый расчёт в HFSS занимает в среднем 45 секунд, следовательно, 1000 расчётов требуют приблизительно 12,5 часа – приемлемое время для персонального компьютера.

Этап 7. Генерация выборки методом латинского гиперкуба (LHS) [10]. Формируется обучающая выборка из 1000 комбинаций конструктивных параметров методом LHS, обеспечивающая равномерное распределение точек в многомерном параметрическом пространстве при ограниченном числе расчётов. При этом ортогональная выборка гарантирует, что набор случайных чисел очень точно отражает реальную вариативность.

Этап 8. Численное многовариантное моделирование в среде HFSS. Для каждой комбинации конструктивных параметров из сформированной выборки выполняется автоматизированное полноволновое электродинамическое моделирование методом FEM в среде HFSS через программный интерфейс PyAEDT с извлечением выходных электрических характеристик S-параметров.

Этап 9. Нормализация данных и разделение выборки. Полученные данные подвергаются предварительной обработке для улучшения сходимости процесса обучения нейронной сети. Применяется метод стандартизации (StandardScaler) для приведения входных геометрических параметров и выходных значений S-параметров (x) к нулевому математическому ожиданию и единичной дисперсии:

$$z = \frac{x - \mu}{\sigma},$$

где μ – среднее значение, σ – среднеквадратическое отклонение. Нормализованная выборка, обеспечивая стандартное соотношение, разделяется на обучающую (80 %) и тестовую (20 %).

Этап 10. Обучение нейросетевой модели алгоритмом Adam [11, 12]. Осуществляется обучение искусственной нейронной сети выбранной архитектуры методом обратного распространения ошибки с применением адаптивного алгоритма Adam – оптимизатор нового поколения, более гибкий и устойчивый по сравнению с предыдущими градиентными методами. Используются функция активации ReLU для скрытых слоёв, которая решает проблему исчезающего градиента, позволяя моделям быстрее обучаться и стабильнее работать, а также функция потерь MSE и критерий ранней остановки для предотвращения переобучения.

Этап 11. Оценка точности аппроксимирующей модели. В процессе обучения используется независимая валидационная выборка из 200 образцов (20 % данных) для контроля переобучения и выбора параметров модели. Вычисляются статистические метрики качества аппроксимации [13, 14].

1) Средняя абсолютная процентная ошибка (Mean Absolute Percentage Error):

$$\text{MAPE} = \frac{1}{N_0} \sum_{i=1}^{N_0} \frac{|y_i - \hat{y}_i|}{|y_i|},$$

где y_i – истинное значение S-параметра из HFSS; \hat{y}_i – предсказание нейронной сети; N_0 – число образцов в выборке. Метрика MAPE показывает среднюю относительную ошибку в процентах и не зависит от масштаба данных.

2) Коэффициент детерминации:

$$R^2 = 1 - \frac{\sum_{i=1}^{N_0} (y_i - \hat{y}_i)^2}{\sum_{i=1}^{N_0} (y_i - \bar{y})^2},$$

где \bar{y} – среднее значение истинных S-параметров.

Метрика R^2 показывает долю дисперсии зависимой переменной, и принимает значения от 0 до 1. Критериями приемлемости модели для инженерных расчётов являются $\text{MAPE} < 3\%$ и $R^2 > 0,9$. При невыполнении критериев осуществляется возврат к этапу 6 для корректировки архитектуры нейронной сети или увеличения объёма обучающей выборки. При выполнении критериев модель признаётся пригодной для применения и переходит к финальной верификации.

Этап 12. Верификация точности нейросетевой модели. Наиболее перспективные конфигурации МЭМС-переключателя, выявленные в процессе многовариантного анализа с использованием обученной нейросетевой модели, подвергаются повторному независимому электродинамическому моделированию в среде HFSS для подтверждения точности нейросетевых предсказаний.



Рисунок 3 – Схема алгоритма создания нейросетевой модели полосковых переключателей
 Figure 3 – Flowchart of the algorithm for developing a neural-network surrogate model for stripline switches

Оптимизация архитектуры нейронной сети

Результаты подбора архитектуры приведены в таблице 2. Увеличение сложности сети (рост числа скрытых слоёв и нейронов) в целом приводит к повышению точности аппроксимации: коэффициент детерминации R^2 возрастает, а MAPE уменьшается. Наилучшие показатели достигнуты для трёхслойной архитектуры с числом нейронов в слоях $16 \times 16 \times 16$, обеспечивающей $R^2 = 0,9085$ при $MAPE = 1,15\%$. Данная архитектура принята в качестве базовой для дальнейших вычислительных экспериментов (рисунок 4).

Таблица 2 – Результаты оптимизации архитектуры нейронной сети
Table 2 – Results of neural network architecture optimization

№ п/п	Число скрытых слоев	Число нейронов на каждом слое	R ²	MAPE (%)
1	1	8	0,8402	1,46
2	1	16	0,8564	1,38
3	2	8×8	0,8614	1,33
4	2	16×16	0,8753	1,29
5	3	8×8×8	0,8877	1,22
6	3	16×16×16	0,9085	1,15

Параметры нейросетевой модели

В качестве входных параметров ИНС выбраны три геометрических параметра: ширина мембраны w (60 – 80 мкм), толщина диэлектрического слоя t_d (0,150 – 0,250 мкм) и диаметр перфорационных отверстий d_r (4 – 12 мкм). Выходными параметрами являются максимальное значение коэффициента отражения S_{11_max} , частота, соответствующая максимуму коэффициента отражения S_{11} (обозначается как $f_{S_{11_max}}$), минимальное значение развязки S_{21_min} и частота, соответствующая минимуму коэффициента развязки S_{21} (обозначается как $f_{S_{21_min}}$). Данные выходные параметры являются информативными признаками отклика и в достаточной мере характеризуют свойства МЭМС-переключателя во включенном состоянии в диапазоне 20 – 40 ГГц. Архитектура нейронной сети представлена на рисунке 4.




Рисунок 4 – Архитектура искусственной нейронной сети для аппроксимации характеристик МЭМС-переключателя
Figure 4 – Architecture of artificial neural network for approximating RF MEMS switch characteristics

Результаты нейросетевой аппроксимации МЭМС-переключателя и анализ точности

Верификация модели: схемотехническое моделирование – AWR и метод конечных элементов – HFSS

Проведено моделирование шунтирующего МЭМС-переключателя во включенном состоянии двумя методами: электродинамическим моделированием в системе HFSS и схемотехническим расчётом по эквивалентной схеме (рисунок 2) в среде AWR.

Результаты моделирования МЭМС-переключателя в режиме включено (мембрана замкнута на полосковой проводник) приведены на рисунках 5 и 6. Резонансная частота для данного переключателя составила 30,01 ГГц (HFSS) и 29,32 ГГц (AWR), максимальная развязка между входом и выходом МЭМС-переключателя достигает значений –52,54 дБ и –

48 дБ соответственно. Дополнительно по уровню -40 дБ определена полоса эффективной развязки: для HFSS границы составляют $28,58 - 31,59$ ГГц ($\Delta f_{-40\text{дБ}} \approx 3,01$ ГГц), для AWR: $26,98 - 31,75$ ГГц ($\Delta f_{-40\text{дБ}} \approx 4,77$ ГГц). Относительное расхождение по резонансной частоте не превышает $2,6\%$, что подтверждает корректность используемой электродинамической модели и обосновывает использование HFSS-данных в качестве эталонных при обучении нейросетевой модели.

Точность нейросетевой аппроксимации

Выбранная архитектура (рисунок 4) использована для получения нейросетевой модели МЭМС-переключателя. Анализ кривой обучения (рисунок 7) демонстрирует устойчивое снижение функции потерь среднеквадратичной ошибки (MSE) как на обучающей, так и на валидационной выборках в процессе обучения. Окончательные значения функции потерь стабилизируются на близких уровнях: $MSE \approx 0,20$ для обучающей выборки и $MSE \approx 0,14$ для валидационной выборки. Параллельное снижение обеих кривых указывает на адекватность выбранной архитектуры нейронной сети и отсутствие признаков переобучения. Процесс обучения занял 358 эпох при общем времени вычислений 38,09 с.

Обученная нейронная сеть была протестирована на независимом тестовом множестве из 200 образцов. Общая оценка качества аппроксимации показала коэффициент детерминации $R^2 = 0.9085$ и среднюю абсолютную процентную ошибку $MAPE = 1.15\%$, что свидетельствует о высокой точности предсказания электрических характеристик переключателя по его геометрическим параметрам.




Рисунок 5 – Развязка S_{21} во включенном состоянии

Figure 5 – Isolation (S_{21}) in ON state




Рисунок 6 – Коэффициент отражения S_{11} во включенном состоянии

Figure 6 – Reflection coefficient (S_{11}) in ON state

Статистические метрики качества аппроксимации для всех выходных параметров приведены непосредственно на диаграммах рассеяния (рисунок 8).

Важным преимуществом разработанной нейросетевой модели является высокая вычислительная эффективность. Предсказание для одного набора входных параметров занимает менее 1 мс, тогда как одно полноволновое электродинамическое моделирование в среде HFSS требует в среднем порядка 45 с вычислительного времени. Все численные эксперименты выполнены на персональном компьютере с процессором Intel Core i5, 16 ГБ оперативной памяти под управлением ОС Windows 11. Таким образом, применение нейронной сети обеспечивает ускорение расчётов более чем на четыре порядка (более чем в 4×10^4 раз), что делает возможным эффективное проведение многовариантного анализа и параметрической оптимизации конструкции.

Верификация точности на независимых тестовых образцах

Для окончательной верификации точности нейросетевой модели осуществлён вероятностный отбор девяти конфигураций из тестовой выборки (образцы с номерами 0, 22, 44, 66, 88, 110, 132, 154, 176 из общего числа 200). Отобранные образцы охватывают параметрическое пространство конструктивных размеров в диапазонах: $w = 60,1 - 76,5$ мкм, $t_d = 0,152 - 0,231$ мкм, $d_r = 4,3 - 9,5$ мкм.

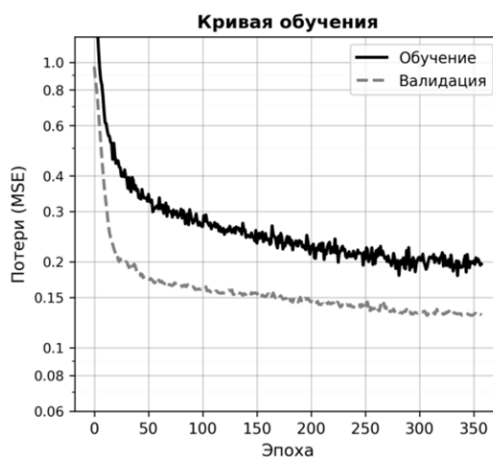


Рисунок 7 – Кривая обучения нейронной сети
Figure 7 – Neural network training curve

Результаты сравнения предсказаний нейронной сети с результатами моделирования в среде HFSS представлены в таблицах 3 и 4.

Таблица 3 – Верификация точности предсказания минимального значения коэффициента развязки и соответствующей частоты

Table 3 – Verification of minimum isolation coefficient and corresponding frequency prediction accuracy

№ п/п	w (мкм)	t_d (мкм)	d_r (мкм)	S_{21_min} (дБ) HFSS	S_{21_min} (дБ) ИНС	ΔS_{21_min} (%)	$f_{S_{21_min}}$ (ГГц) HFSS	$f_{S_{21_min}}$ (ГГц) ИНС	$\Delta f_{S_{21_min}}$ (%)
1	68,1	0,207	8,5	-50,2	-50,23	0,02	32,2	32,16	0,12
2	61,1	0,204	8,0	-51,1	-51,15	0,04	32,3	32,42	0,37
3	67,5	0,152	7,8	-53,8	-53,78	0,06	27,5	28,57	3,89
4	60,1	0,231	4,8	-49,8	-50,3	1,04	33,4	33,24	0,48
5	69,5	0,201	5,9	-51,2	-50,63	1,06	31,1	31,28	0,58
6	62,4	0,231	8,3	-49,2	-49,69	1,08	33,9	33,84	0,18
7	76,5	0,219	9,5	-52,0	-49,47	4,92	34,0	33,51	1,44
8	61,6	0,166	4,3	-57,0	-54,18	4,96	29,4	28,97	1,46
9	62,7	0,227	9,0	-52,6	-49,7	5,48	34,9	33,82	3,09

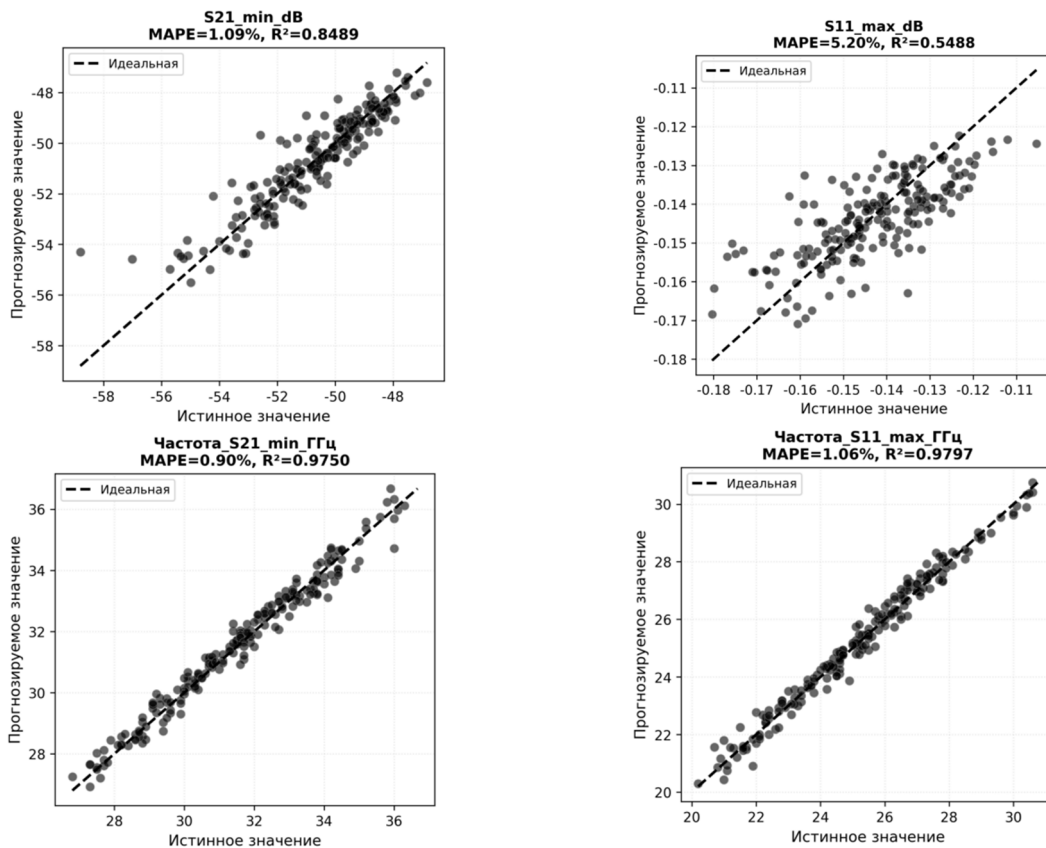


Рисунок 8 – Диаграммы рассеяния предсказанных и истинных значений выходных параметров

Figure 8 – Scatter plots of predicted and true output parameter values

Таблица 4 – Верификация точности предсказания максимального значения коэффициента отражения и соответствующей частоты

Table 4 – Verification of maximum reflection coefficient and corresponding frequency prediction accuracy

№ п/п	w (МКМ)	t_d (МКМ)	d_r (МКМ)	S_{11_max} (дБ) HFSS	S_{11_max} (дБ) ИНС	ΔS_{11_max} (%)	$f_{S_{11_max}}$ (ГГц) HFSS	$f_{S_{11_max}}$ (ГГц) ИНС	$\Delta f_{S_{11_max}}$ (%)
1	68,1	0,207	8,5	-0,145	-0,15	3,45	25,9	26,014	0,44
2	61,1	0,204	8,0	-0,153	-0,15	1,96	26,7	26,457	0,91
3	67,5	0,152	7,8	-0,122	-0,13	6,56	21,9	22,352	2,06
4	60,1	0,231	4,8	-0,156	-0,16	2,56	27,8	27,298	1,81
5	69,5	0,201	5,9	-0,145	-0,14	3,45	24,6	24,921	1,30
6	62,4	0,231	8,3	-0,149	-0,16	7,38	28,7	27,89	2,82
7	76,5	0,219	9,5	-0,171	-0,15	12,28	27,2	27,374	0,64
8	61,6	0,166	4,3	-0,163	-0,14	14,11	23,0	23,022	0,10
9	62,7	0,227	9,0	-0,167	-0,16	4,19	28,6	27,874	2,54

Результаты верификации на девяти независимых тестовых образцах (таблицы 3, 4) подтверждают статистические показатели на полной выборке (рисунок 8). Средняя погрешность предсказания резонансных частот $f_{S_{21_min}}$ составляет 1,3 – 1,4 %, экстремального значения развязки – 2,2 %. Пониженная точность аппроксимации S_{11_max} (средняя погрешность 6,2 %) обусловлена крайне узким диапазоном значений данного параметра (от -0,11 до -0,18 дБ), однако этот параметр носит вспомогательный характер. Достигнутая точность удовлетворяет требованиям многовариантного проектирования и параметрической оптимизации полосковых переключателей.

Алгоритм создания нейросетевой модели на примере PIN-диодного переключателя

Для подтверждения универсальности предложенного алгоритма было проведено дополнительное исследование на устройстве принципиально иного типа – PIN-диодном переключателе SPST с открытым шлейфом. Переключатель представляет собой Т-образную микрополосковую структуру. Основная микрополосковая линия (50Ω) ориентирована горизонтально, а открытый шлейф (Transmission Line Stub Resonator) длиной L_{stub} и шириной W_{stub} расположен перпендикулярно. PIN-диод D размещён в зазоре между шлейфом и основной линией [18]. Схема переключателя и его режимы работы представлены на рисунке 9.

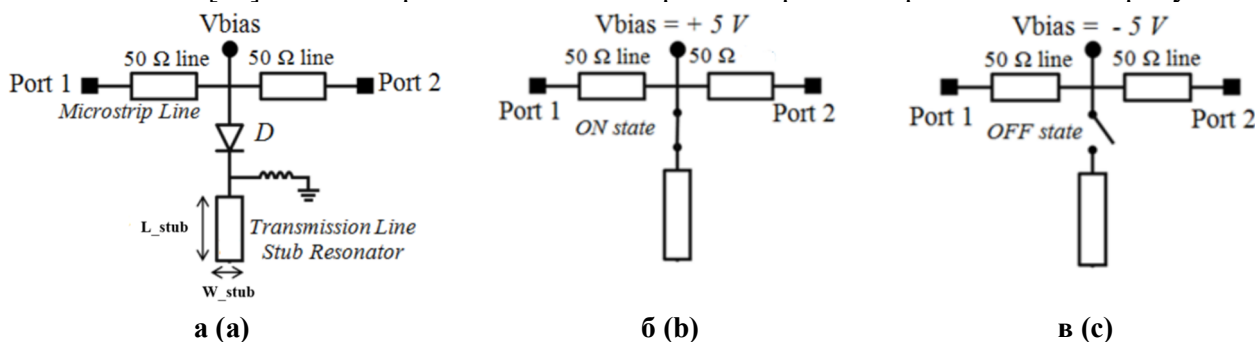


Рисунок 9 – Схема PIN-диодного переключателя с открытым шлейфом: а – конструкция, б – состояние включения, в – состояние выключения

Figure 9 – Circuit diagram of switchable open stub resonator PIN diode switch: a – structure, b – ON state, c – OFF state

При подаче прямого смещения на PIN-диод (рисунок 9, б) диод переходит в состояние включения (ON state) и открытый шлейф подключается к основной линии передачи. В этом режиме шлейф трансформирует разомкнутый конец в короткое замыкание на основной линии, обеспечивая режим загораживания с высокой развязкой. При подаче обратного смещения (рисунок 9, в) диод переходит в состояние выключения, высокий импеданс диода изолирует шлейф от линии передачи, обеспечивая режим пропускания сигнала [18].

В качестве входных геометрических параметров ИНС были выбраны три переменных: h – толщина подложки (0,25 – 0,75 мм), W_{stub} – ширина открытого шлейфа (0,3 – 2 мм), L_{stub} – длина открытого шлейфа (2 – 6 мм). Выходными параметрами являются максимальное значение коэффициента отражения $S_{11_{\text{max}}}$, частота, соответствующая максимуму коэффициента отражения S_{11} (обозначается как $f_{S_{11_{\text{max}}}}$), минимальное значение развязки $S_{21_{\text{min}}}$ и частота, соответствующая минимуму коэффициента развязки S_{21} (обозначается как $f_{S_{21_{\text{min}}}}$). Обучающая выборка из $N = 975$ образцов была сформирована методом LHS, обеспечивающим равномерное распределение точек в трёхмерном параметрическом пространстве. Нормализованная выборка разделена на обучающую (780 образцов, 80 %) и тестовую (195 образцов, 20 %) с последующей стандартизацией данных методом StandardScaler.

Обучение проводилось с использованием той же архитектуры $16 \times 16 \times 16$, определённой ранее для МЭМС-переключателя (таблица 2), и тех же методов: оптимизатор Adam, функция активации ReLU, функция потерь MSE. Общая оценка качества аппроксимации на тестовой выборке показала $R^2 = 0,9684$ и MAPE = 2,98 % при времени обучения 52,55 с. Результаты по отдельным выходным параметрам: для $S_{11_{\text{max}}}$ – MAPE = 4,22 %, $R^2 = 0,9656$; для частоты $f_{S_{11_{\text{max}}}}$ – MAPE = 2,49 %, $R^2 = 0,9881$; для $S_{21_{\text{min}}}$ – MAPE = 2,82 %, $R^2 = 0,9328$; для частоты $f_{S_{21_{\text{min}}}}$ – MAPE = 2,54 %, $R^2 = 0,9871$. Наибольшую точность демонстрируют предсказания резонансных частот $f_{S_{21_{\text{min}}}}$ ($R^2 > 0,98$), что физически обосновано прямой зависимостью частоты от длины шлейфа через соотношение $\lambda/4$.

Таким образом, в обоих случаях с использованием единого алгоритма и одной и той же архитектуры $16 \times 16 \times 16$ достигнута высокая точность аппроксимации: $R^2 > 0,90$ и $MAPE < 5\%$. Тот факт, что архитектура, подобранная для МЭМС-переключателя, обеспечивает высокую точность и для PIN-диодного переключателя при ином объёме выборки ($N = 975$ вместо $N = 1000$) без дополнительной оптимизации, подтверждает устойчивость предложенного алгоритма к изменению типа устройства, физического механизма переключения и диапазона частот. Таким образом, предложенный алгоритм может быть рекомендован в качестве типового подхода к созданию нейросетевых моделей полосковых переключателей различных типов.

Заключение

В работе предложен и верифицирован алгоритм создания нейросетевой модели полосковых переключателей, обеспечивающий баланс между точностью аппроксимации и вычислительной эффективностью. Универсальность алгоритма подтверждена на двух принципиально различных типах устройств: МЭМС-переключателе ($R^2 = 0,9085$, $MAPE = 1,15\%$) и PIN-диодном переключателе ($R^2 = 0,9684$, $MAPE = 2,98\%$). В обоих случаях использовались одни и те же методы и архитектура $16 \times 16 \times 16$ без дополнительной оптимизации, при сокращении времени расчёта более чем на четыре порядка по сравнению с полноволновым моделированием. Полученные результаты позволяют рекомендовать предложенный алгоритм в качестве типового подхода к созданию нейросетевых моделей полосковых коммутационных устройств радиотехнических систем. В дальнейших исследованиях планируется расширение алгоритма на другие классы полосковых переключателей [15-17], а также учёт дополнительных конструктивных и электрофизических параметров.

Библиографический список

1. **Rebeiz G.M.** RF MEMS: Theory, Design, and Technology. Hoboken, NJ: John Wiley & Sons, 2003, 485 pp.
2. **Zhang Q.J., Gupta K.C.** Neural Networks for RF and Microwave Design. Boston: Artech House, 2000, 392 pp.
3. **Pozar D.M.** Microwave Engineering. 4th ed. Hoboken, NJ: Wiley, 2012, 752 pp.
4. **Rayas-Sánchez J.E.** EM-based optimization of microwave circuits using artificial neural networks: The state-of-the-art. IEEE Trans. Microw. Theory Techn. 2004, vol. 52, no. 1, pp. 420-435.
5. **Cao Y., Reitzinger S., Zhang Q.** Simple and efficient high-dimensional parametric modeling for microwave cavity filters using modular neural network. IEEE Microw. Wireless Compon. Lett. 2011, vol. 21, no. 5, pp. 258-260.
6. **Feng F., Zhang C., Na W., et al.** Adaptive feature zero assisted surrogate-based EM optimization for microwave filter design. IEEE Microw. Wireless Compon. Lett. 2019, vol. 29, no. 1, pp. 2-4.
7. **Marinković Z., Marković V., Ćirić T., Vietzorreck L., Pronić-Rančić O.** Artificial neural networks in RF MEMS switch modeling. Facta Universitatis - Series: Electronics and Energetics. 2016, vol. 29, no. 2, pp. 177-191.
8. **Lucyszyn S, editor.** Advanced RF MEMS. Cambridge: Cambridge University Press; 2010, 440 pp. DOI:10.1017/CBO9780511781995
9. **Oberhammer J.** Novel RF MEMS switch and packaging concepts. Royal Institute of Technology. Sweden; 2004. 154 pp.
10. **McKay M.D., Beckman R.J., Conover W.J.** A comparison of three methods for selecting values of input variables in the analysis of output from a computer code. Technometrics. 1979, vol. 21, no. 2, pp. 239-245.
11. **Kingma D.P., Ba J. Adam.** A Method for Stochastic Optimization. Proceedings of the 3rd International Conference on Learning Representations. 2015. doi:10.48550/arXiv.1412.6980.
12. **Goodfellow I., Bengio Y., Courville A.** Deep Learning. Cambridge, MA: MIT Press, 2016, 800 pp.
13. **Queipo N.V., Haftka R.T., Shyy W. et al.** Surrogate-based analysis and optimization. Progress in Aerospace Sciences. 2005, vol. 41, pp. 1-28.
14. **Koziel S., Pietrenko-Dabrowska A.** Performance-Driven Surrogate Modeling of High-Frequency Structures. Cham: Springer Nature, 2020. 441 p.

15. **Васильев Е.П., Нгуен Данг Хоп, Лыу Тхань Дат.** Полосовой фильтр на связанных микрополосковых линиях с двумя секторными резонаторами // Вестник Рязанского государственного радиотехнического университета. 2021. № 75. С. 15-23.

16. **Васильев Е.П., Нгуен Данг Хоп.** Анализ численными методами конструктивных вариантов миниатюрных радарных резонансных элементов // Вестник Рязанского государственного радиотехнического университета. 2023. № 84. С. 3-14.

17. **Васильев Е.П., Нгуен Данг Хоп.** Моделирование электромагнитных ключевых элементов в микроволновом диапазоне // Вестник Рязанского государственного радиотехнического университета. 2025. № 92. С. 13-24.

18. **Algumaei M.Y., Shairi N.A., Zakaria Z., Zobilah A.M.S., Ahmad B.H.** Analysis of Open Stub Resonator and its Application in Dual Isolation Band of SPDT Switch Design // International Journal of Electrical and Computer Engineering (IJECE). 2016. Vol. 6, No. 6. P. 2900-2910.

19. ANSYS HFSS: 3D High Frequency Simulation Software. URL: <https://www.ansys.com/products/electronics/ansys-hfss> (дата обращения: 20.02.2026).

UDC 621.372.049.77: 004.032.26

ALGORITHM TO CREATE NEURAL NETWORK MODEL BASED ON THE EXAMPLE OF MICROSTRIP MEMS SWITCH

D. H. Nguyen, post-graduate student, RSREU, Ryazan, Russia;
orcid.org/0000-0002-2456-5220, e-mail: danghoprzn@mail.ru

E. P. Vasiliev, Doctor in Technical Sciences, department of space technologies, Professor of the Department, RSREU, Ryazan, Russia;
orcid.org/0000-0003-2747-7012, e-mail: evasiliev48@mail.ru

The algorithm for modeling shunt-type capacitive MEMS switches based on artificial neural networks is proposed. Modern methods to analyze microstrip devices, including electromagnetic modeling, equivalent circuit models, and machine learning-based models are reviewed. The aim of this work is to develop an algorithm for creating a neural network model to predict S-parameters, providing balance between accuracy and computational time. The algorithm proposed includes stages of design synthesis, training sample generation using Latin Hypercube Sampling ($N = 1000$ computational experiments), electromagnetic modeling in High Frequency Structure Simulator (HFSS) environment via PyAEDT Python library interface, data normalization, and training of multilayer neural network with $16 \times 16 \times 16$ architecture. The developed model achieves high approximation accuracy ($R^2 = 0,9085$ – coefficient of determination, MAPE = 1,15 % – mean absolute percentage error) while reducing computation time by more than 10^4 times compared to full-wave electromagnetic modeling. Independent test set verification confirms prediction accuracy for resonant frequencies (average error 1,3 – 1,4 %) and isolation (average error 2,2 %). The universality of the algorithm is confirmed by additional study on PIN diode switch, achieving $R^2 = 0,9684$ and MAPE = 2,98 % with $N = 975$ samples. The proposed approach for approximating frequency-dependent output S-parameters is applicable to a wide class of microstrip switches.

Key words: circuit and electromagnetic modeling; microstrip MEMS switch; approximation; S-parameters; artificial neural network; neural network model; PIN diode switch.

DOI: 10.21667/1995-4565-2026-95-27-40

References

1. **Rebeiz G.M.** RF MEMS: Theory, Design, and Technology. Hoboken, NJ: John Wiley & Sons. 2003, 485 pp.
2. **Zhang Q.J., Gupta K.C.** Neural Networks for RF and Microwave Design. Boston: Artech House, 2000, 392 pp.
3. **Pozar D.M.** Microwave Engineering. 4th ed. Hoboken, NJ: Wiley. 2012, 752 pp.
4. **Rayas-Sánchez J.E.** EM-based optimization of microwave circuits using artificial neural networks: The state-of-the-art. IEEE Trans. Microw. Theory Techn. 2004, vol. 52, no. 1, pp. 420-435.

5. **Cao Y., Reitzinger S., Zhang Q.** Simple and efficient high-dimensional parametric modeling for microwave cavity filters using modular neural network. *IEEE Microw. Wireless Compon. Lett.* 2011, vol. 21, no. 5, pp. 258-260.
6. **Feng F., Zhang C., Na W., et al.** Adaptive feature zero assisted surrogate-based EM optimization for microwave filter design. *IEEE Microw. Wireless Compon. Lett.* 2019, vol. 29, no. 1, pp. 2-4.
7. **Marinković Z., Marković V., Ćirić T., Vietzorreck L., Pronić-Rančić O.** Artificial neural networks in RF MEMS switch modeling. *Facta Universitatis – Series: Electronics and Energetics.* 2016, vol. 29, no. 2, pp. 177-191.
8. **Lucyszyn S, editor.** *Advanced RF MEMS.* Cambridge: Cambridge University Press; 2010, 440 pp. DOI:10.1017/CBO9780511781995
9. **Oberhammer J.** *Novel RF MEMS switch and packaging concepts.* Royal Institute of Technology. Sweden. 2004, 154 pp.
10. **McKay M.D., Beckman R.J., Conover W.J.** A comparison of three methods for selecting values of input variables in the analysis of output from a computer code. *Technometrics.* 1979, vol. 21, no. 2, pp. 239-245.
11. **Kingma D.P., Ba J. Adam:** A Method for Stochastic Optimization. *Proceedings of the 3rd International Conference on Learning Representations.* 2015. DOI:10.48550/arXiv.1412.6980.
12. **Goodfellow I., Bengio Y., Courville A.** *Deep Learning.* Cambridge. MA: MIT Press, 2016, 800 pp.
13. **Queipo N.V., Haftka R.T., Shyy W., et al.** Surrogate-based analysis and optimization. *Progress in Aerospace Sciences.* 2005, vol. 41, pp. 1-28.
14. **Koziel S., Pietrenko-Dabrowska A.** *Performance-Driven Surrogate Modeling of High-Frequency Structures.* Cham: Springer Nature. 2020. 441 p.
15. **Vasilyev E.P., Nguyen Dang Hop, Lyu Thanh Dat.** Polosovoy filtr na svyazannykh mikropoloskovykh liniyakh s dvumya sektornymi rezonatorami. *Vestnik Ryazanskogo gosudarstvennogo radiotekhnicheskogo universiteta.* 2021, no. 75, pp. 15-23. (in Russian).
16. **Vasilyev E.P., Nguyen Dang Hop.** Analiz chislennymi metodami konstruktivnykh variantov miniaturnykh radarnykh rezonansnykh elementov. *Vestnik Ryazanskogo gosudarstvennogo radiotekhnicheskogo universiteta.* 2023, no. 84, pp. 3-14. (in Russian).
17. **Vasilyev E.P., Nguyen Dang Hop.** Modelirovanie elektromagnitnykh klyuchevykh elementov v mikrovolnovom diapazone. *Vestnik Ryazanskogo gosudarstvennogo radiotekhnicheskogo universiteta.* 2025, no. 92, pp. 13-24. (in Russian).
18. **Algumaei M.Y., Shairi N.A., Zakaria Z., Zobilah A.M.S., Ahmad B.H.** Analysis of Open Stub Resonator and its Application in Dual Isolation Band of SPDT Switch Design. *International Journal of Electrical and Computer Engineering (IJECE),* 2016, vol. 6, no. 6, pp. 2900-2910.
19. ANSYS HFSS: 3D High Frequency Simulation Software. URL: <https://www.ansys.com/products/electronics/ansys-hfss>. (accessed February 20, 2026).