

УДК: 621.311.6:621.791.76/.79

Асан уулу Аскам asanaskat@gmail.com

*Кыргызский государственный технический университет им. И. Раззакова,
Кыргызстан, Бишкек, проспект Ч. Айтматова, 66*

ПРИМЕНЕНИЕ НЕЙРОННОЙ СЕТИ ДЛЯ МОДЕЛИРОВАНИЯ ЭЛЕКТРОСТАТИЧЕСКИХ РАЗРЯДОВ В КОМПЬЮТЕРНЫХ МОДЕЛЯХ

Моделирование электростатического разряда (ЭСР) имеет решающее значение для обеспечения надежности и безопасности электронных систем, аэрокосмических компонентов и промышленного оборудования. Однако точное моделирование событий ЭСР остается серьезной проблемой из-за их крайне нелинейной, стохастической и многомасштабной природы. Традиционные численные методы, такие как конечно-элементный анализ (КЭА) и методы конечно-разностной временной области (КРВО), часто сталкиваются с вычислительной неэффективностью и ограниченной точностью прогнозирования при моделировании сложных явлений разряда [1].

Недавние достижения в области машинного обучения, в частности глубокие нейронные сети (DNN), предлагают многообещающую альтернативу для улучшения моделирования ЭСР. Используя подходы, основанные на данных, нейронные сети могут изучать основные физические закономерности из экспериментальных или высокоточных данных моделирования, что позволяет быстрее и точнее прогнозировать поведение разряда. Такие методы, как нейронные сети с физической информацией (PINN) и гибридные фреймворки моделирования, могут преодолеть разрыв между эмпирическими наблюдениями и теоретическими моделями, повышая точность моделирования ЭСР и сокращая вычислительные затраты [2].

В данной статье рассматривается потенциал нейронных сетей в развитии моделирования ЭСР, обсуждаются ключевые методологии, проблемы и будущие направления в этой новой области.

Ключевые слова: электростатический разряд, глубокие нейронные сети, гибридные фреймворки моделирования, частотный спектр, нейронные сети с физической информацией.

Материалы и методы

Для того чтобы глубокая нейронная сеть могла реализовать задачу по улучшению моделирования электростатических разрядов в компьютерных моделях, подготавливается набор данных. Набор данных представляет собой результат всех имеющихся моделей ЭСР, также его частотный анализ [3]. Основными результатами анализа стали два параметра:

1. Формы сигналов ЭСР.
2. Электромагнитные поля, излучаемые ЭСР.

Корреляционная матрица используемого набора данных представлена на рисунке 1. Главная диагональ этой матрицы показывает гистограмму факторов, от которых зависит форма токов ЭСР (например, формы тела, длины канала, напряженности поля в канале и состояния воздуха). Другие элементы изображены в диаграммах рассеяния, показывающих связь между соответствующим фактором и другими факторами (например, связь между формой тела и влажностью воздуха). Кроме того, сообщаемое значение выражает корреляцию между двумя факторами в каждой диаграмме. Согласно последним двум строкам этой матрицы, ИНС значительно коррелирует со всеми входными факторами, в то время как обычные методы — нет.

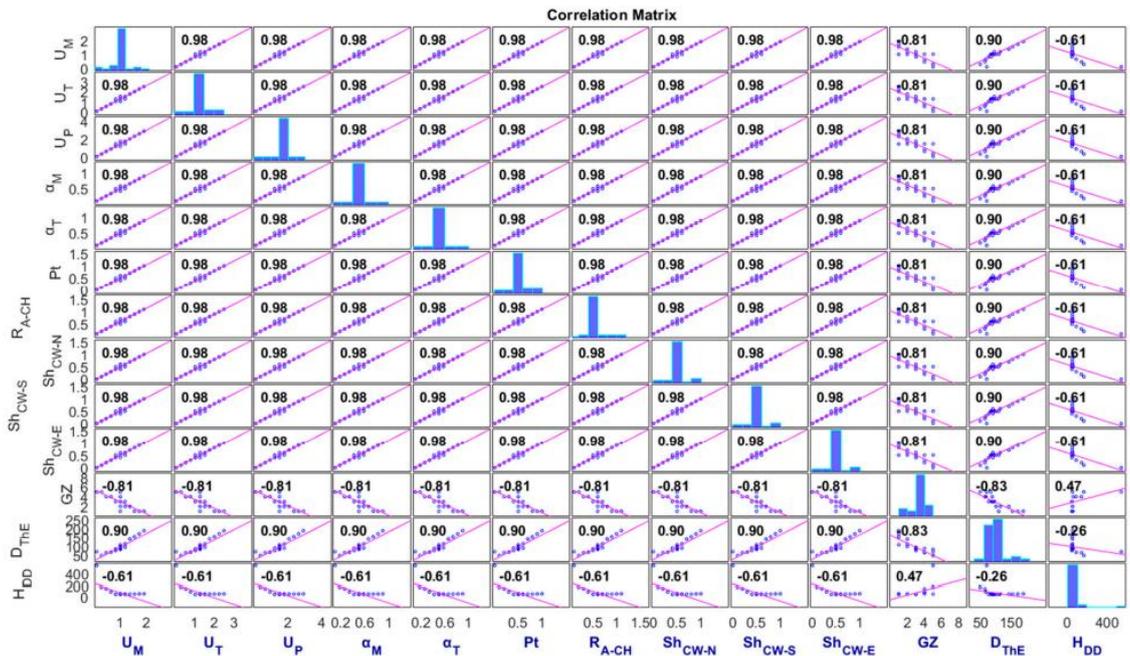


Рисунок 1– Диаграммы рассеяния и гистограммы набора данных

Более того, набор данных был статистически проанализирован в среде Excel с помощью инструмента If ata Analysis Section — Descriptive Statistics. В таблице 1 представлены результаты этого процесса.

Таблица 1– Результаты статистической оценки набора данных

Type	Factor	Mean	Standard Deviation	Sample Variance	Minimum	Maximum
Inputs	U_M (W.m ⁻² .K ⁻¹)	1.00	0.33	0.11	0.10	1.90
	U_T (W.m ⁻² .K ⁻¹)	1.30	0.44	0.19	0.10	2.50
	U_P (W.m ⁻² .K ⁻¹)	1.50	0.51	0.26	0.10	2.90
	α_M (-)	0.50	0.15	0.02	0.10	0.90
	α_T (-)	0.50	0.15	0.02	0.10	0.90
	Pt (W.m ⁻¹ .K ⁻¹)	0.51	0.18	0.03	0.01	1.00
	R_{A-CH} (v.h ⁻¹)	0.60	0.18	0.03	0.10	1.10
	Sh_{CW-N} (-)	0.50	0.18	0.03	0.00	1.00
	Sh_{CW-S} (-)	0.50	0.18	0.03	0.00	1.00
	Sh_{CW-E} (-)	0.50	0.18	0.03	0.00	1.00
Targets	GZ (-)	2.94	1.00	1.00	1.00	5.00
	D_{The} (kWh.m ⁻² .year ⁻¹)	96.15	27.92	779.72	48.19	188.94
	H_{DD} (°C.h.year ⁻¹)	69.53	87.07	7580.95	44.55	546.98

Всего 35 образцов составляют используемый набор данных (размер = 35 x 13). Для этого исследования он был разделен на два поднабора с 28 и 7 образцами для операций обучения и тестирования соответственно. Расчет соотношений показывает, что 80% данных посвящены задаче обучения, в то время как тестовое задание использует 20% из них. Для равномерного распределения данных здесь был применен случайный выбор.

Алгоритм электростатического разряда (АЭСР)

Как известно, метаэвристические алгоритмы в основном вдохновлены естественным поведением, таким как действия животных по поиску пищи [5,6] . С другой стороны, есть некоторые из них, которые следуют известным правилам мира физики, чтобы выполнить оптимизацию (например, оптимизация, вдохновленная оптикой [7]). Алгоритм ЭСР

является еще одним членом последнего семейства, которое было разработано под влиянием явления электростатического разряда [8]. По определению два тела с разными уровнями электростатического потенциала имеют общий заряд [9].

Оптимизация с использованием АЭСР начинается с создания популяции. Способность каждой особи в этой популяции определяется значением приспособленности, которое представляет иммунитет особи. В каждой реализации (т. е. итерации) АЭСР три особи случайным образом учитываются для выполнения разряда. Затем создается случайное значение. На основе значения этого случайного числа возможны два случая:

- (а) Если случайное значение больше 0,5, то два индивида с позициями x_1 и x_2 выполняют разряд следующим образом:

$$x_{2_{new}} = x_2 + 2 \cdot \beta_1 \cdot (x_1 - x_2). \quad (1)$$

- (б) Если случайное значение меньше 0,5:

$$x_{2_{new}} = x_3 + 2 \cdot \beta_2 \cdot (x_1 - x_3) + 2 \cdot \beta_2 \cdot (x_2 - x_3). \quad (2)$$

В приведенных выше уравнениях β_i ($i = 1, 2, 3$) обозначают случайные значения, а $x_{i_{new}}$ представляет новое положение индивидуума i .

После этого алгоритм проводит комплексную проверку, чтобы подтвердить, что все особи находятся внутри границ. Наконец, еще одна проверка выявляет особей, которые прошли более 3 разрядов, поскольку алгоритм должен рассматривать их как исключенных особей и заменять их вновь сгенерированными. Объясненный процесс повторяется для каждой итерации с новыми особями, и таким образом обнаруживается выдающееся решение (т. е. наилучшая пригодность) [8].

Нейронная сеть прямого распространения и используемая структура

До сих пор были предложены и использованы различные версии ИНС для различных симуляций. Эти модели моделируются на основе естественных нейронных сетей в человеческом мозге [2,5]. Следовательно, взаимодействие между нейронными компонентами формирует согласованную сеть, которая способна распознавать и изучать шаблон в данных. Как сети прямого распространения, FFNN сначала получают соответствующие данные, и эти данные обрабатываются по мере продвижения вперед в сети [51]. Например, в ИНС MLP выход слоя i является входом для слоя $i + 1$ [11]. Далее объясняется механизм этих сетей.

Фигура 2 показывает конфигурацию FFNN, оптимизированную метаэвристическими алгоритмами в этом исследовании. Как видно, эта сеть состоит из трех слоев:

- (i) Входной слой, на который поступают одиннадцать входных данных из набора данных.
 (ii) Скрытый слой, который их обрабатывает.
 (iii) Выходной слой.

На этом рисунке каждый синий круг представляет вычислительную единицу FFNN, которые являются 11, 6 и 2 в первом, втором и третьем слоях соответственно. По всей сети нейроны соединены напрямую с помощью черных стрелок (названных весами). Кроме того, красные стрелки считаются смещением вычислений (B означает смещение). Обратите внимание, что при обучении FFNN эти веса и смещения корректируются и

улучшаются несколько раз, пока не будут достигнуты критерии остановки. Таким образом, алгоритм ESDA отвечает за настройку этих переменных для создания наилучшего вклада.

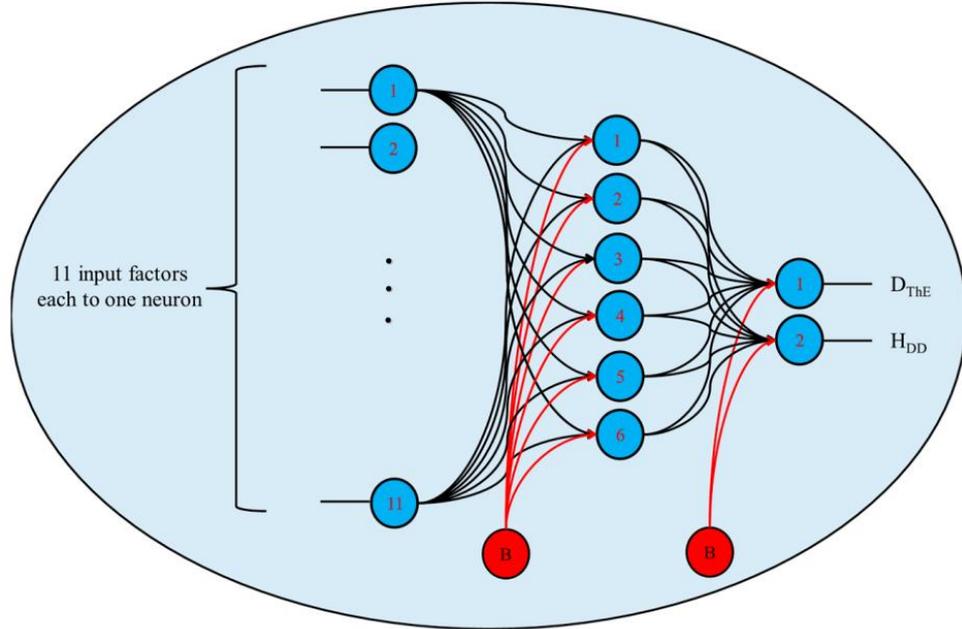


Рисунок 2 – Топология ИНС

Результаты и обсуждение

Основная цель проведения этого исследования — изучить пригодность алгоритма DNN для прогнозирования двух параметров, связанных с ЭСР. После создания модели и организации данных результаты представлены и обсуждаются в следующих частях.

Надежность прогнозов моделей оценивается в два этапа:

(i) Фаза обучения, в течение которой модели приобретают знания о взаимосвязи между с одиннадцатью входными факторами. В этой фазе окончательно создается шаблон с использованием набора данных обучения.

(ii) Фаза тестирования для оценки точности разработанного шаблона.

Для оценки точности используются известные критерии точности: среднеквадратическая ошибка (RMSE), средняя абсолютная ошибка (MAE) и коэффициент корреляции Пирсона (Rp). Уравнения (3)-(5) выражают, как рассчитываются эти критерии.

$$RMSE = \sqrt{\frac{1}{K} \sum_{i=1}^K [Q_{i\text{expect}} - Q_{i\text{estimate}}]^2}, \quad (3)$$

$$MAE = \frac{1}{K} \sum_{i=1}^K |Q_{i\text{expect}} - Q_{i\text{estimate}}|, \quad (4)$$

$$R_p = \frac{\sum_{i=1}^K Q_{i\text{estimate}} - \bar{Q}_{\text{estimate}}}{\sqrt{\sum_{i=1}^K Q_{i\text{estimate}} - \bar{Q}_{\text{estimate}}}} \cdot \frac{Q_{\text{expect}} - \bar{Q}_{\text{expect}}}{\sqrt{\sum_{i=1}^K Q_{\text{expect}} - \bar{Q}_{\text{expect}}}}. \quad (5)$$

В приведенных выше уравнениях $Q_{i\text{expect}}$ представляет собой ожидаемые целевые значения, $Q_{i\text{estimate}}$ обозначает соответствующие оценочные значения, а K показывает

размер наборов данных, который равен 28 на этапе объединения и 8 на этапе тестирования.

Широко признано, что в зависимости от типа проблемы (т. е. регрессии или классификации) существуют различные статистические меры для оценки производительности моделей машинного обучения. Во многих подобных работах использование индекса корреляции вместе с критериями ошибок обеспечивало надежную оценку точности для задач прогнозирования, использующих регрессионный анализ [13- 15], поэтому R_p принимается во внимание в сочетании с двумя известными критериями ошибок (т. е. $RMSE$ и MAE). В частности, при связывании $RMSE$ и MAE фокусируясь на разнице между прогнозом и реальностью, R_p решает проблему согласованности результатов, сообщая значение в диапазоне $[0,1]$. Кроме того, меньшие значения $RMSE$ и MAE , а также большие значения R_p демонстрируют лучшее прогнозирование.

Однако из-за разного количества входных данных их единая $RMSE$ также контролировалась в конце оптимизации. Количество итераций составило 1000, в зависимости от поведения алгоритмов, в то время как размер популяции определялся отдельно для каждой модели после выбора некоторых соответствующих значений. Рисунок 3-а показывает результаты этого процесса для алгоритма ЭСР с размером популяции 50-500. Было обнаружено, что АЭСР выполняют наилучшую оптимизацию, когда размер популяции составляет 300, 400, 400 и 400 соответственно. Рисунок 3б иллюстрирует полученные кривые оптимизации для сообщенных размеров популяции АЭСР по сравнению с эталонными алгоритмами. Этот рисунок дает важную информацию об оптимизации поведения алгоритмов, таких как начальный результат поиска, скорость сходимости и сравнение между алгоритмами.

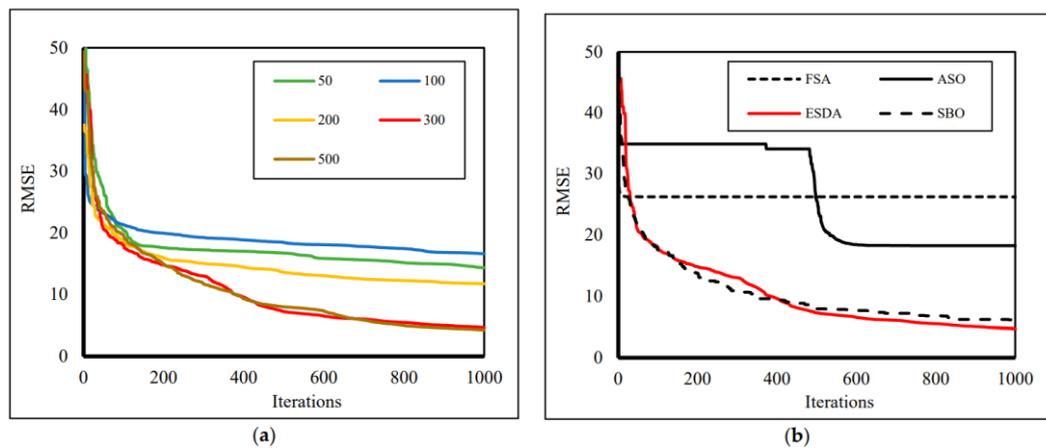


Рисунок 3 – Результаты оптимизации в (а) различных размерах популяции ЭСР и (б) конечные кривые для всех алгоритмов

Как видно из рисунка 5, ИНС дает более полную картинку, что происходит во время ЭСР. Благодаря новейшим моделям можно не только оценить токи ЭСР, но и сделать по ним частотный анализ.

Заключение

Интеграция нейронных сетей в моделирование ЭСР представляет собой преобразующий сдвиг в том, как инженеры и исследователи моделируют эти сложные, высокоскоростные электрические явления. Традиционные методы моделирования, хотя и ценны, часто ограничены вычислительными затратами, стохастическими

неопределенностями и многомасштабной природой событий ESD. Нейронные сети — особенно архитектуры глубокого обучения, модели на основе физики и гибридные подходы — предлагают многообещающий путь преодоления этих ограничений.

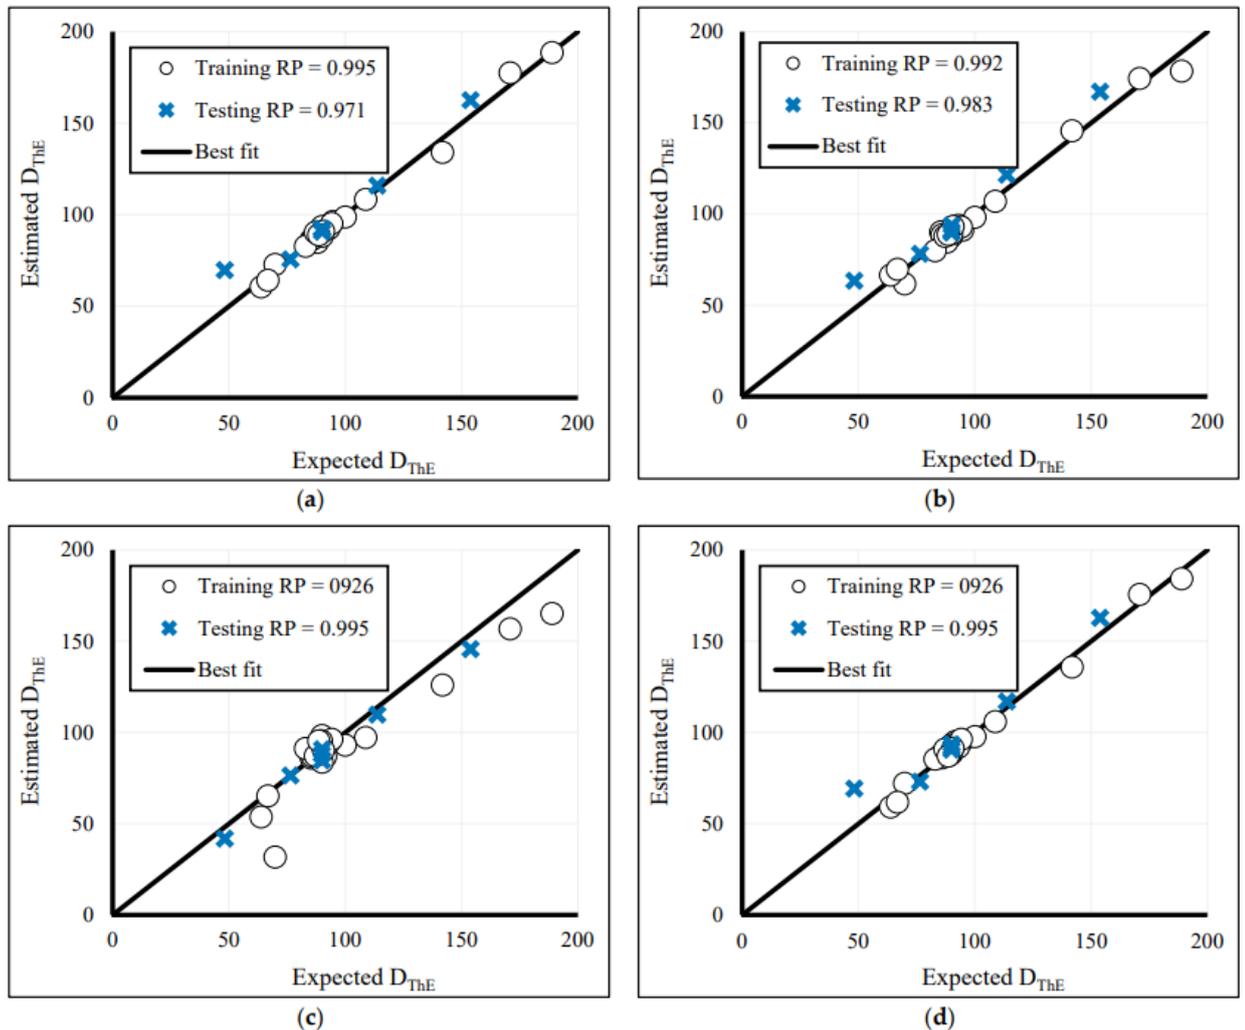


Рисунок 4— Результаты корреляции для фаз обучения и тестирования

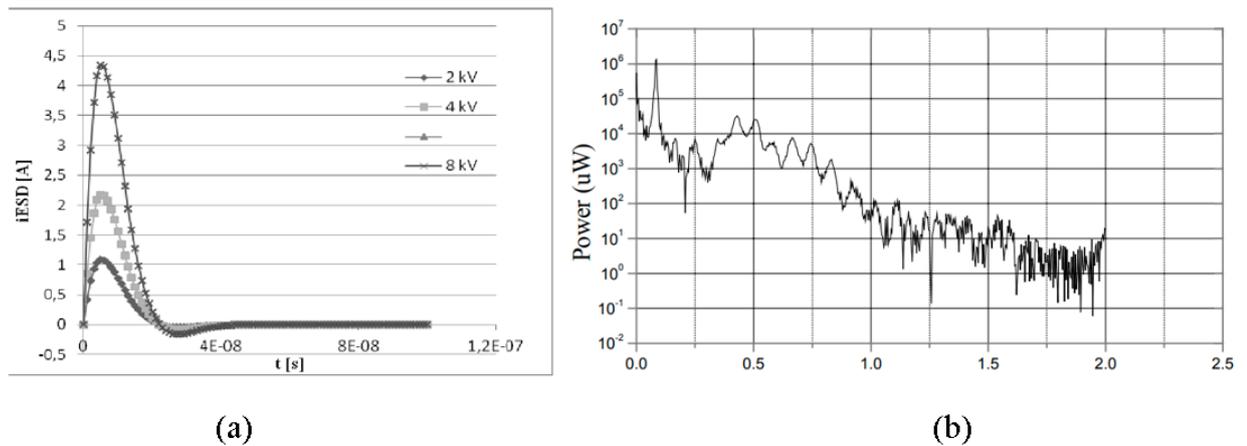


Рисунок 5— Результаты моделирования: а-стандартный метод, б-нейронная сеть

Основные достижения, обеспечиваемые нейронными сетями

Скорость и эффективность: нейронные сети могут служить суррогатными моделями, радикально сокращая время моделирования при сохранении приемлемой точности. Это обеспечивает быстрые итерации проектирования и оптимизацию, которые имеют решающее значение в таких отраслях, как производство полупроводников и аэрокосмическая техника.

Повышенная точность: обучаясь на высокоточных моделированиях или экспериментальных данных, нейронные сети могут улавливать нелинейное и стохастическое поведение, которое трудно моделировать традиционными численными методами.

Гибридные модели физики-МО: нейронные сети с физической информацией (PINN) и другие гибридные подходы гарантируют, что прогнозы остаются основанными на фундаментальных физических законах, сокращая разрыв между моделированием на основе данных и теоретическим моделированием.

Обработка неопределенности: байесовские нейронные сети (BNN) и вероятностные методы МО обеспечивают количественную оценку неопределенности, позволяя инженерам более эффективно оценивать риск и надежность.

Остающиеся проблемы и будущие направления

Несмотря на свой потенциал, моделирование ЭСР на основе нейронных сетей по-прежнему сталкивается с препятствиями:

Требования к данным: высококачественные, хорошо маркированные наборы данных для обучения остаются дефицитными, особенно для редких или экстремальных событий ЭСР.

Обобщение: модели, обученные на определенных сценариях, могут испытывать трудности с невидимыми условиями, что требует надежных методов переноса обучения.

Интерпретируемость: природа «черного ящика» моделей глубокого обучения может препятствовать доверию к критически важным инженерным приложениям, мотивируя исследования в области объяснимого ИИ (XAI) для ЭСР.

Будущие достижения, вероятно, будут сосредоточены на:

- Активном обучении и адаптивной выборке: оптимизация сбора данных для более эффективного обучения моделей.
- Моделировании в реальном времени: развертывание легких нейронных сетей для оперативного прогнозирования ESD в промышленных приложениях.
- Интеграции с традиционными решателями: объединение нейронных сетей с FDTD, FEM или другими устоявшимися методами для использования сильных сторон обоих подходов.

Список литературы

[1] M.T. Gengoglu, M. Cebeci, "Investigation of pollution flashover on high voltage insulators using artificial neural network", Elsevier, Expert Systems with Applications 36 7338-734, (2009).

[2] A. B. Bakasova and A. Uulu Askat, "Neuro-fuzzy approach to identification of electromagnetic fields of electrostatic discharge," 2023 5th International Youth Conference on Radio Electronics, Electrical and Power Engineering (REEPE), Moscow, Russian Federation, 2023, pp. 1-5, doi: 10.1109/REEPE57272.2023.10086745.

- [3] R. Ahmed Refai, A. H. Mansour, M. A- H.Ahmed, “Estimation of the Electric Field and Potential Distribution on Three Dimension Model of Polymeric Insulator Using Finite Element Method”, IJEDR | Volume 3, Issue 2 | ISSN: 2321-9939, (2015).
- [4] M.Enokizono, and Yuji Tsuchida, “Optimal Design by Boundary Element Method with Fuzzy Inference”, IEEE Trans, on Magnetics, Vol.30, No.5, pp.3447-3450, Sept 1994.
- [5] Бакасова, А. Б., & Асан уулу, А. (2023). АДАПТИВНЫЙ НЕЙРО-НЕЧЕТКИЙ ПОДХОД ОЦЕНКИ ЭЛЕКТРИЧЕСКИХ ПОЛЕЙ ЭЛЕКТРОСТАТИЧЕСКОГО РАЗРЯДА. Проблемы автоматизации и управления, (1), 83–95. извлечено от <http://pau.imash.kg/index.php/pau/article/view/396>
- [6] B. Marungsri, W. Onchantuek, A. Oonsivilai “Electric Field and Potential Distributions along Surface of Silicone Rubber Polymer Insulators Using Finite Element Method” World Academy of Science, Engineering and Technology, (2008).
- [7] EMS 2013 Program User’s guide, <http://www.emworks.com>.
- [8] Aydogmus, Z., & Cebeci, M. A new flashover dynamic model of polluted HV insulators. IEEE Transactions on Dielectrics and Electrical Insulation, 11(4), 577-584, (2004).
- [9] Бакасова, А., & Асан уулу, А. (2022). ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ ЭЛЕКТРОМАГНИТНЫХ ПОМЕХ. Проблемы автоматизации и управления, (1), 95–103. извлечено от <http://pau.imash.kg/index.php/pau/article/view/259>
- [10] Асан уулу, А., & Бакасова, А. Б. (2022). ОБЗОР АЛЬТЕРНАТИВНЫХ ПОДХОДОВ К МОДЕЛИРОВАНИЮ ЭЛЕКТРОМАГНИТНОЙ ОБСТАНОВКИ НА ВЫСОКОВОЛЬТНОЙ ЭЛЕКТРИЧЕСКОЙ ПОДСТАНЦИИ. Проблемы автоматизации и управления, (2), 4–14. извлечено от <http://pau.imash.kg/index.php/pau/article/view/307>
- [11] Mohamed M. Zahra, Mohamed H. Essai, Ali R. Abd Ellah, "Performance Functions Alternatives of Mse for Neural Networks Learning", International Journal of Engineering Research & Technology (IJERT), Vol. 3, Issue 1, pp. 967-970, January - (2014).
- [12] Ali R. Abd Ellah, Mohamed H. Essai, Ahmed Yahya, “Robust Backpropagation Learning Algorithm Study for Feed Forward Neural Networks”, Thesis, Al- Azhar University, Faculty of Engineering, -(2016).
- [13] Z. Aydogmus, “A neural network-based estimation of electric fields along high voltage insulators”, Expert Systems with Applications 36 8705-8710, www.elsevier.com/locate/eswa, (2009).
- [14] Nasrat L. S., & Aly.Saleh, “Evaluation of Flashover Voltage on Hydrophobic Polymer Insulators with Artificial Neural Network”, International Journal of Electrical and Computer Engineering (IJECE) Vol.2, No.4, pp. 487~494, August (2012)
- [15] Neural Network Toolbox: For use with MATLAB, the Math Works