

ФИЗИЧЕСКИ-ИНФОРМИРОВАННОЕ МАШИННОЕ ОБУЧЕНИЕ В ЗАДАЧЕ ОЦЕНКИ ПАРАМЕТРОВ СИЛОВЫХ ПРЕОБРАЗОВАТЕЛЕЙ

Швецов Д. А.¹

Научный руководитель – канд. техн. наук, доцент Демидова Г. Л.¹

¹Университет ИТМО
robo.daniil@gmail.com

Введение

Современная силовая электроника предъявляет высокие требования к надежности и эффективности преобразователей энергии. Ключевым фактором обеспечения их бесперебойной работы является точное знание текущих параметров компонентов: пассивных элементов (индуктивностей, емкостей) и силовых полупроводниковых ключей. Отклонение этих параметров от номинальных значений вследствие старения, тепловых нагрузок или внешних воздействий ведет к снижению КПД, ухудшению качества переходных процессов и, в итоге, к аварийным отказам.

Традиционные методы идентификации параметров часто требуют отключения преобразователя от нагрузки, введения тестовых возмущений или использования дополнительной измерительной аппаратуры, что не всегда приемлемо в условиях реальной эксплуатации. Актуальные исследования все чаще обращаются к методам машинного обучения для решения задач диагностики. Однако классические нейросетевые подходы ("черный ящик") требуют больших размеченных датасетов для обучения и не гарантируют физической достоверности результатов, что критически важно для силового оборудования. В последние годы в зарубежной литературе активно развивается направление физически-информированных нейронных сетей (PINN), позволяющее сочетать аналитические модели с аппроксимирующей способностью нейросетей [1]. В данной работе рассматривается применение этого подхода для идентификации параметров силового преобразователя.

Основная часть

Суть рассматриваемого подхода, известного как Physics-Informed Neural Networks (PINN), заключается во встраивании дифференциальных уравнений, описывающих динамику силового преобразователя, непосредственно в процесс обучения нейронной сети. В отличие от классического машинного обучения, сеть обучается не только на экспериментальных данных, но и минимизирует невязку физической модели, что обеспечивает согласованность решений с законами электротехники, заложенными в модель. Базовым примером для апробации метода служит понижающий импульсный преобразователь [2].

Оценка параметров пассивных элементов и силовых полупроводников производится путем включения этих параметров в список оптимизируемых переменных – в процессе обучения происходит поиск оптимальных значений не только весовых коэффициентов нейронной сети, но и неизвестных величин в физической модели преобразователя. На вход сети подаются пиковые значения измеренных электрических сигналов (ток катушки, выходное напряжение) – по два значения на сигнал за один период коммутации. Для связки дискретных измерений с непрерывной моделью применяется схема неявного метода Рунге–Кутты, позволяющая выразить наблюдаемые пиковые состояния системы через латентные промежуточные состояния.

Нейронная сеть предсказывает промежуточные состояния, по которым с помощью физической модели проводится расчет пиковых значений сигналов – невязка между вычисленными на основе предсказаний значениями и обучающими данными формирует функцию потерь.

Для эффективной оценки параметров преобразователя тренировочный набор данных содержит участки переходных режимов, вызванных, например, сменой сопротивления нагрузки [3].

Данный подход снижает требования к объему обучающей выборки и позволяет проводить оценку параметров без вывода преобразователя из рабочего режима, используя малый набор уже доступных датчиков.

Выводы

Апробация метода проведена с применением имитационной модели понижающего импульсного преобразователя. Исследования показали высокую точность и робастность идентификации параметров даже в условиях, приближенных к реальным: при наличии шумов, ограниченной разрядности АЦП и неидеальной синхронизации измерений. Это доказывает пригодность метода для задач технической диагностики и мониторинга состояния. Метод может быть рекомендован для использования в системах мониторинга технического состояния преобразователей, где требуется раннее обнаружение деградации компонентов без вмешательства в рабочий процесс.

Перспективным направлением является масштабирование метода на более сложные топологии электрических схем (трехфазные инверторы, резонансные преобразователи). Практическое внедрение результатов возможно в рамках задач предиктивной диагностики и адаптивного управления оборудованием силовой электроники.

Литература

1. M. Raissi, P. Perdikaris, and G. E. Karniadakis, "Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations," *Journal of Computational Physics*, vol. 378, pp. 686–707, Feb. 2019, doi: 10.1016/j.jcp.2018.10.045.
2. S. Zhao, Y. Peng, Y. Zhang and H. Wang, "Physics-informed Machine Learning for Parameter Estimation of DC-DC Converter," 2022 IEEE Applied Power Electronics Conference and Exposition (APEC), Houston, TX, USA, 2022, pp. 324-329, doi: 10.1109/APEC43599.2022.9773482.
3. S. Zhao, Y. Peng, Y. Zhang and H. Wang, "Parameter Estimation of Power Electronic Converters With Physics-Informed Machine Learning," in *IEEE Transactions on Power Electronics*, vol. 37, no. 10, pp. 11567-11578, Oct. 2022, doi: 10.1109/TPEL.2022.3176468.

Автор _____ Швецов Д.А.

Научный руководитель _____ Демидова Г.Л.