

ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНАЛИЗА ПИЛИНГ-БАЛЛОННОЙ НЕУСТОЙЧИВОСТИ ДЛЯ ТОКАМАКА ГЛОБУС-М2

Белоус Ф.В. (СПбПУ им. Петра Великого), Солоха В.В.² (ФТИ им Иоффе),

Ткаченко Е.Е.² (ФТИ им Иоффе)

Научный руководитель – кандидат физико-математических наук, доцент ВШ ФФИ

Яшин А.Ю. (СПбПУ им. Петра Великого)

Консультант – кандидат физико-математических наук, доцент ВШ ПМ и ВФ

Баженов А.Н. (СПбПУ им. Петра Великого)

Введение. Токамаки – это реакторы, направленные на исследование управляемого термоядерного синтеза. Основным режим их работы в настоящее время – режим улучшенного удержания или H-мода характеризуется большими значениями градиента давления плазмы на периферии [1], что является причиной возникновения различных неустойчивостей, в том числе, периферийных локализованных мод (ELM).

ELM приводят к импульсным выбросам частиц и энергии из области удержания на первую стенку и пластины дивертора, что может привести к повреждению установки [2]. Также в плазме токамаков возникают другие явления, такие как колебания предельного цикла (LCO), которые представляют собой циклические колебательные процессы в установившейся плазме [3] и не представляют опасности для установки. При этом LCO сложно отличимы от ELM с помощью диагностик доплеровского обратного рассеяния (ДОР) и D_α [4], что создаёт трудности при изучении процессов, происходящих в H-моде.

Исходя из физической природы этих явлений, их можно классифицировать с помощью расчёта инкремента неустойчивости пилинг-баллонной моды γ (ПБ) с помощью кода BOUT++ [5]. Для этого необходимо сгенерировать диаграмму зависимости значений γ от параметров плазмы, что занимает много времени – порядка 100 CPU часов, так как требует решения дифференциальных уравнений на сложной сетке [6].

Применение машинного обучения позволяет сократить время для получения данных в несколько раз [7], что будет рассмотрено в данном докладе для токамака Глобус-М2 [8].

Основная часть. Инкремент ПБ-неустойчивости γ во время ELM больше, чем во время LCO. Во время наших исследований, исходя из физических закономерностей, наблюдаемых на токамаках и, в частности, на Глобус-М2, мы приняли границу разделения устойчивого состояния плазмы по значению $\gamma = 0.1$ обратного альфвеновского времени.

Для классификации явлений будет решаться задача регрессии – построение модели, позволяющей прогнозировать значение инкремента ПБ-неустойчивости γ на основе параметров плазмы. Данные для общей выборки были получены с помощью моделирования диаграмм ПБ-неустойчивости с использованием кода BOUT++ [6]. В качестве входных данных мы выбрали следующие параметры плазмы:

- ширина и высота пьедестала – параметры профиля давления плазмы;
- треугольность (δ) и вытянутость (κ) – параметры формы плазмы;
- ток по плазме (I_p) и тороидальное поле (B_T) – параметры внешних сил.

Полученная выборка состоит из 10000 элементов для 25 сочетаний дискретных значений параметров δ , κ , I_p и B_T . При обучении данные разбивались на обучающую и тестовую выборки в соотношении 80/20 соответственно.

Для решения вышеописанной задачи использовались следующие модели машинного обучения: random forest regressor (RF), CatBoost [9], multi-layer perceptron (MLP). RF реализован на основе библиотеки SciKit-Learn [10]. Модели MLP реализованы и обучены с помощью PyTorch [11]. Для оптимизации гиперпараметров моделей использовался подход поиска по сетке (GridSearch):

- Для RF: количество деревьев ($n_estimators$), максимальная глубина деревьев (max_depth), минимальное количество “листьев” ($min_samples_leaf$), минимальное количество разделений ($min_samples_split$);
- Для CatBoost: количество итераций, скорость обучения, глубина деревьев ($depth$);
- Для MLP: количество внутренних слоёв и количество нейронов на них.

Предложенные методы позволяют использовать различные подходы к обучению моделей и прогнозированию данных с их помощью. Это позволяет провести бенчмаркинг моделей и выявить оптимальный метод решения поставленной задачи.

Выводы. Удалось достичь значений показателя R^2 на тестовой выборке: для RF $R^2 = 0.85$, для CatBoost $R^2 = 0.91$, для MLP $R^2 = 0.99$.

При это время генерации диаграмм ПБ-неустойчивости сократилось в среднем на 4 порядка: с нескольких дней до нескольких секунд.

Модель MLP прогнозирует данные непрерывно относительно входных параметров, а для RF и CatBoost функция регрессии является кусочно-постоянной, так как в основе этих методов лежат деревья. Поэтому для обучения моделей MLP не обязательна мелкая сетка по параметрам плазмы, чтобы обобщить исходные закономерности с достаточной точностью, что облегчает процесс подготовки данных и формирования обучающей выборки. Исследование показало, что использование RF и CatBoost оправданно, так как требует меньше ресурсов и такие модели меньше подвержены галлюцинациям, а их результат можно легче интерпретировать в силу использования решающих деревьев небольшой глубины.

Настоящая работа поддержана Министерством науки и высшего образования Российской Федерации в рамках государственного задания в сфере науки по проекту № FSEG-2024-0005.

Список использованных источников:

1. Wagner F. A quarter-century of H-mode studies //Plasma Physics and Controlled Fusion. – 2007. – Т. 49. – №. 12B. – С. B1.
2. Connor J. W., Kirk A., Wilson H. R. Edge localised modes (ELMs): experiments and theory //AIP Conference Proceedings. – American Institute of Physics, 2008. – Т. 1013. – №. 1. – С. 174-190.
3. Yashin A. Y. et al. Phenomena of limit-cycle oscillations in the Globus-M spherical tokamak //Nuclear Fusion. – 2018. – Т. 58. – №. 11. – С. 112009.
4. Tokarev A. Y. et al. Application of multi-frequency doppler backscattering for studying edge localized modes at the Globus-M2 tokamak //Plasma Physics Reports. – 2024. – Т. 50. – №. 5. – С. 541-551.
5. Solokha V. V. et al. Classification of Edge Instabilities at Globus-M2 Tokamak //Plasma Physics Reports. – 2023. – Т. 49. – №. 4. – С. 419-427.
6. Dudson B. D. et al. BOUT++: A framework for parallel plasma fluid simulations //Computer Physics Communications. – 2009. – Т. 180. – №. 9. – С. 1467-1480.
7. Heo C. et al. Development of a neural network model for peeling–ballooning stability analysis in the KSTAR tokamak pedestals //Nuclear Fusion. – 2024. – Т. 64. – №. 7. – С. 076031.
8. Minaev V. B. et al. Spherical tokamak Globus-M2: design, integration, construction //Nuclear Fusion. – 2017. – Т. 57. – №. 6. – С. 066047.
9. Prokhorenkova L. et al. CatBoost: unbiased boosting with categorical features //Advances in neural information processing systems. – 2018. – Т. 31.
10. SciKit-Learn: [сайт]. URL: <https://scikit-learn.org> (дата обращения: 15.02)
11. PyTorch: [сайт]. URL: <https://pytorch.org/> (дата обращения: 15.02)