

ПРИМЕНЕНИЕ РЕКУРРЕНТНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ МОДЕЛИРОВАНИЯ ЭЛЕКТРОМЕХАНИЧЕСКИХ ПЕРЕХОДНЫХ ПРОЦЕССОВ

Умаров Г.Е.¹, Прохоров А.В.²

¹ Томский Политехнический Университет, ИШЭ, зр. О-5КМ21, Umarov-ge@outlook.com

² Томский Политехнический Университет, к.т.н., доцент, antonprokhorov@tpu.ru

Введение

Анализ динамической устойчивости генераторов электростанций требует значительных временных затрат, так как в настоящее время основывается на использовании моделей энергосистем большой размерности, представленных системами нелинейных дифференциальных уравнений, для решения которых применяются численные итерационные методы (метод Рунге-Кутты в ПК «Rustab»).

В международной практике для анализа динамической устойчивости энергосистем активно применяются искусственные нейронные сети (ИНС). ИНС используются для классификации случаев нарушения устойчивости [1], адаптивного обнаружения нарушения синхронизма генераторов [2] и прогнозирования характера изменения величин при переходных процессах [3].

Для сокращения времени расчета переходных процессов предлагается использование алгоритмов прогноза временных рядов на базе LSTM-нейронных сетей [4]. Степень сокращения времени расчета зависит от того, какую часть переходного процесса необходимо воспроизвести в программном комплексе для получения корректного прогноза, так как непосредственное прогнозирование временного ряда с помощью ИНС занимает доли секунды (около 330 мс).

Описание алгоритма

Для моделирования электромеханических переходных процессов с учетом действия противоаварийной автоматики был разработан алгоритм. Блок-схема алгоритма представлена на рис. 1.

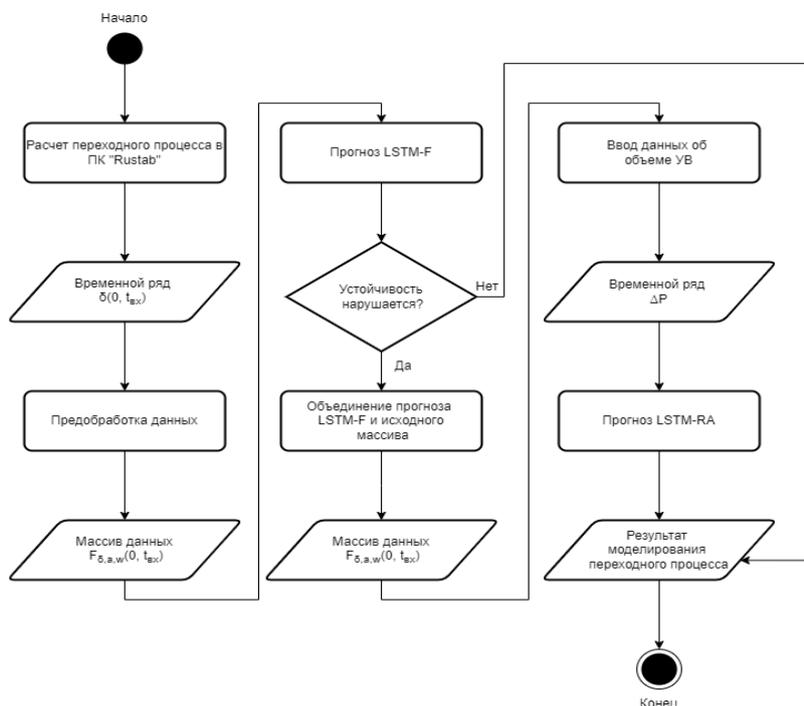


Рис. 1. Блок-схема работы алгоритма.

Алгоритм состоит из следующих основных этапов:

1. Моделирование переходного процесса в ПК «Rustab». На динамической модели ЭЭС производится расчет взаимного угла посредством численного решения дифференциальных уравнений движения, от момента возникновения возмущения ($t = 0$) до момента времени $t_{вх}$ – равного длине окна наблюдения, принятой на этапе обучения нейронной сети. На выходе, получаем временной ряд $\delta = \delta 0 \dots t_{вх}$ в формате csv.

2. В блоке «Предобработка» осуществляется преобразование временного ряда δ в формат DataFrame, производится расчет первой (w) и второй производной (a) целевого признака δ и формирование массива данных F (Features).

3. Подготовленный массив данных F подается на вход ИНС LSTM-F, которая прогнозирует тренд изменения целевых признаков после ликвидации возмущения в пределах от $t_{вх}+1$ до момента времени T , определяющего границу окна прогнозирования LSTM-F. На выходе, получаем массив спрогнозированных данных $F_{пр}$ в формате csv.

4. Объединение массивов F и части массива $F_{пр}$ до момента времени $t'_{вх}$ (граница окна наблюдения LSTM-RA) для получения массива $F + F_{пр}$

5. Формирование в блоке «Учет УВ» целевого признака ΔP , который характеризует изменение суммарной мощности станции после ввода управляющего воздействия (УВ). Для этого из ПК «Rustab» извлекается величина суммарной мощности станции в доаварийном режиме Рд/ав, затем вводятся объем УВ и время его реализации.

6. Подготовленный массив данных $F + F_{пр}$ и целевой признак ΔP подаются на вход LSTM-RA, которая прогнозирует тренд изменения целевых признаков после ввода УВ в пределах от $t'_{вх}$ до момента времени T' , определяющего границу окна прогнозирования LSTM-RA. На выходе, получаем массив спрогнозированных данных $F'_{пр}$ в формате csv.

Алгоритм был детализирован и частично реализован в программе на языке Python.

Апробация алгоритма

Богучанская ГЭС, находящаяся в Красноярской энергосистеме ОЭС Сибири, была выбрана для апробации алгоритма моделирования переходных процессов. В качестве опорного генератора для расчета углов генератора Богучанской ГЭС использовался генератор Красноярской ГЭС, как наименее электрически удаленный.

В целях формирования выборки, наиболее полно описывающей границы динамической устойчивости для обучения модели LSTM-F было сформировано 60 файлов исходных режимов, с учетом диапазона изменения влияющих факторов, приведенного в таблице 1, и 40 сценариев возмущений (короткие замыкания с отключениями основной защитой или действием УРОВ).

Таблица 1

Диапазон изменения факторов, влияющих на границу динамической устойчивости

Влияющий фактор	Диапазон изменения	Шаг
Потребление Кодинской ГПП	20 – 110 МВт	10 МВт
Потребление БоАЗ	465 – 490 МВт	5 МВт
Переток в КС «Тайшет, Ангара – Запад»	2000 – 2400 МВт	100 МВт
Уровень напряжения на шинах 500 кВ Богучанской ГЭС	525 – 520 кВ	1 кВ
Состояние СКРМ на Богучанской ГЭС	0/1	-
Загрузка генерирующего оборудования Богучанской ГЭС	283 – 333 МВт	10 МВт

Переходный процесс был смоделирован для всех комбинаций режимов и сценариев, что привело к формированию 2400 временных рядов. Из этих данных были созданы обучающая, валидационная и тестовая выборки в соотношении 70:10:20.

Для модели машинного обучения заданы следующие параметры: максимальное количество итераций (1500 эпох), количество слоев LSTM (3), размер скрытого слоя (128), длина окна наблюдения (300 мс) и окна прогноза (900 мс). Влияние объема набора данных на качество прогноза представлено в таблице 2.

Таблица 2

Влияние объёма набора данных на качество прогноза и длительность обучения ИНС

Объем набора данных	Объем обучающей выборки	MAE	Время обучения ИНС, ЧЧ:ММ:СС
500	392	0,24	4:00.21
750	525	0,22	5:23.31
1000	700	0,21	6:56.92

1500	1050	0,23	11:37.36
1250	875	0,23	8:22.94
1500	1050	0,23	11:37.36

Так как процесс обучения ИНС автоматизирован и не требует участия специалиста, то для дальнейших расчетов выбран объем выборки данных равный 1000 временных рядов, для которого получено наименьшее значение MAE.

Для обучения LSTM-RA были выбраны комбинации режимов и сценариев, в которых наблюдалось нарушение устойчивости. В сценарии был добавлен последовательный ввод ОГ различных ступеней АПНУ. Таким образом, было набрано 721 временной ряд, но для предотвращения переобучения набор данных был сокращен до 600 временных рядов, чтобы соблюсти соотношение устойчивых случаев к неустойчивым в обучающей выборке.

Параметры модели для LSTM-RA были аналогичны LSTM-F, за исключением длины окна наблюдения (400 мс) и окна прогноза (1000 мс).

Обученные модели показали приемлемую точность прогнозов и соблюдение тренда нарушения или сохранения устойчивости на всех случаях тестовой выборки.

Демонстрация работы алгоритма

Для проверки работоспособности алгоритма, был рассмотрен один из случаев тестовой выборки: значение влияющего фактора в доаварийном режиме – переток 1600 МВт в КС «Тайшет, Ангара – Запад» и возмущение – двухфазное короткое замыкание на землю на КВЛ 500 кВ Богучанская ГЭС – Ангара № 1 вблизи Богучанской ГЭС с отказом выключателя и действием УРОВ. Прогноз LSTM-F представлен на рис. 2.

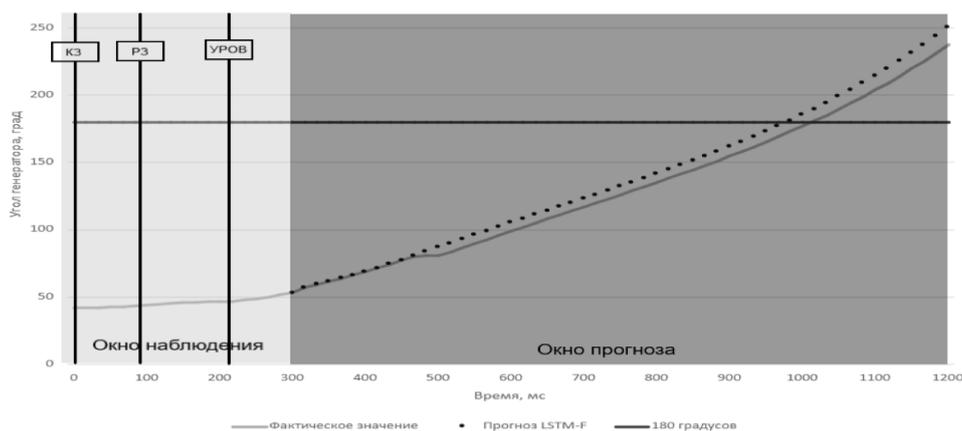


Рис. 2. Прогноз LSTM-F (Нарушение ДУ)

Прогноз LSTM-RA при отключении одного генератора БoГЭС представлен на рис. 3.

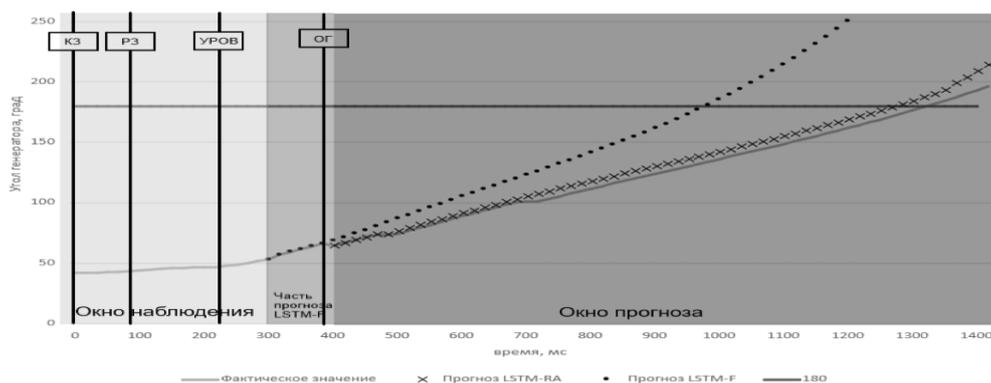


Рис. 3. Прогноз LSTM-RA (Нарушение ДУ)

Прогноз LSTM-RA при отключении двух генераторов БоГЭС представлен на рис. 4.

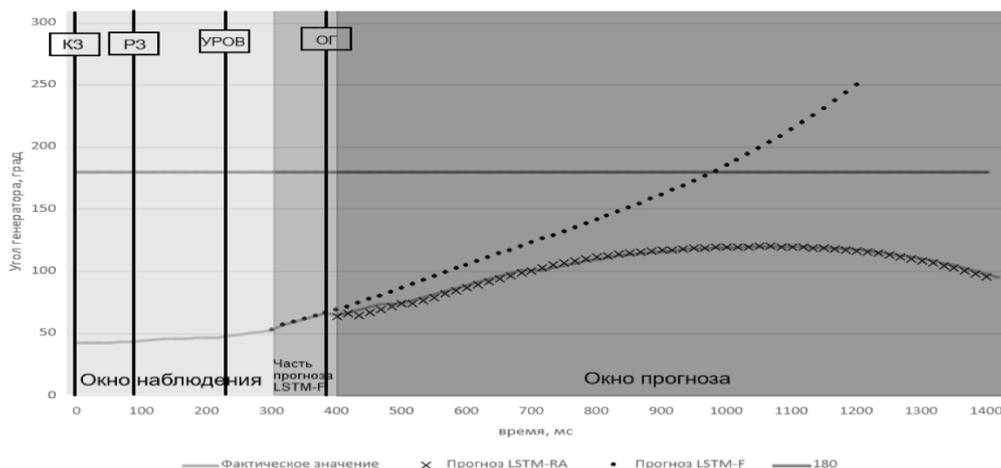


Рис. 4. Прогноз LSTM-RA (Сохранение ДУ)

Заключение

В работе предложен алгоритм моделирования переходных процессов с использованием искусственных нейронных сетей с долгой краткосрочной памятью, позволяющий сократить время расчета изменения угла ротора генератора в программных комплексах в пределах от 38 % для момента нарушения устойчивости 650 мс до 66,6 % для момента нарушения устойчивости 1200 мс. Если для случаев, содержащих нарушение устойчивости, у технолога имеется инструмент, позволяющий остановить моделирование при обнаружении факта нарушения устойчивости, то для случаев сохранения устойчивости – необходимо моделировать окно расчета, заданное технологом, полностью. Для анализа динамики Богучанской ГЭС величина этого окна составляет 5 с. Таким образом, сокращение времени моделирования устойчивого случая составит 94 %. Разработанный алгоритм предполагает также интеграцию с другими ИУС. Например, для сокращения времени расчетного цикла ИУС СМЗУ, для решения задачи определения МДП по критерию отсутствия нарушения устойчивости при нормативном возмущении.

Список использованных источников

1. Wang Q., Pang C., Alnami H. Transient stability assessment of a power system using multi-layer SVM method // 2021 IEEE Texas Power and Energy Conference (TPEC), 2021. – DOI:10.1109/TPEC51183.2021.9384918.
2. Abdelaziz A.Y., Irving M.R., Mansour M.M., El-Arabaty A.M., & Nosseir A.I. Adaptive detection of generator out-of-step conditions in power systems using an artificial neural network // UKACC International Conference on Control, 1996. – No. 427, 132. – DOI: 10.1049/cp:19960546
3. Küçüktezcan C.F., & Genç V.M. A comparison between ANN based methods of critical clearing time estimation // 2013 8th International Conference on Electrical and Electronics Engineering (ELECO), 2013. – No. 140. – DOI: 10.1109/ELECO.2013.6713818
4. Wang Q., Pang C., & Alnami H. Transient stability prediction based on long short-term memory network // 2021 North American Power Symposium (NAPS), 2021. – No. 151. – DOI:10.1109/NAPS52732.2021.9654462.