

**КОНТРОЛЬ СОСТОЯНИЯ ОБЪЕКТОВ ЦИФРОВЫХ ПОДСТАНЦИЙ С ПРИМЕНЕНИЕМ
НЕЙРОННОЙ СЕТИ И ГРАФИЧЕСКИХ УСКОРИТЕЛЕЙ**

А.С. Попов, И.Е. Меняйло, С.Г. Кузнецов

Научный руководитель: доцент, к.т.н. А.В. Обходский

Национальный исследовательский Томский политехнический университет,

Россия, г. Томск, пр. Ленина, 30, 634050

E-mail: asp5@tpu.ru

**CONTROL THE CONDITION OF DIGITAL SUBSTANCES OBJECTS USING NEURAL
NETWORK AND GRAPHIC ACCELERATORS**

A.S. Popov, I.E. Menyailo, S.G. Kuznetsov

Scientific Supervisor: Associate Professor, Ph.D. A.V. Obkhodkiy

Tomsk Polytechnic University, Russia, Tomsk, Lenin str., 30, 634050

E-mail: asp5@tpu.ru

***Abstract.** The paper deals with the problem of monitoring objects of digital substations, which consists in a large amount of data that must be processed. It is proposed to solve this problem by using the neural network as a mathematical model of control, and graphic accelerators as a platform for calculations. The experimentally obtained information confirms the appropriateness of the chosen solutions.*

Введение. Концепция построения цифровой подстанции (ЦПС) подразумевает использование средств и методов, позволяющих предоставить высокую точность параметров контроля текущего состояния объектов ЦПС, а также дать достоверный прогноз будущего состояния. Основной проблемой является большое количество входных данных, которые необходимо анализировать.

Для оценки технического состояния системы при проведении диагностики, пользуются диагностическими параметрами. Для того, чтобы выбрать конкретный параметр, оцениваются свойства, которыми он обладает в каждом конкретном случае технической эксплуатации системы: избыточность информации, достоверность информации и т.д. Практически используются сразу несколько параметров для диагностики одновременно по различным причинам: если узел технической системы обладает несколькими функциями, занимает важнейшее положение в системе, обладает высокой сложностью или большими габаритами и т.д. Также возможен случай, где число параметров может зависеть не от вида прибора, а от уровня развития методов диагностики в технической системе в целом. К примеру, бессмысленно устанавливать интеллектуальное устройство с цифровым выводом на подстанции, если этот вывод некуда подключить.

Оценка технического состояния электрической системы решает задачу оценки состояний отдельных узлов системы, на основе чего делается вывод об их работоспособности. Если состояния соответствуют требованиям, которые диктуют нормативные документы, то оборудование считается исправным, если нет – неисправным. Изготовление, испытания, монтаж, настройка, ремонт и эксплуатация могут сделать из исправного оборудования неисправное [1]. Все эти моменты должны каким-то образом учитываться на цифровой подстанции.

Теоретическое исследование. Поставленную проблему предлагается решить с помощью двух подходов, первый из которых – использование нейронных сетей для проведения необходимых расчетов.

Нейросетевая модель обладает достаточной гибкостью и быстродействием для применения практически на любой цифровой подстанции. Основным недостатком нейронной сети в данном случае является необходимость в обучении, при котором все равно нужно создавать достоверную модель цифровой подстанции. Однако использование нейросетей позволит значительно ускорить расчеты, поскольку основной ресурсозатратный процесс – обучение будет проведен до введения модели в эксплуатацию. Другим преимуществом нейронной сети является возможность проведения процедуры дополнительного обучения на реальном объекте с целью повышения точности моделирования.

Вторым подходом является использование графических ускорителей для проведения необходимых расчетов. Количество контролируемых параметров может достигать 38 только для трансформатора [2]. При этом цифровая подстанция состоит из многих компонентов, каждый из которых обладает определенными параметрами. При этом возникает проблема большого количества данных даже для нейросетевой модели, поскольку весь процесс моделирования должен происходить в условиях реального времени. Графические ускорители способны решить эту проблему, поскольку скорость вычислений при их использовании значительно увеличивается [3].

Экспериментальная часть. Экспериментальный стенд представляет собой сервер с процессором Intel Core i5 4460 и графическим ускорителем GeForce GTX 1070. Программная реализация нейронной сети для графических ускорителей производилась в программном пакете Nvidia Nsight Eclipse Edition с использованием библиотеки cudNN. Для процессора нейронная сеть создавалась и тестировалась в MatLab Simulink. Наборы статистических данных создавались с помощью доработанной модели, представленной в работе [4], составленной в MatLab Simulink. Объектом исследования являлся трансформатор.

Сначала было рассчитан массив с 1000 наборов напряжения на вторичной обмотке трансформатора. Наборы необходимы для обучения нейронной сети. Для наглядности преимущества использования графических ускорителей, обучение происходило последовательно со 100, 200, 400, 600, 800 и 1000 наборами с соответствующими замерами времени. Один набор представлял собой 1000 значений для одного периода колебания напряжения за 10 периодов до возможного выхода из строя. Каждому набору соответствовала температура наиболее нагретой точки трансформатора в момент начала считывания значений. Наконец, каждому набору из значений напряжения и температуры ставилось в соответствие число 0 или 1, что соответствовало работоспособности или неработоспособности трансформатора спустя 10 периодов. В итоге примерно в 50% случаев трансформатор выходил из строя. Для оценки работоспособности нейронной сети были созданы 10 аналогичных наборов.

Результаты и обсуждение. На обучение нейронной сети из всех 1000 наборов процессору понадобилось 3248,3 с, графический ускоритель справился с этой задачей за 18,7 с. Время, потраченное на обучение остальных вариантов, представлено на рисунке 1. Показано именно время обучения, а не время обработки, поскольку обработка со столь малым количеством данных происходит приблизительно одинаково.

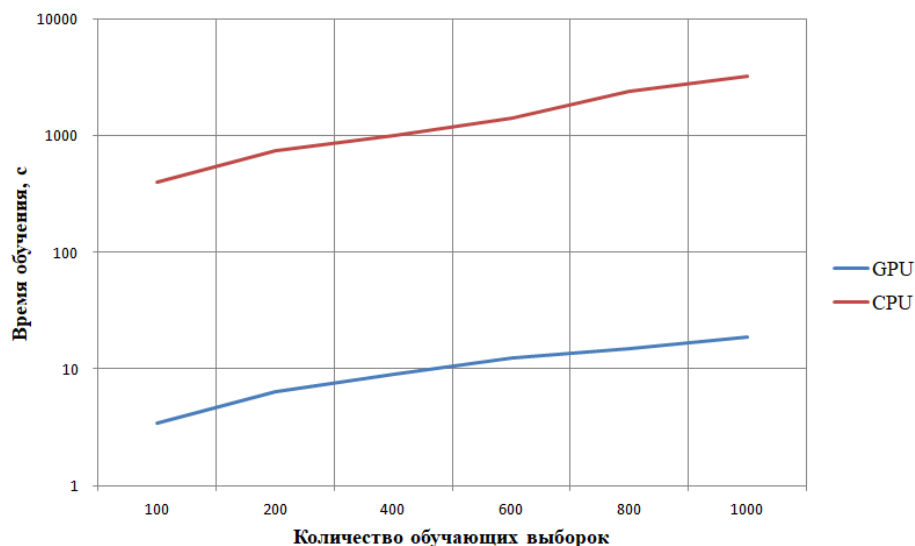


Рис.1. Сравнение времени обучения нейронной сети

Время анализа контрольных 10 наборов составило 0,07 сек. Верно предсказано 10 из 10 случаев.

Принцип распараллеливания расчетов обуславливает большую разницу во времени. Поскольку GPU обладает гораздо большим количеством ядер, чем CPU, расчеты происходят значительно быстрее.

Заключение. Эффективность использования нейросетевого анализа данных была экспериментально установлена, поскольку было верно предсказано 100% случаев. В совокупности со скоростью расчета на графических ускорителях это подтверждает перспективность использования выбранных подходов для проведения анализа данных на цифровых подстанциях.

Работа выполнена при финансовой поддержке Министерства образования и науки Российской Федерации, уникальный идентификатор работ (проекта) RFMEFI57818X0272.

СПИСОК ЛИТЕРАТУРЫ

1. Сви П.М. Методы и средства диагностики оборудования высокого напряжения. – М.: Энергоатомиздат, 1992. – 240 с.
2. Вдовико В.П. Методология системы диагностики электрооборудования высокого напряжения // Электричество. – 2010. – № 2. – С. 14–20.
3. Dyachkov E.V., Kazaryan M.A., Obkhodskiy A.V., Obkhodskaya E.V., Popov A.S. & Sachkov V.I. Algorithm for Processing and Analysis of Raman Spectra using Neural Networks // Bulletin of the Lebedev Physics Institute. – 2018. – Vol. 45. – № 11. – pp. 331–333.
4. Андреев М.В., Рубан Н.Ю., Суворов А.А. Математическое моделирование цифровой дифференциальной защиты трансформатора в среде Matlab Simulink // Энергетика. – 2018. – № 22. – С. 134–150.