

*Норов П.А.,
курсант 5 курс, факультет
«Радиотехнические комплексы»
Ярославское высшее военное училище противовоздушной обороны
Россия, Ярославль*

**ПЕРСПЕКТИВНЫЕ ВИДЫ ИДЕНТИФИКАЦИИ
ТЕХНИЧЕСКОГО СОСТОЯНИЯ РЭТ РТВ С ПРИМЕНЕНИЕМ
СРЕДСТВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА**

Аннотация: В статье рассмотрены виды нейросетей основанная на результатах исследований контролируемых параметров технического состояния РТС РТВ в реальном масштабе времени в автоматическом режиме решается задача идентификации их фактических (текущих) технических состояний

Ключевые слова: аномалии, нейросети, обучаемая модель, алгоритмы, техническое состояние, идентификация.

Annotation: The article considers the types of neural networks based on the results of studies of the controlled parameters of the technical state of the RTS RTV in real time in automatic mode, the problem of identifying their actual (current) technical states is solved.

Keywords: anomalies, neural networks, trainable model, algorithms, technical condition, identification.

В целях улучшения оборона способности армии России стали актуальны разработки в сфере искусственного интеллекта и разработки нейросетей, для обслуживания и поддержание в постоянной боевой готовности радиоэлектронной техники. Суть данного подхода заключается в нахождении

неполадок, ведущих к деградации системы на ранних этапах, до её отказа с использованием искусственного интеллекта. Данный подход не исключает полностью ручной мониторинг системы. Он является вспомогательным для процесса мониторинга в целом.

Основным инструментом реализации предиктивного обслуживания является задача поиска аномалий во временных рядах, так как при возникновении аномалии в данных велика вероятность того, что через некоторое время возникнет сбой или отказ. Аномалия – это некоторое отклонение показателей программной системы, такое как выявление деградации скорости выполнения запроса одного вида или снижение среднего числа обслуживаемых обращений при постоянном уровне клиентских сессий.

Задача поиска аномалий для программных систем имеет свою специфику. По идее для каждой программной системы необходима разработка или доработка имеющихся методов, так как поиск аномалий очень зависит от данных, в которых он производится, а данные программных систем очень различаются в зависимости от инструментов реализации системы вплоть до того, под какой вычислительной машиной она запущена.

Основная логика для поиска аномалий при помощи данных нейронных сетей изображена на рисунке 1:



Рисунок 1. Поиск аномалий при помощи нейросети.

На результате прогноза или восстановления окна текущего потока метрик рассчитывается отклонение от полученного с работающей программной системы. В случае большой разницы между полученными метриками от программной системы и нейронной сети можно делать вывод об аномальности текущего отрезка данных. Возникает следующий ряд проблем

для использования нейронных сетей: для корректной работы в потоковом режиме данные для обучения моделей нейронных сетей должны включать в себя только «нормальные» данные; необходимо иметь актуальную модель для корректного обнаружения.

Также нельзя забывать о поиске и предотвращении частого возникновения ложных срабатываний. Предполагается, что они будут чаще всего возникать в нештатных ситуациях. Однако они могут быть и следствием ошибки нейронной сети по причине недостаточности её обучения. Необходимо минимизировать количество ложных срабатываний модели.

Рекуррентная нейронная сеть

Для обнаружения аномалий во временных рядах можно применить рекуррентную нейронную сеть с памятью LSTM. Проблема есть лишь в том, что она может применяться только для прогнозируемых временных рядов. В нашем случае не все метрики являются прогнозируемыми. Попытка применить RNN LSTM для временного ряда представлена на рисунке 2.

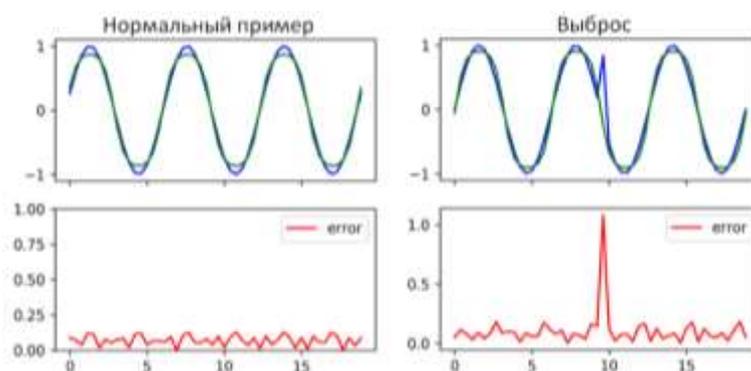


Рисунок 2. Пример работы рекуррентной нейронной сети с ячейками памяти LSTM.

Как видно из рисунка 2, RNN LSTM удалось справиться с поиском аномалии на данном участке времени. Там, где результат имеет высокую ошибку прогнозирования (mean error), действительно произошла аномалия по показателям. Использование одной RNN LSTM явно будет недостаточно,

поскольку она применима к малому количеству метрик. Можно использовать как вспомогательный метод поиска аномалий.

Автокодировщик для прогнозирования отказов

Автокодировщик – по сути искусственная нейронная сеть. Входной слой – encoder, выходной слой – decoder. Недостаток всех нейросетей данного типа – плохо локализует аномалии. Была выбрана архитектура синхронного автокодировщика.

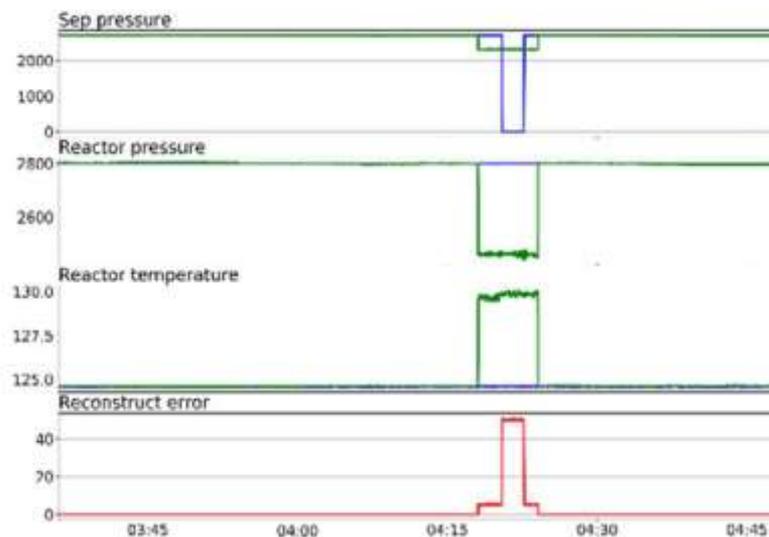


Рисунок 3. Пример работы автокодировщика.

Автокодировщики обучаются на нормальных данных и затем находят, что-то аномальное в подаваемых в модель данных. Как раз то, что нужно для данной задачи. Остается только выбрать, какой из автокодировщиков подойдет для данной задачи. Архитектурно простейшая форма автокодировщика представляет собой прямую, невозвратную нейронную сеть, которая очень похожа на многослойный персептрон (multilayer perceptron, MLP), с входным уровнем, уровнем выхода и одним или несколькими скрытыми слоями, соединяющими их.

Задача автокодировщика заключается в нахождении временных индексов $r_0 \dots r_n$, соответствующих аномальным элементам во входном векторе X . Данный эффект достигается за счет поиска квадратичной ошибки.

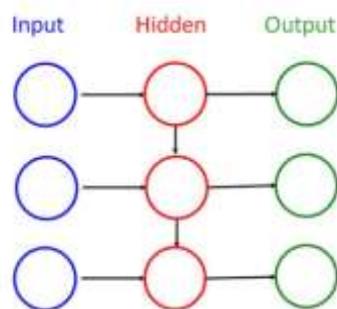


Рисунок 4. Синхронный автокодировщик

Для автокодировщика была выбрана синхронная архитектура. Её преимущества: возможность использования потокового режима обработки и сравнительно меньшее количество параметров нейронной сети относительно других архитектур.

Механизм минимизации ложных срабатываний

В связи с тем, что возникают различные нештатные ситуации, а также возможна ситуация недостаточного обучения нейронной сети, для разрабатываемой модели обнаружения аномалий было принято решение о необходимости разработки механизма минимизации ложных срабатываний. Этот механизм основан на базе шаблонов, которую классифицирует администратор.

Основной принцип минимизации ложных срабатываний – это сбор базы эталонов при помощи оператора, который классифицирует подозрительные случаи, обнаруженные при помощи нейросетей. Далее происходит сравнение проклассифицированного эталона с тем случаем, который обнаружила система, и делается вывод о принадлежности случая к ложному либо приводящему к сбою.

Анализ современных диагностических систем свидетельствует о том, что существует объективная научно-техническая проблема создания комплексных систем диагностирования, построенных на универсальных принципах, обеспечивающих высокий уровень достоверности постановки диагноза и прогнозирования технического состояния изделий.

Перспективным направлением является создание инфраструктуры диагностирования неисправностей изделий, основанной на использовании искусственных нейронных сетей.

Искусственные нейронные сети (ИНС) в задачах диагностирования и прогнозирования технического состояния изделий могут быть использованы в качестве подсистемы выборки и принятия решений, передающей диагностическую информацию другим подсистемам управления.

Задачи прогнозирования отказов изделий сложны из-за невозможности четкой постановки соответствия изменений входных и выходных параметров состояния, в котором находится или к которому стремится объект диагностирования.

Для решения задач диагностирования и прогнозирования необходимо сформировать базу с множеством состояний и произвести оценку степени влияния каждого информационного параметра на вероятность перехода изделия в какое-либо из возможных состояний.

Применение ИНС позволит проводить корректировку значений выходных сигналов объекта диагностирования, что позволит своевременно проводить при необходимости техническое обслуживание (ТО) и текущий ремонт (ТР) для обеспечения его работоспособного состояния.

Использованные источники:

1. Кания Кан. Нейронные сети. Эволюция/ Кания Алексеевич Кан, 2018.-156-183с.
2. Рашид, Тарик. Создаем нейронную сеть. Пер. с англ. — СПб. ООО “Альфа-книга”, 2017. — 272 с.
3. Рудой Г.И. Выбор функции активации при прогнозировании нейронными сетями / Г.И. Рудой // Машинное обучение и анализ данных-2011. С.45-61.