

Исследование эффективности нейросетевых алгоритмов для детектирования неисправностей в гидравлических системах

А.М. Гареев¹, Е.Ю. Минаев^{1,2}, Д.М. Стадник¹, В.И. Проценко^{1,2}, И.А. Попельнюк¹,
А.В. Никоноров^{1,2}, А.Г. Гимадиев¹

¹Самарский национальный исследовательский университет им. академика С.П. Королева, Московское шоссе 34А, Самара, Россия, 443086

²Институт систем обработки изображений РАН - филиал ФНИЦ «Кристаллография и фотоника» РАН, Молодогвардейская 151, Самара, Россия, 443001

Аннотация. В настоящей статье проведено исследование эффективности нейросетевых алгоритмов для детектирования неисправностей в гидравлических системах. Было проведено математическое моделирование типового узла гидравлической системы, по результатам которого были сформированы исходные данные для обучения нейросетевых моделей. Проверка эффективности классификаторов проводилась как на модельных данных, так и в результате стендовых испытаний реальной гидравлической системы. Лучший результат детектирования составил 98% верно распознанных состояний системы.

1. Введение

Согласно исследованию [1], расходы на техническое обслуживание (ТО) оборудования являются основной частью общих эксплуатационных расходов всех производственных предприятий. В зависимости от конкретной отрасли, затраты на ТО могут составлять от 15% до 40% стоимости произведенных товаров. Фактически, эти затраты связаны с трудозатратами на техническое обслуживание и материалы, и в будущем они, вероятно, будут еще выше с внедрением автоматизации производства за счет разработки новых технологий.

В настоящее время разработка стратегии обслуживания подразумевает внедрение информационных технологий в аппаратном и в программном обеспечении технологических комплексов. Предсказательная диагностика основывается на непрерывном мониторинге системы с целью выявления участков или узлов падения производительности и прогнозирования узлов, нуждающихся в обслуживании до отказа.

Большое число исследований посвящено как проблемам мониторинга и получения данных телеметрии технологических комплексов, так и разработке математических моделей и методов обнаружения неисправностей [2, 3, 4, 5, 6]. Так в работах [2, 3] рассмотрены классические подходы на основе математического и имитационного моделирования, цифровой обработки сигналов, тогда как в работах [4, 5] и более поздних рассматриваются подходы к обнаружению и диагностике неисправностей на основе данных. История исследований в этой области восходит к 70-тым годам прошлого века, именно тогда исследования в этой области разделились на такие направления, как диагностика неисправностей на основе математических

моделей, на основе методов обработки сигналов, на основе методов анализа данных, гибридных, а также активных методов диагностики.

В задачах детектирования неисправностей и предиктивной диагностики количество данных от датчиков, как правило, является очень большим. Выявление зависимостей между снимаемыми показаниями и аномалиями в работе системы в этих условиях является сложным процессом, требующим применения экспертных знаний как в области обработки сигналов, так и в области анализируемых систем. С развитием нейросетевых подходов в последние годы стало понятно, что спроектированные ручным образом признаки сигналов уступают по качеству автоматически извлечённым из данных и кроме того требуют немало времени для их создания. Современные технологии сбора и хранения параметров агрегатов позволяют в полную силу применять обучение многослойных нейронных сетей для создания признаков сложно различимых зависимостей в данных в автоматическом режиме.

На текущий день глубокое обучение показывает рекордные результаты качества во многих задачах компьютерного зрения [7], распознавания речи [8], обработки естественного языка [9] и медицинских приложениях [10]. Нейросетевые методы машинного обучения стали также применяться для классификации и предсказания неисправностей в асинхронных электродвигателях [11], промышленных механических [12] и гидравлических [13] агрегатах, в авиационных силовых установках [14].

В данной статье исследована эффективность различных нейросетевых алгоритмов для детектирования неисправностей в типовом гидравлическом узле.

2. Постановка задачи

Для решения задачи детектирования и локализации неисправности будем строить классификатор таким образом, чтобы каждому виду неисправности соответствовал один класс. Исправной системе всегда будет соответствовать нулевой класс, различным неисправностям соответствуют классы от 1 до N . Таким образом, в общем виде задача локализации неисправности сводится к задаче $N+1$ классовой классификации.

Задача классификации решается по данным M датчиков установленным в гидравлической системе. Данные полагаем поступающими равномерно с одинаковой частотой. Если это не так, всегда может быть выполнена интерполяция значений или прореживание. Данные об управляющем воздействии, прилагаемом к системе также полагаем поступающим с некоторого датчика.

Классификация для i -того класса неисправности выполняется по набору из W_i отсчетов измерений датчиков – размеру окна. Размер окна для разных неисправностей может быть различным. В общем виде состояние системы может быть описано в виде класса неисправности c , нулевой класс соответствует исправной системе:

$$c = G(f_i(\mathbf{X}_i, \mathbf{a})), \quad (1)$$

где $X_{W_i} - W_i \times M$ – матрица данных, каждый столбец которого соответствует одному из датчиков, каждая строка – одному измерению; $f_i()$ – классификатор, обнаруживающий i -тую неисправность; \mathbf{a} – вектор параметров классификатора, определяемый в процессе обучения; $G()$ – решающее правило ансамбля классификаторов определяющее общее состояние системы, также настраиваемый в процессе обучения.

Для обучения классификаторов необходимо собрать достаточно большой набор данных по каждой неисправности. Для нескольких типов неисправностей и различных управляющих воздействий это затруднительно даже на стендовой гидравлической системе. В этой связи, в настоящей статье используется подход, основанный на использовании имитационной модели системы для получения исторических данных обучения.

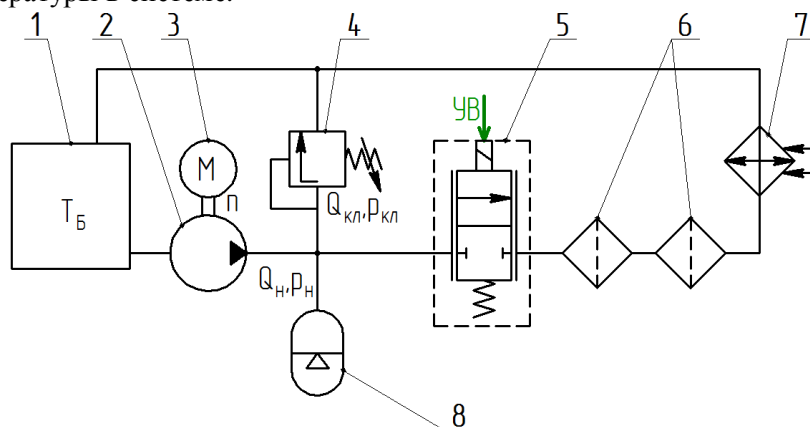
Имитационная модель системы используется для получения данных о возможных неисправностях при различных управляющих воздействиях. Полученные на имитационной модели данные используются для обучения классификаторов (1) и определения их параметров.

Валидация обученной системы выполняется реальными данными о неисправной системе, полученных со стенда.

Предложенный подход на основе комбинации виртуальной имитационной модели гидравлической системы позволяет минимизировать количество стендовых измерений, и при этом позволяет использовать гибкость и универсальность подходов на основе машинного обучения.

3. Математическая модель гидравлической системы

В данной статье исследуется детектирование неисправностей в типовом узле гидравлической системы. На рисунке 1 представлена принципиальная схема системы, обеспечивающей подачу рабочей жидкости с требуемыми параметрами в распределительную и исполнительную подсистемы. Для имитации работы распределительной и исполнительной подсистемы используется двухлинейный двухпозиционный (2/2) пропорциональный распределитель, который при изменении площади проходного сечения приводит к изменению давления, расхода и температуры в системе.



1 - бак; 2 - насос; 3 - электродвигатель; 4 - предохранительный клапан; 5 - двухлинейный пропорциональный распределитель; 6 - фильтр; 7 - теплообменник; 8 - ПГА;
УВ- управляющее воздействие

Рисунок 1. Принципиальная схема ЭГМУ с объектом управления в виде двухлинейного пропорционального распределителя.

При создании систем диагностирования на базе методов машинного обучения требуется большой объем данных, представляющий собой выборки изменяющихся во времени параметров системы при различных ее состояниях. Эти данные могут быть получены на основе теоретических и экспериментальных исследований. Использование расчетных данных, как результатов виртуального моделирования в процессе обучения и настройки нейросетевых классификаторов, может значительно сэкономить временные и материальные ресурсы при диагностике неисправностей.

Для узла гидравлической системы, была разработана его имитационная модель в программном пакете SimulationX (рисунок 2). Разработанная модель позволяет рассчитывать переходные процессы в гидравлическом узле при исправном и неисправном состояниях с учетом различных законов управления пропорциональным распределителем.

Имитационная модель стендового комплекса в первую очередь ориентирована на имитацию четырех состояний ЭГМУ:

- исправное состояние;
- ПГА разряжен;
- внешняя негерметичность трубопровода на выходе из насоса;
- некорректная настройка пружины предохранительного клапана.

Для обучения нейронных сетей были сгенерированы модельные временные ряды параметров гидравлической системы.

нулей (параметр padding равен «casual»). Применение Pooling слоёв позволило сократить количество нейронов между последним свёрточным слоем и полносвязным слоем. Его также применяют для обеспечения инвариантности к ядрам свёрточного слоя, которые в процессе обучения специализируются на определённых особенностях сигнала.

4.3 Описание модели softmax классификатора на основе рекуррентных слоёв

Архитектура softmax_vanilla_lstm состояла из одного рекуррентного LSTM слоя и одного полносвязного слоя. Первый LSTM слой возвращал одномерный тензор, который направлялся далее в слой с функцией активации softmax. Функции активации LSTM слоёв были оставлены по умолчанию: сигмоида для рекуррентной функции активации и гиперболический тангенс для функции активации применяемой к выходному тензору значений. Количество параметров было самым низким из всех рассматриваемых архитектур сетей – 92.

4.4 Описание модели softmax классификатора на основе автокодировщика (softmax_autoencoder)

В данной разновидности классификатора первым слоем являлся составным из конкатенации кодировщиков, обученных на предварительном этапе на тех же данных, на которых обучался сам классификатор. В этой модели использовался классическая архитектура многослойного автокодировщика с сужающимися к центру слоями.

4.5 Описание модели softmax классификатора на основе разреженного автокодировщика (softmax_sparse_autoencoder)

В данной разновидности классификатора первым слоем являлся составным из конкатенации кодировщиков, обученных на предварительном этапе на тех же данных, на которых обучался сам классификатор. В этой модели использовался классическая архитектура многослойного автокодировщика с сужающимися к центру слоями. Архитектура автокодировщика аналогична предыдущему за исключением добавления L1 регуляризации для внутреннего слоя.

4.6 Описание модели softmax классификатора на основе сжимающего автокодировщика (softmax_contractive_autoencoder)

Классификатор, построенный на основе сжимающего автокодировщика. К выходному вектору значений с последнего слоя был добавлен шум, распределённый по нормальному закону распределения.

4.7 Описание модели softmax классификатора на основе шумоподавляющего автокодировщика (softmax_denoising_autoencoder)

Классификатор, построенный на основе шумоподавляющего автокодировщика. К входному вектору значений с последнего слоя был добавлен шум, распределённый по нормальному закону распределения.

4.8 Описание модели softmax классификатора на основе вариационного автокодировщика (softmax_variational_autoencoder)

Классификатор, построенный на основе вариационного автокодировщика [18]. В данном автокодировщике кодировщик обучается отображать входные вектора в вектора из заранее выбранного распределения z , в нашем случае нормального распределения. Сетевая часть кодировщика обучается находить вектор средних μ и вектор стандартных отклонений σ заданной при проектировании архитектуры длины.

5. Результаты экспериментов

Обучение моделей производилось на множестве временных рядов, полученных с помощью разбиения исходных данных на окна со смещением. В случае смоделированных данных размер окна и смещение были 5000 и 500, что дало 159985 примера с размерностями 5000 на 3. Экспериментальные данные были сгенерированы с тем же размером окна, но со смещением 50,

создавшим 41744 примера. Модели обучались с размером батча (количество примеров для которых считается усреднённая ошибка предсказания) равным 64 для всех моделей.

В таблице 1 представлена сводная информация о достигнутой точности(доля верно распознанных состояний) обученных классификаторов на модельных данных.

Таблица 1. Точность классификаторов, полученная на модельных данных.

	softmax dense	softmax conv	softmax conv dilated	softmax vanilla lstm	softmax avgpool lstm	softmax autoencoder	softmax sparse autoencoder	softmax denoising autoencoder	softmax contractive autoencoder	softmax variational autoencoder
Точность	0.92	0.97	0.98	0.90	0.94	0.97	0.95	0.97	0.92	0.97

В таблице 2 представлена сводная информация о достигнутой точности(доля верно распознанных состояний) обученных классификаторов на экспериментальных данных.

Первая модель softmax_dense_simple с линейной функцией активации (которая эквивалентна отсутствию активации) с 3 нейронами на среднем слое, отсутствием регуляризации показывала низкие результаты классификации: 60% на 39997 примерах модельных и 54% на 41704 примерах экспериментальных данных. После добавления функции активации ReLU сразу за первым полносвязным слоем (dense) после обучения в течении 16 эпох точность на модельных данных составила 89% правильно распознанных состояний, точность на экспериментальных данных 87%. Аналогичная сеть, но с 4 нейронами в среднем слое позволила получить высокую точность 97% на модельных данных уже к второй эпохе, однако точность на экспериментальных данных стабильно держалась между 60% и 75%. В данном случае можно сделать вывод, что увеличенная выразительная сила привела к переобучению сети на данных, полученных из SimulationX.

Далее было обучено четыре модели с регуляризацией с различными функциями активаций: ReLU, PReLU, ELU и SELU. После применения L2 регуляризации с коэффициентом 0.1 к матрице весов среднего слоя (dense) обучаемые нейронные сети стабильно показывали точность выше 74% на экспериментальных данных во время обучения с самого начала. Для ReLU значения точности поднялись до 91% на модельных данных и 87% на экспериментальных. Регуляризация была ключевым фактором в достижении хорошей точности и обобщающей способности. Максимальную точность 92% на экспериментальных данных удалось получить при использовании SELU.

На основе полученных данных можно сделать вывод что нейросетевые модели хорошо обучаются на данных по виртуальным моделям. Лучший результат распознавания данных по виртуальным моделям составил 98% для архитектуры softmax conv dilated.

При этом, для анализа неисправностей в реальных системах важнее точность полученная при тестировании на предварительно записанных экспериментальных данных.

Точность нейросетевых классификаторов, обученных на массивах данных виртуальной модели гидравлического узла при распознавании его неисправности по массивам экспериментальных данных, полученных во время испытаний на стенде составляет 92%, для сравнения метод опорных векторов с радиально-базисным ядром на идентичных данных показал 78% точности. Это подтверждает преимущество применения нейросетевых методов классификации для практического детектирования неисправностей в гидравлических системах. По результатам экспериментальных исследований, в качестве рабочей нейросетевой архитектуры была выбрана softmax_dense.

В процессе стендовых испытаний было исследовано влияние усреднения результатов распознавания методом голосования в скользящем окне во временной области. Применение

усреднения на 10 секундном периоде позволило улучшить результаты классификации с 92 до 98% точности, за счёт устранения случайных выбросов параметров системы.

Таблица 2. Точность классификаторов, полученная на экспериментальных данных.

	softmax dense	softmax conv	softmax conv dilated	softmax vanilla lstm	softmax avgpool lstm	softmax autoencoder	softmax sparse autoencoder	softmax denoising autoencoder	softmax contractive autoencoder	softmax variational autoencoder
Точность	0.92	0.88	0.56	0.84	0.88	0.79	0.78	0.85	0.84	0.85

6. Выводы

В данной работе проведены исследования эффективности нейросетевых алгоритмов для детектирования неисправностей в гидравлических системах. Выбрана оптимальная архитектура нейронной сети для детектирования неисправностей на реальной стендовой гидравлической системе при обучении сети на имитационной модели. С учётом усреднения результатов детектирования 10-секундным окном получена точность 98% верно распознанных состояний гидравлической системы.

7. Благодарности

Работа выполнена в рамках государственного задания по теме FSSS-2020-0017. При частичной поддержке РФФИ (проекты № 17-29-03112-офи-м, 19-29-01235-мк, 16-29-11744-офи-м, № 16-29-09528-офи-м, № 18-07-01390-а). Экспериментальные исследования выполнены в рамках госзадания ИСОИ РАН - филиал ФНИЦ "Кристаллография и Фотоника" РАН (соглашение № 007-ГЗ/Ч3363/26).

8. Литература

- [1] Mobley, R.K. An Introduction to Predictive Maintenance – New York: Van Nostrand Reinhold, 1990.
- [2] Gao, Z. A Survey of Fault Diagnosis and Fault-Tolerant Techniques - Part I: Fault Diagnosis With Model-Based and Signal-Based Approaches / Z. Gao, C. Cecati, S. X. Ding // IEEE Transactions on Industrial Electronics. – 2015. – Vol. 62(6). – P. 3757-3767.
- [3] Gao, Z. A Survey of Fault Diagnosis and Fault-Tolerant Techniques - Part II: Fault Diagnosis With Knowledge-Based and Hybrid/Active Approaches / Z. Gao, C. Cecati, S. X. Ding // IEEE Transactions on Industrial Electronics. – 2015. – Vol. 62(6). – P. 3768-3774.
- [4] Isermann, R. Model-based fault-detection and diagnosis - Status and applications //Annu. Rev. Control. – 2005. – Vol. 29(1). – P. 71-85.
- [5] Schrick, D. Remarks on terminology in the field of supervision, fault detection and diagnosis / D. Schrick // Proc. IFAC Symp. Fault Detection, Supervision Safety Techn. Process – Hull, U.K., 1997. - P. 959-964.
- [6] Кропотов, Ю.А. Метод прогнозирования изменений параметров временных рядов в цифровых информационно-управляющих системах / Ю.А. Кропотов, А.Ю. Проскураков, А.А. Белов // Компьютерная оптика. – 2018. – Т. 42, № 6. – С. 1093-1100. DOI: 10.18287/2412-6179-2018-42-6-1093-1100.
- [7] Long, J. Fully convolutional networks for semantic segmentation / J. Long, E. Shelhamer, T. Darrell // Proceedings of the IEEE conference on computer vision and pattern recognition, 2015. – P. 3431-3440.
- [8] Devlin, J. Bert: Pre-training of deep bidirectional transformers for language understanding // arXiv preprint arXiv: 1810.04805, 2018.

- [9] Bahdanau, D. End-to-end attention-based large vocabulary speech recognition // IEEE international conference on acoustics, speech and signal processing (ICASSP), 2016. – P. 4945-4949.
- [10] Litjens, G. A survey on deep learning in medical image analysis // Medical image analysis. – 2017. – Vol. 42. – P. 60-88.
- [11] Sun, W. A sparse auto-encoder-based deep neural network approach for induction motor faults classification // Measurement. – 2016. – Vol. 89. – P. 171-178.
- [12] Qi, Y. Stacked sparse autoencoder-based deep network for fault diagnosis of rotating machinery // IEEE Access. – 2017. – Vol. 5. – P. 15066-15079.
- [13] Lu, C. Fault detection for hydraulic pump based on chaotic parallel RBF network / C. Lu, N. Ma, Z. Wang // EURASIP Journal on Advances in Signal Processing. – 2011. – Vol. 2011(1). – P. 49.
- [14] Yuan, M. Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network / M. Yuan, Y. Wu, L. Lin // IEEE International Conference on Aircraft Utility Systems (AUS), 2016. – P. 135-140.
- [15] Kingma, D.P. Adam: A method for stochastic optimization / D.P. Kingma, J. Ba // arXiv preprint arXiv: 1412.6980, 2014.
- [16] Klambauer, G. Self-normalizing neural networks // Advances in neural information processing systems, 2017. – P. 971-980.
- [17] Nair, V. Rectified linear units improve restricted boltzmann machines / V. Nair, G.E. Hinton // Proceedings of the 27th international conference on machine learning (ICML-10). – 2010. – P. 807-814.
- [18] Kingma, D.P. Auto-encoding variational bayes / D.P. Kingma, M. Welling // arXiv preprint arXiv: 1312.6114, 2013.

Investigation of the effectiveness of neural network algorithms for the faults detection in hydraulic systems

A.M. Gareev¹, E.Yu. Minaev^{1,2}, D.M. Stadnik¹, N.S. Davydov^{1,2}, V.I. Protsenko^{1,2},
I.A. Popelniuk¹, A.V. Nikonorov^{1,2}, A.G. Gimadiev¹

¹Samara National Research University, Moskovskoe Shosse 34A, Samara, Russia, 443086

²Image Processing Systems Institute of RAS - Branch of the FSRC "Crystallography and Photonics" RAS, Molodogvardejskaya street 151, Samara, Russia, 443001

Abstract. This article investigates the effectiveness of neural network algorithms for detecting faults in hydraulic systems. Mathematical modeling of a typical unit of a hydraulic system was carried out, according to the results of which initial data were generated for training neural network models. The effectiveness of classifiers was tested both on model data and as a result of bench tests of a real hydraulic system. The best detection result was 98% of correctly recognized system states.