

# АЛГОРИТМЫ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ДИАГНОСТИРОВАНИЯ ГИДРОМЕХАНИЧЕСКИХ СИСТЕМ ПО ДИНАМИЧЕСКИМ ХАРАКТЕРИСТИКАМ

**А.М. Гареев**

*Самарский национальный исследовательский университет имени академика С.П. Королёва*  
Россия, 443086, Самара, Московское шоссе, 34  
E-mail: gareyev@ssau.ru

**А.Б. Прокофьев**

*Самарский национальный исследовательский университет имени академика С.П. Королёва*  
Россия, 443086, Самара, Московское шоссе, 34  
E-mail: prok@ssau.ru

**Е.В. Шахматов**

*Самарский национальный исследовательский университет имени академика С.П. Королёва*  
Россия, 443086, Самара, Московское шоссе, 34  
E-mail: shakhmatov.ev@ssau.ru

**Ключевые слова:** алгоритм, машинное обучение, гидромеханическая система, имитационная модель, сравнительный анализ.

**Аннотация:** Проблема автоматического диагностирования гидромеханических систем, ориентированная на обеспечение надежности, сегодня приобретает все большее значение. В этой работе сравнивается точность четырех подходов машинного обучения для обнаружения неисправностей в типовой гидромеханической системе. Первые три подхода основаны на SVM-классификаторах с линейным, полиномиальным и RBF-ядрами, а последний - на градиентном ускорении на деревьях решений, на каждом уровне которых находятся разбиения по одному и тому же признаку и одному и тому же числу. Алгоритмы сравниваются на синтетическом наборе данных, сгенерированных разработанной имитационной моделью типовой гидромеханической системы. Показана возможность достижения высокой точности обнаружения неисправностей.

## 1. Введение

Проблема обеспечения надежности и повышения эффективности технологического процесса технического обслуживания (ТО) гидромеханических систем (ГМС) является основной задачей организаций, эксплуатирующих современную авиационную технику. В целях оперативного обеспечения оценки технического состояния ГМС актуальной является задача разработки и внедрения новых интеллектуальных методов ТО. Важно обеспечить возможность мониторинга как всей ГМС в целом, так и основных ответственных ее узлов по отдельности.

За последние два десятилетия учеными было предложено несколько методов диагностики неисправностей [1-3], что позволяет сейчас сравнивать и анализировать их эффективность [4, 5].

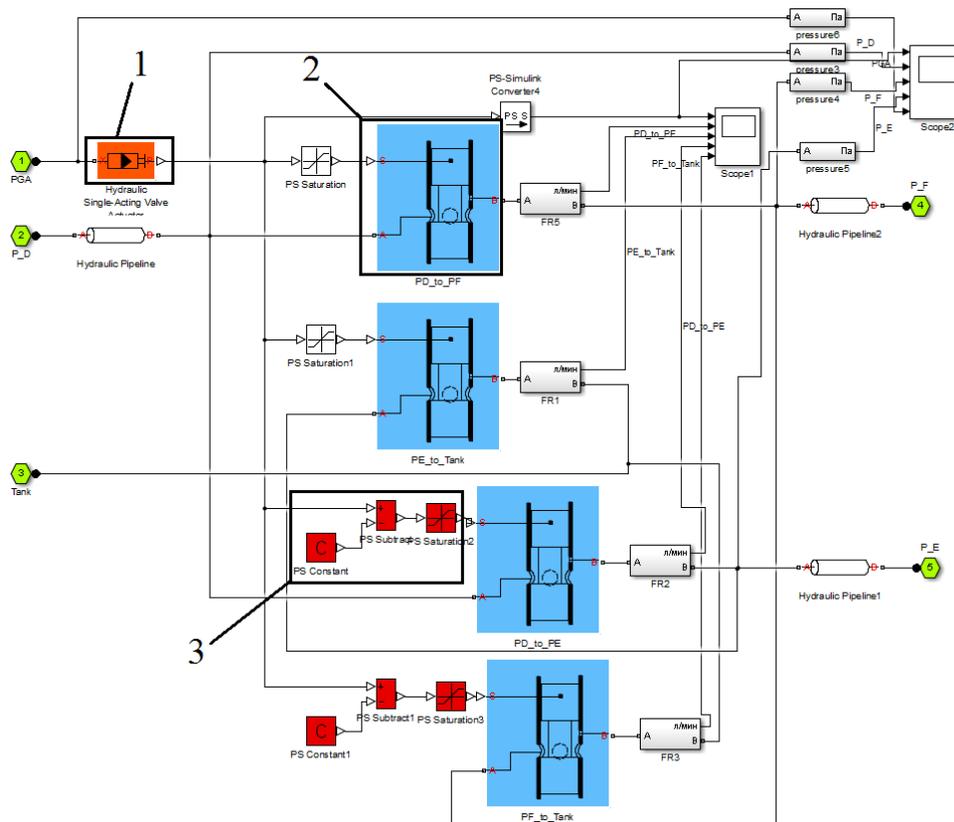
Одним из возможных подходов к решению вопроса автоматизации технологического процесса ТО по состоянию авиационных ГМС является применение

методов машинного обучения. В работе Чжонгай и др. [1] представлен обзор способов диагностики различных типов неисправностей ГМС посредством применения одного из наиболее популярного метода обучения для решения задач классификации и регрессии – метода опорных векторов (англ. Support Vector Machine, SVM). Эль-Бетар и др. [2] на основе данных датчика вибрации применили метод описания данных опорного вектора (англ. Support Vector Data Description, SVDD) для обнаружения неисправностей в трансмиссии вертолета. Нелинейные модификации SVM применительно к этой задаче подробно изучены Леушеном и др. [3]. Нейронные сети также начали использоваться в качестве методов диагностики неисправностей [4].

## 2. Имитационная модель гидромеханической системы

Модель гидравлической системы вертолета Ми-8 была разработана на основе данных, изложенных в работах [6, 7]. Модель представляет собой систему дифференциальных и алгебраических уравнений, запрограммированных в Matlab/Simscare, для моделирования динамического поведения системы при различных управляющих воздействиях.

На рисунке 1 представлена структурная схема клапана командного управления автомата разгрузки насоса ГА-77, реализованная в Matlab/Simscare. Для моделирования всей системы каждая модель имеет входные и выходные порты для подключения.



1 – модель гидравлического привода клапана одностороннего действия; 2 – модель регулируемого дросселя, состоящего из золотника и гильзы с рядом круглых отверстий; 3 – элементы, имитирующие зону нечувствительности золотника

**Рис. 1.** Реализация математической модели функционирования командного золотника ГА-77 в программе Matlab/Simscare.

Мы выбрали для диагностики системы динамический портрет, который состоит из следующих характеристик: давление после насоса, давление в линии накопления, входное давление привода, расход на выходе насоса, расход на выходе ГА-77 в систему, расход на входе в систему привод, абсолютное перемещение золотникового поршня, абсолютное перемещение штока.

Набор данных был сгенерирован для четырех случаев: рабочее состояние, разряженный аккумулятор, снижение объемного КПД на 10% и утечка гидравлической жидкости.

На рис. 2 представлены процессы изменения давления на выходе насоса и в линии нагнетания для исправной и неисправной ГМС с разряженным аккумулятором.

Синусоидальная функция использовалась в качестве входного командного сигнала для золотника со скоростью перемещения, равной 40 мм/с. Моделирование нагрузки на шток привода выполняется пружиной с жесткостью, равной 215 кН/м.

В следующей части статьи мы представляем результаты сравнения точности моделей машинного обучения в задаче обнаружения неисправностей. Мы используем синтезированный набор данных для обучения классификаторов, примеры которых показаны на рис. 3.

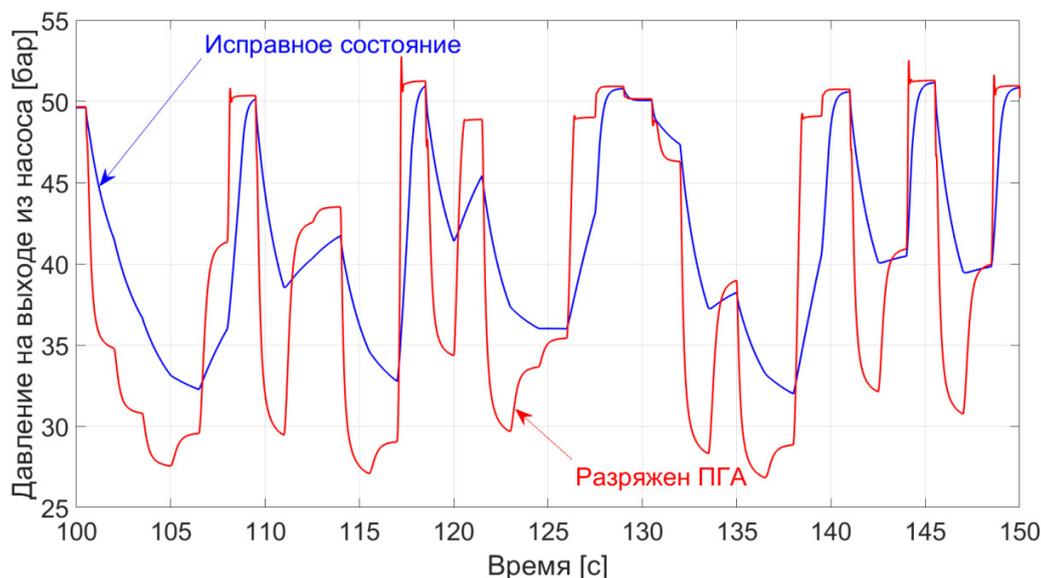


Рис. 2. Переходные процессы изменения давления на выходе из насоса для исправного и неисправного ГМС - разряженный ПГА.

### 3. Методы классификации для обнаружения неисправностей

Мы применили два подхода: kernelized SVM и gradient boosting, которые используют забывчивые деревья решений в качестве базовых предикторов. Для определения характера распределения векторов признаков в классификаторе использовались модификации с различными ядрами: линейным, полиномиальными, радиальными базисными функциями.

Алгоритм CatBoost является современной реализацией метода градиентного бустинга, использующего в качестве слабых предсказывающих моделей особый вид деревьев решений (oblivious decision trees). Задача обучения заключается в подборе функции, минимизирующей функцию ошибки  $\mathcal{L}(F) := EL(y, F(x))$ . Для бинарной классификации на наличие неисправности в качестве использовалась функция Logloss (1):

$$(1) \quad \mathcal{L} = \frac{\sum_{i=1}^N w_i (c_i \log(p_i) + (1-c_i) \log(1-p_i))}{\sum_{i=1}^N w_i},$$

где  $N$  – количество объектов;  $w_i$  – вес  $i$ -ого объекта;  $c_i$  – бинарный индикатор корректности предсказания неисправности  $i$ -ого объекта;  $p_i$  – вероятность того, что  $i$ -ый объект принадлежит к классу неисправности.

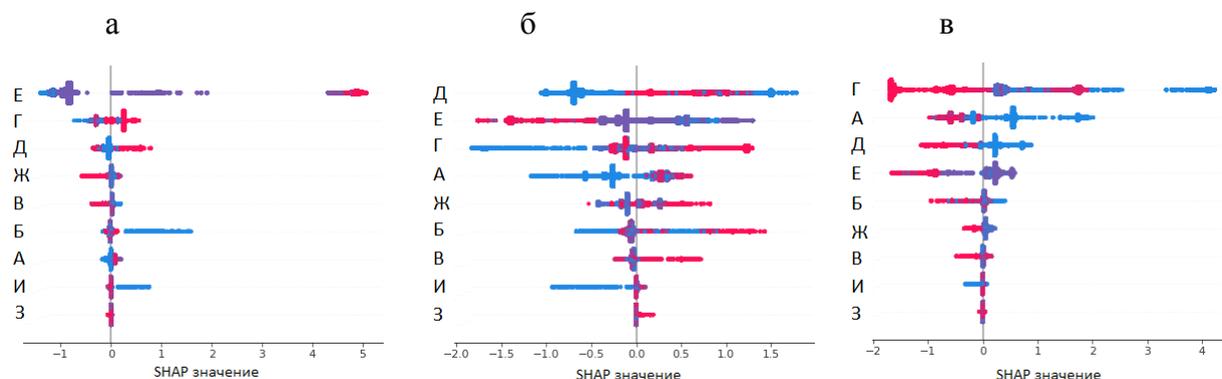
## 4. Результаты

Набор данных содержит 6 смоделированных подмножеств из 9 временных рядов: сценарий разряженного ПГА, сценарий снижения объемного КПД насоса на 10%, сценарий гидравлической утечки и 3 соответствующих рабочих подмножества. Каждое подмножество включает в себя 400 тыс. выборок, которые были разделены на обучающие/проверочные подмножества в соответствии с процентным соотношением 80/20. Все параметры классификатора Cat Boost были оставлены по умолчанию, за исключением количества итераций, которое было установлено равным 200. Это число было уменьшено, поскольку этого было достаточно для получения очень хороших результатов при гораздо меньшем времени тренировок. В таблице 1 представлены основные результаты экспериментов. Видно, что чем более сложные методы мы используем, тем лучше результаты.

Таблица 1. Сравнение результатов распознавания для бинарной классификации.

Метод	Доля верно распознанных неисправностей
SVM, линейное ядро	0.571
SVM, полиномиальное ядро	0.613
SVM, радиальное базисное ядро	0.853
Cat Boost	0.993

Детектирование неисправности утечки воздуха из газовой полости ПГА является более сложным по сравнению с другими неисправностями. 8 из 9 параметров обладают влиянием на решение (SHAP значение) большим 0,5 и их влияние примерно одинаково, в отличие от других классов. Самым важным выходным параметром для этого класса является объемный расход жидкости на выходе из автомата разгрузки. Вторым и третьим по влиянию являются расход жидкости на входе в гидроусилитель и на выходе из насоса.



**Рис. 3.** Влияние входных параметров на предсказание класса CatBoost моделью: (а) утечка жидкости из ГУ, (б) полная разрядка ПГА, (в) снижение КПД насоса на 10 % .

На рис. 3 входные параметры следующие: А – давление на выходе насоса, Б – давление в линии ПГА, В – давление на входе в гидроусилитель, Г – расход на выходе из насоса, Д – расход на выходе из ГА-77 в систему, Е – расход на входе в гидроусилитель, Ж – расход в линии ПГА, З – абсолютное перемещение золотника гидроусилителя, И – абсолютное перемещение штока гидроцилиндра. Значения параметра возрастают от синего цвета к красному

Обученная модель придавала большую роль объемному расходу и давлению жидкости на выходе из насоса, а также расходу жидкости на выходе из автомата разгрузки при детектировании неисправности, связанной с падением КПД насоса на 10%. Сильным признаком данной неисправности были низкий расход жидкости на выходе из насоса от 26,43 до 28,26 л/мин и высокое давление в линии на выходе из насоса выше 4,3 МПа. В 4 раза меньший вклад в уверенность модели в наличие неисправности вносило отсутствие расхода жидкости за автоматом разгрузки. Остальные параметры на решение влияли слабо.

Также было проведено тестирование лучшего классификатора SVM (радиальное базисное ядро) обученного на модельных данных с меньшим количеством входных параметров (давление, расход, управляющее воздействие) для отдельного узла ГМС. Достигнутая точность составила 78%. Cat Boost при аналогичных условиях показал 75%. Таким образом, можно сделать вывод об эффективности SVM по сравнению с Cat Boost при малом количестве параметров в исходных данных.

## 5. Заключение

Результаты показывают, что методы машинного обучения являются правильным способом решения задачи обнаружения неисправностей. Методы, основанные на SVM, с нелинейным ядром RBF, позволяют достичь точности 0,853. Более сложный метод, градиентное усиление на забывчивых деревьях, повышает точность классификации до 0,993. Цена использования сложных методов – их нечеткая интерпретируемость. Эта проблема может быть решена с помощью недавно разработанных инструментов для объяснения моделей, таких как SHAP [8] и Lime [9].

## Список литературы

1. Zhonghai M. A., Shaoping W. A. N. G., Jian S. H. I. Fault diagnosis of an intelligent hydraulic pump based on a nonlinear unknown input observer // Chinese Journal of Aeronautics. 2018. Vol. 31, No. 2. P. 385-394.
2. El-Betar A., Abdelhamed M, M., El-Assal A., Abdelsatar R. Fault Diagnosis of a Hydraulic Power System Using an Artificial Neural Network // Engineering Sciences. 2006. Vol. 17, No. 1. P. 117-137.
3. Leuschen M. L., Walker I. D., Cavallaro J. R. Nonlinear fault detection for hydraulic systems // Fault diagnosis and fault tolerance for mechatronic systems. 2003. P. 169-191.
4. Чиликин А.А. Сравнительный анализ современных методов диагностики состояния гидравлических систем // Известия ТулГУ. Технические науки. 2014. Вып. 3. С. 117-127
5. Квасников В.П. Методы технического диагностирования гидроагрегатов летательных аппаратов // Вестник инженерной академии Украины. 2010. № 3-4. С. 21-25.
6. Попов Д.Н. Механика гидро- и пневмоприводов. М.: Изд-во МГТУ им. Н.Э. Баумана, 2002. 320 с.
7. <https://www.mathworks.com/help/index.html> (дата обращения: 13.10.2023).
8. Lundberg S.M. A unified approach to interpreting model predictions // Advances in Neural Information Processing Systems. 2017. P. 4765-4774.
9. Ribeiro M.T., Singh S., Guestrin C. “Why Should I Trust You?”: Explaining the Predictions of Any Classifier // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, CA, USA. 2016. P. 1135-1144.