



Оптимизация вероятностных эксплуатационных характеристик нейросетевого алгоритма предиктивной диагностики отказов промышленного оборудования за счёт автоматизированной обработки обучающей выборки

И. В. Некрасов кандидат технических наук, старший научный сотрудник;
ИПУ РАН, г. Москва;
ivannekr@mail.ru

Ю. Д. Константиновский студент;
МГТУ им. Н. Э. Баумана, г. Москва;
uran9000@mail.ru

Н. С. Кукин кандидат технических наук, начальник группы;
АНО ИИФ, г. Серпухов;
n.s.kukin@mail.ru

В работе рассматривается оптимизация вероятностных эксплуатационных характеристик нейросетевого алгоритма предиктивной диагностики неисправностей промышленного оборудования. В качестве оптимизируемых параметров приняты вероятность ложной тревоги и вероятность обнаружения неисправности, являющиеся общепринятыми метриками эффективности систем анализа обстановки и принятия решений. Задача оптимизации эксплуатационных характеристик декомпозирована до уровня влияющих технических параметров системы и сведена к нахождению оптимальных значений базового времени расчёта производных измеряемых технологических параметров и времени развития неисправности. Автоматизированная обработка обучающей выборки позволяет сократить затраты времени на создание системы предиктивной диагностики отказов промышленного оборудования. Приведён результат оптимизации вероятностных эксплуатационных характеристик нейросетевого алгоритма и получены оптимальные значения варьируемых параметров, а также в результате обучения и тестирования на реальных телеметрических данных питающего электронасоса турбоагрегата ТЭЦ получены оптимальные значения оптимизируемых параметров, по которому сделаны выводы и предложены дальнейшие действия для улучшения результата.

Ключевые слова: предиктивная диагностика; нейронная сеть; обучающая выборка; исторические данные; аварийная ситуация; предаварийное состояние; время развития отказа; вероятность пропуска аварии; вероятность ложной тревоги

Цитирование: Некрасов, И. В. Оптимизация вероятностных эксплуатационных характеристик нейросетевого алгоритма предиктивной диагностики отказов промышленного оборудования за счёт автоматизированной обработки обучающей выборки / И. В. Некрасов, Ю. Д. Константиновский, Н. С. Кукин // Динамика и виброакустика. – 2024. – Т. 10, №3. – С. 81-92. DOI: 10.18287/2409-4579-2024-10-3-81-92

Введение

В настоящее время в промышленности большое распространение получили так называемые системы предиктивной диагностики оборудования, принцип работы которых основан на анализе фактических измерений технологических параметров объекта и классификации его

текущего состояния как «нормальное» или «аварийное» («предаварийное»). Детальный обзор систем указанного типа представлен, например, в [1, 2, 3 и проч.]. Исследуя перечисленные обзорные статьи, а также прочие источники, можно прийти к выводу, что несмотря на многообразие применяемых подходов и расчётных методов (таких, например, как экстраполяция временных рядов, математическое моделирование, спектральный и волновой анализ, машинное обучение, геометрические методы и многих других), общими проблемными местами подобных систем остаются всевозможные настроечные параметры применяемых алгоритмов, значения которых, как правило, задаются экспертно или подбираются итеративно [4, 5]. Варьирование настроечных параметров может значительно изменить область применимости выбранного метода диагностики как в сторону улучшения точности результатов расчёта, так и в сторону потери адекватности получаемого результата. В настоящей работе предложена комплексная методика формализации, оценки и оптимизации качества работы алгоритмов предиктивной диагностики. Настоящее исследование проведено на примере нейросетевого алгоритма, однако предложенный подход вполне может применяться к системам рассмотренного типа без ограничений применяемой технологии классификации состояний.

1 Формулировка задачи предиктивной диагностики на базе нейронной сети

Типовая система предиктивной диагностики, построенная на базе алгоритма классификации (в данном случае, основанного на технологии нейронной сети) текущего состояния оборудования, имеет следующую структурную схему [2, 6]:

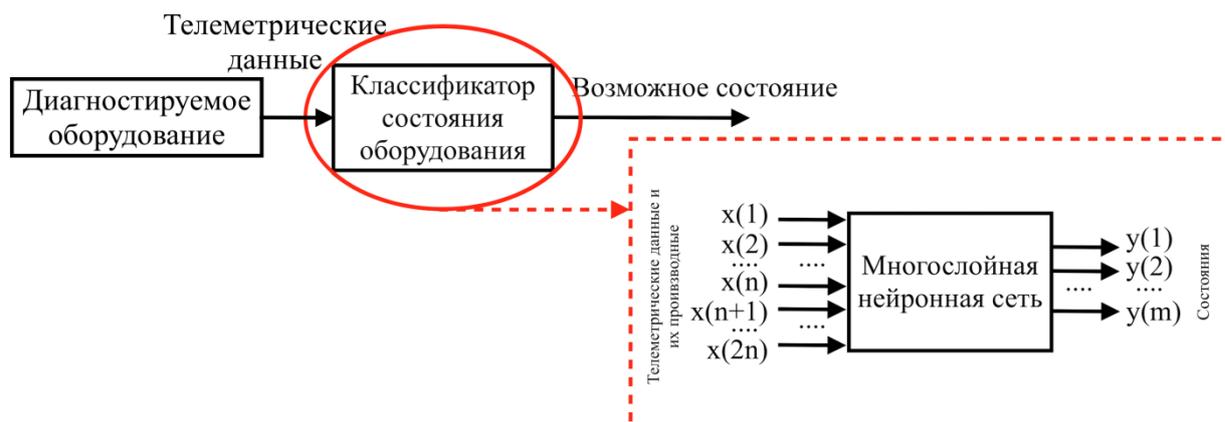


Рисунок 1 – Структурная схема системы предиктивной диагностики

Основным элементом системы является так называемый алгоритм классификации [3], отвечающий за определение состояния диагностируемого оборудования. На вход обученного классификатора поступают телеметрические данные, по которым на выходе генерируются флаги состояния оборудования, соответствующие заранее размеченным областям нормального или аварийного функционирования. В данной работе рассматривается классификатор, построенный в работе [7] на базе нейронной сети, обученной на исторических измерениях параметров работы реального оборудования с применением известной сетки возможных состояний оборудования. Сетка состояний оборудования в простейшем случае определяется как минимум одной булевой переменной «0 = нормальная работа», «1 = аварийное состояние», однако на практике оба состояния могут быть разделены на уточнённые области, например, по конкретным типам аварий, либо режимам работы оборудования [7].

Очевидно, что для обучения нейронной сети по каждой области состояния необходимо точно разделить обучающую выборку и поставить полученные наборы данных в соответствие конкретной неисправности или режиму работы. Например, для разделения области данных в

обобщённом виде (без привязки к конкретной аварии) может быть использована классическая кривая деградации оборудования [8, 9], описывающая отказ как процесс снижения вероятности его безаварийной работы (см. рисунок 2). Как видно из рисунка, развитие отказа – это процесс, характеризующийся тремя граничными параметрами:

- точка P – обнаружение потенциального отказа;
- точка F – наступление функционального отказа;
- T – время развития отказа.

Заметим, что после наступления функционального отказа оборудования в точке F через некоторое время наступает авария, являющаяся конечной стадией деградации. То есть процесс деградации после точки функционального отказа можно считать необратимым.

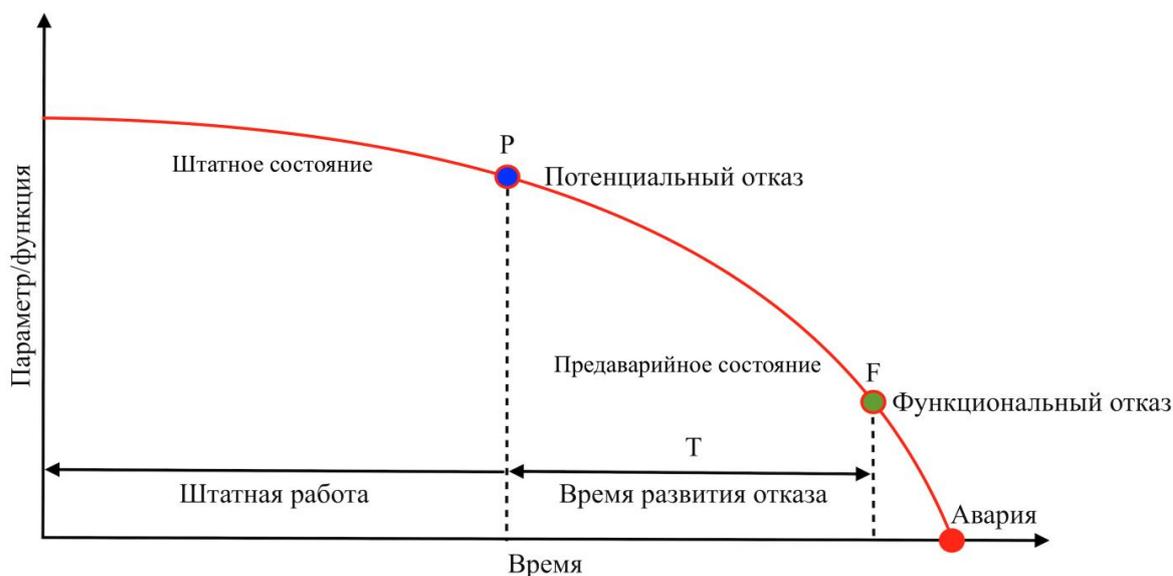


Рисунок 2 – Развитие аварии оборудования

Таким образом, точки P и F (рисунок 2) с эксплуатационной точки зрения обозначают временные границы этапов деградации оборудования, а с точки зрения обработки измеренных параметров выполняют функцию разметки данных [10] на участки, соответствующие указанным этапам деградации.

2 Разметка измеренных данных для обучения нейросети и их связь с граничными параметрами деградации

В большинстве случаев каждый из указанных в разделе 1 граничных параметров $\{P, F, T\}$ является неопределённым, в результате достоверным событием [11] является только точка наступления аварии (обозначена как «Авария» на рисунке 2). Фактически, эффективность практического применения алгоритма классификации состояния оборудования определяется качеством обучения нейронной сети по области «Предаварийное состояние» (рисунок 2). При выборе малого интервала $P-F$ объём обучающей выборки, соответствующей предаварийному состоянию, будет недостаточен и выльется в «недообученность» нейронной сети, что, в свою очередь, не позволит обнаруживать неисправность с достаточной степенью достоверности. Данная ситуация в литературе получила название «пропуск события» или «ошибка первого рода» [12]. Однако, при расширении интервала $P-F$ возрастает риск попадания в об-

ласть «Предаварийное состояние» данных, соответствующих штатной работе и никаким образом не связанных с потенциальной точкой отказа. В итоге правило классификации будет распознавать штатные условия работы оборудования как событие наступления аварии, что соответствует определению «ложная тревога» или «ошибка второго рода» [12]. Для обучения классификатора на основе нейронной сети необходимо точно сформировать обучающую выборку. Телеметрические данные в обучающей выборке должны точно соотноситься с состоянием оборудования, соответственно необходимо точно определить точку, соответствующую откату, а также период предаварийного состояния T .

Как подробно описано в теории автоматического регулирования [13], существенного улучшения качества работы систем управления динамическими объектами и процессами, включая такие задачи как управление, идентификация, прогнозирование и т.п., можно добиться путём учёта динамики изменения входных параметров. Как было сказано выше, в нашем случае рассматривается процесс развития отката во времени, что по определению попадает под классификацию «динамический процесс». Для оптимизации внедряемого нейросетевого алгоритма предиктивной диагностики выбран наиболее простой способ учёта динамики входных параметров, а именно подача их производных на вход нейронной сети (рисунок 1) по аналогии с введением дифференцированного сигнала в канал управления динамическим объектом [13]. Применение производных по каждому из параметров в качестве дополнительных входов нейронной сети позволяет учесть не только мгновенные значения, поступающие на вход, а также и динамику процесса (1).

$$x_i^{dev} = \frac{x_i(t_0) - x_i(t_0 - T_{dev})}{T_{dev}}, \quad (1)$$

где $x_i(t_0)$ – мгновенное значение технологического параметра в момент времени t_0 ; $x_i(t_0 - T_{dev})$ – мгновенное значение технологического параметра в момент времени $x_i(t_0 - T_{dev})$; T_{dev} – опорное время расчёта производной технологического параметра.

Таким образом, точность работы нейронной сети повышается за счёт добавления дополнительной полезной информации на входе, но при этом появляется дополнительный настроечный параметр в виде временной базы расчёта производных входных параметров нейронной сети T_{dev} .

3 Постановка задачи поиска настроечных параметров нейросетевого алгоритма

Как показано выше, исследуемый нейросетевой алгоритм имеет два настроечных параметра – время развития отката T и опорное время расчёта производной T_{dev} . Без ограничения общности для поиска оптимальных настроек применим метод прямого перебора [14]. Будем исследовать качество работы алгоритма на имеющейся исторической выборке отказов оборудования, изменяя настроечные параметры $\{T, T_{dev}\}$. Очевидно, что для организации данной процедуры поиска необходимо сначала определиться с критерием оценки качества. Для этого обратимся к классическим определениям вероятностных понятий эффективности систем обнаружения, поиска и идентификации (см. раздел далее).

3.1 Критерий эффективности работы систем предиктивной диагностики

С учётом того, что основной задачей рассматриваемого алгоритма предиктивной диагностики является обнаружение предаварийных/нештатных режимов оборудования на основе анализа имеющихся измерений, к системе напрямую могут применяться стандартные требования и методы оценки систем выделения полезного сигнала на фоне помех [15]. Главными эксплуатационными характеристиками систем обнаружения являются:

- вероятность пропуска сигнала [15], также именуемая в математической литературе как «ошибка первого рода» [12];
- вероятность ложной тревоги по обнаружению сигнала [15], соответствующая названию «ошибка второго рода» [12];

В терминах рассматриваемой задачи предиктивной диагностики ошибка первого рода напрямую соотносится с пропуском поломки, то есть определяется как неверная классификация неисправного оборудования в качестве штатно работающего. Ложная тревога, напротив, определяется как неверная классификация штатно работающего оборудования в качестве неисправного. Вероятности пропуска поломки (ошибки первого рода) P_1 и ложной тревоги P_2 (ошибки второго рода) определяются по формулам (2-3).

$$P_1 = \frac{\sum_{i=2}^m FN_i}{N_{fail}}, \quad (2)$$

где FN_i – количество неверно классифицированных состояний, соответствующих предаварийному состоянию; N_{fail} – общее число точек, характеризующих предаварийное состояние.

$$P_2 = 1 - \frac{N - \sum_{i=2}^m FP_i}{N}, \quad (3)$$

где FP_i – количество неверно классифицированных состояний, соответствующих штатному состоянию, N – общее количество точек, характеризующих штатное состояние.

В качестве комплексного критерия качества, учитывающего обе вероятностные характеристики P_1 и P_2 , уместно предложить линейную свёртку с равноправными весовыми коэффициентами:

$$J = P_1 + P_2 \rightarrow \min, \quad (4)$$

где P_1 – вероятность пропуска поломки, P_2 – вероятность ложной тревоги.

Введение функционала качества данного вида целесообразно, т.к. параметрами, определяющими качество работы системы предиктивной диагностики, являются именно вероятности (2) и (3), которые взаимосвязаны между собой через интегральные вероятностные функции [15]. Следовательно, их оптимизация по отдельности не является возможной.

3.2 Методика автоматизированного поиска настроечных параметров нейронной сети

После выбора варьируемых параметров $\{T, T_{dev}\}$ и критерия оптимальности работы системы предиктивной диагностики J можем переходить к созданию итеративной процедуры оптимизации настроечных параметров алгоритма обнаружения. Как упоминалось выше, процедура поиска оптимального сочетания настроечных параметров включает в себя автоматизированную методику обработки обучающей выборки. Исходные данные оптимизации представлены в таблице 1.

Таблица 1 – Исходные данные оптимизации

Данные	Обозначение
Массив исторических измерений технологических параметров в виде точек данных с метками времени	$\{x_k(t_n), t_n\}$
Массив достоверно зафиксированных исторических событий отказов в виде перечня событий $fault_m$ с наименованием типа отказа и метки времени события t_m	$\{fault_m, t_m\}$

Оптимизационные расчёты на каждой итерации выполняются по следующему алгоритму.

1. Задание пробных значений настроечных параметров $\{T_i, T_{dev_j}\}$ для текущей итерации;

2. Разбиение множества исторических измерений технологических параметров обучающей выборки на области предаварийного и нормального состояния по каждому достоверно зафиксированному отказу с учётом глубины забора предаварийных значений за период времени T_i , предшествующий каждому из зафиксированных отказов (см. рисунок 2):

$$fault_set_m = \{x_k(t_n), t_n\} \quad | \quad (t_m - T_i) \leq t_n \leq (t_m),$$

где $\{x_k(t_n), t_n\}$ – часть точек массива исторических измерений технологических параметров оборудования, ограниченная временными отрезками предаварийного состояния; t_m – метка времени события m -го отказа; T_i – время развития отказа, принятое на текущей i -й итерации процедуры поиска оптимальных настроечных параметров;

3. Обучение нейронной сети на размеченных в п. 2 данных предаварийного и нормального состояния. Обучение сети производится методом градиентного спуска с учителем [10] с помощью библиотеки «scikit-learn», в частности с использованием класса «MLPClassifier», изменяемые параметры которого можно подробно изучить на официальном сайте [16].

4. Тестирование работы обученной нейронной сети на тестовой выборке достоверно зафиксированных аварийных ситуаций, сформированной из множества исторических измерений технологических параметров. Фиксация фактических вероятностных характеристик обнаружения аварийных ситуаций в тестовой выборке:

$$\{P_1, P_2\}_{ij};$$

5. Подсчёт критерия оптимизации для текущего сочетания параметров $\{T_i, T_{dev_j}\}$:

$$J_{ij} = P_{1ij} + P_{2ij};$$

6. Переход к следующей итерации с сочетанием параметров $\{T_{(i+1)}, T_{dev_j}\}$ или $\{T_i, T_{dev_j}\}$.

Очевидно, что описанная процедура перебора параметров [14] должна осуществляться в заданных границах, определяемых на основании физических параметров. Для границы развития неисправности начальной точкой отсчёта является точка функционального отказа F (рисунок 2). Временной интервал развития неисправности T отсчитывается «назад» по временной шкале от указанной точки так, что при его увеличении область значений, соответствующая предаварийному состоянию, увеличивается. Базовое время расчёта производной T_{dev} отсчитывается от некоторого минимального значения T_{min} в сторону увеличения. Теоретическим нижним пределом может служить рекомендация теоремы Котельникова [13], согласно которой T_{min} должен в несколько раз превосходить частоту квантования дискретного сигнала по времени. На практике, с учётом того, что развитие отказа является медленно текущим процессом (длительностью, как правило, от нескольких дней до нескольких месяцев), значение T_{min} выбирается на уровне нескольких часов.

В результате работы описанной процедуры поиска путём прямого сравнения значений критерия формулы (4) определяются оптимальные значения варьируемых величин $\{T, T_{dev}\}$, соответствующие минимуму суммы вероятностей ошибок первого и второго рода.

4 Экспериментальная обработка методики на реальном промышленном объекте

Настоящая работа является продолжением цикла работ авторов, направленных на практическое применение алгоритмов предиктивной диагностики оборудования на реальных промышленных объектах. В качестве объекта применения алгоритма предиктивной диагностики и апробации предложенной методики выбран один из механических узлов теплоэлектростанция (ТЭЦ), а именно питательный электронасос (ПЭН). По аналогии с [7] выбор сделан исходя из имеющейся в наличии телеметрической информации, а также объективного перечня зафиксированных отказов. В то же время ПЭН является важным элементом технологической цепочки производства электроэнергии, и его отказ может привести к снижению объёма выпуска или полному выводу энергоблока из работы (рисунок 3).

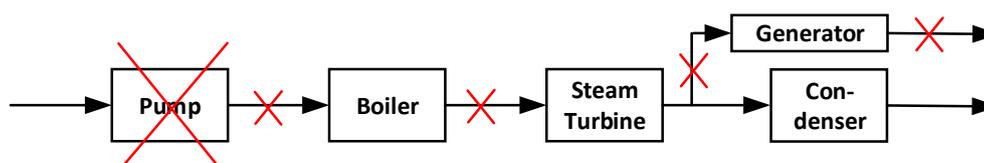


Рисунок 3 – Отказ ПЭН и его влияние на выработку электроэнергии

В качестве технологии для построения системы диагностики выбрана многослойная нейронная сеть, т.к. технология их обучения на исторических данных в настоящее время хорошо отработана [17]. Далее приводятся результаты применения методики автоматизированного поиска настроечных параметров нейронной сети алгоритма поиска неисправностей, позволившая оптимизировать эксплуатационные характеристики системы предиктивной диагностики.

4.1 Результаты оптимизации вероятностных эксплуатационных характеристик нейросетевого алгоритма

В рамках поставленного вычислительного эксперимента имеющаяся база исторических измерений технологических параметров ПЭН была разбита на обучающую и тестовую выборку [10] в пропорции 50% на 50%. Дополнительно 10% от обучающей выборки было использовано для задач валидации. Исторические данные были выгружены из централизованной SCADA-системы ТЭЦ и составили в количественном выражении:

- объём обучающей выборки – 12867 срезов данных;
- объём тестовой выборки – 12867 срезов данных;
- объём валидационной выборки – 1287 срезов данных.

На первом шаге было проведено варьирование величины времени расчёта производной T_{dev} , которое дало оптимальное значение, равное $T_{dev}^* = 120$ часов. Заметим, что это значение укладывается в понятие медленно изменяющегося процесса [13], который характерен для постепенной деградации агрегата [8, 9].

Дальнейшее определение оптимального значения длительности развития неисправности T осуществлялось при фиксированном значении T_{dev} . В результате варьирования величины длительности развития неисправности T получены графики вероятностных характеристик P_1 и P_2 (рисунок 4), а также сводного критерия оптимальности J (рисунок 5).

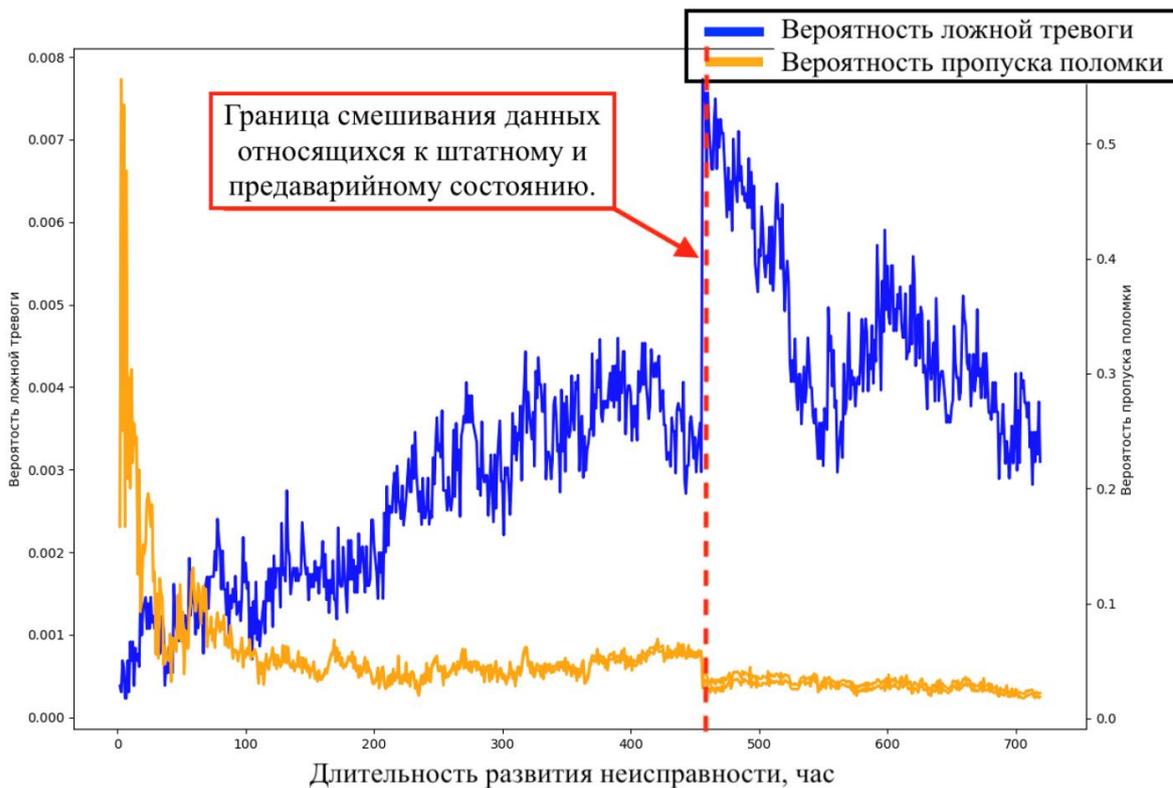


Рисунок 4 – Вероятности ложной тревоги и пропуска поломки при варьировании времени развития неисправности



Рисунок 5 – Значение функционала качества в зависимости от параметра T

Как видно из рисунка 4, при задании малого интервала развития неисправности (левая часть графика) происходит пропуск поломки с высокой вероятностью, что объясняется недостаточностью данных в размеченной области «предаварийное состояние». Однако, с увеличением интервала развития отказа вероятность ошибки первого рода начинает стремиться к определённому оптимальному значению, в данном случае равному $P_1 = 0,0213$, в то же время вероятность ложной тревоги растёт умеренно и достигает в этой точке значения $P_2 = 0,0032$. На рисунке 5 показана точка, соответствующая минимальному значению функционала качества (4) и определяющая оптимальное значение времени развития неисправности T . Минимальное значение равно $J_{min} = 0,0213$ и соответствующее этому значению время развития отказа $T = 234$ часа.

В целом, по графикам (рисунки 4–5) видно, что корректность разметки данных на области предаварийного и штатного состояния оборудования является ключевым параметром, влияющим на показатели эффективности нейросетевого алгоритма предиктивной диагностики. При попадании в обучающую выборку, соответствующую предаварийному состоянию системы, даже небольшого количества срезов данных штатного состояния приводит к резкому росту вероятности ложной тревоги P_2 . При этом наблюдается незначительный спад вероятности пропуска аварии P_1 , предположительно не связанный с объективными улучшениями качества работы нейросетевого классификатора, но объясняемый «массовостью» данных, размеченных как предаварийное состояние (в предельном случае, любое состояние системы можно объявить как предаварийное – в этом случае в системе постоянно будет высвечен флаг «авария», а вероятность пропуска аварии будет обеспечена на уровне $P_1 = 0\%$, однако польза от подобной системы очевидным образом будет сведена к нулю).

При валидации работы нейросетевого алгоритма с оптимизированными настроечными параметрами и полученными выше вероятностными характеристиками получены следующие результаты работы системы предиктивной диагностики:

- точность при проверке на тестовой выборке 0,966;
- вероятность ложной тревоги 0,0032.

Заключение

В результате проведённого исследования предложен комплексный и автоматизированный процесс оптимизации вероятностных эксплуатационных характеристик нейросетевого алгоритма предиктивной диагностики отказов промышленного оборудования. За счёт применения предложенной методики автоматизированной обработки обучающей выборки удалось оптимизировать характеристики нейросетевого алгоритма предиктивной диагностики по двум основным эксплуатационным параметрам:

- минимизация вероятности ложной тревоги;
- максимизация вероятности обнаружения неисправности.

Таким образом, можно сделать вывод, что использование комплексного подхода в автоматизированной оптимизации параметров нейросетевого алгоритма позволяет улучшить эксплуатационные характеристики системы предиктивной диагностики. В данной работе рассмотренные настроечные параметры ограничены только двумя характеристиками, являющимися внешними по отношению к используемой нейронной сети. Дальнейшие исследования авторов предполагаются в области оптимизации параметров самой нейронной сети, применяемой в алгоритме классификации состояния.

Список использованных источников

1. Divya, D. Review of fault detection techniques for predictive maintenance / D. Divya, B. Marath, M. B. Kumar // Journal of Quality in Maintenance Engineering. 2022. – Vol. 29, No. 2, pp. 420-441. DOI: 10.1108/JQME-10-2020-0107.
2. Data-driven Machinery Fault Detection : A Comprehensive Review / D. Neupane, M. R. Bouadjenek, R. Dazeley, S. Aryal ; School of IT. – Australia : School of IT, 2024. – 50 p.
3. Fernandes, M. Machine learning techniques applied to mechanical fault diagnosis and fault prognosis in the context of real industrial manufacturing use-cases: a systematic literature review / M. Fernandes, J. M. Corchado, G. Marreiros // Applied Intelligence. – 2022. – Vol. 52, pp. 14246-14280. DOI: 10.1007/s10489-022-03344-3
4. Агасиев, Т. А. Мета-модельный метод перманентной настройки параметров алгоритмов оптимизации / Т. А. Агасиев, А. П. Карпенко // Машиностроение и компьютерные технологии: наука и образование / Электронный журнал МГТУ им. Н.Э.Баумана. – 2016. – № 9. – С. 92-110.
5. Каширина, И. Л. Исследование и сравнительный анализ методов оптимизации, используемых при обучении нейронных сетей / И. Л. Каширина, В. М. Демченко // Вестник Воронежского Государственного Университета. Серия: Системный анализ и информационные технологии. – 2018. – № 4. – С. 123-132. DOI: 10.17308/sait.2018.4/1262.
6. ГОСТ Р 53564-2009. Мониторинг состояния оборудования опасных производств. Требования к системам мониторинга : национальный стандарт Российской Федерации : издание официальное : утверждено и введено в действие Приказом Федерального агентства по техническому регулированию и метрологии : дата введения. 2009-15-12. – Москва: Стандартинформ, 2019. – 19 с.
7. Nekrasov, I. V. Predictive Diagnostics of Power Generating Equipment Failures Based on Neural Network Technology / I. V. Nekrasov, Yu. D. Konstantinovskiy, N. S. Kukin. // 5th International Conference on Neural Networks and Neurotechnologies (NeuroNT'2024). – 2024. Принято к публикации. (<https://events.etu.ru/#/application/8096/info> - требуется авторизация)
8. Федотов, А. В. Основы теории надежности и технической диагностики: конспект лекций / А. В. Федотов, Н. Г. Скабкин. – Омск : Издательство Омского Государственного Технического Университета, 2010. – 64 с.
9. Шмидт, А. А. Анализ научно-методического аппарата диагностики и контроля, мониторинга и прогнозирования технического состояния военной техники связи / А. А. Шмидт, А. В. Косырев // Техника средств связи. – 2023. – №4 (164). – С. 81-92.
10. Smola, A. Introduction to machine learning / A. Smola, S. V. N. Vishwanathan. – UK : Cambridge University Press, Cambridge, 2008. – 234 p. (pp.136-137).
11. Гмурман, В. Е. Теория вероятностей и математическая статистика / В. Е. Гмурман. – Москва : Высшая школа, 1972. – 368 с.
12. Джонсон, Н. Статистика и планирование эксперимента в технике и науке. Методы обработки данных / Н. Джонсон, Ф. Лион.; пер. с англ. под ред. Э. К. Лецкого. – Москва : Мир, 1980. – 611 с.
13. Солодовников, В. В. Основы теории и элементы систем автоматического регулирования: Учебное пособие для приборостроительных специальностей ВУЗов / В. В. Солодовников, В. Н. Плотников, А. В. Яковлев. – Москва : Машиностроение, 1985. – 535 с.
14. Аттетков, А. В. Методы оптимизации / А. В. Аттетков, С. В. Галкин, В. С. Зарубин. – Москва : МГТУ им. Н. Э. Баумана, 2003. – 440 с.
15. Чердынцев, В. А. Прием сигналов на фоне помех. Учебное пособие для студентов радиотехнических специальностей / В. А. Чердынцев. – Минск : Белорусский Государственный Университет Информатики и Радиоэлектроники, 2007. – 148 с.
16. Scikit-learn reference // Python Package Index : [сайт Machine learning in Python]. – 2024. – URL: <https://scikit-learn.org/> (дата обращения 27.05.2024).
17. Croall, I. F. Industrial Applications of Neural Networks / I. F. Croall, J. P. Mason (Eds.). – Luxembourg : ECSC – EEC – EAEC, 1992. – 312 p.

Optimization of probabilistic operational characteristics of a neural network algorithm for predictive diagnostics of industrial equipment failures through automated processing of a training sample

I. V. Nekrasov | Candidate of Science (Engineering), Senior Researcher;
V. A. Trapeznikov Institute of Control Sciences RAS,
Moscow, Russian Federation;
ivannekr@mail.ru

Yu. D. Konstantinovskiy | Student;
Bauman Moscow State Technical University, Moscow,
Russian Federation;
uran9000@mail.ru

N. S. Kukin | Candidate of Science (Engineering), Head of the group;
Autonomous Non-Profit Organization
“Institute of Engineering Physics”, Serpukhov, Russian
Federation;
n.s.kukin@mail.ru

The paper considers the optimization of probabilistic operational characteristics of a neural network algorithm for predictive diagnostics of industrial equipment malfunctions. The probability of a false alarm and the probability of detecting a malfunction are accepted as optimized parameters, which are generally accepted metrics for the effectiveness of situation analysis and decision-making systems. The task of optimizing operational characteristics is decomposed to the level of influencing technical parameters of the system and reduced to finding the optimal values of the base calculation time of the derivatives of the measured technological parameters and the time of fault development. Automated processing of the training sample allows you to reduce the time spent on creating a system for predictive diagnostics of industrial equipment failures. The result of optimization of the probabilistic operational characteristics of the neural network algorithm is presented and optimal values of the variable parameters are obtained, as well as a result of training and testing on real telemetry data of the electric power pump of the turbine unit of the CHP, optimal values of the optimized parameters are obtained, according to which conclusions are drawn and further actions are proposed to improve the result.

Keywords: predictive diagnostics; neural network; training sample; historical data; emergency; pre-emergency condition; time of failure development; false-negative alarm; false-positive alarm

Citation: Nekrasov, I. V., Konstantinovskiy, Yu. D. and Kukin, N. S. (2024), “Optimization of probabilistic operational characteristics of a neural network algorithm for predictive diagnostics of industrial equipment failures through automated processing of a training sample”, *Journal of Dynamics and Vibroacoustics*, vol. 10, no. 3, pp. 81-92. DOI: 10.18287/2409-4579-2024-10-3-81-92. (In Russian; abstract in English).

References

1. Divya, D., Marath, B. and Kumar, M. B. (2022), “Review of fault detection techniques for predictive maintenance”, *Journal of Quality in Maintenance Engineering*, vol. 29, no. 2, pp. 420-441. DOI: 10.1108/JQME-10-2020-0107.
2. Neupane, D., Mohamed, R. B., Dazeley, R. and Aryal, S. (2024), *Data-driven Machinery Fault Detection: A Comprehensive Review*, School of IT, Deakin University, WaurnPonds, Geelong, Australia.
3. Fernandes, M., Corchado, J. M. and Marreiros, G. (2022), “Machine learning techniques applied to mechanical fault diagnosis and fault prognosis in the context of real industrial manufacturing use-cases: a systematic literature review”, *Applied Intelligence*, vol. 52, pp. 14246-14280. DOI: 10.1007/s10489-022-03344-3

4. Agasiev, T. A. and Karpenko, A. P. (2016), “Meta-model method of permanent parameter tuning of optimization algorithms”, *Mashinostroenie i komp'yuternye tekhnologii. Nauka i obrazovanie. Elektronnyy zhurnal MGTU im. N. E. Baumana*, vol. 9, pp. 92-110. (In Russian).
5. Kashirina, I. and Demchenko, M. (2018), “Research and comparative analysis of optimization methods used in training neural networks”, *Vestnik Voronezhskogo Gosudarstvennogo Universiteta. Seriya: Sistemnyy analiz i informatsionnye tekhnologii*, pp. 123-132. DOI: 10.17308/sait.2018.4/1262. (In Russian).
6. Federal Agency for Technical Regulation and Metrology (2019), *GOST P 53564-2009: Monitoring sostoyaniya oborudovaniya opasnykh proizvodstv. Trebovaniya k sistemam monitoringa*. [GOST P 53564-2009. Monitoring of the equipment condition of hazardous industries. Requirements for monitoring systems], Standartinform, Moscow, Russia. (In Russian).
7. Nekrasov, I. V., Konstantinovskiy, Yu. D. and Kukin, N. S. “Predictive Diagnostics of Power Generating Equipment Failures Based on Neural Network Technology”, *5th International Conference on Neural Networks and Neurotechnologies (NeuroNT'2024)*. Saint Petersburg Electrotechnical University "LETI" – accepted for publication. (<https://events.etu.ru/#/application/8096/info> - authorization is required)
8. Fedotov, A. V. and Skabkin, N. G. (2010), *Osnovy teorii nadezhnosti i tekhnicheskoy diagnostiki: konspekt lektsiy* [Fundamentals of reliability theory and technical diagnostics: lecture notes], Izdatel'stvo Omskogo Gosudarstvennogo Tekhnicheskogo Universiteta, Omsk, Russia. (In Russian).
9. Schmidt, A. A. and Kozyrev, A. V. (2023), “Analiz nauchno-metodicheskogo apparata diagnostiki i kontrolya, monitoringa i prognozirovaniya voennoy tekhniki svyazi”, *Tekhnika sredstv svyazi*, vol. 164, no. 4, pp. 81-92. (In Russian).
10. Smola, A. and Vishwanathan, S. V. N. (2008), *Introduction to machine learning*, Cambridge University Press, Cambridge, UK.
11. Gmurman, V. E. (1972), *Teoriya veroyatnostey i matematicheskaya statistika* [Probability theory and mathematical statistics], Vishaya Shkola, Moscow, Russia. (In Russian).
12. Johnson, N. and Lyon, F. (1980), *Statistika i planirovanie eksperimenta v tekhnike i nauke. Metody obrabotki dannykh* [Statistics and experiment planning in engineering and science. Data processing methods], Translated from English by E. K. Letsky (ed.), Mir, Moscow, Russia. (In Russian).
13. Solodovnikov, V. V., Plotnikov, V. N. and Yakovlev, A. V. (1985), *Osnovy teorii i element system avtomaticheskogo regulirovaniya: Uchebnoe posobie dlya priborostroitel'nykh spetsial'nostey VUZov* [Fundamentals of theory and elements of automatic control systems: A textbook for instrument-making specialties of universities], Mashinostroenie, Moscow, Russia. (In Russian).
14. Attetkov, A. V., Galkin, S. V. and Zarubin, V. S. (2003), *Metody optimizatsii* [Optimization methods], Izdatel'stvo MGTU im. N.E. Baumana, Moscow, Russia. (In Russian).
15. Cherdyntsev, V. A. (2007), *Priem signalov na fone pomekh. Uchebnoe posobie dlya studentov radiotekhnicheskikh spetsial'nostey* [Reception of signals against the background of interference. A textbook for students of radio engineering specialties], Belorusskiy Gosudarstvennyy Universitet Informatiki b Radioelektroniki, Minsk, Belarus. (In Russian).
16. Scikit-learn reference (2024), available at: <https://scikit-learn.org/> (Accessed 27 August 2024).
17. Croall, I. F. and Mason, J. P. (Eds.) (1992), *Industrial Applications of Neural Networks*, ECSC — EEC — EAEC, Brussels, Luxembourg.