

## Искусственная нейронная сеть как инструмент прогнозирования технического состояния агрегатов винтокрылых летательных аппаратов

**Б.Б. САФОКЛОВ,  
С.А. СЕРЕБРЯНСКИЙ,**  
канд. техн. наук  
(МАИ, Москва)  
safoklobbb@mai.ru

*Представлены алгоритмы идентификации признаков дефектов и прогноза технического состояния хвостового вала вертолета при помощи искусственной нейронной сети.*

**Вертолет, винтокрылый летательный аппарат, искусственная нейронная сеть, дефект, предиктивная модель**

Исследования, направленные на внедрение технологий с использованием инструментов на основе искусственного интеллекта в авиационной отрасли для решения различных прикладных задач, включая анализ и обработку данных, поступающих от современных средств мониторинга летательных аппаратов, интегрированных в комплекс бортового оборудования, являются естественным этапом эволюции в рамках концепции «Индустрия 4.0».

Ранее [1] была представлена концепция применения искусственного интеллекта для отслеживания условий эксплуатации, индивидуального контроля накопления повреждений каждым агрегатом и особо ответственными элементами конструкции, дифференцированного учета расходования ресурса и прогнозирования остаточной долговечности каждого вертолета. В разрабатываемой перспективной технологии саморазвивающейся системы интеллектуального взаимодействия комплексов бортового оборудования и искусственных нейронных сетей (ИНС), когда решения принимаются на основании самообучающихся систем обмена данными, т. е. в автоматическом режиме, в качестве ключевого требования принята необходимость развития средств контроля и фиксации данных мониторинга агрегатов, интегрированных в конструкцию летательного аппарата. Это позволяет непрерывно регистрировать физические параметры работы винтокрылого летательного аппарата и обрабатывать эти данные с целью определения технического состояния агрегатов и их остаточного ресурса [2].

Разрабатываемая «система» позволит повысить качество диагностики и объективности прогнозирования технического состояния агрегатов винтокрылых летательных аппаратов [3, 4] и перейти от традиционных моделей технического обслуживания (регламентного и по состоянию) [5, 6] к более эффективной и в перспективе более экономичной предиктивной модели технического обслуживания [7, 8].

Инструментом диагностики и прогнозности интеллектуальной оценки технического состояния по данным отслеживания условий эксплуатации, индивидуального контроля накопления повреждений каждым агрегатом и особо ответственными элементами конструкции [9], дифференцированного учета расходования ресурса и прогнозирования остаточной долговечности каждого вертолета в разрабатываемой системе является ИНС [10].

Схема применения ИНС для диагностики, мониторинга и прогнозирования технического состояния агрегатов винтокрылых летательных аппаратов представлена в работе [2].

Продолжением научно-экспериментальных исследований подтверждения работоспособности инновационного методического подхода интеграции ИНС в комплексы бортового оборудования [11] как инструмента оценки работоспособности и ресурса агрегатов перспективного винтокрылого летательного аппарата является прогнозирование типов дефектов [12, 13].

Метод прогнозирования технического состояния конструкций и агрегатов перспективных винтокрылых летательных аппаратов и обучение ИНС формируется на основе экспериментальной отработки данных диагностики системы мониторинга полунатурного стенда трансмиссии винтокрылого летательного аппарата.

Описание полунатурного стенда, схема размещения датчиков и перечень контролируемых узлов и агрегатов перспективной системы винтокрылого летательного аппарата с ИНС представлен в работах [1, 2].

Для экспериментального полунатурного стенда трансмиссии с колонкой несущего винта и несущим винтом винтокрылого летательного аппарата был сформирован перечень объектов контроля, контролируемых параметров, методов контроля и типов дефектов (табл. 1) [2].

Таблица 1

Номер объекта	Наименование конструкции и/или агрегата	Контролируемые параметры состояния деталей и обнаружение дефектов	Тип повреждения (дефекта)
1	Торсионы	Целостность пластин	Трещины и надрывы пластин
2	Узлы навески лопастей	Наличие трещин и остаточных деформаций	Трещины, пластическая деформация
3	Вал несущего винта	Наличие трещин и остаточных деформаций, крутящий момент	
4	Главный, промежуточный и хвостовой редукторы	Крутящий момент, частота вращения, угол поворота, температура подшипников	Усталостное выкрашивание дорожки или тела качения, разрушение сепаратора, заклинивание подшипника, прогрессивное выкрашивание рабочих поверхностей зубьев, развитие дефектов в зубьях/теле шестерни, разрушение одной из шестерен многопоточной схемы/планетарного редуктора, заедание шестерен, потеря крепежа/затяжки рамы/корпуса редуктора, трещины в корпусных деталях, наличие коррозии
5	Элементы трансмиссии (подшипниковые опоры, муфты)	Повреждения подшипников, частичная или полная потеря работоспособности подшипников, частота вращения, температура подшипников	
6	Несущий винт	Балансировка, нагрузки (изгибные, крутильные), наличие и развитие дефектов, соконусность	Усталостные трещины или иные механические повреждения в тягах, рычагах; механические повреждения на лопастях
7	Хвостовой вал	Крутящий момент, частота вращения, угол поворота, весовая балансировка	Потеря затяжки/разрушение крепежа, возникновение/рост трещины в теле вала

В качестве объекта для оценки технического состояния выбран хвостовой вал (табл. 1, объект № 7).

Мониторинг состояния объекта № 7 в полунатурном стенде включает задачу классификации диагностических признаков [14, 15], а именно определение принадлежности входного набора данных к одному из двух заранее известных типов повреждений (дефектов).

Алгоритм прогностической оценки технического состояния объекта 7 представлен на рис. 1.

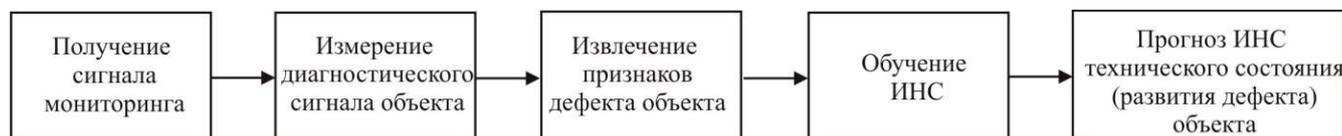


Рис. 1

В ходе эксперимента была проведена калибровка комплекта датчиков из состава объекта испытаний по измерению крутящего момента. Для этого была проведена функциональная проверка трансмиссии на режимах, указанных в табл. 2, с записью данных с датчиков, входящих в состав объекта испытаний.

Таблица 2

Номер режима	Номинальная частота вращения вала, об/мин	Показания крутящего момента на датчике, Н·м
1	$500^{+10}_{-15}$	$784 \pm 40$
2	$2800^{+37}_{-50}$	$784 \pm 40$

Размещение датчиков объекта испытаний на стенде трансмиссии показано на рис. 2. Здесь: 1 – датчики частоты вращения; 2 – электрические кабели; 3 – опора хвостового вала; 4 – датчики вибрации; 5 – хвостовой вал; 6 – блок-регистратор.

После калибровки комплекта датчиков вращения проведена функциональная проверка стенда трансмиссии на всех режимах, указанных в табл. 3.

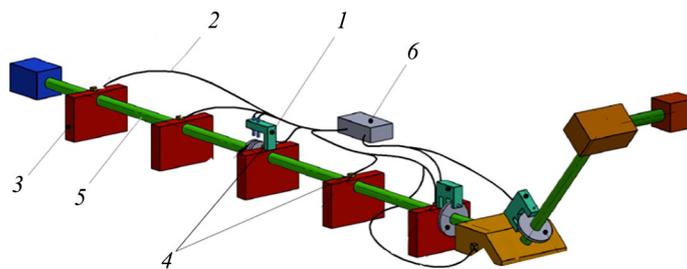


Рис. 2

Таблица 3

Номер режима	Номинальная частота вращения вала, об/мин	Показания крутящего момента на датчике, Н·м
1	$2800^{+37}_{-50}$	$392 \pm 10$
2		$784 \pm 20$
3		$1177 \pm 30$
4		$1569 \pm 40$
5		$1961 \pm 40$

На амплитудном спектре сигнала с датчика вибрации наблюдаются гармоники, соответствующие расчетным.

По данным, собранным с датчиков (см. рис. 2), оценена возможность определения технического состояния элементов трансмиссии методом вибродиагностики.

Для анализа состояния контролируемых деталей необходимо отслеживать уровень вибраций на заданных частотах и сравнивать текущие показатели с исходными значениями, соответствующими бездефектному состоянию изделия.

Значения, соответствующие работе изношенного изделия, получены искусственной разбалансировкой вала.

С целью определения вектора дисбаланса была проведена функциональная проверка с режимом 2800 об/мин в отсутствие крутящего момента. По результатам проведенной гонки определена амплитуда виброускорения датчика вибрации на оборотной частоте. Зарегистрированы вибрационные параметры объекта № 7 трансмиссии для последующего сравнения со значениями, соответствующими бездефектному состоянию, с целью диагностики его технического состояния. В качестве индикатора появления дефекта определены частоты, на которых могут проявляться дефекты по частотам внутреннего и внешнего колец подшипника вала.

Амплитудно-частотный спектр вибросигнала, получаемого с датчика, при гонке трансмиссии на режиме 2800 об/мин и крутящем моменте 784 Н·м представлен на рис. 3.

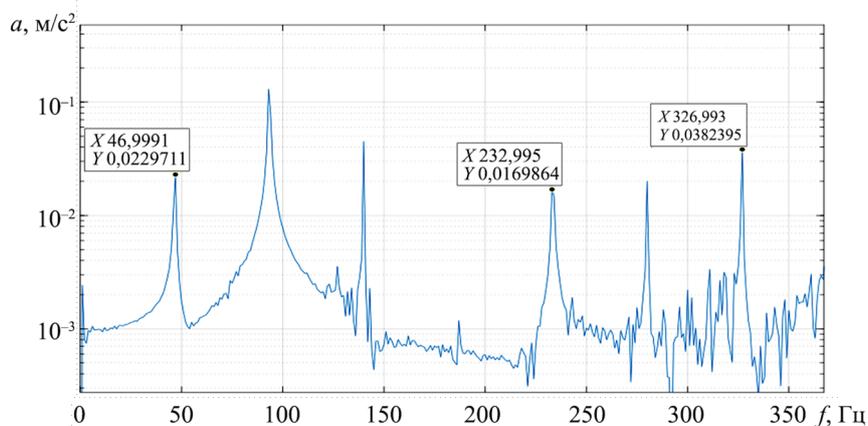


Рис. 3

На спектре отмечены частота вращения и частоты, характеризующие дефекты, которые коррелируют со значениями, полученными ранее [1].

Спектры крутильных колебаний работоспособного состояния объекта № 7 представлены на рис. 4.

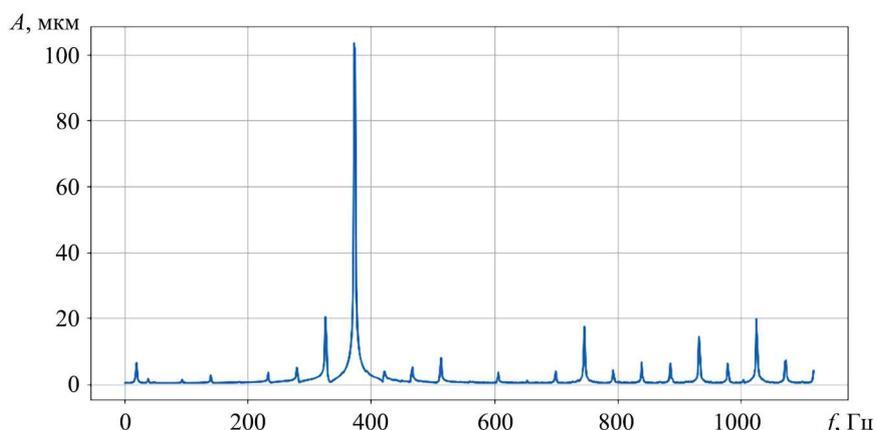


Рис. 4

Данные спектры крутильных колебаний, полученные на стенде в отсутствие внешних воздействий, отображают основные частоты, связанные с конструкцией хвостового вала трансмиссии и ее функционированием.

В эксперименте сравниваемые спектры крутильных колебаний полученные при искусственной разбалансировке, характеризуют работу трансмиссии и могут служить диагностическими признаками дефектного состояния.

На рис. 5, а приведен спектр (начальная стадия формирования дефектов), где зафиксированы первые признаки развития дефектов типа «потеря затяжки/разрушение крепежного соединения» (далее – дефект № 1) и развития второго типа дефектов «возникновение/рост трещины в теле вала» (далее – дефект № 2).

Приведем описание данного спектра.

Дефект № 1:

- частота – 125 Гц, амплитуда – 45 мкм;

- частота – 315 Гц, амплитуда – 2 мкм.

Дефект 2:

- частота – 1030 Гц: амплитуда – 12 мкм;

- частота – 840, 890, 890 Гц, в пределах нормы.

На рис. 5, б приведен спектр (развитие дефектов), где отмечается существенное изменение характеристик.

Дефект № 1:

- частота – 125 Гц, амплитуда – 50 мкм;

- частота – 315 Гц, амплитуда – 18 мкм.

Дефект 2:

- частота – 1030 Гц, амплитуда – 17,5 мкм;

- частота – 840 Гц, амплитуда – 42 мкм;

- частота – 890 Гц, амплитуда – 23 мкм;

- частота – 890 Гц, амплитуда – 31 мкм.

Приведем описание спектра, приведенного на рис 5, в (продолжение развития дефектов).

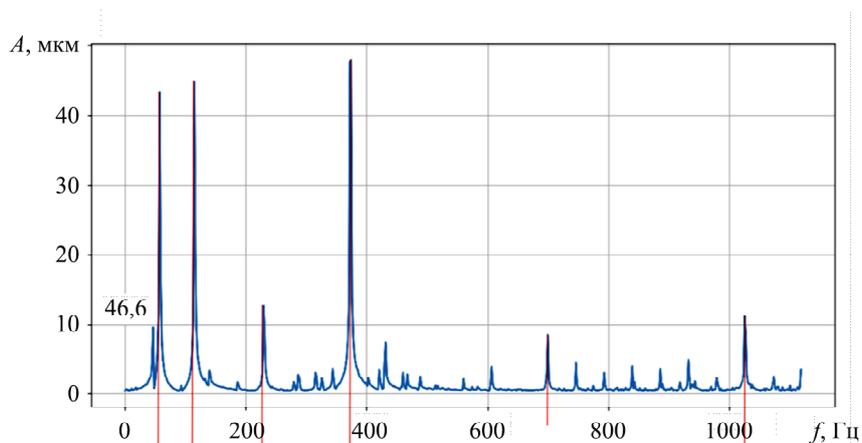
Дефект № 1:

- частота – 125 Гц, амплитуда – 548 мкм;

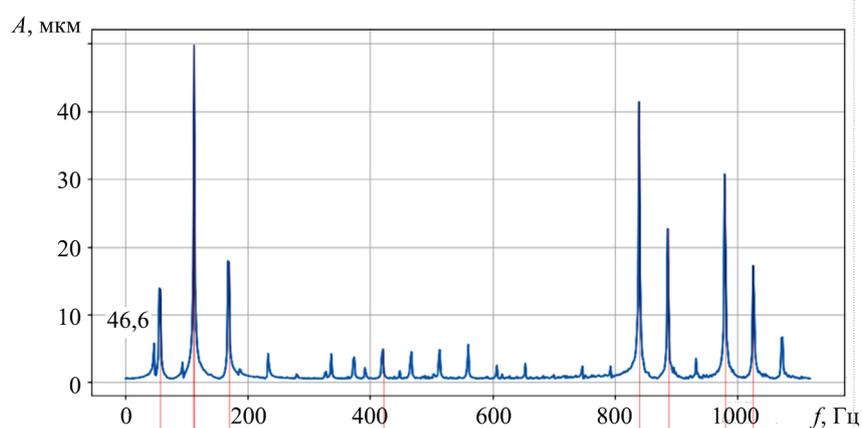
- частота – 315 Гц, амплитуда – 18 мкм.

Дефект 2:

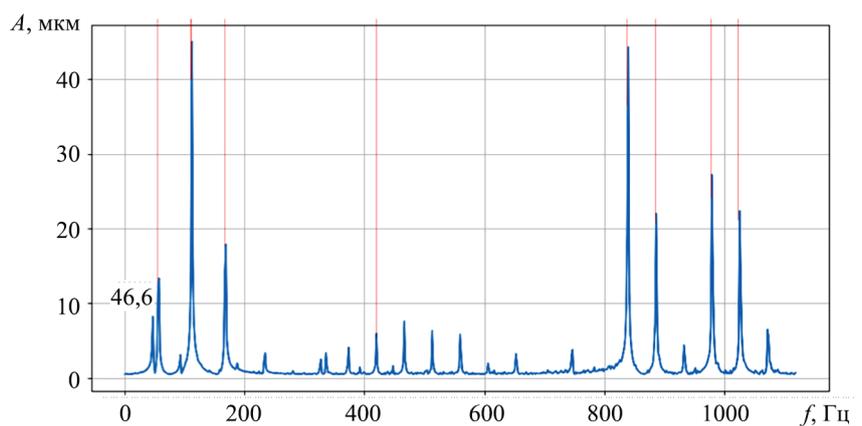
- частота – 1030 Гц, амплитуда – 23 мкм;
- частота – 840 Гц, амплитуда – 46 мкм;
- частота – 890 Гц, амплитуда – 22 мкм;
- частота – 890 Гц, амплитуда – 28 мкм.



а



б



в

Рис. 5

Согласно представленной картине развития дефектов все спектры сохраняют идентичный частотный состав, динамике амплитуд свойственны характерные закономерности, а именно линейные изменения спектров для дефектов, где величина амплитуды отражает степень повреждений.

Представленная в качестве примеров серия спектров наглядно демонстрирует эволюцию дефектов трансмиссии во времени, предоставляя критерии для диагностики и прогнозирования технического состояния оборудования.

На основании возможностей, предоставляемых полунатурным стендом трансмиссии для определения дефектного состояния его элементов, доступны прямая диагностика и прогнозирование проявления и развития дефекта № 1; соответственно, прогнозирование проявления и развития дефекта № 2 возможно при помощи ИНС, но уже на основе индикаторов прогнозных значений общего технического состояния вала. Основанием для упрощения прогнозирования является анализ графиков спектров амплитуд, по которым можно сделать вывод о том, что частоты колебаний сохраняются во времени, не зависят от режимов работы и условий эксплуатации, а количественно изменяется их амплитуда, что обеспечивает количественное сравнение изменений в работе трансмиссии в период эксплуатации.

Таким образом, полученные данные и соответствующие значения по результатам эксперимента можно использовать для решения при помощи ИНС двух задач: 1) прогнозирование времени проявления дефектов № 1, 2) прогнозирование времени работы до предельного состояния [16, 17] для хвостового вала полунатурного стенда трансмиссии винтокрылого летательного аппарата.

С целью прогнозирования времени проявления колебаний, характеризующих дефектное состояние по типу дефекта, используется метод, основанный на обобщенной теореме Байеса. В спектре крутильных моментов рассматриваем изменение амплитуды  $A_i$  и простой признак – временной период  $t_i$ , – проявляющийся в определенные моменты времени:

$$P(A_i t_i) = P(A_i)P(t_i/A_i) = P(t_i)P(A_i/t_i). \quad (1)$$

Отсюда вероятность совместного проявления у объекта состояния  $A_i$  и признака  $t_i$  при условии наличия дефекта  $D$  описывается формулой

$$P(A_i t_i | D) = P(D | A_i t_i) \frac{P(A_i)P(t_i)}{P(D)}, \quad (2)$$

где  $P(D | A_i t_i)$  – вероятность появления дефекта при наблюдении  $t_i$  и  $A_i$  (апостериорная вероятность);  $P(A_i)$  – вероятность проявления амплитуды  $A_i$ ;  $P(t_i)$  – вероятность проявления значения времени;  $P(D)$  – общая вероятность дефекта (нормировочная константа).

С учетом физической природы процесса, при котором наличие дефекта приводит к изменению амплитудного спектра и временных характеристик сигнала, формула принимает следующий вид:

$$P(D | A_i t_i) = \frac{P(D)P(t_i | D)P(A_i | D)}{P(A_i)P(t_i)}, \quad (3)$$

где  $P(A_i | D)$  – гауссово распределение амплитуд  $N(\mu_A, \sigma_A^2)$  при дефекте;  $P(t_i | D)$  – пуассоновское распределение временных периодов  $\lambda_i$  при дефекте.

Таким образом, получение прогнозных значений проявления и развития дефекта объекта № 7 осуществляется байесовской ИНС, набор входных данных в которой состоит из временных рядов спектров амплитуд, включающих  $A_i$  (амплитуды) и  $t_i$  – временные метки, отражающие изменения амплитуд во времени.

Архитектура данной сети: входной слой –  $A_i, t_i$ ; скрытые слои –  $\mu_A, \sigma_A^2, \lambda_i$  (моделируют распределения параметров); выходной слой –  $P(D | A_i t_i)$  через вариационный вывод.

Обучение байесовской ИНС происходит на основе байесовского вывода, что позволяет обновлять распределения весов на основе поступающих данных, для оценки неопределенности в прогнозировании методом Монте-Карло.

Графическое представление архитектуры байесовской ИНС для прогнозирования дефектов приведено на рис. 6.

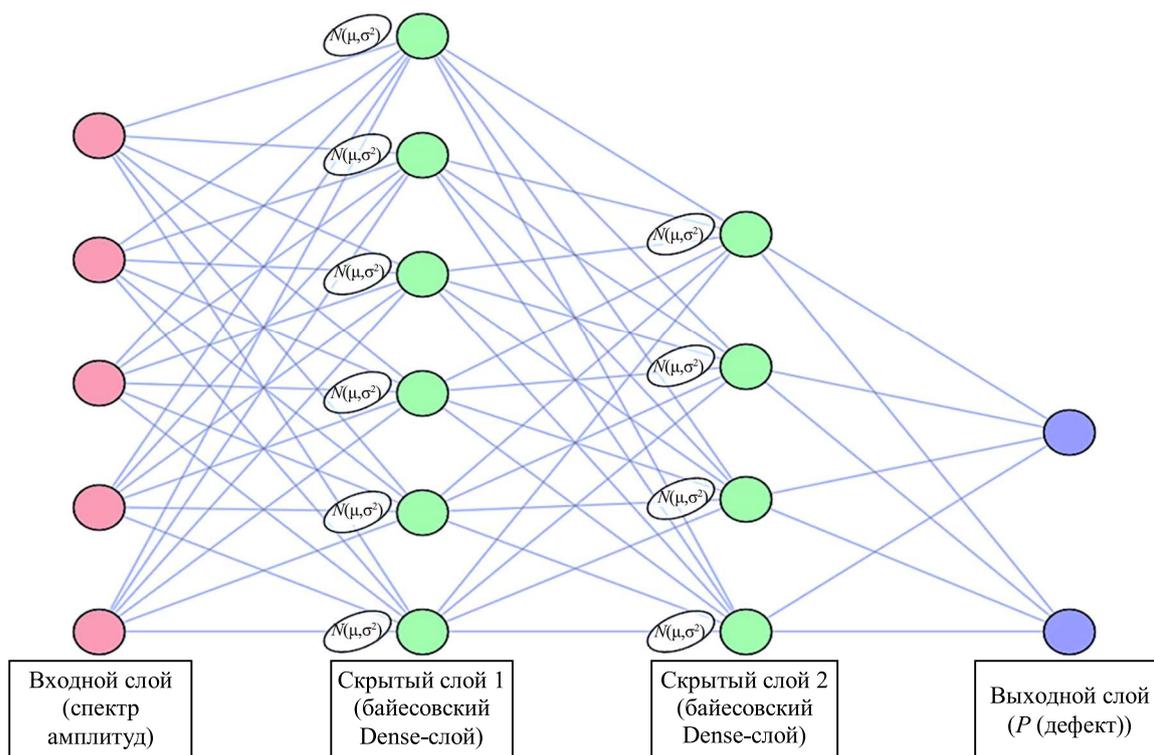


Рис. 6

При помощи байесовской ИНС спрогнозирована временная характеристика проявления значимых амплитуд для частот в спектре крутильных колебаний вала (рис. 7), характеризующих проявление дефектов № 1, 2. На основании обработки экспериментальных данных получен прогноз времени проявления амплитуды в спектрах крутильных колебаний, характеризующих дефектное состояние объекта № 7 (см. табл. 1).

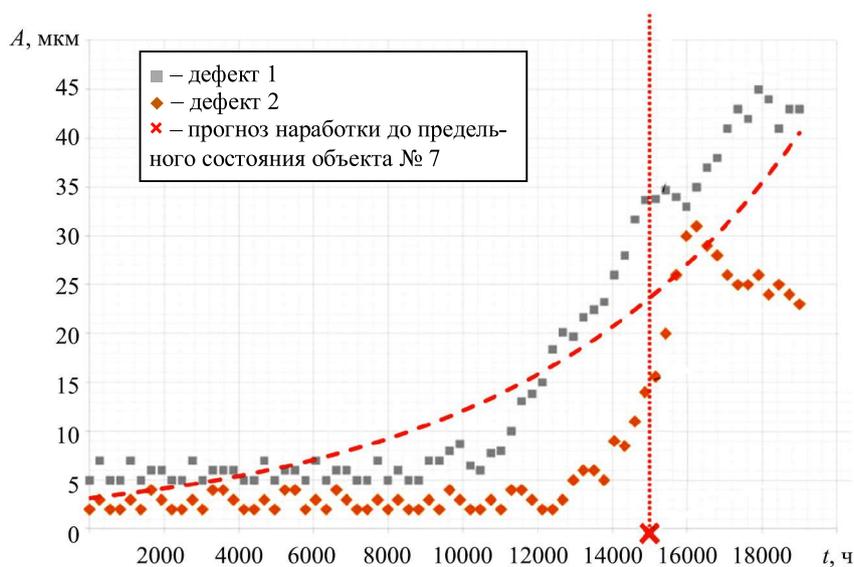


Рис. 7

Получение прогнозных значений ресурса объектов было подробно описано в работах [1, 2]. Алгоритм решения второй задачи применения ИНС как инструмента прогнозирования времени до пре-

дельного состояния ресурса объектов полунатурного стенда трансмиссии винтокрылого летательного аппарата без учета типа дефектов [11] заключается в решении уравнения

$$P(T_{P\gamma}) = \int_{T_{P\gamma}}^{\infty} P(T_P) dT_P, \quad (4)$$

где  $T_{P\gamma}$  – наработка до предельного состояния (ресурса).

По результатам моделирования, представленным ранее в работах [1, 2], получено время работы до предельного состояния  $T_{P\gamma}$ , позволяющее определить прогнозное время для проведения технического обслуживания или ремонтных работ для исследуемого объекта [18].

Получение прогнозных значений второй задачи обработки данных временного ряда осуществлялось рекуррентной ИНС, состоящей из повторяющегося модуля, который на каждом временном шаге  $t$  принимает на вход текущее значение входного вектора  $x_t$  (параметры – вибрация, температура и т. д.), состояние на предыдущем шаге  $h_{t-1}$  (память о предыдущих параметрах), математически описываемое следующим образом:

$$h_t = f(W_h h_{t-1} + W_x x_t + b),$$

где  $h_t$  – скрытое состояние на текущем шаге;  $W_h, W_x$  – веса сети;  $b$  – смещение;  $f$  – функция активации, линейный выпрямитель.

На последнем временном шаге скрытое состояние  $h_t$  используется для вычисления прогноза ресурса вала.

Формируются входные значения из данных мониторинга с датчиков стенда, после чего проводится сбор и стандартизация входных данных [19, 20].

Во избежание проблем затухания временного ряда рекуррентная ИНС была улучшена при помощи двунаправленного закрытого рекуррентного модуля или упрощенной версией долговременной – кратковременной – памяти, добавляющей механизмы запоминания важных данных и забывания менее значимых.

Структура работы рекуррентной ИНС с замкнутым замкнутым рекуррентным узлом для объекта № 7 представлена на рис. 8.

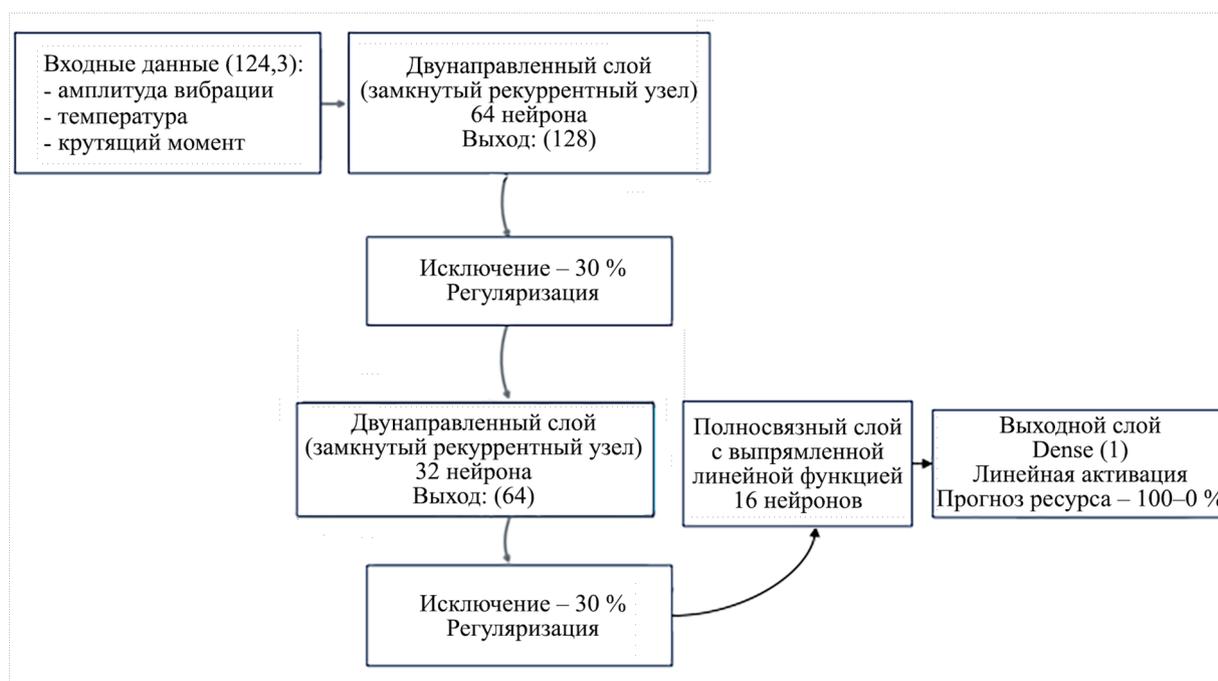


Рис. 8

Приведем описание схемы работы улучшенной ИНС для прогнозирования ресурса (см. рис. 8).

Входной слой принимает заданное количество временных шагов с тремя признаками (амплитуда, температура, крутящий момент).

Двунаправленные слои – два блока, где первый (64 нейрона) возвращает последовательности (Возвращать\_последовательности = Да) для передачи во второй, второй слой (32 нейрона) агрегирует временные зависимости.

Регуляризация – два блока на схеме (исключение 30 %) для предотвращения переобучения.

Полносвязные слои преобразуют выход закрытого рекуррентного модуля в прогнозирование ресурса (от 100 до 0 %).

Выходной слой выдает прогнозное значение ресурса.

Результаты прогнозирования ресурса объекта № 7 приведены на рис. 9.

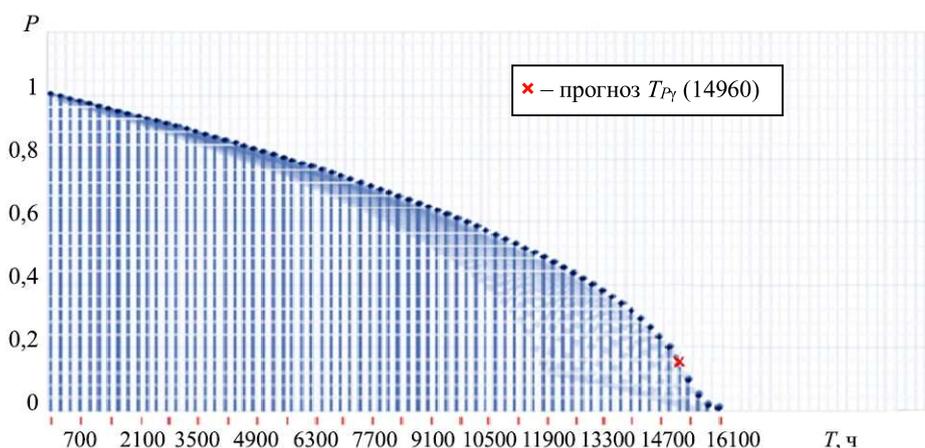


Рис. 9

Полученные результаты экспериментальной отработки метода предиктивной диагностики системы мониторинга для полунатурного стенда винтокрылого летательного аппарата, заключающегося в прогнозировании времени появления и развития дефектов, а также полного ресурса объектов контроля позволяют сформировать направление дальнейших исследований применения искусственного интеллекта в комплексе с бортовым оборудованием. Разработка интеллектуальной модели с применением технологий искусственного интеллекта для комплексного мониторинга, оценки и прогнозирования технического состояния винтокрылых летательных аппаратов создаст новые возможности для оптимизации их послепродажного обслуживания на соответствующем этапе жизненного цикла изделия.

В дальнейшем будут продолжены эксперименты и исследования на базе полунатурного стенда трансмиссии в системе с ИНС как инструментом мониторинга и диагностики винтокрылых летательных аппаратов по определению типов дефектов компонентов системы и прогнозированию предельной возможности эксплуатации винтокрылых летательных аппаратов до ремонта при появлении отдельных видов неисправностей компонентов.

#### СПИСОК ЛИТЕРАТУРЫ

1. Бельский А.Б., Есипович О.А., Сафоклов Б.Б. Прогнозирование технического состояния агрегатов винтокрылых летательных аппаратов на основе нейросетевого моделирования // Изв. вузов. Авиационная техника. 2023. № 4. С. 4–14.
2. Бельский А.Б., Есипович О.А., Сафоклов Б.Б. Экспериментальное апробирование применения искусственных нейронных сетей в системах диагностики для оценки и прогнозирования технического состояния агрегатов винтокрылых летательных аппаратов // Изв. вузов. Авиационная техника. 2024. № 1. С. 109–115.
3. Братухин А.Г. и др. Цифровые технологии в жизненном цикле российской конкурентоспособной авиационной техники. М.: МАИ, 2020. 448 с.
4. Serebryansky S., Shkurin M. Predictive Assessment of the Development of Unmanned Aviation System // Journal of Engineering Science and Technology Review. 2022. Vol. 15. Iss. 6. P. 149–154.

5. ГОСТ Р 55255-2012. Воздушный транспорт. Система технического обслуживания и ремонта авиационной техники. Организация работ по диагностике технического состояния авиационной техники. Основные положения. М.: Стандартинформ, 2014. 20 с.
6. ГОСТ Р 53863-2010. Воздушный транспорт. Система технического обслуживания и ремонта авиационной техники. Термины и определения. М.: Стандартинформ, 2011. 19 с.
7. Бельский А.Б., Ресинец А.И. Систематизация подходов для комплексного решения задачи повышения безопасности полетов вертолетной техники // Качество и жизнь. 2022. № 2. С. 82–90.
8. Долгов О.С., Сафоклов Б.Б., Смагин А.А. Диагностика и прогнозирование ресурса взлетно-посадочных устройств с использованием искусственных нейронных сетей // Изв. вузов. Авиационная техника. 2022. № 2. С. 3–10.
9. Чернов В.Ю. Алгоритм полетного контроля состояния датчиков бортового комплекса управления самолета // Изв. вузов. Авиационная техника. 2005. № 4. С. 49–53.
10. Баутин А.А., Свирский Ю.А. Применение нейросетевых технологий в задачах мониторинга состояния критических мест конструкции транспортных самолетов // Вестник МАИ. 2020. № 4. С. 81–91.
11. Stanton I. et al. Predictive Maintenance Analytics and Implementation for Aircraft: Challenges and Opportunities // Systems Engineering. 2023. Vol. 26. Iss. 2. P. 216–237.
12. Safoklov B. et al. Model of Aircraft Maintenance Repair and Overhaul Using Artificial Neural Networks // Transportation Research Procedia. 2022. Vol. 63. P. 1534–1543.
13. Макаров В.В. Использование методов искусственного интеллекта для оценки технического состояния двигательного-рулевой колонки (ДРК) по вибрационным характеристикам // Учен. зап. физического факультета Московского университета [Электронный журнал]. 2017. № 5. URL: <http://uzmu.phys.msu.ru/file/2017/5/1751406.pdf> (дата обращения: 17.03.2025).
14. Rivas A. et al. A Predictive Maintenance Model Using Recurrent Neural Networks // Proc. of the 14th International Conference on Soft Computing Models in Industrial and Environmental Applications, May 13–15, 2019, Seville, Spain. P. 261–270.
15. Стрелец Д.Ю., Серебрянский С.А., Шкурин М.В. Цифровой двойник изделия в едином информационном пространстве жизненного цикла // Управление развитием крупномасштабных систем: Тр. 13-й Междунар. конф., г. Москва, 28–30 сент. 2020. М.: ИПУ РАН, 2020. С. 1249–1258.
16. Сай Ван Квонг, Щербаков М.В. Метод прогнозирования остаточного ресурса на основе обработки данных многообъектных сложных систем // Прикаспийский журнал: управление и высокие технологии. 2019. № 1. С. 33–44.
17. Babenko G. et al. Results of the Study of the Influence of External Cargo Parameters on the Helicopter Controllability // Aerospace. 2022. Vol. 9. № 5. Article № 229.
18. Матвеев С.А. и др. Методы диагностики технического состояния и прогнозирования ресурса электронасосных агрегатов космических аппаратов // Изв. вузов. Авиационная техника. 2020. № 4. С. 4–10.
19. Бойко О.Г. О правомерности использования условных вероятностей безотказной работы и условных плотностей вероятностей отказов в математических моделях надежности агрегатов // Вестник СибГАУ. 2010. № 2 (28). С. 113–116.
20. Dli M., Puchkov A., Lobaneva E. Predicting the Equipment Useful Lifetime Based on the Deep Neural Networks // Cyber-Physical Systems: Intelligent Models and Algorithms / Eds. A.G. Kravets, A.A. Bolshakov, M. Shcherbakov. Springer, 2022. P. 135–144.

Поступила в редакцию 17.04.25

После доработки 6.05.25

Принята к публикации 6.05.25

## Artificial Neural Network as a Tool for Predicting the Technical Condition of Rotary-Wing Aircraft Components

B.B. SAFOKLOV AND S.A. SEREBRYANSKII

Moscow Aviation Institute (National Research University), Moscow

*The paper presents algorithms for identifying the defect signatures and predicting the technical condition of a helicopter tail rotor shaft using an artificial neural network.*

**Helicopter, rotary-wing aircraft, artificial neural network, defect, predictive model**