

DOI: <https://doi.org/10.26896/1028-6861-2023-89-5-56-63>

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ МОНИТОРИНГА НАГРУЗОК В СИЛОВЫХ ЭЛЕМЕНТАХ АВИАЦИОННЫХ КОНСТРУКЦИЙ

© Александр Александрович Орлов, Кирилл Иванович Сыпало, Владимир Иванович Городниченко, Андрей Александрович Баутин*

Центральный аэрогидродинамический институт имени профессора Н. Е. Жуковского, Россия, 140180, Московская обл., Жуковский, ул. Жуковского, д. 1; *e-mail: andrey.bautin@gmail.com

Статья поступила 27 декабря 2022 г. Поступила после доработки 6 февраля 2023 г. Принята к публикации 28 февраля 2023 г.

Экономическую эффективность при эксплуатации самолетов местных воздушных линий (МВЛ) можно повысить за счет увеличения информированности о нагружении и состоянии авиационной конструкции с последующей корректировкой программы технического обслуживания в соответствии с фактическими условиями эксплуатации. Учет индивидуальных особенностей нагружения силовых элементов конструкции транспортных самолетов в процессе выполнения полетов позволяет значительно продлить ресурс, в некоторых случаях — в два и более раз. Однако на данный момент системы мониторинга нагрузок в авиационной отрасли повсеместно еще не внедрены. Реализация известных подходов, разрабатываемых для мониторинга и анализа нагрузок, требует значительных изменений в программах и процедурах поддержания летной годности, включая необходимость установки дополнительного сложного измерительного оборудования. В данной работе рассматривается альтернативный подход по отношению к существующим методам мониторинга нагрузок. На основе применения технологий искусственного интеллекта предложена методика определения (прогноза) нагрузок в силовых элементах конструкции самолета без использования дополнительного измерительного оборудования. Ключевым этапом методики является формирование с помощью искусственной нейронной сети зависимости между параметрами полета, которые регистрируются штатными бортовыми самописцами, и параметрами нагружения, определяемыми расчетно-экспериментальными методами в результате обработки данных тензометрии. Эти данные в достаточном объеме получают при проведении летно-прочностных испытаний на этапе сертификации. Методика рассмотрена на примере прогноза усилий в элементах механизации закрылков самолета. Полученные результаты показали, что средняя ошибка оценок усилий в шатунах внутренних закрылков не превышает 6 %. Данные результаты позволяют с приемлемой точностью определять в процессе эксплуатации накопленную индивидуальную повреждаемость конструкции летательного аппарата и оценивать величину его остаточного ресурса. Представленный подход является частью методической базы, необходимой для разработки и внедрения современных средств анализа состояния конструкции, реализованных на основе бортовых систем мониторинга самолетов МВЛ.

Ключевые слова: нейронная сеть; персептрон; циклическое нагружение конструкции; усталостная повреждаемость; остаточный ресурс.

APPLICATION OF NEURAL NETWORK TECHNOLOGIES TO LOAD MONITORING IN AIRCRAFT STRUCTURE BEARING ELEMENTS

© Aleksandr A. Orlov, Kirill I. Sypalo, Vladimir I. Gorodnichenko, Andrey A. Bautin*

Central Aerohydrodynamic Institute, 1, ul. Zhukovskogo, Zhukovsky, Moscow obl., 140180, Russia;

*e-mail: andrey.bautin@gmail.com

Received December 27, 2022. Revised February 6, 2023. Accepted February 28, 2023.

Economic efficiency in the operation of aircraft local air lines (LA) can be improved by increasing the awareness of the loading and aircraft structure integrity, with the subsequent adjustment of the maintenance program in accordance with the actual operating conditions. The allowance for specific features of loading load-bearing elements at transport aircraft during particular operations provides a significant extending in the safe life (in some cases, by several times). However, at the moment, load monitoring systems in the aviation industry have not yet been implemented universally. The implementation of the

well-known approaches developed for monitoring and analyzing loads requires significant changes in the programs and procedures for maintaining airworthiness, including the need to install additional sophisticated measuring equipment. We propose an alternative approach to existing methods of load monitoring without using additional measuring equipment. The main stage is formation of the relationship between the flight parameters recorded by the standard on-board recorder and the loading parameters, which are determined by computational and experimental methods as a result of processing strain gauge data. A sufficient bulk of the strain data is usually obtained during the flight tests at the certification stage. Testing of this technique is considered with reference to the example of the loads in the elements of high lift devices of aircraft flaps. The average error in the estimates of the forces in the connecting rods of the inner flaps does not exceed 6%. The results obtained make it possible to determine with the acceptable accuracy the individual accumulated damageability of an aircraft structure and to assess the residual safe life. The presented approach is a part of the methodological framework necessary for the development and implementation of modern means of analyzing the integrity of the structure, implemented on the basis of on-board monitoring systems of local airlines aircraft.

Keywords: neural network; perceptron; cyclic loading of the structure; fatigue damage; residual life.

Введение

В настоящее время одним из приоритетных направлений развития авиационной отрасли является обеспечение регулярного авиационного сообщения между отдельными населенными пунктами внутри страны, в том числе в труднодоступных для наземного транспорта регионах.

Безопасность самолетов местных воздушных линий (МВЛ) достигается выполнением требований и процедур, определенных рядом нормативных документов, соблюдение которых обеспечивает длительную эксплуатацию воздушных судов транспортной категории без происшествий чрезвычайного характера.

Конкретный состав обязательных и дополнительных требований к типовой конструкции самолетов, для которых требуется подтверждение соответствия, предусмотрено разрабатывать в рамках сертификационного базиса (специальных технических условий). Сертификационный базис отражает все характерные важные свойства конструкции воздушного судна, состав его функциональных систем, характеристики, обеспечивающие безопасный полет, эксплуатационные процедуры, содержащиеся в летном руководстве и в документах по поддержанию летной годности. Как показано в статьях [1, 2], сертификационный базис может быть использован не только для сертификации, но и для определения класса беспилотных воздушных судов, в соответствии с которым рекомендуется устанавливать область их применения.

Повышение надежности и экономичности эксплуатации авиационной техники во многом обеспечивается уровнем технического совершенства производственного комплекса, системой технического обслуживания и поддержания работоспособности, а также выбором приемлемого уровня риска в прогнозируемых условиях эксплуатации.

В целях безопасности полетов важно обеспечить оперативное и своевременное выполнение

всего комплекса мер, направленного на контроль и поддержание летной годности самолета во время эксплуатации. К числу основных работ при этом относятся не только мониторинг технического состояния, но и специальные осмотры с применением неразрушающего контроля, высокотехнологичные способы ремонта, а также прогнозирование показателей аварийности и причин возникновения вероятных рисков.

В соответствии с ГОСТ 27.002–2015 на основе данных мониторинга должен осуществляться контроль технического состояния, а также определяться остаточный ресурс объекта мониторинга. За последнее время задача мониторинга частично решена в [3], более полное ее решение с определением остаточного ресурса представлено в патенте [4]. Результаты разработки методов мониторинга состояния, а именно обнаружения повреждений с помощью бортового измерительного комплекса, представлены в работах [5 – 8]. Реализация известных подходов, разрабатываемых для мониторинга и анализа нагрузок, требует значительных изменений в программах и процедурах поддержания летной годности, включая необходимость установки дополнительного сложного измерительного оборудования.

Возможны и альтернативные подходы к контролю состояния и мониторингу нагружения основных силовых элементов (ОСЭ) конструкции самолета в процессе эксплуатации, например, на основе теории искусственных нейронных сетей (ИНС), статистического анализа и обработки данных, обеспечивающих оценку нагруженности авиационной конструкции в процессе эксплуатации [9 – 11].

Применение нейросетевых технологий искусственного интеллекта позволяет предложить перспективную методику определения (прогноза) нагрузок в силовых элементах конструкции самолета. Ключевым этапом методики является формирование с помощью искусственной нейронной сети зависимости между параметрами полета от



Рис. 1. Общая схема мониторинга нагруженности ЛА с применением ИНС

Fig. 1. General scheme for monitoring aircraft loads using artificial neural networks

штатных бортовых средств регистрации и параметрами нагружения, что реализуется расчетно-экспериментальными методами в результате обработки данных тензометрии. Эти данные в достаточном объеме получают при проведении летных прочностных испытаний на этапе сертификации.

Методика мониторинга нагруженности

Вопросы мониторинга нагруженности ОСЭ конструкции летательных аппаратов (ЛА) в процессе эксплуатации и при летных прочностных испытаниях активно изучают в связи с применением нейросетевых технологий. В целях контроля характеристик нагружения и оценки усталостной повреждаемости конструкции ЛА в летных исследованиях получены большие объемы информации. Их использовали для создания специальных алгоритмов анализа нагруженности, которые планируется интегрировать в программное обеспечение бортовых измерительных комплексов.

Для мониторинга нагруженности ЛА по данным штатных бортовых регистраторов предлагается методика, разработанная на основе нейросетевых технологий искусственного интеллекта (рис. 1), состоящая из следующих основных этапов:

1) формирование перечня параметров полета, регистрируемых штатными бортовыми средствами и связанных с нагруженностью элементов конструкции;

2) выбор зон контроля, формирование схемы установки датчиков деформации для сбора информации о нагруженности элементов конструкции (рис. 2);

3) летные испытания с регистрацией тензометрии силовых элементов конструкции;

4) обработка, фильтрация, определение корреляции между исходными данными для уменьшения размерности задачи, формирование синхронизированных данных;

5) формирование архитектуры ИНС, включая структуру нейронов и их слоев;

6) разделение данных на выборки, обучение и тестирование ИНС;

7) определение точности восстановления нагрузки с помощью ИНС.

Для разработки системы мониторинга нагруженности ЛА на основе ИНС необходимо создание:

методов идентификации, используемых при обработке информации, полученной в летных прочностных испытаниях;

требований к входным/выходным сигналам, измеряемым при летных прочностных испытаниях и используемым для настройки и обучения нейронных сетей;

рациональной структуры ИНС для идентификации характеристик нагружения конструкции ЛА в процессе эксплуатации и в летных прочностных испытаниях.

Структура информационной системы для ЛА, помимо самой модели ИНС, включает специальные блоки обработки исходной информации:




Рис. 2. Схема сбора данных для мониторинга элементов привода закрылка

Fig. 2. Data collection scheme for monitoring elements of flap drive system

блок детерминированной обработки входных переменных, на выходе которого формируются данные для входного слоя ИНС;

блок детерминированной обработки измерений выходных переменных нагружения конструкции, используемых для обучения модели ИНС.

Функции блока обработки входных переменных заключаются в вычислении по имеющимся исходным данным дополнительных входных параметров, необходимых для анализа нагружения. К числу таких переменных, в частности, относится скоростной напор, вычисляемый с учетом сжимаемости по измеренным в полете параметрам — числу Маха M и давлению на текущей высоте p_H .

Преимущество аппроксиматоров на основе ИНС перед традиционными функциональными моделями и применением регрессионного анализа заключается в том, что ИНС не требует построения явной модели исследуемого процесса, а работоспособность метода не теряется при неполной входной информации. Важно отметить устойчивость к помехам и высокое быстродействие моделей ИНС.

Одним из необходимых этапов методики является корреляционный анализ исходных данных — взаимозависимости входных переменных оцениваются на основе коэффициента парной корреляции Пирсона, который изменяется в пределах от -1 до $+1$ и вычисляется по формуле

$$r_{XY} = \frac{\sum (X - \bar{X})(Y - \bar{Y})}{\sqrt{\sum (X - \bar{X})^2 \sum (Y - \bar{Y})^2}},$$

где $\bar{X} = \frac{1}{n} \sum_{t=1}^n X_t$, $\bar{Y} = \frac{1}{n} \sum_{t=1}^n Y_t$ —

средние значения выборок; X , Y — регистрируемые параметры. Значение -1 означает полную

отрицательную зависимость, а $+1$ — полную положительную зависимость, значение 0 интерпретируется как отсутствие корреляции или связи. Две переменные отрицательно коррелированы, если при увеличении одной переменной другая уменьшается.

Выбор структуры ИНС обусловлен особенностями и уровнем сложности поставленной задачи. На сегодняшний день для формирования зависимости между параметрами в многомерном пространстве используют персептроны (нейросети прямого распространения), которые являются универсальными аппроксиматорами [12 – 16].

В совокупности элементы персептрона представляют собой структуру, состоящую из нескольких слоев нейронов с прямой передачей сигнала. Элементы этих слоев взаимодействуют между собой через синаптические связи, имеющие соответствующие значения весов. На каждый элемент последующего слоя поступает суммарный сигнал от всех элементов предыдущего слоя. С элементов (элемента) последнего слоя снимается искомый сигнал. Точность оценок (прогноза) ИНС в существенной степени зависит от объема ретроспективной выборки, используемой для обучения персептрона.

Входные данные для предотвращения «эффекта насыщения», при котором элемент (нейрон) персептрона оказывается чувствительным к входным значениям, лежащим за пределами рассматриваемой области, необходимо нормировать по максимальному значению в рассматриваемой выборке.

Кроме структуры нейронной сети и значений весовых коэффициентов, следует задать вид функции активации, которая преобразует входной сигнал нейрона в выходной. В качестве такой активационной функции в данной задаче для

всех слоев использовали сигмоидную функцию, определяемую как

$$f = \frac{1}{1 + e^{-au}},$$

где f — функция активации; a — параметр, выбираемый экспериментально исходя из обеспечения минимума ошибки описания исследуемого процесса; u — взвешенная сумма входных сигналов нейрона.

Выбор сигмоидной функции обусловлен тем, что она обладает следующими свойствами:

- имеет непрерывные производные, которые требуются для обучения сети с помощью алгоритма обратного распространения ошибки;

- усиливает слабые сигналы в большей степени, чем сильные, что важно для достижения высокой точности результатов вычислений.

В процессе итеративного обучения перцептрона исходные данные разделяют на три составные части:

- обучающий набор (training set), используемый для вычисления весов нейросети;

- набор данных для множества перекрестных проверок (cross-validation set) и остановка процедуры обучения при достижении наилучшей обобщающей способности нейросети и предотвращения переобучения (слишком точной аппроксимации данных, когда сеть дает правильные ответы только для тех данных, на которых ее обучили);

- контрольный набор (test set), с помощью которого проверяется качество полученного аппроксиматора; это тестовое множество не используется при обучении.

Опыт применения нейронных сетей показывает, что объем обучающей последовательности не должен превышать число ее соединений более чем в 10 раз. В противном случае имеет место переобучение сети. Важную роль в процессе обучения перцептрона играет и время обучения сети.

В процессе обучения перцептрона происходит настройка его весовых коэффициентов таким образом, чтобы значения выходных сигналов как можно меньше отличались от их заданных образов для каждой из обучающих пар. Процедура обучения перцептрона заключается в следующем:

- на вход перцептрона подается некоторый тренировочный вектор из обучающего набора входных сигналов;

- по специальной процедуре происходит варьирование значений весовых коэффициентов в целях достижения возможно более близкого отображения (преобразования) набора тренировочных входных векторов в выходные векторы;

- на каждой итерации вычисляется разница (ошибка) между фактическим выходом и резуль-

татом прогноза, полученным с помощью нейросети;

процесс обучения завершается, когда ошибка достигает минимума на множестве перекрестных проверок или достигается установленное количество итераций.

Эффективность обучения сети можно повысить за счет следующих мероприятий:

- изменения порядка наблюдений в обучающих выборках различных итераций (для снижения вероятности попадания алгоритма в локальный минимум и исключения эффекта переобучения сети);

- варьирования значений коэффициента, определяющего скорость обучения сети, от величины 0,1 в начале итеративного процесса обучения до 0,01 — в конце;

- установления предельного числа итераций для обеспечения заданной точности обучения.

В связи с возможными изменениями характера моделируемого процесса параметры модели требуют периодической адаптации, которая выполняется в случае превышения допустимой погрешности вычислений и сопровождается процедурой переобучения ИНС на новых выборках данных с применением классических алгоритмов и общего принципа нормировки данных с максимизацией энтропии входов и выходов.

Исследование усилий в шатунах закрылков

В целях проведения исследований по решению задачи автоматизации контроля нагруженности ОСЭ конструкции ЛА на основе операционных систем реального времени разработана специализированная встраиваемая система, в которой для слежения за осредненными статическими и динамическими составляющими усилий в элементах системы управления самолетом (шатунах закрылков) использованы ИНС.

Возможность применения ИНС для мониторинга нагрузок в реальном времени экспериментально проверена в летных испытаниях по определению усилий в элементах механизации ЛА. В проведенных исследованиях с помощью ИНС определяли выходные переменные, соответствующие усилиям в шатунах левого и правого внутренних закрылков. Перечень входных переменных представлен в табл. 1.

Исходные данные параметров нагружения конструкции ЛА делятся на несколько групп, отличающихся способами первичной обработки для формирования выходных переменных, к которым относятся, прежде всего, усилия Ph , осредненные за интервал времени $\Delta t = 1$ с.

В целях наглядного представления наличия связи между двумя переменными и выявления

нелинейных зависимостей удобно строить диаграмму рассеяния, которая позволяет анализировать положение точек относительно диагональной прямой.

Осредненные усилия и среднеквадратические отклонения при обработке данных рассчитываются на скользящих интервалах по следующим формулам:

$$STPh(\Delta t_k) = \frac{1}{N} \sum_{i=1}^{i=N} Ph(t_i);$$

$$СКО(Ph(\Delta t_k)) = \sqrt{\frac{1}{N} \sum_{i=1}^{i=N} (dPh(t_i))^2},$$

где $dPh(t_i)$ — динамическая составляющая усилия; $Ph(t_i)$ — усилие в шатуне внутреннего закрылка; N — размер окна (256 отчетов); Δt_k — интервал времени, на котором производится осреднение; t_i — текущее время (время регистрации).

Осредненные значения $STPh$ и $СКО(Ph)$, полученные таким образом для секундных промежутков времени, подлежат линейной интерполяции для получения промежуточных величин, соответствующих значениям входных переменных, найденных с частотой опроса $f_{\text{опр}} = 16$ Гц.

Определение с помощью ИНС оценок нагруженности ОСЭ конструкции имеет преимущества по сравнению со статистическими методами, особенно в случаях, когда обрабатываются неполные входные данные, а также при наличии между входными данными нелинейной зависимости.




Рис. 3. Исходные значения усилий в шатуне левого внутреннего закрылка и оценки усилий по модели ИНС

Fig. 3. Comparison of the initial values of the loads in the connecting rod of the left inner flap and the estimates of the loads according to the model of an artificial neural network

На рис. 3 для шатуна левого внутреннего закрылка показаны совмещенные графики исходных значений усилий и оценок усилий, полученных по модели ИНС. Диаграмма рассеивания исходных значений и выходных оценок модели ИНС для переменных усилий в шатуне левого внутреннего закрылка представлена на рис. 4.

Оценка средней погрешности усилий показывает, что модель ИНС для переменных усилий в шатуне левого внутреннего закрылка дает среднюю ошибку около 4,8 %. Аналогичные результаты получены для шатуна правого внутреннего закрылка, для которого средняя ошибка составила менее 6 %. Видно, что применение модели ИНС для определения параметров нагружения позволяет в эксплуатации с высокой точностью оценивать историю нагружения конструкции, это

Таблица 1. Перечень входных параметров

Table 1. List of input parameters

Исх.	Обозначение	Название переменной	Единица измерения
1	t	Текущее время	с
2	H_{bar}	Высота барометрическая	М
3	V_{pr}	Скорость приборная	км/ч
4	Max	Число Маха	
5	N_{yf}	Перегрузка по оси Y в центре тяжести самолета	
6	N_{zf}	Перегрузка по оси Z в центре тяжести самолета	
7	Alf_u	Угол атаки самолета	Градусы
8	Bet_u	Угол скольжения самолета	
9	$Dzklv$	Угол отклонения левого закрылка	
10	W_x	Угловая скорость по крену	Градусы/с
11	W_z	Угловая скорость по тангажу	
12	Dst	Угол отклонения стабилизатора	Градусы
13	Drn	Угол отклонения руля направления	
14	$Dzkpr$	Угол отклонения правого закрылка	
15	q	Скоростной напор	кГ/м ²




Рис. 4. Отношение исходных и смоделированных с помощью нейронной сети данных

Fig. 4. The ratio of the initial and simulated data using a neural data network

дает возможность усовершенствовать методику оценки повреждаемости ОСЭ конструкции ЛА.

В процессе оптимизации структуры ИНС для определения нагруженности в элементах механизации крыла ЛА выбран трехслойный персептрон (рис. 5) с сигмоидной функцией активации нейронов.

Восстановление (прогноз) значений усилий в шатунах левого и правого внутренних закрылков проводили по отдельным процедурам, в результате которых были выбраны разные структуры ИНС. Структура и алгоритмы обучения ИНС представлены в табл. 2, где MLP $N_1 - N_1 - N_1$ — многослойный персептрон (multilayer perceptron); N_h — количество нейронов в слое h ; BFGS — алгоритм Бройдена – Флетчера – Гольдфарба – Шанно [13].

В процессе формирования оценки степени расхода ресурса конструкции повреждаемость, определяемую по стандартной процедуре [14, 15] в зависимости от фактических нагрузок, зарегистрированных с помощью системы мониторинга, следует относить к повреждаемости программы нагружения натурных испытаний, составленной на основе типовых полетов. Натурные испытания проводят в рамках сертификационных работ для определения величины назначенного ресурса.




Рис. 5. Структура персептрона

Fig. 5. Perceptron structure

Таким образом, расчетно-экспериментальные исследования, проведенные на основе материалов летных испытаний, показали, что применение методики мониторинга нагруженности на базе нейронных сетей позволяет достаточно точно определять нагрузки, действующие на элементы механизации крыла. Полученные результаты являются основой для формирования комплексной методики определения накопленной повреждаемости и оценки остаточного ресурса (от назначенного или проектного уровня) для различных типов воздушных судов. Внедрение методики позволит повысить эффективность всего комплекса мер, применяемого для поддержания летной годности в процессе эксплуатации транспортных самолетов.

ЛИТЕРАТУРА

1. Шибаев В. М., Матвеев В. А., Городниченко В. И. и др. Прогнозирование показателей надежности беспилотных воздушных судов / Труды ЦАГИ. 2021. № 2795. С. 4 – 14.
2. Суханов В. Л., Шибаев В. М., Матвеев В. А. и др. Методика балльной оценки показателей безопасности полета при сертификации воздушных судов беспилотных авиационных систем / Техника воздушного флота. 2021. Т. ХСIII. № 3 – 4(736 – 737). С. 32 – 47.
3. Пат. 2545150 Российская Федерация, МПК G01M 17/02. Способ контроля состояния конструкции летательного аппарата / Винокуров В. И., Зыков В. Н.; заявитель и патентообладатель Винокуров В. И., Зыков В. Н. — № 2014108188/11; заявл. 03.03.14; опубл. 27.03.15. Бюл. № 9.

Таблица 2. Структура и алгоритмы обучения ИНС для восстановления усилий в шатунах левого и правого внутренних закрылков

Table 2. Structure and training algorithms of neural networks for determining the forces in the connecting rods of the left and right inner flaps

Переменные	Усилия в шатуне левого закрылка Ph_1	Усилия в шатуне правого закрылка Ph_2
Структура сети	MLP 13-9-1	MLP 13-15-1
Алгоритмы обучения	BFGS 209	BFGS 322
Распределение остатков	Нормальное	Нормальное
Диаграмма рассеивания	Точки на прямой	Точки на прямой
Средняя ошибка прогнозирования	4,8 %	6,0 %

4. Пат. 2599108 Российская Федерация, МПК B64F 5/00, G01D 21/00. Способ мониторинга нагрузок и накопленной усталостной повреждаемости в условиях эксплуатации самолета / Цымбалюк В. И., Орлова Т. И., Фролов А. В.; заявитель и патентообладатель Федеральное государственное унитарное предприятие «Центральный аэрогидродинамический институт имени профессора Н. Е. Жуковского» (ФГУП «ЦАГИ») — № 2015127185/11; заявл. 07.07.15; опубл. 10.10.16. Бюл. № 28.
5. **Баутин А. А.** Мониторинг элементов авиационных конструкций по данным тензометрии / Заводская лаборатория. Диагностика материалов. 2019. Т. 85. № 1. С. 57 – 63. DOI: 10.26896/1028-6861-2019-85-1-I-57-63
6. **Баутин А. А., Свирский Ю. А., Панков А. В.** Мониторинг состояния конструкции с помощью анализа кинетики местного напряженно-деформированного состояния / Заводская лаборатория. Диагностика материалов. 2019. Т. 85. № 2. С. 42 – 47. DOI: 10.26896/1028-6861-2019-85-2-42-47
7. **Урнев А. С., Чернятин А. С., Матвиенко Ю. Г., Разумовский И. А.** Экспериментально-численное определение размеров дефектов типа расслоения в слоистых композитных материалах / Заводская лаборатория. Диагностика материалов. 2018. Т. 84. № 10. С. 59 – 66. DOI: 10.26896/1028-6861-2018-84-10-59-66
8. **Урнев А. С., Чернятин А. С., Матвиенко Ю. Г., Разумовский И. А., Гавриков М. Ю.** Исследование кинетики разрушения композитной панели с применением сетки встроенных волоконно-оптических датчиков / Машиностроение и инженерное образование. 2019. № 3. С. 18 – 27.
9. Пат. № 2595066 Российская Федерация, МПК B64F 5/00, G01M 7/02, G06N 3/08. Способ оценки нагружения конструкции самолета при летных прочностных исследованиях с использованием искусственных нейронных сетей / Лучинский М. Н., Арнаутков Е. В., Орлов А. А., Хоменко А. Г., Балашова Т. А.; заявитель и патентообладатель открытое акционерное общество «Летно-исследовательский институт имени М. М. Громова» — № 2015124804/11; заявл. 24.06.15; опубл. 20.08.16. Бюл. № 23.
10. **Zheng J., Jiao S., Cui D.** Application of Principal Component Analysis-Assisted Neural Networks for the Rotor Blade Load Prediction / International Journal of Aerospace Engineering. 2021. Vol. 2021. Article ID 5594102. P. 13. DOI: 10.1155/2021/5594102
11. **Candon M., Esposito M., Fayek H., et al.** Advanced multi-input system identification for next generation aircraft loads monitoring using linear regression, neural networks and deep learning / Mechanical Systems and Signal Processing. 2022. Vol. 171. N 108809. P. 25. DOI: 10.1016/j.ymssp.2022.108809
12. **Hornik K., Stinchcombe M., White H.** Multilayer feedforward networks are universal approximations / Neural Networks. 1989. Vol. 2. P. 359 – 366.
13. **Cybenko G.** Approximation by superpositions of a sigmoidal function / Mathematics of Control. Signals and Systems. 1989. Vol. 2. P. 303 – 314.
14. **Funahashi K.** On the approximate realization of continuous mappings by neural networks / Neural Networks. 1989. Vol. 2. N 3. P. 183 – 191.
15. **Bautin A., Svirskiy Y.** Applying Neural Networks for Multi-site Damage Detection in Fuselage Lap Joints of Cargo Aircraft / Lecture Notes in Civil Engineering. 2021. Vol. 128. P. 67 – 76. DOI: 10.1007/978-3-030-64908-1_7
16. **Бюшгенс А. Г., Городниченко В. И., Десятник П. А., Овсянников М. О., Шибяев В. М., Студнев С. Р.** Оценка безопасного срока службы тренажера пространственной дезориентации на основе анализа усталостной прочности и безопасности повреждения конструктивных элементов / Проблемы безопасности полетов. 2020. № 12. С. 3 – 11.
2. **Sukhanov V. L., Shibaev V. M., Matveev V. A., et al.** The method of scoring flight safety indicators in the certification of unmanned aircraft systems / Tekhn. Vozd. Flota. 2021. Vol. XCIII. N 3 – 4(736 – 737). P. 32 – 47 [in Russian].
3. RF Pat. 2545150, MPK G01M 17/02. Method of aircraft structure inspection / Vinokurov V. I., Zykov V. N.; applicant and patent holder Vinokurov V. I., Zykov V. N. — N 2014108188/11; appl. 03.03.14; publ. 27.03.15. Byull. N 9 [in Russian].
4. RF Pat. 2599108, MPKV 64F 5/00, G01D 21/00. A method for monitoring loads and accumulated fatigue damage under aircraft operating conditions / Tsymbalyuk V. I., Orlova T. I., Frolov A. V.; applicant and patent holder Federalnoe gosudarstvennoe unitarnoe predpriyatie "Tsentrallyy aerogidrodinamicheskii institut imeni professora N. E. Zhukovskogo" (FGUP "TsAGI") — N 2015127185/11; appl. 07.07.15; publ. 10.10.16, Byull. N 28 [in Russian].
5. **Bautin A. A.** Monitoring of the elements of aviation structures using strain-gauge measurement / Zavod. Lab. Diagn. Mater. 2019. Vol. 85. N 1(I). P. 57 – 63 [in Russian]. DOI: 10.26896/1028-6861-2019-85-1-I-57-63
6. **Bautin A. A., Svirsky Yu. A., Pankov A. V.** Development of structural health monitoring methods through the analysis of kinetics of local stress-strain state. / Zavod. Lab. Diagn. Mater. 2019. Vol. 85. N 2. P. 42 – 47 [in Russian]. DOI: 10.26896/1028-6861-2019-85-2-42-47
7. **Urnev A. S., Chernyatin A. S., Matvienko Yu. G., Razumovskii I. A.** Experimental and numerical sizing of a delamination defect in layered composite materials / Zavod. Lab. Diagn. Mater. 2018. Vol. 84. N 10. P. 59 – 66 [in Russian]. DOI: 10.26896/1028-6861-2018-84-10-59-66
8. **Urnev A. S., Chernyatin A. S., Matvienko Yu. G., Razumovskii I. A., Gavrikov M. Yu.** Studying the destruction kinetics of a composite panel with a embedded fiber-optic sensors grid / Mashinostr. Inzh. Obrazov. 2019. N 3. P. 18 – 27 [in Russian].
9. RF Pat. 2595066, MPK V64F 5/00, G01M 7/02, G06N 3/08. A method for assessing the loading of an aircraft structure during flight strength tests using artificial neural networks / Luchinskiy M. N., Arnautov E. V., Orlov A. A., Homenko A. G., Balashova T. A.; applicant and patent holder otkrytoe aktsionernoe obshchestvo "Lyotno-issledovatel'skij institut imeni M. M. Gromova" — N 2015124804/11; appl. 24.06.15; publ. 20.08.16, Byull. N 28 [in Russian].
10. **Zheng J., Jiao S., Cui D.** Application of Principal Component Analysis-Assisted Neural Networks for the Rotor Blade Load Prediction / International Journal of Aerospace Engineering. 2021. Vol. 2021. Article ID 5594102. P. 13. DOI: 10.1155/2021/5594102
11. **Candon M., Esposito M., Fayek H., et al.** Advanced multi-input system identification for next generation aircraft loads monitoring using linear regression, neural networks and deep learning / Mechanical Systems and Signal Processing. 2022. Vol. 171. N 108809. P. 25. DOI: 10.1016/j.ymssp.2022.108809
12. **Hornik K., Stinchcombe M., White H.** Multilayer feedforward networks are universal approximations / Neural Networks. 1989. Vol. 2. P. 359 – 366.
13. **Cybenko G.** Approximation by superpositions of a sigmoidal function / Mathematics of Control. Signals and Systems. 1989. Vol. 2. P. 303 – 314.
14. **Funahashi K.** On the approximate realization of continuous mappings by neural networks / Neural Networks. 1989. Vol. 2. N 3. P. 183 – 191.
15. **Bautin A., Svirskiy Y.** Applying Neural Networks for Multi-site Damage Detection in Fuselage Lap Joints of Cargo Aircraft / Lecture Notes in Civil Engineering. 2021. Vol. 128. P. 67 – 76. DOI: 10.1007/978-3-030-64908-1_7
16. **Bushgens A. G., Gorodnichenko V. I., Desyatnik P. I., Ovsyannikov M. O., Shibaev V. M., Studnev S. R.** Assessment of safe service life of spatial disorientation simulators based on the analysis of fatigue strength and safety of structural component damage / Probl. Bezopasn. Poletov. 2020. 12. P. 3 – 11 [in Russian].

REFERENCES

1. **Shibaev V. M., Matveev V. A., Gorodnichenko V. I., et al.** Forecasting the Reliability Indicators of Unmanned Aircraft / Tr. TsAGI. 2021. N 2795. P. 4 – 14 [in Russian].