

УДК 004: 629.7

НЕЙРОСЕТЕВЫЕ ТЕХНОЛОГИИ В ПОЛУНАТУРНОМ МОДЕЛИРОВАНИИ: ПРИНЦИПЫ РЕАЛИЗАЦИИ ЦИФРОВЫХ ДВОЙНИКОВ ГТД

А. И. АБДУЛНАГИМОВ¹, Г. К. АГЕЕВ²

¹abdulnagimov@yandex.ru, ²ageevgeo@mail.ru

ФГБОУ ВО «Уфимский государственный авиационный технический университет» (УГАТУ)

Поступила в редакцию 09.11.2019

Аннотация. Рассматривается принцип реализации цифровых двойников в авиадвигателестроении – создание математических моделей газотурбинных двигателей в виде рекуррентных нейронных сетей и применение их в полунатурном комплексном моделировании для отладки систем автоматического управления, контроля и диагностики. Описывается методика построения нейросетевой модели сложного технического объекта, особенности реализации модели на стенде полунатурного моделирования. Приводятся результаты имитационного и полунатурного моделирования параметров авиационного двигателя. Проводится анализ точности и адекватности модели. Показано, что развитие подобных методик позволяет решать задачи анализа и синтеза систем управления, их оптимизации и повышения надежности на существенно другом технологическом уровне.

Ключевые слова: ГТД; цифровой двойник; машинное обучение; динамическая модель; рекуррентная нейронная сеть; полунатурное моделирование.

ВВЕДЕНИЕ

Экспериментальные исследования и моделирование газотурбинных двигателей (ГТД) и их систем управления являются постоянными элементами познания поведения сложного технического объекта во всем его жизненном цикле, начиная с этапа проектирования, доводки, сертификации и заканчивая эксплуатацией и утилизацией. Такие исследования требуют создания специальной технологии комплексного моделирования, которая позволяет подтвердить надежность, работоспособность, требуемые характеристики систем до установки их на двигатель или самолет.

Сегодня развитие машиностроительной и топливо-энергетической промышленности опирается на технологии цифрового производства, компьютерного моделирования, машинного обучения, облачных вычислений и киберфизических систем. В полной мере реализуется концепция «цифровых

двойников» – виртуального представления физического объекта не только на этапах проектирования, доводки и запуска в производство, как это было раньше, но и на протяжении всего жизненного цикла, включая эксплуатацию и утилизацию [1].

В авиакосмической отрасли технология полунатурного моделирования сложных объектов управления, где реальные системы сопряжены с математическими моделями объектов управления, применяется уже давно. Однако методики и инструменты создания таких моделей зачастую остаются прежними.

Одной из наиболее важных и актуальных проблем является обеспечение адекватности полунатурной модели газотурбинной силовой установки и элементов системы автоматического управления, контроля и диагностики (САУКиД). Одновременная работа алгоритмов управления, контроля и диагностики может приводить к различным «кол-

лизиям», которые необходимо моделировать и учитывать при проектировании и доводке системы управления.

Кроме того, в процессе эксплуатации летательного аппарата двигателя постепенно вырабатывают свой ресурс и их характеристики начинают деградировать. В процессе анализа и синтеза систем автоматического управления возникает необходимость коррекции и адаптации существующей модели ГТД под конкретный двигатель для эффективной его эксплуатации. Для решения такой проблемы необходимы адаптивные модели, которые идентифицируются по реальным характеристикам объекта и условиям его эксплуатации.

В последние годы интеллектуальные технологии на основе нейронных сетей находят широкое применение в исследованиях и разработках сложных систем управления и контроля газотурбинными силовыми установками [2–5]. Однако остается проблема адекватности и применимости математических моделей ГТД на полунатурных стендах, которые в большинстве своем представляются в виде быстросчетных кусочно-линейных динамических моделей [6, 7].

Целью исследования является повышение эффективности полунатурного комплексного моделирования и тестирования реальной САУКИД за счет использования нелинейных динамических математических моделей ГТД и их систем в виде рекуррентных нейронных сетей в составе стенда. Предлагается методика построения рекуррентной нейросетевой модели газотурбинного двигателя, включающая алгоритмы обучения и идентификации математической модели двигателя по реальным данным с выбором структуры и размера сети.

РЕАЛИЗАЦИЯ НЕЙРОСЕТЕВОЙ МОДЕЛИ ГТД

Математическое представление нелинейной динамической модели двухвального ГТД можно представить в виде системы дифференциальных уравнений, где a_{ij} и b_{ij} – коэффициенты для каждого режима, управляющий сигнал G_T – расход топлива, переменные состояния на предыдущем шаге: (n_{i-1}) – частоты вращения роторов низкого

(n_1) и высокого (n_2) давления, $(T_{ТНД-1})$ – температура за турбиной, $(\pi_{К-1})$ – степени повышения давления за компрессором, $(\alpha_{РНА-1})$ – угол положения направляющих аппаратов.

$$\left\{ \begin{array}{l} \Delta \dot{n}_{1i} = a_{11} \cdot \Delta n_{1i-1} + a_{12} \cdot \Delta n_{2i-1} + a_{13} \cdot \Delta T_{ТНДi-1} + \dots \\ \dots a_{14} \cdot \Delta \pi_{Кi-1} + b_{11} \cdot \Delta G_{Ti} ; \\ \Delta \dot{n}_{2i} = a_{21} \cdot \Delta n_{1i-1} + a_{22} \cdot \Delta n_{2i-1} + a_{23} \cdot \Delta T_{ТНДi-1} + \dots \\ \dots a_{24} \cdot \Delta \pi_{Кi-1} + \dots + b_{21} \cdot \Delta G_{Ti} ; \\ \Delta \dot{T}_{ТНДi} = a_{31} \cdot \Delta n_{1i-1} + a_{32} \cdot \Delta n_{2i-1} + a_{33} \cdot \Delta T_{ТНДi-1} + \\ \dots + a_{34} \cdot \Delta \pi_{Кi-1} + \dots + b_{31} \cdot \Delta G_{Ti} ; \\ \Delta \dot{\pi}_{Ki} = a_{41} \cdot \Delta n_{1i-1} + a_{42} \cdot \Delta n_{2i-1} + a_{43} \cdot \Delta T_{ТНДi-1} + \dots \\ \dots a_{44} \cdot \Delta \pi_{Кi-1} + \dots + b_{41} \cdot \Delta G_{Ti} . \end{array} \right.$$

Для построения такой нелинейной динамической модели предлагается использовать рекуррентный многослойный перцептрон (NARX – nonlinear autoregressive neural network with external input), который представляет собой динамическую сеть, характеризующуюся запаздыванием входных и выходных сигналов, объединяемых во входной вектор сети (рис. 1).

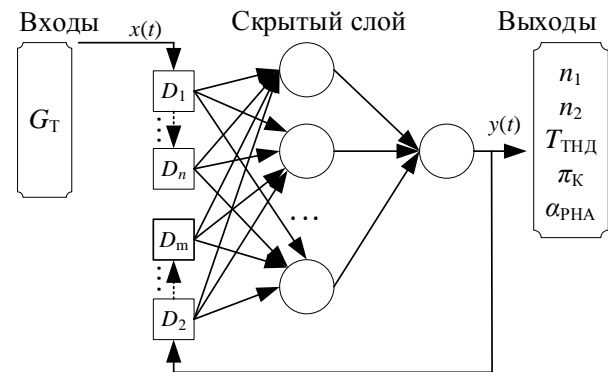


Рис. 1. Рекуррентная сеть с одним скрытым слоем

Такая математическая модель в виде НС с обратной связью позволяет учитывать нелинейные динамические характеристики двигателя и гарантировать его структурно-параметрическую адекватность аналитической модели ГТД.

Поддаваемый на вход вектор x имеет вид $x(t)=[1, x(t), x(t-1), \dots, x(t-D_1), y(t-D_2), y(t-(D_2+1)), \dots, y(t-1)]^T$, где D_n – количество задержек входного сигнала, D_m – количество задержек выходного сигнала. В зависимости от модели ГТД (запуска или вы-

сотных режимов) вектор x формируется по параметрам, указанным в ТЗ, например, высота, скорость, расход топлива, режим работы двигателя, дискретные параметры запуска/останова стартера и т.д. Выходной вектор сети имеет отображение:

$$y(t+1) = f(x(t), x(t-1), \dots, x(t-D_n), y(t-1), y(t-2), \dots, y(t-D_m)),$$

тогда рекуррентная сеть характеризуется набором чисел (D_n, D_m, K_n) , где K_n – количество нейронов в i -м скрытом слое.

НС обучается для земных-высотных режимов или режима запуска. Для каждого из режимов нейронная сеть моделирует весь комплекс параметров. Для обучения предлагается использовать алгоритм шкалированных сопряженных градиентов [8], который позволяет обучать большие массивы данных и решает проблему переполнения оперативной памяти, где алгоритмы байесовской регуляризации и Левенберга–Марквардта не справляются. Также при обучении большого объема данных для увеличения производительности вычислений применяются процедуры MapReduce/MemoryReduce и параллельных вычислений.

Кратко методику идентификации математической модели ГТД по реальным характеристикам можно представить в виде рис. 2.

Идентификация проводится на основе данных, зарегистрированных с помощью электронной системы управления (ЭСУ) во время полета ЛА или натурных испытаний. Данные регистрации хранятся в виде отдельных бинарных файлов и считываются с помощью специальной программы регистрации. Интересующие режимы выбираются и импортируются в среды разработки, такие как Matlab, или дистрибутивы языков программирования Python и R. Далее определяются входные и выходные массивы параметров ГТД. Проводится предварительная обработка данных для соответствия уникальности (неповторимости) выборки, непротиворечивости и репрезентативности.

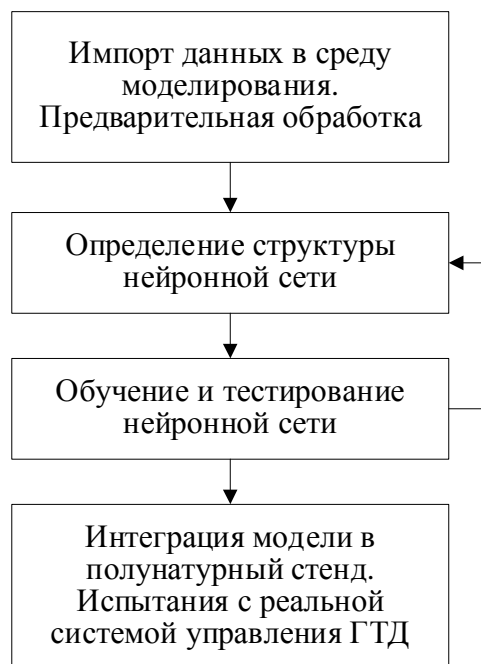


Рис. 2. Методика идентификации ММ ГТД по реальным данным

Задается структура НС: один или два скрытых слоя с радиально-базисной функцией или функцией активации Эллиота вида

$$f(x) = \frac{x}{(1+|x|)}.$$

Функция Эллиота представляет собой модификацию сигмоидальной функции гиперболического тангенса и является более быстрой аппроксимацией сигмоидной функции. При инициализации задаются очень маленькие весовые коэффициенты, что существенно сказывается на качестве обучения. Минимизация функционала ошибок осуществляется на основе взвешенной оценки дисперсии

$$\sigma^2 = \sum_{i=1}^n w_i (x_i - \bar{x}),$$

где веса являются позитивными значениями

$$\text{и } \sum_{i=1}^n w_i = 1.$$

Обучение проводится с учителем и с разомкнутой сетью, когда управляющие сигналы и ожидаемые выходные параметры с учетом задержек подаются на вход от-

дельно. Выходные результаты моделирования сети не учитываются. В таком режиме НС легче обучается. Затем сеть замыкают (выход подключают ко входу), чтобы обеспечить динамичное моделирование параметров, где НС начинает работать с учетом смоделированных выходных значений, которые подаются на вход. НС тестируется на точность, чтобы ответы сети минимально отличались от целевых значений. Для проверки применяют другие выборки, чтобы проверить адекватность модели.

Последний этап заключается в интеграции модели в ПО полунатурного стенда и настройке работы модели в реальном времени. Нейросетевая модель ГТД сопрягается с реальной САУКиД и работает в замкнутом цикле, выступая в роли прототипа «цифрового двойника». Модель неоднократно дообучается в процессе эксплуатации САУКиД и уточняется по результатам натурных испытаний.

Для исследования нейросетевой методики в работе использованы переходные процессы двухконтурного турбореактивного двигателя на земных режимах (рис. 3). Па-

раметры: G_T – расход топлива, частоты вращения роторов низкого (n_1) и высокого (n_2) давления, ($T_{ТНД-1}$) – температура за турбиной, ($\pi_{к-1}$) – степени повышения давления за компрессором, ($\alpha_{РНА-1}$) – угол положения направляющих аппаратов. Дискретность данных – 200 Гц, объем выборки $6 * 50000$. Для обучения использовалась среда Matlab с пакетом Deep Learning Toolbox [9].

После обучения для оценки обобщающей способности нейросетевой модели ГТД использовалась расширенная выборка $6*58000$, где последние 8000 значений – резкий процесс перехода от малого газа до «максимала».

Результаты имитационного моделирования пяти параметров (частот вращения роторов низкого и высокого давления, температуры за турбиной, положения направляющих аппаратов, степени повышения давления за компрессором) показали, что максимальная ошибка моделирования составила менее 1%. На рис. 4 и 5 представлены реальный и смоделированный процессы частот вращения ротора низкого давления и температуры газов за турбиной низкого давления.




Рис. 3. Исходные данные для обучения (переходные процессы двухконтурного турбореактивного двигателя на режимах $M=0$, $H=0$)

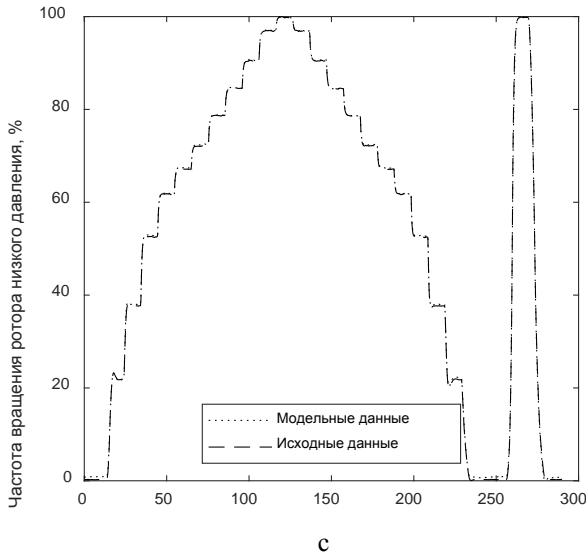


Рис. 4. Результат тестирования нейросетевой модели ГТД (параметр n_1)

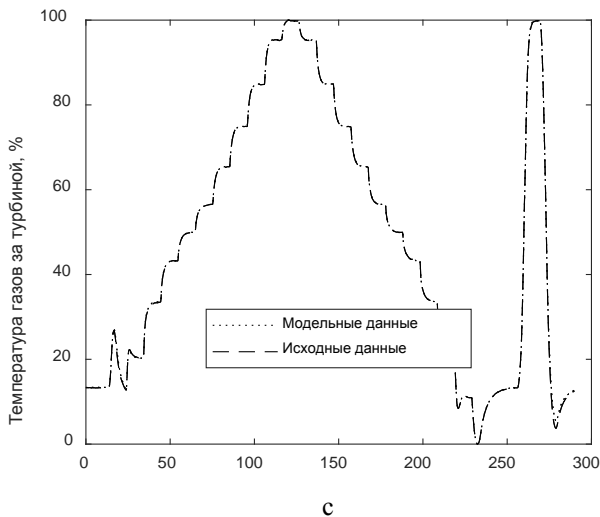


Рис. 5. Результат тестирования нейросетевой модели ГТД (параметр $T_{гнд}$)

ПОЛУНАТУРНОЕ МОДЕЛИРОВАНИЕ И АПРОБАЦИЯ МОДЕЛИ

На рис. 6 представлена схема взаимодействия нейросетевой модели ГТД со стендом полунатурного моделирования (СПМ). Модель ГТД разбита на два цикла времени, каждый из которых выполняется на отдельном ядре центрального процессора ПЭВМ. В основном цикле с наивысшим приоритетом осуществляется прием данных от СПМ и работа нейросетевой модели. В другом цикле с меньшим приоритетом осуществляется передача рассчитанных модельных данных на СПМ.

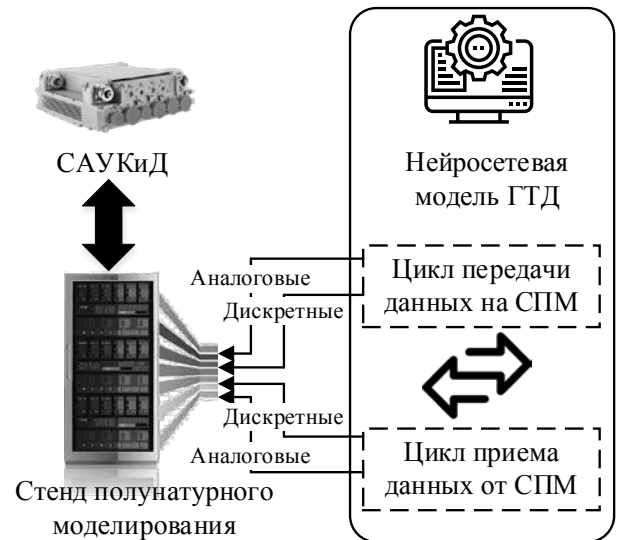


Рис. 6. Схема взаимодействия модели ГТД с СПМ

Разделение на два цикла времени между ядрами процессора с различными приоритетами необходимо для обеспечения работы модели в реальном времени.

СПМ работает с графической средой имитационного моделирования Simulink пакета Matlab. В ней реализуются каналы информационного обмена, имитатор дозатора топлива, система визуализации, записи и др. Интеграция обученной нейросетевой модели ГТД в формат Simulink производится встроенными средствами, представляет собой простую процедуру, что и объясняется выбором данного пакета для реализации моделей. Пример сгенерированного блока НС (структура скрытого слоя) в среде Simulink показан на рис. 7.

Результат моделирования процесса запуска ГТД в составе полунатурного стенда приведен на рис. 8. Представлена характеристика частоты вращения ротора низкого давления в сравнении с эталонными характеристиками: сплошной линией нарисованы смоделированные характеристики, а пунктирной — эталонные значения n_1 . Видно, что нейронная сеть менее точно работает на участках с резкими переходами — такими, как отключение стартера (~41 секунда), выход на режим (~47 секунда). Максимальное отклонение частоты n_1 составляет 3,6%, а отклонение n_2 — 2,4%.




Рис. 7. Структура представления скрытого слоя нейронной сети в Matlab Simulink (30 нейронов)




Рис. 8. Результаты полунатурных испытаний модели запуска ГТД: характеристика частоты вращения ротора n_1 в сравнении с эталонной характеристикой

Результат моделирования работы ГТД на основных земных режимах при условии $H=0$ м, $M=0$ в составе стенда полунатурного моделирования приведен на рис. 9. Представлена характеристика частоты вращения ротора низкого давления в сравнении с эталонной характеристикой: сплошной линией нарисована смоделированная характеристика, а пунктирной – эталонное значение параметра n_1 . Максимальное отклонение частот вращения n_1 и n_2 – 0,3%.

Максимальное отклонение параметра $T_{ТНД}$ составляет $\approx 2\%$, отклонение степени повышения давления π_k – 0,8%, параметра $\alpha_{РНА}$ – 0,9%




Рис. 9. Результаты полунатурных испытаний модели земных режимов работы ГТД: характеристика частот вращений ротора n_1 в сравнении с эталонными характеристиками

ЗАКЛЮЧЕНИЕ

Предложен принцип реализации цифровых двойников в авиадвигателестроении. Разработанная методика идентификации и моделирования на основе рекуррентных НС, учитывающая динамическую характеристику двигателя с соблюдением структурной и параметрической адекватности аналитической модели. Рассмотрено применение методики для полунатурного комплексного моделирования и отладки систем автоматического управления, контроля и диагностики ГТД. Методика позволяет получать адекватные модели ГТД для любого режима работы.

Апробация проведена на полунатурном стенде в составе САУКиД для режимов работы во время запуска, на земле и в полете. Подтверждена точность, необходимая для решения задач управления и формирования требований к агрегатам электронных систем управления.

В процессе деградации (для обеспечения всего жизненного цикла) нейросетевая модель ГТД будет дополнительно обучаться, чтобы точно коррелировать с физическим объектом, и тем самым будет служить инструментом для решения задач анализа и синтеза систем управления, их оптимизации и повышения надежности.

СПИСОК ЛИТЕРАТУРЫ

1. **Васильев А. Н., Тархов Д. А., Малыхина Г. Ф.** Методы создания цифровых двойников на основе нейросетевого моделирования // Современные информационные технологии и ИТ-образование. 2018. Т. 14, № 3. С. 521–532. [A. N. Vasilyev, D. A. Tarkhov, G. F. Malykhina, "Methods of creating digital twins based on neural network modeling", (in Russian), in *Sovremennye informacionnye tekhnologii i IT-obrazovanie*, vol. 14, no. 3, pp. 521-532, 2018.]
2. **Концевич А. Г., Епифанов С. В.** Учет фактора времени при идентификации модели ГТД искусственной нейронной сетью // Авиационно-космическая техника и технология. 2006. № 10 (36). С. 144–151. [A. G. Kontsevich, S. V. Epifanov, "Accounting for time factor in identification of gas turbine engine model using artificial neural network", (in Russian), in *Aviacionno-kosmicheskaya tekhnika i tekhnologiya*, no. 10 (36), pp. 144-151, 2006.]
3. **Жернаков С. В.** Идентификация характеристик ГТД на основе технологии нейронных сетей // Информационные технологии. 2010. № 3. С. 39–47. [S. V. Zhernakov, "Identification of gas turbine engines characteristics on neural network technology", (in Russian), in *Informacionnye tekhnologii*, no. 3, pp. 39-47, 2010.]
4. **Butterweck A., Gluch J.** Neural Network Simulator's Application to Reference Performance Determination of Turbine Blading in the Heat-Flow Diagnostics. In: *Intelligent Systems in Technical and Medical Diagnostics. Part I.* Springer Berlin Heidelberg. 2014. Pp. 137-147.
5. **Asgari H., Chen X.** Gas Turbines Modeling, Simulation, and Control: Using Artificial Neural Networks // CRC Press, Taylor & Francis Group, 2016. 190 p.
6. **Методика** представления и использования многомерной характеристики винтовентилятора при полунатурном моделировании ГТД и его САУ / И. А. Кривошеев и др. // Известия вузов. Авиационная техника. 2010. № 1. С. 37–40. [I. A. Krivosheev et. al., "A technique for presentation and application of the propeller fan multidimensional characteristics in semi-full-scale simulation of a gas turbine engine and its automatic control system", (in Russian), in *Izvestiya vuzov. Aviacionnaya tekhnika*, vol. 53, no. 1, pp. 57-62, 2010.]
7. **Методология** комплексного полунатурного функционального моделирования ГТД и его систем / Г. Г. Куликов и др. // Вестник Самарского государственного аэрокосмического университета им. академика С. П. Королёва. 2009. № 3-2 (19). С. 392–400. [G. G. Kulikov et. al., "Methodology of complex hardware-in-the-loop functional modelling of gas turbines and its systems", (in Russian), in *Vestnik Samarского gosudarstvennogo aerokosmicheskogo universiteta im. akademika S. P. Korolyova*, no. 3-2 (19), pp. 392-400, 2009.]
8. **Moller M. F.** A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning, in *Neural Networks*, vol. 6, pp. 525-533, 1993.
9. **Beale M. H., Hagan M. T., Demuth H. B.** Deep Learning Toolbox™ User's Guide [Электронный ресурс]. URL: <https://www.mathworks.com/help/deeplearning/index.html>; jsessionid=c898439ee193cf09f2b8f14dd2fb (дата обращения 01.10.2019). [M.H. Beale, M.T. Hagan, H. B. Demuth, Deep Learning Toolbox™ User's Guide [Online]. Available: <https://www.mathworks.com/help/deeplearning/index.html>; jsessionid=c898439ee193cf09f2b8f14dd2fb]

ОБ АВТОРАХ

АБДУЛНАГИМОВ Ансаф Ирекович, доц. каф. АСУ. Дипл. магистра техн. и технол. (УГАТУ, 2007). Канд. техн. наук по сист. анализу и управлению (УГАТУ, 2012). Иссл. в обл. автоматич. упр., идентификации и сист. безопасности авиац. двигателей.

АГЕЕВ Георгий Константинович, доц. каф. авиационных двигателей. Дипл. инж. по авиационным двигателям (УГАТУ, 2007), канд. техн. наук (УГАТУ, 2012). Иссл. в обл. моделирования параметров агрегатов ГТД и энергоустановок летательных аппаратов по наработке.

METADATA

Title: Neural network technologies in hardware-in-the-loop simulation: principles of gas turbine digital twin development.

Authors: A. I. Abdunagimov¹, G. K. Ageev²

Affiliation:

Ufa State Aviation Technical University (UGATU), Russia.

Email: ¹abdunagimov@yandex.ru, ²ageevgeo@mail.ru

Language: Russian.

Source: Vestnik UGATU (scientific journal of Ufa State Aviation Technical University), vol. 23, no. 4 (86), pp. 115-121, 2019. ISSN 2225-2789 (Online), ISSN 1992-6502 (Print).

Abstract: The principle of gas turbine digital twin development, the creation of a mathematical model of a gas turbine engine based on the recurrent neural network and its application in complex hardware-in-the-loop modeling for tuning automatic control, condition-monitoring and diagnostic systems, is considered. The technique of creation a neural network model of the complex technical object and the features of its integration in the hardware-in-the-loop test-bed are described. The results of modelling and hardware-in-the-loop simulation of aircraft engine parameters are presented. The accuracy and adequacy of the constructed model is analyzed. It is shown that the development of such methodologies solves the problem of analysis and synthesis of control systems, their functional optimization and reliability improvement on a completely different technological level.

Key words: gas turbine engine; digital twine; machine learning; dynamic model; recurrent neural network; hardware-in-the-loop simulation.

About authors:

ABDULNAGIMOV, Ansaф Irekovich, associate professor of automated control and management systems department. Master of Technics & Technology (USATU, 2007). Dr. of Tech. Sci. in syst. analysis and control (USATU, 2012). Scientific interests: automatic control, identification and system safety of aircraft engines.

AGEEV, George Konstantinovich, associate professor of aircraft engines department. Dipl. Ing. of aviation engines (USATU, 2007). Candidate of Tech. Sci. (USATU, 2012). Scientific interests: parameter modeling of gas turbine engines and power plants of aircraft.