

Многоагентная система поддержки жизненного цикла сложного технического объекта

А.И. Загитова
Факультет информатики и робототехники
Уфимский
государственный авиационный технический
университет
Уфа, Россия
e-mail: zagitova92@mail.ru

Н.В. Кондратьева
Факультет информатики и робототехники
Уфимский
государственный авиационный технический
университет
Уфа, Россия
e-mail: knv24@mail.ru

С.С. Валеев
Факультет информатики и робототехники
Уфимский
государственный авиационный технический
университет
Уфа, Россия
e-mail: vss2000@mail.ru

Аннотация¹

В процессе реализации жизненного цикла сложного технического объекта, например, газотурбинного авиационного двигателя, генерируется огромное количество различной информации, что требует новых решений для ее эффективного использования. Предлагается применение агентных технологий для повышения качества процессов управления этапами жизненного цикла сложного технического объекта, повышения эффективности процедур обмена информацией и сокращения затрат временных и аппаратных ресурсов.

1. Введение

Период создания и существования технического объекта от этапа разработки технического задания до утилизации, называется его жизненным циклом. В ходе реализации жизненного цикла сложного технического объекта генерируется, передается, хранится и обрабатывается большой объем различной информации. В авиадвигателестроении на данный момент является актуальной проблема автоматизированного управления постоянно возрастающим объемом информации, информационными потоками и сложностью их обработки в процессе всего жизненного цикла авиационного двигателя [1]. Применение интеллектуальных информационных технологий

Труды шестой всероссийской научной конференции "Информационные технологии интеллектуальной поддержки принятия решений", 28-31 мая, Уфа, Россия, 2018

поддержки жизненного цикла авиационного двигателя дает возможность решения этой проблемы.

2. Жизненный цикл авиационного двигателя

Жизненный цикл (ЖЦ) авиационного двигателя включает в себя следующие основные этапы: этап проектирования, этап производства, этап технической эксплуатации и этап утилизации [2,3].

Более подробно ЖЦ газотурбинного авиационного двигателя (ГТД) представлен на рис. 1.

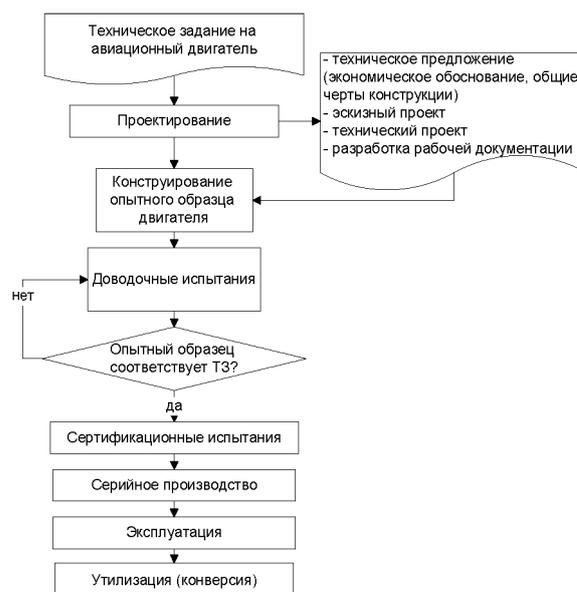


Рис. 1. Схема жизненного цикла газотурбинного авиационного двигателя

Техническое задание на ГТД разрабатывается на основе технического задания на летательный аппарат. На этапе проектирования разрабатывается пакет технических документов, детализирующий конструкцию ГТД и его агрегатов и процесс их производства. После создания опытных образцов агрегатов двигателя, производятся их доводочные испытания для обеспечения соответствия рабочих параметров ГТД техническому заданию [4]. При обнаружении несоответствий опытные образцы отправляются на доработку, и этот этап жизненного цикла ГТД может длиться до 10 лет. Следующим этапом ЖЦ ГТД являются сертификационные испытания перед запуском двигателя в серийное производство. На этапе эксплуатации двигателя на летательном аппарате происходит износ агрегатов, и при достижении определенного предела износа ГТД утилизируется, либо отправляется на конверсию, т.е. для использования в наземных газотурбинных энергетических установках.

2.1. Интеллектуальные информационные технологии поддержки ЖЦ ГТД

В настоящее время авиадвигателестроительные предприятия используют различные системы автоматизации на различных этапах ЖЦ ГТД, в частности, системы автоматизированного проектирования, автоматизированные системы производства, автоматизированные системы технологической подготовки, системы управления базами данных о выпускаемой продукции др.

В последние годы происходит активное внедрение нейросетевых технологий на этапах проектирования и эксплуатации ГТД. [5-7]

Однако системы поддержки ЖЦ ГТД на основе агентных технологий имеют потенциал охвата всего жизненного цикла изделия, поскольку способны обеспечить интеллектуальную обработку информации, генерируемой в ходе ЖЦ ГТД и обмен этой информацией между различными предприятиями и их структурными подразделениями в унифицированном виде.

3. Гибридный метод повышения качества нейросетевой аппроксимации характеристик агрегатов ГТД

Предложенный в [8,9] метод аппроксимации характеристик компрессора с применением искусственных нейронных сетей (ИНС) имеет существенный недостаток – низкое качество аппроксимации по причине небольшого объема обучающей выборки данных. В качестве обучающей выборки для ИНС использовались значения параметров работы компрессора, полученные в результате стендовых полунатурных испытаний агрегатов авиационного газотурбинного двигателя. Временные и материальные затраты на проведение стендовых и летных испытаний опытных образцов двигателя или его агрегатов очень значительны,

поэтому объем экспериментальных данных на ранних этапах проектирования ГТД не может быть произвольно увеличен. Расширение обучающей выборки для ИНС возможно путем применения интерполяции поверхности, построенной на основе экспериментальных данных, кубическими сплайнами и полиномами различного порядка для получения приближенных промежуточных значений параметров работы компрессора.

Рассмотрим аппроксимацию характеристики компрессора низкого давления, которая является функцией двух переменных:

$$G_{в пр кнд} = \hat{f}(\pi_{кнд}^*; n_{пр кнд}), \quad (1)$$

где $G_{в пр кнд}$ - приведенный расход воздуха через КНД, $n_{пр кнд}$ - приведенная частота вращения КНД, $\pi_{кнд}^*$ - степень повышения давления воздуха в каскаде низкого давления (КНД), и задана набором экспериментально полученных значений в приведенных координатах. Данная характеристика используется в математической модели двухвального турбореактивного газотурбинного авиационного двигателя на режимах от минимальной до максимальной тяги [10].

На рис. 2 представлены напорные ветви характеристики компрессора низкого давления (КНД).

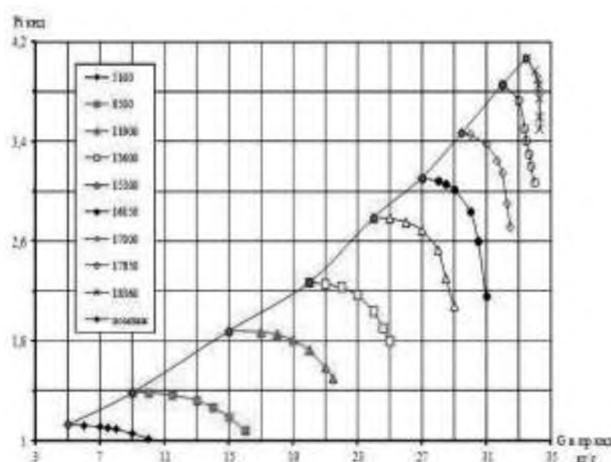


Рис. 2. Напорные ветви характеристики КНД

Двухслойный персептрон с 9 нейронами в скрытом слое был обучен на наборе из 63 точек экспериментальных данных с использованием алгоритма обучения Левенберга-Марквардта. В результате обучения среднее отклонение от целевых значений в точках обучающей выборки составило 1,6% от среднего значения выходной переменной. Однако в промежуточных между заданными напорными ветками областях качество аппроксимации низкое, среднее отклонение в процентах составило почти 14%, а максимальное – 72%. На рис. 3 представлена поверхность,

построенная по экспериментальным точкам характеристики КНД, на рис.4 – поверхность, построенная по результатам работы обученной на экспериментальных данных нейронной сети с шагом, равным 100 по переменной n_{pr_knd} .

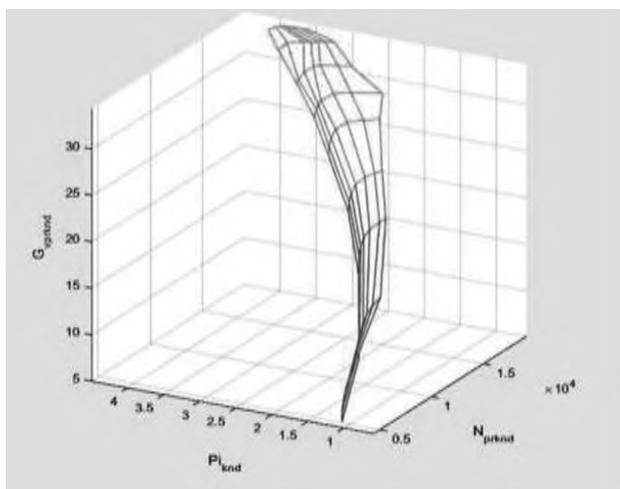


Рис. 3. Поверхность характеристики КНД по экспериментальным данным

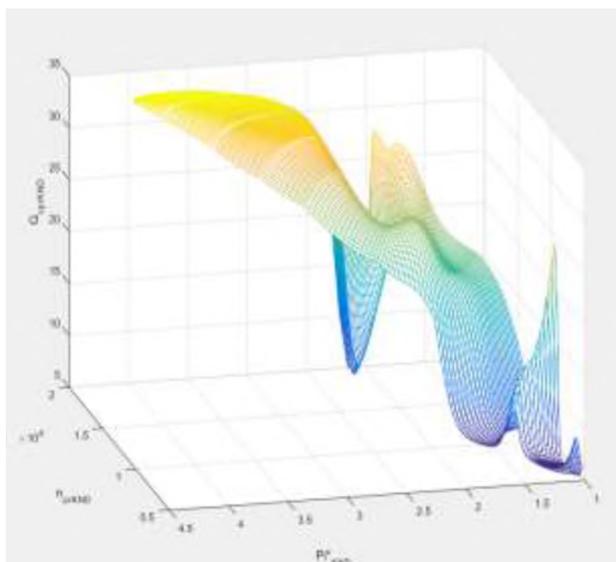


Рис. 4. Поверхность характеристики КНД по результатам работы обученной ИНС

Была разработана методика расширения обучающей выборки для ИНС. На первом этапе с помощью линейной интерполяции по переменным и были построены промежуточные напорные ветки с шагом, равным 100 по переменной n_{pr_knd} между каждыми двумя соседними экспериментально заданными напорными ветками характеристики КНД. Таким образом, поверхность была разбита на 8 участков, ограниченных заданными напорными ветками. На втором этапе расширения обучающей выборки на каждом из участков была применена полиномиальная аппроксимация с использованием функций `polyfit` и `polyval` пакета математического моделирования Matlab. Порядок полинома в промежутке от 1 до 6

для каждого участка поверхности был подобран таким образом, чтобы максимизировать точность аппроксимации. Точность измерялась как средний процент отклонения результатов полиномиальной аппроксимации от результатов кусочно-линейной интерполяции (итога выполнения этапа 1).

Оптимальные порядки полиномов и показатели точности аппроксимации приведены в табл. 1.

Таблица 1. Результаты полиномиальной аппроксимации характеристики КНД

№ участка	1	2	3	4	5	6	7	8
Порядок аппроксимирующего полинома	3	3	4	4	3	3	4	3
Средний процент отклонения от результатов кусочно-линейной интерполяции	5.6	5.4	3.6	1.8	2.2	1.2	0.4	0.3

На рис. 5 приведена поверхность характеристики КНД, полученная в результате полиномиальной интерполяции. На рис. 6 приведена поверхность характеристики КНД, полученная в результате интерполяции кубическими сплайнами.

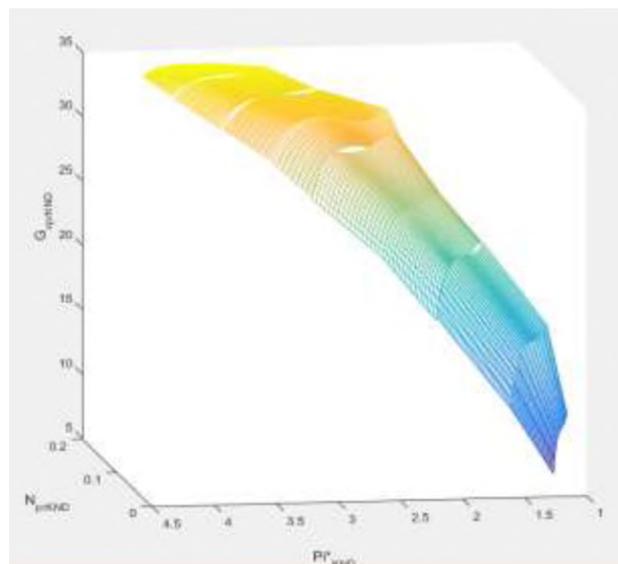


Рис. 5. Результат полиномиальной интерполяции экспериментальной характеристики КНД

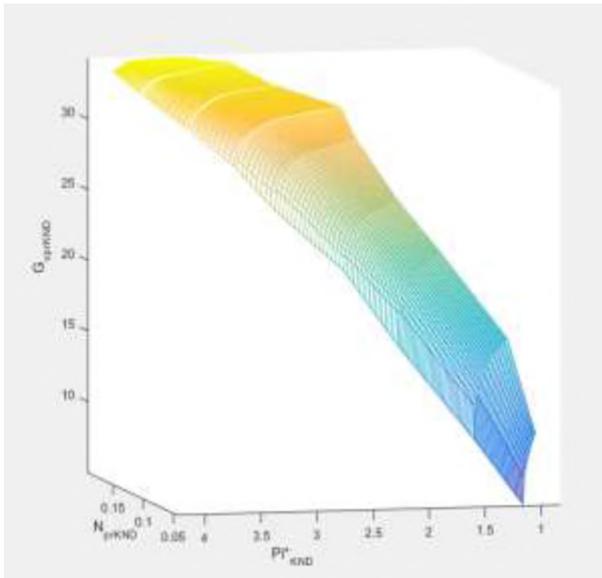


Рис. 6. Результат интерполяции экспериментальной характеристики КНД кубическими сплайнами

Каждый из рассмотренных методов имеет свои преимущества и недостатки. Интерполяция кубическими сплайнами обеспечивает большую точность по сравнению с полиномиальной интерполяцией, однако требует хранения всех координат точек, полученных в результате интерполяции. Для восстановления результатов полиномиальной интерполяции рассмотренной характеристики КНД с любым шагом по переменным N и P^* , требуется хранение в памяти вычислителя только массива коэффициентов интерполирующих полиномов.

Были получены 2 расширенные обучающие выборки - с помощью интерполяции кубическими сплайнами и интерполяции полиномами, состоящие каждая из 5653 точек.

Была подобрана оптимальная по точности аппроксимации за приемлемое время обучения структура нейронной сети представляющая собой двухслойный перцептрон, с 9 нейронами в скрытом слое, реализующая алгоритм прямого распространения сигнала и обратного распространения ошибки (feed-forward backprop). В качестве алгоритма обучения был выбран алгоритм Левенберга-Марквардта.

Нейронная сеть была обучена последовательно на каждом из 8 участков поверхности характеристики КНД. В результате обучения была достигнута точность аппроксимации, составляющая в среднем 0,025 % от средней величины выходной переменной G_{vprknd} для интерполяции сплайнами и 0,0353% для полиномиальной.

В качестве аппаратной базы для быстрых нейросетевых вычислений могут быть использованы как специализированные нейрочипы (например,

NeuroMatrix), так и графические ускорители NVIDIA, поддерживающие архитектуру параллельных вычислений CUDA.

NeuroMatrix — микропроцессорная архитектура, разработанная в компании НТЦ «Модуль». Устройства на базе NeuroMatrix предназначены для цифровой обработки сигналов. Благодаря ряду аппаратных особенностей микропроцессоры этой серии могут быть использованы для создания нейронных сетей. Для NeuroMatrix существует набор средств разработки программ (SDK), включающий компилятор C/C++, драйвера, а также прикладные библиотеки.

Более доступным вариантом является использование технологии CUDA для ускорения вычислений нейронных сетей. Библиотеки языка Python – Theano и TensorFlow, используют эффективные реализации операций над матрицами и компилируют код для эффективных параллельных вычислений как на обычных CPU, так и на графических процессорах.

4. Многоагентная адаптивная система поддержки ЖЦ ГТД

Предложенный выше метод использования нейросетевой аппроксимации характеристики компрессора ГТД может быть автоматизирован с применением многоагентной системы на основе платформы агентного моделирования JADE в рамках предлагаемого подхода [11, 12].

При проведении новых испытаний агрегата, корректирующих ранее полученные данные, необходимо вручную обновлять обучающую выборку для ИНС, переобучать ИНС, и возможно, корректировать ее структуру. Автоматизация этого процесса с помощью агентной системы предполагает передачу выполнения всех необходимых операций агентам JADE.

Для автоматизации ЖЦ ГТД с помощью агентных технологий необходимо обеспечить объединение всех вычислительных устройств и хранилищ информации, задействованных в автоматизируемом участке ЖЦ ГТД, в распределенную вычислительную сеть и развертывание на этой сети платформы многоагентного моделирования JADE. Аппаратное и программное обеспечение каждого из вычислительных узлов сети накладывает свои ограничения на скорость выполнения и вычислительную точность выполняемых на них имитационных моделей ГТД, его агрегатов и систем автоматического управления. Чтобы обеспечить оптимальное по скорости и точности вычислений моделирование в рамках жизненного цикла ГТД, необходимо учитывать эти ограничения.

Предлагаемая адаптивная многоагентная система реализует автоматический выбор метода расширения обучающей выборки для нейросетевого моделирования характеристики компрессора в зависимости от доступных аппаратных ресурсов

вычислительных устройств, на которых выполняется моделирование.

В случае, если доступная оперативная память устройства позволяет хранить большой объем данных, используется метод интерполяции кубическими сплайнами для расширения обучающей выборки для аппроксимирующей ИНС, что дает более высокую точность моделирования характеристики КНД. Если доступный объем памяти не позволяет хранить требуемый объем данных, агент выбирает полиномиальную интерполяцию для

расширения обучающей выборки, поскольку в этом случае требуется хранение только коэффициентов интерполирующих полиномов.

Архитектура предложенной многоагентной системы представлена на рис. 7.

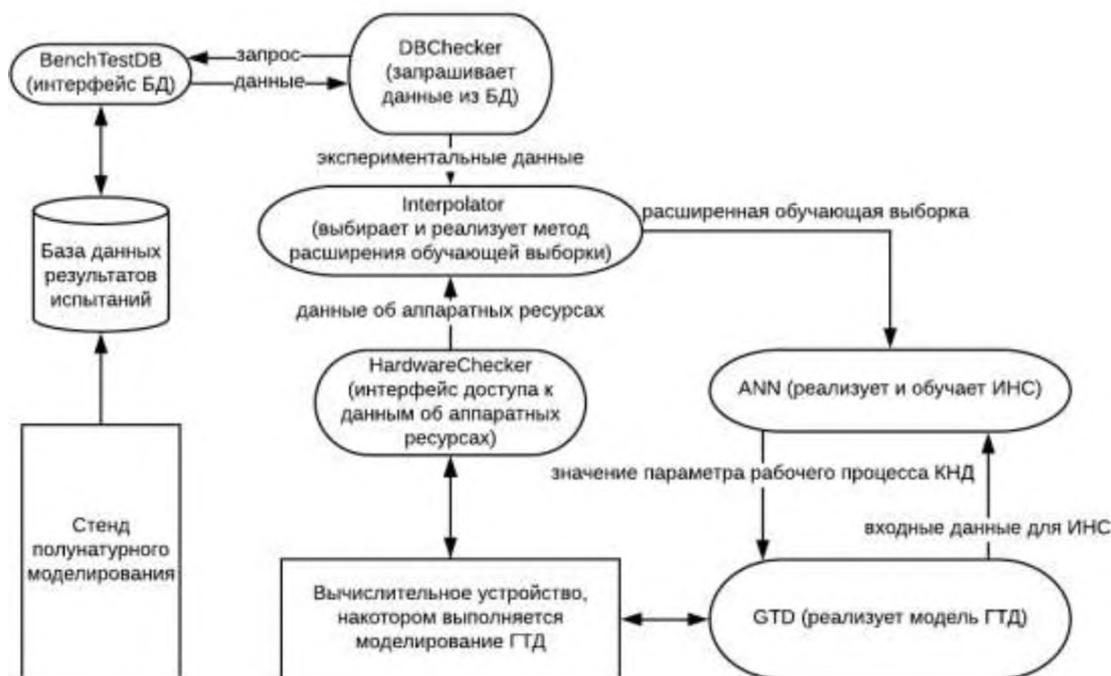


Рис. 7. Архитектура многоагентной адаптивной системы

После проведения испытаний агрегатов на стенде полунатурного моделирования, полученные данные сохраняются в базе данных BenchTestDB. Одноименный агент реализует интерфейс доступа агентов JADE к базе данных. Агент DBChecker с заданной периодичностью обращается к базе данных, проверяя, обновлены ли результаты испытаний некоторого агрегата (в данном случае компрессора). При получении новых данных, агент DBChecker отправляет их агенту Interpolator, который выбирает и реализует метод расширения обучающей выборки на основе данных об аппаратных ресурсах вычислительного устройства, получаемых от агента HardwareChecker. Расширенная обучающая выборка отправляется агенту ANN, который реализует структуру ИНС и переобучает ее. Агент GTD реализует полноразмерную модель ГТД. Он передает агенту ANN входные данные – значения переменных

$n_{пр\ кнд}$ и $\pi_{кнд}^*$, и получает результат нейросетевых вычислений – переменную $G_{в\ пр\ кнд}$.

На рис. 8 представлен фрагмент диаграммы обмена сообщениями между агентами системы,

визуализированная с помощью SnifferTool, специального средства JADE.

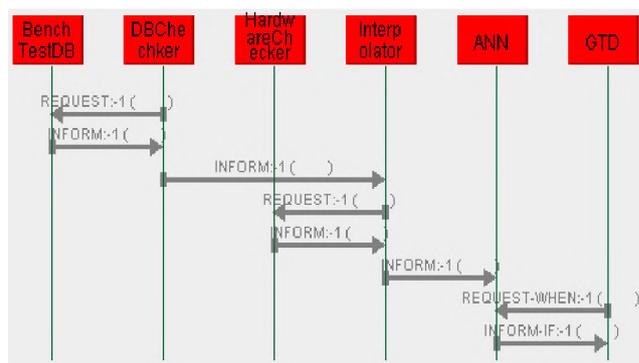


Рис. 8. Диаграмма обмена сообщениями между агентами

Платформа JADE позволяет реализовать распределенное взаимодействие агентов путем создания контейнеров на различных компьютерах, задействованных в процессе реализации жизненного цикла ГТД. Подобная система может быть реализована для различных агрегатов ГТД.

4. Заключение

Таким образом, предлагаемая архитектура многоагентной адаптивной системы поддержки жизненного цикла ГТД, позволяет решить следующие задачи:

- повышение эффективности и прозрачности обмена информацией в ходе реализации процесса ЖЦ ГТД;
- адаптация нейросетевых моделей агрегатов ГТД к доступным аппаратным ресурсам.

Список используемых источников

1. Богуслав А.В., Дубровин В.И., Набока И.А. Информационные технологии поддержки жизненного цикла изделий в авиадвигателестроении // Радиоэлектроника, информатика, управление, 2004. - №1 (11). - С.136-145.
2. Куликов Г. Г., Ризванов К. А., Денисова С. С. Архитектура интегрированной информационной модели для разработки, производства и эксплуатации ГТД совместно с его системой автоматического управления, контроля и диагностики // Вестник Самарского государственного аэрокосмического университета им. академика С.П. Королёва. – Самара, СГАУ, 2009. - №3-1. - с. 244-252.
3. Кривошеев И.А. Опыт разработки и внедрения компонентов информационной поддержки проектирования, доводки и эксплуатации ГТД и ГТУ // Известия Самарского научного центра РАН, 2012. – №4-2. - с.428-436.
4. Кривошеев И. А., Иванова О. Н., Горюнов И. М.. Методы получения и использования характеристик узлов ГТД при имитационном моделировании // Вестник Уфимского государственного авиационного технического университета, Уфа, УГАТУ, 2006. - №3. - с.127-135.
5. Валеев С.С., Васильев В.И., Ильясов Б.Г. Отказоустойчивые системы управления сложными динамическими объектами с использованием искусственных нейронных сетей // Нейрокомпьютеры: разработка, применение. – М.: Радиотехника, 2000 - № 1. - С. 32.
6. Васильев В.И., Валеев С.С., Шилоносов А.А. К выбору структуры нейрорегулятора в системе управления динамическим объектом // Нейрокомпьютеры: разработка, применение. – М.: Радиотехника, 2001. - № 4-5. - С. 52.
7. Кондратьева Н.В., Валеев С.С. Моделирование жизненного цикла сложного технического объекта на основе концепции больших данных // In: G.A. Timofeeva, A.V. Martynenko (eds.): Proceedings of 3rd Russian Conference "Mathematical Modeling and Information Technologies" (MMIT 2016). Yekaterinburg, Russia: 2016. - с.216-223.
8. Загитова А.И., Валеев С.С. Архитектура гетерогенной вычислительной системы для моделирования состояния сложного динамического объекта // Сборник трудов Пятой международной конференции «Информационные технологии интеллектуальной поддержки принятия решений» (ITIDS'2017), Уфа, 2017. – С.52-56.
9. Валеев С.С., Загитова А.И. Построение имитационной модели сложного технического объекта с применением нейросетевых технологий // Естественные и технические науки № 5 (107) 2017. – М.: Спутник+. - с.172-174.
10. Горюнов И. М. Метод представления характеристик компрессоров в математических моделях газотурбинных двигателей // Вестник Самарского государственного аэрокосмического университета им. академика С.П. Королёва, Самара, СГАУ, 2006. - №3 - с.7-12.
11. Ковтуненко А.С., Валеев С.С., Масленников В.А. Многоагентная платформа распределенной обработки данных реального времени // Естественные и технические науки. № 2 (64), 2013.. – М.: Спутник+. - с.311-313.
12. Блинов В.Н., Валеев С.С., Исламгулов Т.В., Каримов Р.Р., Косицын В.В., Рубан В.Н. Информационная поддержка жизненного цикла микроспутника на основе сквозных интеллектуальных моделей // Вестник Уфимского государственного авиационного технического университета, Уфа, УГАТУ, 2010. - Т. 14. № 4 (39). - С. 97-103.