

ДИНАМИЧЕСКАЯ МОДЕЛЬ ГАЗОТУРБИННОГО ДВИГАТЕЛЯ НА ОСНОВЕ СТРУКТУРЫ LSTM С ИЗМЕНЯЕМОЙ ПАМЯТЬЮ

© 2020

А. В. Кузнецов аспирант кафедры автоматических систем энергетических установок; Самарский национальный исследовательский университет имени академика С.П. Королёва; a.v.kuznetsov91@mail.ru

Г. М. Макарьянц доктор технических наук, доцент, профессор кафедры автоматических систем энергетических установок; Самарский национальный исследовательский университет имени академика С.П. Королёва; georgy.makaryants@gmail.com

Основным способом повышения эффективности газотурбинных двигателей является увеличение параметров цикла. Однако рост степени повышения температуры и давления по тракту двигателя приводит к усилению тепловой нагрузки на лопатки соплового аппарата турбины, что значительно снижает ресурс. Задача сохранения ресурса особенно важна для малоразмерных газотурбинных двигателей, поскольку их ограниченные габариты не позволяют реализовать многие мероприятия по охлаждению лопаток соплового аппарата. В сложившихся условиях возрастает роль контроля тепловой нагруженности элементов таких двигателей, что ужесточает требования к точности управления по основным регулируемым параметрам (оборотам ротора двигателя и температуре газа за турбиной). Повышение качества управления в современных газотурбинных двигателях решается за счёт использования бортовых математических моделей двигателя. Рабочие процессы, описываемые такими моделями, характеризуются быстротечностью и значительным перерегулированием, что предъявляет высокие требования к точности моделирования. Однако вопросы точного и в то же время ресурсосберегающего расчёта быстропеременных процессов изменения оборотов ротора и температуры газа за турбиной остаются малоизученными. В работе использовались нейросетевые методы для моделирования нестационарных режимов малоразмерных газотурбинных двигателей. С использованием данных, полученных в результате огневых испытаний двигателя JetCat P-60, создана его регрессионная нейросетевая модель. Главным вопросом, возникшим при создании модели, было описание динамики быстропеременных процессов с ярко выраженным перерегулированием. Для этого была проведена модификация архитектуры классической LSTM сети, суть которой сводилась к добавлению функциональной зависимости выходного узла от тензора памяти. Это позволило сделать размер памяти независимым от количества выходов модели и тем самым повысило точность моделирования. Разработанной архитектуре было предложено новое название – VMLSTM сеть. В результате сравнения с традиционной сетью Элмана и классической LSTM сетью разработанная VMLSTM сеть показала наименьшее значение средней ошибки при сопоставимом количестве изменяемых параметров модели. Кроме этого, в отличие от существующих нейросетей, разработанная сеть продемонстрировала возможность моделирования забросов температуры газа за турбиной в моменты изменения режима работы двигателя. Разработанная архитектура нейросети повысила достоверность моделирования динамики малоразмерного газотурбинного двигателя как объекта управления, что в условиях экономного использования вычислительных ресурсов открыло возможности её применения в бортовых электронно-вычислительных машинах.

Малоразмерный газотурбинный двигатель; моделирование переходных процессов; рекуррентные нейронные сети; LSTM с вариативной памятью.

Цитирование: Кузнецов А.В., Макарьянц Г.М. Динамическая модель газотурбинного двигателя на основе структуры LSTM с изменяемой памятью // Вестник Самарского университета. Аэрокосмическая техника, технологии и машиностроение. 2020. Т. 19, № 2. С. 38-52. DOI: 10.18287/2541-7533-2020-19-2-38-52

Введение

Согласно исследованиям, проведённым в Центральном институте авиационного моторостроения, математическое моделирование газотурбинных двигателей (ГТД) позволяет уменьшить время на их разработку и создание, а также помогает решить многие проблемы управления, возникающие в процессе эксплуатации [1]. Здесь же приводится ряд требований к математическим моделям ГТД, представляющим двигатель как объект управления. Такие модели должны:

- рассчитывать параметры рабочих процессов в ГТД на установившихся и переходных режимах его работы в широком диапазоне изменений как условий полёта, так и самих режимов работы двигателя;
- обладать точностью, достаточной для решения задач управления;
- обеспечивать приемлемое время расчёта на ЭВМ при использовании моделей высокого уровня;
- предоставлять возможность выполнения расчётов в реальном и ускоренном времени при использовании моделей на полунатурных стендах.

Существующие методики математического моделирования динамики ГТД позволяют осуществлять расчёт практически всех параметров рабочих процессов в двигателе с приемлемой точностью. Однако вопросы сокращения времени расчёта требуют отдельного рассмотрения. В своей монографии Джо и Матингли [2] приводят частотный состав сигналов регулируемых параметров двигателя. Авторами отмечается, что частотность основных процессов управления (топливоподача, положение лопаток направляющего аппарата, раскрытие сопла, перепуск воздуха) лежит в диапазоне от 0,01 до 10 Гц, а частоты процессов управления по ограничению (заброс оборотов, срывные явления в компрессоре, радиальные зазоры) расположены в диапазоне от 10 до 300 Гц. Применяя теорему Котельникова к максимальной частоте динамических процессов в ГТД, можно увидеть, что для их описания при помощи элементов цифровой техники необходимо иметь частоту дискретизации моделируемых сигналов не менее 1 000 Гц. Поэтому величина скорости вычислений должна обеспечивать расчёт рабочих параметров двигателя за время, меньшее, чем обратная величина полученной частоты дискретизации. Другими словами, время обновления рассчитываемых параметров не должно превышать 1 мс. В свою очередь возможности современных бортовых ЭВМ весьма скромны. Согласно данным, приведённым в [1], оперативная память бортовых ЭВМ составляет 24...32 кБ, постоянная память – 64...128 кБ, разрядность в большинстве случаев – 16 бит, иногда применяются 32-битные системы. Таким образом, для удовлетворения требований по частоте дискретизации моделируемых сигналов с помощью бортовых ЭВМ необходимо использовать методы математического моделирования, обладающие низкими требованиями к вычислительным мощностям.

Гольберг Ф.Д. и Баженов А.В. [3] приводят следующую классификацию методов математического моделирования процессов в ГТД:

- термодинамические модели, представленные в виде алгебраических и нелинейных дифференциальных уравнений, описывающих физические процессы, протекающие в узлах двигателя [4- 9];
- эмпирические модели, представляющие собой комплекс линейных дифференциальных и алгебраических уравнений с кусочно-линейными коэффициентами [10-12];
- регрессионные модели, получаемые методами многофакторного планирования эксперимента и регрессионного анализа [13-15].

Рассмотрев представленные классы моделей в контексте требований к ним, а также ограничений вычислительной мощности бортовых ЭВМ, можно сделать вывод о целесообразности применения регрессионных методов для моделирования динамики

ГТД. При этом для обеспечения автоматизации составления таких моделей и упрощения их практического использования перспективным видится нейросетевое моделирование.

Для описания динамических процессов составляются так называемые рекуррентные нейронные сети. Впервые структуру рекуррентных сетей предложили Элман [16] и Джордан [17]. Традиционная нейронная сеть ими была дополнена обратными связями, передающими информацию в направлении из скрытого и выходного слоёв во входной. Такая новая структура выполняла обработку уже не только текущих данных, но и значений обрабатываемого параметра на предыдущем временном шаге, что позволило моделировать изменяющиеся во времени процессы. Дальнейшим развитием сетей Элмана и Джордана стали NARX сети [18]. В них были введены обратные связи с задержками по времени. С увеличением количества таких связей увеличивалось и количество предыдущих временных шагов, информация с которых использовалась для моделирования текущего шага. Другими словами, NARX сети в сравнении с сетями Элмана и Джордана обладали большей исторической памятью, дающей возможность моделировать более сложные динамические процессы, например, с некоторыми колебаниями временных сигналов. Тем не менее, NARX сети имели существенный недостаток. Для увеличения объёма информации о предыстории изменения сигнала подразумевалось одновременное обращение к большому количеству ретроспективных временных шагов. Поэтому повышение точности NARX сетей обеспечивалось исключительно ростом их размера, что неминуемо приводило к замедлению работы всей сети. В 1995 г. Хохрайтер и Шмидхубер [19] предложили структуру рекуррентной сети, способной к обучению на базе долговременных процессов без какого-либо увеличения её размеров. Вместо введения дополнительных временных задержек и увеличения количества обратных связей были разработаны алгоритмы по использованию долгосрочной и краткосрочной памяти (Long Short Term Memory – LSTM сети). В 1997 г. эти же исследователи [20] усовершенствовали LSTM структуру, а в конце 1990-х к таким сетям были добавлены забывающие узлы [21]. Окончательно архитектура LSTM сетей была сформирована в 2000 г. [22]. Наиболее полный обзор существующих на данный момент LSTM сетей представлен в [23]. В настоящее время LSTM сети представляют собой наиболее удачный инструмент моделирования динамических процессов.

Однако классические LSTM сети, несмотря на возможность работы с долговременными зависимостями, всё же не позволяют достоверно описывать динамику быстропеременных процессов с ярко выраженным перерегулированием. Это ставит под сомнение их способность моделировать динамику рабочих параметров ГТД, например, изменение температуры газа за турбиной T_T^* или в камере сгорания T_G^* . Причина такого недостатка связана с ограниченными возможностями в использовании ячеек памяти. Их количество непосредственно влияет на точность моделирования, но оно строго лимитировано равенством числу выходных параметров сети. Если нужно выполнить моделирование только двух параметров ГТД, например, частоты вращения ротора и температуры T_G^* , то количество ячеек памяти тоже будет равно двум, что явно недостаточно для идентификации заброса температуры. Для увеличения предсказательной способности модели можно добавить большее количество ячеек памяти. Это вызовет увеличение количества выходных сигналов модели, которые можно сократить, добавив ещё один слой нейросети. Однако это приведёт к увеличению количества операций матричного умножения и повысит сложность самой модели, а также времени вычисления.

Целью статьи является повышение точности модели ГТД как объекта управления за счёт модификации архитектуры LSTM сети, которая может быть использована в качестве бортовой модели двигателя или энергетической установки.

Принцип работы LSTM сетей

LSTM ячейка представляет собой набор небольших полносвязных нейронных сетей (гейтов или узлов). Каждая ячейка имеет один выходной нейрон для предсказания какого-либо параметра (например, частоты вращения ротора двигателя). Совокупность ячеек представляет собой сеть для предсказания нескольких параметров. Основным отличием LSTM сетей от других рекуррентных сетей является наличие тензора памяти. Тензор памяти – переменная, информация в которую может записываться или стираться в процессе работы сети.

Работа LSTM сети (рис. 1) основана на принципе управления тензором памяти при помощи узлов запоминания и забывания:

$$c_t = f_t \circ c_{t-1} + i_t \circ cc_t.$$

Здесь c_t – тензор памяти, представляющий вектор взвешенных входов на шаге t ; f_t – тензор на выходе из забывающего узла на шаге t , представляющий собой сумму взвешенных входов и выходов на предыдущем шаге $t-1$; c_{t-1} – тензор памяти на шаге $t-1$; i_t – тензор на выходе из входного узла на шаге t , представляющий собой сумму взвешенных входов на текущем шаге и выходов на предыдущем шаге; cc_t – тензор-кандидат для записи в тензор памяти.

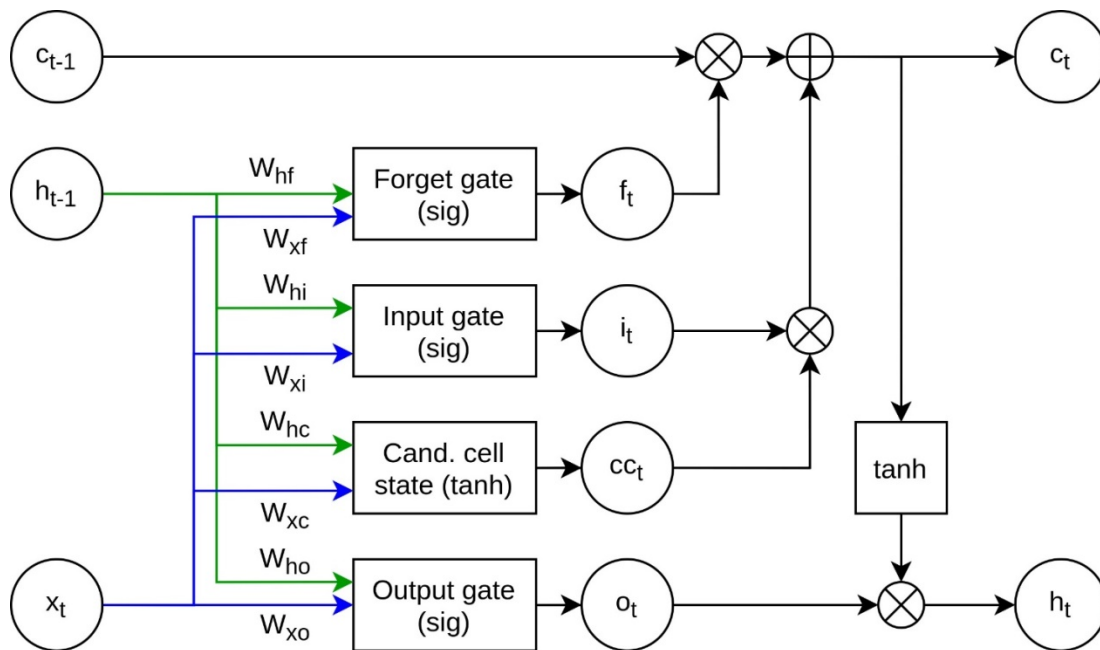


Рис. 1. Схема LSTM сети:

Forget gate (sig) – забывающий узел с сигмоидальной функцией активации; *Input gate (sig)* – входной узел с сигмоидальной функцией активации; *Cand. cell state (tanh)* – узел для вычисления тензора-кандидата на запись в память с тангенциальной функцией активации; *Output gate (sig)* – выходной узел с сигмоидальной функцией активации; c_{t-1} – тензор памяти на предыдущем шаге; c_t – тензор памяти на текущем шаге; h_{t-1} – тензор выхода сети на предыдущем шаге; h_t – тензор выхода сети на текущем шаге; x_t – тензор входа на текущем шаге; f_t – тензор на выходе из забывающего узла; i_t – тензор на выходе из входного узла; cc_t – тензор на выходе из узла кандидата на запись в память; o_t – тензор на выходе из выходного узла; $W_{hf}, W_{xf}, W_{hi}, W_{xi}, W_{hc}, W_{xc}, W_{ho}, W_{xo}$ – весовые коэффициенты, связывающие входы с узлами

Тензор на выходе из забывающего узла представляет собой взвешенный вектор входных данных, конкатенированный с вектором выходных данных, сохранённых с предыдущего временного шага:

$$f_t = \sigma(W_{hf}h_{t-1} + W_{xf}x_t + b_f).$$

Здесь σ – сигмоидальная функция активации; W_{hf} , W_{xf} – матрицы весов узла забывания, которые настраиваются в процессе обучения сети; h_{t-1} – вектор выходных значений нейронной сети на предыдущем шаге по времени; x_t – вектор входных значений на текущем шаге; b_f – вектор смещений узла забывания, который настраивается в процессе обучения сети. Сигмоидальная функция изменяется в диапазоне от 0 до 1. Таким образом, если тензор на выходе из забывающего узла принимает значение 0, то из соответствующего элемента тензора памяти полностью стирается записанная в него информация, если принимает значение 1, то соответствующее значение остаётся неизменным. При промежуточном результате функции активации значения в тензоре памяти будут уменьшены пропорционально.

Запись значений в тензор памяти происходит в два этапа. Во время первого этапа узел запоминания определяет, какие значения в тензоре памяти должны быть перезаписаны; во время второго этапа вычисляются значения, которые будут записываться:

$$i_t = \sigma(W_{hi}h_{t-1} + W_{xi}x_t + b_i),$$

$$cc_t = \tanh(W_{hc}h_{t-1} + W_{xc}x_t + b_c).$$

Здесь W_{hi} , W_{xi} – матрицы весов узла запоминания, которые настраиваются в процессе обучения сети; b_i – вектор смещений узла запоминания; W_{hc} , W_{xc} – матрицы весов узла кандидата на запись в тензор памяти; b_c – вектор смещений узла кандидата на запись; \tanh – функция гиперболического тангенса.

Результатом работы сети является тензор h_t :

$$h_t = \tanh(c_t) \circ \sigma(W_{ho}h_{t-1} + W_{xo}x_t + b_o),$$

где W_{ho} , W_{xo} – матрицы весов выходного узла; b_o – вектор смещений выходного узла.

Модификация LSTM сети

Размер памяти в классической LSTM сети зависит от размера вектора выхода модели (количество предсказываемых параметров), что ограничивает сложность моделируемых процессов. Для моделирования сложных динамических процессов (быстродействующих, с ярко выраженным перерегулированием и т.д.) было принято решение модифицировать архитектуру LSTM сети. На основе результатов современных исследований [23] были объединены узлы Forget gate и Input gate в узел Control gate, что позволило уменьшить количество весовых коэффициентов и матричных операций. Для удобства понимания новой структуры нейронной сети и работы с ней узел Cand. cell state переименован в Recording gate с сохранением прежней функциональности. Главным изменением в архитектуре было добавление функциональной зависимости узла Output gate от тензора памяти, что позволило сделать размер памяти не зависимым от количества выходов модели. Предлагаемая схема LSTM сети с варьируемой памятью приведена на рис. 2.

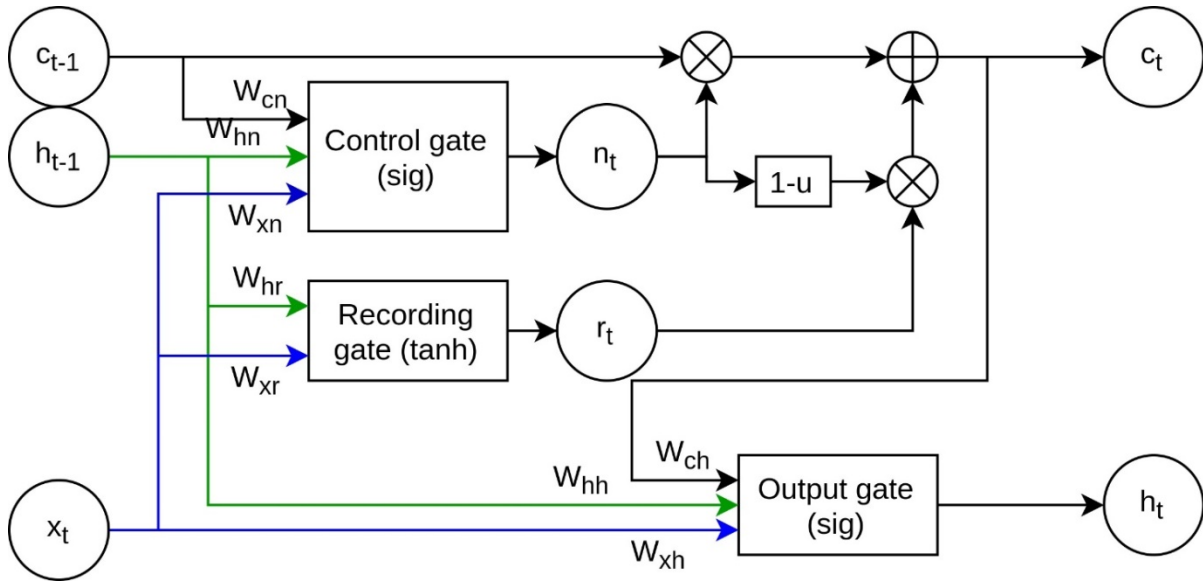


Рис. 2. Схема LSTM сети с варьируемой памятью:

Control gate (sig) – управляющий узел с сигмоидальной функцией активации; *Recording gate (tanh)* – записывающий узел с тангенциальной функцией активации; *Output gate (sig)* – выходной узел с сигмоидальной функцией активации; c_{t-1} – тензор памяти на предыдущем шаге; c_t – тензор памяти на текущем шаге; h_{t-1} – тензор выхода сети на предыдущем шаге; h_t – тензор выхода сети на текущем шаге; x_t – тензор входа на текущем шаге; n_t – тензор на выходе из управляющего узла; r_t – тензор на выходе из записывающего узла; $W_{cn}, W_{hn}, W_{xn}, W_{hr}, W_{xr}, W_{ch}, W_{hh}, W_{xh}$ – весовые коэффициенты, связывающие входы с узлами

Модифицированная LSTM сеть содержит три узла – управляющий узел (*Control gate*), записывающий узел (*Recording gate*) и выходной узел (*Output gate*). Для вычисления тензора памяти используются два из них – управляющий и записывающий узлы:

$$c_t = n_t \circ c_{t-1} + (1 - n_t) \circ r_t,$$

где n_t – тензор на выходе из управляющего узла на шаге t ; r_t – тензор на выходе из записывающего узла на шаге t .

Управляющий узел определяет, какое количество информации будет забыто или насколько важна новая информация для записи её в память на основе входных значений, выходных значений на предыдущем шаге и значений, хранящихся в памяти сети:

$$n_t = \sigma(W_{cn}c_{t-1} + W_{hn}h_{t-1} + W_{xn}x_t + b_n),$$

где W_{cn}, W_{hn}, W_{xn} – матрицы весов управляющего узла; b_n – вектор смещений управляющего узла. Функцией активации является сигмоида с диапазоном выходных значений 0..1.

Записывающий узел определяет новую информацию, которая потенциально может быть сохранена во внутреннюю память сети:

$$r_t = \tanh(W_{hr}h_{t-1} + W_{xr}x_t + b_r),$$

где W_{hr}, W_{xr} – матрицы весов записывающего узла; b_r – вектор смещений записывающего узла.

Функцией активации является гиперболический тангенс с диапазоном выходных значений $-1..1$. Таким образом, значение в памяти может как увеличиваться, так и уменьшаться на основе текущих входных значений и выходных значений на предыдущем шаге. Если результат вычислений управляющего узла равен 0, то соответствующее значение тензора памяти будет обнулено. Если результат равен 1, то значение в памяти останется без изменений. При промежуточных значениях будет записана взвешенная сумма Recognition gate и тензора памяти. Основное отличие предлагаемой архитектуры сети – использование памяти сети в выходном узле:

$$h_t = \sigma(W_{ch}c_t + W_{hh}h_{t-1} + W_{xh}x_t + b_h),$$

где W_{ch} , W_{hh} , W_{xh} – матрицы весов выходного узла; b_h – вектор смещений выходного узла. Это даёт возможность использовать размерность тензора памяти как новый гиперпараметр сети.

Результаты идентификации ГТД

Для проведения вычислительных экспериментов были взяты результаты огневых испытаний двигателя JetCat P-60. Сами вычисления проводились на языке Python с использованием фреймворка Tensorflow. Огневое испытание представляло собой серию переходов двигателя с одного режима работы на другой при непродолжительном (порядка двух секунд) поддержании постоянным значения оборотов ротора. Экспериментальные исследования проводились при температуре окружающей среды $+15^{\circ}\text{C}$. Установка представляла собой открытый стенд, на котором был закреплён двигатель со всей арматурой. Переходы по режимам выполнялись с помощью изменения положения рычага управления тягой (РУТ) с заданным шагом частотной модуляции: минимальное значение на цифровой шкале РУТ 1000 Гц, максимальное 2200 Гц, шаг 100 Гц. В начале каждого замера режим ступенчато увеличивался до максимального, затем выполнялся ступенчатый сброс оборотов на минимальный режим. В конце замера двигатель переводился с минимальных оборотов на максимальные и обратно без задержки на промежуточных режимах. Такая схема работы двигателя позволила исследовать его динамику в состояниях максимального ускорения и замедления ротора с записью соответствующих значений частоты вращения ротора и температуры за турбиной (рис. 3).

Для идентификации частоты вращения ротора и температуры за турбиной использовались три модели: классическая сеть Элмана, существующая традиционная LSTM сеть и новая разработанная LSTM сеть с вариативной памятью – Variative Memory LSTM (VMLSTM). В сети Элмана использовалось 25 скрытых нейронов, в LSTM сети – 20 ячеек, а в VMLSTM в качестве памяти использовался тензор размерностью 10×10 . Приведённые конфигурации были получены после ряда этапов процесса обучения. При этом на каждом новом этапе количество нейронов увеличивалось до тех пор, пока не перестала повышаться точность моделирования. Результаты моделирования приведены на рис. 4 – 6.

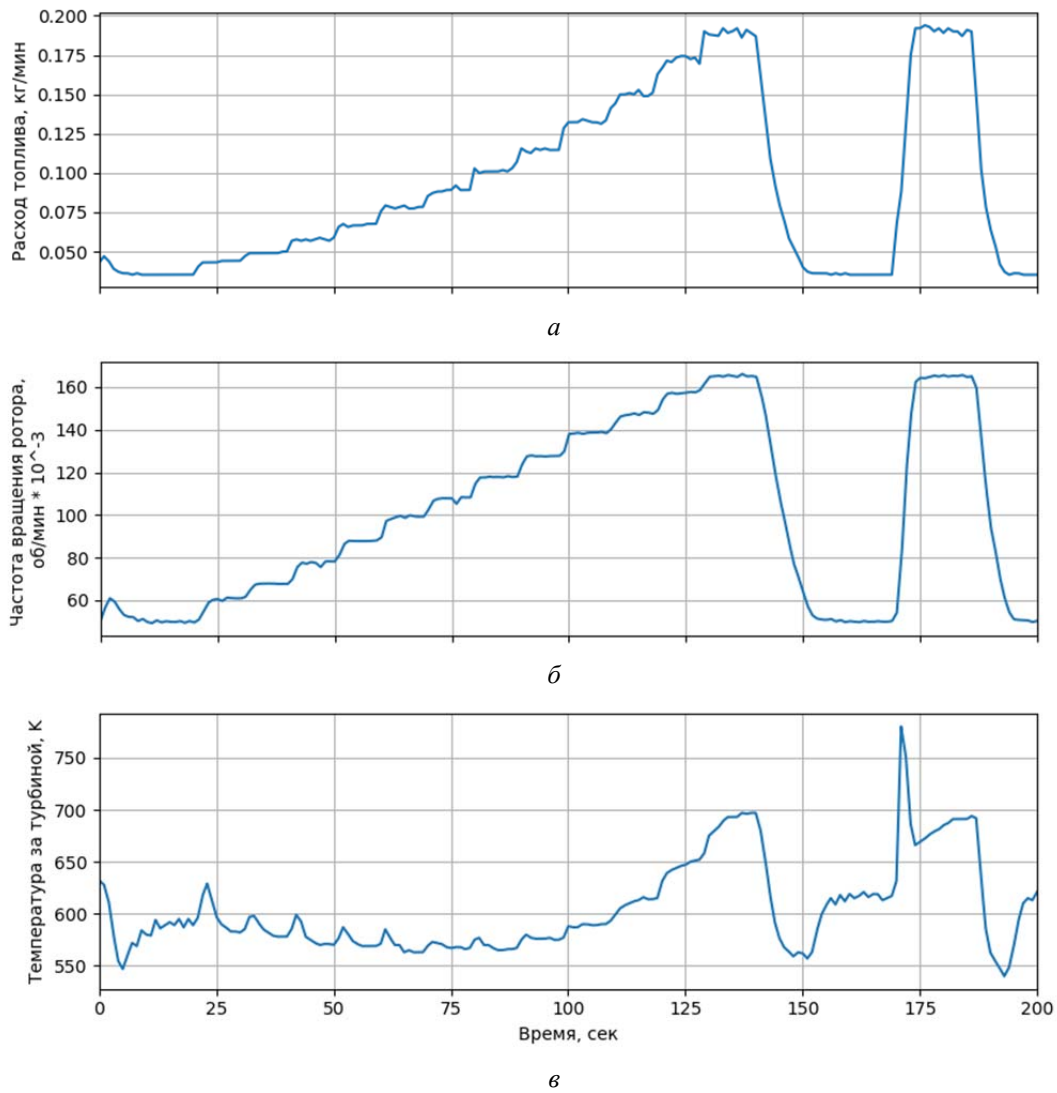


Рис. 3. Результаты огневых испытаний двигателя JetCat P-60:
 а – расход топлива; б – частота вращения ротора; в – температура за турбиной


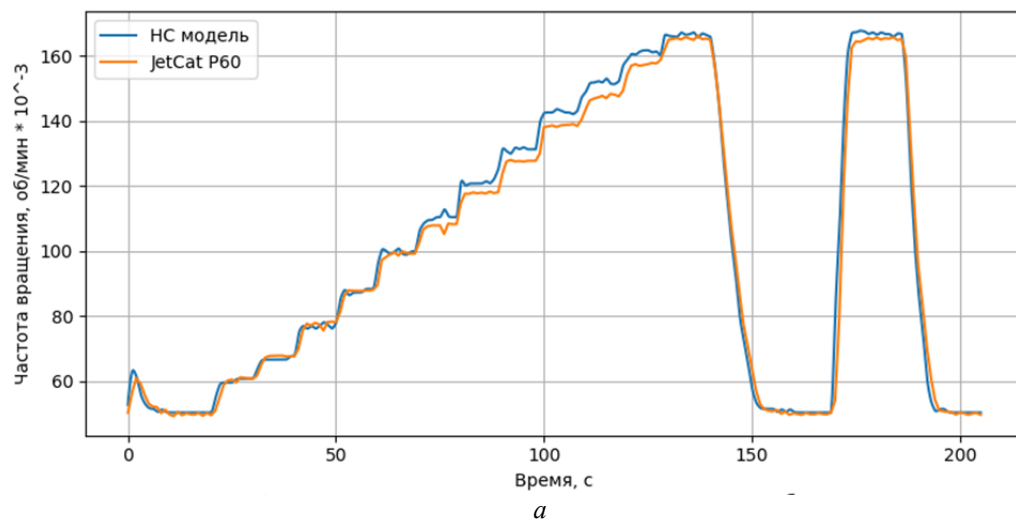


Рис. 4. Результаты моделирования сетью Элмана:
а – частота вращения ротора; б – температура за турбиной

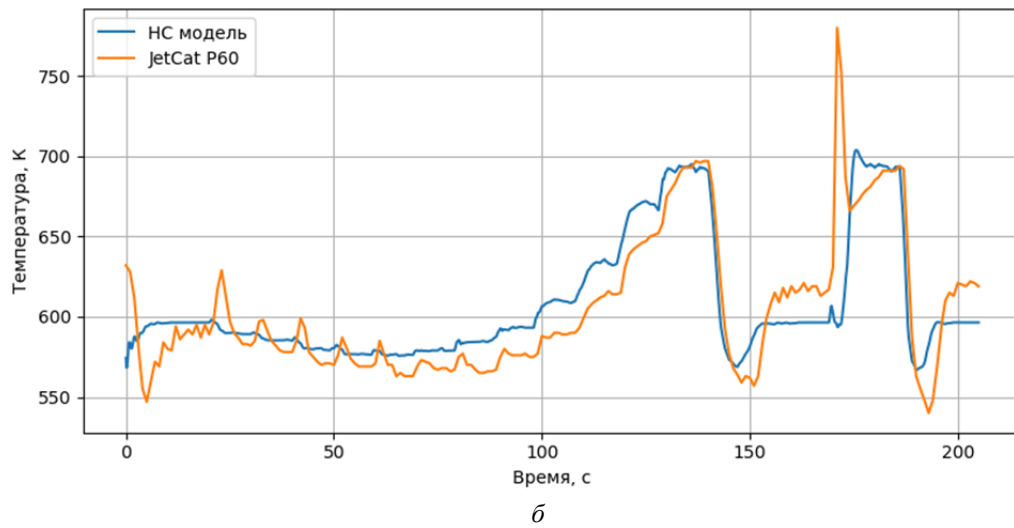



Рис. 5. Результаты моделирования LSTM сетью:
 а – частота вращения ротора; б – температура за турбиной

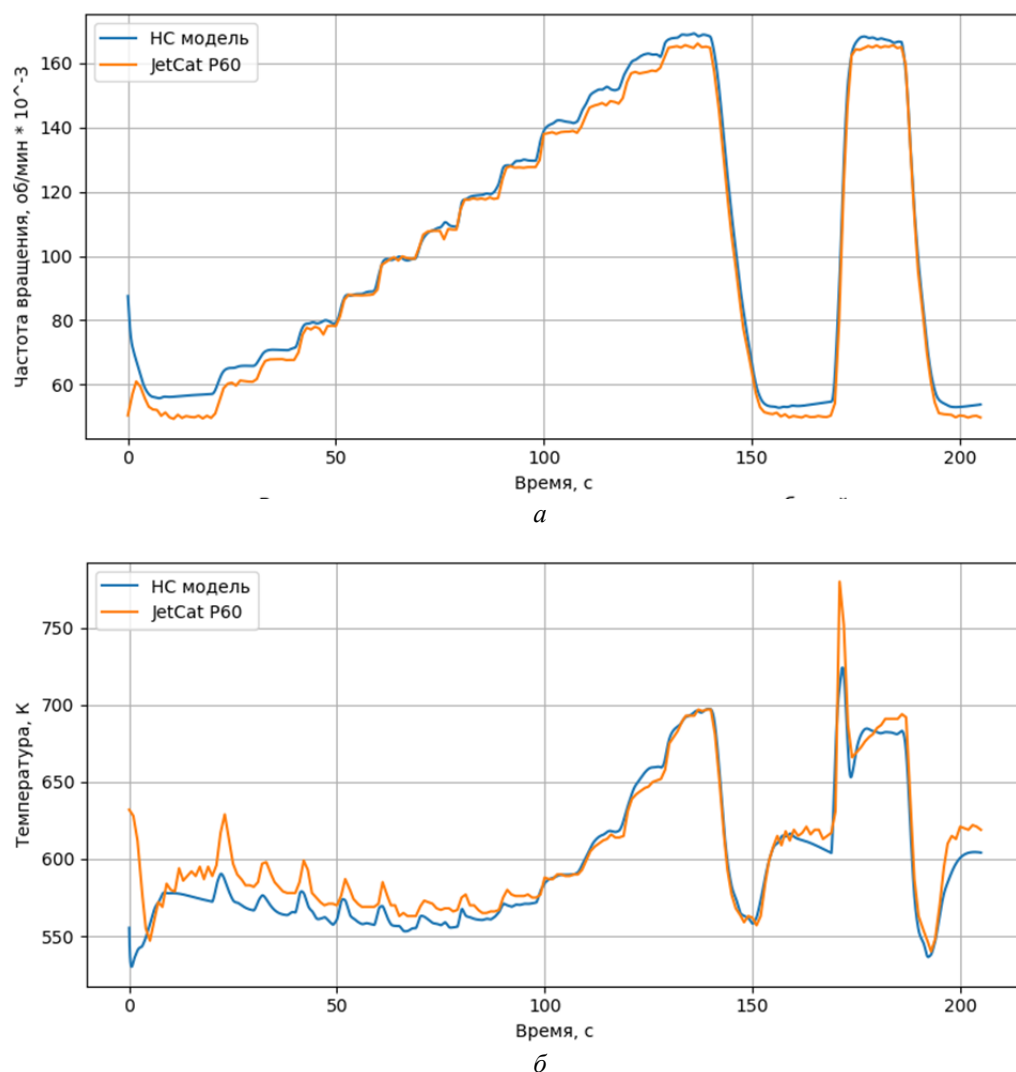


Рис. 6. Результаты моделирования VMLSTM сетью:
 а – частота вращения ротора; б – температура за турбиной

Анализ результатов моделирования показал, что средняя абсолютная ошибка моделей по выходным параметрам составила: для модели Элмана – 3,38%; для LSTM модели – 2,72% и для VMLSTM модели – 2,51%. При этом динамика VMLSTM модели значительно ближе к целевой динамике процесса, чем в LSTM модели. Результаты VMLSTM модели показали значительно лучшее качество моделирования процесса температуры, чем модель Элмана и LSTM, которые не моделировали забросы температуры в моменты перехода с режима на режим.

Заключение

Представлена разработанная модификация LSTM сети с переменной памятью – VMLSTM. Для моделирования динамики малоразмерного газотурбинного двигателя JetCat P-60 использовались три архитектуры нейронной сети: сеть Элмана, LSTM сеть и разработанная сеть VMLSTM. Архитектуры были реализованы на языке Python с использованием фреймворка Tensorflow. В результате сравнения VMLSTM модель показала наименьшее значение средней ошибки по сравнению с классической сетью Элмана и традиционной LSTM сетью. В отличие от сети Элмана и LSTM сети разработанная архитектура показала возможность моделирования динамики быстропеременных про-

цессов с ярко выраженным перерегулированием, что важно при описании переходных процессов рабочих параметров ГТД, например, изменения температуры газа за турбиной T_T^* или в камере сгорания T_G^* .

В результате разработанная модификация структуры LSTM сети повысила точность моделирования динамики ГТД как объекта управления и открыла возможности применения предложенной нейросети в бортовых ЭВМ двигателей и в энергетических установках.

Работа выполнена при финансовой поддержке Министерства науки и высшего образования в рамках проекта FSSS-2020-0015.

Библиографический список

1. Гуревич О.С. Системы автоматического управления авиационными ГТД: энциклопедический справочник. М.: Торус Пресс, 2011. 208 с.
2. Jaw L., Mattingly J. Aircraft engine controls. Reston, Va: American Institute of Aeronautics and Astronautics, Inc., 2009. 364 p.
3. Гольберг Ф.Д., Батенин А.В. Математические модели газотурбинных двигателей как объектов управления. М.: Московский авиационный институт, 1999. 79 с.
4. Интегральные системы автоматического управления силовыми установками самолёта / под ред. А.А. Шевякова. М.: Машиностроение, 1983. 283 с.
5. Шевяков А.А. Системы автоматического управления авиационными воздушно-реактивными силовыми установками. М.: Машиностроение, 1992. 424 с.
6. Теория автоматического управления силовыми установками летательных аппаратов / под ред. А.А. Шевякова. М.: Машиностроение, 1976. 344 с.
7. Badami M., Ferrero M.G., Portoraro A. Dynamic parsimonious model and experimental validation of a gas microturbine at part-load conditions // Applied Thermal Engineering. 2015. V. 75. P. 14-23. DOI: 10.1016/j.applthermaleng.2014.10.047
8. Arsalis A. Thermoeconomic modeling and parametric study of hybrid SOFC–gas turbine-steam turbine power plants ranging from 1.5 to 10MWe // Journal of Power Sources. 2008. V. 181, Iss. 2. P. 313-326. DOI: 10.1016/j.jpowsour.2007.11.104
9. Ахмедзянов Д.А. Неустановившиеся режимы работы авиационных ГТД // Вестник Уфимского государственного авиационно-технического университета. 2006. Т. 7, № 1 (14). С. 36-46.
10. Грасько Т.В., Маяцкий С.А. Методика анализа процессов горения в регулируемой основной камере сгорания перспективного газотурбинного двигателя численными методами // Вестник Уфимского государственного авиационно-технического университета. 2014. Т. 18, № 3 (64). С. 23-29.
11. Максимов А.В., Киселёв Е.А., Кургалин С.Д., Зуев С.А. Математическая модель, описывающая динамику воздушных потоков в турбинном спирометре // Труды Института системного программирования РАН. 2019. Т. 31, № 1. С. 105-114. DOI: 10.15514/ISPRAS-2019-31(1)-7
12. Бирюков Р.В., Киселёв Ю.В. Эмпирическая модель теплового состояния роторных подшипников и масляной системы ГТД // Известия Самарского научного центра РАН. 2016. Т. 18, № 2 (3). С. 848-852.
13. Asgari H., Chen X.Q., Morini M., Pinelli M., Sainudin R., Spina P.R., Venturini M. NARX models for simulation of the start-up operation of a shaft gas turbine // Applied Thermal Engineering. 2016. V. 93. P. 368-376. DOI: 10.1016/j.applthermaleng.2015.09.074

14. Nikpey H., Assadi M., Breuhaus P. Development of an optimized artificial neural network model for combined heat and power micro gas turbines // *Applied Energy*. 2013. V. 108. P. 137-148. DOI: 10.1016/j.apenergy.2013.03.016
15. Ali Lilo M., Latiff L.A., Abu A.B.H., Al Mashhadany Y.I., Ilijan A.K. Gas Turbine bearing and vibration classification of using multi-layer Neural Network // 2015 International Conference on Smart Sensors and Application (ICSSA) (May, 26-28, 2015, Kuala Lumpur, Malaysia). 2015. P. 20-23. DOI: 10.1109/ICSSA.2015.7322503
16. Elman J.L. Finding structure in time // *Cognitive science*. 1990. V. 14, Iss. 2. P. 179-211. DOI: 10.1016/0364-0213(90)90002-E
17. Jordan M.I. Serial order: A parallel distributed processing approach // *Advances in Psychology*. 1997. V. 121. P. 471-495. DOI: 10.1016/s0166-4115(97)80111-2
18. Siegelmann H.T., Horne B.G., Giles C.L. Computational capabilities of recurrent NARX neural networks // *IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)*. 1997. V. 27, Iss 2. P. 208-215. DOI: 10.1109/3477.558801
19. Hochreiter S., Schmidhuber J. Long short-term memory. Tech. Rep. no. FKI-207-95. Fakultat fur Informatik, Technische Universitat Munchen, 1995.
20. Hochreiter S., Schmidhuber J. Long short-term memory // *Neural Computation*. 1997. V. 9, Iss. 8. P. 1735-1780. DOI: 10.1162/neco.1997.9.8.1735
21. Gers F.A., Schmidhuber J., Cummins F. Learning to forget: continual prediction with LSTM // *Neural Computation*. 2000. V. 12, Iss. 10. P. 2451-2471. DOI: 10.1162/089976600300015015
22. Gers F.A., Schmidhuber J. Recurrent nets that time and count // *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium (July, 25-27, 2000, Como, Italy)*. 2000. DOI: 10.1109/ijcnn.2000.861302
23. Greff K., Srivastava R.K., Koutnik J., Steunebrink B.R., Schmidhuber J. LSTM: A search space Odyssey // *IEEE Transactions on Neural Networks and Learning Systems*. 2017. V. 28, Iss. 10. P. 2222-2232. DOI: 10.1109/tnnls.2016.2582924

GAS TURBINE ENGINE DYNAMIC MODEL BASED ON VARIABLE-MEMORY LSTM ARCHITECTURE

© 2020

A. V. Kuznetsov Postgraduate Student; Department of Power Plant Automatic Systems;
Samara National Research University, Samara, Russian Federation;
a.v.kuznetsov91@mail.ru

G. M. Makaryants Doctor of Science (Engineering), Assistant Professor, Professor of the Department
of Power Plant Automatic Systems;
Samara National Research University, Samara, Russian Federation;
georgy.makaryants@gmail.com

The buildup of thermodynamic cycle parameters is the main way to increase gas turbine engine efficiency. However, the growth of engine pressure and temperature ratio leads to the increase in the turbine heat load, which reduces the engine lifetime dramatically. In terms of gas turbine engines, to avoid the engine life loss is a crucial problem especially for small engines, because the limited size of a small gas turbine engine does not allow implementing various measures for nozzle vane cooling. In light of this, the contribution of the turbine heat control is essentially increasing. It places great demands on the accuracy of control over the main engine variables (such as the rotor speed and turbine outlet temperature). The state-of-the-industry gas turbine engines use an on-board engine mathematical model to improve the quality of the control. These models deal with engine processes of short duration and considerable overshooting. For that reason, the model accuracy is the main aspect in the control process. However, the issues of accurate and at the same time resource-saving calculation of rapidly

varying processes of changing the rotor speed and the turbine gas temperature remain under-investigated. In the work, neural network methods were used to model the unsteady modes of a small gas turbine engine. Using the data obtained as a result of firing tests of the JetCat P-60 engine, the engine regression neural network model was created. The main issue that arose during the creation of the model was to describe the dynamics of rapidly varying processes with pronounced overshoot. For this purpose, modification of the architecture of the classical LSTM network was carried out, the essence of which was to add a functional dependence of the exit node on the memory tensor. This allowed us to make the memory size independent of the number of model outputs, thereby increasing the modeling accuracy. The developed architecture was proposed a new name - VMLSTM network. As a result of comparison with the traditional Elman network and the classic LSTM network, the developed VMLSTM network showed the least value of the average error with a comparable number of modifiable model parameters. In addition, unlike the existing neural networks, the developed network demonstrated the ability to simulate turbine outlet gas over-temperature at the moments when the engine operating mode changes. The developed neural network architecture increases the reliability of modeling the dynamics of a small gas turbine engine as an object of control, which in the conditions of economical use of computing resources opens up possibilities of its application in on-board microcomputers.

Small gas turbine engine; transition process modeling; recurrent neural networks; LSTM with variable memory.

Citation: Kuznetsov A.V., Makaryants G.M. Gas turbine engine dynamic model based on variable-memory LSTM architecture. *Vestnik of Samara University. Aerospace and Mechanical Engineering*. 2020. V. 19, no. 2. P. 38-52. DOI: 10.18287/2541-7533-2020-19-2-38-52

References

1. Gurevich O.S. *Sistemy avtomaticheskogo upravleniya aviatsionnymi GTD: entsiklopedicheskiy spravochnik* [Aviation gas turbine engine control systems: Encyclopedic reference book]. Moscow: Torus Press Publ., 2011. 208 p.
2. Jaw L., Mattingly J. Aircraft engine controls. Reston, Va: American Institute of Aeronautics and Astronautics, Inc., 2009. 364 p.
3. Gol'berg F.D., Batenin A.V. *Matematicheskie modeli gazoturbinnnykh dvigateley kak ob"ektov upravleniya* [Mathematical models of gas turbine engines as objects of control]. Moscow: Moscow Aviation Institute Publ., 1999. 79 p.
4. *Integral'nye sistemy avtomaticheskogo upravleniya silovymi ustanovkami samoleta / pod red. A.A. Shevyakova* [Integrated systems for automatic control of aircraft power plants / ed. by A.A. Shevyakov]. Moscow: Mashinostroenie Publ., 1983. 283 p.
5. Shevyakov A.A. *Sistemy avtomaticheskogo upravleniya aviatsionnymi vozdušno-reaktivnymi silovymi ustanovkami* [Automatic control systems for aviation air-breathing propulsion systems]. Moscow: Mashinostroenie Publ., 1992. 424 p.
6. *Teoriya avtomaticheskogo upravleniya silovymi ustanovkami letatel'nykh apparatov / pod red. A.A. Shevyakova* [Theory of automatic control of aircraft power plants / ed. by A.A. Shevyakov]. Moscow: Mashinostroenie Publ., 1976. 344 p.
7. Badami M., Ferrero M.G., Portoraro A. Dynamic parsimonious model and experimental validation of a gas microturbine at part-load conditions. *Applied Thermal Engineering*. 2015. V. 75. P. 14-23. DOI: 10.1016/j.applthermaleng.2014.10.047
8. Arsalis A. Thermoeconomic modeling and parametric study of hybrid SOFC–gas turbine-steam turbine power plants ranging from 1.5 to 10MWe. *Journal of Power Sources*. 2008. V. 181, Iss. 2. P. 313-326. DOI: 10.1016/j.jpowsour.2007.11.104
9. Akhmedzyanov D.A. Non-stable regimes of aviation GTE. *Vestnik UGATU*. 2006. V. 7, no. 1 (14). P. 36-46. (In Russ.)
10. Gras'ko T.V., Mayatskiy S.A. Numerical technique for projected gas turbine engine's main chamber combustion analysis. *Vestnik UGATU*. 2014. V. 18, no. 3 (64). P. 23-29. (In Russ.)

11. Maksimov A.V., Kiselev E.A., Kurgalin S.D., Zuev S.A. Mathematical model describing air flow dynamics in a turbine spirometer. *Proceedings of the Institute for System Programming of the RAS*. 2019. V. 31, no. 1. P. 105-114. (In Russ.). DOI: 10.15514/ISPRAS-2019-31(1)-7
12. Biryukov R.V., Kiselyov Yu.V. Empirical model of the thermal state of rotor bearings and oil system at gas turbine engines. *Izvestiya Samarskogo Nauchnogo Tsentra RAN*. 2016. V. 18, no. 2 (3). P. 848-852. (In Russ.)
13. Asgari H., Chen X.Q., Morini M., Pinelli M., Sainudin R., Spina P.R., Venturini M. NARX models for simulation of the start-up operation of a singleshaft gas turbine. *Applied Thermal Engineering*. 2016. V. 93. P. 368-376. DOI: 10.1016/j.applthermaleng.2015.09.074
14. Nikpey H., Assadi M., Breuhaus P. Development of an optimized artificial neural network model for combined heat and power micro gas turbines. *Applied Energy*. 2013. V. 108. P. 137-148. DOI: 10.1016/j.apenergy.2013.03.016
15. Ali Lilo M., Latiff L.A., Abu A.B.H., Al Mashhadany Y.I., Ilijan A.K. Gas Turbine bearing and vibration classification of using multi-layer Neural Network. *2015 International Conference on Smart Sensors and Application (ICSSA) (May, 26-28, 2015, Kuala Lumpur, Malaysia)*. 2015. P. 20-23. DOI: 10.1109/ICSSA.2015.7322503
16. Elman J.L. Finding structure in time. *Cognitive science*. 1990. V. 14, Iss. 2. P. 179-211. DOI: 10.1016/0364-0213(90)90002-E
17. Jordan M.I. Serial order: A parallel distributed processing approach. *Advances in Psychology*. 1997. V. 121. P. 471-495. DOI: 10.1016/s0166-4115(97)80111-2
18. Siegelmann H.T., Horne B.G., Giles C.L. Computational capabilities of recurrent NARX neural networks. *IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)*. 1997. V. 27, Iss 2. P. 208-215. DOI: 10.1109/3477.558801
19. Hochreiter S., Schmidhuber J. Long short-term memory. Tech. Rep. no. FKI-207-95. Fakultat fur Informatik, Technische Universitat Munchen, 1995.
20. Hochreiter S., Schmidhuber J. Long short-term memory. *Neural Computation*. 1997. V. 9, Iss. 8. P. 1735-1780. DOI: 10.1162/neco.1997.9.8.1735
21. Gers F.A., Schmidhuber J., Cummins F. Learning to forget: continual prediction with LSTM. *Neural Computation*. 2000. V. 12, Iss. 10. P. 2451-2471. DOI: 10.1162/089976600300015015
22. Gers F.A., Schmidhuber J. Recurrent nets that time and count. *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium (July, 25-27, 2000, Como, Italy)*. 2000. DOI: 10.1109/ijcnn.2000.861302
23. Greff K., Srivastava R.K., Koutnik J., Steunebrink B.R., Schmidhuber J. LSTM: A search space Odyssey. *IEEE Transactions on Neural Networks and Learning Systems*. 2017. V. 28, Iss. 10. P. 2222-2232. DOI: 10.1109/tnnls.2016.2582924