

РАЗРАБОТКА МЕТОДИКИ СИНТЕЗА НЕЙРОКОНТРОЛЛЕРА ЧАСТОТЫ ВРАЩЕНИЯ РОТОРА МАЛОРАЗМЕРНОГО ГАЗОТУРБИННОГО ДВИГАТЕЛЯ С УЧЁТОМ ОГРАНИЧЕНИЙ ПО РАСХОДУ ТОПЛИВА

© 2018

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

Вопросы создания нейросетевых систем управления газотурбинных двигателей с учётом их нелинейной динамики и ограничений по расходу топлива в зависимости от режима работы двигателя остаются малоизученными. Для учёта ограничений по расходу топлива разработан метод модификации рассогласования между фактическим и целевым значением частоты вращения в процессе обучения нейроконтроллера. Проведено обучение двух нейроконтроллеров – один по разработанному методу, второй – без учёта ограничений по расходу топлива. По результатам работы синтезированных систем управления сделаны выводы о динамике переходных процессов и работе двигателя в допустимых пределах. Разработанный метод модификации ошибки обучения нейронной сети позволяет в автоматизированном режиме синтезировать нелинейную систему управления с учётом требований к ограничениям.

Малоразмерный газотурбинный двигатель; нелинейная система управления; ограничение по расходу топлива; нейроконтроллер; синтез.

Цитирование: Кузнецов А.В., Макарьянц Г.М. Разработка методики синтеза нейроконтроллера частоты вращения ротора малоразмерного газотурбинного двигателя с учётом ограничений по расходу топлива // Вестник Самарского университета. Аэрокосмическая техника, технологии и машиностроение. 2018. Т. 17, № 3. С. 93-102. DOI: 10.18287/2541-7533-2018-17-3-93-102

Введение

Применение нелинейных регуляторов обеспечивает предсказуемое поведение сложных нелинейных объектов, к которым относятся газотурбинные двигатели (ГТД), и позволяет получить требуемую динамику и точность системы во всём диапазоне режимов работы двигателя [1; 2]. В связи с этим разработка нелинейных систем управления является актуальной задачей в течение последних нескольких десятилетий [3-5]. Наиболее важным аспектом при создании нелинейных систем управления является настройка регулятора на разные режимы работы объекта управления. Кроме того, при управлении газотурбинным двигателем важно не только точно поддерживать регулируемые параметры на установившихся режимах работы, но и обеспечивать требуемую динамику системы на переходных режимах. При управлении двигателем во время переходных процессов обязательным критерием является ограничение по ускорению ротора и ограничение по температуре в камере сгорания. Эти ограничения позволяют защитить компрессор от помпажа, а элементы конструкции камеры и турбины – от прогорания [1; 6-8].

Несмотря на широкое применение линейных регуляторов и регуляторов с корректировкой коэффициентов, при представлении объекта как линейной системы происходит значительное упрощение динамики модели по сравнению с реальным объектом. Это сказывается на возможности спроектировать линейную систему управления, рабо-

тающую на границе устойчивости, так как реальный объект с таким регулятором может иметь непредсказуемое поведение [9]. Использование нейронных сетей в качестве регуляторов, по сравнению с линейными, позволяет сразу получить необходимую динамику нелинейной системы (регулятор-объект) без дополнительной подстройки его коэффициентов в процессе работы. В работах [10-14] производится обучение нейронной сети регулятора по результатам отклика двигателя на управляющий сигнал. Также проводятся исследования по управлению нейронными сетями двигателей с учётом помпажа [15] и требований ко времени переходного процесса [16], исследования по управлению отдельного компрессора с учётом его устойчивости [17] и объектов с неизвестными ограничениями входного сигнала на входе [18]. Однако во всех приведённых исследованиях не рассматриваются вопросы синтеза нейросетевого регулятора ГТД с учётом его ограничений по расходу топлива в зависимости от режима работы двигателя.

Целью работы является синтез нейросетевого регулятора частоты вращения малоразмерного газотурбинного двигателя с учётом ограничений по расходу топлива. Для обучения регулятор подключён к модели объекта. На полученную систему подавалось значение уставки, с которой сравнивалось значение текущей частоты вращения ротора двигателя, рассчитанной в модели. Для учёта ограничений по расходу топлива была разработана методика корректировки ошибки обучения нейроконтроллера.

Разработка метода обучения нейроконтроллера

В качестве объекта выступает модель малоразмерного газотурбинного двигателя JetCat P-60 SE [19]. В качестве регулятора выступает нейронная сеть прямого распространения с тремя входами и одним выходом. Входами в нейронную сеть являются: ошибка рассогласования между уставкой и текущей частотой вращения ротора, интеграл этой ошибки и само значение уставки. Выходом нейронной сети является значение расхода топлива в двигатель [13].

Нейронная сеть обучается с помощью метода градиентного спуска, расширенного на многослойную сеть – метод обратного распространения ошибки. Процесс обучения можно разделить на два основных этапа – прямое прохождение информации и обратное. Во время первого этапа вычисляются результаты работы всех слоёв сети. Во время второго этапа происходит вычисление отклонения результата вычисления сети (расхода топлива) от целевого значения. Затем определяется, какой вклад в ошибку внёс каждый из весовых коэффициентов. Аналогичным образом вычисляется рассогласование результатов работы нейронов скрытого слоя и далее по цепочке ошибка результатов работы сети распространяется по всем её слоям [20]. Большое влияние на сходимость обучения нейронной сети оказывает скорость обучения. В работе использована адаптивная подстройка скорости обучения для каждого слоя на каждом шаге обучения. Выбор последующего значения скорости обучения вычисляется из условия минимизации ошибки рассогласования [21]. Для вычисления скорости обучения берутся три значения среднеквадратичной ошибки работы сети и три значения скорости обучения на предыдущих шагах вычисления. По этим точкам определяются коэффициенты параболы по методу наименьших квадратов. Затем находится минимум параболы, значение которого является минимальным значением ошибки, являющейся следующим значением скорости обучения:

$$e = k_0 + k_1 a + k_2 a^2 ,$$

$$E = \begin{bmatrix} e_{t-1} \\ e_{t-2} \\ e_{t-3} \end{bmatrix}, \quad A = \begin{bmatrix} 1 & \alpha_{t-1} & \alpha_{t-1}^2 \\ 1 & \alpha_{t-2} & \alpha_{t-2}^2 \\ 1 & \alpha_{t-3} & \alpha_{t-3}^2 \end{bmatrix}, \quad K = \begin{bmatrix} k_0 \\ k_1 \\ k_2 \end{bmatrix},$$

$$K = (A^T A)^{-1} A^T E,$$

$$\frac{de}{d\alpha} = 0 \Rightarrow k_1 + 2k_2\alpha = 0 \Rightarrow \alpha = -\frac{k_1}{2k_2},$$

где e – среднеквадратичное отклонение; k_0, k_1, k_2 – коэффициенты в квадратном уравнении; α – скорость обучения; t – шаг итерации.

Регулятор представляет собой нейронную сеть прямого распространения с одним скрытым слоем (рис. 1). Такая сеть была выбрана из-за возможности аппроксимировать любые зависимости между входом и выходом, варьируя число скрытых нейронов [22]. Схема работы искусственного нейрона приведена на рис. 2 [20].

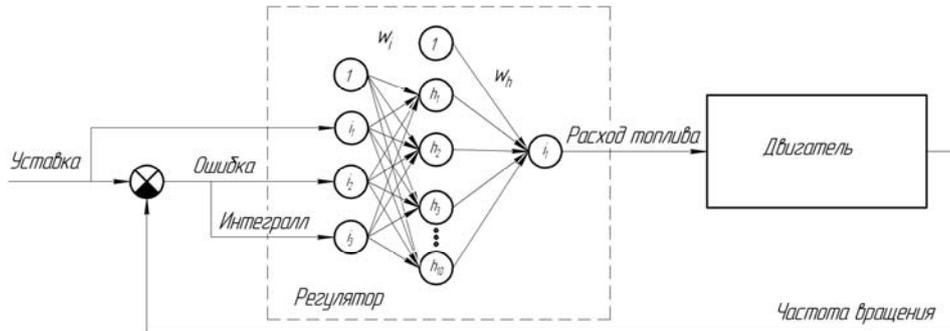


Рис. 1. Схема системы управления с нейросетевым регулятором

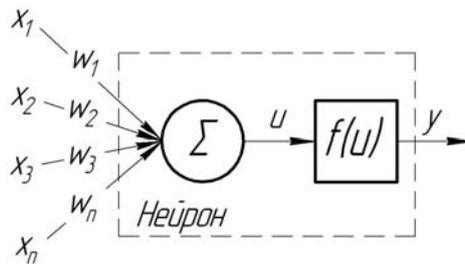


Рис. 2. Схема искусственного нейрона

Нейронная сеть (рис. 1) имеет три входа: ошибка, интеграл ошибки и значение уставки и один выход – расход топлива. Скрытый слой содержит 10 нейронов, число которых варьировалось в процессе создания регулятора для получения заданной точности. Во входной и скрытый слой были добавлены смещения, представляющие собой добавочные нейроны, на которых всегда присутствует значение, равное 1. Нейроны входного, скрытого и выходного слоёв соединены матрицами весовых коэффициентов, где w_i – матрица весовых коэффициентов за входным слоем, а w_h – за скрытым (рис. 1). В первоначальный момент времени эти матрицы инициализируются случайными числами из интервала от $-0,5$ до $0,5$, а затем в процессе обучения значения в матрицах подбираются так, чтобы выходное значение нейронной сети максимально соответствовало целевому значению. Для расчёта результата работы каждого слоя нейрон-

ной сети необходимо последовательно умножать вектор значений предыдущего слоя на матрицу весов, начиная со скрытого слоя (так как входной слой является сенсорным и он представляет собой те значения, которые поступают на вход сети). Полученный в результате матричного умножения вектор u (рис. 2) используется для вычисления функции активации нейрона $f(u)$. При моделировании нейроконтроллера использовалась сигмоидальная функция активации.

Для корректировки значений весов необходимо знать, насколько вычисленное в нейронной сети значение отличается от требуемого. Для обучения нейроконтроллера невозможно напрямую построить переходный процесс со всеми ограничениями по выходным параметрам. Поэтому была разработана схема вычисления ошибки рассогласования без непосредственного построения переходных процессов системы (рис. 3).

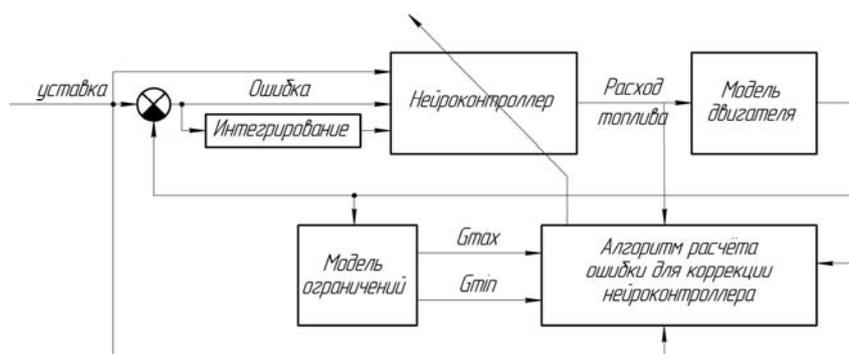


Рис. 3. Схема обучения нейроконтроллера

На схеме, приведённой на рис. 3, в каждый момент времени производится вычисление верхнего G_{max} и нижнего G_{min} допустимого значения расхода топлива и значения расхода топлива на установившемся режиме для текущего значения частоты вращения ротора. Ограничения берутся из динамической характеристики двигателя (рис. 4). Верхнее ограничение соответствует максимально допустимому ускорению ротора двигателя, при котором сохраняется устойчивая работа компрессора и не возникает недопустимого заброса температуры в камере сгорания. Нижнее ограничение соответствует поддержанию устойчивого процесса горения в камере сгорания.

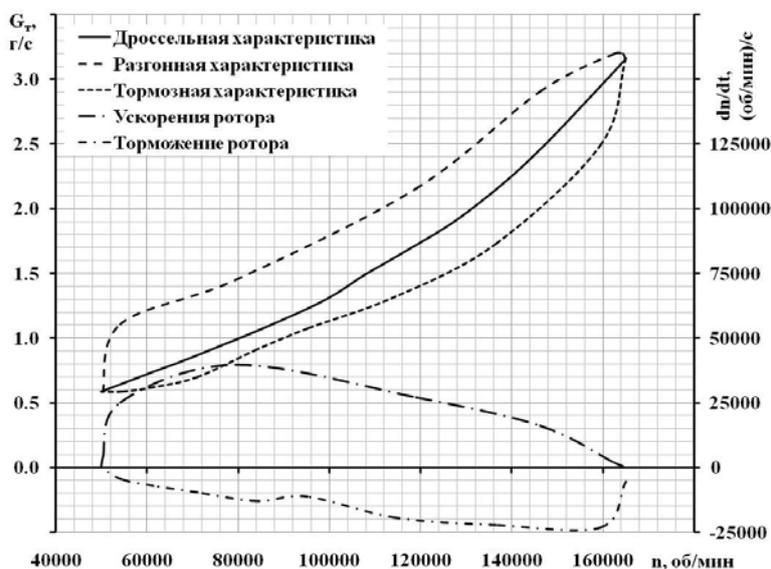


Рис. 4. Динамическая характеристика двигателя

Для первоначального приближения переходного процесса двигателя к допустимым по ограничениям значениям производилась модификация значений уставки по схеме, представленной на рис. 5.

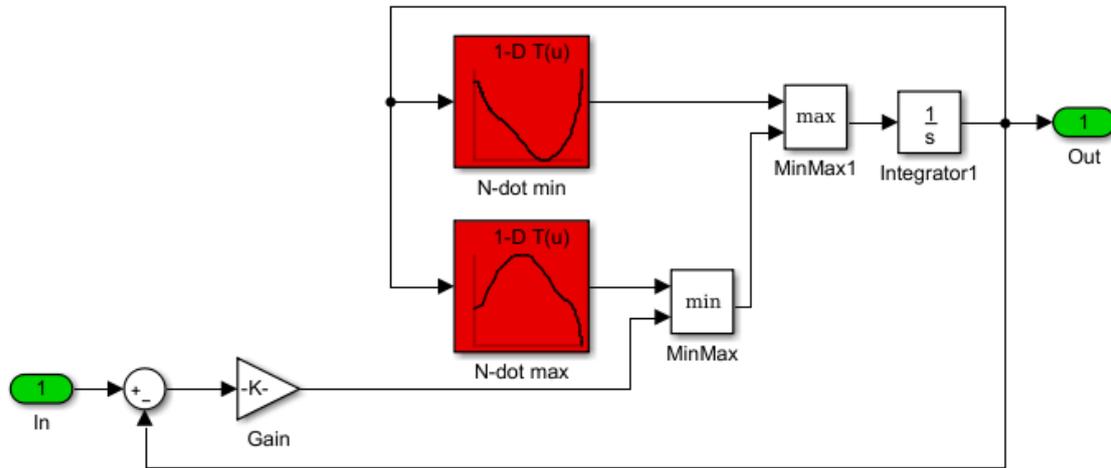


Рис. 5. Модификация значений уставки

Представленная на рис. 5 схема работает следующим образом. В интеграторе (Integrator1) в первоначальный момент времени задано значение частоты вращения ротора двигателя на режиме малого газа, а на вход (In) подаётся значение уставки. Разница между входом и выходом (Out), разделённым на шаг дискретизации системы в блоке Gain, представляет собой значение ускорения, которое нужно подать на интегратор, чтобы за один шаг по времени привести его значение к значению уставки. Полученное значение ускорения ограничивается максимально допустимыми для двигателя ускорениями сверху (N-dot max) и снизу (N-dot min), которые взяты из динамической характеристики двигателя. Результатом работы системы является приближенный к допустимому переходный процесс, который затем используется как значение уставки для алгоритма обучения нейронной сети регулятора. При этом сам регулятор использует первоначальное немодифицированное значение уставки.

Вычисление текущей ошибки рассогласования проводится на основании расположения в данный момент величины расхода топлива относительно его верхнего и нижнего значения. Если расход топлива лежит в допустимых пределах, то величина рассогласования остаётся неизменной и равной разности между уставкой и текущим значением частоты вращения, вычисленным в модели двигателя. Если значение расхода топлива больше максимально допустимого для данной частоты вращения, то алгоритм рассчитывает ошибку исходя из того, насколько было превышено допустимое значение:

$$err = err_n + \frac{G - G_{mean}}{G_{max} - G_{mean}} |err_n|,$$

$$err_n = n_t - n_f,$$

$$G_{mean} = \frac{G_{max} + G_{min}}{2},$$

где err – значение рассогласования для обучения нейронной сети; err_n – значение рассогласования между уставкой и фактической частотой вращения; n_t – уставка; n_f – фактическая частота вращения; G – текущий расход топлива.

Если расход топлива меньше минимально допустимого, то рассогласование вычисляется по формуле:

$$err = err_n - \frac{G_{mean} - G}{G_{mean} - G_{min}} |err_n|.$$

Обучение нейронной сети проводится циклически – сначала производится симуляция схемы, представленной на рис. 3. На следующем шаге производится коррекция весов на основе результатов работы блока алгоритма расчёта ошибок. Затем симуляция повторяется. Цикл заканчивается, когда среднеквадратичное значение ошибки станет меньше либо равным установленному значению.

Результаты моделирования

По результатам моделирования были получены графики переходных процессов и динамической характеристики двигателя с линией рабочих режимов (рис. 6).

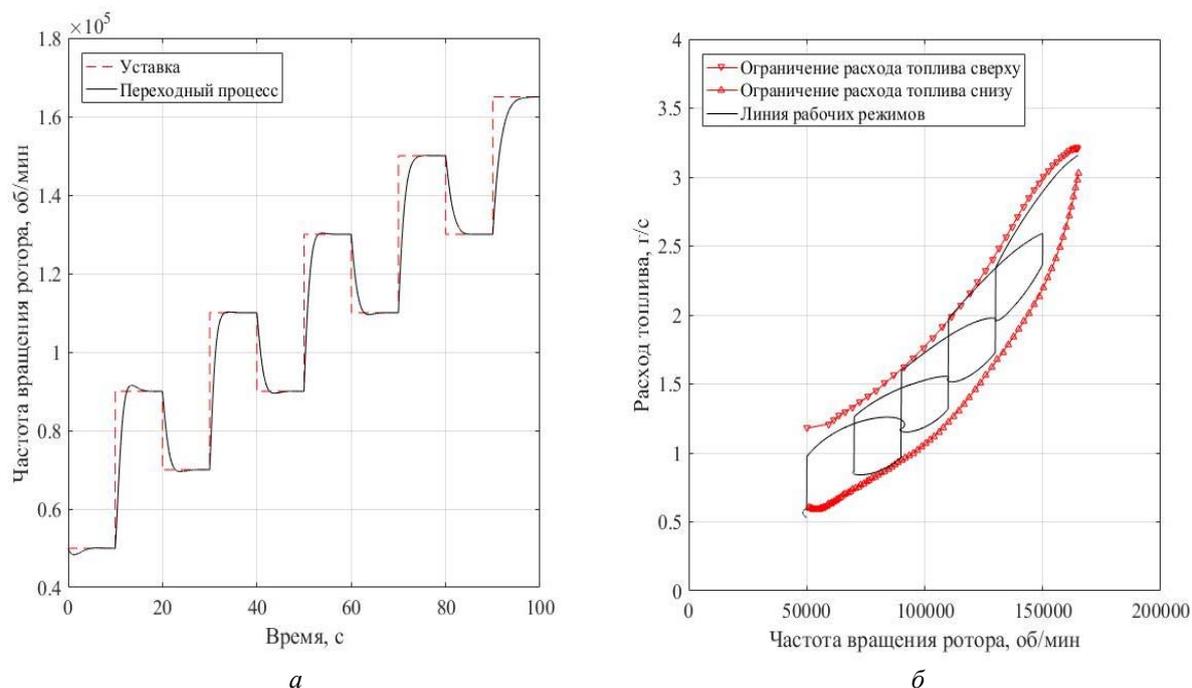


Рис. 6. Результат работы нейроконтроллера, обученного с учётом ограничений:
 а – график переходных процессов; б – динамическая характеристика двигателя

На рис. 6, а показано, что на установившихся режимах работы отсутствует статическая ошибка регулирования, при этом линии рабочих режимов двигателя (рис. 6, б) лежат в пределах допустимых значений по расходу топлива.

При обучении нейроконтроллера без учёта ограничений по расходу топлива были получены отрицательные значения расхода топлива на выходе регулятора. Поэтому обучение нейронной сети регулятора непосредственно на значении уставки не гарантирует обеспечение работы двигателя в области допустимых значений по расходу топлива.

Заключение

Разработанный метод позволяет синтезировать системы управления газотурбинных двигателей при помощи нейронных сетей, учитывающих ограничение по расходу топлива и нелинейную характеристику двигателя. Полученные результаты могут быть применимы для создания нейроконтроллеров двигателей различной тяги.

Библиографический список

1. Link C.J., Jack D.M. Aircraft engine controls: design, system analysis, and health monitoring. Reston, Virginia: American Institute of Aeronautics and Astronautics, 2009. 397 p.
2. Евсюков В.Н. Нелинейные системы автоматического управления: учебное пособие для студентов вузов. Оренбург: ГОУ ОГУ, 2007. 172 с.
3. Чернодуб А.Н., Дзюба Д.А. Обзор методов нейрорегулирования // Проблемы программирования. 2011. № 2. С. 79-94.
4. Isermann R. Perspectives of automatic control // Control Engineering Practice. 2011. V. 19, Iss. 12. P. 1399-1407. DOI: 10.1016/j.conengprac.2011.08.004
5. Tao G. Multivariable adaptive control: A survey // Automatica. 2014. V. 50, Iss. 11. P. 2737-2764. DOI: 10.1016/j.automatica.2014.10.015
6. Wang X., Zhao J., Xi-M. S. Overshoot-free acceleration of aero-engines: An energy-based switching control method // Control Engineering Practice. 2016. V. 47. P. 28-36. DOI: 10.1016/j.conengprac.2015.12.007
7. Xiaofeng L., Jing S., Yiwen Q., Ye Y. Design for aircraft engine multi-objective controllers with switching characteristics // Chinese Journal of Aeronautics. 2014. V. 27, Iss. 5. P. 1097-1110. DOI: 10.1016/j.cja.2014.08.002
8. Agüero J.L., Beroqui M.C., Pasquo H.D. Gas turbine control. Modifications for: Availability and limitation of spinning reserve and limitation of non-desired unloading. 2002. 8 p.
9. Филипс Ч., Харбор Р. Системы управления с обратной связью. М.: Лаборатория знаний, 2001. 616 с.
10. Nabney I.T., Cressy D.C. Neural network control of a gas turbine // Neural Computing and Applications. 1996. V. 4, Iss. 4. P. 198-208. DOI: 10.1007/BF01413818
11. Vasilyev V.I., Valeyev S.S., Shilonosov A.A. Design of neurocontroller for gas-turbine engine multi-mode control // Proceedings of the 8th International Conference on Neural Information Processing (ICONIP-2001) (Shanghai, Nov. 14-18, 2001). V. 2. P. 746-750.
12. Mu J., Rees D. Approximate model predictive control for gas turbine engines // Proceedings of the 2004 American Control Conference. 2004. V. 6. P. 5704-5709. DOI: 10.23919/acc.2004.1384765
13. Васильев В.И., Идрисов И.И. Алгоритмы проектирования и анализа устойчивости интеллектуальной системы управления ГТД // Вестник Уфимского государственного авиационного технического университета. 2008. Т. 11, № 1. С. 34-42.
14. Bazazzadeh M., Badihi H., Shahriari A. Gas turbine engine control design using fuzzy logic and neural networks // International Journal of Aerospace Engineering. 2011. V. 2011. DOI: 10.1155/2011/156796
15. Васильев В.И., Валеев С.С. Проектирование интеллектуальных систем управления ГТД на основе принципа минимальной сложности // Вестник Уфимского государственного авиационного технического университета. 2007. Т. 9, № 2. С. 32-41.

16. Sartori M.A., Antsaklis P.J. Implementations of learning control systems using neural networks // *IEEE Control Systems Magazine*. 1992. V. 12, Iss. 2. P. 49-57. DOI: 10.1109/37.126853

17. Jokar A., Zomorodian R., Ghofrani M.G., Khodaparast P. Active control of surge in centrifugal compressors using a brain emotional learning-based intelligent controller // *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*. 2015. V. 230, Iss. 16. P. 2828-2839. DOI: 10.1177/0954406215602281

18. Gao W., Selmic R.R. Neural network control of a class of nonlinear systems with actuator saturation // *Proceedings of the 2004 American Control Conference*. 2004. V. 3. P. 2569-2574. DOI: 10.23919/acc.2004.1383852

19. Кузнецов А.В., Макарьянц Г.М. Имитационная модель малоразмерного газотурбинного двигателя // *Вестник Самарского университета. Аэрокосмическая техника, технологии и машиностроение*. 2017. Т. 16, № 2. С. 65-74. DOI: 10.18287/2541-7533-2017-16-2-65-74

20. Хайкин С. Нейронные сети: полный курс. М.: Издательский дом «Вильямс», 2006. 1104 с.

21. Осовский С. Нейронные сети для обработки информации. М.: Финансы и статистика, 2004. 344 с.

22. Cybenko G. Approximation by superpositions of a sigmoidal function // *Mathematics of Control, Signals, and Systems*. 1989. V. 2, Iss. 4. P. 303-314. DOI: 0.1007/bf02551274

DEVELOPMENT OF A PROCEDURE FOR THE SYNTHESIS OF A MICRO GAS TURBINE ENGINE NEURAL CONTROLLER WITH ACCOUNT FOR FUEL CONSUMPTION CONSTRAINTS

© 2018

A. V. Kuznetsov Postgraduate Student;
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

Neural networks are often used to model dynamic processes in objects and to synthesize their control systems. However, their application in real systems is now rather limited due to insufficient research into the process of creating control systems. The issues of creating neural network control systems for gas turbine engines, taking into account both their nonlinear dynamics and the fuel consumption constraints depending on the engine operating mode, remain practically unexplored. To take into account the fuel consumption constraints, a method was developed for modifying the misalignment between the actual and target RPM values during the training of the neural controller. The resulting neural controller is characterized by implicit fuel consumption constraints and non-linear dynamics of the engine itself. The developed method for modifying the neural network training error allows one to synthesize a nonlinear control system, taking into account the requirements for limitations in the automatic mode.

Micro gas turbine engine; non-linear control system; fuel consumption constraints; neural controller; synthesis.

Citation: Kuznetsov A.V., Makaryants G.M. Development of a procedure for the synthesis of a micro gas turbine engine neural controller with account for fuel consumption constraints. *Vestnik of Samara University. Aerospace and Mechanical Engineering*. 2018. V. 17, no. 3. P. 93-102. DOI: 10.18287/2541-7533-2018-17-3-93-102

References

1. Link C.J., Jack D.M. Aircraft engine controls: design, system analysis, and health monitoring. Reston, Virginia: American Institute of Aeronautics and Astronautics, 2009. 397 p.
2. Evsyukov V.N. *Nelineynye sistemy avtomaticheskogo upravleniya: uchebnoe posobie dlya studentov vuzov* [Nonlinear automatic control systems: manual for university students]. Orenburg: GOU OGU Publ., 2007. 172 p.
3. Chernodub A.N., Dzyuba D.A. A review of methods of neuro management. *Problems in Programming*. 2011. No. 2. P. 79-94. (In Russ.)
4. Isermann R. Perspectives of automatic control. *Control Engineering Practice*. 2011. V. 19, Iss. 12. P. 1399-1407. DOI: 10.1016/j.conengprac.2011.08.004
5. Tao G. Multivariable adaptive control: A survey. *Automatica*. 2014. V. 50, Iss.11. P. 2737-2764. DOI: 10.1016/j.automatica.2014.10.015
6. Wang X., Zhao J., Xi-M. S. Overshoot-free acceleration of aero-engines: An energy-based switching control method. *Control Engineering Practice*. 2016. V. 47. P. 28-36. DOI: 10.1016/j.conengprac.2015.12.007
7. Xiaofeng L., Jing S., Yiwen Q., Ye Y. Design for aircraft engine multi-objective controllers with switching characteristics. *Chinese Journal of Aeronautics*. 2014. V. 27, Iss. 5. P. 1097-1110. DOI: 10.1016/j.cja.2014.08.002
8. Agüero J.L., Beroqui M.C., Pasquo H.D. Gas turbine control. Modifications for: Availability and limitation of spinning reserve and limitation of non-desired unloading. 2002. 8 p.
9. Phillips Ch.L., Harbor R.D. Feedback Control systems. New Jersey: Prentice Hall, 2000. 664 p.
10. Nabney I.T., Cressy D.C. Neural network control of a gas turbine. *Neural Computing and Applications*. 1996. V. 4, Iss. 4. P. 198-208. DOI: 10.1007/BF01413818
11. Vasilyev V.I., Valeyev S.S., Shilonosov A.A. Design of neurocontroller for gas-turbine engine multi-mode control. *Proceedings of the 8th International Conference on Neural Information Processing (ICONIP-2001) (Shanghai, Nov. 14-18, 2001)*. V. 2. P. 746-750.
12. Mu J., Rees D. Approximate model predictive control for gas turbine engines. Proceedings of the 2004 American Control Conference. 2004. V. 6. P. 5704-5709. DOI: 10.23919/acc.2004.1384765
13. Vasilyev V.I., Idrisov I.I. Algorithms of design and analysis of intelligent gas-turbine engine (GTE) control system. *Vestnik UGATU*. 2008. V. 11, no. 1. P. 34-42. (In Russ.)
14. Bazazzadeh M., Badihi H., Shahriari A. Gas turbine engine control design using fuzzy logic and neural networks. *International Journal of Aerospace Engineering*. 2011. V. 2011. DOI: 10.1155/2011/156796
15. Vasilyev V.I., Valeyev S.S. Design of intelligent control systems of gas-turbine engine on the basis of minimal complexity principle. *Vestnik UGATU*. 2007. V. 9, no. 2. P. 32-41. (In Russ.)
16. Sartori M.A., Antsaklis P.J. Implementations of learning control systems using neural networks. *IEEE Control Systems Magazine*. 1992. V. 12, Iss. 2. P. 49-57. DOI: 10.1109/37.126853
17. Jokar A., Zomorodian R., Ghofrani M.G., Khodaparast P. Active control of surge in centrifugal compressors using a brain emotional learning-based intelligent controller. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*. 2015. V. 230, Iss.16. P. 2828-2839. DOI: 10.1177/0954406215602281
18. Gao W., Selmic R.R. Neural network control of a class of nonlinear systems with actuator saturation. *Proceedings of the 2004 American Control Conference*. 2004. V. 3. P. 2569-2574. DOI: 10.23919/acc.2004.1383852

19. Kuznetsov A.V., Makaryants G.M. Micro gas turbine engine imitation model. *Vestnik of Samara University. Aerospace and Mechanical Engineering*. 2017. V. 16, no 2. P. 65-74. DOI: 10.18287/2541-7533-2017-16-2-65-74. (In Russ.)

20. Haykin S. *Neural networks*. New Jersey: Prentice Hall, 1999. 896 p.

21. Osowski S. *Sieci neuronowe do przetwarzania informacji*. Warszawa: Oficyna Wydawnicza Politechniki Warszawskiej, 2000. 325 p.

22. Cybenko G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems*. 1989. V. 2, Iss. 4. P. 303-314. DOI: 0.1007/bf02551274