

Матвеев Игорь Юрьевич (автор)

Самарский национальный исследовательский университет имени академика С. П. Королева, институт двигателей и энергетических установок, студент группы № 2409
Направление подготовки: 13.03.03 – Энергетическое машиностроение
e-mail: ya.igorec@yandex.ru

Макарьянц Георгий Михайлович (научный руководитель)

Самарский национальный исследовательский университет имени академика С. П. Королева, институт двигателей и энергетических установок, д.т.н., профессор
e-mail: georgy.makaryants@gmail.com

УДК 62-503.51

РАЗРАБОТКА РЕКУРРЕНТНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ ИДЕНТИФИКАЦИИ ПАРАМЕТРА ГАЗОТУРБИННОГО ДВИГАТЕЛЯ

И.Ю. Матвеев

Научный руководитель – д.т.н., профессор Г.М. Макарьянц

В работе рассмотрен вопрос по идентификации параметра частоты вращения газотурбинного двигателя с применением нейросетевой технологии для повышения эффективности работы алгоритма. Нейронная сеть обучалась по данным, полученным в результате симуляции термодинамической модели газотурбинного двигателя в программном пакете Matlab/Simulink. В ходе верификации нейроалгоритма по результатам модели относительная ошибка составила 0,549%. В будущем планируется использовать разработанную рекуррентную сеть при проектировании интеллектуальной системы управления газотурбинным двигателем.

Ключевые слова: рекуррентная нейронная сеть, математическая модель двигателя, частота вращения, расход топлива, функция активации, обучающая и тестовая выборки.

Идентификация подразумевает точное определение характера объекта по известным входным и выходным данным, полученным экспериментальным или аналитическим путем. На текущий момент существует множество способов для проведения идентификации параметров авиационного двигателя. Среди которых хорошо себя зарекомендовали численные методы, базирующиеся на дифференциальных уравнениях физических законов, протекающих в газотурбинном двигателе, однако они не нашли промышленного применения в силу того, что в процессе эксплуатации характеристики ГТД ухудшаются, и данный алгоритм управления становится неоптимальным [1]. Помимо аналитических методов существует еще и экспериментальное определение характеристик, где искомые величины получают путем непосредственного их измерения в рассматриваемом узле двигателя, но это не всегда возможно из-за наличия агрессивных условий рабочей среды [2]. Усложнение конструкции авиационных двигателей повлекло за собой ужесточение требований, предъявляемых при проектировании интеллектуальных систем управления, для которых важным фактором при формировании управляющего сигнала является точная и быстрая идентификация рабочих параметров объекта. В связи с развитием информационных технологий и аппаратного обеспечения появилась возможность использовать нейросетевые технологии в задаче идентификации параметров, которые обладают большей эффективностью по скорости вычисления рабочего параметра. Целью работы является создание рекуррентной нейронной сети, обладающей задержками в один такт по входным сигналам и новой функцией активации нейронов на скрытом слое для повышения эффективности алгоритма.

В решении поставленной цели были сформулированы следующие задачи: сформировать обучающую и тренировочную выборки по расходу топлива в камеру сгорания и частоте вращения ротора двигателя, разработать и обучить рекуррентную нейросеть, провести верификацию нейроалгоритма по данным термодинамической модели. В работе используется

математическая термодинамическая модель газотурбинного двигателя, представленная на рис. 1 [3].

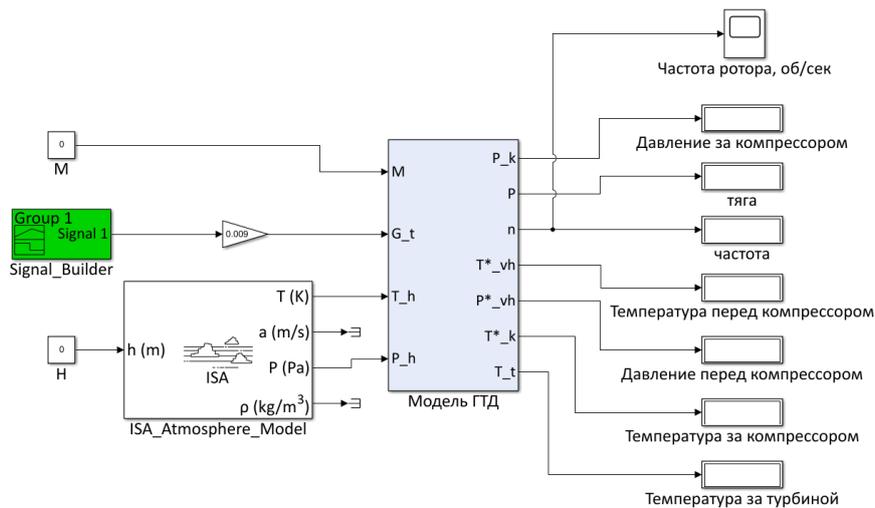


Рисунок 1. Общий вид математической модели газотурбинного двигателя в программе Matlab/Simulink

Расход топлива в камеру сгорания задан функциональным блоком «Signal_Builder», в котором определены значения входного параметра в каждый момент времени. Остальные сигналы задаются нулями для определения условий при земных испытаниях двигателя. Моделирование проводилось в течение 20 секунд. На рис. 2 показана зависимость расхода топлива в камеру сгорания от времени.



Рисунок 2. Расход топлива в камеру сгорания

В качестве идентифицируемого параметра модели примем частоту вращения ротора двигателя. Характер зависимости частоты вращения ротора двигателя от времени при заданном входном воздействии можно увидеть на рис. 3.

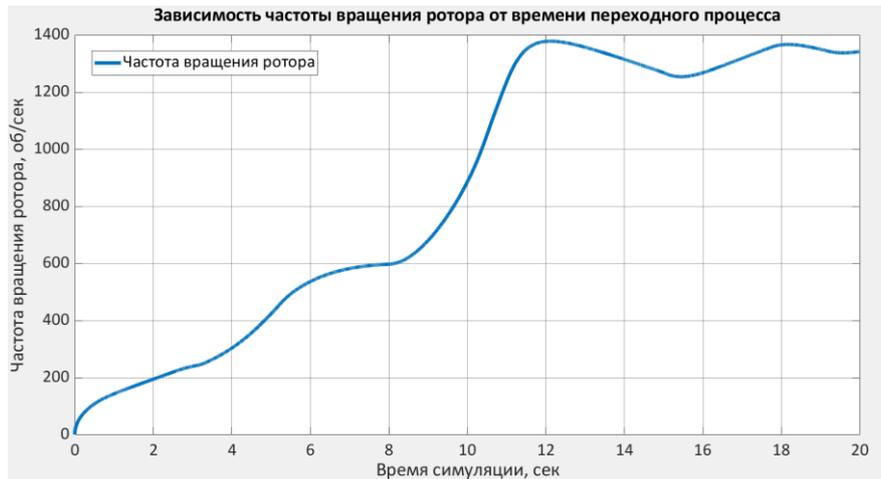


Рисунок 3. Частота вращения ротора двигателя

Массивы данных для обучения сети, полученных в результате расчета модели, можно представить в виде отдельных выборок.

$$U = \begin{pmatrix} Gt_0 & N_0 \\ \vdots & \vdots \\ Gt_{n-1} & N_{n-1} \\ Gt_n & N_n \end{pmatrix}$$

где U – это матрица входных данных.

$$Y = \begin{pmatrix} N_0 \\ \vdots \\ N_{n-1} \\ N_n \end{pmatrix}$$

где Y – вектор ответов для нейронной сети.

В процессе обучения и верификации сети выделяют обучающую и тестовую выборки. На обучающей выборке проводят оптимизацию весовых коэффициентов нейронной сети, где на вход сети подается массив признаков, а на выходе предоставляют вектор, содержащий ответы на входные параметры. На тестовой выборке проверяют качество обучения сети. Перед процедурой обучения нейронной сети необходимо провести нормализацию обучающих данных. Нормализация подразумевает сведение входных сигналов к единообразному представлению данных для качественной оптимизации сети [4].

$$\hat{x}_i = \frac{x_i - avr}{\Delta} \quad (1)$$

где \hat{x}_i – нормализованное значение сигнала, avr – среднее значение для входного нейрона, x_i – элемент из обучающей выборки, Δ – стандартное отклонение для входного нейрона.

Структура рекуррентной нейросети представляет ориентированный граф, состоящий из трех основных слоев. Входной слой никаких вычислительных операций не осуществляет, он является источником входных сигналов для передачи данных по нейронным связям на входы в скрытый слой. Скрытый слой принимает взвешенную сумму сигналов и в качестве аргумента подает на вход активационной функции. Разработанная функция подходит для решения задачи регрессии, так как ее область значений лежит в диапазоне $(-\infty; +\infty)$.

$$f(s) = e^s + s^3 \quad (2)$$

где $f(s)$ – функция активации нейронов на скрытом слое, s – входной сигнал нейрона

На основании решения функции активации каждый нейрон в скрытом слое отправляет сигнал на выходной слой сети, где принимается окончательное решение. Топология рекуррентной сети представлена на рис. 4.

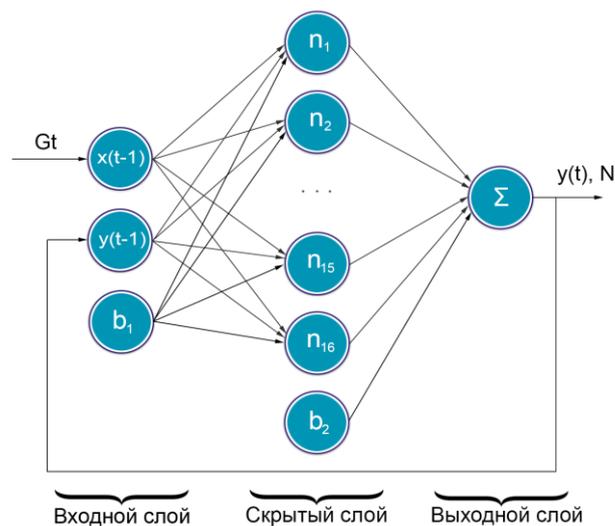


Рисунок 4. Структура рекуррентной нейронной сети

В качестве оптимизатора был выбран алгоритм Левенберга-Марквардта [5]. Этот метод гораздо производительнее градиентного спуска. Суть которого состоит в задании доверительных интервалов и в последовательном приближении значений коэффициентов сети к точкам оптимума. Сеть обучалась в течение 15 эпох т.е. итераций, в результате чего максимальная ошибка сети составила на обучающей выборке 29,14 об/с. Результат обучения сети можно увидеть на рис. 5.

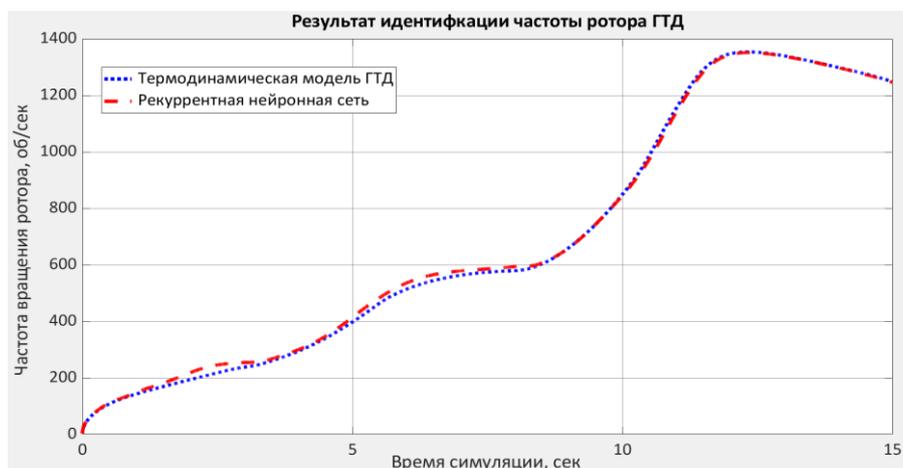


Рисунок 5. Идентификация частоты вращения ротора на обучающей выборке

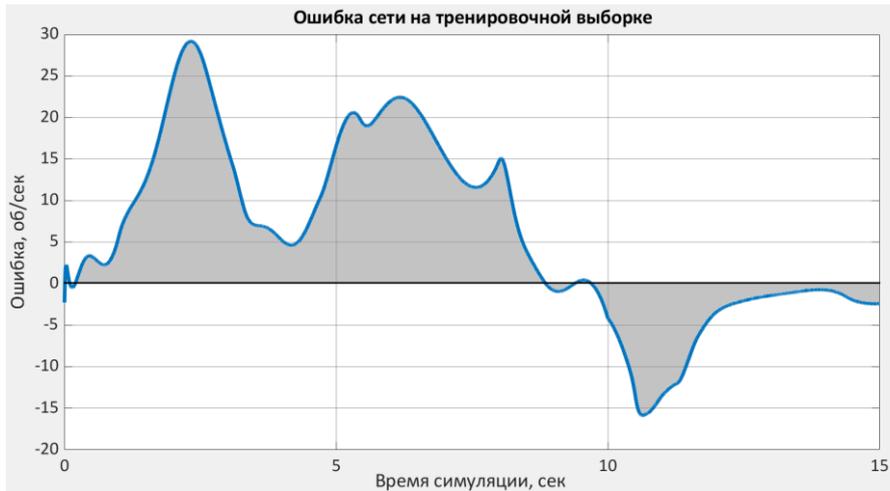


Рисунок 6. Ошибка сети на обучающей выборке

Проверка рекуррентной сети на тестовых данных показала максимальную погрешность по абсолютной величине в 6,831 об/с. На рис. 7 представлен результат определения исходного параметра на тестовой выборке. Данные взяты с последних 5 секунд симуляции термодинамической модели.

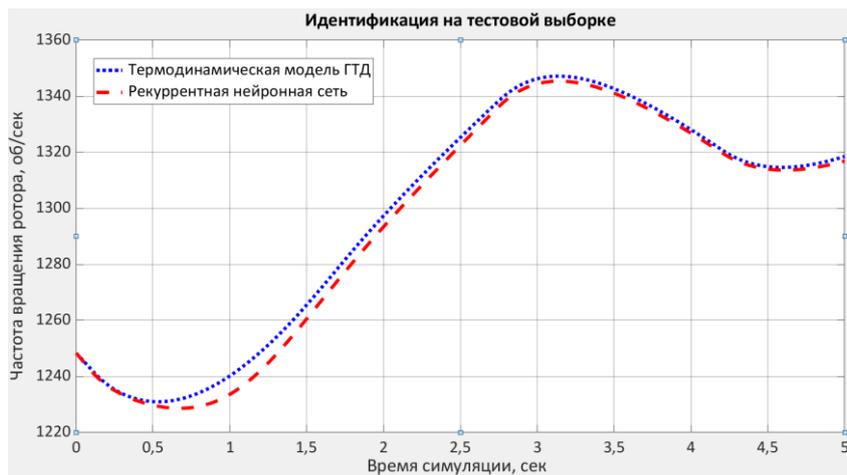


Рисунок 7. Идентификация частоты вращения ротора на тестовой выборке

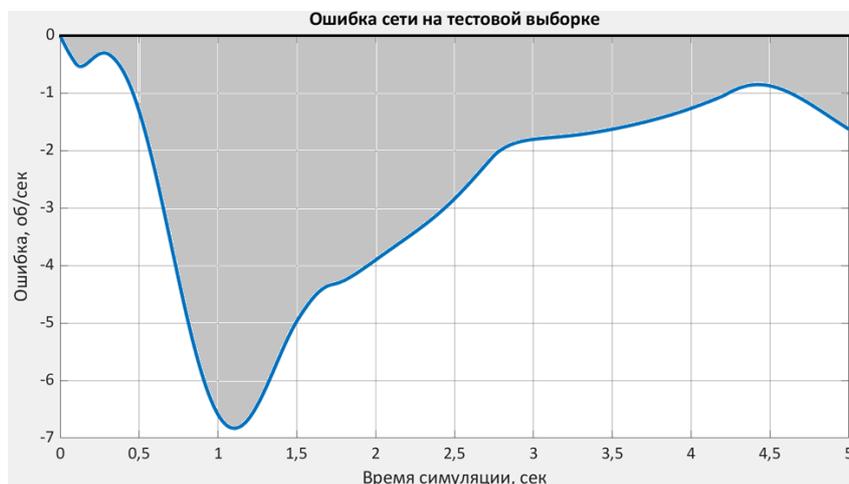


Рисунок 8. Ошибка сети на тестовой выборке

В работе была рассмотрена возможность применения рекуррентной нейронной сети в задаче идентификации параметра частоты вращения ротора малоразмерного газотурбинного двигателя для повышения эффективности вычисления искомого параметра. Для обучения рекуррентной нейронной сети были сформированы обучающие и тренировочные выборки данных по результатам вычисления термодинамической модели газотурбинного двигателя. Разработана собственная рекуррентная нейронная сеть для идентификации частоты вращения ротора газотурбинного двигателя с задержками в один такт по входным сигналам и новой функцией активации. В результате обучения сети был получен переходный процесс частоты вращения ротора двигателя с максимальной ошибкой сети в 29,14 об/с, проведена проверка обобщающей способности сети на тестовой выборке с максимальным отклонением в 6,831 об/с, а также получена относительная погрешность сети в 0,549%. Таким образом, рекуррентная нейронная сеть с задержками в один такт по входным сигналам и новой функцией активации на скрытом слое показала приемлемые результаты по идентификации параметра объекта газотурбинного двигателя. В будущем планируется использовать разработанный нейроалгоритм при проектировании интеллектуальной системы управления газотурбинным двигателем.

Литература

1. Гольберг Ф.Д., Батенин А.В. Математические модели газотурбинных двигателей как объектов управления. М.: Московский авиационный институт, 1999. – 82 с.
2. Система измерения частоты вращения ротора газотурбинного двигателя / Корноухов А.А., Понькин В.Н., Хуснуллин В.Х.; пат. RU 2416731; заявл. 27.10.09; опубл. 20.04.11.
3. 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.
4. Трофимова Е.А., Кисляк Н.В., Гилёв Д.В. Теория вероятностей и математическая статистика / Под ред. Е.А. Трофимовой; М-во образования и науки Рос. Федерации, Урал. федер. ун-т. – Екатеринбург: Изд-во Урал. ун-та, 2018. – 160 с.
5. Sousa C. Neural network learning by the levenberg-marquardt algorithm with Bayesian regularization (part 1) [Электронный ресурс]. – Режим доступа: http://www.crsouza.blogspot.com/2009/11/neural-networklearning-bylevenberg_18.html. (дата обращения: 20.05.2020).