

Виртуальный адаптивный измеритель вредных веществ в камере сгорания ГТД на базе *RBF*-сети

Никулин В.С.*, Хижняков Ю.Н., Южаков А.А.

*Пермский национальный исследовательский политехнический университет,
ПНИПУ, Комсомольский проспект, 29, Пермь, 614990, Россия*

**e-mail: kalif23@yandex.ru*

Статья поступила 31.03.2021

Аннотация

Рассматривается применение нейронного управления на базе *RBF*-сети при разработке виртуального адаптивного измерителя вредных веществ на основе расчета коэффициента камеры сгорания с целью снижения выхода вредных веществ в процессе горения, адаптивного расхода окислителя и адаптивного расхода топлива гомогенного коллектора для регулирования температуры продуктов горения за камерой сгорания.

Ключевые слова: газотурбинный двигатель, камера сгорания, измеритель вредных веществ, функция Гаусса, *RBF*-сеть, адаптивный нечеткий регулятор.

Введение

В авиационном газотурбинном двигателе (ГТД) применяют горючее нефтяного происхождения (керосин), которое состоит из 84–86% углерода и 14–16% водорода. В воздухе же содержится 23,2% кислорода. На окисление 1 кг водорода требуется 8 кг кислорода, а на окисление 1 кг углерода – 2,7 кг кислорода. При сгорании

продуктов горения керосина наряду с другими образуются оксиды азота (NO_x), которые разрушают озоновый слой и увеличивают радиацию на поверхности Земли [1; 2]. Международная организация гражданской авиации требует, чтобы при проектировании двигателей современных самолетов применялись «чистые» камеры сгорания [3; 4]. Снижение вредных веществ осуществляется за счет перераспределения топлива (керосина) по коллекторам с сохранением газодинамической устойчивости горения в камере сгорания (КС), которое характеризуется коэффициентом избытка кислорода (коэффициент камеры сгорания):

$$\alpha_{kc} = \frac{G_g}{G_T L_0}; \quad (1)$$

где $L_0 = 14,7 - 15,2$ – стехиометрический коэффициент керосина;

G_g – расход воздуха;

G_T – расход топлива.

Сгорание топливовоздушной смеси (ТВС) с соответствующим количеством окислителя должно происходить в диапазоне температур 1100–1600 °С. Если кислорода в ТВС мало, то при температуре ниже 1100 °С возможен срыв пламени (режим «бедного» горения), а при температуре выше 1600 °С возникает режим вибрационного горения с атомарным разложением NO_x [4; 5]. Протекание режимов «бедного» горения и вибрационного горения зависит от многих параметров: состава ТВС, температуры и давления в КС, геометрии КС и т.д. В совокупности указанные параметры характеризуют недетерминированный процесс горения в КС с фреймовым математическим описанием [6; 7; 8; 9; 10]. Предлагается рассмотреть нейронное

управление процессом горения в КС на базе *RBF*-сети. Достоинством данной сети по сравнению с сетью прямого распространения на базе нейронов с логистическими активационными функциями является минимум расхода расчетных ресурсов, малый требуемый объем статической памяти с целью оптимального сокращения программного обеспечения регулятора электронного двигателя (РЭД) авиационного ГТД.

На рис.1 приведена структурная схема управления процессом горения в камере ГТД с применением *RBF*-сети и адаптивного нечеткого регулятора (АНР).

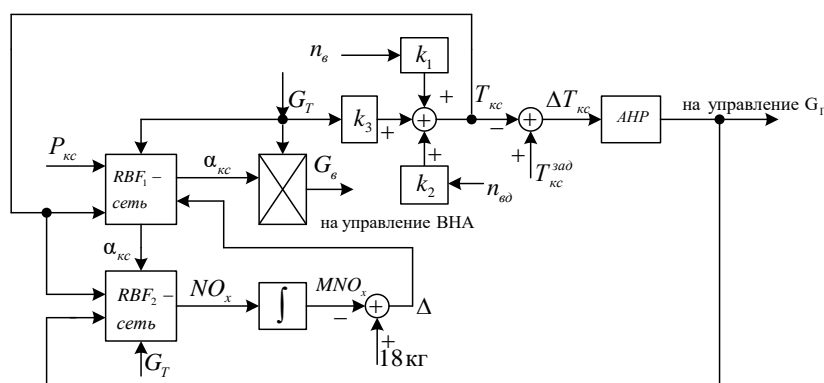
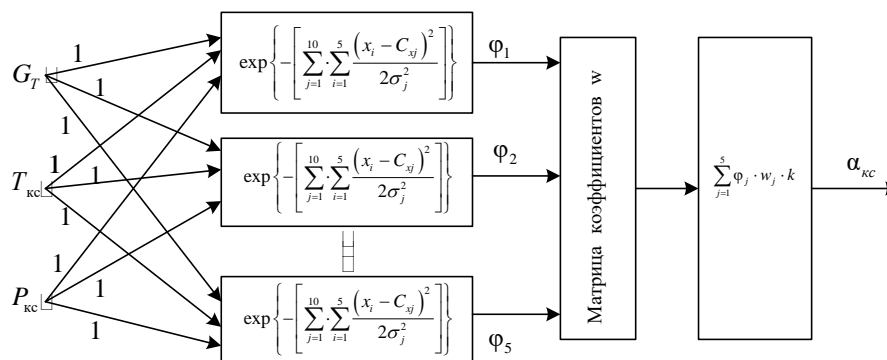


Рис.1. Структурная схема управления процессом горения в камере ГТД с применением *RBF*- сети и АНР

Структурная схема управления процессом горения в камере ГТД с применением *RBF*-сети и адаптивного нечеткого регулятора (АНР) включает контур управления выносным управляющим аппаратом (ВНА), контур управления расходом топлива гомогенного коллектора, виртуальный интегрированный адаптивный измеритель вредных веществ.

На рис. 2 приведена адаптивная *RBF*₁ - сеть измерения $\alpha_{кc}$, состоящая из пяти радиально-базисных нейронов и линейного выходного нейрона.

Рис.2. Адаптивная RBF_1 -сеть для измерения α_{kc} , имеющая три входа:

$$x_1 = f(G_T), x_2 = f(T_{kc}), x_3 = f(P_{kc})$$

Рассмотрим графоаналитический способ проектирования архитектуры $RBF1$ - сети для расчета α_{kc} как альтернатива применению алгоритма Кохонена.

Для проектирования архитектуры RBF_1 -сети расчета α_{kc} необходимы приведенные нормированные выборки, см. в табл. 1.

Таблица 1. Исходные данные расчета α_{kc}

Номер эксперимента	Входы			Выход
	G_T	T_{kc}	P_{kc}	
1	-0,6895	-1,6998	-0,9612	-1,5006
2	-0,6375	-0,0916	-0,6214	1,1331
3	-0,6375	-0,0916	-0,6214	1,1331
4	-0,6375	-0,0916	-0,6214	1,1331
5	2,0994	1,1749	1,9182	-0,5584
6	1,4893	1,0301	1,4626	-0,4034
7	-0,6441	0,4213	-0,0009	0,2797
8	-0,1582	0,4055	-0,0114	0,3028
9	-0,4258	-1,6998	-0,9612	-1,5006

В декартовой системе координат в относительных единицах согласно выбранным масштабам по оси абсцисс и оси ординат необходимо построить статические характеристики значений входных параметров от номера эксперимента (см. рис.2)

Выбрав одну из них (желательно среднюю) (см. рис.3), необходимо задаться центрами радиально–базисных нейронов, а затем циркулем построить окружности с равными радиусами σ (дисперсии) с центрами выбранных точек, которые бы охватывали все статические характеристики и пересекались между собой.

Таблица 2. Данные построений

Номер эксперимента	2	4	6	8	9
Центры нейронов (Cx_j)	-0,4501	-0,4501	1,3273	0,0786	0,4340
Центры нейронов (Y_j)	1,1331	1,1331	-0,4034	0,3028	-0,0189
Радиусы дисперсий (σ_i), ед.	1,9	1,5	2,2	2,3	1,9

В качестве функции активации нейронов примем функцию Гаусса [6, 8] и сформируем матрицу Грина G_I :

Число столбцов прямоугольной матрицы Грина G_I равно выбранному числу нейронов скрытого слоя RBF_1 -сети. Число строк матрицы Грина G_I равно числу выборок, неравное числу выбранных нейронов.

Запишем выходы скрытых нейронов в соответствии с матрицей Грина G_I согласно (3).




Рис. 3 Статические характеристики значений входных параметров от номера эксперимента

Запишем выходы скрытых нейронов в соответствии с матрицей Грина G_I согласно (3).

$$\begin{aligned}
 \varphi_1 &= \exp \left\{ - \left[\sum_{j=1}^9 \cdot \sum_{i=1}^5 \frac{(x_i - C_{xj})^2}{2\sigma_j^2} \right] \right\}; \\
 \varphi_2 &= \exp \left\{ - \left[\sum_{j=1}^9 \cdot \sum_{i=1}^5 \frac{(x_i - C_{xj})^2}{2\sigma_j^2} \right] \right\}; \\
 \varphi_3 &= \exp \left\{ - \left[\sum_{j=1}^9 \cdot \sum_{i=1}^5 \frac{(x_i - C_{xj})^2}{2\sigma_j^2} \right] \right\}; \\
 \varphi_4 &= \exp \left\{ - \left[\sum_{j=1}^9 \cdot \sum_{i=1}^5 \frac{(x_i - C_{xj})^2}{2\sigma_j^2} \right] \right\}; \\
 \varphi_5 &= \exp \left\{ - \left[\sum_{j=1}^9 \cdot \sum_{i=1}^5 \frac{(x_i - C_{xj})^2}{2\sigma_j^2} \right] \right\}.
 \end{aligned} \tag{3}$$

где C_{xj} – координаты центров нейронов.

Составим матрицу H_I на базе матрицы Грина (3)

$$H_I = \begin{pmatrix} \varphi_{11} & \varphi_{21} & \varphi_{31} & \varphi_{41} & \varphi_{51} \\ \varphi_{12} & \varphi_{22} & \varphi_{32} & \varphi_{42} & \varphi_{52} \\ \varphi_{13} & \varphi_{23} & \varphi_{33} & \varphi_{43} & \varphi_{53} \\ \varphi_{14} & \varphi_{24} & \varphi_{34} & \varphi_{44} & \varphi_{54} \\ \dots & & & & \\ \varphi_{19} & \varphi_{29} & \varphi_{39} & \varphi_{49} & \varphi_{59} \end{pmatrix} \tag{4}$$

0.8593	0.6585	0.2282	0.3416	0.3413
0.9507	0.958	0.4613	0.7951	0.7036
0.9507	0.958	0.4613	0.7951	0.7036
0.9507	0.958	0.4613	0.7951	0.7036
0.08203	0.03771	0.9254	0.1456	0.4652
0.1811	0.1181	0.9894	0.3433	0.7047
0.7891	0.8009	0.5959	0.8663	0.8293
0.7642	0.799	0.6785	0.9627	0.9267
0.8511	0.6668	0.2471	0.368	0.3669
0.5852	0.5833	0.8204	0.9029	0.9889

Рис. 4. Результаты моделирования матрицы H_I

Входы выборок необходимы для расчета выходов нейронов скрытого слоя RBF_1 - сети.

Для определения матрицы коэффициентов \bar{w} выходного нейрона необходимо воспользоваться [6] (5)

$$\bar{w} = (H_1^T \cdot H_1)^{-1} H_1^T \cdot \bar{Y}_{kc} \quad (5)$$

где $\bar{Y}_{kc} = (\alpha_{kc1}, \alpha_{kc2}, \alpha_{kc3}, \alpha_{kc4}, \dots, \alpha_{kc9})^T$.

После определения матрицы весов \bar{w} для всех выборок их необходимо занести в память и в дальнейшем использовать для расчета α_{kc} для текущих входов RBF_1 - сети.

Далее определяется коэффициент α_{kc} по формуле (6) путем суммирования произведения выходов скрытых нейронов на взятый из памяти соответствующий элемент матрицы w_i

$$\alpha_{kc} = \sum_{i=1}^5 \varphi_i \cdot w_i \cdot k \quad (6)$$

Процесс обучения с учителем (без итераций) придает RBF_1 -сети адаптивность.

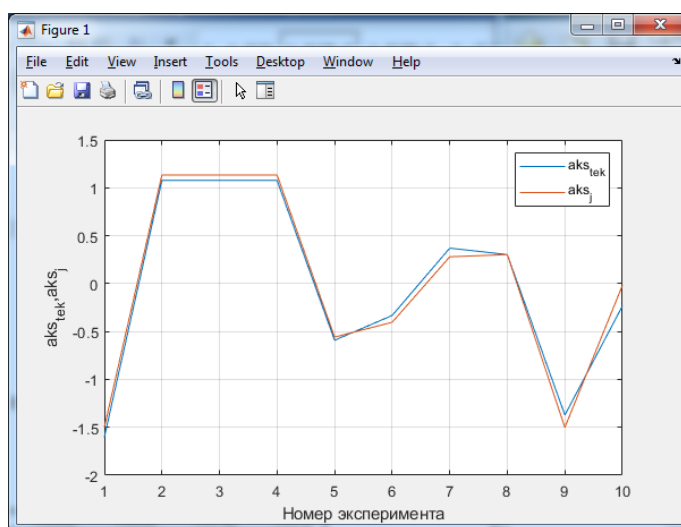


Рис. 5. Результаты моделирования работы измерителя α_{kc}

Аналогично проводится проектирование архитектуры адаптивной RBF_2 - сети для расчета текущих значений NO_x .

На рис. 6 приведена архитектура адаптивной RBF_2 -сети для измерения текущих значений NO_x при четырех входных параметрах:

$$x_1 = f(G_T), x_2 = f(T_{кc}), x_3 = f(G_T), x_4 = f(\alpha_{кc})$$

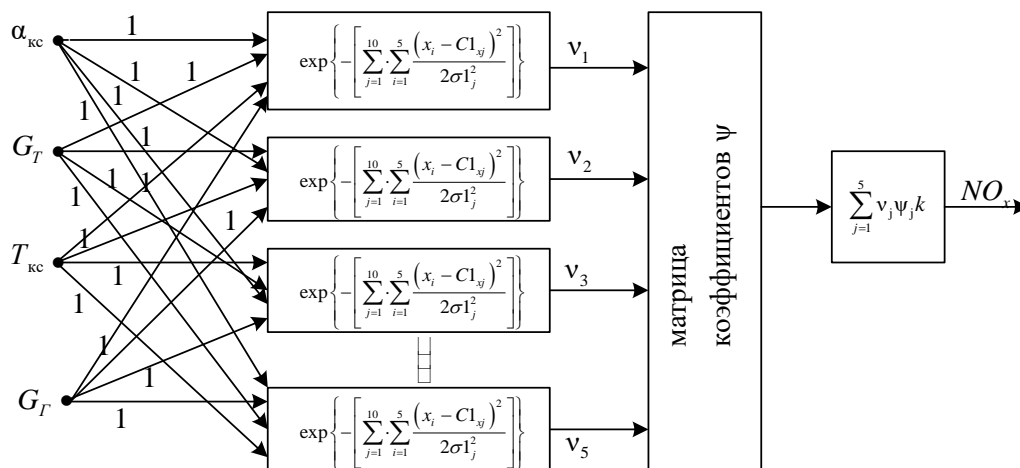


Рис. 6. Адаптивная RBF_2 – сеть для измерения параметра NO_x

Для проектирования архитектуры RBF_2 - сети необходимы выборки, приведенные в табл. 2

Таблица 2. Исходные данные расчета NO_x

Номер эксперимента	Входы				Выход
	G_T	$\alpha_{кc}$	G_T	$T_{кc}$	NO_x
1	-1,5280	0,9487	0,4390	-0,0889	-0,7683
2	-0,9621	0,9487	-0,1560	-1,4216	-0,7195
3	-0,9621	0,9487	-0,6528	0,7997	-0,4336
4	-0,3962	0,9487	-1,1005	-0,5331	-0,5624
5	-0,3962	0,9487	0,7749	1,2439	0,3670
6	0,1698	0,9487	0,4390	-0,0889	-0,2001
7	0,7357	0,9487	-0,1560	-1,4216	-0,5628
8	0,7357	0,9487	-0,6528	0,7997	0,5786
9	1,3017	0,9487	-1,1005	-0,5331	-0,2484

В декартовой системе координат в относительных единицах согласно выбранным масштабам по оси абсцисс и оси ординат необходимо построить статические характеристики (см. рис.7)

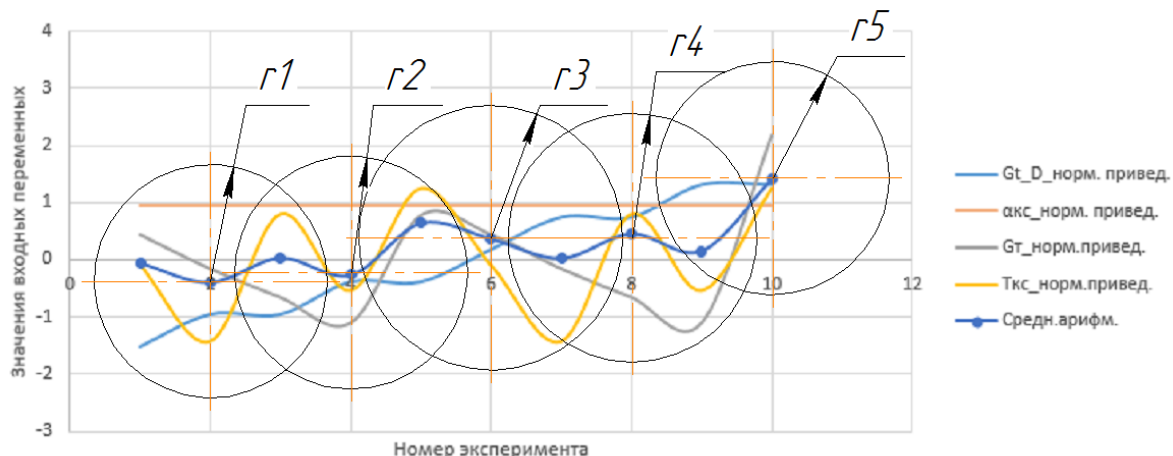


Рис.7. Статические характеристики значений входных параметров от номера эксперимента

Выбрав одну из них (желательно среднюю) (см. рис.7), необходимо задаться центрами радиально–базисных нейронов, а затем циркулем построить окружности с равными радиусами σ_1 (дисперсии) с центрами выбранных точек, которые бы охватывали все статические характеристики и пересекались между собой.

В табл. 3 занести данные построений.

Таблица 3. Данные построений

Номер эксперимента	2	4	6	8	9
Центры нейронов ($C1x_j$)	-0,3978	-0,2703	0,3671	0,4578	1,4150
Центры нейронов ($Y1_j$)	-0,7195	-0,5624	-0,2001	0,5786	2,5495
Радиусы дисперсий (σ_1), ед.	1,8	1,8	2,2	2,1	1,8

В качестве функции активации нейронов примем функцию Гаусса [6] и сформируем матрицу Грина G_2 для сети RBF_2 :

$$G_2 = \begin{bmatrix} \varphi(\|x_1 - C1x_1\|) & \varphi(\|x_1 - C1x_2\|) & \varphi(\|x_1 - C1x_3\|) & \varphi(\|x_1 - C1x_4\|) & \varphi(\|x_1 - C1x_5\|) \\ \varphi(\|x_2 - C1x_1\|) & \varphi(\|x_2 - C1x_2\|) & \varphi(\|x_2 - C1x_3\|) & \varphi(\|x_1 - C1x_4\|) & \varphi(\|x_2 - C1x_5\|) \\ \dots & & & & \\ \varphi(\|x_9 - C1x_1\|) & \varphi(\|x_9 - C1x_2\|) & \varphi(\|x_9 - C1x_3\|) & \varphi(\|x_9 - C1x_4\|) & \varphi(\|x_9 - C1x_5\|) \end{bmatrix} \quad (7)$$

Число столбцов прямоугольной матрицы Грина G_2 равно выбранному числу нейронов скрытого слоя RBF_2 - сети. Число строк матрицы Грина G_2 равно числу выборок и неравное числу выбранных нейронов RBF_2 - сети.

Запишем выходы скрытых нейронов RBF_2 - сети в соответствии с матрицей Грина G_2 и выражения (8).

$$\begin{aligned} v_1 &= \exp \left\{ - \left[\sum_{j=1}^9 \cdot \sum_{i=1}^5 \frac{(x_i - C1_{xj})^2}{2\sigma 1_j^2} \right] \right\}; \\ v_2 &= \exp \left\{ - \left[\sum_{j=1}^9 \cdot \sum_{i=1}^5 \frac{(x_i - C1_{xj})^2}{2\sigma 1_j^2} \right] \right\}; \\ v_3 &= \exp \left\{ - \left[\sum_{j=1}^9 \cdot \sum_{i=1}^5 \frac{(x_i - C1_{xj})^2}{2\sigma 1_j^2} \right] \right\}; \\ v_4 &= \exp \left\{ - \left[\sum_{j=1}^9 \cdot \sum_{i=1}^5 \frac{(x_i - C1_{xj})^2}{2\sigma 1_j^2} \right] \right\}; \\ v_5 &= \exp \left\{ - \left[\sum_{j=1}^9 \cdot \sum_{i=1}^5 \frac{(x_i - C1_{xj})^2}{2\sigma 1_j^2} \right] \right\}. \end{aligned} \quad (8)$$

Составим матрицу H_2 на базе матрицы Грина G_2 (7) и (8).

$$H_2 = \begin{pmatrix} v_{11} & v_{21} & v_{31} & v_{41} & v_{51} \\ v_{12} & v_{22} & v_{32} & v_{42} & v_{52} \\ v_{13} & v_{23} & v_{33} & v_{43} & v_{53} \\ v_{14} & v_{24} & v_{34} & v_{44} & v_{54} \\ \dots & & & & \\ v_{19} & v_{29} & v_{39} & v_{49} & v_{59} \end{pmatrix} \quad (9)$$

0.8856	0.6892	0.7527	0.8034	0.2538
0.9038	0.7109	0.6821	0.74	0.1561
0.8928	0.7144	0.7957	0.8385	0.3033
0.9299	0.7918	0.7661	0.8074	0.2135
0.8321	0.6036	0.8805	0.9209	0.64
0.9125	0.7954	0.9603	0.97	0.5684
0.8769	0.6728	0.7628	0.8135	0.2811
0.8662	0.6761	0.8899	0.9218	0.5462
0.8497	0.6144	0.751	0.8081	0.3092
0.6463	0.284	0.6993	0.8032	0.9109

Рис. 8. Результаты моделирования матрицы H_2

Входы выборок необходимы для расчета выходов нейронов скрытого слоя RBF_2 - сети.

Для определения матрицы коэффициентов $\bar{\psi}$ выходного нейрона необходимо использовать выходные данные исходной выборки) и матрицу H_2 .

$$\bar{\psi} = (H_2^T \cdot H_2)^{-1} H_2^T \cdot \bar{Y}_{NO_x} \quad (10)$$

где $\bar{Y}_{NO_x} = (NO_{x1}, NO_{x2}, NO_{x3}, NO_{x4}, \dots, NO_{x9})^T$.

После определения матриц коэффициентов всех выборок их необходимо занести в память и в дальнейшем использовать для расчета NO_x в реальном времени для текущих входов адаптивной RBF_2 - сети.

Далее определяется коэффициент NO_x по формуле (11) путем суммирования произведения откорректированных выходов скрытых нейронов на соответствующий элемент матрицы ψ .

$$NO_x = \sum_{i=1}^5 v_i \cdot \psi_i \cdot k \quad (11)$$

Адаптация RBF_2 - сети достигается обучением с учителем (без итераций).

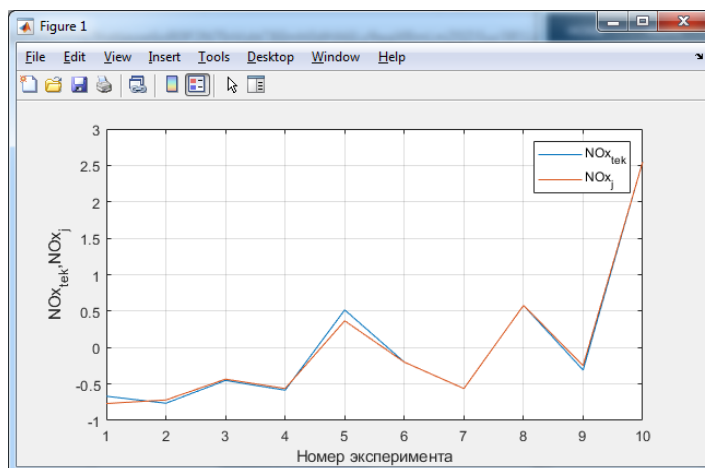


Рис. 9. Результаты моделирования работы измерителя NO_x

В вычислительной практике операция псевдоинверсии выполняется за один шаг и рассчитывается с применением декомпозиции SVD [11; 12; 13].

Расчет MNO_x проводится интегрированием текущих значений NO_x с контролем предельного значения не более 18 кг (см. рис.1). Разность текущего и заданного значений вредных веществ подается на вход RBF_1 - сети для коррекции подачи окислителя в КС через расчетное значение расхода окислителя с помощью системы управления ВНА.

Обучение RBF_1 - сети и RBF_2 - сети по сравнению с персептроном с помощью алгоритма Левенберга–Марквардта [13] требует на два порядка меньше числа выборок, на порядок быстрее обучается, исключает попадание в минимум [14] в процессе обучения и требует меньший объем статической памяти.

Расчет расхода гомогенного коллектора выполняется с помощью адаптивного нечеткого регулятора (АНР) с применением метода последовательного обучения [15; 17; 18; 19; 20].

Заключение

1. Разработан метод и алгоритм проектирования виртуального адаптивного измерителя вредных веществ авиационного ГТД с применением сети RBF_1 и сети RBF_2
2. Разработан метод и алгоритм расчета коэффициента камеры сгорания с применением RBF_1 - сети.
3. Разработан графоаналитический способ построения архитектур RBF_1 - сети и RBF_2 – сети, исключающий применение алгоритма Кохонена.
4. Разработано проектирование RBF_1 -сети с коррекцией по отклонению заданного и текущего отклонений MNO_x .
5. Разработана структура управления ВНА ГТД на базе расчета коэффициента избытка воздуха камеры сгорания.
6. Разработана типовая структура управления расходом топлива гомогенного коллектора ГТД на базе адаптивного нечеткого регулятора с применением метода последовательного обучения.

Библиографический список

1. Метечко Л.Б., Тихонов А.И., Сорокин А.Е., Новиков С.В. Влияние экологических нормативов на развитие авиационного двигателестроения // Труды МАИ. 2016. № 85. URL: <http://trudymai.ru/published.php?ID=67495>
2. Гуревич О.С. Управление авиационными газотурбинными двигателями. – М: Изд-во МАИ, 2001. – 100 с.

3. Иноземцев А.А., Нихамкин А.А., Сандрацкий В.Л. Основы конструирования авиационных двигателей и энергетических установок. - М.: Машиностроение, 2008. Т. 2. – 368 с.
4. Исаев А.И. Скоробогатов С.В. Методологические аспекты экспериментальных исследований процесса горения в камерах сгорания газотурбинных двигателей // Труды МАИ. 2018. № 98. URL: <http://trudymai.ru/published.php?ID=87340>
5. Андриевская Н.В., Андриевский О.А., Леготкина Т.С., Хижняков Ю.Н., Сторожев А.А., Никулин В.С., Южаков А.А., Кузнецов М.Д. Нейронечеткое управление выбросами вредных веществ авиационного газотурбинного двигателя // Мехатроника. Автоматизация, Управление. 2020. Т. 21. № 6. С. 348 - 355. DOI: [10.17587/mau.21.348-355](https://doi.org/10.17587/mau.21.348-355)
6. Дмитриев В.Г., Мунин А.Г. Экологические проблемы гражданской авиации // Аэрокосмический курьер. 2003. № 2. С. 15 - 17.
7. Черепанов Ф.М., Ясницкий Л.Н. Нейросетевой фильтр для исключения выбросов в статистической информации // Вестник Пермского университета. Серия: Математика. Механика. Информатика. 2008. № 4. С. 151 - 155.
8. Ясницкий Л.Н. Нейронные сети - инструмент для получения новых знаний: успехи, проблемы, перспективы // Нейрокомпьютеры: разработка, применение. 2015. № 5. С. 48 – 56.
9. Каллан Р. Основные концепции нейронных сетей / Пер. с англ. – М.: Вильямс, 2001. - 288 с.

10. Девятков В.В. Системы искусственного интеллекта. – М.: Машиностроение, 1991. – 320 с.
11. Гостев В.И. Проектирование нечетких регуляторов для систем автоматического управления. - СПб: БХВ-Петербург, 2011. - 416 с.
12. Осовский С. Нейронные сети для обработки информации / Пер. с польского. – М.: Финансы и статистика, 2004. – 344 с.
13. Хижняков Ю.Н. Нечеткое, нейронное и гибридное управление. – Пермь: Изд-во Пермского национального исследовательского политехнического университета, 2013. – 303 с.
14. Бакланов А.В., Макарова Г.Ф., Васильев А.А., Нуждин А.А. Влияние перфорированного обтекателя фронтального устройства на основные характеристики камеры сгорания ГТД // Труды МАИ. 2018. № 103. URL: <http://trudymai.ru/published.php?ID=100700>
15. Пегат А. Нечеткое моделирование и управление / Пер. с англ. – М.: БИНОМ. Лаборатория знаний, 2007. – 798 с.
16. Мосолов С.В., Сидлеров Д.А., Пономарев А.А. Сравнительный анализ особенностей рабочего процесса в камерах сгорания ЖРД со струйно-струйными и струйно-центробежными форсунками на основе численного моделирования // Труды МАИ. 2012. № 59. URL: <http://trudymai.ru/published.php?ID=34989>
17. Леоненков А.В. Нечеткое моделирование в среде MATLAB и FuzzyTech. - СПб.: БХВ-Петербург, 2005. – 736 с.

18. Ярушкина Н.Г. Основы теории нечетких и гибридных систем. – М.: Финансы и статистика, 2004. – 320 с.
19. Mamdani E.H. Application of Fuzzy Algorithms for the Control of a Simple Dynamic Plant // Proceedings of the IEEE, 1974, pp. 121 - 159. DOI:[10.1049/PIEE.1974.0328](https://doi.org/10.1049/PIEE.1974.0328)
20. Никулин В.С., Сторожев С.А., Абдулин Д.М., Хижняков Ю.Н. Адаптивный виртуальный измеритель вредных веществ в камере сгорания ГТД с применением нечеткой // Труды МАИ. 2020. № 116. URL: <http://trudymai.ru/published.php?ID=121086>. DOI: [10.34759/trd-2021-116-11](https://doi.org/10.34759/trd-2021-116-11)

Virtual adaptive meter of deleterious substances in combustion chamber of a gas turbine engine based on the RBF-network

Nikulin V.S.*, Khizhnyakov Yu.N., Yuzhakov A.A.

Perm National Research Polytechnic University, PNRPU,

29, Komsomolsky Prospekt, Perm, 614990, Russia

**e-mail: kalif23@yandex.ru*

Abstract

The soft computing technology toolkit is based on fuzzy systems, probabilistic models, neural networks, genetic algorithms, etc., which have their own advantages and disadvantages. This toolkit application was considered for an aircraft gas turbine engine (GTE) operating under conditions of uncertainties such as regulating hardware elements aging, variable ambient environment parameters, and variable fuel parameters.

Combustion chamber, ensuring the process of the air-fuel mixture (AFM) burning, is one of the basic parts of the gas turbine engine. Today's progress in aircraft building development imposes requirements to the aircraft and engine soft-hardware facilities integration simplicity, as well as reduction of deleterious substances exhaust to the environment.

The purpose of the presented study consists in the following:

- developing method and algorithm for the adaptive virtual measurer of the deleterious substances exhaust by the GTE combusting chamber based on the RBF-network;
- adaptive control of air consumption into the combustion chamber;
- adaptive control of the gases temperature behind the combustion chamber employing fuel consumption regulation by the homogeneous collector.

The following research techniques were used in this work:

- grapho-analytical method for the RBF-network architecture building as an alternative to the Kohonen algorithm;
- an algorithm for oxidizer feeding control with the RBF-network;
- creating an algorithm for the current total value of deleterious substances correction at the specified value exceedance;
- creating an algorithm for the fuel consumption control in the homogeneous collector while temperature control behind the GTE combustion chamber by the adaptive fuzzy regulator

Based on the total computing of the deleterious substances, the following conclusion can be made on the exhausts requirements, which is 18 kg, as well as improvement of control system of the remote guiding device (RGD), and combustion products temperature behind the GTE combustion chamber.

The results of the research confirmed the decline of the combustion process uncertainty impact, and exhausts reduction in the airfield vicinity.

Keywords: gas turbine engine, combustion chamber, meter of deleterious substances, Gaussian function, RBF-network, adaptive fuzzy controller.

References

1. Metechko L.B., Tikhonov A.I., Sorokin A.E., Novikov S.V. *Trudy MAI*, 2016, no. 85.

URL: <http://trudymai.ru/eng/published.php?ID=67495>

2. Gurevich O.S. *Upravlenie aviatsionnymi gazoturbinnymi dvigatelyami* (Aircraft Gas Turbine Engine Control), Moscow, Izd-vo MAI, 2001, 100 p.
3. Inozemtsev A.A., Nikhamkin A.A., Sandratskii V.L. *Osnovy konstruirovaniya aviatsionnykh dvigatelei i energeticheskikh ustanovok* (Fundamentals of Aircraft Engines and Power Plants Design), Moscow, Mashinostroenie, 2008, vol. 2, 368 p.
4. Isaev A.I. Skorobogatov S.V. // *Trudy MAI*, 2018, no. 98. URL: <http://trudymai.ru/eng/published.php?ID=87340>
5. Andrievskaya N.V., Andrievskii O.A., Legotkina T.S., Khizhnyakov Yu.N., Storozhev A.A., Nikulin V.S., Yuzhakov A.A., Kuznetsov M.D. *Mekhatronika. Avtomatizatsiya, Upravlenie*, 2020, vol. 21, no. 6, pp. 348 - 355. DOI: [10.17587/mau.21.348-355](https://doi.org/10.17587/mau.21.348-355)
6. Dmitriev V.G., Munin A.G. *Aerokosmicheskii kur'er*, 2003, no. 2, pp. 15 - 17.
7. Cherepanov F.M., Yasnitskii L.N. *Vestnik Permskogo universiteta. Seriya: Matematika. Mekhanika. Informatika*, 2008, no. 4, pp. 151 - 155.
8. Yasnitskii L.N. *Neirokomp'yutery: razrabotka, primenenie*, 2015, no. 5, pp. 48 – 56.
9. Kallan R. *Osnovnye kontseptsii neironnykh setei* (Basic Concepts of Neural Networks), Moscow, Vil'yams, 2001, 288 p.
10. Devyatkov V.V. *Sistemy iskusstvennogo intellekta* (Artificial Intelligence Systems), Moscow, Mashinostroenie, 1991, 320 p.
11. Gostev V.I. *Proektirovanie nechetkikh regulyatorov dlya sistem avtomaticheskogo upravleniya* (Fuzzy Controllers Design for Automatic Control Systems), Saint Petersburg, BKhV-Peterburg, 2011, 416 p.

12. Osovskii S. *Neironnyye seti dlya obrabotki informatsii* (Neural Networks for Information Processing), Moscow, Finansy i statistika, 2004, 344 p.
13. Khizhnyakov Yu.N. *Nechetkoe, neironnoe i gibridnoe upravlenie* (Fuzzy, Neural and Hybrid Control), Perm', Izd-vo Permskogo natsional'nogo issledovatel'skogo politekhnicheskogo universiteta, 2013, 303 p.
14. Baklanov A.V., Makarova G.F., Vasil'ev A.A., Nuzhdin A.A. *Trudy MAI*, 2018, no. 103. URL: <http://trudymai.ru/eng/published.php?ID=100700>
15. Pegat A. *Nechetkoe modelirovanie i upravlenie* (Fuzzy Modeling and Control), Moscow, BINOM. Laboratoriya znaniy, 2007, 798 p.
16. Mosolov S.V., Sidlerov D.A., Ponomarev A.A. *Trudy MAI*, 2012, no. 59. URL: <http://trudymai.ru/eng/published.php?ID=34989>
17. Leonenkov A.V. *Nechetkoe modelirovanie v srede MATLAB i FuzzyTech* (Fuzzy Modeling in MATLAB and FuzzyTech), Saint Petersburg, BKhV-Peterburg, 2005, 736 p.
18. Yarushkina N.G. *Osnovy teorii nechetkikh i gibridnykh system* (Fundamentals of the Fuzzy and Hybrid Systems Theory), Moscow, Finansy i statistika, 2004, 320 p.
19. Mamdani E.H. Application of Fuzzy Algorithms for the Control of a Simple Dynamic Plant, *Proceedings of the IEEE*, 1974, pp. 121 - 159. DOI: [10.1049/PIEE.1974.0328](https://doi.org/10.1049/PIEE.1974.0328)
20. Nikulin V.S., Storozhev S.A., Abdulin D.M., Khizhnyakov Yu.N. *Trudy MAI*, 2020, no. 116. URL: <http://trudymai.ru/eng/published.php?ID=121086>. DOI: [10.34759/trd-2021-116-1119](https://doi.org/10.34759/trd-2021-116-1119)