

DOI: 10.5862/JCSTCS.252.6

УДК 621.436-55

Е.А. Серикова, С.А. Сериков

НЕЙРОСЕТЕВАЯ АППРОКСИМАЦИЯ ХАРАКТЕРИСТИК ДВИГАТЕЛЯ ВНУТРЕННЕГО СГОРАНИЯ

E.A. Serikova, S.A. Serikov

NEURAL NETWORK APPROXIMATION OF INTERNAL-COMBUSTION ENGINE CHARACTERISTICS

Для создания математических моделей сложных технических объектов наиболее предпочтительным является подход, использующий аппроксимацию экспериментальных данных. В качестве инструмента аппроксимации целесообразно применять системы интеллектуального анализа данных, в частности, системы нечёткого вывода и искусственные нейронные сети (ИНС).

В статье представлены результаты применения ИНС прямого распространения для построения математической модели двигателя внутреннего сгорания. Математическая модель создана путём аппроксимации следующих исходных данных: скоростных характеристик двигателя внутреннего сгорания, показателей экономичности и токсичности отработавших газов. В процессе вычислительных экспериментов исследована зависимость ошибки аппроксимации характеристик двигателя от структуры и параметров модели. Созданная модель позволяет в дальнейшем решать задачи анализа и оптимизации рабочих процессов двигателя на задаваемых тягово-скоростных режимах транспортных средств.

ИСКУССТВЕННАЯ НЕЙРОННАЯ СЕТЬ; ДВИГАТЕЛЬ ВНУТРЕННЕГО СГОРАНИЯ; ИДЕНТИФИКАЦИЯ; ТОПЛИВНАЯ ЭКОНОМИЧНОСТЬ; ТОКСИЧНОСТЬ ОТРАБОТАВШИХ ГАЗОВ.

The most preferable approach to develop mathematical models of complex technical objects is based on experimental data approximation. It is reasonable to use data mining systems, in particular, fuzzy inference systems and artificial neural networks (ANN) as an approximation tool.

The article presents the results of applying a feedforward ANN to developing a mathematical model of an internal combustion engine. The mathematical model is developed through approximating the following basic data: internal combustion engine speed characteristics, efficiency and exhaust toxicity indicators. During computing experiments, the approximation error of the engine characteristics versus the model structure and parameters has been investigated. The developed model allows to solve further problems connected with analysis and optimization of the engine's working processes for specified traction and high-speed modes of vehicles.

ARTIFICIAL NEURAL NETWORK; INTERNAL COMBUSTION ENGINE; IDENTIFICATION; FUEL EFFICIENCY; ENGINE EMISSIONS.

Оптимизация рабочих процессов двигателя внутреннего сгорания (ДВС) оказывает существенное влияние на показатели его топливной экономичности и токсичности отработавших газов (ОГ). Для решения задач анализа и оптимизации рабочих процессов двигателя на задаваемых тягово-скоростных режимах транспортных средств (ТС) ключевой является проблема идентификации его математической модели. При этом предпоч-

тительными оказываются математические модели, полученные в результате аппроксимации экспериментальных характеристик ДВС, которые снимают в процессе стендовых испытаний двигателей.

Анализ публикаций

При аналитическом описании рабочих процессов ДВС возникает противоречие между сложностью такого описания и уров-

нем идеализации модели. При этом математическая модель может оказаться бесполезной с точки зрения решения поставленных задач как при ее излишней сложности, так и в случае пренебрежения существенными взаимосвязями, определяющими характер протекания рабочих процессов.

Математические модели ДВС в виде систем дифференциальных уравнений, полученных на основе анализа термодинамических процессов в камере сгорания, впускном и выпускном коллекторах, особенностей взаимодействия систем смесеобразования и зажигания, кинематических связей между различными узлами и агрегатами и т. д., оказываются чрезвычайно сложными и громоздкими [1, 2]. Линеаризация данных уравнений приводит к существенному возрастанию невязки выходов модели и объекта при необходимости использовать модель в широком диапазоне эксплуатационных режимов ДВС.

Более предпочтительными оказываются математические модели, полученные в результате аппроксимации экспериментальных характеристик ДВС, которые снимают в процессе стендовых испытаний двигателей. В [3] рассмотрены методы автоматической идентификации параметров силового агрегата автомобиля при непосредственном испытании на стенде, что позволяет в реальном масштабе времени получить силовые и кинематические параметры модели. В работах [4, 5] представлена полиномиальная аппроксимация статических характеристик, полученных в результате стендовых испытаний. Данный подход требует большого объема экспериментальных данных, а также делает математическую модель достаточно громоздкой в случае, когда различные участки области допустимых режимов работы двигателя аппроксимируют отдельными полиномами.

В условиях высокой стоимости экспериментальных данных, их ограниченности, высокой зашумленности, неполноты, а часто и противоречивости, эффективными оказываются модели на основе систем нечеткого вывода и искусственных нейронных сетей (ИНС) [6–8]. Использование нечеткой аппроксимации

характеристик ДВС позволяет учитывать априорные слабоформализованные знания о протекающих рабочих процессах и использовать результаты стендовых испытаний для уточнения модели. Достоинствами ИНС является простота автоматизации процесса идентификации модели при описании как статических, так и динамических свойств системы, выборочная чувствительность в областях сосредоточения данных и гладкая интерполяция характеристик в других областях [9, 10]. В настоящее время актуальна разработка формального подхода к нейросетевой аппроксимации характеристик ДВС.

Постановка задачи

Математическая модель ДВС представляет собой некоторый оператор $F : U \mapsto Y$, в соответствии с которым каждому входному вектору

$$\mathbf{u} = \begin{bmatrix} \omega \\ \dot{\omega} \\ \beta \\ \dot{\beta} \end{bmatrix}, \quad \mathbf{u} \in U \subset \mathbb{R}^4, \quad \forall t; \quad (1)$$

$$U = \begin{bmatrix} \omega_{\min} \leq \omega \leq \omega_{\max} \\ \dot{\omega}_{\min} \leq \dot{\omega} \leq \dot{\omega}_{\max} \\ 0 \leq \beta \leq 1 \\ \dot{\beta}_{\min} \leq \dot{\beta} \leq \dot{\beta}_{\max} \end{bmatrix},$$

где ω — скорость вращения коленчатого вала (КВ); β — положение органа управления мощностью; $\dot{\omega} = d\omega/dt$; $\dot{\beta} = d\beta/dt$, ставится в соответствие выходной вектор

$$\mathbf{y} = \begin{bmatrix} M_e \\ G_T \\ C_{NOx} \\ C_{CO} \\ C_{HC} \end{bmatrix}, \quad \mathbf{y} \in Y \subset \mathbb{R}^5, \quad \forall t; \quad (2)$$

$$Y = \begin{bmatrix} M_{e \min} \leq M_e \leq M_{e \max} \\ 0 \leq G_T \leq G_{T \max} \\ 0 \leq C_{NOx} \leq C_{NOx \max} \\ 0 \leq C_{CO} \leq C_{CO \max} \\ 0 \leq C_{HC} \leq C_{HC \max} \end{bmatrix},$$

где M_e – эффективный момент вращения КВ; G_T – часовой расход топлива; C_{NOx} – часовая эмиссия оксидов азота; C_{CO} – часовая эмиссия оксида углерода; C_{HC} – часовая эмиссия углеводородов.

Учитывая, что постоянные времени большинства физико-химических процессов, протекающих в двигателе, малы по сравнению с постоянной времени ТС, ДВС будем считать безынерционным объектом. В этом случае размерность входного вектора можно сократить:

$$\mathbf{u} = \begin{bmatrix} \omega \\ \beta \end{bmatrix}, \quad \mathbf{u} \in U \subset \mathbb{R}_+^2, \quad \forall t; \quad (3)$$

$$U = \left[\begin{array}{l} \omega_{\min} \leq \omega \leq \omega_{\max} \\ 0 \leq \beta \leq 1 \end{array} \right].$$

Оператор модели F должен быть в определенном смысле наилучшим образом приближен к неизвестному оператору объекта F*. Близость операторов будем оценивать исключительно по близости их реакций на одно и то же входное воздействие. Процесс идентификации математической модели заключается в определении структуры Ω оператора F и вектора неизвестных параметров модели P:

$$F = \langle \Omega, C \rangle. \quad (4)$$

Процесс идентификации должен опираться на экспериментально полученные скоростные и нагрузочные характеристики ДВС, обеспечивать простоту настройки модели на конкретный тип двигателя, обладать достаточной помехозащищенностью, являться автоматическим или

автоматизированным.

Идентификация модели ДВС

В настоящее время неизвестны методы нахождения оптимальной структуры ИНС при решении конкретных задач аппроксимации характеристик. Вместе с тем известно, что ИНС с одним скрытым и одним выходным слоем способна аппроксимировать с любой заранее заданной точностью на компактном множестве произвольную непрерывную функцию.

Будем аппроксимировать статические свойства ДВС при помощи иерархической структуры ИНС, реализующих отображения:

$$[\tilde{M}_e, G_T]^T = F_1(\omega, \beta); \quad (5)$$

$$[C_{NOx}, C_{CO}, C_{HC}]^T = F_2(\omega, M_e).$$

Регулировочная характеристика выбранного ДВС, в соответствии с которой происходит ограничение максимальных оборотов КВ при низкой нагрузке, моделируется при помощи зависимости:

$$M_e(\tilde{M}_e, \omega) = \min(\tilde{M}_e, M_{ep}(\omega)); \quad (6)$$

$$M_{ep}(\omega) = k_{p1}\omega + k_{p0},$$

где k_{p0} , k_{p1} – параметры регулировочной характеристики.

Для реализации отображений F_1 и F_2 используются трехслойные ИНС прямого распространения с линейными нейронами в выходном слое. В качестве активационных функций нейронов скрытых слоев выбраны функции гиперболического тангенса:

$$\begin{cases} \mathbf{N}_{11} = 2 : (1 + \exp(-2(\mathbf{W}_{11}[\bar{\omega}, \bar{\beta}]^T + \mathbf{B}_{11}))) - 1 \\ \mathbf{N}_{12} = 2 : (1 + \exp(-2(\mathbf{W}_{12}\mathbf{N}_{11} + \mathbf{B}_{12}))) - 1 \\ [\bar{M}_e, \bar{G}_T]^T = \mathbf{W}_{13}\mathbf{N}_{12} + \mathbf{B}_{13} \end{cases}; \quad (7)$$

$$\begin{cases} \mathbf{N}_{21} = 2 : (1 + \exp(-2(\mathbf{W}_{21}[\bar{\omega}, \bar{M}_e]^T + \mathbf{B}_{21}))) - 1 \\ \mathbf{N}_{22} = 2 : (1 + \exp(-2(\mathbf{W}_{22}\mathbf{N}_{21} + \mathbf{B}_{22}))) - 1 \\ [\bar{C}_{NOx}, \bar{C}_{CO}, \bar{C}_{HC}]^T = \mathbf{W}_{23}\mathbf{N}_{22} + \mathbf{B}_{23} \end{cases}, \quad (8)$$

где \mathbf{N}_{11} , \mathbf{N}_{12} , \mathbf{N}_{21} , \mathbf{N}_{22} – векторы выходов нейронов первого и второго слоев соответственно; \mathbf{W}_{11} , \mathbf{W}_{12} , \mathbf{W}_{13} , \mathbf{W}_{21} , \mathbf{W}_{22} , \mathbf{W}_{23} –

матрицы весовых коэффициентов нейронов; \mathbf{B}_{11} , \mathbf{B}_{12} , \mathbf{B}_{13} , \mathbf{B}_{21} , \mathbf{B}_{22} , \mathbf{B}_{23} – векторы смещений нейронов первого, второго и

третьего слоев соответственно.

Нормирование и денормирование сигналов ИНС F_1 осуществляется согласно выражениям:

$$\begin{aligned} \left[\frac{\bar{\omega}}{\bar{\beta}} \right] &= 2 \left(\left[\frac{\omega}{\beta} \right] - \left[\frac{\min\{\omega\}}{\min\{\beta\}} \right] \right) : \\ &: \left(\left[\frac{\max\{\omega\}}{\max\{\beta\}} \right] - \left[\frac{\min\{\omega\}}{\min\{\beta\}} \right] \right) - 1; \\ \left[\frac{\bar{M}_e}{\bar{G}_T} \right] &= 0,5 \left(\left[\frac{\max\{M_e\}}{\max\{G_T\}} \right] - \left[\frac{\min\{M_e\}}{\min\{G_T\}} \right] \right) * \\ &* \left(\left[\frac{\bar{M}_e}{\bar{G}_T} \right] + \left[\frac{1}{1} \right] \right) + \left[\frac{\min\{M_e\}}{\min\{G_T\}} \right], \end{aligned} \quad (9)$$

где $\min\{\omega\}$, $\min\{\beta\}$, $\max\{\omega\}$, $\max\{\beta\}$, $\min\{M_e\}$, $\min\{G_T\}$, $\max\{M_e\}$, $\max\{G_T\}$ – соответственно минимальные и максимальные значения множеств ω_i , β_i , M_{ei} и G_{Ti} , $i = \overline{1, N_1}$; N_1 – количество точек $\{M_{ei}, \omega_i, \beta_i\}$ и $\{G_{Ti}, \omega_i, \beta_i\}$ экспериментально полученных статических характеристик ДВС, которые используются при обучении ИНС. Знаками «:» и «*» обозначается поэлементное деление и поэлементное умножение векторов соответственно.

Для ИНС F_2 выражения нормирования и денормирования имеют вид:

$$\begin{aligned} \left[\frac{\bar{\omega}}{\bar{M}_e} \right] &= 2 \left(\left[\frac{\omega}{M_e} \right] - \left[\frac{\min\{\omega\}}{\min\{M_e\}} \right] \right) : \\ &: \left(\left[\frac{\max\{\omega\}}{\max\{M_e\}} \right] - \left[\frac{\min\{\omega\}}{\min\{M_e\}} \right] \right) - 1; \\ \left[\begin{matrix} C_{NOx} \\ C_{CO} \\ C_{HC} \end{matrix} \right] &= 0,5 \left(\left[\frac{\max\{C_{NOx}\}}{\max\{C_{CO}\}} \right] - \left[\frac{\min\{C_{NOx}\}}{\min\{C_{CO}\}} \right] \right) * \\ &* \left(\left[\frac{\bar{C}_{NOx}}{\bar{C}_{CO}} \right] + \left[\frac{1}{1} \right] \right) + \left[\frac{\min\{C_{NOx}\}}{\min\{C_{CO}\}} \right], \end{aligned} \quad (11)$$

где $\min\{\omega\}$, $\min\{M_e\}$, $\min\{C_{NOx}\}$, $\min\{C_{CO}\}$, $\min\{C_{HC}\}$, $\max\{\omega\}$, $\max\{M_e\}$, $\max\{C_{NOx}\}$, $\max\{C_{CO}\}$, $\max\{C_{HC}\}$ – соответственно минимальные и максимальные значения множеств ω_j , M_{ej} , C_{NOxj} , C_{COj} и C_{HCj} , $j = \overline{1, N_2}$; N_2 – количество то-

чек $\{C_{NOxj}, \omega_j, M_{ej}\}$, $\{C_{COj}, \omega_j, M_{ej}\}$ и $\{C_{HCj}, \omega_j, M_{ej}\}$ экспериментально полученных характеристик токсичности отработавших газов ДВС, которые используются при обучении ИНС.

Задача структурной идентификации модели ДВС может быть параметризована, т. е. различные структуры могут кодироваться вектором структурных параметров \mathbf{D} :

$$\mathbf{F} = \langle \mathbf{D}, \mathbf{P} \rangle. \quad (13)$$

В данном случае элементами вектора \mathbf{D} является количество нейронов в скрытых слоях ИНС F_1 и F_2 , которое определяет размерности соответствующих матриц весовых коэффициентов и смещений нейронов. В свою очередь элементами вектора \mathbf{P} неизвестных параметров модели являются элементы матриц весовых коэффициентов и смещений нейронов ИНС F_1 и F_2 , а также параметры регуляровочной характеристики k_{p0} и k_{p1} .

Будем считать, что в результате стендовых испытаний ДВС были получены множества точек $\{M_{ei}, \omega_i, \beta_i\}$, $\{G_{Ti}, \omega_i, \beta_i\}$, $i = \overline{1, N_1}$ и $\{C_{NOxj}, \omega_j, M_{ej}\}$, $\{C_{COj}, \omega_j, M_{ej}\}$, $\{C_{HCj}, \omega_j, M_{ej}\}$, $j = \overline{1, N_2}$, которые представляют собой репрезентативную выборку экспериментальных данных и достаточно точно отражают поведение скоростных характеристик ДВС, показателей его экономичности и токсичности ОГ при $\omega \in [\omega_{\min}, \omega_{\max}]$, $\beta \in [0, 1]$.

Если параметры $\mathbf{P}_3 = [k_{p0}, k_{p1}]$ регуляровочной характеристики заданы, идентификация математической модели ДВС сводится к определению структуры и параметров нейронных сетей F_1 и F_2 :

$$\begin{aligned} \langle \mathbf{D}, \mathbf{P} \rangle &= \langle [\mathbf{D}_1, \mathbf{D}_2], [\mathbf{P}_1, \mathbf{P}_2, \mathbf{P}_3] \rangle = \\ &= \begin{cases} \arg \min_{\mathbf{D}_1, \mathbf{P}_1} J_1(\mathbf{D}_1, \mathbf{P}_1) \\ \arg \min_{\mathbf{D}_2, \mathbf{P}_2} J_2(\mathbf{D}_2, \mathbf{P}_2) \end{cases} \end{aligned} \quad (14)$$

где целевые функционалы имеют вид:

$$\begin{aligned} J_1(\mathbf{D}_1, \mathbf{P}_1) &= \frac{1}{N_1} \cdot \sum_{i=1}^{N_1} \psi_1(i, \mathbf{D}_1, \mathbf{P}_1); \\ J_2(\mathbf{D}_2, \mathbf{P}_2) &= \frac{1}{N_2} \cdot \sum_{j=1}^{N_2} \psi_2(j, \mathbf{D}_2, \mathbf{P}_2). \end{aligned} \quad (15)$$

В свою очередь функции невязки выхо-

дов модели и объекта в каждой точке экспериментальных характеристик:

$$\begin{cases} \psi_1(i, \mathbf{D}_1, \mathbf{P}_1) = (M_{ei} - y_{11})^2 + (G_{Ti} - y_{12})^2 \\ [y_{11}, y_{12}]^T = F_1(\omega_i, \beta_i, \mathbf{D}_1, \mathbf{P}_1) \end{cases}; \quad (16)$$

$$\begin{cases} \psi_2(j, \mathbf{D}_2, \mathbf{P}_2) = (C_{NOxj} - y_{21})^2 + \\ + (C_{COj} - y_{22})^2 + (C_{HCj} - y_{23})^2 \\ [y_{21}, y_{22}, y_{23}]^T = F_2(\omega_j, M_{ej}, \mathbf{D}_2, \mathbf{P}_2) \end{cases}. \quad (17)$$

Для решения идентификационной задачи могут использоваться известные методы обучения нейронных сетей [9–12]. Одним из таких методов, который показал свою высокую эффективность при решении рассматриваемой задачи, является алгоритм SCG (Scaled Conjugate Gradient Algorithm), предложенный Моллером (Moller). Этот алгоритм объединяет идеи метода сопряженных градиентов с квазиньютоновыми методами [12].

Экспериментальные исследования

В качестве исходных данных для идентификации математической модели ДВС использовались результаты экспериментальных исследований двигателя MeM3-307 на нагрузочном стенде. Эксплуатационные режимы ДВС были ограничены допустимыми скоростями вращения КВ: $\omega_{\min} = 62,8 \text{ с}^{-1}$, $\omega_{\max} = 732,7 \text{ с}^{-1}$. Приняты следующие параметры регулировочной характеристики $k_{p0} = 0,7643 \cdot \omega_{\max} [\text{Нм}]$, $k_{p1} = -0,7643 \text{ Нм} \cdot \text{с} \cdot \text{рад}^{-1}$. В результате обработки экспериментальных характеристик были получены множества точек $\{M_{ei}, \omega_i, \beta_i\}$, $\{G_{Ti}, \omega_i, \beta_i\}$, $\{C_{NOxj}, \omega_j, M_{ej}\}$, $\{C_{COj}, \omega_j, M_{ej}\}$, $\{C_{HCj}, \omega_j, M_{ej}\}$, $i = \overline{1, N_1}$, $N_1 = 157$, $j = \overline{1, N_2}$, $N_2 = 160$, необходимые для обучения нейронных сетей.

В дальнейшем при обучении ИНС F_1 на этих множествах были выделены обучающее ($N_{V1} = 106$ точек) и контрольное ($N_{V1} = 51$ точка) подмножества. При обучении ИНС F_2 из-за отсутствия избыточности в экспериментальных данных, с точки зрения описания сложных поверхностей характеристик токсичности, контрольное подмножество точек не выделялось. Для предотвращения эффекта переобучения применялось

ограничение длительности обучения сети – 800 эпох. Для обучения нейронных сетей применялся алгоритм SCG.

Качество аппроксимации характеристик ДВС сетью F_1 оценивалось по величине среднеквадратического значения ошибки на контрольном подмножестве точек:

$$\begin{cases} \sigma_{Me} = \left(\frac{1}{N_{V1}} \cdot \sum_{i=1}^{N_{V1}} (M_{ei} - y_{11})^2 \right)^{1/2} \\ \sigma_{GT} = \left(\frac{1}{N_{V1}} \cdot \sum_{i=1}^{N_{V1}} (G_{Ti} - y_{12})^2 \right)^{1/2} \\ [y_{11}, y_{12}]^T = F_1(\omega_i, \beta_i, \mathbf{D}_1, \mathbf{P}_1) \end{cases}, \quad (18)$$

$$i = \overline{1, N_{V1}}.$$

Качество аппроксимации характеристик токсичности ОГ ДВС нейронной сетью F_2 оценивалось по величине среднеквадратического значения ошибки на обучающем множестве точек:

$$\begin{cases} \sigma_{NOx} = \left(\frac{1}{N_2} \cdot \sum_{j=1}^{N_2} (C_{NOxj} - y_{21})^2 \right)^{1/2} \\ \sigma_{CO} = \left(\frac{1}{N_2} \cdot \sum_{j=1}^{N_2} (C_{COj} - y_{22})^2 \right)^{1/2} \\ \sigma_{HC} = \left(\frac{1}{N_2} \cdot \sum_{j=1}^{N_2} (C_{HCj} - y_{23})^2 \right)^{1/2} \\ [y_{21}, y_{22}, y_{23}]^T = F_2(\omega_j, M_{ej}, \mathbf{D}_2, \mathbf{P}_2) \end{cases}, \quad (19)$$

$$j = \overline{1, N_2}.$$

Результаты обучения ИНС показывают, что качество аппроксимации характеристик ДВС существенно зависит от общего количества нейронов и лишь незначительно – от их распределения по слоям. Следовательно, структуры сетей F_1 и F_2 с достаточной точностью можно характеризовать только одним параметром – числом синаптических весов (количеством свободных параметров нейронной сети):

$$k_{F1} = 3k_{11} + (k_{11} + 1)k_{12} + 2(k_{12} + 1); \quad (20)$$

$$k_{F2} = 3k_{21} + (k_{21} + 1)k_{22} + 3(k_{22} + 1), \quad (21)$$

где k_{11} , k_{12} , k_{21} и k_{22} – количество нейронов в скрытых слоях ИНС.

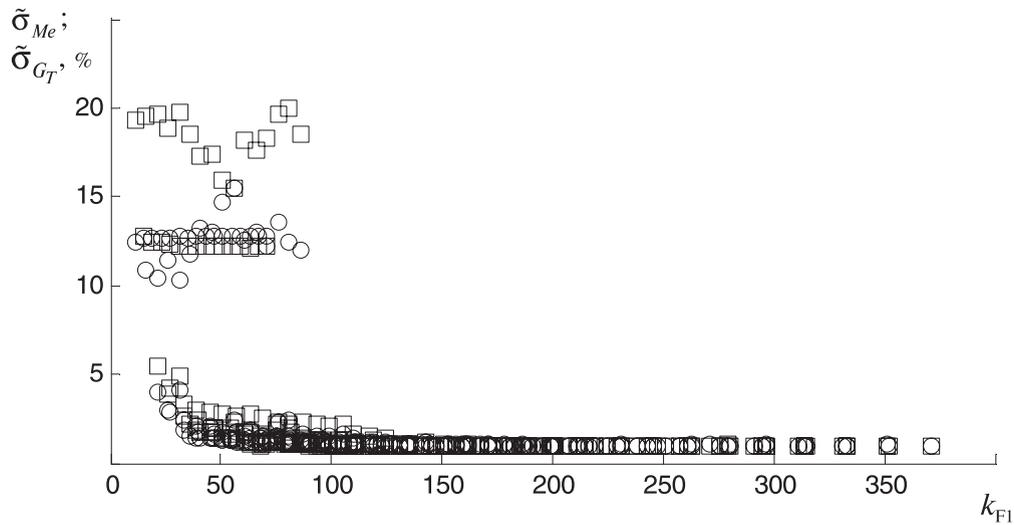


Рис. 1. Зависимость ошибки ИНС, реализующей отображение F_1 , от количества свободных параметров сети k_{F1}
 (□) — $\tilde{\sigma}_{Me}$; (○) — $\tilde{\sigma}_{G_T}$

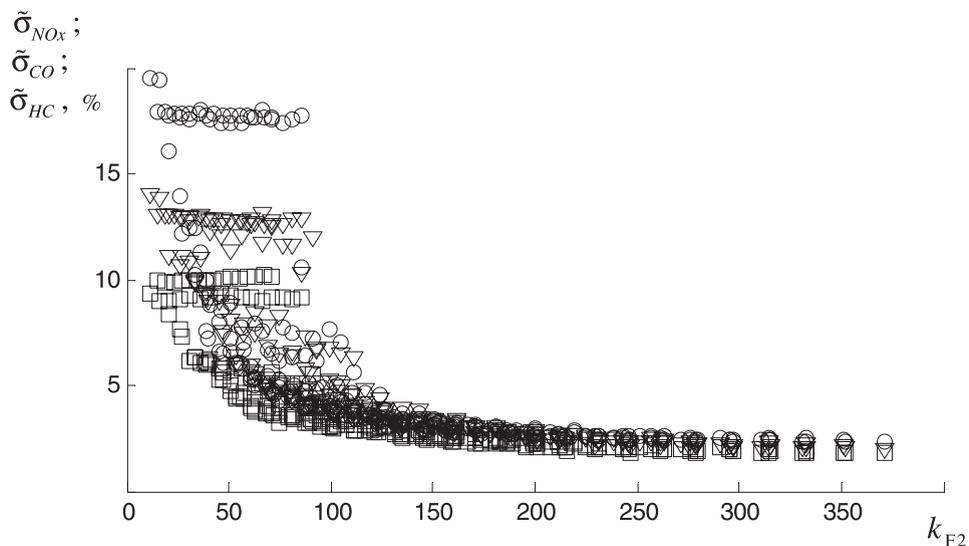


Рис. 2. Зависимость ошибки ИНС, реализующей отображение F_2 , от количества свободных параметров сети
 (□) — $\tilde{\sigma}_{NOx}$; (○) — $\tilde{\sigma}_{CO}$; (▽) — $\tilde{\sigma}_{HC}$

На рис. 1 приведены зависимости $\tilde{\sigma}_{Me}$ и $\tilde{\sigma}_{G_T}$ от количества свободных параметров нейронной сети F_1 .

На рис. 2 приведены зависимости среднеквадратических ошибок показателей токсичности ОГ от количества свободных параметров нейронной сети F_2 .

Каждая точка данных зависимостей была получена путем усреднения резуль-

татов десяти экспериментов по обучению нейронных сетей при случайных начальных значениях элементов матриц весовых коэффициентов и векторов смещений нейронов.

Для удобства сравнения среднеквадратические значения ошибок выражены в процентах от максимальных значений соответствующих величин:

$$\tilde{\sigma}_{M_e} = \frac{\sigma_{M_e}}{\max\{M_e\}} \cdot 100 \%;$$

$$\tilde{\sigma}_{G_T} = \frac{\sigma_{G_T}}{\max\{G_T\}} \cdot 100 \%.$$

$$\tilde{\sigma}_{NOx} = \frac{\sigma_{NOx}}{\max\{C_{NOx}\}} \cdot 100 \%;$$

$$\tilde{\sigma}_{CO} = \frac{\sigma_{CO}}{\max\{C_{CO}\}} \cdot 100 \%;$$

$$\tilde{\sigma}_{HC} = \frac{\sigma_{HC}}{\max\{C_{HC}\}} \cdot 100 \%.$$

Анализируя поведение среднеквадратической ошибки при изменении количества свободных параметров нейронной сети F_1 , выберем количество нейронов в первом скрытом слое $k_{11} = 8$, количество нейронов во втором скрытом слое $k_{12} = 4$. Данной структуре соответствует количество свободных параметров $k_{F1} = 70$. Такая нейронная сеть имеет наименьшую сложность, при которой еще можно добиться наименьшей ошибки аппроксимации. Для ИНС F_2

аналогичным образом получим значения $k_{21} = 8$, $k_{22} = 8$, что соответствует величине $k_{F2} = 123$.

Математические ожидания и среднеквадратические отклонения ошибок ИНС F_1 выбранной структуры для контрольного подмножества составили: $M\{M_e\} = 0,061313$ Нм, $M\{G_T\} = 0,00062177$ кг/ч; $\sigma_{M_e} = 0,93371$ Нм, $\sigma_{G_T} = 0,13093$ кг/ч.

Соответствующие параметры ошибок ИНС F_2 , полученные на обучающем подмножестве точек, составили: $M\{C_{NOx}\} = 3,4669 \cdot 10^{-5}$ г/ч, $M\{C_{CO}\} = 1,2362 \cdot 10^{-5}$ г/ч, $M\{C_{HC}\} = 3,1023e \cdot 10^{-6}$ г/ч; $\sigma_{NOx} = 0,0046963$ г/ч, $\sigma_{CO} = 0,0013966$ г/ч, $\sigma_{HC} = 0,00066031$ г/ч.

Учитывая, что удельный эффективный расход топлива $g_e = G_T \cdot M_e^{-1} \cdot \omega^{-1}$, на основании аппроксимации скоростных характеристик ДВС нейронной сетью можно получить зависимости $g_e = f(n_{KV}, \beta)$ и $g_e = f(M_e, \beta)$, которые приведены на рис. 3 и рис. 4 соответственно. Здесь для удобства сравнения результатов моделирования

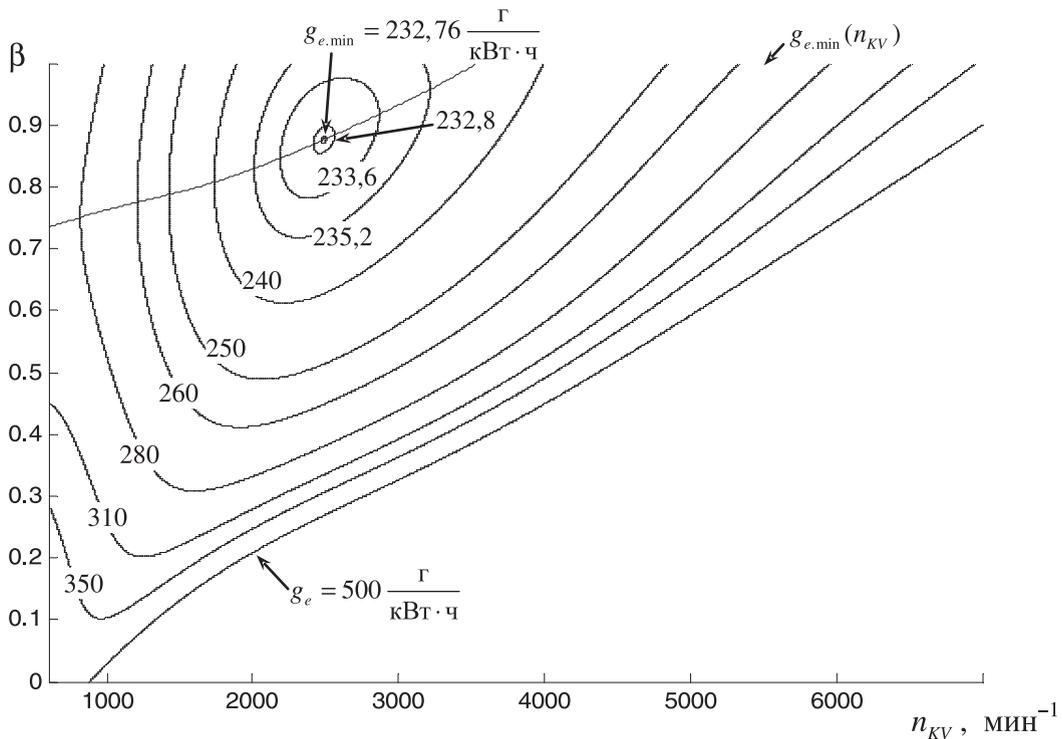


Рис. 3. Зависимость удельного эффективного расхода топлива ДВС от сигнала управления мощностью и скорости вращения КВ

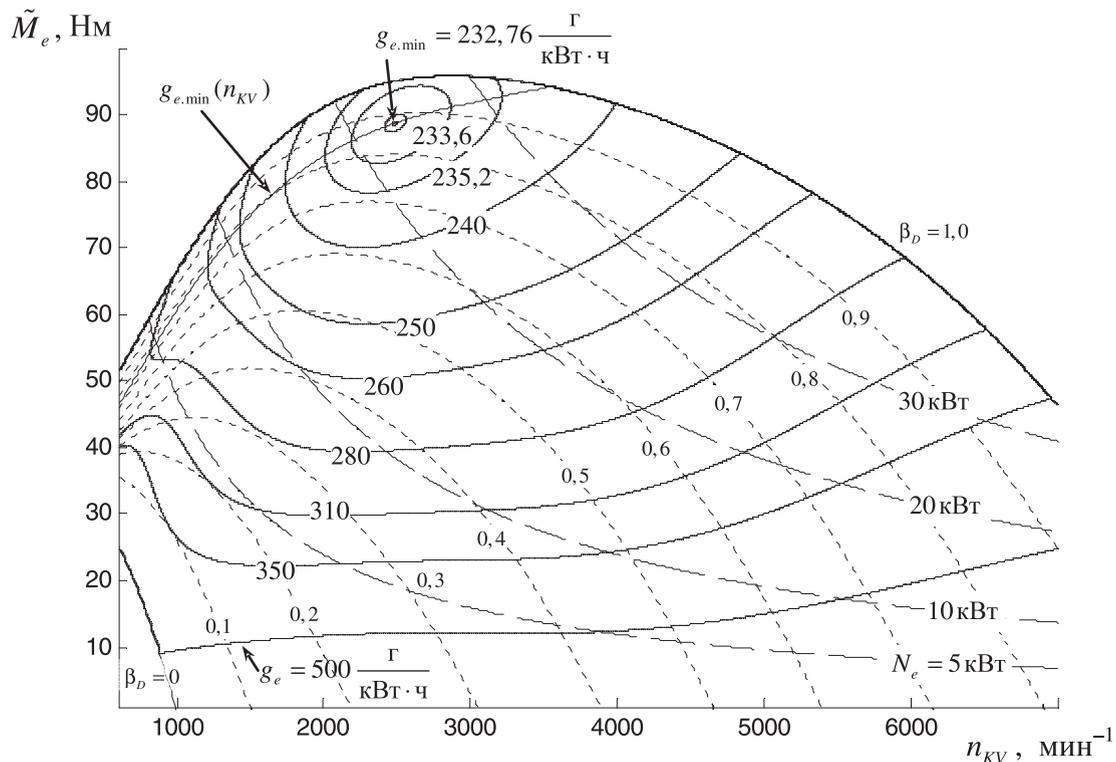


Рис. 4. Зависимость удельного эффективного расхода топлива ДВС от эффективного крутящего момента и скорости вращения КВ

с экспериментальными данными по оси абсцисс отложена частота вращения КВ в мин^{-1} : $n_{KV} = 30 \cdot \omega / \pi$.

Как видно из приведенных многопараметрических характеристик, высокие показатели экономичности работы ДВС могут быть обеспечены только в достаточно узком диапазоне нагрузок и частот вращения КВ. Оптимальный режим работы ДВС соответствует скорости вращения КВ $\omega = 260,62 \text{ рад/с}$ ($n_{KV} = 2490 \text{ мин}^{-1}$) и эффективному крутящему моменту $\tilde{M}_e = 88,94 \text{ Нм}$ ($\beta = 0,88$). При этом удельный эффективный расход топлива составляет $g_{e,\text{min}} = 232,76 \text{ г/кВт}^{-1} \cdot \text{ч}^{-1}$.

Использование для согласования режима работы ДВС и тягово-скоростного режима ТС трансмиссии с переменным передаточным отношением от КВ к ведущим колесам оказывается неэффективным при малой мощности сопротивления движению. Так, при $N_e = M_e \cdot \omega = 10 \text{ кВт}$, минималь-

ный удельный эффективный расход топлива при оптимальной скорости вращения КВ составляет около $g_e = 254 \text{ г/кВт}^{-1} \cdot \text{ч}^{-1}$, что на 9,1 % выше минимального эффективного расхода. При $N_e = 5 \text{ кВт}$ увеличение эффективного расхода топлива на оптимальном скоростном режиме по сравнению с $g_{e,\text{min}}$ составит уже 20,3 %.

Получена математическая модель двигателя внутреннего сгорания на основе аппроксимации его скоростных характеристик и показателей токсичности отработавших газов при помощи искусственных нейронных сетей прямого распространения.

Достоинствами предложенного подхода можно считать простоту настройки модели на конкретный тип двигателя при использовании экспериментально полученных скоростных или нагрузочных характеристик, невысокий уровень сложности с точ-

ки зрения ее использования при решении оптимизационных задач. Математические преобразования, используемые при построении модели, допускают эффективную реализацию средствами системы компьютерной математики MATLAB.

Предложенная математическая модель

может использоваться при разработке систем автоматического управления ДВС и силовых установок гибридных автомобилей, обеспечивающих оптимизацию рабочих процессов двигателя, повышение его топливной экономичности и экологической безопасности.

СПИСОК ЛИТЕРАТУРЫ

1. **Чесноков С.А., Фролов Н.Н., Дунаев В.А., Кузьмина И.В.** Моделирование горения и образования токсичных веществ в ДВС с непосредственным впрыском топлива // *Двигателестроение*. 2005. № 2 (220). С. 12–28.

2. **Вырубов Д.Н., Иващенко Н.А., Ивин В.И. и др.** Двигатели внутреннего сгорания: Теория поршневых и комбинированных двигателей. 4-е изд., перераб. и доп. М.: Машиностроение, 1983. 372 с.

3. **Науменко Б.С., Саватеев Р.И.** Методы автоматической идентификации информационных параметров силового агрегата автомобиля при испытании на стенде // *Сб. науч. трудов СевКавГТУ*. 2007. № 3. С. 45–47.

4. **Лепешкин А.В., Курмаев Р.Х., Катанаев Н.К.** Идентификация работы двигателя самоходной машины для использования в математической модели ее движения (на примере двигателя DT466) // *Известия МГТУ «МАМИ»*. 2007. № 2(4). С. 68–73.

5. **Куделин О.Г., Лебедев О.Н.** Решение уравнения вихревого движения вязкости газа в цилиндре ДВС в аналитическом виде // *Теплофизика и аэродинамика*. Новосибирск: НГАВТ, 2005. Т. 12. № 4. С. 609–614.

6. **Сериков С.А., Дзюбенко А.А.** Идентификация математической модели двигателя вну-

треннего сгорания с использованием системы нечеткого вывода // *Двигатели внутреннего сгорания*. Харьков: НТУ «ХПИ», 2009. № 1. С. 14–18.

7. **Rajagopalan A., Washington G., Rizzoni G., Guezennec Y.** Development of Fuzzy Logic and Neural Network Control and Advance Emissions Modeling for Parallel Hybrid Vehicles. Center for Automotive Research. The Ohio State University Columbus, Ohio. Subcontract Report. Dec. 2003.

8. **Сериков С.А.** Оптимизация управления перераспределением мощности между агрегатами гибридной силовой установки // *Автоматика-2008: XV Междунар. конф. по автоматическому управлению*. Одесса: ОНМА, 2008. С. 525–528.

9. Методы робастного, нейро-нечеткого и адаптивного управления. Под ред. Н.Д. Егупова. Изд. 2-е, стереотип. М.: Изд-во МГТУ им. Н.Э. Баумана, 2002. 744 с.

10. **Руденко О.Г., Бодянский Е.В.** Искусственные нейронные сети. Харьков: ООО «Компания «СМИТ», 2005. 408 с.

11. **Хайкин С.** Нейронные сети: полный курс. 2-е изд. Пер. с англ. М.: ИД «Вильямс», 2006. 1104 с.

12. **Медведев В.С., Потемкин В.Г.** Нейронные сети. MATLAB 6. М.: Диалог-МИФИ, 2002. 496 с.

REFERENCES

1. **Chesnokov S.A., Frolov N.N., Dunayev V.A., Kuzmina I.V.** Modelirovaniye goreniya i obrazovaniya toksichnykh veshchestv v DVS s neposredstvennym vpryskom topliva [Imitation of Combustion Process and Generation of Toxic Exhaust Components in Engines with Direct Fuel Injection]. *Dvigatelistroyeniye [Engines construction]*, 2005, No. 2 (220), Pp. 12–28. (rus)

2. **Vyubov D.N., Ivashchenko N.A., Ivin V.I., et al.** *Dvigateli vnutrennego sgoraniya: Teoriya porshnevnykh i kombinirovannykh dvigateley [Internal combustion engines: theory and combined piston engines]*. Moscow: Mashinostroyeniye Publ., 1983, 372 p. (rus)

3. **Naumenko B.S., Savateyev R.I.** Metody

avtomaticheskoy identifikatsii informatsionnykh parametrov silovogo agregata avtomobilya pri ispytanii na stende [Automatic identification information parameters of the power unit of the car during the test on the stand]. *Sbornik nauchnykh трудов SevKavGTU*, 2007, No 3, Pp. 45–47. (rus)

4. **Lepeshkin A.V., Kurmayev R.Kh., Katanayev N.K.** Identifikatsiya raboty dvigatelya samokhodnoy mashiny dlya ispolzovaniya v matematicheskoy modeli yeye dvizheniya (na primere dvigatelya DT466) [Identification of engine-propelled machines for use in the mathematical model of its motion (for example, DT466 engine)]. *Izvestiya MGTU «MAMI»*, 2007, No. 2(4), Pp. 68–73. (rus)

5. **Kudelin O.G., Lebedev O.N.** Resheniye



uravneniya vikhrevogo dvizheniya vyazkosti gaza v tsilindre DVS v analiticheskom vide [Analytic-form solution of the equation for vortex motion of viscous gas in the ice cylinder]. *Teplofizika i aerodinamika* [Thermophysics and Aeromechanics], Novosibirsk: NGAVT Publ., 2005, Vol. 12, No. 4, Pp. 609–614. (rus)

6. **Serikov S.A., Dzyubenko A.A.** Identifikatsiya matematicheskoy modeli dvigatelya vnutrennego sgoraniya s ispolzovaniyem sistemy nechetkogo vyvoda [The identification of the mathematical model of the internal combustion engine using a fuzzy inference system]. *Dvigateli vnutrennego sgoraniya*, Kharkov: NTU «KhPI» Publ., 2009, No. 1, Pp. 14–18. (rus)

7. **Rajagopalan A., Washington G., Rizzoni G., Guezennec Y.** *Development of Fuzzy Logic and Neural Network Control and Advance Emissions Modeling for Parallel Hybrid Vehicles*. Center for Automotive Research, the Ohio State University Columbus, Ohio. Subcontract Report, Dec. 2003.

8. **Serikov S.A.** Optimizatsiya upravleniya

pereraspredeleniyem moshchnosti mezhdu agregatami gibridnoy silovoy ustanovki ustanovki [Redistribution of power management optimization between units of the hybrid power plant]. *Avtomatika-2008: XV Mezhdunar. konf. po avtomaticheskomu upravleniyu* [Automation 2008: The XV International Conference on Automatic Control], Odessa: ONMA, 2008, Pp. 525–528. (rus)

9. **Yegupov N.D. ed.** *Metody robastnogo, neyro-nechetkogo i adaptivnogo upravleniya* [Methods of robust, neuro-fuzzy and adaptive control]. Moscow: MGTU im. N.E. Baumana Publ., 2002, 744 p. (rus)

10. **Rudenko O.G., Bodyanskiy Ye.V.** *Iskusstvennyye neyronnyye seti* [Artificial neural networks]. Kharkov: ООО «Компания «СМИТ» Publ., 2005, 408 p. (rus)

11. **Khaykin S.** *Neyronnyye seti: polnyy kurs* [Neural networks: a complete course]. Moscow: ID «Vilyams» Publ., 2006, 1104 p. (rus)

12. **Medvedev V.S., Potemkin V.G.** *Neyronnyye seti. MATLAB 6* [Neural networks. MATLAB 6]. Moscow: Dialog-MIFI Publ., 2002, 496 p. (rus)

СЕРИКОВА Елена Андреевна — доцент кафедры «Автоматы» Института металлургии, машиностроения и транспорта Санкт-Петербургского политехнического университета Петра Великого, кандидат технических наук.

195251, Россия, Санкт-Петербург, ул. Политехническая, д. 29.

E-mail: wdv08@inbox.ru

SERIKOVA Elena A. *Peter the Great St. Petersburg Polytechnic University.*

195251, Politekhnikeskaya Str. 29, St. Petersburg, Russia.

E-mail: wdv08@inbox.ru

СЕРИКОВ Сергей Анатольевич — профессор кафедры мехатроники и робототехники Института металлургии, машиностроения и транспорта Санкт-Петербургского политехнического университета Петра Великого, доктор технических наук.

195251, Россия, Санкт-Петербург, ул. Политехническая, д. 29.

E-mail: srkv@inbox.ru

SERIKOV Sergey A. *Peter the Great St. Petersburg Polytechnic University.*

195251, Politekhnikeskaya Str. 29, St. Petersburg, Russia.

E-mail: srkv@inbox.ru