

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ДВИГАТЕЛЯ ВНУТРЕННЕГО СГОРАНИЯ

Ключевые слова: *искусственная нейронная сеть, двигатель внутреннего сгорания, идентификация, топливная экономичность, токсичность отработанных газов.*

ВВЕДЕНИЕ

Повышение экономичности и экологической безопасности — основные направления совершенствования транспортных средств (ТС). Определяющее влияние на показатели топливной экономичности и токсичности отработавших газов (ОГ) оказывают особенности рабочих процессов двигателя внутреннего сгорания (ДВС), который остается наиболее распространенной силовой установкой для ТС, движущихся без внешнего подвода энергии. Для решения задач анализа и оптимизации рабочих процессов двигателя на задаваемых тягово-скоростных режимах ТС ключевой является проблема идентификации математической модели ДВС.

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 использования модели в широком диапазоне эксплуатационных режимов ДВС.

Математические модели в виде рядов Вольтерра не нашли широкого распространения при анализе режимов ДВС. Это связано с большим объемом дорогих экспериментальных исследований для определения ядер Вольтерра.

Более предпочтительными оказываются математические модели, полученные в результате аппроксимации экспериментальных характеристик ДВС, которые снижают в процессе стендовых испытаний двигателей. Наиболее широко используется полиномиальная аппроксимация статических характеристик. При этом различные участки областей допустимых режимов работы двигателя аппроксимируют отдельными полиномами, что делает математическую модель достаточно громоздкой [3].

В условиях высокой стоимости экспериментальных данных, их ограниченного количества, высокой зашумленности, неполноте, а часто и противоречивости наилучшими оказываются модели на основе искусственных нейронных сетей (ИНС). Они выборочно чувствительны в областях сосредоточения данных и дают гладкую интерполяцию в других областях [4, 5].

ПОСТАНОВКА ЗАДАЧИ

Под математической моделью ДВС будем понимать некоторый оператор $F: U \mapsto Y$, в соответствии с которым каждому входному вектору

$$\mathbf{u} = \begin{bmatrix} \omega \\ \dot{\omega} \\ \beta \\ \dot{\beta} \end{bmatrix}, \quad \mathbf{u} \in U \subset \mathbb{R}^4, \quad \forall t; \quad U = \begin{bmatrix} \omega_{\min} \leq \omega \leq \omega_{\max} \\ \dot{\omega}_{\min} \leq \dot{\omega} \leq \dot{\omega}_{\max} \\ 0 \leq \beta \leq 1 \\ \dot{\beta}_{\min} \leq \dot{\beta} \leq \dot{\beta}_{\max} \end{bmatrix}, \quad (1)$$

где ω — скорость вращения КВ; β — положение органа управления мощностью;

© С.А. Сериков, 2010

$\dot{\omega} = d\omega / dt$; $\dot{\beta} = d\beta / dt$, ставится в соответствие выходной вектор

$$\mathbf{y} = \begin{bmatrix} M_e \\ G_T \\ C_{NOx} \\ C_{CO} \\ C_{HC} \end{bmatrix}, \quad \mathbf{y} \in \mathbf{Y} \subset \mathbb{R}^5, \quad \forall t; \quad \mathbf{Y} = \begin{bmatrix} M_{e \min} \leq M_e \leq M_{e \max} \\ 0 \leq G_T \leq G_{T \max} \\ 0 \leq C_{NOx} \leq C_{NOx \max} \\ 0 \leq C_{CO} \leq C_{CO \max} \\ 0 \leq C_{HC} \leq C_{HC \max} \end{bmatrix}, \quad (2)$$

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, т.е.

$$\mathbf{y} = F(\mathbf{u}). \quad (3)$$

При этом 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 \mathbf{P} :

$$F = \langle \Omega, \mathbf{P} \rangle. \quad (4)$$

Уровень сложности модели должен быть приемлемым с точки зрения ее использования для поиска оптимального управления. Поскольку постоянные времени большинства физико-химических процессов, протекающих в двигателе, малы по сравнению с постоянной времени ТС, ДВС будем считать безынерционным объектом. Размерность входного вектора статической модели сокращается:

$$\mathbf{u} = \begin{bmatrix} \omega \\ \beta \end{bmatrix}, \quad \mathbf{u} \in \tilde{\mathbf{U}} \subset \mathbb{R}_+^2, \quad \forall t; \quad \tilde{\mathbf{U}} = \begin{bmatrix} \omega_{\min} \leq \omega \leq \omega_{\max} \\ 0 \leq \beta \leq 1 \end{bmatrix}. \quad (5)$$

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

СТРУКТУРНАЯ ИДЕНТИФИКАЦИЯ МОДЕЛИ ДВС

Построение нейросетевой модели ДВС представляет собой способ нелинейного преобразования в виде композиции многомерных линейных и одномерных нелинейных преобразований. При этом методы нахождения оптимальной структуры ИНС сегодня неизвестны. Исследователями было установлено, что ИНС с одним скрытым и одним выходным слоем способна аппроксимировать с любой наперед заданной точностью на компактном множестве произвольную непрерывную функцию. Тем не менее из данных исследований не следует, что один скрытый слой является оптимальным в смысле времени обучения, простоты реализации и качества обобщения [6, 7].

Будем аппроксимировать статические свойства ДВС с помощью трехслойных ИНС прямого распространения с линейными нейронами в выходном слое. В качестве активационных функций нейронов скрытых слоев будем использовать функцию гиперболического тангенса

$$f(s) = th(s) = \frac{2}{1 + e^{-2s}} - 1. \quad (6)$$

Схема модели ДВС, в которой оператор F представлен в виде композиции трех операторов F_1, F_2, F_3 , приведена на рис. 1.

Отображение $[\tilde{M}_e, G_T]^T = F_1(\omega, \beta)$ реализуется посредством ИНС, схема которой приведена на рис. 2.

Нормирование входного вектора ИНС F_1 , которое приводит входные сигналы к диапазону $[-1, 1]$, осуществляется согласно выражению

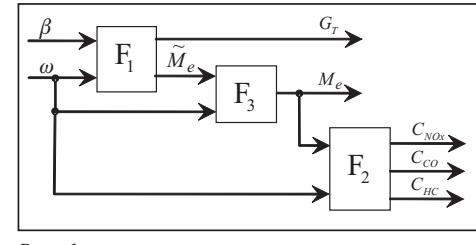


Рис. 1

$$\begin{bmatrix} \bar{\omega} \\ \bar{\beta} \end{bmatrix} = 2 \left(\begin{bmatrix} \omega \\ \beta \end{bmatrix} - \begin{bmatrix} \min\{\omega\} \\ \min\{\beta\} \end{bmatrix} \right) : \left(\begin{bmatrix} \max\{\omega\} \\ \max\{\beta\} \end{bmatrix} - \begin{bmatrix} \min\{\omega\} \\ \min\{\beta\} \end{bmatrix} \right) - 1, \quad (7)$$

где $\min\{\omega\}$, $\min\{\beta\}$, $\max\{\omega\}$, $\max\{\beta\}$ — соответственно минимальные и максимальные значения множеств ω_i и β_i , $i = \overline{1, N_1}$; 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. Знак « $:$ » обозначает поэлементное деление векторов.

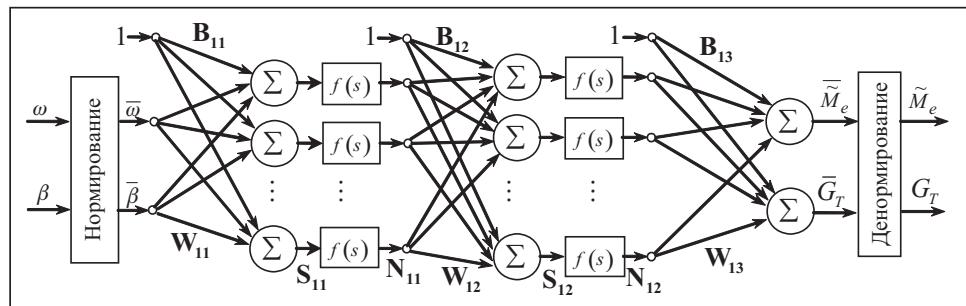


Рис. 2

Функционирование нейронной сети F_1 описывается выражениями

$$\begin{cases} \mathbf{N}_{11} = 2:(1+\exp(-2 \cdot (\mathbf{W}_{11} \cdot [\bar{\omega}, \bar{\beta}]^T + \mathbf{B}_{11}))) - 1, \\ \mathbf{N}_{12} = 2:(1+\exp(-2 \cdot (\mathbf{W}_{12} \cdot \mathbf{N}_{11} + \mathbf{B}_{12}))) - 1, \\ [\tilde{M}_e, \tilde{G}_T]^T = \mathbf{W}_{13} \cdot \mathbf{N}_{12} + \mathbf{B}_{13}, \end{cases} \quad (8)$$

где \mathbf{N}_{11} , \mathbf{N}_{12} — векторы выходов нейронов первого и второго слоев соответственно; \mathbf{W}_{11} , \mathbf{W}_{12} , \mathbf{W}_{13} — матрицы весовых коэффициентов нейронов; \mathbf{B}_{11} , \mathbf{B}_{12} , \mathbf{B}_{13} — векторы смещений нейронов первого, второго и третьего слоев соответственно.

Денормирование выходного сигнала нейронной сети осуществляется согласно выражению

$$\begin{bmatrix} \tilde{M}_e \\ G_T \end{bmatrix} = 0,5 \left(\begin{bmatrix} \max\{M_e\} \\ \max\{G_T\} \end{bmatrix} - \begin{bmatrix} \min\{M_e\} \\ \min\{G_T\} \end{bmatrix} \right) * \left(\begin{bmatrix} \tilde{M}_e \\ \tilde{G}_T \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \end{bmatrix} \right) + \begin{bmatrix} \min\{M_e\} \\ \min\{G_T\} \end{bmatrix}, \quad (9)$$

где $\min\{M_e\}$, $\min\{G_T\}$, $\max\{M_e\}$, $\max\{G_T\}$ — соответственно минимальные и максимальные значения множеств M_{ei} и G_{Ti} , $i = \overline{1, N_1}$. Знак « $*$ » обозначает поэлементное умножение векторов.

Отображение $[C_{NOx}, C_{CO}, C_{HC}]^T = F_2(\omega, M_e)$ реализуется посредством ИНС, структурная схема которой приведена на рис. 3.

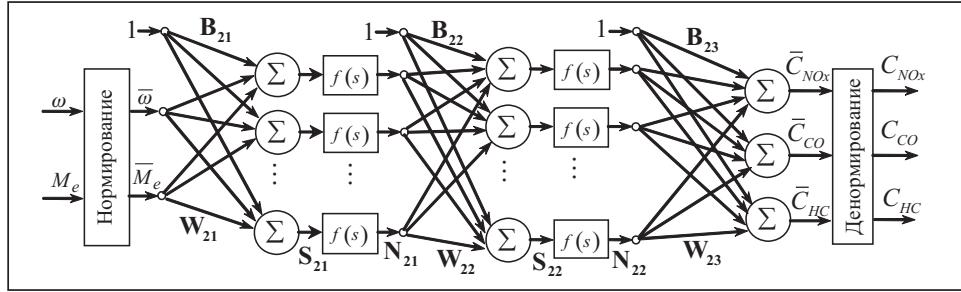


Рис. 3

Нормирование, денормирование сигналов и функционирование нейронной сети F_2 описывается выражениями:

$$\left[\frac{\bar{\omega}}{M_e} \right] = 2 \left(\left[\frac{\omega}{M_e} \right] - \left[\min \{M_e\} \right] \right) : \left(\left[\frac{\max \{\omega\}}{\max \{M_e\}} \right] - \left[\min \{M_e\} \right] \right) - 1, \quad (10)$$

$$\begin{cases} N_{21} = 2 \cdot (1 + \exp(-2 \cdot (\mathbf{W}_{21} \cdot [\bar{\omega}, \bar{M}_e]^T + \mathbf{B}_{21}))) - 1, \\ N_{22} = 2 \cdot (1 + \exp(-2 \cdot (\mathbf{W}_{22} \cdot N_{21} + \mathbf{B}_{22}))) - 1, \\ [\bar{C}_{NOx}, \bar{C}_{CO}, \bar{C}_{HC}]^T = \mathbf{W}_{23} \cdot N_{22} + \mathbf{B}_{23}, \end{cases} \quad (11)$$

$$\begin{bmatrix} C_{NOx} \\ C_{CO} \\ C_{HC} \end{bmatrix} = 0,5 \left(\begin{bmatrix} \max \{C_{NOx}\} \\ \max \{C_{CO}\} \\ \max \{C_{HC}\} \end{bmatrix} - \begin{bmatrix} \min \{C_{NOx}\} \\ \min \{C_{CO}\} \\ \min \{C_{HC}\} \end{bmatrix} \right) * \begin{bmatrix} \bar{C}_{NOx} \\ \bar{C}_{CO} \\ \bar{C}_{HC} \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} + \begin{bmatrix} \min \{C_{NOx}\} \\ \min \{C_{CO}\} \\ \min \{C_{HC}\} \end{bmatrix}, \quad (12)$$

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} , $j=1, N_2$; N_2 — количество точек $\{C_{NOxj}, \omega_j, M_{ej}\}$, $\{C_{COj}, \omega_j, M_{ej}\}$ и $\{C_{HCj}, \omega_j, M_{ej}\}$ экспериментально полученных характеристик токсичности отработавших газов ДВС, которые используются при обучении ИНС; N_{21} , N_{22} — векторы выходов нейронов; \mathbf{W}_{21} , \mathbf{W}_{22} , \mathbf{W}_{23} — матрицы весовых коэффициентов; \mathbf{B}_{21} , \mathbf{B}_{22} , \mathbf{B}_{23} — векторы смещений нейронов первого, второго и третьего слоев соответственно.

Регулировочная характеристика выбранного ДВС, в соответствии с которой происходит ограничение максимальных оборотов КВ при низкой нагрузке, моделируется с помощью отображения F_3 :

$$M_e(\tilde{M}_e, \omega) = \min(\tilde{M}_e, M_{ep}(\omega)), \quad (13)$$

$$M_{ep}(\omega) = k_{p1} \cdot \omega + k_{p0}, \quad (14)$$

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

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

$$F = \langle \mathbf{D}, \mathbf{P} \rangle. \quad (15)$$

В данном случае элементами вектора \mathbf{D} являются количества нейронов в скрытых слоях ИНС F_1 и F_2 , которые определяют размерности соответствующих матриц весовых коэффициентов и смещений нейронов. В свою очередь, элементами вектора \mathbf{P} неизвестных параметров модели являются элементы матриц весовых ко-

эффициентов и смещений нейронов ИНС F_1 и F_2 , а также параметры регулировочной характеристики k_{p0} и k_{p1} .

ПАРАМЕТРИЧЕСКАЯ ИДЕНТИФИКАЦИЯ МОДЕЛИ ДВС

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

Для нейронной сети $F_1 = \langle \mathbf{D}_1, \mathbf{P}_1 \rangle$ функция невязки выходов модели и объекта ψ_1 в i -й точке экспериментальных характеристик может быть определена следующим образом:

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

Задача параметрической идентификации нейронной сети F_1 сводится к задаче поиска минимума целевого функционала вида

$$J_1(\mathbf{D}_1, \mathbf{P}_1) = \frac{1}{N_1} \cdot \sum_{i=1}^{N_1} \psi_1(i, \mathbf{D}_1, \mathbf{P}_1) \rightarrow \min. \quad (17)$$

Для нейронной сети F_2 соответственно можно записать:

$$\begin{cases} \psi_2(j, \mathbf{D}_2, \mathbf{P}_2) = (C_{NOxj} - y_{21})^2 + (C_{COj} - y_{22})^2 + (C_{HCj} - y_{23})^2, \\ [y_{21}, y_{22}, y_{23}]^T = F_2(\omega_j, M_{ej}, \mathbf{D}_2, \mathbf{P}_2), \end{cases} \quad (18)$$

$$J_2(\mathbf{D}_2, \mathbf{P}_2) = \frac{1}{N_2} \sum_{j=1}^{N_2} \psi_2(j, \mathbf{D}_2, \mathbf{P}_2) \rightarrow \min. \quad (19)$$

Если параметры $\mathbf{P}_3 = [k_{p0}, k_{p1}]$ регулировочной характеристики F_3 заданы, идентификация математической модели ДВС сводится к определению структуры и параметров нейронных сетей F_1 и F_2 :

$$\langle \mathbf{D}, \mathbf{P} \rangle = \langle [\mathbf{D}_1, \mathbf{D}_2], [\mathbf{P}_1, \mathbf{P}_2, \mathbf{P}_3] \rangle = \begin{cases} \arg \min_{\mathbf{D}_1, \mathbf{P}_1} J_1(\mathbf{D}_1, \mathbf{P}_1), \\ \arg \min_{\mathbf{D}_2, \mathbf{P}_2} J_2(\mathbf{D}_2, \mathbf{P}_2). \end{cases} \quad (20)$$

Для решения идентификационной задачи могут использоваться известные методы обучения нейронных сетей [4–8]. Одним из таких методов, который показал высокую эффективность при решении рассматриваемой задачи, является алгоритм SCG (Scaled Conjugate Gradient), предложенный Моллером (Moller). Этот алгоритм объединяет идеи метода сопряженных градиентов с квазиньютоновыми методами [8]. Алгоритм SCG может потребовать большего числа итераций, чем другие алгоритмы метода сопряженных градиентов, но при этом количество вычислений на каждой итерации существенно сокращено.

Одна из наиболее серьезных трудностей, возникающих при обучении ИНС, связана с явлением переобучения (overfitting). Оно заключается в том, что при минимизации выбранного функционала сеть минимизирует ошибку на некотором ограниченном обучающем множестве, что может привести к неустойчивости результатов вне данного множества.

В [7] утверждается, что переобучение может наступить в том случае, когда количество точек множества, на котором проводится обучение нейронной сети,

$N < 30 k_F$, где k_F — количество свободных параметров сети. Вместе с тем необходимо учитывать, что помимо структуры ИНС и объема обучающего множества на эффект переобучения влияет также характер аппроксимируемой зависимости и распределение точек обучающего множества.

Методика оценки ошибки обобщения, базирующаяся на использовании меры Вапника–Червоненкиса, которая отражает уровень сложности ИНС и тесно связана с количеством содержащихся в ней синаптических связей, изложена в [6, 7]. Однако на данный момент метод точного определения меры Вапника–Червоненкиса неизвестен, что затрудняет ее использование при управлении обучением сети.

Для преодоления эффекта переобучения множество исходных данных может быть разделено на два подмножества: обучающее (training set) и контрольное (validation set). Обучение сети осуществляется с использованием обучающего подмножества. Контрольное подмножество используется только для контроля ошибки обучения. На начальной фазе обучения ошибка для контрольного подмножества уменьшается так же, как и для обучающего. На определенном этапе уменьшение ошибки для контрольного подмножества прекращается или она начинает возрастать. В этот момент необходимо прерывать процедуру обучения для предотвращения явления переобучения.

Если ошибка для контрольного подмножества значительно превышает ошибку для обучающего подмножества, можно сделать вывод, что исходные данные не представительны, т.е. не точно отражают поведение характеристик ДВС.

Для разделения множества исходных данных на обучающее и контрольное подмножества в [7] предложено использовать коэффициент разбиения $r_F \in [0,1]$:

$$r_F = \frac{\sqrt{2k_F - 1} - 1}{2(k_F - 1)}. \quad (21)$$

Количество точек, выделяемых в обучающее подмножество, определяется из соотношения $N_T = (1 - r_F)N$, где N — общее количество экспериментально полученных точек, принадлежащих аппроксимируемой характеристике. Количество точек, выделяемых в контрольное подмножество, $N_V = r_F N$. При этом выбор r_F существенно влияет на эффективность обучения нейронной сети только в случае высокой сложности аппроксимируемой характеристики по сравнению с размером обучающего множества. С увеличением сложности характеристики оптимальное значение r_F имеет тенденцию к уменьшению.

ВЫЧИСЛИТЕЛЬНЫЙ ЭКСПЕРИМЕНТ

В качестве исходных данных для идентификации математической модели ДВС использовались результаты экспериментальных исследований двигателя МeM3-307 на нагружочном стенде. При этом были получены зависимости эффективной мощности N_e и циклового расхода топлива g_e от режима работы двигателя: $N_e = f(n, \beta)$ и $g_e = f(n, \beta)$.

Учитывая, что частота вращения КВ (в мин^{-1}) $n = (30/\pi)\omega$; $M_e = N_e / \omega$; $G_T = g_e N_e$, после предобработки экспериментальных зависимостей получены множества точек $\{M_{ei}, \omega_i, \beta_i\}$ и $\{G_{Ti}, \omega_i, \beta_i\}$, $i = \overline{1, N_1}$, $N_1 = 157$, необходимые для обучения нейронной сети F_1 . В дальнейшем на этих множествах были выделены обучающее ($N_{T1} = 106$ точек) и контрольное ($N_{V1} = 51$ точка) подмножества. Поскольку скоростные характеристики ДВС $M_e = f(\omega, \beta)$ и $G_T = f(\omega, \beta)$ представляют собой достаточно гладкие функции, а количество экспериментальных точек, описывающих поведение данных функций, достаточно велико, коэффициент разбиения r_F при изменении количества свободных параметров сети k_F не изменялся.

Качество аппроксимации характеристик ДВС нейронной сетью оценивалось по величине среднеквадратического значения ошибки на контрольном подмноже-

стве точек:

$$\begin{cases} \sigma_{Me} = \left(\frac{1}{N_{V1}} \sum_{i=1}^{N_{V1}} (M_{ei} - y_{11})^2 \right)^{1/2}, \\ \sigma_{G_T} = \left(\frac{1}{N_{V1}} \sum_{i=1}^{N_{V1}} (G_{Ti} - y_{12})^2 \right)^{1/2}, \quad i = \overline{1, N_{V1}}. \\ [y_{11}, y_{12}]^T = F_1(\omega_i, \beta_i, D_1, P_1), \end{cases} \quad (22)$$

Поскольку величины и диапазоны изменения компонентов выходного вектора сети F_1 могут существенно различаться, для удобства сравнения среднеквадратические значения ошибок выражались в процентах от $\max\{M_e\}$ и $\max\{G_T\}$ соответственно:

$$\tilde{\sigma}_{Me} = \frac{\sigma_{Me}}{\max\{M_e\}} 100\%; \quad \tilde{\sigma}_{G_T} = \frac{\sigma_{G_T}}{\max\{G_T\}} 100\%. \quad (23)$$

На рис. 4 приведены зависимости $\tilde{\sigma}_{Me}$ и $\tilde{\sigma}_{G_T}$ от количества нейронов k_{11} и k_{12} в скрытых слоях ИНС, реализующей отображение F_1 .

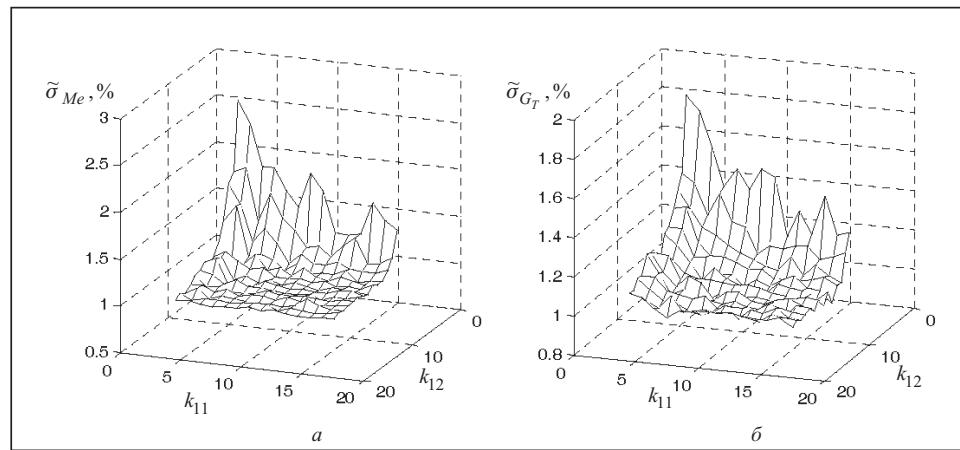


Рис. 4

Каждая точка данных зависимостей получена усреднением результатов десяти экспериментов по обучению нейронной сети при случайных начальных значениях элементов матриц весовых коэффициентов W_{11} , W_{12} , W_{13} и векторов смещений B_{11} , B_{12} , B_{13} нейронов первого, второго и третьего слоев соответственно.

Из приведенных зависимостей следует, что качество аппроксимации характеристик ДВС сетью существенно зависит от общего количества нейронов и лишь незначительно от распределения нейронов по слоям. Следовательно, структуру сети F_1 достаточно точно можно охарактеризовать только одним параметром — числом синаптических весов (количеством свободных параметров нейронной сети) k_{F1} :

$$k_{F1} = 3k_{11} + (k_{11} + 1)k_{12} + 2(k_{12} + 1). \quad (24)$$

На рис. 5 приведены зависимости $\tilde{\sigma}_{Me}$ и $\tilde{\sigma}_{G_T}$ от количества свободных параметров нейронной сети F_1 .

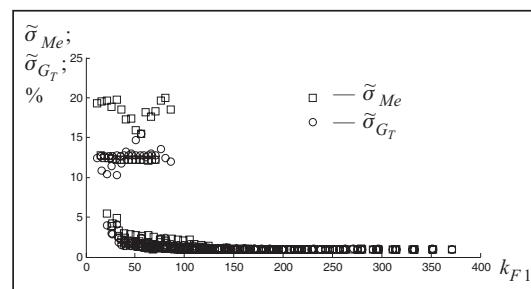


Рис. 5

Анализируя поведение среднеквадратической ошибки при изменении количества свободных параметров нейронной сети, 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 $k_{F_1} = 70$. Такая нейронная сеть имеет наименьшую сложность, при которой еще можно добиться наименьшей ошибки аппроксимации.

После обучения ИНС выбранной структуры получим параметры оператора модели, который реализует отображение $[\tilde{M}_e, G_T]^T = F_1(\omega, \beta)$ и является субоптимальным для функционала качества $J_1(\mathbf{D}_1, \mathbf{P}_1)$.

На рис. 6 приведены результаты аппроксимации скоростных характеристик ДВС нейронной сетью F_1 (сплошные линии.). Символы «□» соответствуют точкам обучающего подмножества, а символы «○» — точкам контрольного подмножества.

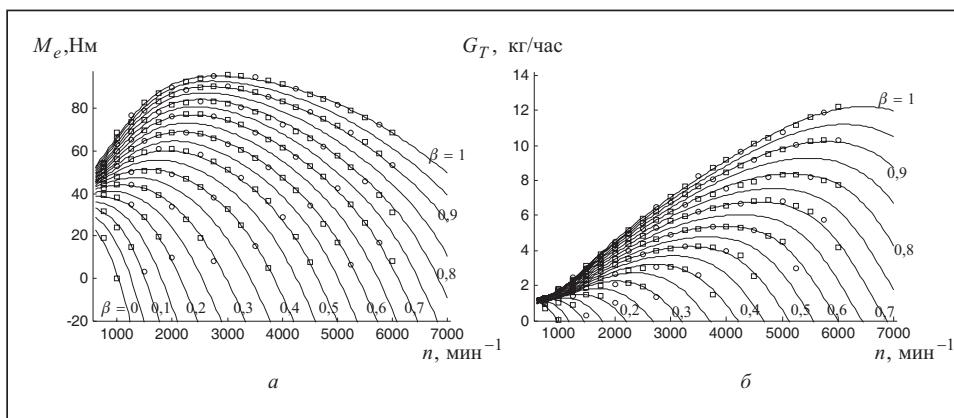


Рис. 6

В данном случае сеть тестировалась при расширенной области определения входного вектора. Это позволяет проверить способность ИНС к экстраполяции характеристик ДВС, в частности, на область режимов торможения двигателем.

Математические ожидания и среднеквадратические отклонения ошибок выходов сети для контрольного подмножества составили: $M\{M_e\} = 0,061313 \text{ Нм}$, ($0,063993\%$ от $\max\{M_e\}$); $M\{G_T\} = 0,00062177 \text{ кг/час}$, ($0,005104\%$ от $\max\{G_T\}$); $\sigma_{M_e} = 0,93371 \text{ Нм}$, ($\tilde{\sigma}_{M_e} = 0,97453\%$ от $\max\{M_e\}$); $\sigma_{G_T} = 0,13093 \text{ кг/час}$, ($\tilde{\sigma}_{G_T} = 1,0748\%$ от $\max\{G_T\}$).

В результате обработки экспериментальных характеристик [9] токсичности ОГ ДВС получены множества точек $\{C_{NOx_j}, \omega_j, M_{ej}\}$, $\{C_{CO_j}, \omega_j, M_{ej}\}$, $\{C_{HC_j}, \omega_j, M_{ej}\}$, $j = \overline{1, N_2}$, $N_2 = 160$, необходимые для обучения нейронной сети F_2 , которая реализует отображение $[C_{NOx}, C_{CO}, C_{HC}]^T = F_2(\omega, M_e)$. 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.

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

$$\begin{cases} \sigma_{NOx} = \left(\frac{1}{N_2} \sum_{j=1}^{N_2} (C_{NOx,j} - y_{21})^2 \right)^{1/2}, \\ \sigma_{CO} = \left(\frac{1}{N_2} \sum_{j=1}^{N_2} (C_{CO,j} - y_{22})^2 \right)^{1/2}, \\ \sigma_{HC} = \left(\frac{1}{N_2} \sum_{j=1}^{N_2} (C_{HC,j} - y_{23})^2 \right)^{1/2}, \\ [y_{21}, y_{22}, y_{23}]^T = F_2(\omega_j, M_{ej}, \mathbf{D}_2, \mathbf{P}_2), \end{cases} \quad j = \overline{1, N_2}. \quad (25)$$

Поскольку величины и диапазоны изменения $C_{NOx,j}$, $C_{CO,j}$ и $C_{HC,j}$, $j = \overline{1, N_2}$, могут существенно различаться, для удобства сравнения среднеквадратические значения ошибок выражались в процентах от $\max\{C_{NOx}\}$, $\max\{C_{CO}\}$ и $\max\{C_{HC}\}$ соответственно:

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

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

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

На рис. 7 приведены зависимости $\tilde{\sigma}_{NOx}$, $\tilde{\sigma}_{CO}$ и $\tilde{\sigma}_{HC}$ от количества нейронов k_{21} и k_{22} в скрытых слоях ИНС, реализующей отображение F_2 . Каждая точка данных зависимостей получена усреднением результатов десяти экспериментов по обучению нейронной сети F_2 при случайных начальных значениях элементов матриц весовых коэффициентов \mathbf{W}_{21} , \mathbf{W}_{22} , \mathbf{W}_{23} и векторов смещений \mathbf{B}_{21} , \mathbf{B}_{22} , \mathbf{B}_{23} нейронов первого, второго и третьего слоев соответственно.

Аналогично предыдущему случаю из характера приведенных зависимостей можно сделать вывод, что структуру сети F_2 достаточно точно можно охарактеризовать только одним параметром — числом синаптических весов (количеством свободных параметров нейронной сети) k_{F2} :

$$k_{F2} = 3k_{21} + (k_{21} + 1)k_{22} + 3(k_{22} + 1).$$

Для оценки необходимой величины k_{F2} построим зависимости (см. рис. 8) среднеквадратических ошибок от количества свободных параметров ИНС.

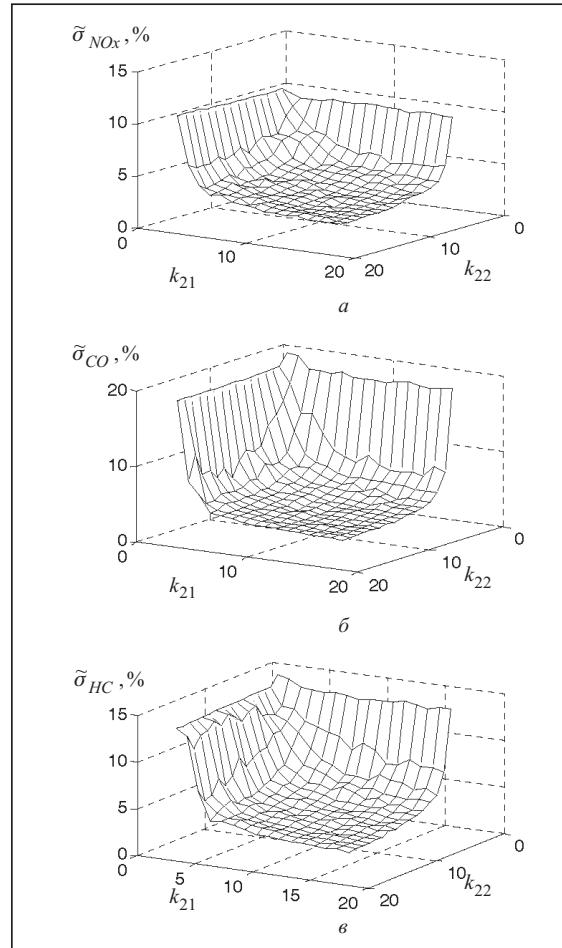


Рис. 7

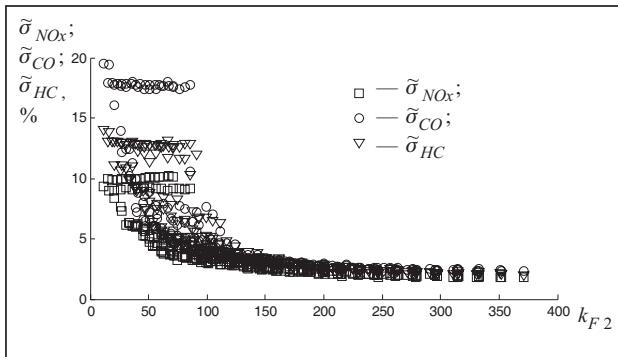


Рис. 8

Анализируя поведение среднеквадратической ошибки при изменении количества свободных параметров ИНС, выберем количество нейронов в первом скрытом слое $k_{21} = 8$, а количество нейронов во втором скрытом слое $k_{22} = 8$, что соответствует количеству свободных параметров $k_F2 = 123$. Данная нейронная сеть наилучшим образом сочетает невысокую сложность и малую достижимую ошибку аппроксимации.

После обучения нейронной сети выбранной структуры получим параметры оператора модели, который реализует отображение $[C_{NO_x}, C_{CO}, C_{HC}]^T = F_2(\omega, M_e)$ и является субоптимальным для функционала качества $J_2(\mathbf{D}_2, \mathbf{P}_2)$.

На рис. 9 *a, б, д* приведены экспериментальные зависимости показателей токсичности ОГ от режима работы ДВС, а рис. 9 *б, г, е* иллюстрирует результат аппроксимации данных характеристик нейронной сетью F_2 .

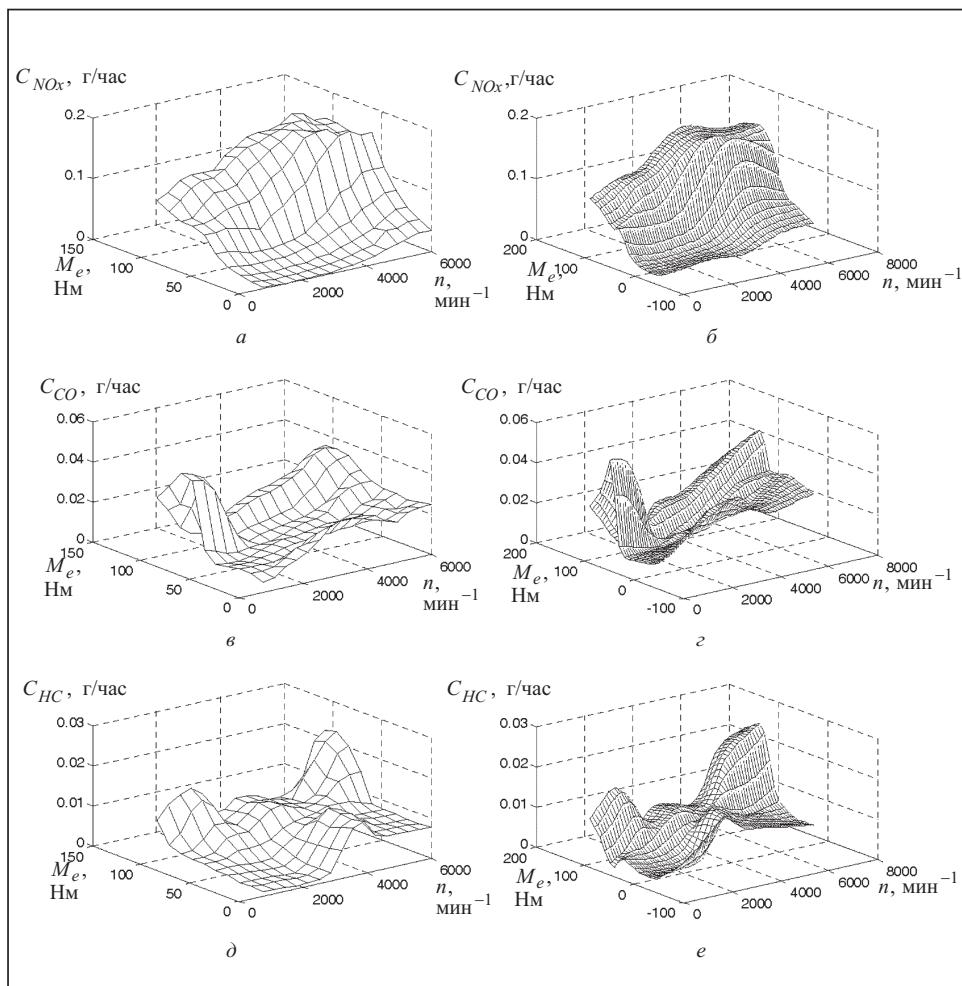


Рис. 9

О качестве полученной модели можно судить по гладкости аппроксимации характеристик в промежуточных точках между экспериментальными значениями. Математические ожидания ошибок выходов сети на обучающем подмножестве составили: $M\{C_{NO_x}\} = 3,4669 \cdot 10^{-5}$ г/час, (0,019811 % от $\max\{C_{NO_x}\}$); $M\{C_{CO}\} = 1,2362 \cdot 10^{-5}$ г/час, (0,028096 % от $\max\{C_{CO}\}$); $M\{C_{HC}\} = 3,1023e \cdot 10^{-6}$ г/час, (0,013488 % от $\max\{C_{HC}\}$). Среднеквадратические отклонения ошибок на обучающем подмножестве: $\sigma_{NO_x} = 0,0046963$ г/час, ($\tilde{\sigma}_{NO_x} = 2,6836$ % от $\max\{C_{NO_x}\}$); $\sigma_{CO} = 0,0013966$ г/час, ($\tilde{\sigma}_{CO} = 3,174$ % от $\max\{C_{CO}\}$); $\sigma_{HC} = 0,00066031$ г/час, ($\tilde{\sigma}_{HC} = 2,8709$ % от $\max\{C_{HC}\}$).

ЗАКЛЮЧЕНИЕ

В настоящей работе получена математическая модель двигателя внутреннего сгорания на основе аппроксимации его скоростных характеристик и показателей токсичности отработанных газов с помощью ИНС прямого распространения.

Преимуществами предложенного подхода можно считать простоту настройки модели на конкретный тип двигателя при использовании экспериментально полученных скоростных или нагрузочных характеристик, невысокий уровень сложности с точки зрения ее использования при решении оптимизационных задач и, в частности, простоту получения частных производных по входным переменным. Математические преобразования, используемые при построении модели, допускают эффективную реализацию средствами системы компьютерной математики MATLAB.

СПИСОК ЛИТЕРАТУРЫ

1. Моделирование горения и образования токсичных веществ в ДВС с непосредственным впрыском топлива / С.А. Чесноков, Н.Н. Фролов, В.А. Дунаев, И.В. Кузьмина // Двигателестроение. — 2005. — № 2 (220). — С. 1228.
2. Двигатели внутреннего сгорания: Теория поршневых и комбинированных двигателей / Д.Н. Вырубов, Н.А. Иващенко, В.И. Ивин и др. / Под ред. А.О. Орлина, М.Г. Круглова. — 4-е изд., перераб. и доп. — М.: Машиностроение, 1983. — 372 с.
3. Лепешкин А.В., Курмаев Р.Х., Катаев Н.К. Идентификация работы двигателя самоходной машины для использования в математической модели ее движения (на примере двигателя DT466) // Изв. МГТУ «МАМИ». — 2007. — № 2(4). — С. 68–73.
4. Методы робастного, нейро-нечеткого и адаптивного управления / Под ред. Н.Д. Егупова; издание 2-е, стереотипное. — М.: Изд. МГТУ им. Н.Э. Баумана, 2002. — 744 с.
5. Руденко О.Г., Бодянский Е.В. Искусственные нейронные сети. — Харьков: ООО «Компания СМИТ», 2005. — 408 с.
6. Осовский С. Нейронные сети для обработки информации / Пер. с польского И.Д. Рудинского. — М.: Финансы и статистика, 2002. — 344 с.
7. Хайкин С. Нейронные сети: полный курс, 2-е изд. / Пер. с англ. — М.: Издательский дом «Вильямс», 2006. — 1104 с.
8. Медведев В.С., Потемкин В.Г. Нейронные сети. MATLAB 6 / Под общ. ред. В.Г. Потемкина. — М.: Диалог-МИФИ, 2002. — 496 с.
9. Development of fuzzy logic and neural network control and advance emissions modeling for parallel hybrid vehicles / A. Rajagopalan, G. Washington, G. Rizzoni, Y. Guezenec. Center for Automotive Research. The Ohio State University Columbus, Ohio. Subcontract Report — December 2003 (<http://www.osti.gov/bridge>).

Поступила 05.05.2009