

ALGORITHM FOR PARAMETRIC IDENTIFICATION OF FUEL CONSUMPTION CHARACTERISTICS OF A VESSEL USING NEURAL NETWORK TECHNOLOGY

A. A. Chertkov, Ya. N Kask, V. G. Nikiforov

Admiral Makarov State University of Maritime and Inland Shipping,
St. Petersburg, Russian Federation

The purpose of the study is to enhance methods for computer monitoring and parametric identification of models describing vessels' fuel consumption characteristics. These improvements aim at analyzing and forecasting energy efficiency indicators of water transport facilities and optimizing the operational modes of diesel generator units. The paper proposes an algorithm for parametric identification of input-output characteristics across various technological processes and systems (technical, biological, economic, social, environmental, etc.) based on measurement data using approximate motor (regression) neural networks. The algorithm enables quantitative error assessment of parametric optimization using the Euclidean norm. Unlike traditional methods relying on statistical series for model fitting, the proposed approach trains a multilayer neural network with backpropagation to minimize deviations in output signal values from reference values by adjusting synaptic weight coefficients. The study demonstrates that radial neural networks with fixed structures—comprising one hidden layer with nonlinear activation functions and one output layer with linear activation functions—are suitable for solving problems in this domain. These networks ensure accurate image mapping based on the Euclidean metric while simplifying training modes and maintaining acceptable approximation and identification accuracy. The algorithm has been implemented to estimate parameters of a vessel's fuel consumption model based on statistical series with a predefined initial approximation. It can also be applied to identify energy consumption characteristics in the inland water transport sector when calculating target indicators and developmental metrics.

Key words: algorithm, parametric identification, fuel consumption characteristics, neural networks, network technologies, approximation, parameter estimation.

For citation:

Chertkov Alexandr A., Ya. N. Kask, and V. G. Nikiforov. Algorithm for parametric identification of fuel consumption characteristics by a vessel using neural network technology. *Vestnik Gosudarstvennogo universiteta morskogo i rechnogo flota imeni admirala S. O. Makarova* 17.2 (2025): 291–301. DOI: 10.21821/2309-5180-2025-17-2-291-301.

УДК. 621.398.04

АЛГОРИТМ ПАРАМЕТРИЧЕСКОЙ ИДЕНТИФИКАЦИИ РАСХОДНОЙ ХАРАКТЕРИСТИКИ СУДНА С ПРИМЕНЕНИЕМ НЕЙРОСЕТЕВОЙ ТЕХНОЛОГИИ

А. А. Чертков, Я. Н. Каск, В. Г. Никифоров

ФГБОУ ВО «ГУМРФ имени адмирала С. О. Макарова»,
Санкт-Петербург, Российская Федерация

Цель работы состоит в усовершенствовании методов компьютерного мониторинга и параметрической идентификации моделей расходных характеристик судов для анализа и прогнозирования показателей энергоэффективности объектов водного транспорта, а также оптимизации режимов работы дизель-генераторных агрегатов. Предложен алгоритм параметрической идентификации характеристик «вход-выход» различных по природе технологических процессов и систем (технических, биологических, экономических, социальных, экологических и др.) по данным измерений с помощью аппроксиматорных

(регрессионных) нейронных сетей с возможностью количественной оценки погрешности параметрической оптимизации по евклидовой норме. В отличие от известных методов параметрической пригонки модели по статистическим рядам предлагаемый способ базируется на обучении многослойной нейронной сети с обратным распространением ошибки отклонений значений выходных сигналов от эталонных с целью ее коррекции за счет введения поправок в значения весовых коэффициентов синаптических связей. Реализация алгоритма идентификации на основе предлагаемого способа пригонки модели выполнена с помощью радиальных нейронных сетей, имеющих фиксированную структуру с одним скрытым и одним выходным слоями в соответствии с нелинейными и линейными функциями активации нейронов, обеспечивающих точность отображения образов на основе евклидовой метрики. Предлагаемый подход позволяет упростить режимы обучения и обеспечить приемлемую точность аппроксимации и идентификации. Алгоритм реализован при оценивании параметров расходной характеристики судна с известной структурой модели потребления топлива по соответствующему статистическому ряду при заданном начальном приближении. Алгоритм может быть применен для идентификации параметров моделей характеристик расхода энергоресурсов как на судах, так и в целом в отрасли внутреннего водного транспорта при вычислении целевых индикаторов и показателей ее развития.

Ключевые слова: алгоритм, параметрическая идентификация, расходная характеристика, нейронные сети, сетевые технологии, аппроксимация, оценка параметров.

Для цитирования:

Чертков А. А. Алгоритм параметрической идентификации расходной характеристики судна с применением нейросетевой технологии / А. А. Чертков, Я. Н. Каск, В. Г. Никифоров // Вестник Государственного университета морского и речного флота имени адмирала С. О. Макарова. — 2025. — Т. 17. — № 2. — С. 291–301. DOI: 10.21821/2309-5180-2025-17-2-291-301. — EDN XZTFOR.

Введение (Introduction)

В условиях цифровой трансформации открываются новые возможности совершенствования методов параметрической идентификации расходных характеристик объектов водного транспорта, что позволяет обеспечить экономный расход топлива и электроэнергии судовыми дизель-генераторными агрегатами, а также повышение надежности их работы за счет выбора энергоэффективных режимов. Использование компьютерных технологий и роботизированных систем на основе искусственного интеллекта в управлении энергетическими системами объектов морского и речного флота является важнейшей задачей цифровизации в судостроении и вспомогательных производствах отрасли [1]–[3].

В последнее десятилетие существенно повысился интерес к применению искусственных нейронных сетей для решения задач обработки, распознавания и кластерного анализа больших объемов информации, а также оптимизации, идентификации моделей и диагностики дефектов на ранних стадиях их проявления. С помощью нейронных моделей можно выполнять диагностирование параметров расходных характеристик как судна, так и отдельно дизель-генераторного агрегата (ДГА), представленных математическими моделями в виде степенных полиномов любого порядка (как правило, второго или третьего), в которых переменными параметрами являются скорость судна или мощность ДГА, а диагностируемыми — постоянные коэффициенты при этих переменных, подлежащие оцениванию [4].

Цифровизация мониторинга и диагностирования параметров, не подлежащих измерениям с применением аппаратных датчиков, заставляет использовать математические датчики и интеллектуальные алгоритмы, базирующиеся на методах интерполяции статистических рядов измерений с применением сплайнов или получивших широкую известность в последнее время нейронных сетей. Далее с применением регрессионного анализа производится оценивание параметров идентифицируемой характеристики путем «пригонки» ее по модели аппроксимации, построенной с применением этих методов. Эффективность мониторинга и прогнозирования характеристик расхода энергоресурсов может быть повышена с применением искусственных нейронных сетей, моделирующих адаптируемые и обучаемые процессы распределенных мультипроцессорных систем, ассоциируемые с нейросетевыми процессами человеческого мозга [5], [6].

Нейросетевые процессы, протекающие в синаптических связях многослойной сети между нейронами за счет массового параллелизма их работы, значительно ускоряют обработку информации, обеспечивая вычисления с требуемой точностью. В отличие от известных технологических процессов они не программируются, а обучаются. Поэтому наиболее предпочтительными нейросетями будут те, которые сами обучаются в автоматическом режиме на заданном числе циклов обучения, а не пользователем вручную. В связи с этим предложены сети, отображающие пространство входного множества в многомерное радиальное пространство точек с ненулевыми значениями, образующих кластер. Такая структура нейросети позволяет гарантировать решение задач распознавания образов с высокой точностью при наличии лишь одного скрытого слоя в двухслойной сети. Таким образом, применение нейросетевых технологий с радиальной организацией многомерного базисного пространства при мониторинге энергоэффективности объектов в судоходных компаниях, портах и других объектах транспортной инфраструктуры может значительно ускорить и облегчить решение задач аппроксимации расходных характеристик и идентификацию их параметров с требуемой точностью [5].

Методы и материалы (Methods and Materials)

Впервые возможность линейного разделения случайного множества входных переменных на подмножества выходных переменных для локальной аппроксимации функций нескольких переменных сформулировал Томас М. Кавер в 1965 г. На основе такого разделения множество ожидаемых (выходных) значений функции может отображать множество входных данных ее аргументов через сумму локальных преобразований в ограниченной области многомерного пространства.

Применительно к нейронным сетям такие локальные преобразования могут выполняться нейронами в скрытом слое. В частности, если в качестве базисных функций для них выбрать радиальные функции $r(x)$, то многомерным пространством, в пределах которого выполняются эти преобразования, будет гиперсфера. Таким образом, в радиальных сетях входное множество данных x_i ($i = 1, 2, \dots, p$) преобразуется каждым скрытым нейроном в локальное радиальное пространство, а множество данных (образов) y_i ($i = 1, 2, \dots, p$) в выходном слое отображается взвешенной суммой локальных множеств в пространстве гиперсферы [7]. Отсюда скрытый слой должен содержать p нейронов, реализующих радиальные базисные функции, а выходной слой может содержать один нейрон для суммирования этих функций с вектором весов w .

Пусть на вход такой сети подаются p пар входных векторов (x_i, y_i) , один из которых x_i задает координаты $c = (c_1, c_2, \dots, c_n)$ одного из p центров сети. Тогда взаимосвязь входа и выхода сети можно описать системой линейных уравнений с вектором переменных весов w .

В задачах распознавания образов широко используется функция Гаусса, которую выбирают в качестве радиальной базисной функции:

$$r(x, c) = e^{-\frac{\sum_{j=1}^n (x_j - c_j)^2}{\Delta^2}}, \quad (1)$$

где Δ — ширина окна функции активации в пространстве гиперсферы [8].

В отличие от традиционных алгоритмов нейронные сети требуют обучения, в процессе которого определяются значения весов синаптических связей между нейронами. При фиксированных координатах c и радиуса Δ функции (1) вектор переменных w может быть найден посредством выполнения процедуры псевдообращения, когда решается задача наилучшей аппроксимации (с минимизацией евклидовой нормы) для системы линейных уравнений. Согласно этой процедуре для интерполяционной матрицы R , состоящей из действительных значений [9], [10]:

$$R = \begin{bmatrix} r_1(x_1) & r_2(x_1) & \dots & r_m(x_1) \\ r_1(x_2) & r_2(x_2) & \dots & r_m(x_2) \\ \dots & \dots & \dots & \dots \\ r_1(x_p) & r_2(x_p) & \dots & r_m(x_p) \end{bmatrix}, \quad (2)$$

определяется псевдообратная матрица

$$R^+ = (R^*R)^{-1}R^*, \quad (3)$$

где R^* — эрмитово сопряженная матрица R , которая для действительных значений $r_i(x_i)$ соответствует транспонированной матрице R , т. е. $R^* = R^T$.

В окончательном виде матрица весов находится из выражения

$$W = (R^*R)^{-1}R^*y = R^+y. \quad (4)$$

Архитектуру сети, реализованной на множестве скрытых нейронов, для гарантированного решения задачи распознавания образов достаточно построить с двумя слоями, состоящими из входного слоя скрытых нейронов с радиальными базисными функциями и выходного слоя линейных нейронов. Предложенный алгоритм состоит из двух этапов.

На первом этапе выполняется аппроксимация нейронной моделью расходной характеристики судна вида

$$G(v) = kv^p, \quad (5)$$

где G — расход топлива, кг/ч;

v — скорость судна, уз;

k и p — оцениваемые параметры по данным массивов измерений.

На втором этапе выполняется параметрическая идентификация расходной характеристики с использованием средств MATLAB.

Рассмотрим выполнение алгоритма на каждом этапе.

На **первом этапе** построение нейронной модели расходной характеристики выполняется в следующем порядке: подготовка входных данных для нейросети; выбор сети и ее параметров обучения; тестирование сети и проверка ее работоспособности; обучение сети и построение нейронной модели расходной характеристики с оценкой ее достоверности.

Рассмотрим подробно реализацию первого этапа алгоритма.

1. Определимся с размерностью входного массива. Пусть ряд измерений из $N = 10$ значений функции G получен для соответствующего массива значений скоростей v судна. Согласно данным измерений получены следующие значения расхода топлива:

$$G = [0.1 \ 1 \ 4 \ 10 \ 23 \ 40 \ 65 \ 100 \ 150 \ 205],$$

соответствующие значениям вектора скоростей судна:

$$v = [1 \ 3 \ 5 \ 7 \ 9 \ 11 \ 13 \ 15 \ 17 \ 19].$$

Полученные массивы входных данных будем использовать для обучения нейросети, с помощью которой выполним сначала интерполяцию дискретных данных измерений G , соответствующих значениям v непрерывной функции, т. е. получим нейронную модель, а затем с применением операции регрессии найдем искомые параметры k и p расходной характеристики.

2. Построим предложенную нейронную сеть и определим способ ее обучения. С целью аппроксимации и моделирования расходной характеристики судна по данным измерений выберем нейросеть на базе обобщенно-регрессионной сети (GRNN), представленной в инструментарии MATLAB функцией *newgrnn*. Обобщенная сеть (GRNN) представляет разновидность радиальной базисной сети, широко используемой для аппроксимации функций. В данном случае функция *newgrnn* возвращает регрессионную нейронную модель аппроксимированной расходной характеристики.

Согласно синтаксису функции *newgrnn* (X, T, SPREAD), ее аргументами X и T служат матрицы входных векторов-столбцов размерности $R \times Q$ и целевых векторов-столбцов $S \times Q$ соответственно, а также параметр SPREAD радиальных базисных функций (по умолчанию равен 1.0). Чем больше параметр SPREAD , тем более плавной будет аппроксимация функции, но меньшей точность. Для точной подгонки аппроксимации нейронной модели к входным данным значение параметра SPREAD задается меньше евклидова расстояния между координатами входных векторов.

3. Проверим работоспособность алгоритма на тестовом массиве входных векторов x и t , компоненты которых отличаются от компонентов обучающегося массива векторов X и T . Приведем фрагмент программы, позволяющей проверить работоспособность обобщенной радиальной базисной сети на небольшой выборке входных данных:

```
x = [1 2 3];
t = [2.0 4.1 5.9];
net = newgrnn(x, t);
y = net(x)
y =
    2.8280 4.0250 5.1680
```

Как видно из полученных результатов, построенная нейронная модель на базе обобщенной регрессии массива данных целевого вектора t является для них аппроксимирующей функцией.

4. Убедившись в работоспособности тестовой нейронной модели, используем в качестве обучающей выборки для целевого вектора T данные измерений расхода топлива G , а в качестве вектора входа — соответствующие данным G значения вектора скоростей судна v .

Кроме того, оценим достоверность результатов регрессионного анализа, обеспечивающего сравнение значений целевого вектора со значениями, полученными на выходе сети с помощью функции *postreg* из инструментария MATLAB. Приведем фрагмент программы (основного файла-сценария) построения нейронной модели для аппроксимации данных измерений, являющихся компонентами целевого вектора с оценкой достоверности их отображения:

```
X=[1 3 5 7 9 11 13 15 17 19];
T=[0.1 1 4 10 23 40 65 100 150 205];
G=T';
% Создание и обучение нейронной сети
spread=1.0;
net=newgrnn(X, T, spread)
% Моделирование расходной характеристики
Gm=sim(net, X)
% Графический анализ достоверности результатов обработки
[m, b, r]=postreg(Gm(1,:), T(1,:));
figure
```

С целью анализа результатов обучения нейронной сети построен график, представленный на рис. 1, в котором отображаются значения каждого из компонентов целевого вектора T с соответствующими компонентами вектора выхода G_m нейросети. Как видно из этого графика, все точки целевого вектора (измерений) находятся на прямой, состоящей из значений выходного вектора нейронной модели, что свидетельствует о правильном ее обучении.

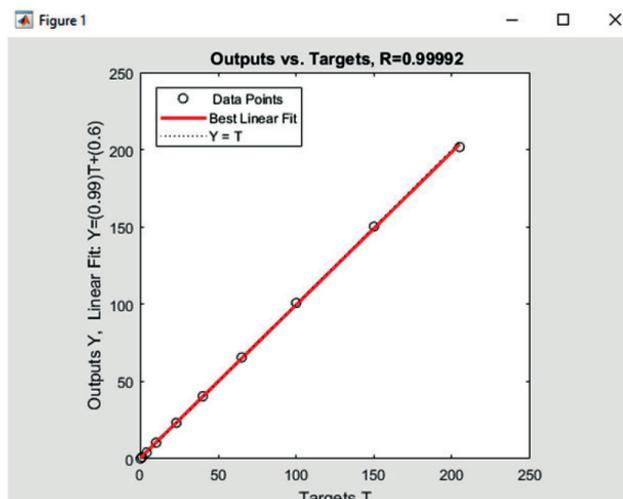


Рис. 1. Графики сравнения компонентов целевого (эталонного) и выходного вектора нейронной модели

В результате обучения нейросети получим следующие ее параметры:

```
net =
Neural Network
name: 'Generalized Regression Neural Network'
userdata: (your custom info)

dimensions:
    numInputs: 1
    numLayers: 2
    numOutputs: 1
    numInputDelays: 0
    numLayerDelays: 0
    numFeedbackDelays: 0
    numWeightElements: 24
    sampleTime: 1

connections:
    biasConnect: [1; 0]
    inputConnect: [1; 0]
    layerConnect: [0 0; 1 0]
    outputConnect: [0 1]
```

Как видно из полученных результатов, обученная модель нейронной сети содержит 24 весовых элемента (numWeightElements). По результатам моделирования построенной нейросетью модели расходной характеристики судна получены следующие оценки исходного статистического ряда Y значений расхода топлива:

```
Gm =
0.1530 1.1168 4.1669 10.3892 23.2225 40.4448 65.5561
100.8339 150.2766 201.7632
```

При этом суммарное среднее квадратическое отклонение, определяемое по формуле

$$\sigma = \sqrt{\sum_{i=1}^{n=10} \|G_i - G_m\|^2}, \quad (6)$$

составило

```
evcm =
3.2394.
```

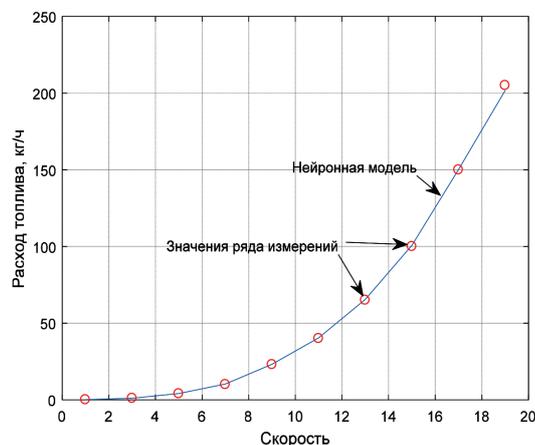


Рис. 2. Аппроксимация расходной характеристики при помощи нейросети

Графики эксперимента (статистического ряда) и нейронной модели расходной характеристики судна представлены на рис. 2. Из приведенных графиков видно, что непрерывная кривая нейронной модели G_m точно проходит через систему точек эксперимента «о», т. е. произведена 100 %-я интерполяция статистического ряда G , что свидетельствует о высоком качестве моделирования обобщенной регрессионной нейросетью.

На **втором этапе** выполняется параметрическая идентификация расходной характеристики путем ее «пригонки» по модели, построенной в результате обучения нейросети с использованием средств MATLAB, по результатам которой рассчитываются численные значения параметров k и p расходной характеристики с оценкой точности их определения.

С этой целью воспользуемся операторной функцией *lsqcurvefit* из инструментария MATLAB, которая обеспечивает наилучшим образом приближение функции (5) расхода топлива судном к выходу нейронной модели $G_m = \text{sim}(\text{net}, X)$.

Компьютерное моделирование на этапе параметрической идентификации предусматривает следующий алгоритм действий:

1. Создается файл-функция к основному файлу-сценарию для модели (5) расходной характеристики судна вида

$$f = a_1(v^{a_2}),$$

где $a_1 = k, a_2 = p$ — искомые постоянные параметры соответствующей размерности;
 v — скорость судна.

2. Обеспечивается соблюдение синтаксиса функции «пригонки» *lsqcurvefit*, аргументами которой являются файл-функция, начальное приближение, вход и выход нейронной модели, нижняя и верхняя границы искомых переменных.

3. С помощью функции «пригонки» по данным вектора G_m реализуются наилучшие оценки вектора коэффициентов $x = [x(1), x(2)]$ искомых параметров $x(1) = a_1$ и $x(2) = a_2$ заданной структуры (5) расходной характеристики судна:

$$f = x(1) * (v^{x(2)}).$$

4. По известной модели $f(x, v)$ находится погрешность параметрической идентификации с использованием метода наименьших квадратов:

$$\min_x \|f(x, v) - G_m\|^2, \quad (7)$$

выполняются графические построения нейронной модели и аппроксимирующей ее модели идентифицированной расходной характеристики.

Приведем фрагмент файла-сценария «пригонки» нейронной модели к идентифицированной кривой расходной характеристики:

```
x0=[0.01 0.01]';%Вектор начальных условий
lb=zeros(2,1); ul=[];% Значения нижней и верхней границ переменных
xdata=X';
ydata=Gm';
% Оценки параметров вектора x:
x=lsqcurvefit(@(x, xdata)myfun2(x, xdata), x0, xdata, ydata, lb, ub)
y=x(1)*(xdata.^x(2));
```

Здесь файл-функция представлена следующим набором операторов:

```
function f=myfun2(x, xdata);
f=x(1)*(xdata.^x(2));
```

По результатам моделирования процесса пригонки функции $f(x, v)$ по модели G_m получили вектор коэффициентов $x = [x(1) x(2)]^T$:

$x =$
0.0360
2.9343
>>

Полученные численные оценки коэффициентов вектора x соответствуют параметрам a_1, a_2 модели (5), наилучшим образом отображая нелинейную функцию f относительно ее нейронной модели G_m . В результате вектор искомым коэффициентов модели (6) может быть записан в следующем виде:

$$x = \begin{bmatrix} x(1) \\ x(2) \end{bmatrix} = \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} = \begin{bmatrix} 0.360 \\ 2.9343 \end{bmatrix},$$

где $a_1 = x(1) = 0,0360$; $a_2 = x(2) = 2,9343$.

Таким образом, выполнена параметрическая идентификация расходной характеристики судна.

Результаты (Results)

По результатам пригонки по методу наименьших квадратов кривой регрессии f по нейронной модели G_m , являющейся результатом аппроксимации с использованием радиальной нейронной сети, получена следующая идентифицированная модель расходной характеристики судна:

$$G(v) = 0,0360 v^{2,9343}.$$

Графики кривых, визуально отображающих степень «пригонки» идентифицированной (регрессионной) функции $G(v)$ к ее нейронной модели G_m , построенной с помощью радиальной обобщенно-регрессионной сети, приведены на рис. 3.

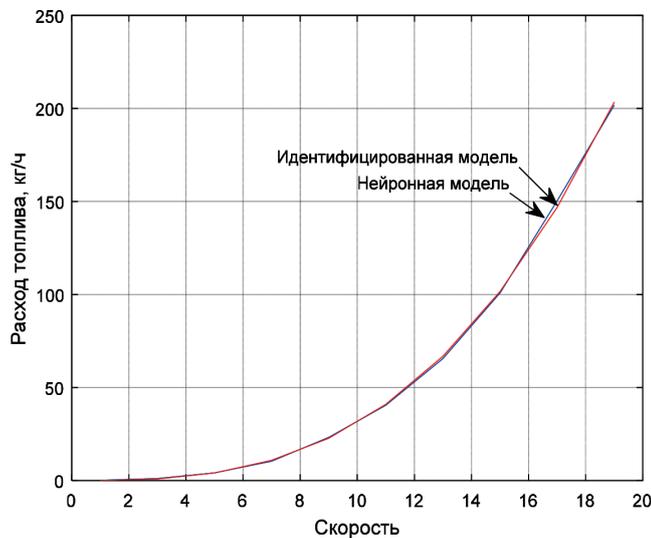


Рис. 3. Графики регрессионной модели функции $G(v)$ расходной характеристики и ее нейронной модели

Выполнена численная оценка качества регрессии расходной характеристики путем вычисления средней ошибки аппроксимации (отклонения идентифицированной функции от статистического ряда измерений расхода топлива) на интервале выборки из десяти значений по формуле

$$\delta_a = \frac{\sum_{i=1}^{n=10} \left(\frac{|G_i - G(v)|}{G_i} \right)}{n} \cdot 100 \% \quad (8)$$

Величина средней ошибки аппроксимации (регрессии) расходной характеристикой данных измерений составляет величину $\delta_a = 9,4324 \%$. Таким образом, ее значение при малочисленной вы-

борке не превышает 10 %, что свидетельствует о высоком качестве подобранной модели расходной характеристики [10].

Обсуждение (Discussion)

Предложен алгоритм параметрической идентификации расходной характеристики судна путем аппроксимации ее нейронной моделью радиальной сети с последующей оценкой ее параметров в результате подгонки по статистическим данным измерений.

Использование нейронной сети с радиальными базисными функциями из пакета NNT (Neural Networks Toolbox) MATLAB позволяет наилучшим образом производить линейное разделение любых нелинейных множеств. Благодаря своим преимуществам этим сетям достаточно только одного скрытого слоя для аппроксимации (моделирования) нелинейной функции, в частности расходной характеристики. Использование евклидовой нормы ошибки при оценивании параметров кривой регрессии расходной характеристики позволяет осуществлять оптимизацию достаточно быстро без риска попадания в локальные минимумы.

Выполнена оценка качества параметрической идентификации по величине средней ошибки аппроксимации расходной характеристики согласно экспериментальным данным, что подтверждает эффективность алгоритма идентификации и подобранной модели расходной характеристики.

Выводы (Summary)

На основе результатов решения задачи параметрической идентификации расходной характеристики можно сделать следующие выводы:

1. Нейросетевые технологии сетей с радиальными базисными функциями позволяют аппроксимировать любую нелинейную функцию с помощью одного лишь слоя скрытых нейронов, упрощая разработчику процесс решения вопроса о выборе числа скрытых слоев.

2. Использование функции Гаусса для активации нейронов скрытого слоя не только задает ширину окна активации в пространстве гиперсферы, но и способствует усилению малого евклидова расстояния между координатами входных векторов.

3. В радиальной нейронной сети оптимизация параметров выходных сигналов сети, являющихся линейной комбинацией взвешенных сумм входных сигналов, обеспечивается применением методов линейной оптимизации, которые отличаются быстродействием и способностью избегать локальных минимумов.

4. Показано, что параметрическая идентификация моделей расходных характеристик, выполняемая с применением радиальных нейронных сетей, обеспечивает наилучшее решение задачи аппроксимации ряда измерений нейронной моделью (с минимизацией евклидовой нормы).

5. Практическая значимость предложенного алгоритма состоит в расширении возможностей численной оценки параметров расходной характеристики судна на этапах испытаний, эксплуатации и диагностики судовых дизель-генераторных агрегатов на различных стадиях мониторинга судовых систем.

СПИСОК ЛИТЕРАТУРЫ

1. *Барышников С. О.* Модели и алгоритмы управления объектами водного транспорта в условиях цифровой трансформации: монография / С. О. Барышников, Д. В. Дмитриенко, В. В. Сахаров, А. А. Чертков. — СПб: Изд. «Заневская площадь», 2022. — 520 с.

2. *Сахаров В. В.* Модели и алгоритмы оптимизации технологических процессов на объектах водного транспорта в среде MatLab: монография / В. В. Сахаров, А. А. Кузьмин, А. А. Чертков. — СПб.: Федеральное государственное бюджетное образовательное учреждение высшего образования Государственный университет морского и речного флота имени адмирала С. О. Макарова, 2015. — 436 с. — EDN ULLLID.

3. *Чертков А. А.* Алгоритм идентификации параметров моделей производственных функций при помощи нейронной сети / А. А. Чертков, С. В. Сабуров, Я. Н. Каск // Вестник государственного университета

морского и речного флота им. адмирала С. О. Макарова. — 2023. — Т. 15. — № 6. — С. 1096–1104. DOI: 10.21821/2309-5180-2023-15-6-1096-1104. — EDN AQZQGR.

4. Герасимов Б. И. Основы научных исследований / Б. И. Герасимов, В. В. Дробышева, Н. В. Злобина, Е. В. Нижегородов, Г. И. Терехова. — 2-е изд. доп. — М.: Форум: ИНФРА-М, 2015. — 272 с.

5. Хайкин, Саймон. Нейронные сети: полный курс. — 2-е изд. / Пер. с англ. М.: Издательский дом «Вильямс», 2016. — 1104 с.

6. Вакуленко С. А. Практический курс по нейронным сетям / С. А. Вакуленко, А. А. Жихарева. — СПб., Ун-т ИТМО, 2018. — 71 с.

7. Осовский С. Нейронные сети для обработки информации / С. Осовский; пер. с польского И. Д. Рудинского. — М.: Финансы и статистика, 2002. — 344 с.

8. Гашников М. В. Методы компьютерной обработки изображений: учеб. пособие для студентов вузов, обучающихся по направлению подготовки дипломированных специалистов «Прикладная математика» / М. В. Гашников, Н. И. Глушов, Н. Ю. Ильясова [и др.]; под ред. В. А. Соифера. — 2 изд., испр. — М.: ООО Издательская фирма «Физико-математическая литература», 2003. — 784 с. — EDN QMMTJV.

9. Fursov V. A. Constructing unified identification algorithms using a small number of observations for adaptive control and navigation systems / V. A. Fursov // Navigation and Control Technologies for Unmanned Systems II — SPIE, 1997. — С. 34–44. DOI: 10.1117/12.277217.

10. Sanjeev Kumar Dash Radial basis function neural networks: a topical state-of-the-art survey / Kumar Dash Sanjeev, Ajit Kumar Behera, Satchidananda Dehuri, and Sung-Bae Cho // Open Computer Science. — 2016. — Vol. 6. — Is. 1. — Pp. 33–63. DOI: 10.1515/comp-2016-0005.

11. Аникина О. В. Табличная реализация искусственной нейронной сети радиальных базисных функций для классификации образцов / О. В. Аникина, О. М. Гущина, Е. В. Панюкова, Н. Н. Рогова // Современные информационные технологии и ИТ-образование. — 2018. — Т. 14. — № 2. — С. 436–445. DOI: 10.25559/SITITO.14.201802.436–445. — EDN VNHQUM.

12. Goodfellow I. Deep Learning / I. Goodfellow, Y. Bengio, A. Courville — London; Cambridge: MIT Press, 2016.

REFERENCES

1. Baryshnikov, S. O., D. V. Dmitrienko, V. V. Sakharov and A. A. Chertkov. *Modeli i algoritmy upravleniya ob'ektami vodnogo transporta v usloviyakh tsifrovoy transformatsii* SPb: Izd. «Zanevskaya ploschad'», 2022: 520.

2. Sakharov, V. V., A. A. Kuz'min and A. A. Chertkov. *Modeli i algoritmy optimizatsii tekhnologicheskikh protsessov na ob'ektykh vodnogo transporta v srede MatLab* Sankt-Peterburg: Federal'noe gosudarstvennoe byudzhethnoe obrazovatel'noe uchrezhdenie vysshego obrazovaniya Gosudarstvennyy universitet morskogo i rechnogo flota im. admirala S. O. Makarova, 2015: 436.

3. Chertkov, A. A., C. V. Saburov and Ya. N. Kask. “Algorithm for identifying parameters of production function models using a neural network.” *Vestnik gosudarstvennogo universiteta morskogo i rechnogo flota im. admirala S. O. Makarova* 15.6 (2023): 1096–1104. DOI: 10.21821/2309-5180-2023-15-6-1096-1104.

4. Gerasimov, B. I., G. I. Terekhova., et al. *Osnovy nauchnykh issledovaniy*. Second edition. M: Forum: INFRA-M, 2015: 272.

5. Khaikin, Simon. *Neural Networks: A Complete Course*, 2nd Edition. with anrl. Moscow, Williams Publishing House, 2006. 1104 с.: ил.

6. Vakulenko, S. A. and A. A. Zhikhareva. *Prakticheskiy kurs po neyronnym setyam* SPb: Universitet ITMO, 2018: 71.

7. Per, S. Osovskiy. *Neyronnye seti dlya obrabotki informatsii* M: Finansy i statistika, 2002: 344.

8. Gashnikov, M. V. et al. *Metody komp'yuternoy obrabotki izobrazheniy: Uchebnoe posobie dlya studentov vuzov, obuchayuschikhsya po napravleniyu podgotovki diplomirovannykh spetsialistov “Prikladnaya matematika”* Ed. by V. A. Soifer. Moskva: ООО Izdatel'skaya firma “Fiziko-matematicheskaya literatura”, 2003: 784.

9. Fursov, V. A. “Constructing unified identification algorithms using a small number of observations for adaptive control and navigation systems.” *Navigation and Control Technologies for Unmanned Systems II* SPIE, 1997: 34–44. DOI: 10.1117/12.277217.

10. Ch. Sanjeev Kumar Dash, Ajit Kumar Behera, Satchidananda Dehuri and Sung-Bae Cho “Radial basis function neural networks: a topical state-of-the-art survey.” *Open Computer Science* 6.1 (2016): 33–63. DOI: doi:10.1515/comp-2016-0005.

11. Anikina, O. V., O. M. Guschina, E. V. Panyukova and N. N. Rogova. “Abular artificial neural network implementation of radial basis functions for the samples classification.” *Modern Information Technologies And It-Education* 14.2 (2018): 436–445. DOI: 10.25559/SITITO.14.201802.436–445.

12. Goodfellow, I., Y. Bengio and A. Courville. *Deep Learning* London; Cambridge: MIT Press, 2016.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Чертков Александр Александрович —
доктор технических наук, доцент
ФГБОУ ВО «ГУМРФ имени адмирала
С. О. Макарова»
198035, Российская Федерация, Санкт-Петербург,
ул. Двинская, 5/7
e-mail: chertkov51@mail.ru,
kaf_electricautomatic@gumrf.ru
Каск Ярослав Николаевич —
кандидат технических наук, доцент
ФГБОУ ВО «ГУМРФ имени адмирала
С. О. Макарова»
198035, Российская Федерация,
Санкт-Петербург, ул. Двинская, 5/7
e-mail: rgam2010@yandex.ru,
kaf_electricautomatic@gumrf.ru
Никифоров Владимир Григорьевич —
доктор технических наук, профессор
ФГБОУ ВО «ГУМРФ имени адмирала
С. О. Макарова»
198035, Российская Федерация,
Санкт-Петербург, ул. Двинская, 5/7
e-mail: nikiforovvg@gumrf.ru

INFORMATION ABOUT THE AUTHORS

Chertkov, Alexandr A. —
Dr. of Technical Sciences, associate professor
Admiral Makarov State University
of Maritime and Inland Shipping
5/7 Dvinskaya Str., St. Petersburg,
198035, Russian Federation
e-mail: chertkov51@mail.ru,
kaf_electricautomatic@gumrf.ru
Kask, Yaroslav N. —
PhD
Admiral Makarov State University of Maritime
and Inland Shipping
5/7 Dvinskaya Str., St. Petersburg, 198035,
Russian Federation
e-mail: rgam2010@yandex.ru, kaf_electricautomatic@gumrf.ru
Nikiforov Vladimir G. —
Dr. of Technical Sciences, professor,
Admiral Makarov State University
of Maritime and Inland Shipping
5/7 Dvinskaya Str., St. Petersburg,
198035, Russian Federation
e-mail: nikiforovvg@gumrf.ru

*Статья поступила в редакцию 05 февраля 2025 г.
Received: Feb. 5, 2025.*