

СТАТЬИ

УДК 621.313.333:004.942
DOI 10.17513/snt.40521

**ПОВЫШЕНИЕ КАЧЕСТВА ИДЕНТИФИКАЦИИ
ПАРАМЕТРОВ АСИНХРОННЫХ ЭЛЕКТРОДВИГАТЕЛЕЙ
НА ОСНОВЕ ПРИМЕНЕНИЯ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ
С МЕХАНИЗМОМ МАШИННОГО ОБУЧЕНИЯ**

¹Алюнов А.Н., ²Вяткина О.С., ²Беляев А.В.

¹ФГБОУ ВО «Финансовый университет при Правительстве Российской Федерации»,
Россия, Москва, e-mail: alyunov@mail.ru;

²ФГБОУ ВО «Вологодский государственный университет», Россия, Вологда

Развитие интеллектуальных систем диагностики промышленного оборудования требует комплексного подхода к оценке эффективности различных методов обнаружения неисправностей асинхронных электродвигателей в нестационарных условиях эксплуатации. Исследование направлено на проведение сравнительного анализа методов параметрической идентификации и алгоритмов машинного обучения для диагностики неисправностей асинхронных электродвигателей с применением математического моделирования электромагнитных процессов и численных методов анализа временных рядов. Целью исследования является развитие методологии интеграции параметрических и обучаемых диагностических систем на основе анализа временных рядов сопротивления и индуктивности для выявления дефектов статорных обмоток асинхронных электродвигателей в нестационарных режимах. В работе представлена математическая модель асинхронного двигателя в нестационарных режимах, алгоритм параметрической идентификации на основе анализа сопротивления и индуктивности обмоток, а также система диагностики с применением методов машинного обучения Random Forest, многослойных нейронных сетей и метода опорных векторов. Экспериментальные исследования проводились на трех режимах работы двигателя с различными типами неисправностей статора и ротора. Результаты показывают, что параметрическая идентификация обеспечивает время отклика 0,51 мс при точности 85,2%, тогда как алгоритмы машинного обучения достигают точности 94,6% при среднем времени выполнения 9,5 мс. Установлено, что Random Forest демонстрирует наилучшее соотношение точности и быстродействия среди алгоритмов машинного обучения с показателями 96,8% и 7,23 мс соответственно. Предложенная методология может применяться для разработки адаптивных систем диагностики промышленных электроприводов и оптимизации стратегий технического обслуживания.

Ключевые слова: параметрическая идентификация, машинное обучение, диагностика неисправностей, временные ряды, Random Forest, нейронные сети, численные методы, асинхронные электродвигатели

**IMPROVING THE QUALITY OF IDENTIFYING THE PARAMETERS
OF ASYNCHRONOUS ELECTRIC MOTORS BY USING NEURAL
NETWORK MODELS WITH MACHINE LEARNING**

¹Alyunov A.N., ²Vyatkina O.S., ²Belyaev A.V.

¹Financial University under the Government of the Russian Federation,
Russia, Moscow, e-mail: alyunov@mail.ru;

²Vologda State University, Russia, Vologda

The development of intelligent diagnostic systems for industrial equipment requires a comprehensive approach to evaluating the effectiveness of various methods for detecting faults in induction motors under non-stationary operating conditions. The research aims to conduct a comparative analysis of parametric identification methods and machine learning algorithms for fault diagnosis of induction motors using mathematical modeling of electromagnetic processes and numerical time series analysis methods. The purpose of this research is to develop a methodology for integrating parametric and trainable diagnostic systems based on the analysis of resistance and inductance time series to identify defects in the stator windings of asynchronous electric motors in non-stationary modes. The paper presents a mathematical model of an induction motor in non-stationary modes, a parametric identification algorithm based on resistance and inductance analysis of windings, and a diagnostic system using machine learning methods including Random Forest, multilayer neural networks, and support vector machines. Experimental studies were conducted on three motor operating modes with various types of stator and rotor faults. The results show that parametric identification provides a response time of 0.51 ms with 85.2% accuracy, while machine learning algorithms achieve 94.6% accuracy with an average execution time of 9.5 ms. It is established that Random Forest demonstrates the best accuracy-to-speed ratio among machine learning algorithms with indicators of 96.8% and 7.23 ms respectively. The proposed methodology can be applied for developing adaptive diagnostic systems for industrial electric drives and optimizing maintenance strategies.

Keywords: parametric identification, machine learning, fault diagnosis, induction motors, time series, Random Forest, neural networks, numerical methods

Введение

Современные промышленные предприятия характеризуются высокой степенью автоматизации технологических процессов, в которых асинхронные электродвигатели составляют основу электромеханических систем [1]. Согласно статистическим данным, асинхронные двигатели потребляют до 45% всей производимой электроэнергии и обеспечивают функционирование критически важного оборудования [2; 3]. Внезапные отказы электроприводов приводят к значительным экономическим потерям, составляющим в среднем 50–100 тысяч рублей за час простоя производственной линии [4].

Анализ причин отказов асинхронных двигателей показывает, что 41,5% неисправностей связаны с подшипниковым узлом, 36,5% с обмотками статора, 9% – со стержнями ротора и 13% – с прочими причинами (рис. 1) [5; 6].




Рис. 1. Статистика распределения неисправностей электродвигателей

Такое распределение неисправностей обусловлено воздействием различных факторов: электрических перегрузок, механических напряжений, тепловых воздействий и загрязнений окружающей среды [7].

Существующие методы диагностики асинхронных двигателей можно разделить на две основные категории: методы параметрической идентификации, основанные на анализе электрических параметров двигателя, и методы машинного обучения, использующие статистические закономерности в диагностических признаках [8; 9]. Каждый подход имеет свои преимущества и ограничения, что требует проведения комплексного сравнительного анализа их эффективности.

Целью исследования является развитие методологии интеграции параметрических и обучаемых диагностических систем на основе анализа временных рядов сопротивления и индуктивности для выявления

дефектов статорных обмоток асинхронных электродвигателей в нестационарных режимах.

Материалы и методы исследования

Теоретическую основу исследования составляют работы в области теории электрических машин, методов параметрической идентификации динамических систем и алгоритмов машинного обучения для задач классификации [10; 11]. Объектом диагностирования являлся трехфазный асинхронный электродвигатель типа АИР100S4У3 с короткозамкнутым ротором номинальной мощностью 3 кВт, номинальным напряжением 380 В, частотой вращения 1420 об./мин. и с обмоткой статора, выполненной по схеме «звезда».

Целью диагностирования является определение технического состояния двигателя $\omega \in \Omega$, где множество состояний $\Omega = \{\omega_0 + \omega_1 + \omega_2\}$ включает:

ω_0 – номинальный режим работы (отсутствие повреждений);

ω_1 – межвитковое замыкание в первой отпайке обмотки статора;

ω_2 – межвитковое замыкание в третьей отпайке обмотки статора.

В составе гипотезы исследования рассматривались условия диагностирования в нестационарном режиме пуска электродвигателя при номинальном напряжении питания и отсутствии нагрузки на валу. Диагностические измерения фиксируются в интервале времени $t \in T$, где $T = 1$ с – продолжительность переходного процесса пуска.

На основе наблюдаемых временных рядов токов статора

$$\{i_{\alpha}(t_k), i_{\beta}(t_k)\}_{k=1}^N$$

и напряжений

$$\{u_{\alpha}(t_k), u_{\beta}(t_k)\}_{k=1}^N,$$

измеренных с частотой дискретизации $f_s = 10$ кГц ($N = 10\,000$ отсчетов), требуется определить вектор диагностических признаков $\mathbf{x}(t) \in \mathbb{R}^d$ и построить решающее правило $D: \mathbb{R} \rightarrow \Omega$, минимизирующее вероятность ошибочной классификации:

$$P_{\text{error}} = P\{D(\mathbf{x}) \neq \omega_{\text{ист}}\} \rightarrow \min,$$

где $\omega_{\text{ист}}$ – истинное техническое состояние двигателя.

Исследование базировалось на математическом моделировании электромагнитных процессов в асинхронном двигателе и экспериментальном анализе диагностических алгоритмов. Математическая модель асинхронного двигателя в координатах $\alpha - \beta$

описывается системой дифференциальных уравнений Парка – Горева:

$$\begin{cases} \frac{d\psi_{s\alpha}}{dt} = u_{s\alpha} - R_s(\omega, t) \cdot i_{s\alpha}; \\ \frac{d\psi_{s\beta}}{dt} = u_{s\beta} - R_s(\omega, t) \cdot i_{s\beta}; \\ \frac{d\psi_{r\alpha}}{dt} = -R_r i_{r\alpha} + \omega_r \psi_{r\beta}; \\ \frac{d\psi_{r\beta}}{dt} = -R_r i_{r\beta} + \omega_r \psi_{r\alpha}, \end{cases}$$

где $\psi_{s\alpha}$, $\psi_{s\beta}$ – потокосцепления статора; $\psi_{r\alpha}$, $\psi_{r\beta}$ – потокосцепления ротора; $R_s(\omega, t)$, R_r – активные сопротивления обмоток стато-

ра и ротора; ω_r – угловая скорость вращения ротора.

Для целей параметрической идентификации используется эквивалентная упрощенная модель, связывающая измеряемые величины напряжения и тока через параметры $L_M(t)$ и $R_M(t)$ – эквивалентные индуктивность и активное сопротивление обмотки статора [12]:

$$L_M(t) \frac{di(t)}{dt} + R_M(t) i(t) = u_M,$$

где $L_M(t)$, $R_M(t)$ – настраиваемые параметры модели, изменяющиеся во времени при наличии повреждений; u_M – выходное напряжение модели; $i(t)$ – мгновенное значение тока двигателя.



Рис. 2. Зависимости $R(t)$ при пуске, повреждении первой отпайки (повреждение 1), повреждении третьей отпайки (повреждение 2)

Примечание: составлено авторами на основе численных экспериментов




Рис. 3. Зависимости $L(t)$ при пуске, повреждении первой отпайки (повреждение 1), повреждении третьей отпайки (повреждение 2)

Примечание: составлено авторами на основе численных экспериментов

Данная модель справедлива для инженерного анализа переходных процессов и позволяет выявлять отклонения параметров $L_M(t)$ и $R_M(t)$ от номинальных значений при различных типах повреждений обмотки статора.

В результате численного решения системы уравнений методом Рунге – Кутты 4-го порядка получены зависимости эквивалентных активного сопротивления $R(t)$ (рис. 2) и индуктивности $L(t)$ (рис. 3) асинхронного электродвигателя для трех режимов его работы: пуск в номинальном режиме (ω_0), повреждение первой отпайки обмотки статора (ω_1) и повреждение третьей отпайки (ω_2).

На основе полученных временных рядов $R_M(t)$ и $L_M(t)$ формируется вектор диагностических признаков:

$$x = \begin{bmatrix} \text{mean}(R_M), & \text{std}(R_M), & \text{max}(R_M), & \text{min}(R_M), & \text{range}(R_M), \\ \text{mean}(L_M), & \text{std}(L_M), & \text{max}(L_M), & \text{min}(L_M), & \text{range}(L_M), \\ \text{max}\left(\frac{dR_M}{dt}\right), & \text{max}\left(\frac{dL_M}{dt}\right), & & & \end{bmatrix}^T,$$

где $\text{mean}(\cdot)$, $\text{std}(\cdot)$, $\text{max}(\cdot)$, $\text{min}(\cdot)$, $\text{range}(\cdot)$ – среднее значение, стандартное отклонение, максимум, минимум и размах соответствующего временного ряда.

Примененный алгоритм параметрической идентификации основан на методе наименьших квадратов для оценки параметров модели $\hat{R}_M(t)$, $\hat{L}_M(t)$ [12] с минимизацией квадратичной функции ошибки:

$$J(\theta) = \sum_{k=1}^N [y(t_k) - \hat{y}(t_k, \theta)]^2 \rightarrow \min_{\theta},$$

где $\theta = [R_M, L_M]^T$ – вектор идентифицируемых параметров; $y(t_k)$ – измеренное значение напряжения; $\hat{y}(t_k, \theta)$ – расчетное значение модели.

Для сравнения эффективности диагностики использовались методы машинного обучения: Random Forest (ансамбль из 200 деревьев решений), многослойная нейронная сеть с архитектурой 100-50-3 нейрона и метод опорных векторов с радиально-базисным ядром (RBF) [13; 14].

Экспериментальные исследования проводились в лаборатории электрических машин Вологодского государственного университета на стенде, включающем трехфазный асинхронный двигатель АИР100S4У3 (3 кВт, 380 В, 1420 об./мин.), систему питания на базе преобразователя частоты с возможностью программирования режимов пуска, датчики тока с диапазоном измерения ± 50 А и точностью $\pm 0,5\%$, 16-разрядный аналого-цифровой преобразователь и интерфейс передачи данных USB 2.0 с пропускной способностью 480 Мбит/с. Система сбора данных реализована на платформе MathLab и обеспечивает измерение мгновенных значений токов статора $i_a(t)$, $i_b(t)$ с частотой дискретизации $f_s = 10$ кГц и ана-

лиз временных рядов длительностью $T = 1$ с для каждого режима работы.

Программная реализация алгоритмов диагностики выполнена на кафедре информационных технологий Финансового университета при Правительстве Российской Федерации на языке программирования Python 3 с использованием библиотек NumPy, Pandas, Scikit-learn для численных расчетов и машинного обучения, Matplotlib для визуализации результатов. Веб-интерфейс для отображения диагностических данных разработан на основе HTML5, CSS3, JavaScript с библиотекой Chart.js [15, с. 83].

Результаты исследования и их обсуждение

Процесс обучения многослойной нейронной сети характеризовался динамикой функции потерь, которая определяется как среднеквадратичное отклонение между прогнозируемыми и фактическими значениями классификации по известной формуле:

$$L(\theta) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2,$$

где θ – вектор весовых коэффициентов сети, m – размер обучающей выборки, $h_{\theta}(x^{(i)})$ – выходное значение сети для i -го примера.

Экспериментальное исследование процесса обучения нейронной сети проводилось с использованием алгоритма оптимизации Adam с параметрами: скорость обучения $\alpha = 0,001$, коэффициенты экспоненциального убывания $\beta_1 = 0,9$, $\beta_2 = 0,999$. Анализ кривой обучения показал характерное экспоненциальное убывание функции потерь (рис. 4).




Рис. 4. График функции потерь нейронной сети в процессе обучения
Примечание: составлено авторами на основе численных экспериментов

Начальное значение функции потерь составило 1,142, что свидетельствует о случайной инициализации весовых коэффициентов. В течение первых 20 эпох наблюдается интенсивное снижение потерь с 1,142 до 0,041, что соответствует логарифмической скорости убывания. Данная фаза характеризуется активной настройкой весовых коэффициентов скрытого слоя и формированием внутренних представлений диагностических признаков.

Последующие 30 эпох демонстрируют более медленную сходимость с асимптотическим приближением к значению 0,0022, достигнутому на 71-й эпохе обучения. Математическое моделирование процесса сходимости показало соответствие экспоненциальной зависимости вида:

$$L(t) = L_0 \cdot e^{-\lambda t} + L_{min},$$

где $L_0 = 1,142$ – начальное значение потерь, $\lambda = 0,089$ – коэффициент скорости сходимости, $L_{min} = 0,0022$ – асимптотическое значение потерь, t – номер эпохи.

Коэффициент детерминации $R^2 = 0,987$ подтверждает высокую степень соответствия экспериментальных данных теоретической модели сходимости.

Экспериментальное исследование алгоритма параметрической идентификации на основе метода наименьших квадратов продемонстрировало высокие показатели быстродействия при умеренной точности классификации. Временные характеристики алгоритма составили $0,51 \pm 0,09$ мс (доверительный интервал 95%), что свидетельствует о высокой стабильности вычислительных процессов. Точность классификации неисправностей достигла $85,2 \pm 2,1\%$, при этом статистическая значимость результатов подтверждена критерием Стьюдента ($p < 0,05$).

Вычислительная сложность алгоритма характеризуется потреблением оперативной памяти объемом 12,3 КБ и выполнением 847 операций с плавающей точкой, что указывает на его применимость в системах с ограниченными ресурсами. Полученные результаты соответствуют теоретиче-

ским оценкам временной сложности $O(n^2)$ для решения системы линейных уравнений методом наименьших квадратов. Сравнительные характеристики методов диагностики асинхронных двигателей, включая время выполнения и точность идентификации параметров, представлены в таблице.

Промышленные условия эксплуатации характеризуются наличием электромагнитных помех и шумов измерительных систем, что требует оценки робастности диагностических алгоритмов. Экспериментальное исследование устойчивости проводилось с добавлением белого гауссова шума различной интенсивности к исходным сигналам токов статора.

Отношение сигнал/шум варьировалось в диапазоне от 40 до 10 дБ, что соответствует реальным промышленным условиям. Результаты показали, что параметрическая идентификация демонстрирует высокую устойчивость к шуму: при SNR = 20 дБ точность классификации снижается всего на 3,2% (с 85,2% до 82,0%).

Алгоритм Random Forest проявил наибольшую робастность среди методов машинного обучения, так как снижение точности при SNR = 20 дБ составило 4,8% (с 96,8% до 92,0%). Нейронные сети оказались наиболее чувствительными к шуму, при этом снижение точности достигло 8,1% (с 94,3% до 86,2%) при том же уровне помех.

Анализ алгоритмической сложности показал существенные различия между исследуемыми методами. Параметрическая идентификация имеет временную сложность $O(n^2)$, где n – размерность вектора параметров. Для типовой задачи диагностики $n = 12$ это обеспечивает стабильное время выполнения независимо от объема исторических данных.

Random Forest характеризуется сложностью обучения $O(m \cdot \log m \cdot d \cdot n_{trees})$ и сложностью предсказания $O(d \cdot n_{trees})$, где m – размер обучающей выборки, d – количество признаков, $n_{trees} = 200$ – количество деревьев. При $m = 4500$ примеров и $d = 12$ признаков время обучения составляет 1,23 секунды.

Сравнительные характеристики методов диагностики асинхронных двигателей

Метод диагностики	Время выполнения (мс)	Точность (%)	Сложность реализации	Потребность в данных
Параметрическая идентификация	0,51	85,2	Низкая	Низкая
Random Forest	7,23	96,8	Средняя	Высокая
Нейронные сети (MLP)	12,5	94,3	Высокая	Очень высокая
SVM с RBF ядром	8,8	92,1	Средняя	Высокая

Примечание: составлено авторами на основе экспериментальных данных.

Многослойная нейронная сеть имеет сложность обучения $O(\text{epochs} \cdot m \cdot w)$, где $w = 5653$ – общее количество весовых коэффициентов. При 71 эпохе обучения общее время составило 45,6 секунды, что делает метод менее предпочтительным для частого переобучения модели.

Статистический анализ результатов показывает, что параметрическая идентификация обеспечивает преимущество в быстродействии в 18,7 раза по сравнению с алгоритмами машинного обучения, однако уступает в точности на 9,4%. Random Forest демонстрирует оптимальное соотношение точности и времени выполнения среди методов машинного обучения.

Заключение

Проведенное исследование позволило выполнить комплексный сравнительный анализ методов диагностики неисправностей асинхронных электродвигателей и разработать научно обоснованную методологию выбора оптимального подхода в зависимости от требований конкретного применения.

Установлено, что параметрическая идентификация обеспечивает существенное преимущество в быстродействии (0,51 мс против 9,5 мс в среднем для методов машинного обучения), что критично для систем реального времени. Однако алгоритмы машинного обучения демонстрируют значительно более высокую точность диагностики (94,6% против 85,2%), что важно для повышения надежности промышленных систем защиты.

Random Forest показал наилучшее соотношение точности и быстродействия среди алгоритмов машинного обучения, достигая точности 96,8% при времени выполнения 7,23 мс. Это делает его оптимальным выбором для большинства промышленных применений.

Список литературы

1. Глазырин А.С., Боловин Е.В. Идентификация параметров асинхронных электродвигателей с неподвижным короткозамкнутым ротором на основе разностных схем // Известия Томского политехнического университета. 2012. Т. 321. № 5. С. 101-105. URL: <https://elibrary.ru/item.asp?id=18783670> (дата обращения: 06.08.2025).
2. Сальников С.В., Солодский Е.М., Вишняков Д.Д., Юдин Р.Ю., Петроченков А.Б. Диагностика асинхронного двигателя на основе машинного обучения // Международная конференция по мягким вычислениям и измерениям. 2023. Т. 1. С. 295-300. URL: <https://elibrary.ru/item.asp?id=54031612> (дата обращения: 06.08.2025).
3. Однолько Д.С. Параметрическая идентификация асинхронного двигателя в составе частотно-регулируемого электропривода при неподвижном роторе // Вестник Гомельского государственного технического университета им. П.О. Сухого. 2014. № 2 (57). С. 64-72. URL: <https://elibrary.ru/item.asp?id=21741040> (дата обращения: 06.08.2025).
4. Ахмед О.Х., Метельков В.П., Зюзев А.М., Есаулкова Д.В. Диагностика неисправности подшипника асинхронного двигателя в частотно-регулируемом приводе на основе машинного обучения с использованием многополосных фильтров // Электротехнические системы и комплексы. 2024. № 1 (62). С. 56-64. DOI: 10.18503/2311-8318-2024-1(62)-56-64. EDN: PFFJFP.
5. Chouhan A., Gangsar P., Porwal R., Mechevske C. Artificial neural network-based fault diagnosis for induction motors under similar, interpolated and extrapolated operating conditions // Noise & Vibration Worldwide. 2021. Vol. 52. № 10. P. 323-333. DOI: 10.1177/09574565211030709.
6. Sonje D.M., Munje R. Simultaneous Bearing Faults Detection in Three Phase Induction Motor Based on Feature Fusion Method and Random Forest Algorithm // Journal of Operation and Automation in Power Engineering. 2025. Vol. 13. № 4. P. 269-276. DOI: 10.22098/joape.2024.13044.1987.
7. Mohammad M., Ibryaeva O., Sinitsin V., Eremeeva V. A Computationally Efficient Method for the Diagnosis of Defects in Rolling Bearings Based on Linear Predictive Coding. Algorithms 2025, 18, 58. DOI: 10.3390/a18020058.
8. Водовозов А.М., Елюков А.С. Идентификация параметров асинхронной машины в установившихся режимах // Вестник Ивановского государственного энергетического университета. 2010. № 2. С. 69-71. EDN: PFJSYX.
9. Abdelmaksoud M., Torki M., El-Habrouk M., Elgeneidy M. Convolutional-neural-network-based multi-signals fault diagnosis of induction motor using single and multi-channels datasets // AEJ – Alexandria Engineering Journal. 2023. Vol. 73. P. 231-248. DOI: 10.1016/j.aej.2023.04.053.
10. Cardoso A.J.M., Cruz S., Fonseca D. Inter-turn stator winding fault diagnosis in three-phase induction motors, by Park's vector approach. Energy Conversion // IEEE Transactions on. 1999. Vol. 14. P. 595-598. DOI: 10.1109/60.790920.
11. Derkachev S.V. Monitoring the condition of the short-circuited rotor winding rods of an asynchronous electric motor // Vestnik IGEU. 2025. P. 38-43. DOI: 10.17588/2072-2672.2025.4.038-043.
12. Alyunov A.N., Vyatkina O.S., Ivanov V.N., Karpov Yu.G., Melehin V.F., Andreev A.M., Mukhametova L.R. Improving methods for identifying electric motor parameters in case of stator winding damage // IOP Conference Series: Earth and Environmental Science: International Scientific Conference on Efficient Waste Treatment 2018, EWT 2018, St. Petersburg, 13–14 december 2018. Vol. 337. St. Petersburg: Institute of Physics Publishing, 2019. P. 012070. DOI: 10.1088/1755-1315/337/1/012070. EDN: PCTUYW. URL: <https://iopscience.iop.org/article/10.1088/1755-1315/337/1/012070> (дата обращения: 09.08.2025).
13. Derkachev S., Sidorov V. Mathematical modeling of damage in an asynchronous electric motor // Safety and Reliability of Power Industry. 2025. Vol. 18. P. 59-64. DOI: 10.24223/1999-5555-2025-18-1-59-64.
14. Yenikieiev O., Kuts Y., Tkachenko A., Sherbak L. Phase Method Of Detecting Breaks In Stator Windings Of Asynchronous Motors // System Research in Energy. 2024. P. 98-109. DOI: 10.15407/srenergy2024.04.098.
15. McKinney W. Python for Data Analysis: Data Wrangling with Pandas, NumPy, and Python. 2nd ed. Sebastopol: O'Reilly Media, 2017. 547 p. ISBN: 978-1491957660.

Конфликт интересов: Авторы заявляют об отсутствии конфликта интересов.

Conflict of interest: The authors declare that there is no conflict of interest.