

УДК 519.246.85

И.Ю. КОНДРАТЬЕВА, А.В. РУДАКОВА, О.В. ПОЛИВОДА
Херсонский национальный технический университет**МОДЕЛИРОВАНИЕ АКУСТИЧЕСКИХ СИГНАЛОВ ЭЛЕКТРООБОРУДОВАНИЯ
МЕТОДОМ АВТОРЕГРЕССИИ СКОЛЬЗЯЩЕГО СРЕДНЕГО**

В данной статье авторами проведено моделирование акустического шума, генерируемого электромеханическими системами в режиме реального времени. Осуществлен обзор моделей и методов прогнозирования временных рядов, выявлены достоинства и недостатки каждого класса. Параметры модели авторегрессии идентифицированы при помощи метода наименьших квадратов. Определена зависимость коэффициентов от порядка модели. Качество полученной модели авторегрессионного скользящего среднего оценено по шести критериям. Показано, что с помощью спектрального анализа можно оценить максимальные частоты спектра случайных процессов, на основании которых определяется шаг дискретизации согласно теореме Котельникова.

Ключевые слова: акустические сигналы, временные ряды, авторегрессия, скользящее среднее, МНК

I.YU. KONDRATIEVA, A.V. RUDAKOVA, O.V. POLYVODA
Херсонський національний технічний університет**МОДЕЛЮВАННЯ АКУСТИЧНИХ СИГНАЛІВ ЕЛЕКТРООБЛАДНАННЯ МЕТОДОМ
АВТОРЕГРЕСІЇ КОВЗНОГО СЕРЕДНЬОГО**

У даній статті авторами проведено моделювання акустичного шуму, що генерується електромеханічними системами в режимі реального часу. Здійснено огляд моделей і методів прогнозування часових рядів, виявлені переваги і недоліки кожного класу. Параметри моделі авторегресії ідентифіковані за допомогою методу найменших квадратів. Визначено залежність коефіцієнтів від порядку моделі. Якість отриманої моделі авторегресійного середнього змінного оцінено по шести критеріям якості. Показано, що за допомогою спектрального аналізу можна оцінити максимальні частоти спектра випадкових процесів, на підставі яких визначається крок дискретизації згідно теореми Котельникова.

Ключові слова: акустичні сигнали, часові ряди, авторегресія, ковзне середнє, МНК

I.U. KONDRATIEVA, H.V.RUDAKOVA, O.V.POLYVODA
Kherson National Technical University**MODELING OF ELECTRICAL EQUIPMENT ACOUSTIC SIGNALS BY THE METHOD OF
AUTOREGRESSIVE SLIDING AVERAGE**

In this article, the authors simulated acoustic noise generated by electromechanical complexes in real time. A detailed study of the sound signals of operating equipment is of great importance for the functional diagnostics of electrical equipment. Each state of the system's working capacity corresponds to its characteristic spectrum of the acoustic signal. According to the registered data obtained as a result of the experiment, it is possible to determine the technical state of the controlled object. The method for extracting the dominant information component of the signal on the background of external and internal excitations of the object operation is developed in the article. A thorough review of models and methods for predicting time series has been made, and the merits and demerits of each class have been revealed. The model was chosen based on the results of the experiment; it accurately describes the acoustic process. The parameters of the autoregression model are identified by the least squares method. The dependence of the coefficients of the acoustic process on the order of the model is determined. The dispersion and mathematical expectation of the model are calculated. With the help of spectral analysis, which is a fairly objective criterion, the authors calculated the maximum frequencies of the spectrum of random processes. On the basis of the calculations performed, the step of discretization of measurements was clarified, the authors used Kotel'nikov's theorem in the analysis. The spectral density of the amplitudes of the random process was found by means of the Fourier transform of the correlation function. The quality of the obtained model of the autoregressive moving average is estimated by 6 quality criteria. A comprehensive approach to studying the methods of acoustic analysis allowed not only to analyze the data, but to draw specific conclusions based on the information obtained.

Keywords: acoustic signals, time series, autoregression, average variable.

Постановка проблеми

Повышение производительности и точности работы современного электрооборудования требует обеспечения надежности и безопасности его эксплуатации, как следствие, улучшения точности и быстрого действия технической диагностики в режиме реального времени.

Для получения оперативной информации об исследуемом объекте можно использовать акустический сигнал, порождаемый электромеханическими компонентами в процессе работы. Это позволяет расширить возможности мониторинга и управления работой сложных технических систем.

Анализ последних исследований и публикаций

Исследование акустических сигналов относится к классу задач анализа временных рядов. Задачи подобного плана решаются на основе создания модели, адекватно описывающей происходящий процесс. На сегодняшний день существует множество моделей анализа и прогнозирования временных рядов: регрессионные и авторегрессионные модели, нейросетевые модели, модели экспоненциального сглаживания, модели на базе цепей Маркова, классификационные модели и др. [1].

Одним из распространенных классов являются регрессионные модели. Они просты и гибки в использовании, единообразны в анализе и проектировании [2]. Работа с линейными регрессионными моделями дает возможность для анализа всех промежуточных значений, к тому же результаты можно получить быстрее. Однако низкая адаптивность и отсутствие способности моделирования нелинейных процессов делает линейные модели узкоспециализированными. А в нелинейных моделях того же класса сложно определять параметры и вид функциональной зависимости модели.

Модели и методы экспоненциального сглаживания чаще других используют для долгосрочного прогнозирования. Они унифицированы и просты в использовании, но в них отсутствует гибкость [1].

Нейросетевые модели и методы способны улавливать нелинейные зависимости между будущими и фактическими значениями процессов. Им свойственна адаптивность, масштабируемость (параллельная структура ускоряет вычисления) и сходство в анализе и проектировании. Но в них – отсутствует прозрачность моделирования, сложная процедура подбора архитектуры, высокие требования к непротиворечивости обучающей выборки, ресурсоемкость процесса обучения и неоднозначность подбора алгоритма при обучении [3].

Моделям и методам на базе цепей Маркова присущи легкость и унифицируемость в анализе и проектировании, но с их помощью невозможно моделировать процессы с длинной памятью [1].

Модели классификационно-регрессионных деревьев отличаются масштабируемостью, за счет которой возможна быстрая обработка сверхбольших объемов данных. Они характеризуются быстротой и однозначностью процесса обучения дерева (в отличие от нейросетевых моделей), а также возможностью использовать категориальные внешние факторы. Недостатками данных моделей являются неоднозначность алгоритма построения структуры дерева; сложность вопроса останова (момент прекращения дальнейших ветвлений); отсутствие единообразия анализа и проектирования [4].

В области анализа временных рядов наиболее популярными и широко используемыми являются классы авторегрессионных моделей. Однако им присуще большое число свободных параметров, идентификация которых неоднозначна и ресурсоемка. Перспективными для анализа акустических сигналов являются алгоритмы цифровой обработки, построенные на базе авторегрессионной модели скользящего среднего.

Цель исследования

Целью работы является разработка метода анализа акустических сигналов, возникающих при работе электромеханических системам, на базе авторегрессионной модели скользящего среднего. Требуется осуществить разработку методики выделения доминантной информационной из составляющих сигнала.

Изложение основного материала исследования

В основу авторегрессионной модели заложено предположение о том, что значение процесса $y[k]$ линейно зависит от некоторого количества предыдущих значений того же процесса $y[k-1], \dots, y[k-n]$ [5]. Для достижения большей гибкости в подгонке модели целесообразно объединить в одной модели авторегрессию и скользящее среднее (по сути дела являющееся фильтром низких частот).

Особенностью возникающих акустических сигналов является наличие периодически повторяющихся интервалов (участков), что позволяет для их моделирования использовать авторегрессионные модели вида:

$$y[k] = A_0 + \sum_{i=1}^n A_i y[k-i]. \quad (1)$$

Для идентификации параметров модели (1) на основе проведенных экспериментов можно использовать метод наименьших квадратов (МНК) [2]. Из экспериментальных данных формируем уравнение:

$$\vec{Y} = X \vec{a}, \tag{2}$$

где $\vec{Y} = [y[n+1] \ y[n+2] \ \dots \ y[N]]^T$ – вектор выхода, формируемый из элементов временного ряда, начиная с $(n+1)$ -го порядка. Матрица входных факторов X так же комплектуется из элементов того же временного ряда:

$$X = \begin{bmatrix} y[n] & y[n-1] & \dots & y[1] \\ y[n+1] & y[n] & \dots & y[2] \\ \dots & \dots & \dots & \dots \\ y[N] & y[N-1] & \dots & y[N-n] \end{bmatrix}. \tag{3}$$

Вектор параметров модели определяется, согласно МНК, как:

$$\vec{a} = [X^T X]^{-1} X^T \vec{Y}. \tag{4}$$

В результате обработки зарегистрированных акустических сигналов получены значения коэффициентов моделей 1–7 порядков, значения которых показаны в табл.1.

Таблица 1

Расчеты коэффициентов в зависимости от порядка модели

Коэффициенты модели	Порядок модели n						
	1	2	3	4	5	6	7
A1	0.918	1.528	1.757	1.904	2.06	2.21	2.244
A2	-	-0.664	-1.192	-1.696	-2.099	-2.55	-2.656
A3	-	-	0.346	1.089	1.716	2.411	2.576
A4	-	-	-	-0.423	-1.127	-1.977	-2.178
A5	-	-	-	-	0.37	1.204	1.417
A6	-	-	-	-	-	-0.405	-0.589
A7	-	-	-	-	-	-	0.083

Для анализируемого временного ряда акустического сигнала, порождаемого электрооборудованием, получаем модель 4-го порядка в виде:

$$y[k] = 1,904y[k-1] - 1,696y[k-2] + 1,089y[k-3] - 0,423y[k-4]. \tag{5}$$

На рис.1,а показаны графики фактических нормированных значений временного ряда, полученных в результате эксперимента (жирная линия) и прогнозируемые, согласно модели (тонкая линия). Относительная ошибка восстановления прогнозируемых временных рядов приведена на рис. 1,б.

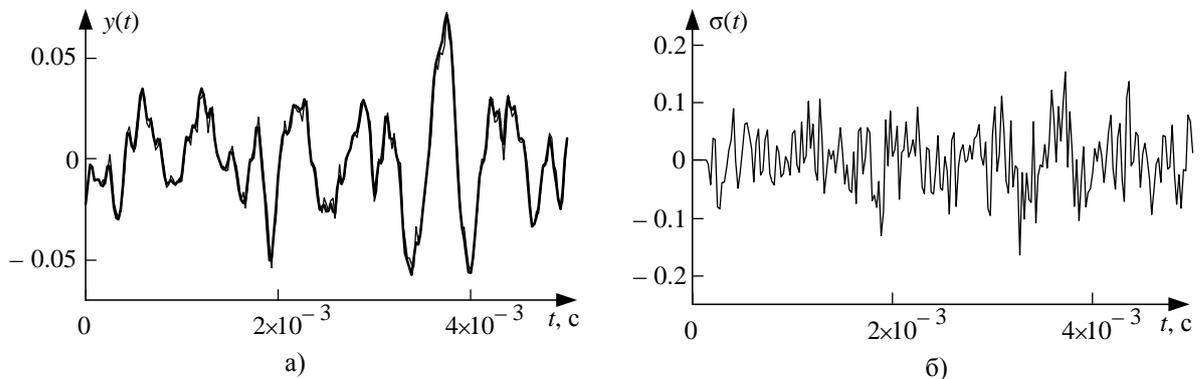


Рис.1. Графическое представление временных рядов

Для оценки работоспособности полученной модели можно использовать следующие критериям качества [5]:

1. Средняя ошибка (ME) – характеризует предвзятость в оценивании параметров модели:

$$ME = \frac{1}{N} \sum_{i=1}^N (y_{oi} - y_{mi}), \quad (6)$$

где N – количество отчетов, y_o – фактические нормированные значения временного ряда, а y_m – прогнозные.

2. Среднеквадратичная ошибка (MSE):

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_{oi} - y_{mi})^2. \quad (7)$$

3. Среднеквадратическая ошибка восстановления прогнозируемых временных рядов (SKO):

$$SKO = \sqrt{\frac{\sum_{i=1}^N (y_{oi} - y_{mi})^2}{\sum_{i=1}^N y_{oi}^2}}. \quad (8)$$

4. Мера точности – иллюстрирует стандартное отклонение остатков модели (RMSE):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{oi} - y_{mi})^2}. \quad (9)$$

5. Средняя абсолютная ошибка (MAE). Этот показатель характеризует, насколько велики ошибки прогноза в сравнении с действительными значениями ряда:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_{oi} - y_{mi}|. \quad (10)$$

6. Коэффициент несоответствия Тейла U . Его значение должно находиться в пределах от 0 до 1:

$$U = \frac{\sqrt{\sum_{i=1}^N (y_{oi} - y_{mi})^2}}{\sqrt{\sum_{i=1}^N (y_{oi})^2} + \sqrt{\sum_{i=1}^N (y_{mi})^2}}. \quad (11)$$

Если величина коэффициента выше 1, то модель нельзя использовать для прогноза, поскольку прогнозируемые и реальные временные ряды являются некоррелированными [5]. В нашем случае согласно критерию Тейла прогнозные и реальные ряды совпадают, поэтому можно сделать вывод, что построенная модель адекватно прогнозирует реальный ряд.

Результаты расчетов зависимостей вышеупомянутых критериев качества от порядка полученной модели приведены в табл.2.

Таблица 2

Критерии качества полученных моделей авторегрессионного среднего

Порядок модели n	SCO	ME	MSE	RMSE	MAE	U
2	0.296	$-2.256 \cdot 10^{-6}$	$2.67 \cdot 10^{-5}$	$5.167 \cdot 10^{-3}$	$4.075 \cdot 10^{-3}$	0.148
3	0.278	$-1.33 \cdot 10^{-6}$	$2.35 \cdot 10^{-5}$	$4.848 \cdot 10^{-3}$	$3.835 \cdot 10^{-3}$	0.139
4	0.252	$-1.819 \cdot 10^{-6}$	$1.93 \cdot 10^{-5}$	$4.393 \cdot 10^{-3}$	$3.47 \cdot 10^{-3}$	0.126
5	0.234	$-9.683 \cdot 10^{-7}$	$1.666 \cdot 10^{-5}$	$4.081 \cdot 10^{-3}$	$3.21 \cdot 10^{-3}$	0.117
6	0.214	$-1.536 \cdot 10^{-6}$	$1.393 \cdot 10^{-5}$	$3.732 \cdot 10^{-3}$	$2.957 \cdot 10^{-3}$	0.107
7	0.213	$-1.222 \cdot 10^{-6}$	$1.383 \cdot 10^{-5}$	$3.719 \cdot 10^{-3}$	$2.947 \cdot 10^{-3}$	0.107

С увеличением порядка модели n значения всех критериев качества уменьшаются, что естественно. Однако, в связи с высокими скоростями протекающих процессов для уменьшения объема вычислений целесообразно проводить расчеты не по всем отсчетным временным точкам, а через некоторые интервалы с использованием агрегации значений по интервалам. В зависимости от приложенной нагрузки и/или от физического состояния компонентов электромеханического состояния характер акустических сигналов может меняться. Это особенно актуально при осуществлении процедуры идентификации параметров модели в системах адаптивного управления в режиме реального времени.

Для определения оптимальной величины интервала агрегации можно воспользоваться классическим спектральным методом анализа сигналов [6].

Спектральный анализ позволяет оценить максимальные частоты спектра случайных процессов, на основании которых можно выяснить шаг дискретизации, согласно теоремы Котельникова:

$$\Delta t \leq \frac{\pi}{\omega_c}, \tag{12}$$

где ω_c – частота среза, для нахождения которой традиционно используют уравнение Парсевала:

$$\frac{1}{\pi} \int_0^{\omega_c} [S(\omega)]^2 d\omega = \frac{\mu}{\pi} \int_0^{\infty} [S(\omega)]^2 d\omega, \tag{13}$$

где μ – коэффициент характеризующий точность воспроизведения, обычно $\mu = 0,95$; $S(\omega)$ – спектральная плотность амплитуд случайного процесса, которую можно найти на основе автокорреляционной функции сигнала $K_y(\tau)$ с помощью преобразования Фурье:

$$S(\omega) = \frac{2}{\pi} \int_0^{\infty} K_y(\tau) \cos(\omega\tau). \tag{14}$$

Автокорреляционную функцию можно определить с помощью методов статистического анализа непосредственно из экспериментально полученной выборки [7].

Выводы

Перспективно использовать авторегрессионные модели скользящего среднего для анализа звуковых сигналов, генерируемых электрооборудованием. Параметры модели можно рассчитать методом наименьших квадратов, но для идентификации в режиме реального времени целесообразно применять рекуррентный метод. Для уменьшения объемов перерабатываемой информации без потери точности используют агрегированные значения. Длительность процесса агрегирования стоит определять на основе спектрального анализа акустического сигнала. Все это открывает возможности для обеспечения безопасности и надежности эксплуатации электрооборудования за счет своевременного обнаружения и предотвращения аварийных сбоев работы в режиме реального времени.

Список использованной литературы

1. Рунова Л.П. Модель авторегрессии и скользящего среднего (ARMA) / Л.П. Рунова. – Ростов-на-Дону: Изд-во ЮФУ, 2013. – 59 с.
2. Королев А.Л. Компьютерное моделирование / А.Л. Королев. – М.: БИНОМ. ЛЗ, 2013. – 230 с.
3. Савиных В.Н. Математическое моделирование производственного и финансового менеджмента: Учебное пособие / В.Н. Савиных. – М.: КноРус, 2013. – 192 с.
4. Чупрынов Б.П. Математика в экономике: математические методы и модели / М.С. Красс, Б.П. Чупрынов; Под ред. М.С. Красс. – М.: Юрайт, 2013. – 541 с.
5. Бидюк П.И. Моделирование и прогнозирование нелинейных динамических процессов/ И.В. Баклан, Я.И. Баклан, Л.О. Коршевнюк, В.И. Литвиненко, М.Ю. Минин, В.В. Петренко, О.О. Петренко, Ю.М. Селин, А.А. Фелелов // К.:ЕКМО, 2004 – 120с.
6. Дмитриев В.И. Прикладная теория информации / В.И. Дмитриев. – М.: Высшая школа, 1989. – 320 с.
7. Вентцель Е.С. Теория вероятностей / Е.С. Вентцель. – М.: Наука, 1964. – 576 с.