

УДК 004.94

## МОДЕЛИРОВАНИЕ И ПРОГНОЗИРОВАНИЕ ОТКАЗОВ ВЕНТИЛЯЦИОННОГО ШАХТНОГО ОБОРУДОВАНИЯ

*Коваленко А.А., Секирин А.И.*

*Донецкий национальный технический университет  
кафедра автоматизированных систем управления*

*E-mail: triplefrost@gmail.com*

*Рассмотрены существующие методы моделирования прогнозирования отказов оборудования. Проанализированы преимущества и недостатки данных методов. Определены наиболее подходящие методы для решения задачи.*

### **Актуальность задачи**

Задача анализа моделирования и прогнозирования отказов оборудования является актуальной, поскольку от его исправности зависит безопасность рабочих, к тому же ее решение задачи позволит планировать время ремонта и закупок нового оборудования. В настоящее время диагностика оборудования производится, как правило, при помощи анализа спектрограмм вибросигналов, снятых в различных точках. Это приводит к задаче анализа многомерных временных рядов. Обработка многомерных данных, включающая хранение, передачу по каналам связи, задачи классификации и прогнозирования, представляет определенные трудности [1].

Поскольку под вентиляционным оборудованием понимают несколько групп оборудования (вентиляторы, электродвигатели, воздушные фильтры, шумоглушители, а также их составные части: подшипники, муфты и др.), для решения задачи необходимо разработать универсальный алгоритм, позволяющий быстро обрабатывать поступающие данные, либо набор алгоритмов для каждой группы оборудования.

### **Существующие методы, модели, алгоритмы, применяемые для решения задачи**

На основании анализа входных данных (спектрограмм вибросигналов) можно прогнозировать лишь «постепенные отказы», когда на допустимые значения параметров установлен допуск, ограниченный верхним и нижним уровнями значений параметра.

Для прогнозирования таких отказов могут быть использованы методы прогнозирования многомерных временных рядов.

Кроме «постепенных отказов», необходимо учитывать возможные «внезапные отказы», причина возникновения которых связана не с изменением состояния объекта, а с неблагоприятным сочетанием действующих факторов. Вероятность возникновения таких отказов на некотором промежутке зависит только от длины промежутка и интенсивности отказов.

Поэтому в данном случае для прогнозирования отказов следует применять методы моделирования.

### Методы моделирования «внезапных отказов»

Характеристикой уровня случайных внешних воздействий, которым может подвергаться объект при эксплуатации, и возможностей объекта к их восприятию является интенсивность отказов  $l(t)$  которая в случае внезапных отказов является постоянной величиной  $l(t) = const$ , что является основным признаком внезапного отказа.

Широко используется экспоненциальный закон надежности.

Рассмотрим модель внезапного устойчивого отказа невосстанавливаемого объекта, когда на допустимые значения выходного параметра установлен допуск  $d$ , ограниченный предельными верхним  $X_H$  и нижним  $X_L$  уровнями значений выходного параметра, выход из которых означает отказ объекта (рис. 1).




Рисунок 1 – Модель «внезапного отказа»

В отличие от постепенных отказов, случайный процесс  $X(t)$  характеризующий изменение состояния объекта во времени, не является детерминированной функцией случайных аргументов, имеющей определенную тенденцию изменения в сторону прогрессивного ухудшения качественных выходных параметров объекта, обусловленного накоплением деградационных повреждений. Процесс  $X(t)$  в случае внезапных отказов представляет собой стационарный случайный процесс, характеристики которого (математическое ожидание  $M(t) = const$ , дисперсия  $D(t) = const$ , функция плотности распределения выходного параметра  $f_x(x, t) = f_x(x)$  не зависят от времени (наработки объекта)  $t$ . Колебания  $X_i(t)$  и  $X_k(t)$  отдельных реализаций этого процесса для  $i$ -го и  $k$ -го экземпляров объекта обусловлены переменностью условий и режимов эксплуатации, случайным характером эксплуатационных нагрузок и внешних воздействий на объект. Моменты  $q_{li}$  и  $q_{lk}$  выхода отдельных реализаций за пределы допуска на выходной параметр фиксируются как отказы соответствующих экземпляров объектов.

В силу стационарности процесса  $X(t)$  в каждый момент времени (наработки)  $t$  условная вероятность выхода определенной реализации процесса  $X_k(t)$  за пределы допуска  $d$  определяемая при условии, что в этот момент данная реализация существует (отказ соответствующего  $i$ -го экземпляра объекта не возник), является постоянной величиной:

$$F_x = F_1 + F_2 = \int_{-\infty}^{X_L} f_x(x) dx + \int_{X_H}^{+\infty} f_x(x) dx \quad (1)$$

## Методы прогнозирования многомерных временных рядов

Существующие методы прогнозирования многомерных временных рядов можно разделить на следующие группы:

1. Статистические методы. К ним относятся простейшие методы, строящие прогноз на основе усредненного значения за некоторый период. Методы обладают низкой точностью, поскольку не учитывают наличие тренда, сезонности, аномальных выбросов в исходных данных.
2. Регрессионные методы. В данную группу методов, кроме собственного регрессионных методов, принято включать методы авторегрессии и их модификации, такие как интегрированная модель авторегрессии – скользящего среднего (ARIMA). Данные методы являются более точными по сравнению со статистическими методами, но также являются неустойчивыми к выбросам.

Обычно, перед использованием данных методов, производится сокращение размерности задачи при помощи одного из существующих методов, например метода главных компонент, дискретно-косинусного преобразования, быстрого преобразования Фурье, факторного анализа и др. [2]. Но в рамках данной задачи сокращение размерности приведет к потере некоторого количества информации, что является недопустимым.

3. Вейвлет-преобразования. В основе данной группы методов лежит основное свойство вейвлетов – возможность анализа различных частотных компонент ряда. В настоящее время данные преобразования используются для прогнозирования одномерных временных рядов, как и все вышеперечисленные группы методов. Математический аппарат, позволяющий анализировать многомерные ряды, еще разрабатывается. Следует заметить, что выбор вейвлет-функции также представляет определенную сложность. [3]
4. Нейросетевые модели. Являются мощным и гибким инструментом прогнозирования многомерных временных рядов, поскольку структура нейронной сети может быть изменена в зависимости от типа оборудования. К недостаткам можно отнести необходимость наличия достаточно большого количества данных для обучения сети, что является затруднительным в случае, например, установки более нового оборудования. [4].
5. Генетические алгоритмы. В основе обучающегося алгоритма LGAP (Learning Genetic Algorithm for Prognosis) лежит идея, ранее использованная в алгоритмах ZET и WANGA, которые, как правило, используются для заполнения пропусков в эмпирических таблицах данных. Данный алгоритм лишен недостатков описанных выше алгоритмов, однако требует большое количество системных ресурсов для своей работы. Алгоритм легко распараллеливается и показывает хорошие результаты при работе на многопроцессорных системах, но такое решение является весьма дорогостоящим [5].
6. Сингулярный анализ временных рядов (SSA). В настоящее время обычно применяют модификацию данного метода, называемую «гусеницей», которая легко обобщается на любое число измерений. Данный алгоритм является двухпараметрическим (задается длина гусеницы и число ее компонент). Выбор параметров оказывает значительное влияние на результат, а также время работы

алгоритма. Особо следует выделить устойчивость алгоритма к выбросам, что является важным в рамках рассматриваемой задачи, поскольку датчик, снимающий спектрограмму вибросигнала, является очень чувствительным. Хорошо справляется с прогнозированием нестационарных временных рядов, что также является преимуществом [6].

### Математическая постановка задачи

Пусть наблюдается система функций  $\left\{ \left( f_i^{(k)} \right)_{i=1}^N \right\}$ , где  $k$  – номер ряда,  $k = 1 \dots s$ ,  $s$  – число временных рядов,  $N$  – длина временного ряда,  $i$  – номер отсчета.

Рядом в данном случае является спектрограмма вибросигнала, снятая в определенной точке.

Требуется разложить в ряд сумму компонент, интерпретировать каждую и построить продолжение ряда  $\left( f_i^{(k)} \right)_{i=1}^{N+M}$  по выбранным компонентам.

### Алгоритм SSA.

В результате применения метода ряд раскладывается на простые компоненты: тренды, сезонные, периодические и колебательные составляющие, а также шумовые компоненты. Полученное разложение может служить как для прогноза ряда в целом, так и отдельных его компонент.

Алгоритм состоит из трех этапов:

1. Построение матрицы наблюдений;
2. Анализ главных компонент;
3. Прогноз.

Для упрощения рассмотрим одномерный временной ряд  $(f_i)_{i=1}^N$ . Выберем  $n$  такое, что  $0 < n < N - 1$  – время жизни гусеницы. Пусть  $\sigma = N - n + 1$  – длина гусеницы. Построим последовательность  $Z$  из  $n$  векторов в пространстве  $R^\sigma$  следующего вида:

$$Z = (Y^{(1)}, \dots, Y^{(n)}), \quad (2)$$

где

$$Y^{(i)} = (f_{i+l-1})_{l=1}^{\sigma} \quad (3)$$

Будем называть  $Z$  нецентрированной матрицей наблюдений, порожденной гусеницей со временем жизни  $n$ . В случае многомерного ряда матрицей наблюдений называется столбец из матриц наблюдений, соответствующий каждой из компонент.

Рассмотрим ковариационную матрицу полученной выборки:

$$C = \frac{1}{n} Z Z^T \quad (4)$$

Выполним ее сингулярное разложение (SVD):

$$C = V \Lambda V^T, \quad (5)$$

где  $\Lambda$  – диагональная матрица собственных чисел,  $V$  – ортогональная матрица собственных векторов:

$$V = (v^{(1)}, \dots, v^{(\tau)}) \quad (6)$$

Далее рассмотрим систему главных компонент:

$$U = V^T Z \quad (7)$$

После проведения анализа, следует восстановить матрицу наблюдений по главным компонентам:

$$Z' = U'V', \quad (8)$$

где 
$$V' = (v^{(i_1)}, \dots, v^{(i_\gamma)}), \quad (9)$$

$$U' = V'^T \quad (10)$$

Далее восстанавливаются исходные последовательности:

$$f_m^{(k)} = \begin{cases} \frac{1}{m} \sum_{i=1}^m x_i^{(m-i+1,k)}, & \text{если } 1 \leq m \leq \sigma, \\ \frac{1}{\sigma} \sum_{i=1}^{\sigma} x_i^{(m-i+1,k)}, & \text{если } \sigma \leq m \leq n, \\ \frac{1}{N-m-1} \sum_{i=1}^{N-m+1} x_{i+m-n}^{(n-i+1,k)}, & \text{если } n \leq m \leq N \end{cases} \quad (11)$$

Затем начинается прогнозирование. Числовой ряд  $(f_i)_{i=1}^{N+1}$  называется продолжением ряда  $(f_i)_{i=1}^N$ , если порождаемая им при гусеничной обработке выборка лежит в той же гиперплоскости, что и у исходного ряда. Ранее был вычислен набор главных компонент  $(i^1, \dots, i^\gamma)$ . Определим:

$$w = \begin{pmatrix} v_{\sigma}^{(i_1)} & \dots & v_{\sigma}^{(i_\gamma)} \\ \vdots & \ddots & \vdots \\ v_{\tau}^{(i_1)} & \dots & v_{\tau}^{(i_\gamma)} \end{pmatrix} \quad (12)$$

$$V_* = \begin{pmatrix} v_1^{(i_1)} & v_1^{(i_2)} & \dots & v_1^{(i_\gamma)} \\ \vdots & \vdots & \ddots & \vdots \\ v_{\sigma-1}^{(i_1)} & v_{\sigma-1}^{(i_2)} & \dots & v_{\sigma-1}^{(i_\gamma)} \\ v_{\sigma+1}^{(i_1)} & v_{\sigma+1}^{(i_2)} & \dots & v_{\sigma+1}^{(i_\gamma)} \\ \vdots & \vdots & \ddots & \vdots \\ v_{2\sigma-1}^{(i_1)} & v_{2\sigma-1}^{(i_2)} & \dots & v_{2\sigma-1}^{(i_\gamma)} \\ \vdots & \vdots & \ddots & \vdots \\ v_{\tau-1}^{(i_1)} & v_{\tau-1}^{(i_2)} & \dots & v_{\tau-1}^{(i_\gamma)} \end{pmatrix} \quad (13)$$

Также определим:

$$Q = (f_{N-\sigma+2}^{(1)}, \dots, f_N^{(1)}, \dots, f_{N-\sigma+2}^{(2)}, \dots, f_N^{(2)}, \dots, f_{N-\sigma+2}^{(s)}, \dots, f_N^{(s)})^T \quad (14)$$

Тогда прогнозируемое значение в точке  $N + 1$  вычисляется по формуле:

$$f_{N+1} = w(V_*^T V_*)^{-1} V_*^T Q \quad (15)$$

### Заключение

Был проведен обзор существующих методов моделирования и прогнозирования отказов оборудования, определены достоинства и недостатки этих методов. Определены наиболее подходящие методы для решения задачи.

### Перечень источников

- [1] Хеннан Э. Многомерные временные ряды [Текст]. / Э. Хеннан. // М.: Мир, 1974. – 576 стр.
- [2] Большаков А.А. Методы обработки многомерных данных и временных рядов [Текст] / А.А. Большаков, Р.Н. Каримов. Учебное пособие для вузов // М.: Горячая линия - Телеком, 2007. – 522 стр.

- 
- [3] Nason G.P. The stationary wavelet transform and some statistical applications. [Text] / G.P. Nason, B.W. Silverman // N.Y.: Springer, 1995. – 464 p.
- [4] Шибалкин А.А. Прогнозирование временных рядов с использованием многослойных нейронных сетей и вейвлет-преобразований [Текст] / А.А. Шибалкин, М.В. Марковский // М.: Научная сессия МИФИ – 2008, т.11.
- [5] Загоруйко Н.Г. Прикладные методы анализа данных и знаний [Текст]. – Н.Г. Загоруйко // Новосибирск: ИМ СО РАН, 1999. – 270 стр.
- [6] Прогнозирование временных рядов методом SSA. [Электронный ресурс] / Интернет-ресурс. – Режим доступа: [http://www.machinelearning.ru/wiki/index.php?title=Прогнозирование\\_временных\\_рядов\\_методом\\_SSA\\_\(пример\)](http://www.machinelearning.ru/wiki/index.php?title=Прогнозирование_временных_рядов_методом_SSA_(пример)). – Загл. с экрана.
- [7] The simplest Singular Structure Analysis forecasting algorithm. [Electronic resource] / Интернет-ресурс. – Режим доступа: [http://strijov.com/demo\\_ssa\\_forecast.php](http://strijov.com/demo_ssa_forecast.php). – Загл. с экрана
- [8] Метод гусеницы [Электронный ресурс] / Интернет-ресурс. – Режим доступа: <http://www.gistatgroup.com>. – Загл. с экрана.