

УДК 620

## МОНИТОРИНГ СЛОЖНЫХ ОБЪЕКТОВ ПО ТЕХНИЧЕСКОМУ СОСТОЯНИЮ

**В. Л. ВЕНГРИНОВИЧ**

ГНУ «Институт прикладной физики НАН Беларуси»

Минск, Беларусь

UDC 620

## CONDITION BASED MONITORING OF COMPLEX OBJECTS

**V. L. VENGRINOVICH**

### **Аннотация**

Исследованы проблемы анализа больших данных и оценки состояния конструкций в задаче мониторинга технического состояния сложных технических сооружений с помощью многосенсорных систем, измеряющих текущие параметры объекта. Задача сводится к идентификации (восстановлению) свойств объекта по измеряемым его характеристикам. Взаимосвязь временных свойств объекта и системы мониторинга определяется на этапе предварительного моделирования, для чего используются все алгоритмы моделирования от Метода Монте-Карло до RBF (радиальные базисные функции). Сущность обратной задачи идентификации рассмотрена на примере восстановления напряжений в любой точке металлической оболочки, на которой расположено разреженное множество датчиков напряжений. Для оценки данных мониторинга предложен фрактальный метод, который позволяет на каждой стадии мониторинга работать с квадратными матрицами, все характеристики которых легко вычисляются. Выделены статистически значимые параметры фракталов, обладающие необходимыми чувствительностями к малым изменениям параметров объекта.

### **Ключевые слова:**

мониторинг по состоянию, многосенсорные системы, идентификация свойств.

### **Abstract**

Big data analysis problems are investigated having the goal to estimate current condition of a complex structure with the help of multi-sensor system by measuring current parameters of an object. The task is reduced to identification (reconstruction) of critical object parameters controlling object safety. Interdependence of a object parameters and monitoring system are determined on the stage of modeling, any modeling algorithms, from Monte-Carlo to RBF (Radial Basic Functions) are available for this. The principle of solving the inverse identification problem is considered using the example for stress values reconstruction in any point of metallic hull, using stress data from sparsely located stress measuring sensors. To estimate object properties from monitoring data the fractal approach is proposed, giving start to use at any monitoring stage to use square matrixes, which characteristics are easily calculated/ The statistically meaningful fractal parameters are separated, which have maximum sensitivity to small changes in object's parameters.

### **Key words:**

condition monitoring, multi-sensors systems, properties identification.

Достижения последних лет в области неразрушающего контроля, сенсорики, обработки данных, передачи информации, информатики позволяют перейти к следующим этапам безопасной эксплуатации сложных технических объектов (СТО): мониторингу технического состояния (МТС) и прогнозированию остаточного ресурса (ПОР). К СТО можно отнести здания и сооружения, средства передвижения (летательные аппараты, суда, автомобили), мосты, электростанции и пр. Эти направления (МТС и ПОР), следовательно, находятся на стыке упомянутых прикладных ресурсов. Основной работы МТС и ПОР служат периодически считываемые показания датчиков, установленных на СТО, их математическая обработка и принятие решения о дальнейшей эксплуатации объекта. Эти задачи в комплексе определяют функциональное назначение системы МТС.

Для примера рассмотрим СТО в виде крупного строительного сооружения (например, высотного здания), для которого необходимо знание его технического состояния в любой момент времени. Здание оснащено установленной на нем системе различных датчиков состояния: деформаций-напряжений, углов наклона, ускорений отдельных узлов здания, базовых расстояний на объекте, датчиков скорости и направления ветра, положения опорных свай и пр. Данные поступают непрерывно, как правило в матричном виде, в обрабатывающий компьютер. Из-за их большого объема из этих данных выделяются их характерные признаки (ХПД), которые сравниваются с некоторыми характерными признаками объекта (ХПО), на основе заранее установленных алгоритмов принимаются решения о дальнейшей эксплуатации. На этом пути надо преодолеть много неопределенностей, задача не относится к классу детерминированных, и в конечном итоге состояние объекта может быть оценено с некоторой вероятностью. Кроме того задачи выбора номенклатуры и количества датчиков, а также характерных признаков данных и признаков состояния объекта относятся к статистическим задачам оптимизации. В действительности надо учесть еще разнообразие СТО, каждый из которых требует своего набора как датчиков, так и способов обработки данных. На рис. 1 показано схематически взаимодействие СТО и системы МТС. На этапе оценки состояния ТО производится сравнение признаков этих систем, причем даже процедура выбора признаков является во многом субъективной.



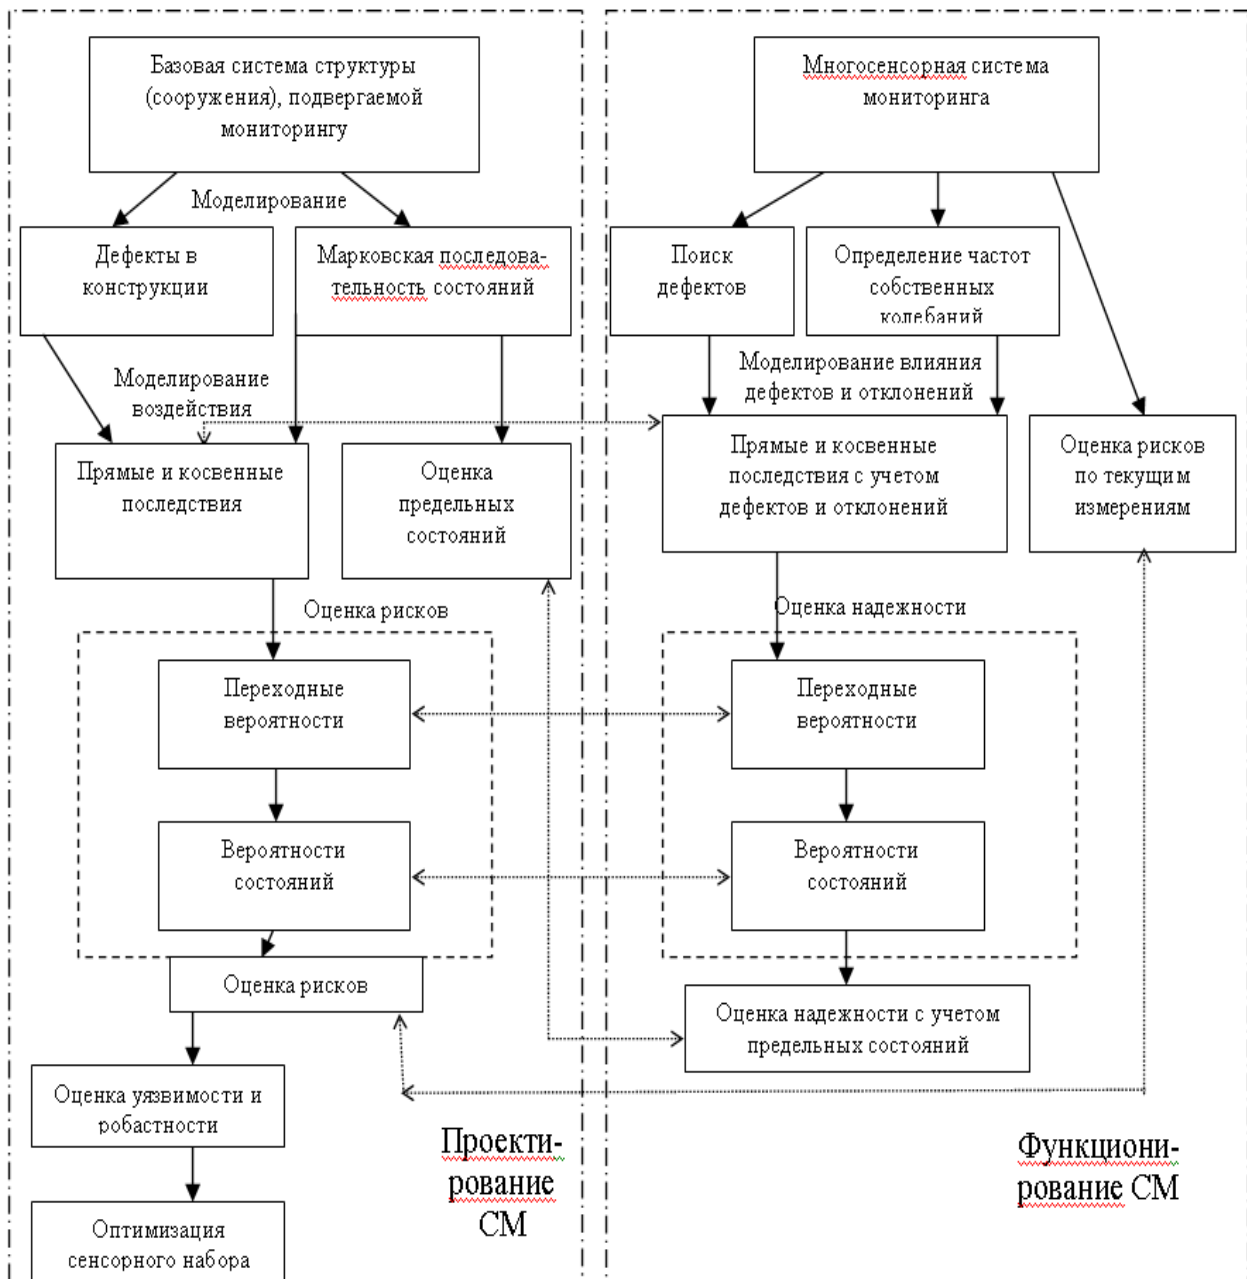


Рис. 1. Структура технического объекта (слева) и Система мониторинга этого объекта

Так на рис. 2 показан пример выходных данных 10-и сенсорной системы мониторинга, представленной в матричном виде.

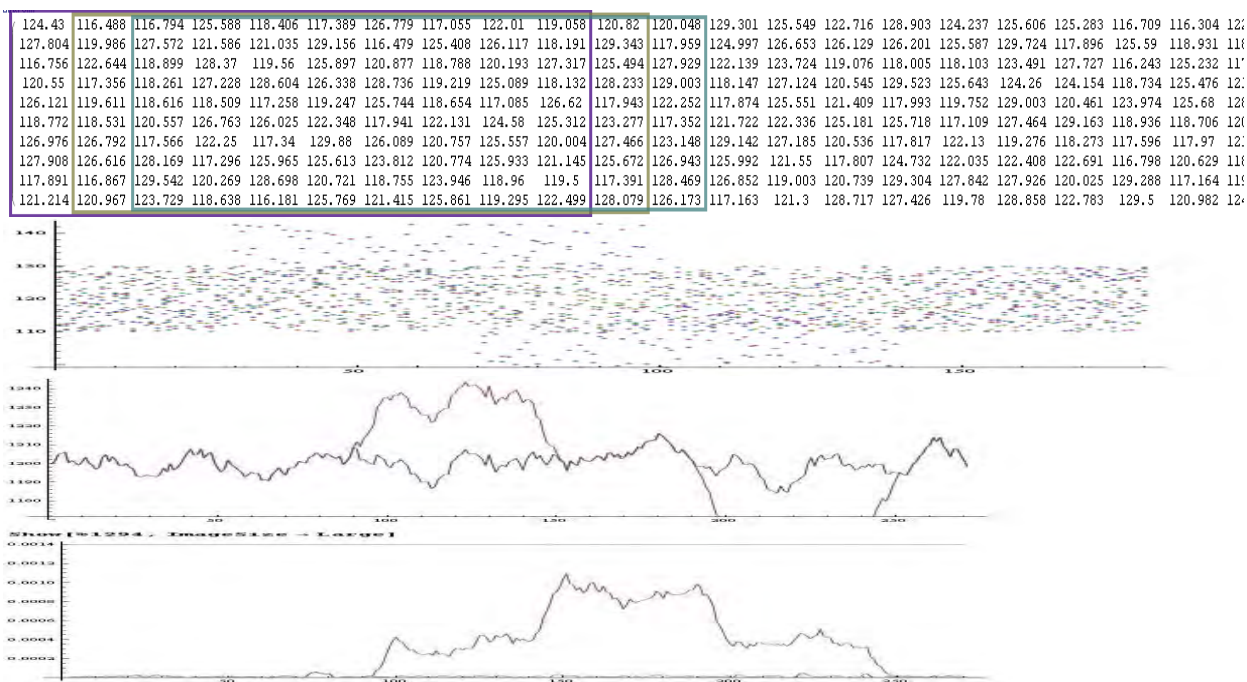


Рис. 2. Матричное представление данных 10-и сенсорной системы мониторинга: сами данные; изменение 1-го собственного значения фракталов, выделенных на 1-м рис.; изменение 1-го собственного вектора значений сверху (сверху вниз)

Выделенные признаки системы мониторинга (СМ) выбираются из условия их значимых изменений при незначительных изменениях данных измерения, которые, в свою очередь, измеряются с определенной ошибкой. Процедура фильтрации сильно зависит от модели процесса, которая для СМ наиболее близко соответствует марковской цепи.

Назначению признаков СТО предшествует большая работа по исследованию СТО. Вот несколько примеров уже изученных систем: повреждение обмоток статоров двигателей – электрический дисбаланс; устойчивость высотных сооружений – частота их собственных колебаний; большие подшипники – гранулометрический состав масла в подшипнике; коррозионные повреждения под изоляцией – спектр электрического высокочастотного импеданса; напряженное состояние металлических башен – величина магнитных параметров вблизи специальных отверстий в башне; целостность турбинных лопаток – изображение картинок промышленной рентгеновской томографии; дефекты в трубопроводах – разность сигналов высокочастотных направленных акустических волн; целостность роторов больших электрических машин – разность сигналов акселерометров, введенных в ротор; целостность мостов балочного типа – эксцентриситет несущей балки моста; функциональность газовой турбины – состав газов на выхлопе. Приведенный список дает представление о многообразии типов повреждений и способов их выявления физическими параметрами. В качестве детектирующих параметров могут также быть набор локальных деформаций, коэффициенты корреляций соседних датчиков деформаций, изменение характерных размеров и многое другое. Иногда применение мето-

дов выявления дефектов требует остановки объекта, например, методы рентгеновской томографии, хотя и в этом направлении наметился прогресс, в частности, томография процессов.

С методами оценки функциональности объекта тесно связаны номенклатура и число устанавливаемых на объект датчиков. Наиболее широкое применение получили датчики деформаций-напряжений (магнитные, оптоволоконные, тензометрические, электрические), индикаторы трещин (вихретоковые, капиллярные, магнитные), инклинометры, акселерометры, виброметры, инфракрасные термографы, газоанализаторы. Как правило, сигналы датчиков, включенных в СМ, подвергаются мощной математической обработке, чтобы выделить из них характерные признаки объекта: нарушение целостности, дисбаланс, расстояние до механического резонанса, коррозионные и усталостные повреждения, зоны концентрации напряжений, частоты собственных колебаний и пр.

Сегодня уже как минимум три инженерных сообщества поставили МТС во главу своей работы в области технического диагностирования. В первых – это Structural Health Monitoring (SHM) сообщество, которое будет проводить уже 9-ю международную конференцию по SHM и ряд других событий, например 18ю SPIE Conference on Smart Structures and Nondestructive Evaluation в США. В США также создано научно-техническое общество PHM (Prognosis and Health Management), научным ресурсом которого также являются мониторинг технического состояния и неразрушающий контроль. Наконец, в 2017 г. создано международное Общество СМ (мониторинг по техническому состоянию), первый Всемирный конгресс которого был проведен в июне 2017 г. в Лондоне. Наблюдается растущий интерес специалистов к переходу от контроля единичных дефектов к оценке непосредственно состояния больших технических систем. Наиболее наукоемкая часть этого направления состоит в обработке больших данных на выходе систем МТС и установление их корреляции с признаками деградации объекта.

В процессе эксплуатации в элементах СТО протекают физико-химические процессы (старение, ползучесть, возникновение зон концентрации напряжений (ЗКН), трещин, диффузионные процессы, изменение структуры материала, коррозия, износ, усталость, старение из-за воздействия температуры или химических реакций и т. п. Эти изменения в конструкции являются медленными и необратимыми. Они определенным образом зависят от времени. Их часто называют квазидетерминированными или полуслучайными. Они поддаются моделированию, наиболее распространенной формой модели принята модель вида:

$$\tilde{y}(t) = \sum_{j=0}^M a_{ij} \epsilon_j(t), i = \overline{0 \dots n} \quad , \quad (1)$$

где  $a_{ij}$  – случайные величины;  $\epsilon_j(t)$  – непрерывные детерминированные функции времени.

В формуле (1) есть разложение случайного процесса по детерминированному базису. Базисом могут быть степенные, экспоненциальные или

другие функции, близко описывающие протекающие в конструкции процессы. В большинстве практических ситуаций порядок модели не превышает 2.

Случайная обратимая составляющая обусловлена флуктуациями температуры, давления, влажности, силы ветра, или другой механической нагрузки, или даже радиации. Это обратимая составляющая, дестабилизирующая воздействие на конструкцию. С учетом всех воздействий случайный процесс дрейфа параметров СТО можно записать в виде:

$$y(t) = \tilde{y}(t) + F(t), \quad (2)$$

где  $\tilde{y}(t)$  – нестационарный необратимый процесс с большой постоянной времени;  $F(t)$  – стационарный случайный процесс обратимых изменений параметров под воздействием внешних условий, как правило, с малой постоянной времени.

Предполагается, что оба процесса статистически независимы, имеющие автокорреляционные функции разного порядка. Необратимая составляющая может иметь как монотонный, так и импульсный характер, например, монотонный процесс коррозии и скачкообразное возникновение трещин соответственно.

Процесс необратимых изменений близок к марковскому процессу, так как логично предположить, что вероятность перехода в новое состояние зависит от самого состояния и не зависит от предыдущих переходных вероятностей (процесс без последствия). Это допущение дает хорошую базу для моделирования необратимого процесса. Значительно облегчается возможность применения для моделирования таких методов, как RBF-метамоделирование, метода Монте-Карло, методов анализа надежности различных порядков и способов анализа причинно-следственных связей, например регрессионного. Методы нелинейного метамоделирования результатов численных экспериментов обеспечивают непрерывное представление результатов моделирования, оценку точности и быструю интерполяцию больших объемов данных.

В БСО вектор, описывающий состояние опасности  $A_r = \{A_k^r\}$ , где  $r$  – индекс состояния системы, которое может появиться под влиянием извне или изнутри;  $k$  – номер элемента системы. Система МТС отображает состояние опасности текущим набором показаний группы датчиков  $B_q = \{B_i^q\}$ , где  $q$  – индекс результата измерения данным датчиком;  $i$  – номер датчика. Цель обратной задачи заключается в минимизации условной вероятности идентификации состояния риска  $A_r$  по  $B_q$  состояниям измеренных данных,  $(P(A_r | B_q))$ , что является типичной байесовской проблемой [1]:

$$P(A_r | B_q) = \frac{P(B_q | A_r)P(A_r)}{P(B_q)}, \quad (3)$$

где  $P(B_q | A_r)$  – условная вероятность получения определенного набора данных измерения при наличии состояния риска повреждения;  $P(A_r)$  –

априорная вероятность риска повреждения;  $P(B_q)$  – некая глобальная вероятность получения данных измерения.

Целью обратной задачи является максимизация условной вероятности идентификации состояния риска  $A_r$  по данным измерения  $B_q$ , что не противоречит условию минимизации ее отрицательного значения ( $\min - P(A_r | B_q)$ ), что является типичной Байесовской задачей минимизации [2]:

$$\min: -\log P(A_r | B_q) = -\log P(B_q | A_r) - \alpha \log P(A_r): \{A_r \in R^k\}, \quad (4)$$

где  $\alpha$  – коэффициент регуляризации.

В случае функциональной корреляции между данными измерений и искомым уровнем риска при Гауссовском распределении ошибки измерений, первый член правой части уравнения (2) можно рассматривать в качестве нормы измеряемых и искомых данных, соответственно, так что решение (2) может быть представлено следующим уравнением:

$$\tilde{A}_r = \arg \min \left\{ \left\| B_q^{meas} - B_q^{calc} \right\| + \alpha \log P(A_r) \right\}: \{A_r \in R^k\}, \quad (5)$$

где индексы *meas* и *calc* означают соответственно измеренные данные и данные, полученные на основании расчета в соответствии с моделью взаимодействия СМС и БСО.

В соответствии с уравнением (5),  $B_q^{meas}$  является вектором измеренных значений,  $B_q^{calc}$  вектором расчетных модельных данных. Априорная вероятность  $P(A_r)$  может быть выражена в виде функционала, поддерживающего, например, гладкость, положительность, тотальную вариацию и другую качественную информацию о возможных рисках повреждения. Например, если производится поиск критических напряжений в конструкции, то моделирование распределения напряжений может быть выполнено в рамках теории упругости. Описанный способ минимизации в принципе возможен, но требует огромных вычислительных затрат и не пригоден для предсказания повреждений в сложных объектах в режиме реального времени.

В то же время из приведенного анализа следуют необходимости:

- а) ситуационного моделирования взаимодействия моделей СТО и МТС;
- б) повышение точности измерений;
- в) определение нулевого состояния начала минимизации.

Последнее означает, что стабильность минимизации легче обеспечивается, когда начинается с какого-то ранее прогнозируемого уровня. Также необходимость предварительной оценки априорной вероятности состояния опасности и значение коэффициента регуляризации следуют из рассмотрения члена  $\alpha \log P(A_r)$ .

Другими словами, в целом необходимо увеличить вероятность измеренных данных с некоторой качественной штрафной функцией на поведение переходной функции распределения плотности вероятности, обеспечивающей, например, гладкость, положительность, тотальную вариацию, и

т. п., что является типичной Баесовской задачей минимизации [1, 2]. Это уравнение дает только общую характеристику взаимодействия СМС и БСО. По сути это уравнение устанавливает лишь роль моделирования и априорной информации для прогнозирования отказов и повреждений в объекте по данным измерения ограниченным набором сенсоров.

Так как размерность вектора  $B_q = \{B_i^q\}$  слишком велика по сравнению с размерностью вектора  $A_r = \{A_k^r\}$ , восстановить картину повреждений объекта по данным матрицы измерений очень сложно. Эта ситуация похожа на ту, которую Donoho [3] назвал "проклятием" больших данных. Преодоление этого ограничения возможно на пути уменьшения размерности исходных данных, иными словами, путем перехода к выделению некоторых признаков данных, или атрибутов, ассоциированных с векторами  $A_r = \{A_k^r\}$ . Пусть  $X_j$  ( $J = 1, 2 \dots J$ ) будет ограниченный набор признаков (статистических переменных объекта), извлеченных из измеренных данных и определяющих его новый образ объекта. Чтобы предсказать ожидаемое будущее объекта, связанное с данными измерений  $B_q = \{B_i^q\}$ , необходимо определить функцию  $A_r = F(X_j)$ , используя соответствующие инструменты моделирования. Данная формулировка модели означает переход от  $j$ -пространства новых скрытых переменных, соответствующих измеренным данным к  $k$ -мерному пространству сценарий опасных состояний объекта.

Много важных особенностей множества данных измерения может быть учтено в матричном формате  $U \times W$  массива:  $X_{j,m}$ ;  $1 < j < U$ ,  $1 < m < W$ , где ряды – математически выраженные атрибуты объекта, а колонки – субъекты одного признака. Новый подход включает в себя использование истории мониторинга (архив) для предсказания приближительной численной модели объекта. Также могут быть использованы следующие известные алгоритмы.

1. Линейный и нелинейный регрессионные анализ  $a_m = \sum_k b_k (1 - d_{k,m}) + \eta_m$ .
2. Методы главного и независимого компонентных анализов, PCA и ICA соответственно, в качестве способов снижения размерности и реализации корреляционного анализа матрицы.
3. Метод быстро рассчитываемых метамоделей с помощью радиальных базисных функций:  $f(A) = \sum_{i=1}^N q_i \phi((X - X_i))$ , который зависит только от евклидова расстояния между двумя переменными.

Вопрос поиска значимых параметров изменяющейся во времени матрицы результатов измерений также представляет значительные трудности. Разработан так называемый фрактальный метод, который позволяет использовать численные стохастические методы анализа одинаковых матриц во времени. Сущность его представлена на рис. 3. Для описания второго метода обработки больших данных представим выходные данные в системе СМС в виде прямоугольной матрицы  $B_q = \{B_i^q\}$ , в которой в каждой из колонок присутствует вектор  $B_i^q$ , а в каждом из рядов – вектор  $B_j^q$ , где  $I$  –

число сенсоров, а  $Q$  – число одновременных измерений всеми сенсорами, причем, по определению

$$B_q = \begin{pmatrix} B_1^1 & \dots & B_1^Q \\ \vdots & \ddots & \vdots \\ B_I^1 & \dots & B_I^Q \end{pmatrix} \quad (6)$$

Во многих СМС к матрице (6) для оценки риска и степени опасности применяется так называемый пороговый анализ, причем, опасность идентифицируется, когда показания одного из сенсоров превышают некоторое предельное значение, например, напряжения, угол наклона, расстояние и др., заданные разработчиком проекта объекта. В то же время, во многих СМС, в процессе мониторинга изменения в элементах матрицы (6), даже в состоянии приближающегося отказа  $A$ , любого из элементов, свободного от сенсоров, обычно намного ниже, чем предельные значения. Таким образом, они остаются «незамеченными» при автоматическом пороговом наблюдении за данными мониторинга.

Для пояснения рассмотрим произвольно нагруженную оболочку (рис. 3), разбитую на ячейки, причем, наблюдение за распределением напряжений в ячейках проводится датчиками в ограниченном числе ячеек (заштрихованы). Распределение напряжений в ячейках достаточно сложное и может быть рассчитано с помощью известных инженерных инструментов в рамках теории упругости. Ясно, что в общем случае в ячейках, в которых сенсоры отсутствуют, невозможно идентифицировать наступление опасных ситуаций с помощью порогового метода по данным рассредоточенной сети сенсоров в заштрихованных ячейках.

Заметим, что в нашем примере значения в рядах матрицы (4) – это результаты (нормализованные) последовательных измерений  $i$ -ым сенсором, а значения в колонках – результаты измерений соответствующим сенсором в  $q$ -ый момент времени.

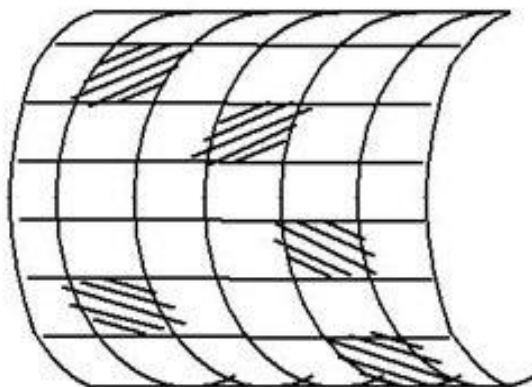


Рис. 3. Схема нагруженной оболочки, разбитой на ячейки. Датчики напряжений расположены в заштрихованных ячейках. По данным измерений в них подлежат определению напряжения в светлых ячейках



Пусть член  $B_i^q$  – значение напряжения в заштрихованной ячейке. Вопрос: имея в распоряжении матрицу  $B_i^q$ , что выбрать в качестве признака (атрибута) риска (под риском здесь понимается, например, величина напряжения, близкая к пределу текучести) в любой точке оболочки, включая ячейки, не содержащие сенсоров? Ответ не так прост и не может быть дан только посредством решения обратной задачи теории упругости по результатам ограниченных в пространстве данных измерения. Например, ясно, что единичные выбросы сигналов отдельными датчиками не обязательно означают возникновение опасной ситуации в конструкции, а могут быть просто сбоем в электронной системе. Поэтому прежде необходимо определить атрибуты состояния опасности оболочки. Последние могут включать в себя показания также группы сенсоров. Определение атрибутов может быть сделано на этапе моделирования опасных ситуаций. В процессе моделирования для вычисления переходных вероятностей,  $\{P(A_r|B_q)\}$ , вводится понятие атрибута опасного состояния,  $X_j$ . В общем случае в качестве инструментов для установления статистического соответствия  $(A_r|X_j|B_q)$  могут быть использованы: регрессия, классификация, анализ главных компонент (РСА), анализ независимых компонент (ІСА), кластеризация (облака), конструирование метамоделей и др. [3]. Общим свойством всех этих инструментов является обработка всех матричных данных целиком. Рассмотрение полной матрицы за продолжительный период времени – это и преимущество и недостаток одновременно, причем, недостаток состоит в игнорировании локальных свойств прямоугольной ( $I \neq Q$ ) матрицы при последовательном ее заполнении со временем, что требует непрерывного сопоставления текущих и предшествующих данных и оперирования каждый раз с очень большими объемами данных. При этом также не используется возможность извлечения многих дополнительных признаков, которые могут быть получены при оперировании квадратными матрицами. Использование последних предусмотрено алгоритмом, предлагаемым ниже.

Для этого выделим в матрице (4) первые  $Q_a = I$  колонок. Получим  $I \times Q_a$  квадратную матрицу. Обратимся к статистическим атрибутам подобных  $I \times Q_a$  матриц, получаемых путем одношагового сдвига исходной квадратной матрицы по мере заполнения прямоугольной матрицы в процессе измерений при мониторинге. Назовем такую смещающуюся матрицу «движущимся фракталом». Общее число возможных сдвигов для получения набора квадратных матриц составляет  $2(Q - I + 1)$ . Можно было бы продолжать дробить квадратные матрицы на меньшие составляющие с целью вычисления ее фрактальных характеристик, однако ограничимся пока свойствами матриц размерности  $I \times Q_a$ . Для этого рассчитаем ее первые собственные значения  $E_j$ , и первые значения собственных векторов  $V_j$ , соот-

ответственно. На выходе процесса мониторинга таким способом образуется двухрядная матрица  $X_{j,2}(t)$ , которая сопоставляется с предварительно генерированной на этапе моделирования матрицей  $\tilde{X}_{j,2}(t)$  для оценки состояния риска. Другие статистические атрибуты состояния объекта мониторинга, полученные с помощью традиционных методов обработки PCA, ICA, и др. также могут быть использованы для статистического описания характеристик квадратной матрицы.

Рис. 2 иллюстрируют применение описанного выше анализа. В двух кластерах значения показаний в среднем соответственно на 10 % выше и ниже среднего по матрице. От пороговых значений величины в матрицах еще далеко, а имеющиеся отклонения могут быть связаны с небольшими изменениями значений искомого параметра (например, напряжений), в близлежащих ячейках. Исходная матрица 10x280 заполнялась случайными числами в диапазоне 110÷130. В 1 и 3 рядах случайные числа в среднем на 10 % превышали средние по матрице, начиная с 30-ой до 100-ой колонок, а в рядах 7 и 9 были ниже средних на 10 % в диапазоне колонок 70–130. Сверху показана матрица в виде точечной диаграммы, а снизу – в цифровом виде. Изображенные на рис. 2 выбросы значений матрицы показаны без привязки к их плотности, происхождению, коэффициенту корреляции, и, в конечном итоге, они не могут идентифицировать наличие "дефекта", чтобы оценить вероятность перехода объекта в состояние "повреждения" или отказа. Часто этот недостаток является критическим, например, при необходимости принятия срочного решения, пока объект еще эксплуатируется. Задача распознавания "дефекта" становится еще более проблематичной при оценке ситуации по среднему значению фрактала. Видно, что изменения средних значений находятся в пределах колебаний шума и не дают возможности адекватно идентифицировать дефектные зоны. Мы реализовали также PCA анализ этих данных в рамках большой прямоугольной матрицы и в рамках "движущегося фрактала". Последний дает возможность идентифицировать дефектную зону с помощью наблюдения за динамикой изменения первых собственных значений и первых значений векторов фракталов (в нормализованном виде), а также оценкой корреляционных матриц. Из-за большого объема выходных данных мы не иллюстрируем тот факт, что традиционный PCA полной прямоугольной матрицы не может быть задействован для системы мониторинга, тогда как на выходе PCA в рамках концепции фракталов получаем ограниченное число статистических атрибутов для добавления к образу объекта.

Наибольшую информацию представляет динамика поведения первых элементов собственных векторов, показанная на рис. 5. Желтая кривая четко идентифицирует дефектные зоны на фоне бездефектной области. Величина превышения выражает степень дефектности. Недостатком оценки образа дефектности объекта собственных значений векторов является игнорирование знака отклонений, но он легко компенсируется путем дополни-

тельных анализа полной матрицы значений, как на рис. 5, или первых собственных значений (не показаны). Путем добавления ограниченного числа статистических атрибутов, полученных из анализа "движущихся фракталов" данных мониторинга возможно формирование сколь угодно сложного образа объекта.




Рис. 5. Первые значения собственных векторов: "дефектная" матрица – желтый цвет; исходная матрица – синий цвет

Одним из параметров, описывающим поведение системы в нашем случае, может быть сумма модулей действительных значений компонент первого собственного вектора фрактала. Этот параметр неплохо описывает поведение средних, вокруг которых «меняются» переменные (рис. 6).




Рис. 6. Сумма модулей действительных значений компонент первого собственного вектора фрактала

Для примера на рис. 7 показано изменение параметра «средние значения фракталов». Из этого графика видно, что данный параметр не представляет интереса в качестве значащего, т. к. он не реагирует на значимые изменения показаний во фракталах.




Рис. 7. Средние значения показаний в столбцах: "дефектная" матрица – желтый цвет; исходная матрица – синий цвет

Весьма информативным может служить PCA анализ фракталов, в частности, корреляционная матрица Пирсона (КМП), которая табулирует коэффициенты корреляции данных отдельных пар (или большего количества) датчиков. Понятно, что, если между показаниями близко лежащих датчиков коэффициенты корреляции (КК) близки к 1, т. е. опасность того, что конструкция в целом реагирует на опасные воздействия (например, снежный покров на крыше), в отличие от ситуации, когда КК соседних пар показаний не коррелируют. В табл. 1 показана парная КМП различных пар датчиков, построенная по реальным данным показаний 8-и датчиков деформации на одном из уровней несущего кольца кровли комплекса «Минск-Арена».

Табл. 1. Correlation matrix (Pearson)

Variables	A	B	C	D	E	F	G	H
A	<b>1</b>	0,709	0,674	0,763	<b>0,987</b>	<b>0,954</b>	0,564	0,747
B	0,709	<b>1</b>	0,235	0,286	0,765	0,836	0,273	0,220
C	0,674	0,235	<b>1</b>	<b>0,971</b>	0,645	0,596	<b>0,946</b>	0,971
D	0,763	0,286	<b>0,971</b>	<b>1</b>	0,732	0,659	0,880	<b>0,992</b>
E	<b>0,987</b>	0,765	0,645	0,732	<b>1</b>	<b>0,964</b>	0,541	0,709
F	<b>0,954</b>	0,836	0,596	0,659	<b>0,964</b>	<b>1</b>	0,541	0,633
G	0,564	0,273	<b>0,946</b>	0,880	0,541	0,541	<b>1</b>	0,862
H	0,747	0,220	<b>0,971</b>	<b>0,992</b>	0,709	0,633	0,862	<b>1</b>

Желтым цветом выделены КК, превышающие значения 0,9. Если принять за критерий опасности КК соседних датчиков, из обозначенных желтым пар опасность представляют высокие КК датчиков С-D и F-E. Следует сказать, что для установления значимости этого критерия требуется провести большую работу по ситуационному моделированию опасных ситуаций

кольца, которые могут привести к последовательному обрушению конструкции.

### Заключения

1. Изучена способность автоматической СМС конструкций предсказывать наступление в последней стадии повреждения или отказа по данным многосенсорных измерений, представленных в матричном виде.

2. Предлагается метод автоматического слежения за изменением матричных данных, возникающих на выходе много сенсорной системы, широко используемой для мониторинга состояний таких объектов, как высотные здания, мосты, электростанции и т. п.

3. Идентификация дефектных зон ограниченным набором атрибутов объекта реализуется путем автоматического выделения статистических параметров фракталов, представляющих из себя квадратные матрицы размером в число рядов исходной прямоугольной матрицы, перемещающиеся дискретно в процессе мониторинга. Предлагаемый метод анализа больших матричных данных на выходе автоматических СМС, названный методом «движущегося фрактала», демонстрирует более эффективную способность распознавания дефектных областей в объекте, подвергающемся мониторингу, чем простейший пороговый метод, или другие статистические методы, оперирующие полным набором измеренных данных.

4. При дальнейшем развитии этого метода предстоит оценка количественного соответствия между типом и степенью дефектности, с одной стороны, и атрибутами объектов, полученными с помощью статистического анализа "движущихся фракталов", с другой. Ясно, что допустимые величины статистических атрибутов должны оцениваться на этапе проектирования и ситуационного моделирования поведения объекта, принимая во внимание допустимость всех прямых и косвенных последствий после небольших повреждений в конструкции. Наша первая практика показывает, что новая техника также дает возможность детектирования скрытых дефектов на ранних стадиях повреждения.

### СПИСОК ЛИТЕРАТУРЫ

1. **Donoho, D.** High-Dimensional Data Analysis: The Blessings and Curses of Dimensionality. Mathematical Challenges of the 21st Century, Stanford University, <http://www-stat.stanford.edu/~donoho>, 52.

2. **Skilling, J.** Probabilistic data analysis: an introductory guide / J. Skilling // Journal of Microscopy. – 1998. – Vol. 190, Pts.1/2. – P. 28–36.

3. **Vengrinovich, V. L.** Bayesian Image and Pattern Reconstruction from Incomplete and Noisy Data / V. L. Vengrinovich // Tutorial. Int.J., "Pattern Recognition and Image Analysis". – 2012. – Vol. 22, No. 1. – P. 99–107.