

DOI: 10.5862/JCSTCS.224.6

УДК 681.51

*А.П. Козионов, А.Л. Пяйт, И.И. Мохов, Ю.П. Иванов*

## **АЛГОРИТМ ОБНАРУЖЕНИЯ АНОМАЛЬНОГО СОСТОЯНИЯ ДАМБЫ НА ОСНОВЕ ВЕЙВЛЕТ-ПРЕОБРАЗОВАНИЯ И ОДНОКЛАССОВОЙ КЛАССИФИКАЦИИ ОДНОМЕРНЫХ СИГНАЛОВ**

*A.P. Kozionov, A.L. Pyayt, I.I. Mokhov, Yu.P. Ivanov*

## **AN ALGORITHM FOR DETECTING ABNORMAL DIKE STATE BASED ON WAVELET TRANSFORM AND ONE-CLASS CLASSIFICATION OF ONE-DIMENSIONAL SIGNALS**

Мониторинг состояния земляных дамб — важная и актуальная задача. Одним из ключевых составляющих системы мониторинга состояния дамб являются алгоритмы обнаружения аномального поведения дамб. Алгоритмы должны в режиме онлайн определять аномальное поведение дамбы по сигналам с аппаратуры контроля. Представлен алгоритм на основе метода машинного обучения обучающийся на исторических данных о нормальном состоянии дамбы, так как данные об аномальном состоянии дамбы недоступны, а моделирование высокочастотно. Обнаружение аномального поведения дамбы производится методом одноклассовой классификации «нейронные облака». «Нейронные облака» оценивают нелинейной, нечеткой функцию принадлежности результатов вейвлет-преобразования сигнала к области нормального поведения. Применение вейвлет-преобразования позволяет обнаружить аномальное поведение дамб, скрытое в частотно-временных свойствах сигнала. Апробация алгоритмов проведена на реальных данных дамбы, расположенной в городе Бостон, Великобритания.

**ОБНАРУЖЕНИЕ АНОМАЛИЙ; МОНИТОРИНГ СОСТОЯНИЯ ДАМБ; ИНТЕЛЛЕКТУАЛЬНАЯ ОБРАБОТКА СИГНАЛОВ; ВЕЙВЛЕТ-ПРЕОБРАЗОВАНИЕ; НЕЙРОННЫЕ ОБЛАКА; ОДНОКЛАССОВАЯ КЛАССИФИКАЦИЯ.**

Dike conditions monitoring is a challenging task. Algorithms for dike anomaly detection are one of the key components of a dike condition monitoring system. Algorithms for anomaly detection have to detect anomalies in dike behaviour (abnormal behaviour) in an on-line mode based on measurements collected from sensors installed in the dike. A machine-learning-based algorithm presented in this paper is trained on historical data on the normal dike state because data for abnormal dike behaviour is not available and simulation is time-consuming. Detection of abnormal dike behaviour is done by applying a 'neural clouds' one-class classification method. The 'neural clouds' one-class classifier is used for estimating the nonlinear fuzzy membership function of normal behavior for features from wavelet decomposition. The application of a wavelet transform can detect abnormal dike behaviour hidden in the time-frequency signal properties. Algorithms were tested on real data of a dike located in Boston, United Kingdom.

**ANOMALY DETECTION; DIKE CONDITIONS MONITORING; INTELLIGENT SIGNAL PROCESSING; WAVELETS; NEURAL CLOUDS; ONE-CLASS CLASSIFICATION.**

В настоящее время более чем две трети европейских городов постоянно находятся под риском затопления. Число зарегистрированных наводнений увеличилось в четыре раза по сравнению с восьмидесятыми годами XX века [1]. Изменение климата и быстрая урбанизация еще сильнее усугубляют проблему.

Большое количество наводнений вызвано прорывом систем защиты от наводнений: дамб и плотин [2]. Например, в Нидерландах с 1134 по 2006 гг. было зарегистрировано примерно 1735 случаев разрушения дамб [3]. В Европе существуют несколько проектов, направленных на исследование и разработку систем контроля защиты от наводнений: FLOODsite [4], FloodControl 2015 [5], UrbanFlood [6]. Одним из важнейших элементов подобных систем является система мониторинга состояния дамб.

Исторически мониторинг дамб осуществляется инспекторами, которые занимаются обходом тысяч километров дамб. Каждый участок дамбы проверяется один раз в несколько лет. Современные технологии позволяют осуществлять непрерывный мониторинг состояния дамбы с использованием технологий дистанционных измерений.

Проблема мониторинга состояния земляных дамб заключается в сложном поведении дамбы и, как следствие, измеряемых параметров системы, что требует детального исследования объекта мониторинга и моделирования большого числа возможных сценариев разрушения дамбы. Это дорого и не всегда возможно.

В данной статье мы представляем подход и алгоритм обнаружения аномального состояния земляных дамб. Предлагаемый подход основан на методах машинного обучения и обработки сигналов и не требует детального исследования объекта мониторинга. Обучение алгоритмов проходит на исторически измеренных данных нормального состояния дамбы. Настоящий подход и алгоритм разрабатывались для системы раннего предупреждения UrbanFlood [6]. Апробация алгоритма проводилась на данных с дамбы, расположенной в городе Бостон (Великобритания).

## Подход к обнаружению аномального поведения дамб

Мониторинг состояния дамбы осуществляется путем анализа измерений, собранных с сети различных датчиков, установленных в дамбу, таких как датчики порового давления (давление воды в порах почвы), инклинометров и температуры. Задача системы мониторинга – обнаружить аномальное состояние дамбы. Под аномальным состоянием (поведением) подразумевается отклонение от нормального состояния объекта, которое может привести к неисправности или разрушению дамбы [7]. Датчики устанавливаются в каждую кросс-секцию дамбы. Такое деление объекта мониторинга позволяет локализовать аномальное состояние и предоставляет избыточность измерений. Применение сетей датчиков как части системы раннего предупреждения в рамках проекта UrbanFlood описано в [8, 9].

Основная идея предлагаемого подхода заключается в применении методов обнаружения аномального поведения, обучающихся на «сырых» и/или предварительно обработанных данных [10, 11]. При этом данные системы контроля состояний дамб могут содержать пропуски, вызванные сбоями системы сбора данных и другими факторами. Такие пропуски могут иметь протяженность от нескольких минут до нескольких дней. Обнаружение аномального состояния состоит из трех этапов, представленных на рис. 1. Первый этап – сбор данных с датчиков. Второй этап – их предварительная обработка, в нашем случае восстановление пропусков в данных алгоритмом на основе метода авторегрессии [12]. На третьем этапе с помощью алгоритма обнаружения аномального состояния извлекается информация из сигналов методами частотно-временного анализа. Далее алгоритмы классификации, основанные на методах машинного обучения, определяют состояние дамбы.

Применение методов частотно-временного анализа обосновано тем, что сигналы с дамбы имеют ярко выраженные частотно-временные зависимости, вызван-




Рис. 1. Этапы обнаружения аномального состояния дамбы

ные влиянием внешних факторов (например, приливы и отливы и т. д.). В работе [13] оконное преобразование Фурье применялось для анализа горизонтального ускорения, полученного в процессе моделирования влияния землетрясения на земляную дамбу. В [14] вейвлеты применялись для анализа измерений температуры воды с Уивенхойской дамбы (Великобритания). Каждый сигнал был разложен с использованием вейвлет-преобразования на дневную, сезонную и годовую составляющие. Каждый уровень разложения использовался для дальнейшего анализа. Обзор возможных применений вейвлет-преобразования для задачи контроля целостности структур представлен в [15]. К примеру, вейвлеты применялись для обнаружения трещины в арке бетонной дамбы [16]. В [17] представлен анализ динамического поведения геотехнических структур для мониторинга землетрясения. Вейвлеты применялись для анализа поведения земляной дамбы. В [18] представлен анализ сейсмического поведения земляной дамбы. Один из результатов этой работы состоит в том, что устойчивость дамбы должна рассматриваться в анализе сейсмического отклика дамбы, т. к. это ведет к уменьшению амплитуд колебаний собственных частот плотины.

Поскольку для дамбы нередко доступны лишь данные о нормальном состоянии, классификацию состояния дамбы логично производить, оценивая степень принадлежности сигналов датчиков к некоей области нормального состояния. Для решения такой задачи применимы алгоритмы одно-

классовой классификации, основанные на оценке принадлежности сигнала к одному заданному классу. В нашем случае это область «исторических» измерений, соответствующих нормальному состоянию дамбы.

#### Дискретное вейвлет-преобразование

Вейвлет-преобразование (wavelet transform) — это метод частотно-временного (масштабно-временного, в терминологии теории вейвлетов) разложения сигнала. В отличие от преобразования Фурье вейвлет-преобразование позволяет анализировать только в частотной области [19]. Вейвлет-преобразование делят на два вида: непрерывное вейвлет-преобразование (НВП) и дискретное вейвлет-преобразование (ДВП).

НВП задано непрерывными вейвлет-функциями. Масштабы и время, на которых происходит разложение, изменяются непрерывно. Данное преобразование получило широкое применение в научных исследованиях [19].

ДВП задано семейством дискретных вейвлет-функций и применяется к дискретным сигналам. В случае ДВП масштабы (уровни разложения в терминологии ДВП), для которых происходит разложение, увеличиваются пропорционально степени двойки, а дискретизация каждого уровня разложения уменьшается в два раза по сравнению с предыдущим более высокочастотным уровнем разложения. У дискретного вейвлет-преобразования много приложений в естественных науках, инженерном деле, математике (включая прикладную).




Рис. 2. Каскадный алгоритм дискретного вейвлет-преобразования

Дискретное вейвлет-преобразование получают применением набора фильтров. Сначала сигнал пропускается через низкочастотный фильтр (масштабирующий фильтр). В результате чего получаются коэффициенты аппроксимации  $V$ . Одновременно сигнал пропускается через высокочастотный фильтр, который называется *вейвлет-фильтром*, в результате получаются вейвлет-коэффициенты  $W$ . Эти два фильтра связаны между собой и называются *квадратурными зеркальными фильтрами*. Так как половина частотного диапазона отфильтрована, то, согласно теореме Котельникова, отсчеты полученных сигналов можно прореживать в два раза. Это разложение можно повторить несколько раз для коэффициентов аппроксимации каждого последующего разложения. Данный каскадный алгоритм, предложенный Стефаном Малла [19], можно записать в следующем виде:

$$W_j = (h * V_{j-1}) \downarrow 2, \quad (1)$$

где  $W_j$  – вейвлет-коэффициенты ДВП, уровня разложения  $j$ ;  $V_{j-1}$  – коэффициенты аппроксимации уровня разложения  $j-1$ ;  $*$  – оператор полной свертки;  $\downarrow$  – оператор прореживания. Алгоритм проиллюстриро-

ван на рис. 2 ( $f_n$  – частота Найквиста).

Коэффициенты аппроксимации:

$$V_j = (h * V_{j-1}) \downarrow 2, \quad (2)$$

где  $V_j$  – коэффициенты аппроксимации ДВП, уровня разложения  $j$ ;  $V_{j-1}$  – коэффициенты аппроксимации уровня разложения  $j-1$ ;  $*$  – оператор полной свертки;  $\downarrow$  – оператор прореживания.

Поскольку квадратурные зеркальные фильтры ДВП на каждом уровне разложения разделяют сигнал на низкочастотную и высокочастотную часть, то полоса частот коэффициентов аппроксимации каждого уровня разложения (по отношению к исходному сигналу) будет находиться в области  $\left[0 : \frac{f_n}{2^j}\right]$ , а полоса частот вейвлет-коэффициентов  $\left[\frac{f_n}{2^j} : \frac{f_n}{2^{j-1}}\right]$ , где  $f_n$  – частота Найквиста (в два раза ниже частоты дискретизации сигнала),  $j$  – уровень разложения. На рис. 3 представлены уровни ДВП в частотной области.

В отличие от непрерывного вейвлет-преобразования, ДВП рассчитывается на масштабах  $2^j$ , где  $j$  называется уровнем разложения, что позволяет рассчитывать ко-



Рис. 3. Представление ДВП в частотной области



эффиценты ДВП быстрее, чем в случае НВП за  $n \log_2(n)$  операций, где  $n$  — длина временного ряда. В силу двукратного прореживания длина сигнала должна быть кратна  $2^{J_{\max}}$ , где  $J_{\max}$  — число уровней разложения.

Также стоит отметить ортогональность вейвлет и масштабирующих фильтров к полиномам заданной степени. Это означает, что если во временном ряде присутствует такой полином, то он будет оставаться в последнем уровне аппроксимации.

### Метод «нейронные облака»

К одним из наиболее быстроразвивающихся и перспективных методов классификации относятся методы на основе машинного обучения. Для обучения классификатора используются лишь данные о нормальном поведении сигнала, данные о видах аномального поведения недоступны. В качестве такого метода в статье рассматривается классификатор «нейронные облака» [20].

Наиболее часто для задач обнаружения аномалий используют различные метрики расстояний (Евклидова, Махаланобиса и др.) [21], методы на основе оценки плотности вероятности данных, например, гауссовские смеси (GMM — Gaussian Mixture Models) [21], которые оценивают плотность вероятности для данных, соответствующих нормальному состоянию. Общий недостаток этих методов состоит в том, что они сами по себе не являются классификаторами, и их выход все равно нужно каким-то образом классифицировать [22]. Также стоит отметить одноклассовый метод опорных векторов (one-class SVM — Support vector machines) [21], недостаток метода заключается в том, что он оценивает четкую границу класса, которую нельзя перенастроить (скорректировать) во время использования классификатора, а можно только при новом переобучении классификатора, что может быть высокзатратно по времени.

«Нейронные облака» оценивают нелинейную, нечеткую функцию принадлежности (инкапсулятор) данных к области нормального поведения, для исходного «нормального» множества признаков. Затем

функция принадлежности используется для оценки принадлежности новых экземпляров данных к области нормального поведения. Выход нейронных облаков — значение от нуля до единицы. Значения, близкие к единице, отражают нормальное поведение, а близкие к нулю — аномальное. Таким образом, «нейронные облака» позволяют давать оценку близости текущего состояния к аномальному, что может использоваться при принятии решения.

Оценка функции принадлежности состоит из двух шагов: кластеризации данных методом АКМ (advanced  $k$ -means, улучшенный  $k$ -средних) и аппроксимации кластеров радиальными базисными функциями (РБФ). Смесь РБФ можно представить в виде нечеткой нейронной сети.

АКМ — это модификации хорошо известного метода  $k$ -средних, с возможностью адаптивного расчета оптимального числа кластеров при заданном максимальном числе кластеров (центроидов).

АКМ состоит из следующих шагов:

1. Задается начальное максимальное и минимальное число центроидов.
2. Вызывается алгоритм  $k$ -средних.
3. Добавляется или убирается центроид, исходя из следующих условий:

если дистанция до данных выше заданной, то создается новый центроид;

если кластер состоит из числа точек, меньше заданного, то он убирается;

если расстояние между центроидами меньше заданного, то кластеры объединяются.

Выход алгоритма АКМ — это центроиды кластеров, представляющих собой нормальное поведение (обучающее множество). После того как все центроиды получены, данные инкапсулируются функцией принадлежности. Для данных задачи используются РБФ, формула (1):

$$R_i = e^{-\frac{|x-m_i|^2}{2\sigma^2}}, \quad (3)$$

где  $m_i$  — среднее (центр) РБФ;  $\sigma$  — СКО (ширина) РБФ;  $x$  — входные данные.

Центроиды, полученные от АКМ, становятся центрами соответствующих РБФ. Сумма всех колоколов дает функцию при-




Рис. 4. «Нейронные облака»:  
 $L_1$  – РБФ;  $L_2$  – суперпозиции РБФ;  $P_c$  – значение функции принадлежности

надлежности (рис. 4). Нормализация применяется для того, чтобы получить выходное значение функции принадлежности в интервале от нуля до единицы.

#### Алгоритм обнаружения аномального состояния дамбы на основе вейвлет-преобразования и одноклассовой классификации одномерных сигналов

Предлагаемый алгоритм основан на одноклассовой классификации результатов частотно-временного преобразования одномерного сигнала. Для частотно-временного преобразования (разложения) сигналов было выбрано дискретное вейвлет-преобразование (ДВП). Для одноклассовой классификации использован метод «нейронные облака». Блок-схема алгоритма обнаружения аномального состояния приведена на рис. 5.

На первом этапе к сигналу с датчика применяется ДВП. Далее выполняет-

ся дополнительная обработка вейвлет-коэффициентов, направленная на расчет локальных СКО (среднеквадратическое отклонение) коэффициентов во времени для каждого уровня разложения, характеризующих мощность каждого уровня.

На втором этапе строится функция принадлежности рассчитанных локальных СКО уровней разложения к области нормального поведения для исходных «нормальных» исторических значений локальных СКО уровней разложения, с использованием метода «нейронные облака».

В итоге, на выходе алгоритма значение изменяется от нуля до единицы, где близость к нулю соответствует аномальному состоянию, а близость к единице соответствует нормальному состоянию.

#### Анализ результатов моделирования алгоритма

В настоящей статье мы будем рассматривать обнаружение реальной аномалии дамбы в городе Бостон (Великобритания). В дамбу была установлена сеть многопараметрических датчиков GeoBeads компании Alert Solutions [23]. Датчики, установленные в дамбу, измеряют поровое давление  $P_p$  (давление воды в порах почвы), температуру почвы и отклонение от вертикали. Расположение датчика показано на рис. 6. Дискретизация данных составляет 15 мин.

Локальное сползание внешнего откоса дамбы в результате эрозии почвы произошло 12 января 2012 г. Аномалия проявилась в поведении сигнала датчика порового давления (рис. 6). Этот датчик был установлен примерно на глубине 2,20 м от поверх-




Рис. 5. Алгоритм обнаружения аномального состояния дамбы на основе вейвлет-преобразования и одноклассовой классификации одномерных сигналов



Рис. 6. Структура одной из кросс-секций дамбы

ности. Далее будет анализироваться сигнал с этого датчика.

Аномальное поведение проявилось как демпфирование дамбой колебаний порового давления, вызванных колебаниями воды (рис. 7 а). Наиболее мощные колебания порового давления вызваны приливами и отливами с периодичностью 12 ч (рис. 7 б). Также в измерениях присутствуют пропуски, вызванные сбоями системы сбора данных или другими факторами. В данных имеются пропуски длительностью от нескольких минут до нескольких дней (рис. 7 а, б). Для обучения и апробации алгоритма в местах пропусков сигналы были восстановлены методом авторегрессии (рис. 7 а, б, светло серый) [12].

Обучающее множество для алгоритма — первые 50 % отсчетов сигналов с 8 августа 2011 г. по 10 ноября 2011 г. Для дискретного вейвлет-преобразования был выбран вейв-

лет Добеши 4, т. к. в уровнях разложения ДВП, полученных с использованием такого вейвлета исключается тренд, описываемый полиномом порядка ниже четвертого [13]. Число уровней разложения — 5 выбрано, чтобы с запасом перекрыть диапазон наиболее мощных частот сигнала.

Для сигнала (рис. 8 а) видно демпфирование колебаний порового давления после 1 января и, как следствие, падение СКО уровней разложения ДВП после 1 января (рис. 8 б), вызванное изменением свойств дамбы, в результате эрозии почвы (рис. 8 а). Значение функции принадлежности на участке после 2 января падает к нулю, что соответствует выходу, что соответствует аномальному состоянию на ее границе функции принадлежности (рис. 8 в). Таким образом, эрозия почвы была обнаружена на 10 дней раньше сползания откоса дамбы. Также присутствует локальный участок 7 декабря (рис. 8 в), в котором значение функции принадлежности падает до 0,1. Данный участок соответствует ложному срабатыванию, вызванному отсутствием подобного поведения в обучающем множестве.

Предложенный подход к мониторингу состояния дамб основан на использовании методов машинного обучения и обработки сигналов. Суть алгоритма заключается в применении одноклассовой классификации алгоритмом «нейронные облака» результатов дискретного вейвлет-преобразования сигналов с датчиков си-




Рис. 7. Сигнал для моделирования:

а — сигнал; б — укрупненный участок сигнала

(—) участки с восстановленными данными; (---) участок с аномальным поведением сигнала




Рис. 8. Результат оценки состояния дамбы:  
а – сигнал; б – локальные СКО уровней ДВП; в – значение функции принадлежности сигнала.  
I – участок с ложным срабатыванием; II – участок с реальной аномалией

стемы контроля состояния дамб. Обучение алгоритма «нейронные облака» проводится на исторических данных о нормальном состоянии дамбы.

Преимущества такого подхода состоят в том, что для его применения не требуется подробного описания структуры объекта и его аномального поведения. Кроме того, система мониторинга на его основе сама подстраивается и обучается с момента установки на объект.

Моделирование алгоритма обнаружения аномального состояния, построенного на основе предлагаемого подхода, проведено на реальных данных дамбы города Бостон (Вели-

кобритания). Сползание откоса дамбы было обнаружено на 10 дней раньше визуального обнаружения как аномальное поведение измерений датчиков порового давления. Преимуществом алгоритма является устойчивый контроль частотно-временных свойств сигнала. К недостаткам можно отнести то, что при отсутствии в обучающих данных некоторых примеров нормального поведения, алгоритм может ложно классифицировать их как аномальное состояние. Увеличение обучающего множества будет вести к улучшению результатов классификации.

Представленный подход и алгоритм могут применяться и в других областях, таких



как системы контроля состояния конструкций, медицинские приложения, системы вибродиагностики и др.

Работа выполнена при поддержке гранта Евросоюза FP7, проект UrbanFlood, грант № 248767.

#### СПИСОК ЛИТЕРАТУРЫ

1. Flood — Data and statistics [электронный ресурс]/ URL: <http://www.preventionweb.net/english/hazards/statistics/> (дата обращения: 01.07.2015).
2. Wohl E. *Inland Flood Hazards: Human, Riparian, and Aquatic Communities*. Cambridge: Cambridge University Press, 2000.
3. Baars S., Kempen M. The Causes and Mechanisms of Historical Dike Failures in the Netherlands // Official Publication of the European Water Association, 2009.
4. FLOODsite project [электронный ресурс]/ URL: <http://www.floodsite.net> (дата обращения: 01.07.2015).
5. FloodControl 2015 [электронный ресурс]/ URL: <http://www.floodcontrol2015.com> (дата обращения: 01.07.2015).
6. UrbanFlood project [электронный ресурс]/ URL: <http://www.urbanflood.eu> (дата обращения: 01.07.2015).
7. Isermann R. Fault-diagnosis systems: an introduction from fault detection to fault tolerance. Berlin: Springer, 2006.
8. Krzhizhanovskaya V.V., Shirshov G.S., Melnikova N.B., Belleman R.G., Rusadi F.I., Broekhuijsen B.J., Gouldby B.P., Lhomme J., Balise B., Bubak M., Pyayt A.L., Mokhov I.I., Ozhigin A.V., Lang B., Meijer R.J. Flood early warning system: design, implementation and computational modules // *Procedia Computer Science*. 2011. Pp. 106–115.
9. Simm J., Jordan D., Topple A., Mokhov I., Pyayt A., Abdoun T., Bennett V., Broekhuijsen J., Meijer R. Interpreting Sensor Measurements in Dikes — Experiences from Urbanflood Pilot Sites // *Comprehensive Flood Risk Management*. 2012.
10. Pyayt A.L., Kozionov A.P., Kuserbaeva V.T., Mokhov I.I., Krzhizhanovskaya V.V., Broekhuijsen B.J., Meijer R.J., Slood P.M.A. Signal analysis and anomaly detection for flood early warning systems // *J. of Hydroinformatics*. 2014. No. 16. Vol. 5. Pp. 1025–1043.
11. Козионов А.П. и др. Вейвлет-преобразование и одноклассовая классификация для мониторинга состояния дамб // Информационно-управляющие системы. 2014. № 4. Т. 71.
12. Козионов А.П., Пяйт А.Л., Мохов И.И., Иванов Ю.П. Исследование алгоритмов восстановления пропусков в измеряемых сигналах для системы мониторинга состояния дамб // Научно-технические ведомости СПбГПУ. Информатика. Телекоммуникации. Управление. 2015. № 2-3. С. 217–222.
13. Anishe S.R., Sharahi M.J. Seismic analysis of Narmab earth dam (Iran) considering dam foundation interaction // *la 78eme congres des grands barrages*. Ханой, 2010.
14. Lennox S.M., Wang Y.G., Darnel R.E., Percival D.B. Wavelet-Based Multiresolution Analysis of Wivenhoe Dam Water Temperatures // *Water resources research*. 2011.
15. Noureldin A., Lucero J.L., Baca Taha T.J., Reda Taha M.M. Wavelet Transform for Structural Health Monitoring: A Compendium of Uses and Features // *J. of Structural Health Monitoring*. 2006. No. 5. Vol. 2.
16. Hesari M.A., Lotfollahi-Yaghin M.A. Using Wavelet Analysis in Crack Detection at the Arch Concrete Dam under Frequency Analysis with FEM // *World Applied Sciences Journal*. 2008.
17. Teymur B., Madabhush, S.P.G., Newland D.E., Haigh S.K. Applications of wavelet analysis to the investigation of the dynamic behaviour of geotechnical structures // *Soil Dynamics and Earthquake Engineering*. 2002.
18. Sadek M., Shahrou I., Parish Y. Numerical analysis of the seismic behavior of earth dam // *Natural Hazards and Earth System Sciences*. 2009.
19. Mallat S. *Wavelet Tour of Signal Processing*. San Diego: Academic Press, 1999.
20. Lang B. et al. Neural Clouds for Monitoring of Complex Systems // *Optical Memory and Neural Networks*. 2008. No. 3. Vol. 17. Pp. 183–192.
21. Bishop C. *Pattern Recognition and Machine Learning*. New York: Springer, 2006.
22. Yousri N.A., Ismael M.A., Kamel M.S. Fuzzy Outlier Analysis a Combined Clustering-outlier Detection Approach // *Systems, Man and Cybernetics*. 2007. Pp. 412–418.
23. Alert Solutions [электронный ресурс]/ URL: <http://www.alertsolutions.nl/?> (дата обращения: 01.07.2015).

#### REFERENCES

1. Flood — Data and statistics. Available: <http://www.preventionweb.net/english/hazards/statistics/> (Accessed: 01.07.2015).
2. Wohl E. *Inland Flood Hazards: Human, Riparian, and Aquatic Communities*. Cambridge: Cambridge University Press, 2000.

3. **Baars S., Kempen M.** The Causes and Mechanisms of Historical Dike Failures in the Netherlands. *Official Publication of the European Water Association*, 2009.
4. **FLOODsite project.** Available: <http://www.floodsite.net/> (Accessed: 01.07.2015).
5. **FloodControl 2015.** Available: <http://www.floodcontrol2015.com> (Accessed: 01.07.2015).
6. **UrbanFlood project.** Available: <http://www.urbanflood.eu> (Accessed: 01.07.2015).
7. **Isermann R.** *Fault-diagnosis systems: an introduction from fault detection to fault tolerance.* Berlin: Springer, 2006.
8. **Krzhizhanovskaya V.V., Shirshov G.S., Melnikova N.B., Belleman R.G., Rusadi F.I., Broekhuijsen B.J., Gouldby B.P., Lhomme J., Balise B., Bubak M., Pyayt A.L., Mokhov I.I., Ozhigin A.V., Lang B., Meijer R.J.** Flood early warning system: design, implementation and computational modules. *Procedia Computer Science*, 2011, Pp. 106–115.
9. **Simm J., Jordan D., Topple A., Mokhov I., Pyayt A., Abdoun T., Bennett V., Broekhuijsen J., Meijer R.** Interpreting Sensor Measurements in Dikes – Experiences from Urbanflood Pilot Sites. *Comprehensive Flood Risk Management*, 2012.
10. **Pyayt A.L., Kozionov A.P., Kuserbaeva V.T., Mokhov I.I., Krzhizhanovskaya V.V., Broekhuijsen B.J., Meijer R.J., Sloot P.M.A.** Signal analysis and anomaly detection for flood early warning systems [Wavelet Transform and One-Class Classification for Dike Health Monitoring], *Journal of Hydroinformatics*, 2014, No. 16, Vol. 5, Pp. 1025–1043.
11. **Kozionov A.P. i dr.** Veyvlet-preobrazovaniye i odnoklassovaya klassifikatsiya dlya monitoringa sostoyaniya damb [Wavelet Transform and One-Class Classification for Dike Health Monitoring], *Informatsionno-upravlyayushchiye sistemy [Information and Control Systems]*, 2014, Vol. 71, No. 4. (rus)
12. **Kozionov A.P., Pyayt A.L., Mokhov I.I., Ivanov Yu.P.** Issledovaniye algoritmov vosstanovleniya propuskov v izmeryayemykh signalakh dlya sistemy monitoringa sostoyaniya damb [Research on Gap-filling Algorithms for Dike Health Monitoring Systems]. *Nauchno-tekhnicheskiye vedomosti SPbGPU. Informatika. Telekommunikatsii. Upravleniye [St. Petersburg State Polytechnical University Journal. Computer Science. Telecommunication and Control]*. St. Petersburg, 2015, No. 2-3 (217-222), Pp. 217–222. (rus)
13. **Anishe S.R., Sharahi M.J.** Seismic analysis of Narmab earth dam (Iran) considering dam foundation interaction. *la 78eme congres des grands barrages*, Khanoy, 2010.
14. **Lennox S.M., Wang Y.G., Darnel R.E., Percival D.B.** Wavelet-Based Multiresolution Analysis of Wivenhoe Dam Water Temperatures. *Water resources research*, 2011.
15. **Noureldin A., Lucero J.L., Baca Taha T.J., Reda Taha M.M.** Wavelet Transform for Structural Health Monitoring: A Compendium of Uses and Features. *Journal of Structural Health Monitoring*, 2006, No. 5, Vol. 2.
16. **Hesari M.A., Lotfollahi-Yaghin M.A.** Using Wavelet Analysis in Crack Detection at the Arch Concrete Dam under Frequency Analysis with FEM. *World Applied Sciences Journal*, 2008.
17. **Teymur B., Madabhush S.P.G., Newland D.E., Haigh S.K.** Applications of wavelet analysis to the investigation of the dynamic behaviour of geotechnical structures. *Soil Dynamics and Earthquake Engineering*, 2002.
18. **Sadek M., Shahrou I., Parish Y.** Numerical analysis of the seismic behavior of earth dam. *Natural Hazards and Earth System Sciences*, 2009.
19. **Mallat S.** *Wavelet Tour of Signal Processing*, San Diego: Academic Press, 1999.
20. **Lang B. et al.** Neural Clouds for Monitoring of Complex Systems. *Optical Memory and Neural Networks*, 2008, No. 3, Vol. 17, Pp. 183–192.
21. **Bishop C.** *Pattern Recognition and Machine Learning*. New York: Springer, 2006.
22. **Yousri N.A., Ismal M.A., Kamel M.S.** Fuzzy Outlier Analysis a Combined Clustering-outlier Detection Approach. *Systems, Man and Cybernetics*, 2007, Pp. 412–418.
23. **Alert Solutions.** Available: <http://www.alertsolutions.nl/?> (Accessed: 01.07.2015).

---

**КОЗИОНОВ Алексей Петрович** — аспирант кафедры аэрокосмических измерительно-вычислительных комплексов Института аэрокосмических приборов и систем Санкт-Петербургского государственного университета аэрокосмического приборостроения; инженер ООО «Сименс».

191186, Россия, Санкт-Петербург, Волынский пер., д. 3а.

E-mail: alexey.kozionov@gmail.com

**KOZIONOV Alexey P.** *St. Petersburg State University of Aerospace Instrumentation; Siemens.*

191186, Volynskii Lane 3a, St. Petersburg, Russia.

E-mail: alexey.kozionov@gmail.com



**ПЯЙТ Александр Леонидович** — *ведущий инженер ООО «Сименс», кандидат технических наук.*  
191186, Россия, Санкт-Петербург, Волынский пер., д. 3а.  
E-mail: alexander.pyayt@siemens.com

**PYAYT Alexander L.** *Siemens.*  
191186, Volynskii Lane 3a, St. Petersburg, Russia.  
E-mail: alexander.pyayt@siemens.com

**МОХОВ Илья Игоревич** — *ведущий эксперт-исследователь ООО «Сименс»*  
191186, Россия, Санкт-Петербург, Волынский пер., д. 3а.  
E-mail: ilya.mokhov@siemens.com

**МОКHOV Илья I.** *Siemens.*  
191186, Volynskii Lane 3a, St. Petersburg, Russia.  
E-mail: ilya.mokhov@siemens.com

**ИВАНОВ Юрий Павлович** — *доцент кафедры аэрокосмических измерительно-вычислительных комплексов Института аэрокосмических приборов и систем Санкт-Петербургского государственного университета аэрокосмического приборостроения, кандидат технических наук.*  
190000, Россия, Санкт-Петербург, ул. Б. Морская, д. 61.  
E-mail: upi@mail.ru

**IVANOV Yuri P.** *St. Petersburg State University of Aerospace Instrumentation.*  
190000, Bolshaya Morskaya Str. 67, St. Petersburg, Russia.  
E-mail: upi@mail.ru